

# تشخیص و شمارش هوشمند گل‌های ذرت در تصاویر پهپادی با استفاده از TSDPC

میترا پیرو حسینی نژاد<sup>۱</sup>، اعظم کرمی<sup>۲\*</sup>

<sup>۱</sup> کارشناس ارشد فوتونیک - دانشکده فیزیک - دانشگاه شهید باهنر کرمان  
mitra.hoseiny195@gmail.com

<sup>۲</sup> دانشیار دانشکده فیزیک - دانشگاه شهید باهنر کرمان  
akarami@uk.ac.ir

(تاریخ دریافت شهریور ۱۴۰۰، تاریخ تصویب بهمن ۱۴۰۰)

## چکیده

در سال‌های اخیر شمارش گل‌های ذرت اطلاعات ارزشمندی در مورد پیش‌بینی میزان محصول فراهم نموده، اما شمارش به روش سنتی و دستی امری گران و زمان‌بر است. در این مقاله برای تشخیص شمارش هوشمند گل‌های ذرت یک مزرعه از آشکارساز مبتنی بر جداسازی مکانی آگاه از وظیفه TSD بهره گرفته شده و ساختار شبکه TSD با استفاده از شبکه‌های پیچشی تغییر شکل‌پذیر و Cascade R-CNN\_x101 اصلاح گردیده و سپس با بهینه‌سازی و تنظیم پارامترهای مربوطه آشکارساز TSDPC معرفی گردیده است. جهت ساخت پایگاه داده تصاویر رنگی با هم‌پوشانی بالا، از مزرعه گل‌های ذرت توسط پهپاد اخذ شده است. سپس با اعمال پیش پردازش‌های لازم ارتوفوتو مزرعه تشکیل گردیده، در مرحله بعد آشکارساز پیشنهادی TSDPC جهت تعیین مکان گل‌های ذرت بر روی ارتوفوتو اعمال شده است. در پایان نتایج به دست آمده از کار نوین انجام شده با نتایج حاصل از کار تیم متخصص کشاورزی و آشکارسازهای معتبر در این زمینه مانند CenterNet و RepPoints مقایسه گردید. TSDPC در مقایسه با روشهای ذکر شده قادر به تشخیص بهتر ذرت‌های با گل کوچکتر به دلیل بهره‌گیری از شبکه‌های پیچشی تغییر شکل‌پذیر است، در نتیجه دقت بالاتری در تشخیص دارد. به عنوان مثال دقت تشخیص صحیح گل‌های ذرت روش پیشنهادی در مزرعه اول به طور میانگین ۲/۵ درصد بیشتر از CenterNet و ۶ درصد بیشتر از RepPoints است.

**واژگان کلیدی:** یادگیری عمیق، پهپاد، تشخیص و شمارش گل ذرت، اشیاء کوچک

\* نویسنده رابط

## ۱- مقدمه

در صنعت کشاورزی، ذرت یکی از محبوب‌ترین دانه‌های غلات در جهان است. منشأ آن قاره آمریکا بوده و پس از گندم، بیشترین اراضی کشاورزی جهان به ذرت اختصاص دارد. این گیاه به عنوان منبع غذایی مهمی در بسیاری از بخش‌های مختلف جهان به شمار می‌رود. شمارش تعداد گل‌های ذرت در واحد سطح برای پرورش دهندگان آن ضروری است. با این وجود، اندازه‌گیری و شمارش گل‌های ذرت بسیار سخت و از راندمان پایین و خطاهای انسانی بسیاری برخوردار است. در سال‌های اخیر استفاده از پهپادها<sup>۱</sup> در کشاورزی دقیق مانند تشخیص آفات، شمارش تعداد گیاهان، برآورد میزان محصول و غیره مورد توجه ویژه قرار گرفته است [۲، ۱]. تصاویر پهپادی که از یک مزرعه کشاورزی اخذ می‌گردند پس از پیش پردازش اولیه، تصاویر با هم ادغام گردیده و اصطلاحاً ارتوفوتو<sup>۲</sup> کل مزرعه تشکیل می‌شود. اما به دلیل ارتفاع بالای پرواز (۲۰-۵۰ متر) چنانچه گیاهان به اندازه کافی رشد نموده باشند، تشخیص گیاهان کوچک جهت شمارش تعداد گیاهان و تخمین میزان محصول امری دشوار است [۳، ۴].

در ماشین بینایی تشخیص اشیاء کوچک در تصاویر به دلیل اطلاعات کم و پیچیده بودن پس‌زمینه جهت استخراج ویژگی‌های اشیاء کوچک امری دشوار و چالش برانگیز به شمار می‌آید [۵]. الگوریتم‌های بکار گرفته شده در زمینه تشخیص شی در دو گروه روش‌های کلاسیک و یادگیری عمیق<sup>۳</sup> تقسیم بندی می‌گردند. از جمله روش‌های کلاسیک می‌توان به تشکیل تصویر دودویی، روش‌های مورفولوژی، لبه یابی و روش‌های یادگیری ماشین اشاره کرد. در این روش‌ها استخراج ویژگی‌های با ارزش تصویر که به منظور کاهش بار محاسباتی الگوریتم باید انجام گیرد به صورت دستی و مجزا از الگوریتم طراحی شده جهت تشخیص باید انجام گیرد اما در یادگیری عمیق این ویژگی‌ها در ساختاری سراسری<sup>۴</sup> توسط لایه‌های شبکه عمیق به صورت خودکار استخراج می‌شوند [۶]. از این رو، استفاده از الگوریتم‌های یادگیری عمیق در تشخیص و یا

