



دانشگاه کاشان
University of Kashan

مجله محاسبات نرم
SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



فناوری ماشین‌بینایی در کشاورزی دقیق: مروری جامع بر اصول و کاربردها[✦]

مرضیه قربانی^۱، دانشجوی دکتری، محمد ابونجمی^{۱*}، دانشیار، کیوان آصف‌پور و کیلیان^۲، استادیار

^۱ گروه مهندسی فنی کشاورزی، پردیس ابوریحان، دانشگاه تهران، تهران، ایران.

^۲ گروه مهندسی مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران.

اطلاعات مقاله

چکیده

تاریخچه مقاله:

دریافت ۳۰ تیر ماه ۱۳۹۹

پذیرش ۲۳ اسفند ماه ۱۳۹۹

کلمات کلیدی:

ماشین‌بینایی

کشاورزی دقیق

استخراج ویژگی

مدیریت موضعی

کنترل علف هرز

رشد جمعیت جوامع و ارتقای سطح زندگی، لزوم بهره‌گیری از روش‌های جدید به‌منظور تهیه مواد غذایی سالم و با کیفیت را پدید آورده است. با توجه به توسعه چشمگیر روش‌های پردازش تصویر و ماشین‌بینایی، تحقیقات بسیاری به‌منظور ارائه یک راه‌حل مبتنی بر پردازش تصویر در مسائل مختلف و رو به رشد کشاورزی دقیق ارائه شده است. در حال حاضر، محققین به‌طور گسترده از پردازش تصویر برای هوشمندسازی بخشی از مراحل مختلف زراعت و باغبانی، از جمله کاشت، کنترل علف‌های هرز، آبیاری، سمپاشی، کودپاشی، بررسی روند رشد گیاه و برداشت محصول استفاده کرده‌اند. این روش‌های هوشمندسازی در بخش کشاورزی علاوه بر کاهش هزینه‌های تولید و نهاده‌های کشاورزی، اثرات چشم‌گیری نیز در حفظ منابع آب و محیط زیست ایفا می‌کنند. در این بررسی مروری، روش‌های مبتنی بر پردازش تصویر که تاکنون برای هوشمندسازی کنترل علف‌های هرز و مدیریت موضعی سمپاشی و آبیاری معرفی شده‌اند، مورد بررسی قرار گرفته‌اند. همچنین تلاش شده است تا عملکرد هر روش به‌همراه مزایا و معایب آن بررسی شود. در نهایت، چشم‌انداز آینده کاربردهای پردازش تصویر در حوزه‌های مورد بررسی کشاورزی دقیق ترسیم شده است.

© ۱۳۹۹ - مجله محاسبات نرم، کلیه حقوق محفوظ است.

۱. مقدمه

که اطلاعات آن موجود است، نهاده‌ها را توزیع می‌کند [۲]. کشاورزی دقیق به متغیرهای مؤثر بر رشد محصول اشاره دارد و از اعمال شیوه‌های مدیریتی یکسان به تمام محصولات بدون در نظر گرفتن شرایط مکانی و زمانی آن‌ها جلوگیری به‌عمل می‌آورد. مزایای استفاده از مدیریت خاص مکانی، کاهش هزینه تولید محصول و آلودگی‌های زیست‌محیطی است [۳ و ۴].

در دهه‌های اخیر، کاهش استفاده از علف‌کش‌ها و آفت‌کش‌ها در کشاورزی، از اهداف اصلی سیاست جهان به‌ویژه اتحادیه اروپا بوده است. علف‌کش‌های شیمیایی نقش مهمی در

کشاورزی دقیق^۱، نوعی از کاربرد فن‌آوری و مفاهیم اساسی را ترسیم می‌کند که با در نظر گرفتن تمام جنبه‌ها و رعایت مسائل زیست‌محیطی برای رسیدن به تولید مناسب، تغییرات مکانی و زمانی را مدیریت [۱] و براساس نیاز واقعی هر بخش از مزرعه

✦ نوع مقاله: مروری

* نویسنده مسئول


پست‌های الکترونیک: marzie.ghorbani@ut.ac.ir (قربانی)

abonajmi@ut.ac.ir (ابونجمی)

keyvan.asefpoor@gau.ac.ir (آصف‌پور و کیلیان)

¹ Precision Agriculture

محصولات صنایع غذایی مقوله‌های دیگری هستند که پیش از این به‌طور گسترده مورد بررسی محققین قرار گرفته‌اند.



شکل (۱): تعداد اسناد مربوط به استفاده از پردازش تصویر در بخش‌های مختلف تولید محصول زراعی یا باغی نمایه شده در پایگاه اسکوپوس

بر اساس شکل (۱)، استفاده از پردازش تصویر در کنترل علف‌هرز مورد توجه محققین بوده است. پس از آن، تحقیقات در زمینه برداشت سهم دوم را دارد. این موضوع قابل پیش‌بینی بود، زیرا اغلب سامانه‌های رباتیکی معرفی شده برای برداشت محصولات کشاورزی دارای یک واحد پردازش تصویر به‌عنوان مرکز تصمیم‌گیری هستند [۱۴ و ۱۵]. پس از آن نیز تحقیقات در زمینه استفاده از پردازش تصویر در سمپاشی و آبیاری در جایگاه‌های بعدی قرار دارند.

در سال‌های اخیر، مقالات مروری متعددی در حوزه کاربردهای پردازش تصویر در برداشت محصولات کشاورزی در داخل و خارج از کشور منتشر شده است. اما بررسی پایگاه‌های اطلاعاتی و کتابخانه‌ای نشان می‌دهد که یک تحقیق جامع درباره پیشرفت‌های اخیر در زمینه کاربرد پردازش تصویر در کنترل علف‌های هرز و مدیریت موضعی سمپاشی و آبیاری در دسترس نیست.

در این مطالعه مروری، روش‌ها و الگوریتم‌های پردازش تصویر معرفی شده در سامانه‌های کنترل علف‌های هرز و مدیریت موضعی سمپاشی و آبیاری مورد بررسی قرار گرفته و مزایا و معایب آن‌ها ارائه شده و در نهایت، یک جمع‌بندی و نتیجه‌گیری کلی به‌همراه چشم‌انداز آینده کشاورزی دقیق آورده شده است.

آلودگی زیست‌محیطی [۶ و ۷]، هزینه‌های تولید محصولات کشاورزی و نگرانی‌های عمومی در مورد سلامت محصولات ایفا می‌کنند [۷-۹]. مدیریت خاص مکانی علف‌های هرز با استفاده از فن‌آوری نرخ متغیر، یکی از وسیع‌ترین فن‌آوری‌های مورد استفاده در کشاورزی دقیق است [۱۰]. در این فن‌آوری، نهاده‌های کشاورزی مانند کود، آفت‌کش و دیگر مواد شیمیایی بر اساس نیاز هر بخش از مزرعه، مورد استفاده قرار می‌گیرند. از زمان آغاز کشاورزی دقیق، جمع‌آوری اطلاعات بصری به روش‌های مختلفی انجام شده است که وابستگی زیادی به فن‌آوری موجود در هر دوره زمانی دارد. تصاویر مورد استفاده برای جمع‌آوری اطلاعات را می‌توان به سه گروه اصلی عکس‌های هوایی، تصاویر ماهواره‌ای و تصاویر ثبت‌شده در سطح زمین تقسیم‌بندی کرد [۱۱-۱۳]. پردازش تصویر در کشاورزی دقیق، به استخراج ویژگی‌هایی که می‌توانند برای هوشمندسازی بخشی از مراحل مختلف زراعت و باغبانی استفاده شوند، منجر می‌شود. این مراحل شامل کاشت، داشت، برداشت و پس از برداشت می‌شوند. در هر یک از این مراحل می‌توان از هر سه گروه تصویر نام‌برده در بالا بهره گرفت.

شکل (۱) نمودار تعداد اسناد مربوط به استفاده از فن‌آوری‌های جدید در بخش‌های مختلف تولید محصول زراعی یا باغی که در سال‌های بین ۲۰۰۰ تا ۲۰۱۹ در پایگاه اسکوپوس^۱ نمایه شده و دارای کلیدواژه‌های «پردازش تصویر» و یا «ماشین‌بینایی» هستند، را نشان می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، بیش از ۲۵۰۰ سند علمی به‌طور مستقیم به کاربرد پردازش تصویر و ماشین‌بینایی در مراحل مختلف تولید محصول کشاورزی اختصاص یافته‌اند. در حال حاضر، برخی از این روش‌ها از محیط آزمایشگاهی خارج شده و به‌صورت میدانی مورد استفاده قرار گرفته و یا به‌طور تجاری در دسترس هستند.

باید توجه داشت که شکل (۱) تنها شامل تحقیقات مربوط به مراحل تولید محصولات زراعی و باغی می‌شوند. کاربرد پردازش تصویر در تولید محصولات دامی و کیفیت‌سنجی

¹ Scopus

۲. روش‌شناسی

داشت؛ به طوری که به دلیل ارتفاع، هر پیکسل نماینده بیش از یک متر مربع بود. با پیشرفت فن‌آوری، تمایل به روش‌های تشخیص علف‌های هرز با دقت‌های زیر سانتیمتر به وجود آمد. در راستای تحقق این اهداف، فن‌آوری‌های پردازش تصویر و ماشین‌بینایی در این حوزه گسترش یافت و تصاویر از ارتفاع‌های کمتر از سه متر توسط تراکتور، ربات‌های کشاورز و یا به سادگی توسط دست از سطح زمین گرفته شدند [۱۹].

در ادامه، به دلیل در دسترس قرار گرفتن واحدهای پردازش ارزان قیمت، استفاده از تصویر در کنترل علف‌های هرز در دو دهه اخیر به طور فزاینده‌ای پیشرفت کرد و برخی از این سامانه‌ها در حال حاضر روی تراکتورهای تجاری نسل جدید قرار دارند [۲۰].

۳.۲. مراحل شناسایی و کنترل علف‌های هرز

در روش‌های کنترل علف‌هرز مبتنی بر پردازش تصویر، عموماً یک حسگر روی تراکتور یا ربات حرکت‌کننده در زمین زراعی و یا گلخانه قرار داده می‌شود که می‌تواند تصاویری را در ناحیه طیفی مرئی و یا طیف‌های دیگر از زمین کشاورزی ثبت کند. این تصاویر ممکن است به صورت برخط پردازش شده تا محل قرارگیری علف‌های هرز در مزرعه را به صورت لحظه‌ای تعیین کنند (روش اول)، و یا اینکه تصاویر روی یک حافظه جانبی ذخیره شده و پس از اتمام حرکت تراکتور و یا ربات در مزرعه مورد پردازش قرار گیرند (روش دوم).

روش اول، روش حسگر مبتنی [۲۱] نام دارد که در این حالت، ادواتی مانند وجین‌کن‌های مکانیکی و یا سامانه کنترل پاشش علف‌کش نرخ متغیر نیز روی تراکتور یا ربات قرار دارند. پس از پردازش برخط تصاویر ثبت شده و تعیین محل قرارگیری علف‌های هرز، از یک کارانداز برای به‌کار انداختن وجین‌کن یا پاشنده علف‌کش به‌منظور دفع علف‌های هرز استفاده می‌شود [۲۲].

به منظور جمع‌آوری مقالات مورد استفاده در این مطالعه، کلمات کلیدی «ماشین‌بینایی» و «پردازش تصویر» در کنار کلمات «کشاورزی دقیق»، «گلخانه هوشمند»، «مزرعه هوشمند»، «مدیریت موضعی»، «کنترل علف هرز»، و «سمپاشی مزرعه» در پایگاه‌های وب‌آوساینس^۱، اسکوپوس، و گوگل اسکالر^۲ مورد جستجو قرار گرفت و مقالات یافته شده ذخیره شدند. در ادامه، مقالاتی که منجر به نوآوری نشده و یا در مجلات کم‌اعتبار منتشر شده بودند، از مجموعه حذف شدند. در نهایت، مقالات بر اساس تأثیر بر سایر محققان و تعداد ارجاعات با توجه به سال انتشار مرتب شده و مورد مطالعه و بررسی دقیق قرار گرفتند.

۳. کاربرد پردازش تصویر در کنترل علف‌های هرز

در ادامه به بررسی کاربردهای پردازش تصویر در کنترل علف‌های هرز پرداخته شده است.

