

استفاده از روش‌های یادگیری عمیق برای ارزیابی کیفیت کاشت غلات

هادی کریمی^{۱*}، حسین نوید^۲ و راسموس نایلهوم یورگنسن^۳

چکیده

یکی از روش‌های ارزیابی عملکرد خطی کارها مقایسه درستی عملکرد آن با بررسی جمعیت رویش گیاهان کشت شده در واحد سطح مزرعه می‌تواند باشد. به نظر می‌رسد پیکسل‌های محل رویش گیاهان دارای ویژگی‌های مشابهی با توجه به تغییرات پارامترهای تصویر زمین و گیاهان هستند. استفاده از روش یادگیری عمیق بر پایه شبکه‌های عصبی کانولوشن برای ایجاد نقشه مناطق مورد نظر در تصویر مناسب به نظر می‌رسد. در این رابطه، در مجموع ۲۷۲۰ تصویر از غلات که در مراحل اولیه رشد قرار داشتند از مزرعه مورد نظر گرفته شد. ۲۱۲ تصویر با پس‌زمینه‌های مختلف انتخاب و برای تغذیه و آموزش یک شبکه عصبی کانولوشنی علامت‌گذاری شدند. تصاویر خام به‌عنوان ورودی و نقشه‌های نقاط رویش علامت‌گذاری شده دستی به‌عنوان خروجی شبکه تعریف شدند. بررسی خروجی اولیه شبکه نشان داد که شبکه آموزش دیده به نوک برگ‌های گیاهان، علف‌های هرز و بقایای گیاهی به اشتباه به‌عنوان نقاط رویش گیاه پاسخ داده است. برای غلبه بر این خطاها و بهبود عملکرد شبکه، یک تابع جریمه برای نقاط پیش‌بینی شده به‌صورت غلط، تعریف شد. شبکه با سه نرخ جریمه آموزش دیده و برای هر نرخ، شبکه با ۹ گام آستانه سافت مکس ارزیابی شد. با توجه به خروجی شبکه، تصاویر از نظر تراکم گیاهی محدودبندی شد. برای ارزیابی مدل در محدوده‌های مختلف، در هر محدوده مشخص تصاویری از مزرعه به‌صورت تصادفی انتخاب شدند. این تصاویر به مدل خورنده و خروجی‌های آن‌ها با حقیقت مقایسه شد. میانگین هارمونی شاخص دقیق و شاخص فراخوانی در محدوده‌هایی که حدود ۹۴ درصد از مجموع تصاویر مزرعه در آن قرار داشت بالای ۸۰ درصد تخمین زده شد که نشان دهنده عملکرد مناسب مدل در این زمینه است. نتایج نشان داد که مدل می‌تواند بازخورد قابل قبولی در مورد عملکرد کاشت ارائه کرده و مدیریت و کارایی مزرعه را در گام‌های بعدی بهبود ببخشد.

واژه‌های کلیدی: ارزیابی عملکرد، جمعیت رویش گیاهان، خطی‌کار، شبکه عصبی کانولوشنی، کاشت، یادگیری عمیق.

ارجاع: کریمی، ه. نوید، ح. و نایلهوم یورگنسن، ر. ۱۳۹۹. استفاده از روش‌های یادگیری عمیق برای ارزیابی کیفیت کاشت غلات. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۹(۲): ۱۱۹-۱۳۱.

۱- استادیار پژوهشی بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان کرمان، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرمان، ایران.

۲- دانشیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز.

۳- استاد پژوهشی، گروه مهندسی - پردازش سیگنال، دانشگاه آرهوس، دانمارک.

* نویسنده مسئول: h_karimi@areeo.ac.ir

تاریخ دریافت: ۱۳۹۸/۱/۱۹ تاریخ پذیرش: ۱۳۹۹/۰۱/۱۹

مقدمه

هنگام فرآیند کاشت با کارنده‌ها ممکن است نرخ کاشت با توجه به فاکتورهای مربوط به عملکرد موزع و سرعت حرکت آن‌ها در درون مزرعه تغییر کند. همچنین به دلیل چرخه بسته فرآیند کاشت در خطی‌کارها، عدم کاشت بذرها در وسعت زیاد به دلیل مشکلاتی نظیر خرابی‌های مکانیسم توزیع بذر، گرفتگی لوله‌های بذر، محفظه خالی بذر و غیره می‌تواند اجتناب‌ناپذیر گردد (Lu et al., 2017). به‌روشنی می‌توان دریافت که پایش کیفیت و کمیت کاشت در تولید مواد غذایی و امنیت غذایی دارای اهمیت بسیار فراوانی است.

در سامانه‌های پایش موجود، عملیات پایش کاشت توسط حسگر نصب شده در لوله سقوط انجام می‌گیرد. این در حالی است که، عملکرد کاشت یک کارنده علاوه بر کارکرد بخش‌های مختلفی چون مکانیسم موزع و مسیر هدایت بذر به درون شیار، به کیفیت کاری قسمت‌هایی که باید با کمترین پرش بذر را در خاک تثبیت کنند، نوع و شرایط خاک، خواص فیزیکی بذر، سرعت عملیات کشت و موارد دیگر وابسته است (Murray et al., 2006; Virk et al., 2019). بنابراین با روش‌های معمول برای پایش عملکرد کاری کارنده که با نصب حسگر جریان بذر در محل لوله سقوط همراه است به قضاوت کاملی در مورد کیفیت کاشت کارنده نمی‌توان دست‌یافت. علاوه بر این در کنار عملکرد کارنده، رویش گیاهان تحت تأثیر شرایط پرتش محیطی مانند فقدان رطوبت کافی یا مقدار بیش از اندازه آن، تغییرات دما و غیره قرار می‌گیرد (Liu et al., 2017a). با تعیین جمعیت رویش گیاهان در واحد سطح علاوه بر امکان ارزیابی کارایی سامانه پایش کاشت و سنجش عملکرد کاشت در طول یک مزرعه، تهیه یک نقشه منصفانه پراکنش کاشت برای محصول کشت شده امکان‌پذیر خواهد بود.