شمارش اشیاء به نتایج بهتری منتهی می‌گردد. در روش‌های مبتنی بر یادگیری عمیق جهت تشخیص اشیاء آشکارسازها به دو دسته مبتنی بر کادر<sup>۵</sup> و عاری از کادر<sup>۶</sup> تقسیم می‌شوند [۸، ۷]. آشکارسازهای مبتنی بر کادر خود به دو گروه تک مرحله‌ای و دو مرحله‌ای تفکیک می‌شوند. آشکارسازهای دو مرحله‌ای دارای دقت بالاتری هستند و در مرحله اول شبکه پیشنهادی منطقه<sup>۷</sup>، کادرهای محدود کننده را پیشنهاد و در مرحله دوم ویژگی‌ها از هر جعبه محدود کننده<sup>۸</sup> پیشنهادی به منظور کلاس‌بندی و رگرسیون استخراج می‌گردد. در این مقاله جهت تشخیص هوشمند گل‌های ذرت مسأله تشخیص اشیاء کوچک مطرح گردیده، تشخیص آنها به دلیل عدم وجود ویژگی-های کافی جهت استخراج یک امر چالش برانگیز است. در این راستا الگوریتم‌های متعددی تعریف شده است. در ادامه چندین نمونه از این آشکارسازها جهت تشخیص اشیاء کوچک معرفی می‌گردد: آشکارسازهای SNIP<sup>۹</sup> و SNIPER<sup>۱۰</sup> از یک قاعده تنظیم مقیاس برای تضمین اندازه جسم در یک محدوده ثابت برای تصاویر با وضوح مختلف استفاده می‌کنند [۹، ۱۰]. آشکارساز EFPN<sup>۱۱</sup> یک لایه ویژگی با جزئیات هندسی بیشتر برای تشخیص اشیاء کوچک می‌سازد [۱۱]. آشکارساز TridentNet چندین شاخه موازی از ویژگی‌های اشیاء کوچک را جهت بهبود عملکرد ایجاد می‌کند [۱۲]. آشکارساز تشخیص با وضوح بالا HRDNet<sup>۱۲</sup> با استخراج ویژگی‌های مختلف از وضوح بالا به پایین باعث بهبود عملکرد آشکارساز در جداسازی و تشخیص اشیاء کوچک شد [۱۳].

آشکارساز مبتنی بر کادر دو مرحله‌ای<sup>۱۳</sup> TSD در سال ۲۰۲۰ توسط G.Song و همکارانش ارائه شد. این آشکارساز بر روی پایگاه داده COCO نسبت به آشکارسازهای دیگر به دقت بسیار بالا دست یافته است. پایگاه داده استاندارد مذکور شامل ۱۶۴۰۰ تصویر توسط شرکت مایکروسافت در سال ۲۰۱۴ جهت ارزیابی عملکرد آشکارسازها در تشخیص شی

<sup>۵</sup> Anchor- Based

<sup>۶</sup> Anchor-Free

<sup>۷</sup> Region Proposal Network (RPN)

<sup>۸</sup> Bounding Box (BB)

<sup>۹</sup> Scale Normalization for Image Pyramids

<sup>۱۰</sup> Scale Normalization for Image Pyramids with Efficient Resampling

<sup>۱۱</sup> Extended Feature Pyramid Network

<sup>۱۲</sup> High-Resolution Detection Network

<sup>۱۳</sup> The Sibling Head in Object Detector

<sup>۱</sup> Unmanned Aerial Vehicles (UAV)

<sup>۲</sup> Orthophotos

<sup>۳</sup> Deep Learning

<sup>۴</sup> End-to-End

$$L = L_{cls}(H_1(F_1, P), y) + L_{loc}(H_2(F_1, P), B) \quad (1)$$

$$H_1(0) = \{(f(0), C(0)), H_2(0) = \{f(0), R(0)\}$$

$H$  استخراج کننده ویژگی،  $F_1$  نقشه ویژگی محلی سازی  $f(0)$  و  $C(0)$  و  $R(0)$  توابع تبدیل ویژگی‌ها جهت تعیین موقعیت و کلاس شی هستند.  $L$  تابع اتلاف کلی،  $L_{cls}$  تابع اتلاف کلاس بندی و  $L_{loc}$  تابع اتلاف محلی سازی است. فرض می‌شود که  $f$  به صورت مشترک برای رگرسیون و کلاس بندی بهینه نیست و به صورت جداگانه برای رگرسیون و کلاس بندی به ترتیب به  $f_c$  و  $f_r$  تعمیم داده می‌شود. برای جدا کردن توابع رگرسیون و طبقه بندی رابطه بالا به صورت زیر بازنویسی می‌شود [۱۶].

$$L = L_{cls}^p(H_1^p(F_1, \bar{P}_c), y) + L_{loc}^p(H_2^p(F_1, \bar{P}_r), B) \quad (2)$$