۳.۱. پیشینه استفاده از تصاویر در کنترل علف‌های هرز


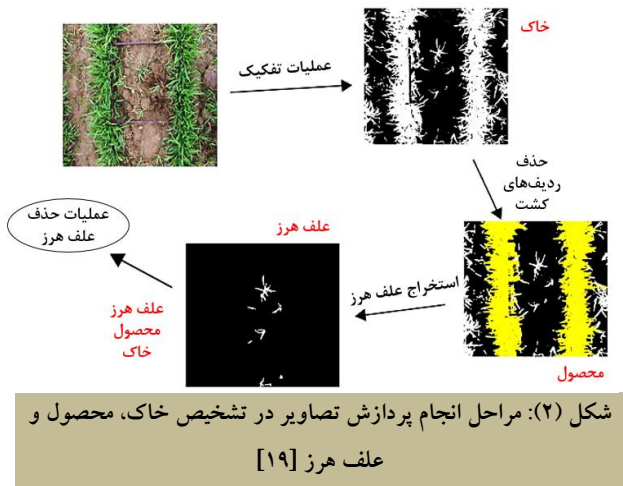
نخستین بار در سال ۱۹۸۰ میلادی از یک هوایمای مجهز به دوربین مادون قرمز نزدیک (NIR) برای استخراج نقشه تقریبی توزیع علف‌های هرز به کمک پردازش تصاویر استفاده شد [۱۶ و ۱۷]. سپس در اوایل دهه ۱۹۹۰ میلادی سامانه موقعیت‌یاب جهانی (GPS) برای کاربردهای تجاری ظهور پیدا کرد و استفاده غیرنظامی از ماهواره‌ها آغاز شد. استفاده از این سامانه‌ها به دلیل کاربرد تصاویر تنها در شرایط آب و هوایی مناسب، پرهزینه و دشوار بود و همچنین به دلیل فاصله از سطح زمین، تصاویر دقت بالایی نداشتند. در اواسط دهه ۱۹۹۰ میلادی، با ظهور رایانه‌های پیشرفته و تجزیه و تحلیل مستقیم عکس و دوربین‌های چندوجهی، سرعت ثبت و پردازش تصاویر هوایی بهبود یافت [۱۸]؛ اما همچنان معایب مشخصی از قبیل هزینه‌های اقتصادی بالا و وضوح پایین تصاویر وجود

¹ Web of Science

² Google Scholar

³ Sensor-Based

حل ساده نبوده و تبعیض بین محصولات زراعی، علف‌های هرز و پس‌زمینه کار پیچیده‌ای است. شکل (۳) روند عمومی تشخیص علف‌هرز مبتنی بر پردازش تصویر را نشان می‌دهد.



شکل (۳): روند عمومی تشخیص علف‌هرز مبتنی بر پردازش تصویر

تقریباً تمام روش‌های شناسایی علف‌های هرز، مستقل از نوع محصول تحت بررسی، در روش قطعه‌بندی^۳ پوشش گیاهی از پس‌زمینه مشترک هستند [۲۸ و ۲۹]. روش‌های طبقه‌بندی پیکسل‌های پوشش گیاهی معمولاً بر مبنای این واقعیت استوارند که تمام پیکسل‌های متعلق به پوشش گیاهی دارای یک مؤلفه سبز قوی هستند و این ویژگی را می‌توان به‌طور مستقیم از طریق مدل رنگ RGB یا شاخص‌های رنگی که سبز بودن یک پیکسل را نشان می‌دهند، بدست آورد [۳۰-۳۴]. از رویکردهای دیگر، استفاده از مدل رنگ HSI همراه با روش‌های طبقه‌بندی^۴ به کمک شبکه‌های بیزی^۵ یا خوشه‌بندی^۶ خوشه‌بندی^۶ است [۳۵-۳۷]. قطعه‌بندی نیز می‌تواند با انتخاب

روش دوم، روش نقشه‌مبنا^۱ [۲۳] نام دارد که در آن، علف‌های هرز در همان لحظه حرکت تراکتور و یا ربات در مزرعه از بین نمی‌روند، بلکه تصاویر پس از پردازش منجر به تشکیل یک نقشه از مزرعه که در آن محل علف‌های هرز تعیین شده است، می‌شوند. پس از استخراج نقشه، ممکن است در آینده از یک ربات یا تراکتور مجهز به وجین‌کن‌های مکانیکی و یا سامانه کنترل پاشش علف‌کش نرخ متغیر برای دفع علف‌های هرز استفاده شود. باید توجه داشت که یک سامانه موقعیت‌یاب جهانی افتراقی^۲ (DGPS) باید به‌هنگام تصویربرداری و یا دفع علف‌های هرز روی تراکتور یا ربات برای ثبت موقعیت آن قرار داشته باشد [۲۴].

تصاویر می‌توانند به کمک دوربین‌های مرئی تجاری برای ثبت باندهای قرمز - سبز - آبی (RGB) با دامنه طیفی ۴۰۰ تا ۷۰۰ نانومتر [۲۵] و یا آرایه‌های فوتودیود برای ثبت تصاویر چندطیفی و ابرطیفی با دامنه طیفی گسترده (به‌طور مثال از ۲۰۰ تا ۱۰۰۰۰ نانومتر) ثبت شوند [۲۶ و ۲۷].

فرآیند پردازش تصویر در هر دو روش حسگرمبنا و نقشه‌مبنا یکسان بوده و از یک الگوریتم کارآمد برای تعیین محل قرارگیری علف‌های هرز روی ردیف کشت و یا بین ردیف‌های کشت بهره گرفته می‌شود.

به‌طور کلی، می‌توان پردازش تصویر را در سه مرحله مختلف شامل تقسیم‌بندی تصویر به پوشش گیاهی در مقابل غیرگیاهی (شناسایی خاک)، حذف ردیف محصول (شناسایی محصول) و استخراج علف‌های هرز (شناسایی علف‌هرز) انجام داد [۱۹]. یک نمونه از این پردازش تصویر در شکل (۲) نشان داده شده است.

با توجه به تفاوتی که در محصولات مختلف و علف‌های هرز آن‌ها با یکدیگر وجود دارد، روش‌های متفاوتی برای تمایز محصول و علف هرز در تصاویر توسعه یافته‌اند. به‌دلیل تغییر شرایط نوری، رطوبت، مراحل رشد پوشش گیاهی و شباهت علف‌های هرز و محصولات به یکدیگر، مسئله دارای یک راه-

³ Segmentation

⁴ Classification

⁵ Bayesian

⁶ Clustering

¹ Map-Based

² Differential Global Positioning System

جدول (۱): مدل‌های رنگی متداول شامل باندهای رنگی و ویژگی‌های قابل تعریف در هر باند [۴۱]

تبدیل از RGB	کانال	مدل رنگی
$r = R/(R + G + B)$	R	rgb
$g = G/(R + G + B)$	G	
$b = B/(R + G + B)$	B	
$X = 0.607R + 0.174G + 0.200B$	X	XYZ
$Y = 0.299R + 0.587G + 0.114B$	Y	
$Z = 0.066G + 1.116B$	Z	
$V = M$ $M = \max\{R, G, B\}$ $m = \min\{R, G, B\}$ $p = 60m/M$ $S = (M - m)/M$	V	HSV
$H = \begin{cases} p(G - B) & \text{if } M = R \\ 120 + p(B - R) & \text{if } M = G \\ 240 + p(R - G) & \text{if } M = B \end{cases}$	H	
$L = (M + m)/2$	L	HLS
$S = (M - m)/\min\{M + m, 2 - M - m\}$	S	
$L^* = \begin{cases} 116Y^{1/3} & \text{if } Y > k \\ 903.3Y & \text{if } Y \leq k \end{cases}$ $k = 0.0089$	L*	L*a*b*
$a^* = 500(f(X) - f(Y))$ $f(t) = \begin{cases} t^{1/3} & \text{if } t > k \\ 7.787t + 0.1379 & \text{if } t \leq k \end{cases}$	a*	
$b^* = 200(f(Y) - f(Z))$	b*	
$u^* = 13L^*(4X/(X + 15Y + 3Z) - 0.197939)$	u*	L*u*v*
$v^* = 13L^*(9Y/(X + 15Y + 3Z) - 0.468311)$	v*	
$Cr = 0.713(R - Y) + 128$	Cr	YCrCb
$Cb = 0.564(B - Y) + 128$	Cb	
$U = -0.14713R - 0.28886G + 0.436B$	U	YUV
$V = 0.615R - 0.51499G - 0.10001B$	V	
$T = \arctan2(r', g')$ $r' = r - 1/3$ $g' = g - 1/3$	T	TSL
$S = [9/5(r'^2 + g'^2)]^{1/2}$	S	
$L = Y$	L	
$I1 = 1/3(R + G + B)$	I1	III1I3
$I2 = 1/2(R - B)$	I2	
$I3 = 1/4(2G - R - B)$	I3	

ویژگی‌های بافت و شباهت‌های آن با مدل‌های قبلی در یک پایگاه داده ذخیره شود [۳۸ و ۳۹] و یا با ترکیبی از دوربین‌های مختلف، مانند دوربین‌های معمولی و NIR انجام شود [۴۰]. برای شناسایی ویژگی‌های سودمند در قطعه‌بندی تصاویر و ایجاد تمایز میان پوشش گیاهی و پیش‌زمینه تصویر، ابتدا لازم است مدل‌های رنگی متداول شامل باندهای رنگی و ویژگی‌های قابل تعریف در هر باند و همچنین نحوه محاسبه آن‌ها را در دست داشت. این اطلاعات به صورت خلاصه در جدول (۱) آورده شده است [۴۱].

تحقیقات نشان داده است که اغلب این ویژگی‌ها در شرایط نوری طبیعی مزارع عملکرد قابل توجهی دارند. این عملکرد در صبح و یا بعدازظهر که سایه محصول کم‌رنگ‌تر می‌شود، افزایش می‌یابد [۴۲]. در جدول ۲، ویژگی‌های سودمند در قطعه‌بندی تصاویر و ایجاد تمایز میان پوشش گیاهی و پیش‌زمینه تصویر آورده شده است. مشاهده می‌شود که بسیاری از این ویژگی‌ها در فضای رنگی RGB یا rgb (که در جدول (۱) تعریف شد) قابل بیان هستند. این موضوع نشان می‌دهد که تصویر مورد نیاز برای قطعه‌بندی جهت استخراج پوشش گیاهی به کمک یک دوربین مرئی تجاری قابل دسترس و یا حتی دوربین موجود در گوشی‌های تلفن همراه هوشمند قابل ثبت است. برخی از این ویژگی‌های رنگی تفاوت‌های ناچیزی در تعریف با یکدیگر دارند. با این حال، تحقیقات نشان داده است که این ویژگی‌ها مؤثرترین ویژگی‌ها در تفکیک میان خاک کشاورزی و پوشش گیاهی هستند. در برخی از مطالعات، از چندین ویژگی به طور همزمان بهره گرفته شده است تا عملکرد روش بهبود یابد [۶۷].

برخی از ویژگی‌های نشان داده شده در جدول (۲) مانند GMR، ERI، EGI و EBI در سال‌های اخیر معرفی شده و به عنوان ویژگی‌های کارآمد در تشخیص بافت گیاهی به کمک پردازش تصویر در مزارع کشاورزی مورد استفاده قرار گرفته‌اند [۶۵ و ۶۶]. از این ویژگی‌ها در مسائل سنجش از دور برای تفکیک و قطعه‌بندی زمین‌های کشاورزی نیز استفاده شده است.