در مورد شناسایی گیاهان رویش یافته پژوهش‌های متعددی صورت پذیرفته است. الگوریتم‌های ماشین‌بینایی مبتنی بر دید دوبعدی برای شناسایی انفرادی گیاهان، شمارش و تعیین فاصله کاشت آن‌ها توسعه داده شده‌اند (Shrestha & Steward, 2003; Tang & Tian, 2008). در این روش‌ها، تصاویر موزاییکی نمای بالا گیاهان در امتداد ردیف محصولات، برای تعیین مکان انفرادی گیاهان پردازش می‌شوند. استفاده از نمای دوبعدی مشکلاتی در

تشخیص انفرادی گیاهان ایجاد می‌کند. این مشکلات به سختی پردازش تصاویر در نمای دید از بالا با وجود تغییرات نور و هم‌پوشانی گیاهان مجاور مربوط می‌شود. سامانه نمای استریو که می‌تواند با فراهم‌آوری نمای بالا تصاویری عمیق فراهم کند، قابلیت ارتقا عملکرد سامانه ماشین‌بینایی در شناسایی نقطه رویش ساقه گیاهان را داراست. (Jin & Tang, 2009) نشان دادند که چنین الگوریتمی با استفاده از اطلاعات عمق تصویر، به‌صورت کارآمد توان تشخیص اسکلت گیاهان را دارد. در ادامه توسعه سامانه‌های ماشین‌بینایی مربوط به سنجش مکان گیاهان، استفاده از تصاویر محصول با نمای عمق جانبی مورد توجه قرار گرفت (Nakarmi & Tang, 2012; Nakarmi & Tang, 2010). کارایی سامانه‌های مبتنی بر دید جانبی به وسیله قابلیت تشخیص گیاهان خم‌شده، بهبود پیدا کرد. ناکامی و تنگ (Nakarmi & Tang, 2012) یک سامانه سه‌بعدی مبتنی بر شدت نور تصاویر کسب‌شده از دید جانبی را پیشنهاد دادند. در این سامانه فاصله، شدت و دامنه داده‌ها تنها در یک شات به‌دست می‌آید و مرکز ساقه‌ها با استفاده از روش مبتنی بر ویژگی پردازش تصاویر متوالی محاسبه می‌شود. اگرچه در مقایسه با سامانه‌های معمول بینایی ماشین، سامانه مبتنی بر نور به اطلاعات رنگ وابسته نبود، حساسیت به شرایط نوری و محدودیت در تشخیص گیاهان متعدد در فاصله کوتاه همچنان باقی می‌ماند. (Nakarmi & Tang, 2014) پیشنهاد سامانه دریافت تصاویر عمیق با تحلیل سه تصویر متوالی رویکردی نو در توسعه سامانه ماشین‌بینایی با دید جانبی ارائه کردند. اشتباهات با انتخاب بهترین تخمین فاصله بین گیاهان با دریافت یک‌باره چندین تصویر متوالی، کاهش یافت. روش چندبعدی در کاهش اثرات نور منعکس‌کننده و اندازه‌گیری گیاهان متعدد رشد کرده در فاصله نزدیک به هم نیز کارا بود.

سامانه‌های ماشین‌بینایی توسعه‌یافته برای مکان‌یابی گیاهان، به‌طور معمول با محدودیت‌ها و مشکلات متعددی مانند تغییرات رنگ ناشی از ساختار سایه‌ها و تشعشع نور، تغییرات نور روز، مشکل جداسازی علف‌های هرز پس‌زمینه، پوشش سایبانی گیاهان مجاور و غیره مواجه هستند، به‌طوری‌که الگوریتمی که بر مبنای این تصاویر توسعه یابد تنها می‌تواند تحت شرایط یکسان مانند اندازه گیاه، رنگ و شکل، ترکیب پس‌زمینه، نور، و غیره عمل

مواد و روش‌ها

آزمایش‌های مزرعه‌ای

آزمایش‌ها در مزارع واقع در کشور دانمارک انجام گرفت. از خطی‌کار نیوماتیک برای کاشت غلات استفاده شد. تصویربرداری زمانی صورت گرفت که غلات در مراحل اولیه رشد خود قرار داشتند این حالت زمانی بود که تخمین زده می‌شد تمامی گیاهان به مرحله رویش رسیده و کاملاً از همدیگر قابل تمایز هستند (شکل ۱). همان‌طور که در شکل ۱ مشاهده می‌شود مزرعه مورد نظر آلوده به علف‌های هرز و بقایای گیاهی بود. در مجموع ۲۷۲۰ تصویر از مزارع مورد نظر جمع‌آوری شد. تصویربرداری از محصولات توسط یک خودرو (ATV^۱) که در گروه پردازش سیگنال دانشگاه آرهوس طراحی و ساخته شده بود، انجام گرفت (Laursen et al., 2017) (شکل ۱). تجهیزات تصویربرداری شامل دوربین ۵ مگاپیکسلی (Point Grey, GS3-U3-51S5C-C) مجهز شده به یک لنز ۲۵ میلی‌متری (Edmund optics) و یک فلش رینگ (AlienBees, ABR800) برای تأمین نور مورد نیاز بود. بستر کامپیوتر تعبیه شده بر پایه لینوکس در پلت فرم داده‌برداری ATV، توانایی اخذ تصاویر به همراه موقعیت مکانی به دست آمده از طریق گیرنده RTK-GNSS (Trimble BD920 RTK-GNSS) را دارا بود. سامانه به‌گونه‌ای تنظیم شده بود که با حرکت دستگاه در هر ۱۰ متر نمونه‌برداری انجام گیرد. به‌طوری‌که فاصله بین هر تصویربرداری با توجه به مسافت طی شده از آخرین تصویر اخذ شده، تعیین می‌شد. نمونه‌برداری نخست از گردش دستگاه ATV دور محیط مزرعه شروع و سپس پوشش باقی‌مانده مزرعه، به‌صورت نظامند بین خطوط کاشت انجام می‌شد. به این ترتیب شبکه‌ای ۱۰ مترمربعی از نمونه‌برداری کل مزرعه فراهم می‌گشت. موقعیت مکانی تصاویر گردآوری شده به‌صورت نقشه در شکل ۱ نشان داده شده است. وضوح تصاویر جمع‌آوری شده ۲۴۵۴×۲۰۵۴ پیکسل بود. دوربین حدود ۱/۸ متر از سطح مزرعه ارتفاع داشت که تصویری به وسعت ۱/۱۱ × ۰/۸۱ مترمربع را از سطح زمین فراهم می‌کرد. فاصله محوری چرخ‌های ATV به‌گونه‌ای بود که اثر چرخ‌ها روی محصولات کشاورزی در قسمت عقب در تصاویر ثبت نمی‌شد.