$$H_1^p(0) = \{f_c(0), R(0)\}, H_2^p(0) = \{f_r(0), R(0)\}$$

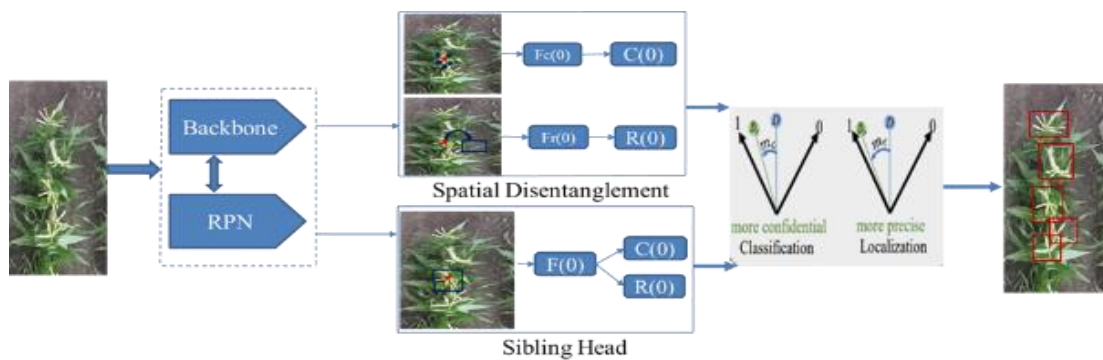
به طور کلی TSD ویژگی ناحیه مورد نظر<sup>۴</sup> را به عنوان  $P$  استخراج می‌کند و سپس پیشنهادات جدا شده  $\bar{P}_c$  و  $\bar{P}_r$  را به ترتیب برای کلاس بندی و رگرسیون ایجاد می‌کند. همچنین نقشه‌های ویژگی طبقه بندی  $\bar{F}_c$  و محلی سازی  $\bar{F}_r$  را جداگانه ایجاد می‌نماید.  $\bar{F}_c$  برای طبقه بندی به یک شبکه سه لایه تمام متصل وصل می‌شود. در واقع TSD می‌تواند نمایشی از ویژگی‌های مناسب را به صورت تطبیقی یاد بگیرد [۱۵]. معماری این آشکارساز در شکل (۱) نشان داده است.

در دسترس عموم قرار گرفته است [۱۴]. در آشکارساز TSD هدف جداسازی تابع اتلاف کلاس بندی و محلی سازی جهت افزایش دقت تشخیص شی می‌باشد [۱۵]. در این مقاله از آشکارساز TSD جهت تشخیص هوشمند گل‌های ذرت<sup>۱</sup> یک مزرعه الهام گرفته شده، از ترکیب Cascade R-CNN و شبکه‌های پیچشی تغییر شکل پذیر<sup>۲</sup> با شبکه مورد نظر و بهبود این آشکارساز و تنظیم پارامترها در نهایت یک ساختار مناسب با دقت و سرعت بالا در این مقاله معرفی گردید و روش پیشنهادی TSDPC<sup>۳</sup> جهت برآورد میزان محصول یک مزرعه معرفی گردیده است.

ادامه مقاله به این صورت سازماندهی شده است که بخش ۲ آشکارساز TSD معرفی سپس در بخش ۳ روش پیشنهادی و بخش ۴ نتایج عملی حاصل از کار تحقیقاتی انجام گرفته و در نهایت بخش ۵ نتیجه گیری و پیشنهاد جهت کارهای آینده را در برمی‌گیرد.

## ۲- معرفی آشکارساز TSD

آشکارساز TSD یک شبکه مبتنی بر کادر می‌باشد که جهت تشخیص اشیاء کوچک بهبود یافته است. در این روش تابع اتلاف جداگانه برای طبقه بندی و محلی سازی در نظر گرفته می‌شود، که سبب می‌شود تأثیر این بخش‌ها بر روی یکدیگر به حداقل برسد که در رابطه زیر نشان داده شده است [۱۵]:



شکل ۱- معماری TSD [۱۵]

<sup>۱</sup> Panicle

<sup>۲</sup> Deformable Convolutional Networks (DCN)

<sup>۳</sup> TSD Panicle Counting

<sup>۴</sup> Region of Interest (ROI)

### ۳- روش پیشنهادی TSDPC

جهت تشخیص هوشمند گل‌های ذرت تغییرات اساسی ذیل در آشکارساز TSD اضافه شده است:

- (۱) استفاده از شبکه پشتیبان ResNeXt با ۱۰۱ لایه
- (۲) اضافه کردن شبکه‌های پیچشی تغییر شکل پذیر جایگزین کردن آن با شبکه کانولوشن عصبی<sup>۱</sup> معمولی
- (۳) در نظر گرفتن Cascade R-CNN
- (۴) بهینه کردن هایپر پارامترهای آشکارساز TSD

با در نظر گرفتن ۴ تغییر فوق دقت آشکارساز TSDPC در تشخیص صحیح گل‌های ذرت (بویژه گل‌های کوچک) افزایش چشمگیر داشته، که در ادامه توضیح داده شده است.

معماری ResNeXt در سال ۲۰۱۷ توسط فیسبوک معرفی گردید. در این معماری از ترکیب VGG و ResNet جهت افزایش دقت تشخیص شی استفاده شده، این ترکیب سبب گردیده که معماری ResNeXt با ۱۰۱ لایه نسبت به معماری ResNet با ۱۵۲ لایه به دقت بالاتری دست یابد [۱۷]. در معماری اولیه ResNext شبکه کانولوشن عصبی معمولی استفاده شده است. اما بدلیل اینکه اندازه ذرت‌های رشد نموده، با هم متفاوت و جهت رشد در تصاویر فرق می‌کند جهت آموزش شبکه باید در هنگام شناسه گذاری تغییرات اندازه، جهت و شکل ذرت‌ها لحاظ گردد ولی اینکار وقتگیر و هزینه‌بر می‌باشد. در سال‌های اخیر شبکه‌های پیچشی تغییر شکل پذیر توسط میکروسافت معرفی شد. که با افزودن دو بخش جدید به شبکه‌های پیچشی عمیق امکان مدل سازی تغییرات هندسی اشیاء فراهم گردید. اولین بخش کانولوشن تغییر شکل پذیر است که پیشنهادات دو بعدی را به مکان‌های نمونه‌برداری منظم از شبکه، در کانولوشن معمولی اضافه می‌کند، این امر سبب تغییر شکل آزاد شبکه می‌گردد. بخش دوم یک لایه ادغام قابل تغییر می‌باشد که می‌تواند یک سری پیشنهادات جدید را به لایه ادغام قبلی اضافه و امکان تطبیق برای اشیاء با اشکال مختلف را فراهم می‌نماید. دو بخش اضافه شده تنها مقدار کمی پارامتر و محاسبات را به شبکه تزریق می‌کنند [۱۸]. در ساختار اصلی TSD، از Faster R-CNN جهت تشخیص شی استفاده شده اما در الگوریتم پیشنهادی TSDPC از

