



Semnan University

# Journal of Modeling in Engineering

Journal homepage: <https://modelling.semnan.ac.ir/>

ISSN: 2783-2538



## Research Article

# A New Deep Vision-Based Identifier As An Intelligent Herbicide Spraying Agent For Potato Farm Application

Hallo Omer Anvar<sup>a</sup>, Fardin Akhlaghian Tab<sup>a</sup>, Mohsen Ramezani<sup>a,\*</sup>, Kaveh Mollazade<sup>b</sup>

<sup>a</sup> Department of Computer Engineering, University of Kurdistan, Sanandaj, Iran

<sup>b</sup> Department of Biosystems Engineering, University of Kurdistan, Sanandaj, Iran

## PAPER INFO

### Paper history:

Received: 2023-11-18

Revised: 2024-05-28

Accepted: 2024-06-01

### Keywords:

Convolutional neural networks;  
Machine vision;  
Precision agriculture;  
Deep model;  
Environmentally friendly model.

## ABSTRACT

Weeding in potato fields with the least consumption of inputs (herbicide or mechanical operations) is one of the main goals of sustainable agriculture. In precision agriculture, machine vision-based systems are used as on-the-go sensing units to detect weeds from the main plant. This paper presents a new approach based on deep learning to detect weeds in potato fields. For this purpose, first, a comprehensive database was created, including the acquired images of the potato field (at different stages of plant growth, at different distances of the camera from the ground, at different hours of the day, and in different environmental conditions). Then, the location of the plants in the field (including weeds and potato plants) was determined using the deep YOLOV3 algorithm. Finally, to separate weeds from the main plant as well as to determine the type of weed, three different types of convolutional neural networks were developed. The results showed that the YOLOV3 algorithm is well able to localize the plants in the images. EN-Inception-V3 classifier was able to distinguish weeds from potato plants in the set of test images with 99.42% accuracy. The classification results of 9 different weed species using the developed deep learning models were satisfactory; so that the overall accuracy of EN-Inception-V3, EN-VGG-16, and HCNN models was 99.82%, 99.89%, and 92.83% in the training phase, and 96.69%, 90.32%, and 82.67% in the test phase, respectively. It should be noted that the combination of models leads to 98.2% accuracy in detecting the type of weeds.

DOI: <https://doi.org/10.22075/jme.2024.32372.2562>

© 2024 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

\* Corresponding author.

E-mail address: [m.ramezani@uok.ac.ir](mailto:m.ramezani@uok.ac.ir)

## How to cite this article:

mer Anvar, H., Akhlaghian Tab, F., Ramezani, M., & Mollazade, K. (2024). A new deep model for locating, detecting, and classifying weeds in potato farms. *Journal of Modeling in Engineering*, 22(79), 79-97. doi: 10.22075/jme.2024.32372.2562

## مقاله پژوهشی

# ارائه یک مدل مبتنی بر یادگیری عمیق برای مکان‌یابی، تشخیص و طبقه‌بندی علف‌های هرز در مزارع سیب‌زمینی

هالو عمر انور<sup>۱</sup>، فردین اخلاقیان طاب<sup>۱</sup>، محسن رضانی<sup>۱\*</sup>، کاوه ملازاده<sup>۲</sup>

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۲/۰۸/۲۷	<p>برداشت محصول سیب‌زمینی در زمین‌های کشاورزی با کمترین مصرف مواد اولیه (علف کش‌ها یا عملیات مکانیکی) یکی از اهداف اصلی کشاورزی پایدار است. در کشاورزی دقیق، سیستم‌های مبتنی بر بینایی ماشین به عنوان حسگرهایی که در حالت حرکت برای تشخیص علف‌ها از گیاه اصلی کاربرد دارند، می‌توانند مورد استفاده قرار گیرند. این مقاله یک مدل جدید بر اساس یادگیری عمیق برای تشخیص علف‌های هرز در زمین‌های سیب‌زمینی را ارائه می‌کند. در این راستا، ابتدا یک پایگاه داده جامع از زمین تحت کشت سیب‌زمینی شامل تصاویری از مراحل مختلف رشد گیاه، در فواصل مختلف دوربین از زمین، در ساعات مختلف روز و در شرایط محیطی متفاوت تهیه شده است. سپس، با استفاده از الگوریتم عمیق YOLOV3، موقعیت کل گیاهان در زمین تعیین می‌گردد. در نهایت، برای جداسازی علف‌های هرز از گیاه اصلی و تعیین نوع علف هرز سه شبکه‌های عصبی کانولوشنی توسعه داده شده است. نتایج نشان داده که الگوریتم YOLOV3 قادر است به خوبی مکان گیاهان را در تصاویر تشخیص دهد. همچنین این روش می‌تواند با دقت ۹۹.۶۴٪ علف‌ها را از گیاهان سیب‌زمینی در مجموعه تصاویر آزمایشی تشخیص دهد. نتایج دسته‌بندی ۹ گونه مختلف علف‌های هرز نیز با استفاده از مدل‌های یادگیری عمیق توسعه داده شده قابل قبول است؛ به طوری که دقت کلی مدل‌های EN-Inception-V3، EN-VGG-16 و HCNN به ترتیب در فاز آموزش ۹۹.۸۲٪، ۹۹.۸۹٪ و ۹۲.۸۳٪ و در فاز آزمایش ۹۶.۶۹٪، ۹۰.۳۲٪ و ۸۲.۶۷٪ می‌باشد. البته ترکیب این مدل‌ها دقت تشخیص را تا ۹۸.۲٪ ارتقا می‌دهد.</p>
بازنگری مقاله: ۱۴۰۳/۰۳/۰۸	
پذیرش مقاله: ۱۴۰۳/۰۳/۱۲	
<p><b>واژگان کلیدی:</b> شبکه عصبی کانولوشنی، بینایی ماشین، کشاورزی دقیق، مدل عمیق، مدل دوست‌دار محیط.</p>	
DOI: <a href="https://doi.org/10.22075/jme.2024.32372.2562">https://doi.org/10.22075/jme.2024.32372.2562</a>	
© 2024 Published by Semnan University Press. This is an open access article under the CC-BY 4.0 license. ( <a href="https://creativecommons.org/licenses/by/4.0/">https://creativecommons.org/licenses/by/4.0/</a> )	