جدول (۲): ویژگی‌های متداول رنگی برای استخراج پوشش گیاهی از پیش‌زمینه تصویر

منبع	روش محاسبه	فضای رنگی	شرح ویژگی	ویژگی رنگی
[۴۳]	$NDI = 128 \times \left(\left(\frac{G-R}{G+R} \right) + 1 \right)$	RGB	اندیس تفاضلی نرمالیزه	NDI
[۴۶-۴۴]	$ExG = 2G - R - B$	RGB	اندیس سطح اضافه سبز	ExG
[۴۸ و ۴۷]	$EG = 2G - R - B + 127$	RGB	سطح اضافه سبز	EG
[۴۹]	$ExR = 1.3R - G$	RGB	اندیس سطح اضافه قرمز	ExR
[۵۱ و ۵۰]	$CIVE = 0.441R - 0.811G + 0.385B + 18.78745$	RGB	اندیس رنگی استخراج پوشش گیاهی	CIVE
[۵۳ و ۵۲]	$ExGR = ExG - ExR$	RGB	اندیس تفاضل سبز و قرمز اضافه	ExGR
[۵۴]	$NGRDI = \frac{G-R}{G+R}$	RGB	اندیس تفاضل سبز و قرمز نرمالیزه	NGRDI
[۵۵]	$VEG = \frac{G}{R^{2/3} B^{1/3}}$	RGB	اندیس پوشش گیاهی	VEG
[۵۶]	$MExG = 1.262G - 0.884R - 0.311B$	RGB	اندیس سطح اضافه سبز اصلاح شده	MExG
[۵۹]	$NEG = 2.8G - R - B$	RGB	سطح اضافه سبز نرمالیزه	NEG
[۶۰]	$GMR = G - R$	RGB	سطح سبز منهای قرمز	GMR
[۶۱]	$COM = ExG + CIVE + ExGR + VEG$	RGB	اندیس ترکیبی	COM
[۶۲]	$GPC = 2G - R \times G - B$	RGB	اندیس پیکسل‌های سبز	GPC
[۶۶-۶۳]	$NDVI = \frac{NIR - R}{NIR + R}$	RGB-NIR	اندیس پوشش گیاهی تفاضلی نرمالیزه	NVDI
[۶۸ و ۶۷]	$GB = g - b$	RGB	پارامتر g منهای b	GB
[۶۸ و ۶۷]	$RBI = \frac{r - b}{r + b}$	RGB	-	RBI
[۶۸ و ۶۷]	$ERI = (r - g) \times (r - b)$	RGB	-	ERI
[۶۸ و ۶۷]	$EGI = (g - r) \times (g - b)$	RGB	-	EGI
[۶۸ و ۶۷]	$EBI = (b - g) \times (b - r)$	RGB	-	EBI

در دو محصول هویج و کلم، علف‌های هرز دارای تفاوت‌های زیادی در رنگ و اندازه هستند که می‌توانند با استفاده از روش‌های افتراق^۱ [۳۵] یا تفاوت در بازتاب‌های طیفی شناسایی شوند [۷۰].

در مطالعه‌ای احتمال تمایز گیاهان نیشکر از علف‌های هرز را با رفتار طیفی برگ‌ها بررسی کردند. آن‌ها عملکرد دو روش مدل سازی SIMCA^۲ (مدل سازی مستقل نرم با مقایسه طبقه) و الگوریتم RF^۳ (جنگل تصادفی) را با هم مقایسه کردند.

پس از آنکه پوشش گیاهی از پیش‌زمینه جدا شد، لازم است پیکسل‌های گیاهی مربوط به علف‌های هرز مشخص شوند. تشخیص علف‌های هرز معمولاً با استخراج اطلاعات مربوط به رنگ، موقعیت، شکل، بافت، اندازه و یا طیف بازتاب علف‌های هرز انجام می‌شود. استفاده از یک یا تعدادی از خصوصیات مذکور، به عواملی از قبیل تصاویر گرفته شده، نوع محصول و گونه‌های علف هرز بستگی دارد. به‌عنوان مثال در صیفی‌جات، گیاهان و علف‌های هرز می‌توانند با تفاوتی که در اندازه و موقعیت دارند، به‌وضوح مشخص شوند، زیرا اندازه صیفی‌جات بسیار بزرگتر از علف‌های هرز است [۳۶].

^۱ Discrimination

^۲ Soft Independent Modelling by Class Analogy

^۳ Random Forest

ویژگی منحصر به فرد برای تمایز بین علف‌هرز و محصول کافی نیست و مطالعات پیچیده‌تری از ویژگی‌های علف‌هرز ضروری است.

جدول (۳) برخی از ویژگی‌های متداول رنگی در تمایز بین محصول و علف‌های هرز را نشان می‌دهد. این ویژگی‌ها به‌طور گسترده در مزارع محصولات مختلف مورد آزمون قرار گرفته و منجر به نتایج قابل قبولی شده‌اند. این ویژگی‌ها در بسیاری از تحقیقات اخیر روی محصولات مختلف کشاورزی مورد استفاده قرار گرفته‌اند. به نظر می‌رسد که ویژگی‌های رنگی در مقایسه با ویژگی‌های ریخت‌شناسی و بافت، بیشتر مورد توجه محققین بوده است.

در یکی از تحقیقات، یک سامانه پاشش علف‌کش موضعی بین ردیفی بر مبنای ماشین‌بینایی طراحی و ارزیابی شده است [۷۸]. در این آزمایش، از ویژگی ExG برای محاسبه نسبت پوشش علف‌هرز و جداسازی گیاه از خاک استفاده شد. نتایج نشان داد که به‌طور متوسط، پاشش موضعی هدفمند، ۷۵ درصد مصرف علف‌کش کمتری نسبت به پاشش معمول داشت، در حالیکه هر دو پاشش از لحاظ ریشه‌کنی علف‌های هرز یکسان عمل کردند تحقیقات زیادی را می‌توان یافت که با استفاده همزمان از ویژگی‌های رنگی RGB و NDVI دقت مناسبی را در تمایز میان محصول کشاورزی و علف‌هرز گزارش کرده‌اند [۷۵].


۳.۴. ویژگی‌های ریخت‌شناسی شناسایی علف‌های هرز

برای گیاهان، ریخت‌شناسی زیستی به‌عنوان شکل و ساختار یک گیاه و یا یکی از قسمت‌های آن تعریف می‌شود [۷۹]. خصوصیات ریخت‌شناسی، به‌ویژه ویژگی‌های شکل، نقش مهمی در شناسایی گونه‌های گیاهی توسط یک فرد خبره دارند، بنابراین می‌توانند در تجزیه و تحلیل تصویر برای تشخیص علف‌های هرز نیز استفاده شوند [۸۰ و ۸۱]. از ویژگی‌های مختلف شکل برای پردازش تصاویر کشاورزی استفاده شده و ثابت شده است که این روش‌ها در تمایز بین محصولات زراعی و علف‌های هرز موفقیت‌آمیز هستند [۸۲ و

ساده‌سازی طیف^۱ Vis-NIR در چهار باند (۵۰۰-۵۵۰، ۶۵۰-۷۵۰، ۱۳۰۰-۱۴۵۰ و ۱۹۰۰-۱۸۰۰ نانومتر) توانایی تمایز کامل با طیف Vis-NIR را تأیید کرد. همچنین نشان دادند که انتخاب باند مناسب و کالیبراسیون محلی با استفاده از یک رویکرد طبقه‌بندی طیفی ممکن است امکان تهیه نقشه علف‌های هرز را فراهم و کاربرد علف‌کش‌های موضعی را تسهیل کند [۷۱].

۳.۳. ویژگی‌های رنگی شناسایی علف‌های هرز

در یک تحقیق پیشگامانه، عملکرد یک ربات هوشمند پاشش علف‌کش مجهز به سامانه پردازش تصویر به‌روش قطعه‌بندی RGB برای کنترل علف‌های هرز روی ردیف‌های کشت گوجه‌فرنگی مورد بررسی قرار گرفت [۷۲]. این ربات دارای هشت نازل مستقل از یکدیگر بوده و هر یک از نازل‌ها عرض ۱۰/۶ سانتیمتر از ردیف‌های کشت را پوشش می‌دادند. در کنار هر یک از نازل‌ها، یک حسگر رنگی وجود داشت و سیگنال خروجی از این حسگرها به‌وسیله یک میکروکنترلر پردازش شده و سوپاپ سولنوئیدهای مربوط به هر نازل را باز و بسته می‌کرد. شکل (۴) عملکرد تمایز بین گیاه و علف‌هرز را نشان می‌دهد.



(ب)

(الف)

شکل (۴): (الف) تصویر رنگی از ردیف کشت گوجه‌فرنگی دارای علف‌هرز (ب) تصویر ایجاد شده در عملیات پردازش تصویر؛ در این تصویر، برگ‌های گوجه‌فرنگی با رنگ سبز و برگ‌های علف‌هرز با رنگ قرمز نشان داده شده‌اند [۷۲].

در بسیاری از محصولات به‌دلیل وجود علف‌های هرز دارای شکل و رنگ بسیار شبیه به محصول اصلی، معمولاً تنها یک

^۱ Visible-Near Infra-Red

۸۳]. برخی از این روش‌ها در جدول (۴) آورده شده است. ویژگی‌های شکل به‌طور کلی شامل محیط، قطر، طول محوری، طول محور اصلی و مساحت نواحی قطعه‌بندی شده می‌شود. بر اساس این ویژگی‌ها، شاخص‌های مختلفی با ترکیب حداقل دو اندازه، از جمله ضریب خروج از مرکز و میزان دایروی بودن شکل می‌گیرند. این شاخص‌ها بی‌بُعد است و در نتیجه مقادیر آن‌ها مستقل از زاویه قرارگیری دوربین، مقیاس و فاصله دوربین از جسم است [۶۰]. محققان نشان داده‌اند که ویژگی‌های ریخت‌شناسی عملکرد قابل قبولی در شناسایی علف‌های هرز تک‌لپه‌ای و دولپه‌ای دارند [۸۸].

در یکی از تحقیقات اخیر از ویژگی‌های ریخت‌شناسی چغندر قند برای تمایز آن با علف هرز استفاده شده است [۶۰]. در این تحقیق، چندین ویژگی شکلی مبتنی بر مساحت برگ‌ها، محیط برگ‌ها، طول محور اصلی برگ استخراج شد و برای آموزش شبکه عصبی مصنوعی و ماشین بردار پشتیبان مورد استفاده قرار گرفت. شکل ظاهری برگ چغندر به‌همراه علف‌های هرز متداول آن در شکل (۵) آورده شده است. نتایج این تحقیق نشان داد که دقت شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تشخیص علف‌های هرز از محصول به‌ترتیب برابر ۹۲/۵ و ۹۳/۳ درصد بود.

جدول (۳): ویژگی‌های متداول رنگی برای تمایز بین محصول و علف هرز

منبع	توضیح ویژگی	ویژگی رنگی
[۷۳]	میانگین باند قرمز در پنجره مورد بررسی	میانگین قرمز
	میانگین باند قرمز در پنجره مورد بررسی	میانگین سبز
	میانگین باند قرمز در پنجره مورد بررسی	میانگین آبی
	انحراف استاندارد باند قرمز در پنجره مورد بررسی	انحراف استاندارد قرمز
	انحراف استاندارد باند قرمز در پنجره مورد بررسی	انحراف استاندارد سبز
	انحراف استاندارد باند قرمز در پنجره مورد بررسی	انحراف استاندارد آبی
[۴۸]	میانگین باند سبز در پنجره مورد بررسی	میانگین سبز
	انحراف استاندارد باند سبز در پنجره مورد بررسی	انحراف استاندارد سبز
[۷۴]	میانگین باند قرمز نرمالیزه در عارضه تفکیک شده	میانگین r
	میانگین باند آبی نرمالیزه در عارضه تفکیک شده	میانگین b
	انحراف استاندارد باند قرمز نرمالیزه در عارضه تفکیک شده	انحراف استاندارد r
	انحراف استاندارد باند آبی نرمالیزه در عارضه تفکیک شده	انحراف استاندارد b
[۷۵]	اندیس پوشش گیاهی تفاضلی نرمالیزه	$NDVI$
[۷۶]	کانال H در فضای رنگی HSI	H
	کانال S در فضای رنگی HSI	S
[۷۷]	مقدار میانگین سومین مؤلفه فضای رنگی YIQ	میانگین Q
	مقدار اضافه اولین مؤلفه فضای رنگی HSI	سطح H اضافه
	مقدار میانگین سومین مؤلفه فضای رنگی HSI	میانگین I
[۶۸]	$[ExG, GB]$	CVI_2
	$[ExG, CIVE, GB, ERI]$	CVI_4
	$[ExR, ExGR, NDI, GB, RBI, ERI, EGI, r, g]$	CVI_9
	$[ExG, CIVE, ExR, ExGR, NDI, GB, RBI, ERI, EGI, EBI, r, g, b, Gray]$ $Gray=0.2898r+0.587g+0.114b$	CVI_{14}