Cascade R-CNN که متشکل از دنباله‌ای از آشکارساز-های آموزش دیده R-CNN است، استفاده شده که امکان تشخیص اشیاء با دقت بالا را فراهم می‌کند. آشکارسازها مرحله به مرحله آموزش می‌بینند و از این دید استفاده می‌کنند که خروجی یک آشکارساز توزیع مناسبی برای آموزش آشکارسازهای با کیفیت بالاتر است [۱۹].

الگوریتم زیر ساختار کلی روش پیشنهادی جهت تشخیص و شمارش هوشمند گل‌های ذرت جهت برآورد میزان محصول را نشان می‌دهد.

ورودی:

تصاویر پهپادی اخذ شده مزرعه، تشکیل ارتوفوتو با استفاده از هم‌پوشانی تصاویر پهپادی، شبکه پشتیبان، عمق شبکه، اندازه دسته، نرخ یادگیری، روش بهینه‌ساز، تعداد مرحله

الگوریتم:

۱- تولید نواحی مورد نظر پیشنهادی

۲- اعمال تابع اتلاف TSD

۳- استفاده از شبکه پشتیبان ResNeXt با ۱۰۱ لایه

۴- اصلاح شبکه پشتیبان با ادغام Cascade R-DCN و CNN\_x101

خروجی:

مدل نهایی شبکه، شمارش و تشخیص موقعیت گل-های ذرت در ارتوفوتو

### ۳-۱- اخذ تصاویر پهپادی مورد نیاز و شناسه گذاری

کاشت ذرت در مرکز تحقیقات و آموزش زراعت (ACRE) دانشگاه پردو انجام شده است. موقعیت پرواز عبارت است از: شهر وست لافایت، ایندیانا، آمریکا ("40°16'49.6" شمال، "86°35'24.8" غرب). ذرت‌ها در ماه می سالهای ۲۰۲۰ و ۲۰۲۱ کاشته شدند. سه هفته بعد از کاشت گیاهان رشد کردند و دو ماه بعد (جولای) رشد پنیکل‌ها بسته به نوع گونه ذرت شروع شد. جهت ساخت پایگاه داده از گل‌های ذرت یک مزرعه، در ابتدا تصاویر رنگی با هم‌پوشانی از مزرعه گل‌های ذرت توسط پهپاد و با نظارت گروهی از متخصصین کشاورزی اخذ شده و کادراهی محدود کننده گل‌های ذرت جهت آموزش به آشکارساز پیشنهادی توسط کشاورزان متخصص تعیین

<sup>۱</sup> Convolutional Neural Networks

برآورد هوشمند میزان محصول گل‌های ذرت مزرعه دقت قابل قبولی حاصل شده است. پارامترهای بهینه آشکارساز پیشنهادی در جدول (۲) آورده شده است.

جدول ۲- پارامترهای بهینه TSDPC

مدل	شبکه پشتیبان	عمق
Cascade-RCNN	ResNeXt+DCN	۱۰۱
تعداد طبقات	تعداد کارت گرافیک	سایز تصویر ورودی
۳	2x Nvidia Geforce GTX 1080 Ti (11 Gb)	(۸۰۰ و ۱۳۳۳)
تعداد مراحل	بهینه ساز	دفعات ارزیابی
۵۰۰	SGD	۵۰
نرخ یادگیری	تبدیلات	سایز تست
۰/۰۴	تغییر مقیاس، نرمالیزه کردن	(۸۰۰ و ۱۳۳۳)

با توجه به تعداد کارت گرافیک که جهت آموزش شبکه استفاده می‌گردد، اندازه دسته تعیین شده است. برای آموزش تصاویر پهنای اندازه دسته تصاویر جهت آموزش، ۲ در نظر گرفته شده است. برای تعیین تعداد مراحل آموزش چندین بار آموزش با تعداد مراحل گوناگون صورت گرفته تا تعداد مراحل بهینه تعیین گردد و مشکل بیش برآزش و یا کم برآزش ایجاد نگردد، و در نهایت تعداد مرحله بهینه تعیین گردیده است. تصاویر مربوط به آموزش آشکارساز پیشنهادی با استفاده از برش‌های تصادفی در ارتوفوتو تهیه شده است.