## ۱- مقدمه

سیب‌زمینی در مناطق گسترده‌ای از بیشتر کشورهای جهان کشت می‌شود، اما به دلیل افزایش جمعیت جهان تقاضا برای این محصول در حال افزایش است. با توجه به محدود بودن منابعی مانند آب و زمین مناسب برای کشت، تولید بیشتر سیب‌زمینی نیازمند بهره‌وری بیشتر در همه مراحل کاشت، رشد و برداشت است. علف‌های هرز در

سیب‌زمینی به دلیل دارا بودن بتاکاروتن، پروتئین و نشاسته یک منبع غذایی مهم برای انسان‌ها است. بر اساس گزارش‌های فائو، سیب‌زمینی با تولید ۳۶۰ میلیون تن در سال ۲۰۲۰ پس از ذرت، گندم و برنج چهارمین محصول کشاورزی پر مصرف توسط بشر است [۱]. اگرچه

\* پست الکترونیک نویسنده مسئول: m.ramezani@uok.ac.ir

۱. گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه کردستان، سنندج، ایران  
۲. گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران

## استناد به این مقاله:

عمر انور، هلو، اخلاقیان طاب، فردین، رضانی، محسن، و ملازاده، کاوه. (۱۴۰۳). ارائه یک مدل عمیق دوست‌دار زیست برای مکان‌یابی، تشخیص و طبقه‌بندی علف‌های هرز در مزارع سیب‌زمینی. مدل سازی در مهندسی، ۲۲(۷۹)، ۷۹-۹۷. doi: 10.22075/jme.2024.32372.2562

پروژه‌های مبتنی بر بینایی استفاده شده‌اند تا محدودیت‌های روش‌های سنتی بینایی ماشین را برطرف کنند که در این زمینه موفق نیز بوده‌اند [۸]. در روش‌های یادگیری عمیق ویژگی‌ها از تعداد زیادی تصویر آموزشی خود به خود یاد گرفته می‌شوند. این عامل باعث می‌شود خروجی مدل‌های طبقه‌بندی در برابر تغییرات شرایط محیطی مقاوم شوند. همچنین در مقایسه با روش‌های سنتی بینایی ماشین، روش‌های یادگیری عمیق بدون نیاز به حذف پس زمینه عملکرد مناسبی خواهند داشت [۹].

تا به امروز انواع روش‌های مبتنی بر شبکه‌های عصبی کانولوشنی (CNN) در کاربردهای مختلفی از حوزه کشاورزی، به ویژه برای تشخیص علف‌هرز، استفاده شده است. در بسیاری از مطالعات مدل‌های CNN از پیش آموزش دیده مانند VGG19 و GoogLeNet برای تمییز علف‌های هرز از گیاه اصلی استفاده شده‌اند. علاوه بر این در برخی از پژوهش‌ها شبکه‌های عصبی کانولوشنی با ساختار تغییر یافته جدید برای طبقه‌بندی گیاهان پیشنهاد شده‌اند [۱۰]. استفاده از مجموعه تصاویری که حاوی تعداد کمی نمونه هستند یکی از چالش‌های پیاده‌سازی مدل‌های CNN در کاربردهای واقعی بوده است. همچنین، با توجه به تنوع علف‌های هرز در مناطق جغرافیایی مختلف، این مدل‌ها باید بر اساس گونه‌های علف‌های هرز موجود در هر منطقه آموزش دیده و توسعه داده شوند. در میان این مناطق ایران به عنوان یکی از بزرگترین تولیدکنندگان سیب‌زمینی دارای بیشترین تراکم علف هرز در مزارع به دلیل شرایط آب و هوایی خاص و عدم اجرای مناسب برنامه‌های مدیریت علف‌های هرز است. تا به امروز نیز هیچ رویکرد جامع بینایی ماشینی برای ایجاد یک مدل جهت مبارزه با علف‌های هرز در مزارع سیب‌زمینی ایران توسعه داده نشده است.