جدول (۴): ویژگی‌های متداول ریخت‌شناسی برای تمایز بین محصول و علف هرز

دسته‌بندی	ویژگی	شرح ویژگی	منبع
ویژگی شکلی مبتنی بر ناحیه	محیط	تعداد پیکسل‌های مرز روی ناحیه قطعه‌بندی شده	[۸۴]
	قطر	قطر دایره‌ای که بر ناحیه قابل رسم است	[۴۸]
	طول محور فرعی	طول قطر فرعی یک بیضی که همان گشتاور مرکزی دوم نرمالیزه ناحیه را دارد	[۸۴]
	طول محور اصلی	طول قطر اصلی یک بیضی که همان گشتاور مرکزی دوم نرمالیزه ناحیه را دارد	[۸۴]
	مساحت	تعداد پیکسل‌های ناحیه قطعه‌بندی شده	[۴۸ و ۸۴]
اندیس‌های شکلی مبتنی بر ناحیه	اندیس خروج از مرکز فرم (فاکتور شکل)	طول قطر اصلی/طول قطر فرعی	[۸۴]
	اندیس دایروی بودن	$2 \times \pi \times \text{مساحت} / \text{محیط}$	[۴۸ و ۷۴]
	اندیس فشردگی	مساحت/محیط	[۴۸]
	استحکام MEC	مساحت ناحیه محیطی/مساحت شعاع کوچکترین دایره در برگ‌گیرنده ناحیه	[۶۳ و ۷۴]
	کشیدگی	ضخامت/مساحت (ضخامت برابر است با دو برابر تعداد مراحل که ناحیه پس از نازک شدن در شکل محو می‌شود)	[۶۳]
	تحدب	محیط/منحنی محیطی	[۶۳ و ۷۴]
	فاکتور شکل ۱	مساحت/طول محور اصلی	[۶۵]
	فاکتور شکل ۲	$3 \times \text{طول محور اصلی} / \text{مساحت}$	[۶۰]
	فاکتور شکل ۳	$(\text{طول محور اصلی} \times \text{طول محور فرعی}) / \text{مساحت}$	[۶۰]
	r_{mean}	فاصله میانگین مرز ناحیه با مرکز ثقل آن	[۸۶]
r_{max}	حداکثر فاصله مرز ناحیه با مرکز ثقل آن	[۸۶]	
D_{rear}	فاصلی عمودی مرز ناحیه تا محور اصلی یا عارضه	[۸۶]	
ویژگی‌های شکلی مبتنی بر مرز ناحیه	متغیرهای گشتاوری	توابع بر اساس اطلاعات درباره مرز ناحیه و مناطق داخل آن	[۶۰]
	ویژگی‌های فوریه	یک بردار ویژگی شامل ۱۲۶ ویژگی مهم استخراج شده از تبدیل گسسته فوریه	[۸۷]
	ویژگی‌های تانسوری	بررسی توزیع جهت‌گیری تانسوری ناحیه	[۸۷]

به صورت یک تابع از تغییرات مکانی شدت روشنایی پیکسل‌ها تعریف نمود. خصوصیات بافت، میزان تغییرات هر سطح مانند همواری، نرمی، زبری و منظم بودن رنگ‌های تشکیل‌دهنده آن را اندازه‌گیری می‌کند [۹۱].

روش‌های مبتنی بر بافت تصویر به‌طور گسترده در مهندسی کشاورزی و کیفیت‌سنجی محصولات صنایع غذایی مورد استفاده قرار گرفته‌اند. روش‌های بافتی را می‌توان در سه دسته آماری، ساختاری و تبدیلی تقسیم کرد [۹۲].

در یک مطالعه، یک سامانه رباتیکی مجهز به پردازش تصویر لحظه‌ای معرفی شده است که از یک طبقه‌بند فازی به‌منظور طبقه‌بندی بافت تصویر پوشش گیاهی برای تشخیص علف

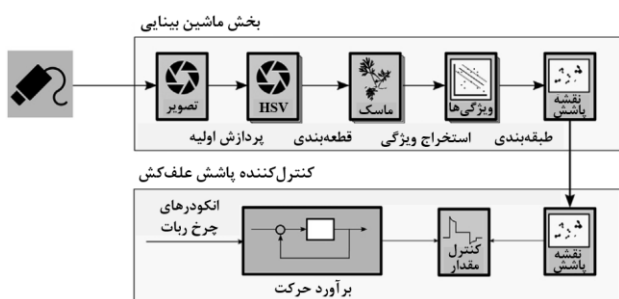


شکل (۵): (الف) شکل ظاهری برگ‌های گیاه چغندرقد، (ب تا ه) شکل ظاهری علف‌های هرز مزرعه چغندرقد [۵]

۳.۵. ویژگی‌های بافتی شناسایی علف‌های هرز

بافت، یکی از خصوصیات مهم تصاویر به‌شمار می‌رود و به ارزش رنگی پیکسل‌ها و موقعیت قرارگیری آن‌ها در تصویر بستگی دارد [۸۹ و ۹۰]. به‌طور کلی، بافت تصاویر را می‌توان

در یکی از تحقیقات اخیر، یک ربات اقتصادی مجهز به پردازش تصویر برای پاشش علف‌کش روی علف‌های هرز موجود بر ردیف کشت معرفی شده است [۹۵]. شکل (۷) فلوجارت مورد استفاده در این ربات را نشان می‌دهد. ویژگی‌های استخراج شده در این تحقیق شامل ویژگی‌های شکل، رنگ (مدل رنگی RGB و HSV) و بافت تصویر بودند.




شکل (۷): فلوجارت مورد استفاده در ربات تشخیص علف هرز [۹۵]

در تحقیقات اخیر همچنین نشان داده شده است که ضریب خودهمبستگی [۹۶] و هیستوگرام جهت‌گیری مرز ناحیه [۹۷] نیز از ویژگی‌های بافتی مؤثر در تشخیص علف هرز در مزرعه هستند.

روش‌های مبتنی بر ریخت‌شناسی و بافت تصویر در مقایسه به روش‌های رنگی در برابر محصول کشاورزی و علف‌های هرز آن اختصاصی‌تر هستند و به‌هنگام انتخاب آن‌ها باید توجه بیشتری به رقم مورد کشت داشت. روش‌های رنگی در مطالعاتی که تعداد رقم‌های علف هرز از یک بیشتر است، عملکرد کلی بهتری نشان داده‌اند. علاوه بر ویژگی‌های فوق، از ویژگی‌های دیگری نیز در تحقیقات استفاده شده است. برخی از محققین، از تبدیل هاف برای مشخص کردن ردیف‌های کشت محصولات استفاده و تمام پیکسل‌های باقیمانده پوشش گیاهی را به‌عنوان علف‌های هرز علامت‌گذاری می‌کنند [۹۸] و [۹۹]. جستجو در تصویر برای استخراج خطوط کشت پیچیدگی محاسبات و زمان مورد نیاز برای پردازش تصویر را افزایش می‌دهد. در دیگر مطالعات، تصاویر را از نزدیکی سطح زمین می‌گیرند و به این ترتیب عوارض اضافی در تصویر حذف و ردیف‌های محصول به آسانی قابل شناسایی می‌باشند [۱۰۰ و ۱۰۱]. با این حال، علف‌های هرز موجود روی

هرز در مزارع نیشکر بهره می‌گیرد [۹۳]. در این تحقیق، ابتدا از اپراتورهای ریخت‌شناسی دایره‌ای برای استخراج نواحی پوشش گیاهی استفاده و نه خصوصیت بافتی تصاویر از جمله انرژی، همگونی، آنتروپی، کنتراست از تصاویر استخراج شدند. در ادامه، یک پایگاه داده بر اساس ویژگی‌های استخراج شده تهیه شد. شکل (۶) نحوه استخراج ویژگی‌های بافتی از تصویر یک علف هرز را نشان می‌دهد. نتایج نشان داد که طبقه‌بند فازی که روی یک مدار Raspberry Pi پیاده‌سازی شده بود، می‌توانست علف‌های هرز را با دقت ۹۲/۹ درصد در مدت زمان پردازش ۰/۰۲ ثانیه شناسایی کند.



شکل (۶): (الف) تصویر ثبت شده از یک علف هرز، (ب) ویژگی‌های بافتی از تصویرهای دایره‌ای شکل استخراج شده به کمک اپراتورهای ریخت‌شناسی [۹۳]

در مطالعه دیگری، پژوهشگران یک سامانه پاشش علف‌کش لحظه‌ای را مبتنی بر ماشین‌بینایی برای شناسایی علف‌های هرز غلات طراحی کردند. آن‌ها یک دوربین CCD تک رنگ^۱ در جلوی تراکتور نصب و تمایز بین محصول و علف‌های هرز را با پردازش تصویر و بر اساس اطلاعات سه بعدی با استفاده از فیلتر گابور^۲ بدست آوردند. این روش اجازه تشخیص سیگنال‌های با تناوب مشخص را از غیر متناوب می‌دهد و باعث افزایش عملکرد در تشخیص ردیف محصول می‌شود. با توجه به وجود علف‌های هرز با توزیع لکه‌دار^۳، لکه‌ها به وضوح با روش رنگ‌آمیزی لکه مشخص شدند تا فرمان صحیح به کارانداز منتقل شود و دریچه الکترونیوماتیک سمپاش بتواند در لحظه مناسب فعال شود [۹۴].

¹ Monochrome

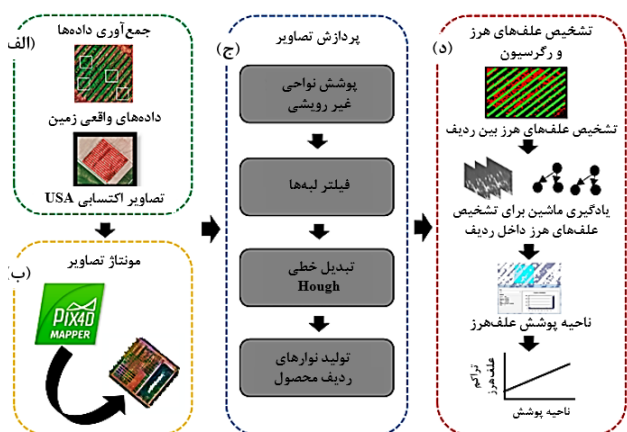
² Gabor

³ Patchy

طبقه‌بندی چند سطحی همراه با الگوریتم‌های یادگیری ماشین برای تشخیص علف‌های هرز داخل ردیف پنبه استفاده کردند (شکل ۹). نتایج آن‌ها سطح دقت ۸۹/۱۶٪، ۸۳/۸۳٪ و ۸۳/۳۳٪ و ارزش کاپای ۰/۷۹، ۰/۷۵ و ۰/۸۴ در تشخیص علف‌های هرز قطعات به ترتیب با تراکم بالا، متوسط و ضریب کم نشان دادند [۱۰۲].

۴. تصویر و مدیریت موضعی سمپاشی و آبیاری

روش‌های معمول سمپاشی آفت‌کش‌ها در باغ‌ها و مزارع کشاورزی هدفدار انجام نمی‌شود و بررسی آمار مصرف سموم شیمیایی در باغ‌ها نشان‌دهنده مصرف بیش از حد مورد نیاز گیاه است.



شکل ۹: روش کلی برای نقشه‌برداری علف‌های هرز در مزرعه پنبه: (الف) جمع‌آوری اطلاعات، (ب) مونتاژ تصویر، (ج) پیش‌پردازش تصویر و (د) تشخیص و رگرسیون علف‌های هرز [۱۰۲]

سمپاش‌های نرخ متغیر با استفاده از سامانه‌های کنترل هوشمند تا حد زیادی در کاهش استفاده از آفت‌کش‌ها و کاهش آلودگی محیط‌زیست مؤثر هستند. تاج درخت، در درختان مختلف، از نظر شکل ساختار و تراکم پوشش متفاوت است. در سمپاش‌های معمول مقدار سم خروجی در تمام حالات یکسان است و این حالت بدون در نظر گرفتن وجود درخت در مسیر سمپاشی، ارتفاع بلند یا کوتاه و عرض پهن یا باریک درخت مطابق شکل (۱۰) صورت می‌گیرد. بنابراین مقدار قابل توجهی سم بین دو درخت و در فضای آزاد بالا و پایین درخت هدر می‌رود [۱۰۳].

ردیف‌های کشت شناسایی نمی‌شوند که محدودیت آن به‌شمار می‌رود.

در یک مطالعه که اخیراً روی تمایز بین ذرت و علف هرز به کمک ویژگی‌های رنگی پوشش گیاهی و استفاده از ماشین بردار پشتیبان به‌عنوان طبقه‌بند انجام شد، محققان به بررسی اثر نور محیط و شرایط آب‌وهوایی بر عملکرد روش پرداختند [۴۲]. آن‌ها نشان دادند که ویژگی‌های رنگی، ویژگی‌های مناسب برای تمایز محصول ذرت از بقیه پوشش گیاهی است و روش پیشنهادی بهترین عملکرد (در حدود ۹۲ درصد) را در ساعت ۱۱ صبح دارد. الگوریتم ارائه شده در این تحقیق در شکل (۸) آورده شده است.