#### ۴-۱- ارزیابی شبکه‌های پیشنهادی

سه معیار اصلی TP<sup>۱</sup> (تعداد تشخیص اشیاء درست در تصاویر)، FP<sup>۲</sup> (تعداد تشخیص اشیاء نادرست در تصاویر) و FN<sup>۳</sup> (تعداد اشیاء تشخیص داده نشده در تصاویر) در این مقاله در نظر گرفته شده است. برای تعیین دقت شبکه‌های پیشنهادی روابط مربوط به درستی، نرخ یادآوری و نمره ارزیابی با استفاده از روابط زیر تعیین می‌شود:

$$Pr = \frac{TP}{TP + FP} \quad (۳)$$

$$Re = \frac{TP}{TP + FN} \quad (۴)$$

$$Sc = 2 \cdot \frac{Pr \cdot Re}{Pr + Re} \quad (۵)$$

<sup>۱</sup> True Positive

<sup>۲</sup> False Positive

<sup>۳</sup> False Negative

گردیده و از طریق دانشگاه پردو ایندیانا آمریکا در اختیار آزمایشگاه تخصصی رباتیک و پردازش تصویر دانشگاه شهید باهنر کرمان (کریپل) قرار گرفته است. تصاویر خام پهنای توسط تیم کریپل پردازش شده، سپس ارتوفوتو مربوط به مزرعه تشکیل گردیده و در ادامه با استفاده از برشهای تصادفی از ارتوفوتو تشکیل شده تصاویر مورد نیاز آموزش، ارزیابی و تست روش پیشنهادی ایجاد گردیدند.

#### ۴- نتایج حاصل در تشخیص و شمارش هوشمند جهت برآورد میزان محصول گل‌های ذرت

در این مقاله جهت برآورد هوشمند میزان محصول مزرعه گل‌های ذرت از آشکارساز پیشنهادی TSDPC برای دو مزرعه استفاده و دقت آن محاسبه گردیده است. در نهایت آشکارساز پیشنهادی با دو آشکارساز معتبر RepPoints [۲۰] و CenterNet [۲۱] مقایسه و نتایج و بررسی‌های انجام شده در این قسمت آورده شده است. آشکارساز RepPoints در سال ۲۰۱۹ توسط میکروسافت ارائه شد. این آشکاز یک آشکارساز عاری از کادر مبتنی بر نقاط کلیدی و به طور خودکار خود را به روشی تنظیم می‌کند که قادر به محدود کردن محدوده مکانی شی موردنظر باشد [۲۰]. آشکارساز CenterNet در سال ۲۰۱۹ توسط X.Zhou و همکارانش ارائه شد. CenterNet یک آشکارساز عاری از کادر مبتنی بر نقاط مرکزی می‌باشد، که از تخمین نقاط کلیدی جهت یافتن نقطه مرکزی و تشخیص شی استفاده می‌کند [۲۱]. آموزش شبکه بر روی سیستم با مشخصات ذکر شده در جدول (۱) انجام شده است.

جدول ۱- مشخصات سیستم کامپیوتری

CPU	Core i7-6850K 3.60GHz
RAM	128 Gb RAM
Graphics	2x Nvidia Geforce GTX 1080 Ti (11 Gb)

قبل از آموزش بر روی تصاویر مزرعه، پیش پردازش موردنیاز جهت افزایش وضوح تصویر و حذف اشیاء اضافی صورت گرفته است. در این مقاله علاوه بر نوآوری صورت گرفته چندین آزمون و خطا جهت بهینه سازی و تنظیم پارامترهای بهینه صورت گرفته است تا دقت به بیشترین حد ممکن افزایش یابد و دقت قابل قبولی حاصل گردد. در نهایت با استفاده از شبکه پیشنهادی TSDPC جهت

#### ۴-۲- نتایج مزرعه ۱

مزرعه ذرت اول نوعی از گل‌های ذرت که در شکل (۲) نشان داده شده می‌باشد. تصویربرداری از این مزرعه در تاریخ ۲۳ آگوست ۲۰۲۰ صورت گرفت و ۲۰ ناحیه از این مزرعه به عنوان تصاویر آموزش و تست در اختیار آزمایشگاه تخصصی رباتیک و پردازش تصویر دانشگاه شهید باهنر کرمان قرار داده شد. از هر بخش به صورت تصادفی تقریباً ۱۰ تصویر به اندازه  $512 \times 200$  برش داده شد و در مجموع ۲۶۳ تصویر تهیه شد. در ادامه در جدول (۳) تعداد تصاویر آموزش، ارزیابی و تست نشان داده شده است. تقریباً ۸۰ درصد داده‌ها به طور تصادفی جهت آموزش به شبکه، ۱۰ درصد جهت ارزیابی و ۱۰ درصد برای تست انتخاب شده است.



شکل ۲- گل‌های ذرت

جدول ۳- شرایط مدت زمان آموزش و تعداد تصاویر آشکارسازهای CenterNet و RepPoints، TSDPC

روش	مدت زمان آموزش	آموزش	ارزیابی	تست
CenterNet	۶ ساعت و ۷ دقیقه	۱۵۰	۱۵	۱۵
RepPoints	۱۸ ساعت و ۲۲ دقیقه	۲۲۸	۲۰	۱۵
TSDPC	۱۱ ساعت و ۱۶ دقیقه	۲۲۸	۲۰	۱۵

در ادامه پارامترهای بهینه آشکارساز پیشنهادی TSDPC، شبکه‌های RepPoints [۲۰] و CenterNet [۲۱] در جدول (۴) نشان داده شده است. در شکل (۳) و (۴) نمونه‌هایی از نتایج هر سه آشکارساز جهت مقایسه آورده شده است.