هدف این مطالعه توسعه یک مدل مبتنی بر یادگیری عمیق است که به تعیین موقعیت و تشخیص نوع علف هرز در مزارع سیب‌زمینی ایران بپردازد. تهیه یک مجموعه داده جامع از مزارع ایران و توسعه مدل‌های یادگیری عمیق برای طبقه‌بندی ۹ گونه علف هرز در این مزارع در شرایط واقعی از اهداف این پژوهش هستند تا با استفاده از این مدل به محدود کردن استفاده از علف کش و حفظ سلامت خاک کمک کرد. در حقیقت این مدل در یک سیستم سازگار با محیط زیست استفاده می‌شود. در اینجا ما سعی می‌کنیم

اکوسیستم‌های کشاورزی به منظور دریافت نور بیشتر، آب و مواد مغذی خاک رشد گیاهانی مانند گیاه سیب زمینی را محدود می‌کند و منجر به کاهش بهره‌وری می‌شود. لذا به عنوان یک عامل بسیار مهم در ارتقای بهره‌وری، از بین بردن علف‌های هرز در مرحله رشد باید مورد توجه قرار گیرد [۲]. استفاده از علف‌کش‌های خاک باعث می‌شود که جز سیب‌زمینی، هیچ گیاه دیگری در زمین رشد نکند. اگرچه این روش از نظر علف‌زدایی مؤثر است، اما به دلیل استفاده زیاد از علف‌کش‌ها آلودگی محیط زیست را به دنبال دارد و با اصول کشاورزی پایدار سازگاری ندارد [۳]. بنابراین علف‌زدایی صحیح نیازمند استفاده از فناوری در کشاورزی است که به وسیله آن علف‌های هرز ابتدا مکانیابی و شناسایی شده و سپس با استفاده از ابزارهای زراعی یا شیمیایی حذف شوند. در هر دو کاربرد شناسایی و تعیین مکان دقیق علف‌های هرز بین گیاهان سیب‌زمینی باید انجام شود و همچنین نوع علف هرز نیز باید شناسایی گردد. این کار از دو جنبه حائز اهمیت است که اولین مورد به امکان پاشش علف کش در حین حرکت به محل قرار گیری علف هرز بر می‌گردد [۴]. مورد دوم نیز به تعیین نوع علف هرز برای انتخاب مایع علف کش مربوط است. به عبارت دیگر، استفاده از یک علف‌کش خاص برای از بین بردن تمام گونه‌های علف‌هرز کافی نیست [۵]. بنابراین می‌توان از سامانه بینایی ماشین استفاده کرد تا گونه‌های علف‌هرز را در حین حرکت تعیین کرد و به تهیه نقشه توزیع و تراکم علف‌های هرز پرداخت.

مرور تحقیقات پیشین نشان می‌دهد که تلاش‌های گسترده‌ای برای توسعه روش‌های تشخیص علف‌هرز در حین حرکت انجام شده است. در عین حال بینایی ماشین به دلیل عدم نیاز به حسگرهای پیشرفته و تجهیزات خاص بیشتر مورد توجه قرار گرفته است. در سیستم‌های سنتی بینایی ماشین ویژگی‌های رنگ، شکل و بافت تصویر برای شناسایی گیاه اصلی از پس زمینه (خاک و سایر گیاهان) استفاده می‌شود. عملکرد این سیستم‌ها به شدت تحت تأثیر شرایط محیطی مانند شدت نور، وجود سایه، فاصله تصویربرداری و تراکم گیاهان است [۶]. حال آنکه چالش‌های جدی دیگری نیز وجود دارند که به تمایز علف‌های هرزی که در ویژگی‌های رنگ و بافت به گیاهان اصلی شباهت دارند بازمی‌گردند [۷]. در سال‌های اخیر شبکه‌های عصبی کانولوشنی (CNN) به طور گسترده در

این، به دلیل پیچیدگی بالای این شبکه‌ها و عدم قابلیت استفاده آنها در کاربردی که برخط<sup>۳</sup> است، یک معماری جدید شبکه عصبی کانولوشنی با تعداد کمتری لایه معرفی شده است که به عنوان یک روش کارآمد و سریع برای طبقه‌بندی محصولات کشاورزی و علف‌هرزها به جای این مدل‌های بهبود یافته استفاده شود. در نهایت نیز برای رسیدن به دقت بیشتر، این مدل‌های اصلاح شده و جدید با هم ترکیب می‌شوند تا تشخیص بهتری انجام گیرد.