کند. علاوه بر این، سامانه‌های معرفی شده، برای مکان‌یابی محصولات چون ذرت که به‌وسیله دقیق‌کارها کشت می‌شوند توسعه داده شدند. در این نوع کشت، بذرها به‌صورت جداگانه و در فواصل مشخص و متمایز کشت می‌شوند. این شرایط موجب می‌شود که پردازش تصویر بدون مزاحمت گیاهان مجاور آسان‌تر گردد. به‌علاوه در برخی از این سامانه‌ها علف‌های هرز پیش از تصویربرداری از مزرعه حذف می‌شدند. این در حالی است که بذرها کشت شده به‌وسیله خطی‌کارها که غالباً از خانواده غلات هستند دارای الگویی تصادفی و با فاصله ردیفی باریک هستند (Murray et al., 2006). این حالت منجر به مداخلات بسیاری در میان گیاهان مجاور می‌شود. اگرچه تلاش‌هایی برای تخمین جمعیت غلات صورت گرفته است (Jin et al., 2017; Liu et al., 2017b)، این مسئله چالشی بزرگ برای سامانه‌هایی هست که با به‌کارگیری روش‌های پردازش ماشین معمول، نقطه رویش ساقه گیاهان و جمعیت آن‌ها در واحد سطح را تخمین می‌زنند.

در سال‌های اخیر، یادگیری عمیق، تحولی بزرگ در زمینه پردازش تصویر و هوش مصنوعی ایجاد کرده است (Dyrmann et al., 2016). یادگیری عمیق زیرشاخه‌ای از یادگیری ماشین است که از لایه‌های متعدد تبدیلات خطی به منظور پردازش سیگنال‌های تصویر استفاده می‌کند. ماشین در این روش هر مفهوم پیچیده را به مفاهیم ساده‌تری تقسیم می‌کند، و با ادامه این روند به مفاهیم پایه‌ای می‌رسد که قادر به تصمیم‌گیری برای آن‌ها است. به نظر می‌رسد پیکسل‌های محل رویش گیاهان دارای ویژگی‌های مشابهی با توجه به تغییرات پارامترهای تصویر زمین و گیاهان است. استفاده از روش یادگیری عمیق بر پایه شبکه‌های عصبی کانولوشن برای ایجاد نقشه مناطق مورد نظر در تصویر مناسب به نظر می‌رسد. هدف این پژوهش بررسی امکان شناسایی نقطه رویش محصول و در نهایت ارزیابی کیفی کارنده‌های خطی‌کار با استفاده از روش‌های یادگیری عمیق و شبکه‌های عصبی کانولوشن است. تحقیقات مربوط به شناسایی نقطه رویش در طول دوره کوتاه تحقیقات، در گروه پردازش سیگنال دانشگاه آرهوس انجام شد.

1- all-terrain vehicle



شکل ۱- نمونه از سطح مزرعه داده‌برداری شده



شکل ۲- یک نمونه از نقشه موقعیت مکانی تصاویر جمع‌آوری شده از سطح مزرعه

مدل پیشنهادی

هدف این پژوهش توسعه مدلی برای شناسایی نقطه رویش انفرادی هر گیاه در تصاویر مزرعه بود. به طوری که برای هر پیکسل در تصویر ورودی شبکه باید در مورد برچسب مربوط به این که آیا این پیکسل یک نقطه رویش گیاه است یا خیر، تصمیم‌گیری کند. معماری شبکه عصبی استفاده‌شده مبتنی بر معماری شبکه عصبی تمام کانولوشنی^۱ با گام^۲ هشت، FCN-8 هست که توسط لانگ و همکاران (۲۰۱۵) ارائه شد. پیرو روش استفاده شده توسط لانگ و همکاران (Long et al., 2015) و شبکه‌های

عصبی کانولوشن ۱۶ لایه‌ای VGG16^۳ (Simonyan & Zisserman, 2014)، یک شبکه تمام کانولوشنی با حفظ پارامترهای آموزش‌یافته ساخته شد. لایه طبقه‌بندی نهایی توسط یک لایه کانولوشن ۱ × ۱ با دو هسته جایگزین شد تا تمایز نهایی را بین نقطه رویش و پس‌زمینه فراهم کند. روش لانگ و همکاران (Long et al., 2015) با استفاده از وزن‌های پیش آموزش داده‌شده VGG16 (Simonyan & Zisserman, 2014)، از شبکه ImageNet برای جداسازی معنایی^۴ به دو کلاس، بازآموزی شد.

3- Visual Geometry Group
4- Semantic Segmentation

1- Fully-Convolutional Neural Network
2- Stride

آماده‌سازی تصاویر

شبکه توسعه یافته باید بتواند یک برچسب برای هر پیکسل در یک تصویر اختصاص دهد به طوری که نقاط رویش و پس‌زمینه تمیز داده شوند. برای آماده‌سازی تصاویر برای فرایند آموزش، مجموعه منتخبی از تصاویر باید به صورت دستی با نقاط رویش شناخته شده علامت‌گذاری شود. تصاویر انتخاب شده باید تا جای ممکن نماینده مناسبی از گوناگونی انواع نقاط رویش گیاه و شرایط مختلف پس‌زمینه شامل تغییرات خاک و علف هرز باشد. بیشترین تلاش‌ها توسط چشم‌های آموزش دیده به منظور انتخاب تصاویر از تراکم‌های متنوع گیاهی و پس‌زمینه‌های با باقی‌مانده‌های مختلف زیست‌توده و خاک صورت گرفت. در این مورد، ۲۱۲ تصویر با پس‌زمینه‌های مختلف انتخاب و برای تغذیه و آموزش یک شبکه عصبی تمام کانولوشنی علامت‌گذاری شدند. به عنوان مثال، شکل نمونه‌ای از نحوه علامت‌گذاری را در این مرحله نشان می‌دهد. نقاط رویش گیاهان غلات با دایره‌های توپر قرمز با قطر ۲۰ پیکسل، در یک لایه تصویر جداگانه با استفاده از نرم‌افزار ^۱GIMP به صورت دستی علامت‌گذاری شدند.