جدول ۴- پارامترهای بهینه آشکارسازهای RepPoints، TSDPC و CenterNet

پارامتر	TSDPC	RepPoints	CenterNet
مدل	RCNN	RCNN	ExtremeNet
شبکه پشتیبان	ResNeXt+DCN	ResNeXt	Hourglass
عمق	۱۰۱	۱۰۱	۱۰۴
تعداد کارت گرافیک	۲	۲	۲
اندازه دسته	۲	۲	۱۱
تعداد مراحل	۵۰۰	۵۰۰	۲۴۰
بهینه ساز	SGD	SGD	Adam
سایز تصویر ورودی	(۱۳۳۳ و ۸۰۰)	(۱۳۳۳ و ۸۰۰)	(۵۱۲ و ۵۱۲)
نرخ یادگیری	۰.۰۰۱۲۵	۰.۰۰۱۲۵	۰.۰۰۰۱۲۵
تبدیلات	تغییر مقیاس، نرمالیزه کردن، چرخش	تغییر مقیاس، نرمالیزه کردن، چرخش	تغییر مقیاس، نرمالیزه کردن
اندازه تصاویر تست	(۱۳۳۳ و ۸۰۰)	(۱۳۳۳ و ۸۰۰)	(۵۱۲ و ۵۱۲)
آستانه	۰/۶	۰/۶	۰/۳



(الف)



(ب)



(ج)




شکل ۳- تصویر اول تشخیص گل‌های ذرت- (الف) TSDPC، (ب) RepPoints و (ج) TP-CenterNet (زرد)، FP (نیلی)، FN (آبی) و Ng (حقیقت زمینی- سبز)



جدول ۵- مقایسه شبکه‌های TSDPC، RepPoints و CenterNet در آشکارسازی گل‌های ذرت مزرعه ۱ در ۱۵ تصویر


روش	Pr(%)	Re(%)	Sc(%)
CenterNet	میانگین ۹۶/۱۶	میانگین ۹۶/۱۲	میانگین ۹۶/۳۷
	واریانس ۳/۳۵	واریانس ۴/۵	واریانس ۲/۷۳
RepPoints	میانگین ۹۲/۸۳	میانگین ۸۸/۷۸	میانگین ۹۷/۷۵
	واریانس ۳/۶۲	واریانس ۷/۸۲	واریانس ۴/۷۵
TSDPC	میانگین ۹۸/۵۲	میانگین ۹۸/۲۳	میانگین ۹۸/۹
	واریانس ۱/۸۹	واریانس ۳/۱۳	واریانس ۱/۵۸

در شکل (۵) نمودارهای مربوط به مقایسه تعداد گل‌های ذرت مربوط به ۱۵ تصویر تست که به درستی شمرده شده است برای این سه آشکارساز آورده شده است:




شکل ۵- نمودار تعداد تشخیص گل‌های ذرت برای آشکارسازهای TSDPC، RepPoints و CenterNet (الف) TP (تعداد ذرت‌های درست)، (ب) FP (تعداد ذرت‌های اشتباه تشخیص داده شده) و (ج) FN (تعداد ذرت‌های تشخیص داده نشده)


همانگونه که در تصویر ۵ (الف) مشخص است نزدیک‌ترین نمودار به نمودار قرمز، که مربوط به تعداد گل‌های



(الف)



(ب)



(ج)

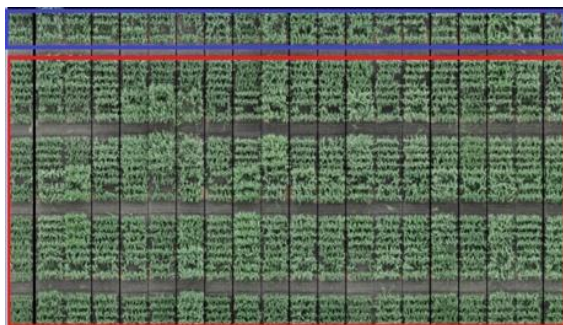
شکل ۴- تصویر دوم از تشخیص گل‌های ذرت (الف) TSDPC، (ب) RepPoints و (ج) TP-CenterNet (زرد)، FP (نیلی)، FN (آبی) و Ng (حقیقت زمینی - سبز)

با توجه به نتایج حاصل از شبکه‌های پیشنهادی که در شکل‌های بالا مشخص است، شبکه پیشنهادی TSDPC به دقت بالاتری در برآورد میزان محصول گل‌های ذرت دست یافته است. شبکه CenterNet یک شبکه عاری از کادر مبتنی بر مرکز می‌باشد، که همانگونه که در شکل ۳ (ج) و ۴ (ج) نشان داده شده است. مبنای آموزش و تست شبکه براساس مرکز گل‌های ذرت بوده است و در نهایت نتایج حاصل با مختصات اصلی مربوط به گل‌های ذرت که توسط تیم متخصص کشاورزی فراهم گردیده، مقایسه شده و دقت بررسی شده است. در جدول (۵) سه آشکارساز TSDPC، RepPoints و CenterNet مقایسه شده است.

RepPoints از درستی، نرخ یادآوری و امتیاز بالاتری برخوردار است.

#### ۴-۳- نتایج مزرعه ۲

مزرعه ذرت دوم گونه ای دیگر از گل‌های ذرت که در شکل ۸ (الف) نشان داده شده است. تصویربرداری از این مزرعه در تاریخ ۱۴ آگوست ۲۰۲۱ توسط دوربین Sony Alpha 7R-III RGB که بر روی پهپاد ماتریس DJI M600 Pro نصب شده با سیستم Trimble APX-15v3 ژئورفرنس گردیده در ارتفاع ۲۰ متری انجام گرفت. رزولوشن ارتوفوتو تولید شده ۰/۲۵ سانتی متر می‌باشد و ۲۰ ناحیه از این مزرعه به عنوان تصاویر آموزش و تست در اختیار آزمایشگاه تخصصی رباتیک و پردازش تصویر کرمان قرار داده شد. توسط تیم پردازش تصویر از بخش‌های تصویربرداری شده توسط پهپاد ارتوفوتو مزرعه تشکیل شد و بخش‌های مربوط به تست و آموزش همانگونه که در شکل ۷ (ب) نشان داده شده، جدا گردیده است و به صورت تصادفی از بخش انتخابی جهت آموزش، ارزیابی و تست ۴۸۴ تصویر به سایز ۷۰۰×۶۰۰ تهیه گردید. تعداد تصاویر آموزش، ارزیابی و تست در جدول (۶) نشان داده شده است.