شکل ۸: الگوریتم پیشنهادی برای تشخیص محصول از علف هرز در مزرعه ذرت [۴۲]

در سال‌های اخیر، سیستم‌های هوایی بدون سرنشین (UAS^۱) به‌عنوان یک فناوری نوآورانه برای ارائه اطلاعات مکانی - زمانی در مورد گونه‌های علف‌های هرز در گیاهان زراعی ظهور کردند. در پژوهشی از یک UAS چند روتوری مجهز به سنسور RGB برای جمع‌آوری تصاویر در سه بانده (قرمز، سبز، آبی و وضوح ۰/۸ سانتی‌متر بر پیکسل) با اهداف نقشه‌برداری علف‌های هرز پنبه و تعیین رابطه بین پوشش علف‌های هرز مبتنی بر تصویر و تراکم علف‌های هرز مبتنی بر زمین استفاده کردند. نقشه‌برداری علف‌های هرز را با سه سطح مختلف تراکم علف‌های هرز (زیاد، متوسط و کم) و برای ترکیبی از گونه‌های مختلف علف‌های هرز انجام دادند. برای تعیین تراکم علف‌هرز، از پنج قطعه زمین (۱ مترمربع) استفاده کردند و بعد از پیش‌پردازش تصاویر هوایی، ردیف‌های پنبه تحت تبدیل Hough قرار گرفتند. برای جداسازی پوشش گیاهی بین ردیف‌های زراعی، از یک

^۱ Unmanned Aerial Systems

مزارع کشاورزی همانند کنترل علف‌هرز می‌تواند به دو صورت حسگر مینا و نقشه‌مینا انجام شود. در این حالت، تصاویر مورد نیاز برای مدیریت موضعی مزرعه را می‌توان از طریق ماهواره، عکس‌های هوایی و یا حسگر متصل به یک تراکتور یا ربات کشاورزی تهیه کرد [۱۰۵].

۴.۱. پردازش تصاویر ماهواره‌ای و هوایی

به‌هنگام تحلیل تصاویر ماهواره‌ای و هوایی، به‌طور کلی از ویژگی‌های طیفی برای تشخیص پوشش گیاهی روی سطح زمین بهره گرفته می‌شود. به کمک این ویژگی‌ها، یک یا چندین نقشه برای مدیریت نرخ متغیر مزرعه آماده می‌شود. در ادامه، نقشه پوشش گیاهی استخراج شده و در اختیار یک کارانداز قرار می‌گیرد تا عملیات سمپاشی یا آبیاری در سطح مزرعه را با توجه به سطح تراکم پوشش گیاهی انجام دهد. برخی از ویژگی‌های رنگی - طیفی پر کاربرد در مدیریت موضعی آبیاری و سمپاشی به کمک سنجنده‌های ماهواره‌ای و هوایی در جدول (۵) آورده شده است.



شکل (۱۰): پاشش بیش از اندازه سمپاش باغی هنگام سراسر پاشی

متداول [۱۰۳]

با استفاده از تجهیزات سمپاشی معمول و بدست آوردن نرخ جریان خروجی، مشاهده شده است که محصولات در گلخانه بیشتر از حد مورد نیاز سمپاشی می‌شوند، در حالیکه تنها ۳۰ درصد از سم پاشیده شده به تاج درخت می‌رسد و باقیمانده آن هدر رفته و باعث خسارت می‌شود [۱۰۴]. آبیاری نیز اگر به‌صورت هدفدار انجام نشود، بازده مصرف آب در مزرعه به‌طور معناداری کاهش می‌یابد. این موضوع برای ایران که با کمبود آب در بخش کشاورزی روبه‌رو است، اهمیت زیادی دارد. مدیریت موضعی سمپاشی و آبیاری در

جدول (۵): ویژگی‌های رنگی - طیفی متداول در مدیریت موضعی آبیاری و سمپاشی به کمک سنجنده‌های ماهواره‌ای و هوایی

منبع	روش محاسبه	شرح ویژگی	ویژگی رنگی
[۱۰۶]	$NDVI = \frac{NIR - R}{NIR + R}$	اندیس پوشش گیاهی تفاضلی نرمالیزه	NDVI
[۱۰۷]	$NDWI = \frac{G - NIR}{G + NIR}$	اندیس آبی تفاضلی نرمالیزه	NDWI
[۱۰۷]	$MNDWI = \frac{G - MIR}{G + MIR}$ MIR: middle infra red	اندیس آبی تفاضلی نرمالیزه اصلاح شده	MNDWI
[۱۰۸]	$GNDVI = \frac{NIR - G}{NIR + G}$	اندیس پوشش گیاهی تفاضلی نرمالیزه سبز	GNDVI
[۱۰۸]	$NDRI = \frac{NIR - A_{715}}{NIR + A_{715}}$	اندیس قرمز تفاضلی نرمالیزه	NDRI
[۱۰۹]	$GRVI = \frac{G - R}{G + R}$	اندیس پوشش گیاهی سبز - قرمز	GRVI
[۱۰۷]	$NDWI = \frac{SWIR - G}{SWIR + G}$ SWIR: short wave infra red	اندیس دریاچه تفاضلی نرمالیزه	NDPI

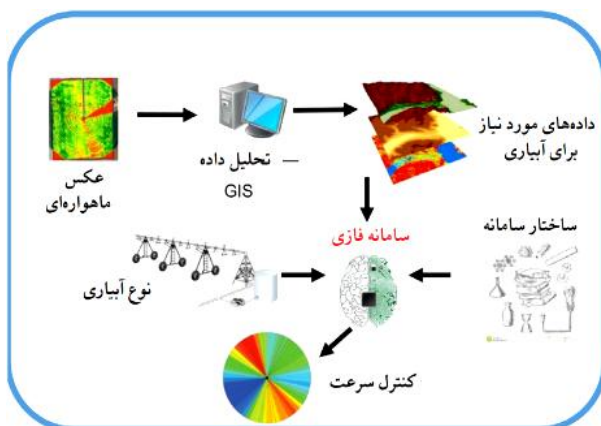
در تحقیقی، از یک سمپاش مه افشان - دمنده هوایی به کمک پردازش تصویر و براساس شناسایی ساختار تاج درختان استفاده شد. تصویربرداری با استفاده از یک دوربین مرئی که در جلوی تراکتور و به ارتفاع یک متر از زمین قرار داشت، صورت گرفت. ابتدا خصوصیات رنگ، مقدار اشباع و روشنایی (HSL) از تصاویر استخراج شده و اندازه تاج درختان تخمین زده شد و سمپاشی بر اساس اندازه تاج درختان اعمال شد. نتایج نشان داد مقدار صرفه‌جویی سم در باغ گلابی به کمک روش مذکور ۲۳/۷ درصد بود [۱۱۱]. البته وجود درختان در ردیف‌های کشت مجاور و دیده شدن در تصاویر گرفته شده توسط دوربین، باعث کاهش دقت آزمایش شد.

در پژوهشی دیگر بر مبنای سمپاشی هدفمند، از یک پوششگر لیزری برای پوشش حجم درختان مرکبات، برآورد تاج درخت، عرض و حجم درخت استفاده شد. نتایج نشان داد تخمین عرض در حدود ۱۵ سانتیمتر و تخمین حجم حداقل ۰/۰۹ درصد خطا به همراه داشت [۱۱۲].

با بررسی منابع می‌توان مشاهده کرد که حجم زیادی از تحقیقات در حوزه محاسبه اندازه تاج گیاه به کمک روش‌های ریخت‌شناسی و یا استفاده از پوششگر لیزری بوده است.

در یک تحقیق، یک نمونه سمپاش باغی مبتنی بر فن‌آوری ماشین بینایی ارزیابی شد [۱۱۳]. سمپاش ساخته‌شده براساس ساختار تاج درخت و میزان سبزینه، عمل سمپاشی را به صورت بی‌درنگ انجام داده و موجب افزایش بهره‌وری سمپاشی در باغ شد. عملکرد سمپاش در باغ زیتون در دو حالت مختلف سمپاشی به صورت سراسر پاشی و منقطع هدفدار مبتنی بر سایه‌انداز درخت، فن‌آوری ماشین بینایی و استفاده از مدل رنگی RGB مقایسه شد. آن‌ها برای تصویربرداری از تاج درخت و انجام مراحل پردازش تصویر برای هر ردیف کاشت درختان در باغ یک دوربین برای تصویربرداری در فضای بالای تاج درختان در نظر گرفتند. همچنین به منظور تصویربرداری همزمان دو ردیف کشت، شاسی دوربین‌ها را به صورت T شکل طراحی کردند. شاسی به نحوی در بالای کابین تراکتور نصب شد که هر دوربین بتواند فضای بالای تاج درخت را

در یکی از تحقیقات اخیر، از داده‌های طیفی تصاویر ماهواره ندست (با وضوح مکانی ۱۵ متر) برای استخراج ویژگی‌های NDVI، رطوبت خاک و دمای تاج گیاهان جهت مدیریت موضعی آبیاری یک مزرعه استفاده شد [۱۰۶]. در این تحقیق، پس از استخراج ویژگی‌ها و تهیه نقشه‌های مورد نیاز، از یک سامانه استنتاج فازی برای تنظیم سرعت چرخش سامانه پاشش آب پیوت^۱ در مزرعه بر اساس نقشه‌های آماده شده استفاده کردند (شکل (۱۱)). برای هر یک از ورودی‌های سامانه فازی ۳ تابع عضویت و برای خروجی سامانه، ۵ تابع عضویت فازی در نظر گرفتند. نتایج تحقیق نشان داد که روش پیشنهادی دارای قابلیت مدیریت مؤثر آبیاری یک مزرعه بزرگ در برزیل با آب‌وهوای خاص است.



شکل (۱۱): پاشش بیش از اندازه سمپاش باغی هنگام سراسر پاشی

متداول [۱۰۶]

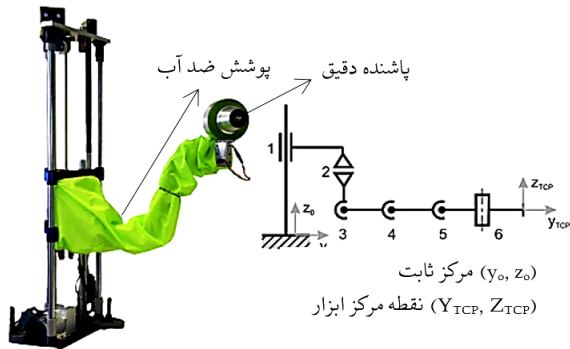
۴.۲. پردازش تصاویر زمینی

سامانه‌های مدیریت موضعی آبیاری و سمپاشی که از تصاویر بدست آمده از سکوی تصویربرداری موجود روی تراکتورها و ربات‌های کشاورز بهره می‌گیرند، عموماً مبتنی بر تنظیم نرخ پاشش آب یا سم آفت‌کش بر اساس اندازه تاج گیاهان هستند. پس از پردازش تصاویر ثبت شده به صورت لحظه‌ای، اندازه تاج گیاهان بدست آمده و بر اساس بزرگی و یا کوچکی گیاهان، نهاده‌های کشاورزی (آب و آفت‌کش) را دریافت می‌کنند [۱۱۰].

¹ Central pivot irrigation system

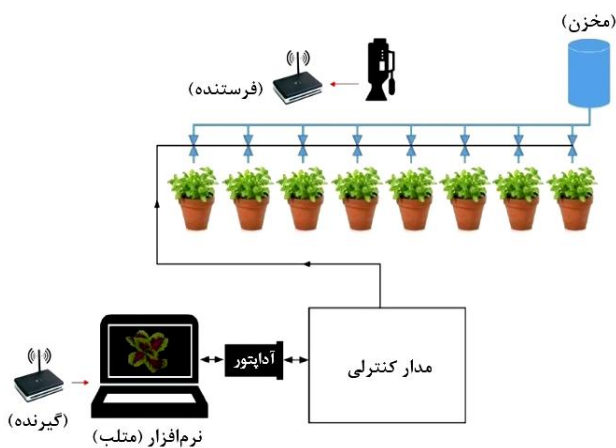


(الف)



(ب)


شکل (۱۳): ربات طراحی شده در آزمایش: (الف) ربات هنگام سمپاشی در گلخانه، (ب) نمای نزدیک ربات سمپاش و قسمت‌های تشکیل دهنده [۱۱۴]



شکل (۱۴): شماتیک سامانه کنترلی سامانه خودکار آبیاری [۱۱۳]

در مطالعه‌های دیگر با هدف تشخیص نیاز آبی گیاه چمن، از تصاویر گیاه تحت تنش خشکی جهت استخراج ویژگی‌های رنگی، بافت و تعدادی از پارامترهای تصویر در حوزه فرکانس استفاده شد و پس از استخراج پارامترهای تصاویر با توجه به نتایج آنالیز آماری در سطح احتمال ۵ درصد، مناسب‌ترین

تصویربرداری کند (شکل (۱۲)).