ادامه این مقاله به صورت زیر سازماندهی می‌شود: در بخش ۲ کارهای انجام شده پیشین بررسی می‌شوند. بخش ۳ مجموعه داده جمع‌آوری شده را معرفی می‌کند. در بخش ۴ روش پیشنهادی به صورت مشروح توضیح داده می‌شود. بخش ۵ نیز به نتایج تجربی و بحث درباره عملکرد روش‌ها اختصاص دارد. در نهایت نتیجه‌گیری از مطالعه حاضر در بخش ۶ ارائه خواهد شد.

## ۲- کارهای پیشین

تحقیقات مختلفی در رابطه با شناسایی گیاهان در کشاورزی وجود دارد. در این مقاله، روش‌هایی که سعی در تشخیص گیاه محصول از علف‌های هرز دارند و یا گیاهان را طبقه‌بندی می‌کنند مد نظر خواهند بود. به عبارت دیگر تشخیص گیاهان از علف‌های هرز و طبقه‌بندی هر کدام از آنها با استفاده از تکنیک‌های بینایی ماشین در این بخش مرور می‌شوند. این روش‌ها را می‌توان به روش‌های سنتی و روش‌های مبتنی بر یادگیری عمیق تقسیم کرد. تحقیقات اخیر نشان می‌دهند که تکنیک‌های یادگیری عمیق عملکرد بهتری نسبت به طبقه‌بندی با استفاده از ویژگی‌های سنتی دارند. در ادامه ابتدا روش‌های سنتی مورد بررسی قرار می‌گیرند و سپس روش‌های عمیق مرور خواهند شد.

در یک روش سنتی از بینایی ماشین استفاده شده است تا محصولات سیب‌زمینی و سه نوع علف‌هرز تشخیص داده شود و آنها را طبقه‌بندی کنند [۱۱]. در این روش، سه ویژگی شامل بافت، رنگ و شکل از تصاویر استخراج می‌شوند و ترکیبی از شبکه عصبی و کلونی مورچگان برای طبقه‌بندی گیاهان بر اساس این ویژگی‌ها مورد استفاده قرار گرفته است. در این روش فاصله بین گیاهان و دوربین ثابت و حدود ۴۰ سانتیمتر است و تنها سه نوع علف‌هرز را

یک مدل پیشرفته با استفاده از شبکه‌های عصبی کانولوشنی (CNN) برای تمییز دادن گیاه سیب زمینی و علف‌های هرز و طبقه‌بندی علف‌های هرز یافته شده بر اساس نوع آنها در مزارع واقعی را معرفی نماییم. در این مطالعه یک مجموعه داده تصویر واقعی جدید که در شرایط مختلف از دو مزرعه جمع‌آوری شده است برای آموزش مدل و ارزیابی آن مورد استفاده قرار گرفته است. برای تشخیص گیاه سیب زمینی از علف‌های هرز و همچنین طبقه‌بندی علف‌های هرز سه شبکه عصبی کانولوشنی (CNN) مختلف پیشنهاد شده‌اند. این شبکه‌ها در یک مدل نهایی نیز تجمیع شده‌اند تا با ترکیب نقاط قوت آنها به دقت قابل توجه رسید. در حقیقت هر شبکه عصبی کانولوشنی (CNN) مورد استفاده روی تصاویر و شرایطی خاصی عملکرد مناسبی دارد و تجمیع این مدل‌ها در یک مدل نهایی باعث نیل به پوشش نقاط ضعف هر مدل می‌گردد. به طور کلی نوآوری‌های پژوهش حاضر عبارتند از:

۱- تصاویر واقعی از دو مزرعه پژوهشی سیب‌زمینی دانشگاه کردستان که در شرایط مختلفی تهیه شده‌اند و در یک مجموعه داده گرد آمده است تا برای مطالعات بیشتر مورد استفاده قرار گیرند. تصاویر شامل مراحل مختلف رشد گیاه در شرایط محیطی متفاوت مانند نور، زمان و آب و هوا می‌باشند.

۲- به منظور رسیدن به یک سیستم سمپاشی مکانیزه سازگار با محیط زیست، در این روش فرآیند مکان‌یابی گیاهان نیز در نظر گرفته شده است. در این پژوهش از YOLOV3 برای مکان‌یابی گیاه سیب زمینی و علف هرز استفاده می‌شود.