+



شکل ۳- نمونه‌ای از نحوه علامت‌گذاری نقاط رویش

آموزش مدل

توسعه اولیه شبکه عصبی کانولوشن مبتنی بر پیکسل‌های محلی، با استفاده از مدل FCN-8s و تابع هزینه استاندارد کراس آنترپی^۲ انجام گرفت. عملیات توسعه این شبکه با استفاده از کتابخانه تنسورفلو (Tensorflow) در محیط برنامه‌نویسی پایتون اجرا شد. تصاویر خام به‌عنوان ورودی و نقشه‌های نقاط رویش علامت‌گذاری شده دستی به‌عنوان خروجی شبکه FCN تعریف شدند. به منظور محاسبه هزینه شبکه، خروجی پیش‌بینی شده توسط شبکه با نقشه از پیش علامت‌گذاری شده پیکسل‌ها مقایسه می‌شدند سپس خطاهای پیش‌بینی به عقب بازگردانده شده^۳ و به‌روزرسانی پارامترهای شبکه انجام می‌گرفت. در طول آموزش، تمام تصاویر به صورت تصادفی به قطعات ۱۵۰۰×۱۵۰۰ پیکسل بریده شدند تا احتمال بیش‌برازش شدن مدل کاهش یابد. با توجه به محدودیت حافظه، مدل تنها قادر به‌قرار دادن یک تصویر در حافظه گرافیکی (Nvidia TitanX GPU) مورد استفاده بود. در طول آموزش، خروجی شبکه شامل یک تصویر با ابعاد ۱۵۰۰×۱۵۰۰ پیکسل می‌شد که دو کانال خروجی آن منعکس‌کننده دو کلاس شامل پیکسل‌های نقاط رویش و پس‌زمینه بود. این شبکه برای ۴۰ دوره^۴ با استفاده از بهینه‌ساز ادگارد^۵ با نرخ یادگیری ۰/۰۳ آموزش داده شد. بعد از دوره ۳۲ و ۳۶، میزان یادگیری به وسیله یک عامل ۲ برابر شد. اگرچه آزمایش‌های اولیه موفقیت‌آمیز بودند، با این وجود خطاهایی در شناسایی نقاط رویش گیاه وجود داشت. بررسی خروجی تصاویر و خروجی تابع سافت‌مکس^۶ نشان داد که در برخی موارد شبکه آموزش دیده به نوک برگ‌های گیاهان، علف‌های هرز و بقایای گیاهی به اشتباه به‌عنوان نقاط رویش گیاه پاسخ داده‌است. برای غلبه بر این خطاها و بهبود عملکرد شبکه، یک تابع جریمه^۷ برای نقاط پیش‌بینی شده به صورت غلط، تعریف شد، به طوری که در فرایند آموزش، جریمه با پیش‌بینی نقاط مشخص شده به‌عنوان نقاط جریمه افزایش می‌یافت. جریمه در شبکه عصبی کانولوشنی با افزایش تابع هزینه در حالیکه معماری شبکه بدون تغییر باقی می‌ماند تعریف شد. تابع هزینه

2- Standard Cross-Entropy Loss Function

3- Backpropagate


4- Epoch

5- Adagrad

6- Softmax

7- Penalty Function

1- GNU Image Manipulation Program



شکل ۴- نقاط جریمه به رنگ آبی، نقاط رویش علامت‌گذاری شده به رنگ قرمز و رنگ سبز مرز بین نقاط رویش و نقاط جریمه

روش ارزیابی

با توجه به نامتعادلی سنگینی که بین کلاس پیکسل‌های نقاط رویش و پیکسل‌های پس‌زمینه وجود داشت، تخمین کلاس‌بندی پیکسل‌های تصویر به‌دقت غیرواقعی ۹۹ درصد می‌رسید و این شاخص قابلیت نمایندگی دقت کلاس‌بندی بین نقاط رویش و پس‌زمینه را نداشت. به‌جای مقایسه پیکسل‌های کلاس‌بندی شده، بررسی توانایی شناسایی نقاط رویش معیارهای به‌صورت شیء برای ارزیابی عملکرد مناسب‌تر به‌نظر می‌رسد. استفاده از شاخص فراخوانی^۳ (۲) که از پیش‌بینی درست پس‌زمینه مستقل است، نتایج منطقی‌تری را به همراه خواهد داشت. شاخص دقت^۴ (۳) تعداد نقاط صحیح را در مقابل تمام نقاط شناسایی‌شده محاسبه می‌کند. به‌عبارت دیگر شاخص فراخوانی در رابطه با کسری از تشخیص درست نسبت به تمام نقاط علامت‌گذاری شده است. شاخص فراخوانی به نقاط جامانده در پیش‌بینی مدل و شاخص دقت به نقاطی که به‌صورت اشتباه به‌عنوان نقطه صحیح پیش‌بینی شده حساس هستند (Martin et al., 2004; Visa & Salembier, 2014). شاخص دقت و فراخوانی به شرح زیر تعریف می‌شود:

کراس- آنترپی^۱ با وزن‌های جریمه در معادله (۱) نشان داده شده‌است.

$$E = -\frac{1}{K} \sum_{n=1}^N \sum_{k=1}^K p_n t_{nk} \ln(y_{nk}) \quad (1)$$

که در آن، N تعداد پیکسل‌ها در تصویر ورودی، k تعداد کلاس‌ها، p_n مجازات برای تک‌تک پیکسل‌ها و t_{nk} ارزش هدف داغ کدگذاری شده^۲ است.

y_{nk} با توجه به پیش‌بینی شبکه عصبی کانولوشنی نواحی جریمه در هر تصویر و خروجی که از شبکه آموزش دیده اولیه به‌دست آمد، تعیین شد. به‌گونه‌ای که در هر تصویر نقاط جریمه از تفریق نقاط رویش علامت‌گذاری حقیقی و خروجی شبکه اولیه به دست می‌آمد. در ماسک خروجی، ارزش یک به نقاط رویش گیاه و دو به مناطق جریمه اختصاص داده‌شد. از آنجایی که تشخیص دقیق موقعیت پیکسل‌های مربوط به نقاط رویش کار دشواری است، در مقایسه با پیش‌بینی‌های کامپیوتری ممکن است از نقاط رویش علامت‌گذاری شده به اندازه چند پیکسل جابه‌جا شوند. بنابراین، به‌منظور کمک به کامپیوتر برای تشخیص موقعیت صحیح، یک منطقه بدون جریمه در اطراف نقاط علامت‌گذاری مشخص‌شده، ساخته شد (شکل). با داشتن این نواحی بدون جریمه، کامپیوتر به سمت تشخیص صحیح مکان رویش هدایت می‌شود. نقاط جریمه نوک برگ‌های گیاه و مناطقی هستند که به نقاط رویش واقعی شباهت دارند. پس از تعیین نقاط جریمه، شبکه با این مناطق جریمه جدید بازآموزی شد. سپس مدل آموزش دیده با ۹ مرحله آستانه سافت‌مکس ۰/۱، ۰/۲، ۰/۳، ۰/۴، ۰/۵، ۰/۶، ۰/۷، ۰/۸ و ۰/۹ درصد مورد ارزیابی قرار گرفت. بنابراین، مجموعه‌ای از ۲۷ مدل مورد بررسی قرار گرفتند. گام‌های آستانه سافت‌مکس احتمال اختصاص نقاط تصویر به هر کلاس هدف شامل پس‌زمینه و نقاط رویش را تعیین می‌کند.