شکل (۱۲): طرح‌واره شاسی طراحی شده برای دوربین‌ها [۱۱۳]

آن‌ها نتیجه گرفتند که در هنگام استفاده از سمپاش باغی نرخ متغیر در مقایسه با نوع متداول، مصرف سم در حدود ۵۴٪ روی درختان زیتون کاهش داشت و بیان کردند که با توجه به عدم پاشش سم در فضای خالی بین درختان، در باغ‌های جوان با درختان کوچکتر و فاصله بیشتر بین تاج درختان، میزان کاهش مصرف سم از این مقدار نیز فراتر می‌رود.

تشخیص به‌موقع و پاشش‌های انتخابی کانون‌های بیماری ممکن است تأثیر قابل توجهی بر مقدار آفت‌کش‌های لازم برای جلوگیری از ایجاد عفونت و گسترش آن به باغ‌ها و گلخانه‌ها داشته باشد. در این راستا، در پژوهشی به بررسی شناسایی علائم بیماری قارچ کپک پودری انگور و امکان پاشش سم به مناطق بیمار با استفاده از ربات هوشمند دارای شش درجه آزادی و مجهز به یک پاشنده دقیق سم پرداخته شد [۱۱۴]. شکل (۱۳) نمایی از ربات طراحی شده در آزمایش را نشان می‌دهد.

علاوه بر سمپاشی نرخ متغیر، آبیاری نرخ متغیر به کمک دوربین دیجیتال مرئی نیز مورد توجه محققین بوده است. در یک تحقیق، سامانه خودکاری برای آبیاری طراحی شد که با بررسی پارامترهای رنگی و ریخت‌شناسی گیاه، می‌توانست میزان پژمردگی گیاه را اندازه‌گیری و بر اساس آن، نیاز گیاه به آب را تشخیص و در راستای بهبود وضعیت گیاه اقدام نماید [۱۱۵]. در این تحقیق، گیاه گلخانه‌ای حُسن یوسف به‌دلیل حساسیت بالای آن به زمان آبیاری انتخاب شد. نتایج حاکی از عملکرد مناسب روش پیشنهادی بود (شکل (۱۴)).




شکل (۱۶): نمای کلی ربات طراحی شده در آزمایش [۱۱۷]

در یک پژوهش جدید، حجازی‌پور و همکاران [۱۱۸] یک ربات مبتنی بر پردازش تصویر برای سمپاشی محصولات گلخانه‌ای بر اساس حجم گیاه پرداختند. ربات ساخته‌شده، دارای ۴ درجه آزادی بود و در آن دوربین رنگی RGB و دید در عمق کینکت^۲ جهت تصویربرداری از بوته به روش مقطع به مقطع استفاده شد (شکل (۱۷)). بدین صورتکه ربات، پس از حرکت در بین ردیف محصولات و تشخیص محل قرارگیری متوقف شده و با بازکردن بازوی خود (با توجه به ارتفاع بوته گیاه)، به صورت مرحله به مرحله اقدام به عکس‌برداری رنگی و عمیق به صورت مقطع به مقطع از بوته کرده و در هر مقطع پس از محاسبه حجم توده گیاه مشاهده‌شده، اقدام به سمپاشی مقطع روبروی خود می‌کرد. کاغذهای حساس به سمی که میان برگ بوته گیاهان و روی زمین دور تا دور بوته جانمایی شد مشاهده شد که کیفیت محلول‌پاشی ربات در سطوح بالای گیاه کاهش نیافته و ربات به خوبی قادر بود ارتفاع گیاه را تشخیص دهد و کیفیت پاشش مطلوب خود را در کل ارتفاع بوته گیاه به طور یکسان حفظ کند.

² Kinect

ویژگی‌ها به‌منظور پیش‌بینی محتوای رطوبت گیاه توسط طبقه‌بند رگرسیون بردار پشتیبان انتخاب شد. تأمین مقدار آب مورد نیاز گیاه در این سامانه با توجه به مقدار ثابت دبی حجمی پمپ تعبیه شده، از طریق محاسبه مدت زمان لازم برای هدایت جریان آب از پمپ به سمت گیاه صورت گرفت. شماتیک سامانه در شکل (۱۵) نشان داده شده است [۱۱۶]. نتایج آن‌ها نشان داد که سامانه پیشنهاد شده از کارایی مناسبی به‌منظور اندازه‌گیری و سنجش پژمردگی گیاه و کنترل میزان آب مورد نیاز برخوردار است.



شکل (۱۵): شماتیک سامانه کنترل هوشمند آبیاری [۱۱۶]


پژوهشگران در مطالعه‌ای جدید یک سامانه رباتیک خودکار با الگوریتم کنترل PID^۱ طراحی کردند که قادر به تولید نقشه مزرعه با استفاده از کیلومترشمار و حسگر pH و همچنین یک مکانیزم CNC برای پاشش دقیق علف‌کش‌ها و انجام آبیاری قطره‌ای است. آن‌ها بیان کردند که این ربات با استفاده از دوربین Pi، تصاویری از مزرعه را در مدل یادگیری ماشین برای شناسایی علف‌های هرز ضبط و قابلیت تنظیم ارتفاع ربات در محدوده ۳۰-۱ اینچ امکان سمپاشی گیاهان مختلف از جمله گوجه‌فرنگی، کلم، پیاز و هویج را فراهم می‌کند. سمپاشی با مخزن ۲ لیتری و پمپ ۱۲ ولتی از طریق لوله‌های اتصال بین مخزن و پمپ به نازل انجام می‌شود. نازل (قطر ۴/۰ اینچ) به یک محفظه در طول محور Z از مکانیسم CNC متصل است. کارکرد ربات بدین صورت است که با شناسایی علف هرز، اطلاعات از مدول یادگیری دریافت و باعث حرکت مکانیسم حذف علف‌هرز می‌شود (شکل (۱۶)). نتایج پژوهش آن‌ها، میزان صحت ۹۲/۴٪ و دقت ۹۴/۷٪ را برای شناسایی اهداف مورد نظر در ربات طراحی شده نشان داد [۱۱۷].

¹ Proportional Integral Derivative

تصاویر مربوط به کشاورزی دقیق به‌منظور استخراج پوشش گیاهی و تمایز در محصول و علف‌های هرز مورد استفاده قرار می‌گیرند، شامل ویژگی‌های رنگی، ریخت‌شناسی و بافت تصویر می‌شوند. صدها تحقیق را می‌توان در سال‌های اخیر یافت که در نشریات معتبر به‌منظور ارائه یک راه‌حل پردازش تصویر، معرفی یک ویژگی جدید به‌منظور بهبود کیفیت تشخیص علف‌هرز در مزرعه و بهبود کیفیت سمپاشی و آبیاری در مزارع و باغ‌ها منتشر شده است. بررسی مقالات نشان می‌دهد که حجم زیادی از این اسناد در مجلاتی نظیر «رایانه و الکترونیک در کشاورزی»^۱، «مهندسی بیوسیستم»^۲ و «کشاورزی دقیق» منتشر شده‌اند و به‌نظر می‌رسد محققینی که علاقمند به تحقیق در این حوزه‌ها هستند، می‌توانند یافته‌های خود را در این مجلات به چاپ برسانند.

با وجود سامانه‌های نوظهور مبتنی بر پردازش تصویر برای کنترل مصرف مواد شیمیایی و کاهش مصرف علف‌کش در مزارع که برخی از آن‌ها نیز به‌طور تجاری در دسترس هستند، استفاده از این سامانه‌ها در مزارع کوچک در اغلب کشورهای در حال توسعه به‌دلیل هزینه پیاده‌سازی بالا قابل توجه نیست. برخی از پارامترهای سامانه مانند تنظیمات دستگاه در شرایط میدانی و نور طبیعی نیاز به تنظیمات از طرف کشاورز دارد که در کشورهای در حال توسعه، دانش و مهارت فنی کشاورز کاربرد این سامانه‌ها را محدود می‌کند. به‌نظر می‌رسد محققین باید به‌دنبال توسعه روش‌هایی باشند که نه تنها از نظر اقتصادی مقرون به‌صرفه است، بلکه به‌سادگی در مزارع کشاورزی قابل پیاده‌سازی بوده و برای اغلب محصولات کشاورزی قابل استفاده باشند. نتایج نشان می‌دهد کاربرد پردازش تصویر در کشاورزی دقیق برای کنترل علف‌های هرز و مدیریت موضعی سمپاشی و آبیاری نهایتاً به حفظ محیط‌زیست و کشاورزی پایدار منجر خواهد شد.

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافعی ندارند.



شکل (۱۷): شماتیک عملکرد ربات در تصویربرداری [۱۱۸]

شناخت تغییرات مکانی متغیرهای اقلیمی، هیدرولوژیک و هیدروژئولوژیک پیش‌نیازی برای بسیاری از فعالیت‌های عمرانی، توسعه منابع آب، کشاورزی و منابع طبیعی است. معمول‌ترین منبع گردآوری داده‌های اقلیمی، آب‌های سطحی و زیرزمینی ایستگاه‌های برداشت است که تعداد آن‌ها محدود و با مشکلات تأسیس، قرائت و دیده‌بانی همراه است [۱۱۷]. در پژوهشی از شبکه عصبی مصنوعی شعاعی با اطلاعات ورودی مختصات جغرافیایی چاه‌های مشاهده‌ای و سال و روز مشاهده سطح آب زیرزمینی، به پیش‌بینی سطح ایستابی آب پرداختند. نتایج آن‌ها با ضریب همبستگی ۰/۹۹ نشان از انطباق بالای تخمین با واقعیت داشت. نمودار خطوط هم‌تراز آب زیرزمینی در ۴ روز دلخواه از سال نیز انطباق بالایی با واقعیت را نشان داد. آن‌ها مزیت این روش را رسم نمودار برای هر روز دلخواه و در هر بازه مکانی در محدوده، سرعت بالا ترسیم نمودار، مدیریت منابع آب‌های زیرزمینی در مواقع در دسترس نبودن اطلاعات همه نقاط محدوده، پیش‌بینی سطح آب در این نقاط و بررسی شرایط آینده بیان کردند [۱۱۹].

۵. نتیجه‌گیری و چشم‌انداز آینده

پردازش تصویر و ماشین‌بینایی به‌عنوان فن‌آوری‌های پرکاربرد می‌توانند نقش مؤثری در کشاورزی دقیق، بویژه کنترل علف‌هرز و مدیریت موضعی سمپاشی و آبیاری ایفا نمایند و کاهش هزینه‌ها، صرفه‌جویی در زمان و حفاظت محیط‌زیست را به‌همراه داشته باشند. ویژگی‌هایی که به‌طور گسترده در پردازش