۳- دو مدل شبکه عصبی کانولوشنی رایج InceptionV3 و VGG16 اصلاح و تنظیم شده‌اند تا برای وظایف تشخیص گیاه و طبقه‌بندی علف هرز استفاده شوند. در این مطالعه این مدل‌ها با نام‌های EN-VGG-16 و EN-Inception-V3 شناخته می‌شوند. معماری شبکه عصبی کانولوشنی با تغییر لایه‌های بالای InceptionV3 و VGG16 اصلاح می‌شود. در این مطالعه از تکنیک یادگیری انتقالی<sup>۲</sup> برای به‌روزرسانی وزن‌های قبلی مدل استفاده می‌شود تا مدل بهبود یافته‌ای حاصل گردد. علاوه بر

<sup>3</sup> Online

<sup>2</sup> Transfer learning technique

بخشی‌پور و جعفری نیز از طبقه‌بندهای ANN و SVM برای تمییز چهار گونه علف هرز از گیاهان چغندر قند استفاده کرده‌اند که ویژگی‌های استخراج شده شامل شکل، Moment invariant و توصیف‌گرهای فوریه است [۱۶]. تصاویر موجود در مجموعه داده استفاده شده در این مطالعه نیز در ارتفاع ثابت یک متری تهیه شده‌اند.

مشخص است که روش‌های سنتی عملکرد دقیق و قوی برای استفاده در کاربردهای واقعی تشخیص و شناسایی گیاهان ندارند. تهدیدهای مختلفی مانند سایه، تداخل گیاهان و مراحل مختلف رشد عملکرد این روش‌ها را تحت الشعاع قرار می‌دهد (O'Mahony و همکاران، ۲۰۲۰). به این منظور نسل‌های جدیدی از الگوریتم‌های بینایی کامپیوتری بر اساس تکنیک‌های یادگیری عمیق از سال ۲۰۱۲ تاکنون توسعه یافته‌اند تا با چالش‌های روش‌های سنتی مقابله کنند [۱۷-۱۹]. در ادامه، مطالعاتی که به دنبال استفاده از روش‌های عمیق هستند مورد بررسی قرار می‌گیرند.

Ng و همکاران یک شبکه عصبی کانولوشنی پیشنهاد کردند که برای تمییز محصولات کشاورزی از علف‌های هرز مورد استفاده قرار گیرد [۱۷]. در این مطالعه یک مجموعه داده استفاده شده است که در هر کلاس ۱۲۳ تصویر وجود دارد و ۸۰ درصد از مجموعه داده برای آموزش مدل و ۲۰ درصد باقی‌مانده برای مرحله اعتبارسنجی استفاده می‌شوند. آنها شبکه عصبی کانولوشنی پیشنهادی خود را با سه طبقه‌بند سنتی K-Nearest-Neighbors، شبکه عصبی و ماشین بردار پشتیبانی مقایسه کرده‌اند که نشان دهنده عملکرد بهتر شبکه عصبی کانولوشنی است. در مطالعه‌ای دیگر یک طبقه‌بند ترکیبی با مدل CNN و طبقه‌بند جنگل تصادفی<sup>۴</sup> برای تمییز دادن گیاه هویج از علف‌های هرز معرفی شده است. مجموعه داده استفاده شده در این مطالعه شامل ۴۷۴۲ تصویر از مراحل مختلف رشد گیاهان است و نتیجه قابل قبولی نیز دارد. Sarvini و همکاران نیز در پژوهش خود سعی در طبقه‌بندی چهار نوع محصول کشاورزی و دو نوع علف هرز با استفاده از سه طبقه‌بند مختلف شامل ماشین بردار پشتیبانی، شبکه عصبی مصنوعی و شبکه عصبی کانولوشنی دارند [۱۹]. مجموعه داده آن‌ها شامل ۲۵۶۰ تصویر است و شبکه عصبی کانولوشنی بهترین نتیجه را بدنبال داشته است.

به روشنی طبقه‌بندهای مبتنی بر شبکه‌های عمیق عملکرد

تشخیص می‌دهد. باید توجه داشت که فاصله ثابت بین دوربین و زمین می‌تواند مشکلات مختلفی را در هنگام رشد گیاهان و افزایش اندازه برگ‌ها ایجاد کند. همچنین می‌توان از تغییرات مورفولوژیک به عنوان ویژگی و شبکه عصبی به عنوان طبقه‌بند استفاده کرد تا بتوان علف‌های هرز و گیاه ذرت را از همدیگر تشخیص داد. این روش بر روی دو مجموعه داده کوچک و دو نوع علف هرز آموزش داده شده است.