3- Recall
4- Precision

1- Cross-Entropy Loss
2- One-Hot Coded Target

شدند. نقاط آبی، نقاطی هستند که توسط مدل به اشتباه به‌عنوان نقاط رویش تشخیص داده شده‌اند، در مقابل نقاط قرمز، نقاط رویش از پیش علامت‌گذاری شده‌ای هستند که مدل نتوانسته به درستی آن‌ها را پیش‌بینی کند.

تحلیل نتایج

مکان‌یابی نقاط رویش گیاهان غلات

شبکه با سه وزن جریمه مختلف آموزش دیده شد. برای هر نرخ وزن جریمه وضع شده، شبکه با ۹ گام آستانه سافت‌مکس ارزیابی شد. بهترین وزن جریمه و آستانه سافت‌مکس همان‌طور که شکل نشان می‌دهد به ترتیب ۷۵ و ۰/۴ مشخص شد. این شکل میانگین نتایج به دست آمده از ۸۴۸ تصویر (۲۱۲ تصویر علامت‌گذاری شده با چرخش ۹۰ درجه و آینه‌ای شده) را نشان می‌دهد. به علاوه شکل نشان می‌دهد که با اضافه کردن نواحی جریمه به تصاویر آموزشی، عملکرد شبکه به طور قابل توجهی افزایش می‌یابد. علاوه بر وزن‌های جریمه ۵۰ و ۷۵، شبکه با وزن‌های جریمه ۱۰۰ و ۱۲۵ نیز آموزش دید. اما شبکه با این تنظیمات به نتایج مفیدی نزدیک نشد. این مسئله احتمالاً به این دلیل بود که نواحی مشخص شده برای جریمه ویژگی‌هایی نزدیک به نقاط رویش واقعی داشتند و با افزایش وزن جریمه شبکه در انتخاب نقاط واقعی رویش نیز با جریمه روبه‌رو می‌شدند.

$$F = \frac{2 \times P \times R}{P + R} \quad (4)$$


$$R = \frac{TP}{TP + FN} \quad (2)$$

$$P = \frac{TP}{TP + FP} \quad (3)$$

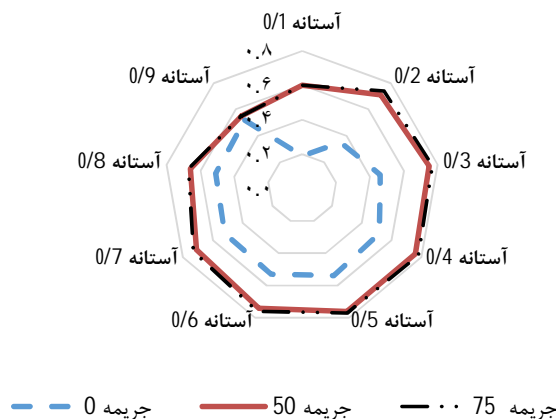
که در آن، P و R به ترتیب شاخص دقت و شاخص فراخوانی، TP شاخص تشخیص صحیح نقاط، FP تشخیص اشتباه و FN تشخیص غلط پس‌زمینه و FN نقاط جامانده را نشان می‌دهد. با توجه به علامت‌گذاری دستی انجام شده در حالت ایده‌آل، مدل توسعه‌یافته باید بتواند بدون هیچ جاگذاری و اشتباهی، نقاط رویش گیاه با شاخص دقت و فراخوانی برابر با یک را تشخیص دهد.

این معیارها عملکرد مدل را از دو بعد بررسی می‌کند. این شاخص به صورت انفرادی قضاوت منصفانه‌ای از عملکرد سامانه نمی‌تواند ارائه دهند. به طوری که دستگاهی با احتمال تشخیص اشتباه شاخص فراخوانی بالا و همچنین دقت بالا می‌تواند نشانگر سامانه‌ای با احتمال جاگذاری نقاط باشد. برای داشتن یک قضاوت جامع درباره سامانه با یک مقدار واحد، میانگین هارمونی شاخص دقت و شاخص فراخوانی به صورت F تعریف شد (معادله (۴)).

شاخص‌های بالا با تطابق علامت‌گذاری‌های دستی انجام شده با نقشه خروجی شبکه برای هر تصویر محاسبه شد. شکل یک نمونه از تطابق انجام شده بین نقاط از پیش علامت‌گذاری شده و نقاط پیش‌بینی در خروجی شبکه را نشان می‌دهد. نقاط هم‌پوشانی شده با رنگ صورتی و یک خط سفید بین آن‌ها به‌عنوان پیش‌بینی‌های صحیح نقاط رویش در نظر گرفته شد. این نقاط به‌عنوان TP که پیش از این در معادلات (۲) و (۳) توضیح داده شده، شمارش

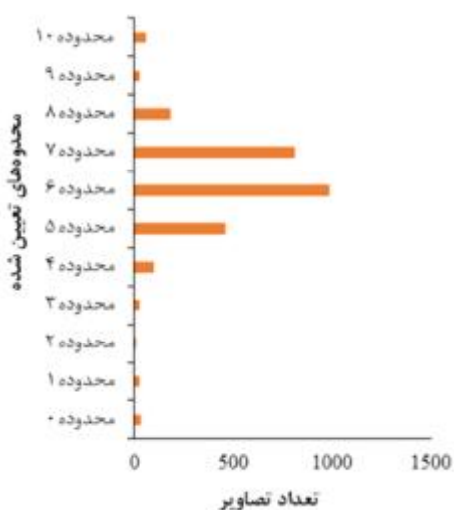


شکل ۵- یک نمونه از تطابق انجام شده بین نقاط از پیش علامت‌گذاری شده و نقاط پیش‌بینی شده توسط شبکه



شکل ۶- ارزیابی توانایی شبکه در سه نرخ جریمه و نه گام آستانه سافت‌مکس

رویش ساقه گیاه با کالیبراسیون پیکسلی بیشتر به‌عنوان تراکم محصولات در واحد سطح می‌تواند محسوب شود.



شکل ۷- طبقه‌بندی تصاویر با توجه به تعداد نقاط رویش هر تصویر


ارزیابی مدل

از مزرعه، در هر محدوده، تصاویر به‌صورت تصادفی برای ارزیابی مدل انتخاب شد. این تصاویر به شبکه خوراندند شدند و خروجی‌های آن‌ها با حقیقت که معادل با علامت‌گذاری‌های دستی در هر تصویر بود، مقایسه شد. نتایج نمونه برای یکی از تصاویر که در محدوده ۵ قرار داشت، در شکل نشان داده شده‌است. در این شکل نقاط آبی اشاره به تشخیص‌های اشتباه و نقاط قرمز به نقاط از دست‌رفته اشاره دارد و نقاط صورتی پیش‌بینی صحیح شبکه هستند.