¹ Computers and Electronics in Agriculture

² Biosystems Engineering

- [1] Das J., Cross G., Qu C., Makineni A., Tokekar P., Mulgaonkar Y., and Kumar V., *Devices, systems, and methods for automated monitoring enabling precision agriculture*, In 2015 IEEE International Conference on Automation Science and Engineering (CASE), pp. 462-469., 2015.
- [2] Plant R.E., "Site-specific management: the application of information technology to crop production", *Computers and Electronics in Agriculture*, 30:9-29, 2001.
- [3] Mulla D.J., "Twenty-five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps", *Biosystems Engineering*, 114(4):358-371, 2013.
- [4] Earl R., Wheeler P.N., Blackmore B.S., and Godwin R.J., "*Precision farming: the management of variability*", *Landwards*, 51:18-23, 1996.
- [5] Sabatier P., Poulenard J., Fangeta B., Reyss J.L., Develle A.L., Wilhelm B., Ployon E., Pignol C., Naffrechoux E., Dorioz J.M., Montuelle B., and Arnaud F., "*Long-term relationships among pesticide applications, mobility, and soil erosion in a vineyard watershed*", *Proceedings of the National Academy of Sciences of the United States of America*, 111:15647-15652, 2014.
- [6] Stehle S., and Schulz R., "*Agricultural insecticides threaten surface waters at the global scale*", *Proceedings of the National Academy of Sciences of the United States of America*, 112:5750-5755, 2015.
- [7] Abdollahi M., Ranjbar A., Shadnia S., Nikfar S., and Rezaie A., "*Pesticides and oxidative stress: a review*", *Medical Science Monitor*, 10: RA141-RA147, 2004.
- [8] Burns C.J., McIntosh L.J., Mink P.J., Jurek A.M., and Li A.A., "*Pesticide exposure and neurodevelopmental outcomes: review of the epidemiologic and animal studies*", *Journal of Toxicology and Environmental Health e Part B Critical Reviews*, 16:127-283, 2013.
- [9] Rauh V.A., Perera F.P., Horton M.K., Whyatt R.M., Bansal R., Hao X., Liu J., Boyd Barr D., Slotkin T.A., and Peterson B.S., "*Brain anomalies in children exposed prenatally to a common organophosphate pesticide*", *Proceedings of the National Academy of Sciences of the United States of America*, 109:7871-7876, 2012.
- [10] National Research Council, *Precision Agriculture in the 21st Century-Geospatial and Information Technologies*, Crop Management, National Academy Press, Washington, D.C, 168 pages, 1997.
- [11] Atzberger C., "Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs", *Remote sensing*, 5:949-981, 2013.
- [12] Steele-Dunne S.C., McNairn H., Monsivais-Huertero A., Judge J., Liu P.W., and Papanthassiou K., "*Radar remote sensing of agricultural canopies: A review*", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10:2249-2273, 2017.
- [13] Faridi H., and Abonajmi M., "*Application of machine vision in agricultural products*", *Proceedings of the 4th Iranian International NDT Conference*, Olympic Hotel, Tehran, Iran, 2017.
- [14] Bechar A., and Vigneault C., "*Agricultural robots for field operations: Concepts and components*", *Biosystems Engineering*, 149:94-111, 2016.
- [15] Bac C.W., Hemming J., Van Tuijl B.A.J., Barth R., Wais E., and Van Henten E.J., "*Performance evaluation of a harvesting robot for sweet pepper*", *Journal of Field Robotics*, 34:1123-1139, 2017.
- [16] Menges R.M., Nixon P.R., and Richardson A.J., "*Light reflectance and remote sensing of weeds in agronomic and horticultural crops*", *Weed Science*, 33:569-581, 1985.
- [17] Richardson A.J., Menges R.M., and Nixon P.R., "*Distinguishing weed from crop plants using video remote sensing*", *Photogrammetric Engineering and Remote Sensing*, 51:1785-1790, 1985.
- [18] Lopez-Granados F., Jurado-Exposito M., Atenciano S., García-Ferrer A., Sánchez de la Orden M., and García-Torres L., "*Spatial variability of agricultural soils in southern Spain*", *Plant and Soil*, 246:97-105, 2002.
- [19] Xavier P., Artizzu B., Ribeiro A., Tellaeche A., Pajares G., and Fernandez-Quintanilla C., "*Analysis of natural images processing for the extraction of agricultural elements*", *Image and Vision Computing*, 28:138-149, 2010.
- [20] Bacco M., Berton A., Ferro E., Gennaro C., Gotta A., Matteoli S., and Zanella A., "*Smart farming: Opportunities, challenges and technology enablers*", In 2018 IoT Vertical and Topical

- Summit on Agriculture-Tuscany (IOT Tuscany) IEEE, pp. 1-6, 2018.
- [21] Abouzar P., Michelson D.G., and Hamdi M., "RSSI-based distributed self-localization for wireless sensor networks used in precision agriculture", IEEE Transactions on Wireless Communications, 15: 6638-6650, 2016.
- [22] Huang Y., Lee M.A., Thomson S.J., and Reddy K. N., "Ground-based hyperspectral remote sensing for weed management in crop production", International Journal of Agricultural and Biological Engineering, 9: 98-109, 2016.
- [23] Rokhmana C.A., "The potential of UAV-based remote sensing for supporting precision agriculture in Indonesia", Procedia Environmental Sciences, 24: 245-253, 2015.
- [24] Deere J., Ess D., and Morgan, M., *The Precision-Farming Guide for Agriculturists*, Deere & Company, Technology & Engineering, Moline, IL, USA, 2003.
- [25] Asefpour Vakilian K., and Massah J., "A farmer-assistant robot for nitrogen fertilizing management of greenhouse crops", Computers and electronics in agriculture, 139: 153-163, 2017.
- [26] Zarco-Tejada P.J., González-Dugo M.V., and Fereres E., "Seasonal stability of chlorophyll fluorescence quantified from airborne hyperspectral imagery as an indicator of net photosynthesis in the context of precision agriculture", Remote Sensing of Environment, 179: 89-103, 2016.
- [۲۷] فیاضی ح., دهقانی ح., حسینی س.م., «مروری بر استفاده از محاسبات تکاملی در تجزیه طیفی تصاویر ابرطیفی»، مجله محاسبات نرم، جلد ۱، شماره ۲، ص ۵۹-۴۶، ۱۳۹۱.
- [28] Guijarro M., Riomoros I., Pajares G., and Zitinski P., "Discrete wavelets transform for improving greenness image segmentation in agricultural images", Computers and Electronics in Agriculture, 118: 396-407, 2015.
- [29] Hamuda E., Glavin M., and Jones E., "A survey of image processing techniques for plant extraction and segmentation in the field", Computers and Electronics in Agriculture, 125: 184-199, 2016.
- [30] Pérez A., Lopez F., Benlloch J., and Christensen S., "Colour and shape analysis techniques for weed detection in cereal fields", Computers and Electronics in Agriculture, 25: 197-212, 2000.
- [31] Aitkenhead M., Dalgetty I., Mullins C., McDonald A., and Strachan N., "Weed and crop discrimination using image analysis and artificial intelligence methods", Computers and Electronics in Agriculture, 39: 157-171, 2003.
- [32] Ribeiro A., Fernandez-Quintanilla C., Barroso J., and García-Alegre M. C., "Development of an image analysis system for estimation of weed", Proceedings of the 5th European Conference on Precision Agriculture (5ECPA), 169-174, 2005.
- [33] Van Evert F. K., Van Der Heijden G. W., Lotz L. A. P., Polder G., Lamaker A., De Jong A., Kuyper M. C., Groendijk E. J., Neeteson J. J., and Van Der Zalm T., "A mobile field robot with vision-based detection of volunteer potato plants in a corn crop", Weed Technology, 20: 853-861, 2006.
- [34] Meyer G., and Neto J., "Verification of color vegetation indices for automated crop imaging applications", Computers and Electronics in Agriculture, 63: 282-293, 2008.
- [35] Hemming J., and Rath T., "Computer-vision based weed identification under field conditions using controlled lighting", Journal of Agricultural Engineering Research, 78: 233-243, 2001.
- [36] Blasco J., Aleixos N., Roger J., Rabatel G., and Molto E., "Robotic weed control using machine vision", Biosystems Engineering, 83: 149-157, 2002.
- [۳۷] سیدیزدی س.ج., حسن‌پور ح., «ابر تفکیک‌پذیری: مروری بر روش‌های موجود»، مجله محاسبات نرم، جلد ۲، شماره ۲، ص ۵۱-۳۶، ۱۳۹۲.
- [38] Mart J., Freixenet J., Batlle J., and Casals A., "A new approach to outdoor scene description based on learning and top-down segmentation", Image and Vision Computing, 19: 1041-1055, 2001.
- [39] Bosch A., Muoz X., and Freixenet J., "Segmentation and description of natural outdoor scenes", Image and Vision Computing, 25: 727-740, 2007.
- [40] Gerhards R., and Christensen S., "Real-time weed detection, decision making and patch spraying in maize sugarbeet winter wheat and winter barley", Weed Research, 43: 385-392, 2003.
- [41] García-Mateos G., Hernández-Hernández J. L., Escarabajal-Henarejos D., Jaén-Terrones S., and Molina-Martínez J. M., "Study and comparison of color models for automatic image analysis in irrigation management applications", Agricultural

- water management, 151: 158-166, 2015.
- [42] Zheng Y., Zhu Q., Huang M., Guo Y., and Qin J., "Maize and weed classification using color indices with support vector data description in outdoor fields", *Computers and electronics in agriculture*, 141: 215-222, 2017.
- [43] Woebbecke D. M., Meyer G. E., Von Bargen K., and Mortensen D. A., "Plant species identification, size, and enumeration using machine vision techniques on near- binary images", In: DeShazer, J.A., Meyer, G.E. (Eds.), *International Society for Optics and Photonics*, pp. 208-219, 1993.
- [44] Guerrero J. M., Pajares G., Montalvo M., Romeo J., and Guijarro M., "Support vector machines for crop/weeds identification in maize fields", *Expert Systems with Applications*, 39:11149-11155, 2012.
- [45] Saha D., Hanson A., and Shin S. Y., "Development of Enhanced Weed Detection System with Adaptive Thresholding and Support Vector Machine", In: *The International Conference*. ACM Press, New York, New York, USA, 85-88, 2016.
- [46] Woebbecke D. M., Meyer G. E., Bargen K. Von., and Mortensen D. A., "Color indices for weed identification under various soil, residue, and lighting conditions", *Trans. ASAE*. 38: 259-269, 1995.
- [47] Chris Gliever D.C.S., *Crop verses Weed Recognition with Artificial Neural Networks*, Sacramento, American Society of Agricultural and Biological Engineers, St. Joseph, MI, p. 1, CA July 29-August 1, 2001.
- [48] Mathanker S. K., Weckler P. R., Taylor R. K., and Fan G., "Adaboost and Support Vector Machine Classifiers for Automatic Weed Control: Canola and Wheat, Pittsburgh, Pennsylvania", *American Society of Agricultural and Biological Engineers*, St. Joseph, MI, p. 1, 2010.
- [49] Meyer G. E., Hindman T. W., and Laksmi K., "Machine vision detection parameters for plant species identification", In: Meyer, G.E., DeShazer, J.A. (Eds.), *International Society for Optics and Photonics*, pp. 327-335, 1999.
- [50] Kataoka T., Kaneko T., Okamoto H., and Hata S., "Crop growth estimation system using machine vision", In: *Proceedings IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM 2003)*, IEEE, b1079-b1083, 2003.
- [51] Guerrero J. M., Pajares G., Montalvo M., Romeo J., and Guijarro M., "Support vector machines for crop/weeds identification in maize fields", *Expert Systems with Applications*, 39:11149-11155, 2012.
- [52] Meyer G. E., Camargo Neto J., Jones D. D., and Hindman T. W., "Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images", *Comput. Electron. Agric*, 42: 161-180, 2004.
- [53] Meyer G. E., and Neto J. C., "Verification of color vegetation indices for automated crop imaging applications", *Comput. Electron. Agric*, 63: 282-293, 2008.
- [54] Hunt E.R., Cavigelli M., Daughtry C. S. T., McMurtrey J. E., and Walthall C. L., "Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status", *Precis. Agric*, 6: 359-378, 2005.
- [55] Hague T., Tillett N. D., and Wheeler H., "Automated crop and weed monitoring in widely spaced cereals", *Precis. Agric*, 7: 21-32, 2006.
- [56] Burgos-Artiztu X. P., Ribeiro A., Guijarro M., and Pajares G., "Real-time image processing for crop/weed discrimination in maize fields", *Comput. Electron. Agric*, 75: 337-346, 2011.
- [57] Ishak A. J., Hussain A., and Mustafa M. M., "Weed image classification using Gabor wavelet and gradient field distribution", *Comput. Electron. Agric*, 66: 53-61, 2009.
- [58] Wu X., Xu W., Song Y., and Cai M., "A detection method of weed in wheat field on machine vision", *Procedia Eng*, 15: 1998-2003, 2011.
- [59] Jeon H.Y., Tian L.F., and Zhu H., "Robust crop and weed segmentation under uncontrolled outdoor illumination", *Sensors*, 11: 6270-6283, 2011.
- [60] Bakhshipour A., and Jafari A., "Evaluation of support vector machine and artificial neural networks in weed detection using shape features", *Comput. Electron. Agric*, 145: 153-160, 2018.
- [61] Guijarro M., Pajares G., Riomoros I., Herrera P. J., Burgos-Artiztu X. P., and Ribeiro A., "Automatic segmentation of relevant textures in agricultural images", *Comput. Electron. Agric*, 75:75-83, 2011.
- [62] Prema P., and Murugan D., "A novel angular texture pattern (ATP) extraction method for crop and weed discrimination using curvelet transformation", *ELCVIA Electron. Lett. Comput. Vis. Image Anal*, 15:27-59, 2016.
- [63] Haug S., Michaels A., and Biber P., and Ostermann J., "Plant classification system for crop/weed discrimination without segmentation", *IEEE Winter Conference on Applications of Computer*