در یک روش با نام ANN-CA دو طبقه‌بند ساده با هم ترکیب شده‌اند که از آن برای تفکیک سیب‌زمینی از پنج نوع علف‌هرز استفاده می‌شود [۱۲]. در این مطالعه، ۴۲۹۹ تصویر برای آموزش و ارزیابی روش استفاده شده است و ویژگی‌های بافت، ماتریس همرفتی (GLCM) تصویر خاکستری، رنگ، طیف بافتی، عدم تغییر لحظه‌ای و شکل از تصاویر بدین منظور استخراج گردیده است. این روش حساس به رنگ و نور می‌باشد و در تصاویر مورد استفاده نیز دوربین فاصله ثابت ۴۵ سانتی متری از زمین دارد. Lin و همکاران [۱۳] در مطالعه‌ای دیگر برای تشخیص ذرت و علف‌های هرز از ویژگی‌های طیفی، شکلی و بافتی استفاده نموده‌اند. الگوریتم مورد استفاده برای طبقه‌بندی در این مطالعه درخت تصمیم C5.0 بوده است. شایان ذکر است که این روش نیز بر روی مجموعه داده خاصی اعمال شده و با استفاده از مجموعه داده‌های دیگر عملکرد آن به شدت افت خواهد کرد. در مطالعه‌ای دیگر از آنالیز موجک به عنوان ویژگی تمییز دهنده محصولات کشاورزی و علف‌های هرز استفاده شده است که بر روی یک مجموعه داده محلی و کم حجم شامل ۷۳ تصویر عملکرد مناسبی داشته است [۱۴]. لازم به ذکر است که این روش‌ها در مقابل تغییرات ارتفاع (خودرو سنجی ممکن است در حال حرکت دچار تغییر ارتفاع شود) و نور مقاوم نیستند.

یک روش دیگر برای طبقه‌بندی تصاویر گلخانه از تحلیل مؤلفه‌های اصلی یا PCA استفاده می‌کند [۱۵]. در آزمایش‌های این مطالعه تغییرات شرایط محیطی، وضعیت خاک و تغییرات سایه یا نور در نظر گرفته نمی‌شوند. علاوه بر این، تصاویر از مراحل اولیه رشد گندم تهیه شده و فقط دو نوع علف‌هرز را شامل می‌شود. ویژگی‌های استفاده شده در این مطالعه ترکیبی از رنگ، بافت و شکل هستند که با استفاده از تبدیل PCA به سه توصیف‌گر نگاهت می‌یابند.

<sup>4</sup> Random Forest

دلیل استفاده از بیش از ۹۰ هزار تصویر دنبال داشته است. بعلاوه، می‌توان با استفاده از ساختاری نوآورانه نیز به اصلاح معماری YOLOV3 پرداخت. این کار در پژوهشی برای مکان‌یابی و طبقه‌بندی علف‌های هرز پس از تمییز دادن آن‌ها از چغندر قند انجام شده است [۲۵]. در این مطالعه یک مجموعه داده شامل ۲۲۷۱ تصویر مصنوعی به همراه ۴۵۲ تصویر واقعی برای آموزش مدل استفاده شده و همچنین مدل با ۱۰۰ تصویر واقعی از مزرعه ارزیابی شده است. به طور کلی، همه این روش‌ها هنوز با محدودیت‌های مختلفی روبه‌رو هستند. به عنوان محدودیت اول، مجموعه داده‌های استفاده شده شامل تعداد کافی تصویر از شرایط واقعی مختلف نیستند. به عنوان محدودیت دیگر که برای کاربردهای برخط حائز اهمیت است اکثر روش‌های شناسایی گیاهان نمی‌توانند به تمییز چندین شیء در یک تصویر و مکان‌یابی آنها بپردازند که در مطالعه حاضر تا حدودی این موارد مورد بررسی قرار می‌گیرند.

### ۳- جمع‌آوری داده‌ها

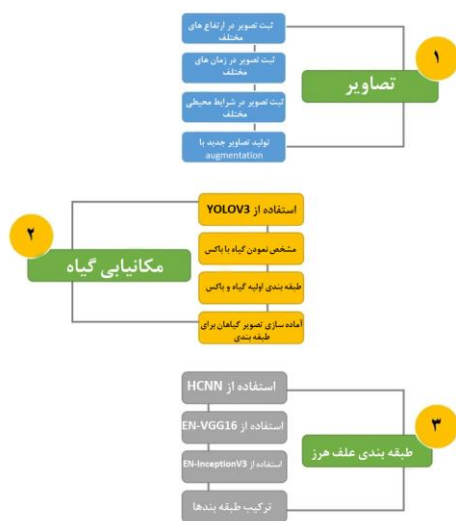
اگرچه مدل‌های یادگیری عمیق ظرفیت قابل توجهی برای مقابله با چالش‌های یادگیری دارند، اما در معرض خطر بیش‌برازش هستند [۲۶]. بنابراین، این مدل‌ها به حجم قابل توجهی از داده‌های آموزشی نیاز دارند تا قابلیت تعمیم را دارا باشند. در این پژوهش سعی شده که تعداد هشت هزار تصویر از مزارع پژوهشی سیب‌زمینی دانشگاه کردستان و شهر سلیمانیه عراق در حالات مختلف جمع‌آوری شود که بتواند برای آموزش مناسب مدل مورد استفاده قرار گیرد. از آنجا که این مزارع برای اهداف پژوهشی استفاده می‌شوند، طی چند سال قبل از این مطالعه برنامه مدیریت علف‌های هرز بر روی آنها انجام نشده است. بنابراین نوع و تراکم علف‌های هرز در این مزارع به اندازه کافی بالا بوده و از آن برای ایجاد یک مجموعه داده مناسب استفاده شده است. برای داشتن مجموعه داده‌ای کامل، تصاویر در مراحل مختلف رشد گیاه، ساعات مختلف روز (۰۸:۰۰ - ۱۱:۰۰ (بازه یک)، ۱۱:۰۰ - ۱۴:۰۰ (بازه دو)، ۱۵:۰۰ - ۱۸:۰۰ (بازه سه) و ۱۸:۰۰ - ۲۰:۰۰ (بازه چهار)) و ارتفاع‌های مختلف (فاصله بین لنز دوربین و زمین شامل ۲۰ سانتی‌متر، ۴۰ سانتی‌متر، ۶۰ سانتی‌متر، ۸۰ سانتی‌متر و ۱۰۰ سانتی‌متر) تهیه شدند.