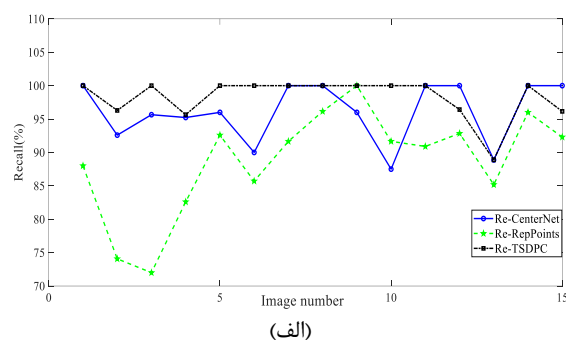
(الف)




(ب)

شکل ۷- (الف) نمونه گل‌های ذرت (ب) ارتوفوتو گل‌های ذرت (بخش قرمز مربوط به آموزش و بخش آبی مربوط به تست می‌باشد).


ذرت اصلی تعیین شده توسط گروه متخصص کشاورزی است نمودار مشکی می‌باشد. که بیانگر دقت بیشتر شبکه پیشنهادی TSDPC نسبت به سایر شبکه‌های پیشنهادی می‌باشد. در ۵ (ب) مشخص است، شبکه پیشنهادی TSDPC نسبت به دو شبکه دیگر تعداد گل‌های ذرت کم-تری را به اشتباه تشخیص داده است و تصویر ۵ (ج) بیانگر این است که شبکه پیشنهادی TSDPC در تشخیص تعداد کمی از گل‌های ذرت ناموفق بوده است. در شکل (۶) نمودارهای مربوط به مقایسه درستی، نرخ یادآوری و امتیاز برای این سه آشکارساز آورده شده است:



(الف)



(ب)



(ج)

شکل ۶- نمودار مقایسه درستی، نرخ یادآوری و امتیاز برای آشکارسازهای TSDPC، RepPoints و CenterNet (الف) درستی، (ب) نرخ یادآوری و (ج) امتیاز

با توجه به تصاویر ۶ (الف)، ۶ (ب) و ۶ (ج) مشخص است که آشکارساز پیشنهادی TSDPC جهت شمارش گل‌های ذرت نسبت به دو شبکه CenterNet و



جدول ۷- مقایسه شبکه‌های TSDPC و RepPoints در آشکارسازی گل‌های ذرت مزرعه ۲ در ۴۴ تصویر

روش	Pr(%)		Re(%)		Sc(%)	
TSDPC	میانگین	۹۴/۲۱	میانگین	۹۲/۷۲	میانگین	۹۲/۵۳
	واریانس	۱۱/۷۳	واریانس	۱۰/۱۸	واریانس	۷/۶۸
RepPoints	میانگین	۹۲/۷۹	میانگین	۸۶/۸۳	میانگین	۸۷/۷۴
	واریانس	۱۴/۷۸	واریانس	۱۵/۷	واریانس	۱۰/۹۸

## ۵- نتیجه گیری

در این مقاله یک آشکارساز نوین TSDPC جهت تشخیص هوشمند گل‌های ذرت در تصاویر پهپادی که نوعی از اشیاء کوچک محسوب می‌شوند، معرفی گردید. یک شبکه پشتیبان ترکیبی جدید از ResNeXt\_101 و DCN همچنین معماری Cascade-RCNN بکارگرفته شد که با تعیین پارامترهای بهینه در تشخیص گل‌های ذرت نسبت به آشکارسازهای معتبر CenterNet و RepPoints در صنعت کشاورزی دقت بالاتری حاصل شد. جهاد کشاورزی می‌تواند از آشکارساز خودکار و هوشمند TSDPC جهت تشخیص و شمارش هوشمند گل‌های ذرت برای برآورد میزان محصول مزرعه استفاده کند. که دارای مزایا ذیل است:

- تشخیص و شمارش سریع گل‌های ذرت جهت برآورد میزان و افزایش بهره‌وری محصول، بهبود عملکرد مدیریت مزرعه
- کاهش خطای انسانی در شمارش گل‌های ذرت، امکان آرشئوسازی میزان محصولات هر سال و بررسی آن‌ها در گذر زمان

پیشنهادات زیر برای آینده می‌تواند مورد بررسی قرار گیرد:

- به دلیل مشابهت گل‌های ذرت به دیگر گیاهان چون سویا و پنبه می‌توان با کمک یادگیری انتقالی<sup>۱</sup> از مدل ایجاد شده کنونی برای شمارش گیاهان در دیگر مزارع استفاده نمود.
- استفاده از مفاهیم یادگیری با تعداد داده آموزشی کم<sup>۲</sup> برای برآورد محصول در تاریخ‌های متفاوت جهت کاهش گیاهان شناسه گذاری شده و کاهش زمان یادگیری بهره گرفت.

## سپاسگزاری

از دانشگاه پردو ایندیانا آمریکا جهت قرار دادن تصاویر خام پهپادی و شرکت دانش بنیان داده کاوی ویرا ژرف کویر که ارتوفوتوهای مربوطه را فراهم نمودند، تشکر می‌نماییم.