انتخاب تصاویر برای ارزیابی مدل


با در نظر گرفتن تنظیمات ویژه مربوط به توزیع بذر توسط خطی‌کارها انتظار می‌رود در حالت بهینه تصاویر مزرعه تقریباً تعداد یکسانی از نقاط رویش را داشته باشند. ارزیابی مدل با انتخاب تصادفی تصاویر از مجموعه داده‌ها، احتمال انتخاب تصاویر با تعداد نسبتاً مشابهی از نقاط رویش را افزایش می‌دهد. این در حالی است که هدف پژوهش این بود که ارزیابی تمام نرخ‌های جمعیت را پوشش دهد و بدین وسیله توانایی مدل را در تشخیص توزیع‌های مختلف نقاط رویش به‌درستی ارزیابی کند. برای رسیدن به این هدف، تصاویر تمام مجموعه داده‌ها به‌عنوان ورودی به شبکه توسعه داده شدند و تعداد نقاط رویش مربوطه برای هر تصویر تخمین زده شد. برای داشتن یک تصویر تصادفی انتخابی با توجه به تعداد نقاط پیش‌بینی شده در هر تصویر و تغییرات جمعیت نقاط رویش در مجموعه تصاویر، داده‌ها به بازه محدوده طبقه‌بندی شدند. به این شکل که، میانگین تعداد نقاط رویش در تمام مزرعه‌ها محاسبه شد و سپس برای مشخص کردن محدوده‌ها، پنج گام از مقدار میانگین محاسبه‌شده به بالا و پایین مقدار جمعیت حرکت صورت گرفت. مقدار میانگین تعداد نقاط رویش حدود ۶۰ عدد به دست آمد که محدوده‌های ۰ تا ۱۰ یا پهنای باند ۱۲ را نتیجه داد. نتایج طبقه‌بندی مجموعه داده‌ها در شکل نشان داده شده‌است. اکثر تصاویر در مزرعه در محدوده ۵ تا ۸ طبقه‌بندی شدند. با دانستن تنظیم از پیش تعریف شده برای توزیع بذر قبل از کاشت (کیلوگرم در هکتار)، عملکرد خطی‌کارها در هر مزرعه می‌تواند مورد قضاوت قرار گیرد. تعداد نقاط

به ترتیب برابر است با ۸۳، ۸۶، ۸۱، ۸۶ و ۸۱ درصد که نشان دهنده عملکرد خوب مدل در این زمینه است. نقاط رویش گمشده در تصاویر ارزیابی شده که پیش از این به عنوان (FN) در رابط شاخص فراخوان تعریف شده است که در شکل ۱۱ نشان داده شده است. شکل ۱۱ نشان می‌دهد که با افزایش تعداد نقاط رویش پیش‌بینی شده در هر تصویر، تعداد نقاط رویش از دست‌رفته به‌طور متقابل افزایش می‌یابد. افزایش تراکم گیاه باعث ایجاد پوشش بیشتر بین گیاهان همسایه شده و کار مدل را در شناسایی نقاط رویش احتمالی مشکل می‌سازد. تعداد پیش‌بینی‌های خطا در محدوده‌های مختلف در شکل ۹ به تصویر کشیده شده است. افزایش جمعیت نقاط رویش پیش‌بینی شده در هر تصویر منجر به رخ دادن خطاهای بیشتر در تشخیص نقطه رویش صحیح می‌شود. با افزایش تعداد گیاهان در هر تصویر، احتمال مناطقی در تصویر که ویژگی مشابه با نقاط رویش واقعی دارند، افزایش خواهد یافت. علاوه بر این، جمعیت بیشتر گیاهان در یک تصویر، احتمال اشتباه در جداسازی نقطه رویش گیاه و پس‌زمینه را افزایش می‌دهد.

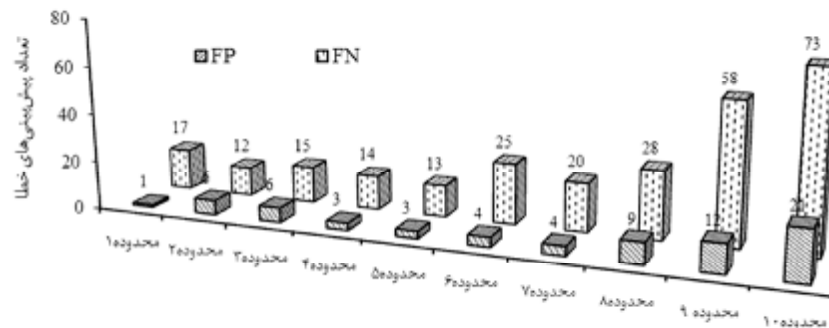


شکل ۸- نتایج نمونه برای یکی از تصاویر مزرعه که در محدوده ۵

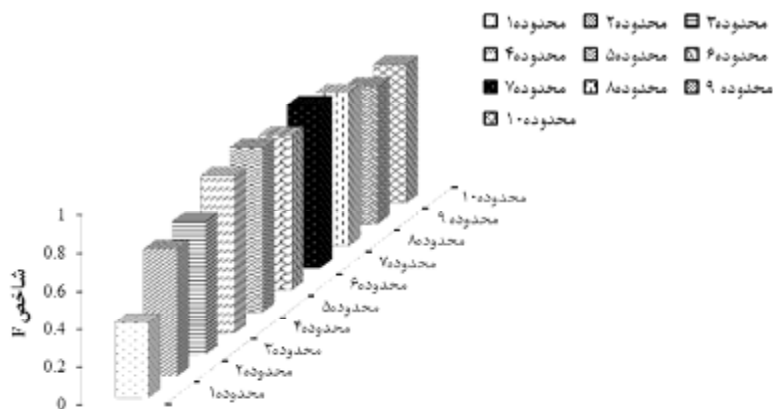
شکل ۹ تغییرات شاخص‌های دقت و فراخوانی به دست آمده را نشان می‌دهد. همچنین نتیجه برآورد میانگین هارمونی دقت و فراخوانی (F) در شکل ۱۰ نشان داده شده است. از مجموعه ۲۷۲۰ تصویر از مزرعه، ۲۵۴۵ تصویر مربوط به محدوده‌های ۴، ۵، ۶، ۷ و ۸ بود. این رقم برابر است با حدود ۹۴ درصد از مجموع تصاویری که از مزرعه به دست آمده است. عملکرد شبکه در این محدوده



شکل ۹- بررسی تغییرات شاخص دقت و فراخوانی در محدوده‌های تعیین شده



شکل ۱۰- نتیجه برآورد میانگین هارمونی دقت و فراخوانی (F) برای مجموعه داده مزرعه



شکل ۱۱- نقاط رویش گمشده (FN) و نقاط رویش پیش‌بینی شده به صورت اشتباه در ۳۰ تصویر ارزیابی شده