بهتری نسبت به طبقه‌بندی سنتی دارند چراکه شبکه‌های عمیق قادر به استخراج ویژگی‌های تمییز دهنده از تصاویر هستند که البته برای آموزش آنها باید داده‌های کافی نیز در اختیار داشت و هر چه تعداد نمونه‌های آموزش دهنده سیستم کمتر باشد قاعدتاً افت دقت نیز رخ خواهد داد. در یک پژوهش، یک مدل عمیق CNN برای شناسایی کردن گیاهان بر اساس الگوی رگ‌برگ ارائه شده است که با وجود استفاده از یک ساختار مناسب در مدل، بدلیل عدم استفاده از تعداد نمونه کافی توفیق چندانی حاصل نشده است [۲۰]. در این مطالعه ۸۶۶ تصویر از سه گونه مختلف لوبیا سفید، لوبیا قرمز و سویا مورد بررسی قرار گرفته است. از سوی دیگر Ferreira و همکاران [۲۱] از یک طبقه‌بند CNN برای تشخیص علف‌های هرز و برگ‌های گیاه در یک مزرعه سویا استفاده کرده‌اند. مجموعه داده استفاده شده در این مطالعه شامل ۱۵,۳۳۶ تصویر است که با توجه به آموزش مناسب انجام شده به دقت مناسب ۹۸ درصد رسیده‌اند. با این وجود این پژوهش به دلیل عدم تهیه تصاویر در ارتفاع‌های مختلف نسبت به ارتفاع دوربین حساسیت نشان می‌دهد.

در مطالعه‌ای دیگر طبقه‌بند شبکه عصبی کانولوشنی (CNN) برای شناسایی گیاهان هنگامی که در مراحل اولیه رشد قرار داشته و در شرایطی که برگ‌ها در تصاویر کمترین اشتراک را دارند و هیچ سایه‌ای در تصویر موجود نیست مورد استفاده قرار گرفته است (Elnemr, 2019). همچنین Suh و همکاران شش معماری CNN از جمله AlexNet, ResNet-101, ResNet50, GoogLeNet, VGG-19 و Inception-v3 را برای طبقه‌بندی چغندر قند و سیب‌زمینی مجدداً آموزش داده‌اند تا به عملکرد بهتری برسند [۲۲]. این مدل‌ها با حذف لایه بالایی و افزودن دو لایه FC اصلاح شده و مجدداً آموزش دیده‌اند. Olsen و همکاران [۲۳] نیز از مدل‌های Inception-v3 و ResNet50 برای تمییز دادن ۱۶ نوع علف هرز استفاده کرده‌اند که در مجموعه داده مورد استفاده آنها بیش از ۱۰۰۰ تصویر از هر گونه هدف در ارتفاع یک متری وجود دارد. همچنین Peteinatos و همکاران [۲۴] نیز از سه شبکه وفق داده شده VGG-16, ResNet50 و Xception برای بهبود طبقه‌بندی گیاه سیب‌زمینی و ۱۱ نوع علف هرز استفاده کرده است که به نسبت دقت بهتری (۰.۹۸) را به