<sup>۱</sup> Transfer Learning

<sup>۲</sup> Few-Shot Learning

جدول ۶- مدت زمان آموزش و تعداد تصاویر آشکارسازهای TSDPC، RepPoints

روش	مدت زمان آموزش	آموزش	ارزیابی	تست
RepPoints	۲۲ ساعت و ۱۲ دقیقه	۴۰۰	۴۰	۴۴
TSDPC	۱۶ ساعت و ۱۰ دقیقه	۴۰۰	۴۰	۴۴

طبق بررسی‌های انجام شده برای گل‌های ذرت مزرعه اول در این بخش پارامترها تنظیم گردیده و آموزش و تست صورت گرفته و با شبکه‌ی RepPoints و حقیقت زمینی که توسط متخصصین کشاورزی تهیه شده مقایسه گردیده و نتایج در شکل (۸) نشان داده شده است.



شکل ۸- مثال‌هایی از تشخیص گل‌های ذرت- الف و ت) TSDPC، ب و ث) RepPoints، پ و ج) حقیقت زمینی

با توجه به تصاویر ۸ (الف)، ۸ (ب) و ۸ (پ) مشخص است که آشکارساز پیشنهادی TSDPC جهت شمارش گل‌های ذرت نسبت به شبکه RepPoints در تشخیص گل‌های ذرت کوچک بسیار بهتر عمل کرده است و نسبت به تصویر حقیقت زمینی شبکه پیشنهادی تنها در تشخیص گل ذرت گوشه تصویر ناتوان عمل کرده است. در تصاویر ۸ (ت)، ۸ (ث) و ۸ (ج) آشکارساز پیشنهادی نسبت به RepPoints بهتر عمل نموده و در مقایسه با حقیقت زمینی یک گل ذرت بسیار کوچک را بیشتر تشخیص داده که این امر بیانگر وجود خطای انسان در شمارش و تشخیص دستی گل‌های ذرت می‌باشد. در جدول (۷) دو آشکارساز TSDPC و RepPoints مقایسه شده است. نتایج بدست آمده نشان می‌دهد آشکارساز پیشنهادی دقت بالاتری در تشخیص صحیح گل‌های ذرت دارد.

## مراجع

- [1] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Computers and electronics in agriculture*, vol. 147, pp. 70-90, 2018.
- [2] W. G. Bastiaanssen, D. J. Molden, and I. W. Makin, "Remote sensing for irrigated agriculture: examples from research and possible applications," *Agricultural water management*, vol. 46, no. 2, pp. 137-155, 2000.
- [3] J. M. Peña, J. Torres-Sánchez, A. I. de Castro, M. Kelly, and F. López-Granados, "Weed mapping in early-season maize fields using object-based analysis of unmanned aerial vehicle (UAV) images," *PloS one*, vol. 8, no. 10, p. e77151, 2013.
- [4] M. Pérez-Ortiz, J. M. Peña, P. A. Gutiérrez, J. Torres-Sánchez, C. Hervás-Martínez, and F. López-Granados, "Selecting patterns and features for between-and within-crop-row weed mapping using UAV-imagery," *Expert Systems with Applications*, vol. 47, pp. 85-94, 2016.
- [5] Z. Zou, Z. Shi, Y. Guo, and J. Ye, "Object detection in 20 years: A survey," *arXiv preprint arXiv:1905.05055*, 2019.
- [6] Y.N. Ofir, "Classic versus deep learning approaches to address computer vision challenges: a study of faint edge detection and multispectral image registration", 2021, Kingston University.
- [7] X. Zhou, J. Zhuo ,and P. Krahenbuhl, "Bottom-up object detection by grouping extreme and center points," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 850-859.
- [8] T. Kong, F. Sun, H. Liu, Y. Jiang, L. Li, and J. Shi, "Foveabox: Beyond anchor-based object detection," *IEEE Transactions on Image Processing*, vol. 29, pp. 7389-7398, 2020.
- [9] B. Singh and L. S. Davis, "An analysis of scale invariance in object detection snip," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 3578-3587.
- [10] B. Singh, M. Najibi, and L. S. Davis, "SNIPER: Efficient multi-scale training," *arXiv preprint arXiv:1805.09300*, 2018.
- [11] C. Deng, M. Wang, L. Liu, Y. Liu, and Y. Jiang, "Extended feature pyramid network for small object detection," *IEEE Transactions on Multimedia*, 2021.
- [12] L. Jiao et al., "A survey of deep learning-based object detection," *IEEE access*, vol. 7, pp. 128837-128868, 2019.
- [13] Z. Liu, G. Gao, L. Sun, and Z. Fang, "HRDNet: high-resolution detection network for small objects," in *2021 IEEE International Conference on Multimedia and Expo (ICME)*, 2021, pp. 1-6: IEEE.
- [14] Lin, T.-Y., et al. Microsoft coco: Common objects in context. in *European conference on computer vision*. 2014. Springer.
- [15] G. Song, Y. Liu, and X. Wang, "Revisiting the sibling head in object detector," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020, pp. 11563-11572.
- [16] Y. Wu et al., "Rethinking classification and localization for object detection," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, pp. 10186-10195.
- [17] S. Xie, R. Girshick, P. Dollár, Z. Tu, and K. He, "Aggregated residual transformations for deep neural networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1492-1500.
- [18] J. Dai et al., "Deformable convolutional networks," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 764-773.
- [19] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097-1105, 2012.
- [20] X. Zhou, D. Wang, and P. Krähenbühl, "Objects as points," *arXiv preprint arXiv:1904.07850*, 2019.
- [21] M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani, and R. Budiarto, "Evaluating trust prediction and confusion matrix measures for web services ranking," *IEEE Access*, vol. 8, pp. 90847-90861, 2020.