نتیجه‌گیری


الگوریتم‌های توسعه‌یافته مبتنی بر سامانه‌های ماشین بینایی تنها در شرایطی از پیش تعریف شده مانند اندازه گیاه، رنگ، شکل، ترکیب پس‌زمینه، نور، و غیره به درستی کار می‌کنند. بنابراین، ایجاد یک سیستم تعمیم‌پذیر موقعیت‌یاب نقاط رویش گیاهان مبتنی بر پردازش تصویر معمول، مشکل خواهد بود. این موضوع در مورد غلات با توجه به نوع کشت غلات که در یک الگوی تصادفی و فاصله ردیف باریک کاشته می‌شود بسیار حادتر خواهد بود. در این مطالعه یک سیستم مکان‌یابی نقاط رویش غلات تعمیم‌پذیر با استفاده از تکنیک‌های یادگیری عمیق و شبکه‌های عصبی کانولوشن توسعه داده شده است. رویکرد فعلی در مقایسه با سامانه‌های بینایی ماشین دارای مزیت‌های مهم چون قابلیت اصلاح خطا و قابلیت یادگیری تحت نظارت است. تصحیح خطا در سیستم پیشنهادی با ایجاد یک تابع جریمه در نواحی از تصویر که به صورت بالقوه می‌توانند به جای نقاط رویش به‌عنوان پس‌زمینه شناخته شود، اعمال شد. یادگیری با نظارت به‌علت ماهیت یادگیری عمیق با وجود شرایط مختلف گیاهان و محیط، ایجاد سیستم موقعیت‌یابی را امکان‌پذیر کرده است. این ویژگی باعث می‌شود رسیدن به هدف توسعه سیستم تعمیم‌پذیر برای تشخیص نقاط رویش بیشتر قابل تصور باشد. نتایج نشان می‌دهد که با اضافه کردن تابع جریمه در روند آموزش، عملکرد شبکه به‌طور قابل‌توجهی افزایش یافته است. به‌طوری‌که در همه مزارع در محدوده‌های مختلف، میانگین هماهنگ دقیق و فراخوانی، کارایی قابل‌قبول شبکه توسعه یافته را در تشخیص نقاط رویش نشان می‌دهد.

مدل توسعه‌یافته مکان‌یابی نقاط رویش برای ارزیابی عملکرد خطی کارها می‌تواند کاملاً کاربردی باشد. با توجه به عواملی که پس از عبور بذرها از لوله سقوط، جایگذاری بذر را در بستر خاک تحت تأثیر قرار می‌دهند، ارزیابی کیفیت کاشت پس از رویش محصولات، منصفانه‌ترین بازخورد را از ارزیابی عملکرد خطی کار ارائه خواهد داد. به‌علاوه اینکه پس از انجام کالیبراسیون پیکسلی مربوطه، فاصله بذرها را می‌توان تعیین کرد. بر اساس فاصله بذر تئوری و فاصله تخمین‌زده‌شده، شاخص‌های ارزیابی کاشت شامل شاخص کیفیت تغذیه، شاخص کپه‌کاری، شاخص نکاشت و شاخص دقت قابل محاسبه خواهد بود (Kocher *et al.*, 1998; Yazgi & Degirmencioglu, 2014). با کشف مکان دقیق هر محصول در سراسر یک مزرعه، علاوه بر ارزیابی عملکرد کاشت، شناسایی علف‌های هرز بسیار ساده‌تر می‌شود. به‌طوری‌که در توسعه یک سیستم تشخیص علف هرز، منطقه از پیش تعیین شده از محصول اصلی که توسط سیستم مکان‌یابی مشخص شده می‌تواند تفریق گردد. در این صورت، پردازش داده‌های مزرعه برای ایجاد نقشه علف‌های هرز بدون تأثیر از تداخل محصول، قابل دستیابی خواهد بود. علاوه بر این، سیستم مکان‌یابی نقاط رویش برای تیمار مبتنی بر موقعیت محصول مانند کودپاشی، وجین و کنترل آفات مربوط به محصول با آفت‌کش‌هایی مانند قارچ‌کش، نماتدکش، باکتری‌کش، و غیره می‌تواند کارآمد باشد. همان‌طور که اشاره شد، در برخی موارد، شناسایی نقطه دقیق رویش ساقه گیاه حتی برای چشم آموزش دیده سخت بود. به این معنی که در برخی موارد عدم اطمینانی مربوط به علامت‌گذاری‌های دستی وجود داشت. این به‌علت مشکلات متعددی بود که


شبکه‌های عصبی کانولوشن برای جداسازی معنایی می‌تواند کمکی ارزشمند برای این منظور باشد. عملکرد چنین الگوریتمی با استفاده از شرایط مختلف خاک و گیاه برای آموزش می‌تواند بهبود داده شود.

در طول آزمایش، تمام داده‌های تصویری با انتساب موقعیت GPS مربوطه اخذ شدند. نقشه مکانی جمعیت نقاط پیش‌بینی شده در ۱۲ نشان داده شده‌است. برای هر تصویر گرفته شده بر اساس تعداد و وابستگی محدوده، یک رنگ در نقشه تعیین شده‌است. با توجه به ضریب تبیین قدرتمند ۸۷ درصدی برای تصاویر ارزیابی‌شده، عملکرد کاشت در نقاط مختلف مزرعه با قابلیت اطمینان بالا مورد بررسی قرار می‌گیرد. نقشه در شکل ۱۲ می‌تواند سرخ قابل اطمینانی را در مورد عملکرد خطی کارها و عوامل تأثیرگذار محیطی بالقوه بر نرخ رویش محصولات ارائه دهد. شکل ۱۳ یک نمونه از تحلیلی را که در این زمینه می‌توان داشت، نشان داده‌است؛ نقاطی که کارنده خطی کار دارای همپوشانی در کشت است و نقاطی که در آن عدم کاشت اتفاق افتاده است، کاملاً متمایز و قابل تفسیر هستند. در این مطالعه یک رویکرد جدید و موفق برای توسعه یک سیستم مکان‌یابی نقاط رویش ساقه گیاهان غلات طراحی شده است. نتایج نشان داد که مدل می‌تواند بازخورد قابل قبولی را در مورد عملکرد کاشت به تولیدکنندگان و کشاورزان ارائه کرده و مدیریت و کارایی مزرعه را در گام‌های بعدی بهبود بخشد. همچنین نقشه نقاط رویش محصول در کنار نقشه علف‌های هرز سرخ‌های معنی‌داری در مورد تأثیر عملکرد کاشت بر توزیع علف‌های هرز در یک مزرعه می‌تواند داشته باشد.