- Vision (WACV), pp. 1142-1149, 2014.
- [64] Lottes P., Hoferlin M., Sander S., Muter M., Schulze P., and Stachniss L. C., “An effective classification system for separating sugar beets and weeds for precision farming applications”, IEEE International Conference on Robotics and Automation (ICRA), pp. 5157-5163, 2016.
- [65] Lottes P., Hoferlin M., Sander S., and Stachniss C., “Effective vision-based classification for separating sugar beets and weeds for precision farming”, J. F. Robot, 34: 1160-1178, 2016.
- [66] Potena C., Nardi D., and Pretto A., “Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture”, In: Advances in Robot Design and Intelligent Control, Springer International Publishing, Cham, pp. 105-121, 2017.
- [67] Golzarian M. R., and Frick R. A., “Classification of images of wheat, ryegrass and brome grass species at early growth stages using principal component analysis”, Plant Methods, 7:1-11, 2011.
- [68] Kazmi W., Garcia-Ruiz F., Nielsen J., Rasmussen J., and Andersen H. J., “Exploiting affine invariant regions and leaf edge shapes for weed detection”, Comput. Electron. Agric, 118: 290-299, 2015.
- [69] Barrero O., and Perdomo S. A., “RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields”, Precision agriculture, 19: 809-822, 2018.
- [70] Piron A., Leemans V., Kleynen O., Lebeau F., and Destain M. F., “Selection of the most efficient wavelength bands for discriminating weeds from crop”, Computers and Electronics in Agriculture, 62: 141-148, 2008.
- [71] Souza M. F. de., Amaral L. R. do., Oliveira S. R. de. M., Coutinho M. A. N., and Ferreira Netto C., “Spectral differentiation of sugarcane from weeds”, Biosystems Engineering, 190:41-46, 2020.
- [72] Lee W. S., Slaughter D., and Ken Giles D., “Robotic weed control system for tomatoes using machine vision and precision chemical application”, Precision Agriculture, 1: 95-113, 1999.
- [73] Cheng B., and Matson E.T., “A feature-Based machine learning agent for automatic rice and weed discrimination”, Springer, Cham, pp. 517-527, 2015.
- [74] Ahmed F., Al-Mamun H. A., Bari A. S. M. H., Hossain E., and Kwan P., “Classification of crops and weeds from digital images: a support vector machine approach”, Crop Prot, 40: 98-104, 2012.
- [75] Hao P., Wang L., and Niu Z., “Comparison of hybrid classifiers for crop classification using normalized difference vegetation index time series: a case study for major crops in North Xinjiang”, China. PLoS One, 10, e0137748-24, 2015.
- [76] Li N., Grift T. E., Yuan T., Zhang C., Momin M. A., and Li W., “Image processing for crop/weed discrimination in fields with high weed pressure, ASABE International Meeting”, American Society of Agricultural and Biological Engineers, pp. 1-11, 2016.
- [77] Sabzi S., Abbaspour-Gilandeh Y., and Garcia-Mateos G., “A fast and accurate expert system for weed identification in potato crops using metaheuristic algorithms”, Comput. Ind, 98: 80-89, 2018.
- [78] Shirzadifar A. M., Loghavi M., and Raoufat M. H., “Development and Evaluation of a Real Time Site-Specific Inter-Row Weed Management System”, Iran Agricultural Research, Vol. 32, 2013.
- [79] Asefpour Vakilian K., and Massah J., “Performance evaluation of a machine vision system for insect pests identification of field crops using artificial neural networks”, Archives of phytopathology and plant protection, 46: 1262-1269, 2013.
- [80] Slaughter D. C., Giles D. K., and Downey D., “Autonomous robotic weed control systems: A review”, Computers and electronics in agriculture, 61: 63-78, 2008.
- [81] Weis M., and Sökefeld M., “Detection and identification of weeds, In Precision crop protection-the challenge and use of heterogeneity”, Springer, Dordrecht, pp. 119-134, 2010.
- [82] Jeon H. Y., Tian L. F., and Zhu H., “Robust crop and weed segmentation under uncontrolled outdoor illumination”, Sensors, 11: 6270-6283, 2011.
- [83] Das S., “Systematics and taxonomic delimitation of vegetable, grain and weed amaranths: a morphological and biochemical approach”, Genetic resources and crop evolution, 59: 289-303, 2012.
- [84] Herrera P., Dorado J., and Ribeiro A., “A novel approach for weed type classification based on shape descriptors and a fuzzy decision-making method”, Sensors, 14: 15304-15324, 2014.
- [85] Mursalin M., and Mesbah-Ul-Awal M., “Towards Classification of Weeds through Digital Image”, Fourth International Conference on Advanced

- Computing & Communication Technologies (ACCT), pp. 1-4, 2014.
- [86] Rumpf T., Roemer C., Weis M., Soekefeld M., Gerhards R., and Pluemer L., "Sequential support vector machine classification for small-grain weed species discrimination with special regard to *Cirsium arvense* and *Galium aparine*", *Comput. Electron. Agric.*, 80: 89-96, 2012.
- [87] Pereira L. A. M., Nakamura R. Y. M., de Souza G. F. S., Martins D., and Papa J. P., "Aquatic weed automatic classification using machine learning techniques", *Comput. Electron. Agric.*, 87: 56-63, 2012.
- [88] Tannouche A., Sbai K., Rahmoune M., Zoubir A., Agounoune R., Saadani R., and Rahmani A., "A Fast and Efficient Shape Descriptor for an Advanced Weed Type Classification Approach", *International Journal of Electrical & Computer Engineering*, 6: 2088-8708, 2016.
- [89] Chen Z., Wang L., Wu W., Jiang Z., and Li H., "Monitoring plastic-mulched farmland by Landsat-8 OLI imagery using spectral and textural features", *Remote Sensing*, 8: 353, 2016.
- [90] Lin F., Zhang D., Huang Y., Wang X., and Chen X., "Detection of corn and weed species by the combination of spectral", shape and textural features, *Sustainability*, 9: 1335, 2017.
- [91] Vakilian K. A., and Massah J., "An apple grading system according to European fruit quality standards using Gabor filter and artificial neural networks, *Scientific Study & Research*", *Chemistry & Chemical Engineering, Biotechnology, Food Industry*, 17: 75, 2016.
- [92] Minaee S., Abdolrashidi A., and Wang Y., "Iris recognition using scattering transform and textural features", *IEEE signal processing and signal processing education workshop (SP/SPE)*, IEEE, August, pp. 37-42, 2015.
- [93] Sujaritha M., Annadurai S., Satheshkumar J., Sharan S. K., and Mahesh L., "Weed detecting robot in sugarcane fields using fuzzy real time classifier", *Computers and electronics in agriculture*, 134: 160-171, 2017.
- [94] Bossu J., G'ee C., and Truchetet F., "Development of a machine vision system for a real time precision sprayer", *Electronic Letters on Computer Vision and Image Analysis*, 7: 54-66, 2008.
- [95] Utstumo T., Urdal F., Brevik A., Dørum J., Netland J., Overskeid Ø., and Gravidahl J. T., "Robotic in-row weed control in vegetables", *Computers and electronics in agriculture*, 154: 36-45, 2018.
- [96] Campos Y., Sossa H., and Pajares G., "Comparative analysis of texture descriptors in maize fields with plants, soil and object discrimination", *Precision agriculture*, 18: 717-735, 2017.
- [97] Ahmad J., Muhammad K., Ahmad I., Ahmad W., Smith M. L., Smith L. N., and Mehmood I., "Visual features based boosted classification of weeds for real-time selective herbicide sprayer systems", *Computers in Industry*, 98: 23-33, 2018.
- [98] Geé C., Bossu J., Jones G., and Truchetet F., "Crop weed discrimination in perspective agronomic images", *Computers and Electronics in Agriculture*, 60: 49-59, 2008.
- [99] Tellaeche A., BurgosArtiz X. P., Pajares G., Ribeiro A., and Fernández-Quintanilla C., "A new vision-based approach to differential spraying in precision agriculture", *Computers and Electronics in Agriculture*, 60: 144-155, 2008.
- [100] Olsen H., "Determination of row position in small-grain crops by analysis of video images", *Computers and Electronics in Agriculture*, 12: 147-162, 1995.
- [101] Sogaard H., and Olsen H., "Determination of crop rows by image analysis without segmentation", *Computers and Electronics in Agriculture*, 38: 141-158, 2003.
- [102] Sapkota B., Singh V., Cope D., Valasek J., and Bagavathiannan, M., "Mapping and Estimating Weeds in Cotton Using Unmanned Aerial Systems-Borne Imagery", *AgriEngineering*, 2: 350-366; 2020.
- [103] Chen Y., Zhu H., Ozkan H., Derksen R., and Krause C., "Spray drift and off-target loss reduction with a precision air-assisted sprayer", *Transactions of the American Society of Agricultural and Biological Engineers*, 56: 1273-1281, 2013.
- [104] Zhu H., Derksen R., Guler H., Krause C., and Ozkan H., "Foliar deposition and off-target loss with different spray techniques in nursery applications", *Transactions of the American Society of Agricultural and Biological Engineers*, 49: 325-334, 2006.
- [105] Zohaib M., Kim H., and Choi M., "Detecting global irrigated areas by using satellite and reanalysis products", *Science of The Total Environment*, 677: 679-691, 2019.
- [106] Mendes W. R., Araújo F. M. U., Dutta R., and

- Heeren D. M., "Fuzzy control system for variable rate irrigation using remote sensing", *Expert Systems with Applications*, 124: 13-24, 2019.
- [107] Ma S., Zhou Y., Gowda P. H., Dong J., Zhang G., Kakani V. G., and Jiang W., "Application of the water-related spectral reflectance indices: A review", *Ecological indicators*, 98: 68-79, 2019.
- [108] Chakraborty M., Khot L. R., and Peters R. T., "Assessing suitability of modified center pivot irrigation systems in corn production using low altitude aerial imaging techniques", *Information Processing in Agriculture*, 2019.
- [109] Chen A., Orlov-Levin V., and Meron M., "Applying high-resolution visible-channel aerial imaging of crop canopy to precision irrigation management", *Agricultural water management*, 216: 196-205, 2019.
- [110] Maghsoudi H., Minaei S., Ghobadian B., and Masoudi H., "Ultrasonic sensing of pistachio canopy for low-volume precision spraying", *Computers and Electronics in Agriculture*, 112: 149-160, 2015.
- [111] Hocevar M., Sirok B., Jecic V., Godesa T., Lesnik M., and Stajko D., "Design and testing of an automated system for targeted spraying in orchards", *Journal of Plant Diseases and Protection*, 117: 71-79, 2010.
- [112] Lee K. H., and Ehsani R., "A Laser Scanner Based Measurement System for Quantification of Citrus Tree Geometric Characteristics", *Applied Engineering in Agriculture*, 25: 777-788, 2009.
- [۱۱۳] آسائی ه.، جعفری ع.، لغوی م.، «ساخت و ارزیابی سمپاش هدفدار باغی با استفاده از فناوری ماشین‌بینایی»، *مجله ماشینهای کشاورزی*، دوره ۶، شماره ۲، ص ۳۷۵-۳۶۲، ۱۳۹۵.
- [114] Oberti R., Marchi M., Tirelli P., Calcante A., Iriti M., Tona E., Hocevar M., Baur J., Pfaff J., Schutz C., and Ulbrich H., "Spraying of grapevines for disease control using a modular agricultural robot", *Biosystems engineering*, 146: 203-215, 2016.
- [۱۱۵] نداف‌زاده م.، آبدانان مهدی‌زاده س.، آسودار م.، صالحی سلمی م.، «طراحی و توسعه سامانه کنترل هوشمند تعیین آب مورد نیاز گیاهان گلخانه‌ای با کمک بینایی ماشین (مورد مطالعه: گیاه حُسن‌یوسف)»، *مجله مهندسی بیوسیستم ایران*، دوره ۴۸، شماره ۲، ص ۲۹۷-۲۸۵، ۱۳۹۶.
- [۱۱۶] نداف‌زاده م.، آبدانان مهدی‌زاده س.، صالحی سلمی م.، «پیش‌بینی و کنترل محتوای رطوبت گیاه چمن توسط یک سامانه هوشمند با بکارگیری پردازش تصویر و الگوریتم رگرسیون بردار پشتیبان»، *مجله ماشین‌بینایی و پردازش تصویر*، دوره ۵، شماره ۲، ص ۸۵-۱۰۲، ۱۳۹۷.
- [117] Hussain M., Naqvi S. H. A., Khan S. H., and Farhan M., "An Intelligent Autonomous Robotic System for Precision Farming", 3rd International Conference on Intelligent Autonomous Systems (ICoIAS), Singapore, pp. 133-139, 2020.
- [118] Hejazipour H., Massah J., Soryani M., Asefpour Vakilian K., and Chegini G., "An intelligent spraying robot based on plant bulk volume", *Computers and Electronics in Agriculture*, 180: 105859, 2021.
- [۱۱۹] سلطانی محمدی س.، لک م.، محمدی س.، کربلا م.ا.، «تخمین ارتفاع سطح ایستابی در روزهای مختلف سال با استفاده از شبکه عصبی مصنوعی شعاعی؛ مطالعه موردی: دشت بهبهان»، *مجله محاسبات نرم*، جلد ۳، شماره ۱، ص ۹۳-۸۲، ۱۳۹۳.