در تمایز نوک برگ از نقطه رویش ساقه گیاه، پوشش گیاهان همسایه و درهم‌وبرهمی ناشی از حرکت خاک بر روی محصول زراعی در طول علامت‌گذاری یافت شد. علاوه بر همه این‌ها، مدل توسعه یافته قابلیت شمارش جمعیت گیاهان و نقاط رویش را داشت. برای کاربردهایی مانند ارزیابی کاشت از طریق تراکم گیاه، ظهور ناهمگن در مزرعه و ازدست‌دادن گیاه به دلیل عوامل زیستی، به سادگی تخمین تعداد نقاط رویش مناسب خواهد بود. بررسی رابطه تعداد نقاط رویش پیش‌بینی شده در مقابل نقاط رویش حقیقی از پیش علامت‌گذاری شده ضریب تعیین حدود ۸۷ درصدی را نشان داد. این ضریب تعیین قوی نشان دهنده توانایی مناسب سیستم در شمارش تعداد نقاط رویش هر تصویر است. در بعضی از تصاویر، به‌خصوص با جمعیت گیاهی متراکم‌تر، پیش‌بینی‌های غلط مربوط به نقاط از دست رفته و نقاط نزدیک به یکدیگر بودند. این باعث شد که این مدل عملکرد بهتری را در شمارش کل جمعیت نقاط رویش در هر تصویر نشان دهد. تعداد نقاط رویش در هر تصویر به تعداد بذره‌های کاشته شده در واحد سطح می‌تواند اشاره داشته باشد. این امر توسط کالیبراسیون پیکسل در هنگام جمع‌آوری داده‌ها در مطالعات می‌تواند امکان‌پذیرتر باشد. همراه با پژوهش حاضر، برای شناسایی تراکم گیاه غلات، چندین مطالعه مبتنی بر پردازش تصویر قبلاً انجام شده‌است (Jin et al., 2017; Liu et al., 2017b). توسعه این الگوریتم‌ها با توجه به ماهیت پردازش تصویر با محدودیت‌های خاص خود مواجه بود. در چنین سامانه‌های مبتنی بر بینایی ماشین، یکی از موانع چالش‌برانگیز، جداسازی کارآمد محصول زراعی مورد نظر از خاک پس‌زمینه است. استفاده از



شکل ۱۲- نقشه مکانی جمعیت نقاط پیش‌بینی شده



شکل ۱۳- نمونه از تحلیلی که می‌توان بر عملکرد کارنده در سطح مزرعه داشت

- plant density at early stages using high resolution imagery. *Frontiers in Plant Science*, 8: 739.
8. Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 3431-3440.
 9. Lu, C., Fu, W., Zhao, C., Mei, H., Meng, Z., Dong, J., Gao, N., Wang, X., & Li, L. (2017). Design and experiment on real-time monitoring system of wheat seeding. *Transactions of the Chinese Society of Agricultural Engineering*, 33(2): 32-40.
 10. Martin, D. R., Fowlkes, C. C., & Malik, J. (2004). Learning to detect natural image boundaries using local brightness, color, and texture cues. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 5: 530-549.
 11. Murray, J., Tullberg, J. N., & Basnet, B. (2006). *Planters and their components: types, attributes, functional requirements, classification and description*. Australian Centre for International Agricultural Research. 178 p.
 12. Nakarmi, A., & Tang, L. (2012). Automatic inter-plant spacing sensing at early growth stages using a 3D vision sensor. *Computers and electronics in agriculture*, 82: 23-31.
 13. Nakarmi, A. D., & Tang, L. (2010). Inter-plant spacing sensing at early growth stages using a time-of-flight of light based 3D vision sensor. *American Society of*

منابع

1. Dyrmann, M., Mortensen, A. K., Midtby, H. S., & Jørgensen, R. N. (2016). Pixel-wise classification of weeds and crops in images by using a fully convolutional neural network. *Proceedings of the International Conference on Agricultural Engineering*. Aarhus, Denmark. 26-29.
2. Jin, J., & Tang, L. (2009). Corn plant sensing using real-time stereo vision. *Journal of Field Robotics*, 26(6-7): 591-608.
3. Jin, X., Liu, S., Baret, F., Hemerlé, M., & Comar, A. (2017). Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment*, 198: 105-114.
4. Kocher, M. F., Lan, Y., Chen, C., & Smith, J. A. (1998). Opto-electronic sensor system for rapid evaluation of planter seed spacing uniformity. *Transactions of the ASAE*, 41(1): 237.
5. Laursen, M. S., Jørgensen, R. N., Dyrmann, M., & Poulsen, R. (2017). *Robo WeedSupport-Sub millimeter weed image acquisition in cereal crops with speeds up till 50 km/h*. this volume.
6. Liu, S., Baret, F., Allard, D., Jin, X., Andrieu, B., Burger, P., Hemmerlé, M., & Comar, A. (2017a). A method to estimate plant density and plant spacing heterogeneity: application to wheat crops. *Plant methods*, 13(1): 38.
7. Liu, S., Baret, F., Andrieu, B., Burger, P., & Hemmerlé, M. (2017b). Estimation of wheat

- Agricultural and Biological Engineers*. 2010 Pittsburgh, Pennsylvania, June 20-June 23.
14. Nakarmi, A. D., & Tang, L. (2014). Within-row spacing sensing of maize plants using 3D computer vision. *Biosystems engineering*, 125: 54-64.
 15. Shrestha, D. S., & Steward, B. L. (2003). Automatic corn plant population measurement using machine vision. *Transactions of the ASAE*, 46(2): 559.
 16. Simonyan, K., & Zisserman, A. (2014). *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv: 1409.1556.
 17. Tang, L., & Tian, L. F. (2008). Real-time crop row image reconstruction for automatic emerged corn plant spacing measurement. *Transactions of the ASABE*, 51(3): 1079-1087.
 18. Virk, S. S., Porter, W. M., Fulton, J. P., & Pate, G. L. (2019). *Field Validation of Seed Meter Performance at Varying Seeding Rates and Ground Speeds*. Applied Engineering in Agriculture.
 19. Visa, G. P., & Salembier, P. (2014). Precision-recall-classification evaluation framework: Application to depth estimation on single images. *European Conference on Computer Vision*. Springer. 648-662.
 20. Yazgi, A., & Degirmencioglu, A. (2014). Measurement of seed spacing uniformity performance of a precision metering unit as function of the number of holes on vacuum plate. *Measurement*, 56: 128-135.