#### ۴- روش پیشنهادی

همانگونه که از شکل (۳) مشخص است روش پیشنهادی این پژوهش که به منظور ارائه یک مدل برای استفاده در کاربردهای واقعی است شامل سه مرحله مکان‌یابی گیاهان، تشخیص محصول از علف هرز و تشخیص نوع علف هرز است. در مرحله اول از این روش برای مکان‌یابی گیاهان از Tiny-YOLOV3 به عنوان مرحله پیش‌پردازش استفاده می‌شود. سپس گیاهان یافته شده باید به عنوان محصول یا علف هرز با استفاده از یک مدل خاص برچسب‌گذاری شوند و در نهایت نوع علف هرز برای تعیین علف‌کش مورد استفاده باید شناسایی گردد. بنابراین برای طبقه‌بندی تصاویر دو مرحله اصلی در نظر گرفته می‌شود که مرحله اول طبقه‌بندی تصاویر به کلاس‌های محصول و علف‌هرز خواهد بود و در مرحله دوم علف‌های هرز بر اساس نوع خود به ۹ کلاس طبقه‌بندی خواهند شد. برای انجام این طبقه‌بندی‌ها سه شبکه شامل دو شبکه قبلاً معرفی شده VGG-16 و GoogleNet InceptionV3 که نسخه اصلاح شده آنها استفاده خواهد شد و شبکه پیشنهادی HCNN در نظر گرفته می‌شوند. شبکه‌های قبلاً آموزش دیده VGG-16 و GoogleNet InceptionV3 توسط یادگیری انتقالی یا transfer learning اصلاح خواهند شد تا در این کاربرد مورد استفاده قرار گیرند.



شکل ۳- مراحل روش پیشنهادی

شبکه HCNN نیز با توجه به کند بودن دو مدل از پیش آموزش دیده به عنوان یک مدل با پیچیدگی پایین و عملکرد مناسب جهت اجرا در دستگاه‌های تعبیه شده به



شکل ۱- نمونه تصاویر از گیاهان و علف‌های هرز در بازه‌های مختلف زمانی (الف) بازه یک (ب) بازه دو (ج) بازه سه (د) بازه چهار




شکل ۲. نمونه تصاویر از گیاهان و علف‌های هرز در ارتفاع‌های مختلف (الف) بیست سانتی متری (ب) چهل سانتی متری (ج) شصت سانتی متری (د) هشتاد سانتی متری (ه) یک متری


تصویربرداری که در ساعات مختلف روز انجام شده موجب داشتن شرایط نورپردازی متفاوت و حضور سایه‌ی گیاهان در تصاویر شده است که برای آموزش مدل عمیق بسیار مفید خواهد بود. همچنین از آنجا که تصاویر در مراحل مختلف رشد گیاه و ارتفاع‌های مختلف تهیه شده‌اند، مجموعه داده نهایی شامل گستره‌ای مناسب از گیاهان با اندازه‌های کوچک تا بزرگ است. تصویربرداری نیز توسط یک دوربین دیجیتال ۱۴ مگاپیکسل با قابلیت زوم اپتیکال ۵ برابر و رزولوشن  $2592 \times 1944$  پیکسل انجام شده که روی یک پایه ثابت با قابلیت تنظیم ارتفاع دوربین نصب شده است. شکل (۱) و شکل (۲) به ترتیب نمونه‌ای از تصاویر گیاهان در ساعات و ارتفاع‌های مختلف را نمایش می‌دهد.

لازم به ذکر است، در مسائلی که از شبکه‌های عمیق استفاده می‌کنند اغلب با استفاده از تکنیک تغییر داده یا data augmentation ایجاد نمونه‌های جدید و افزایش حجم داده‌های مورد استفاده صورت می‌گیرد [۲۷]. تکنیک‌های تغییر داده‌ی تصویری بدون نیاز به حافظه اضافی، داده‌های آموزش بیشتری را از تصاویر موجود تولید می‌کنند. لذا در پژوهش حاضر نیز داده‌های جمع‌آوری شده با استفاده از تکنیک تغییر داده افزایش داده شده‌اند تا تعداد نمونه‌ها در مجموعه داده به سی هزار تصویر افزایش یابد. نمونه‌های جدید با استفاده از تغییرات تصادفی متنوع ایجاد می‌شوند و نتایج تغییرات با هم ترکیب شده تا مجموعه نهایی حاصل شود.





الف



ب


شکل ۵-الف) Max-pooling با ابعاد ۲ در ۲ (ب) لایه کاملاً

متصل

فیلترهای مورد استفاده در لایه‌های کانولوشن ابعاد  $1 \times 1$  و در لایه‌های pooling ابعاد  $2 \times 2$  دارند. در هر لایه کانولوشن  $32$  فیلتر بر روی تصویر ورودی برای استخراج ویژگی‌ها اعمال می‌شوند تا بتوانند رنج مناسبی از ویژگی‌ها را که برای طبقه‌بندی موثر خواهند بود استخراج کند. واضح است که تعداد فیلترهای بیشتر ویژگی‌های استخراجی بیشتری را به دنبال دارد اما باعث پیچیده شدن ساختار و زمانبر شدن رویه می‌شود. در حقیقت در این لایه‌ها فیلترهایی استفاده می‌شوند که برای یادگیری ویژگی‌ها مناسب هستند و هر فیلتر آموزش داده شده در لایه‌های کانولوشن نقشه ویژگی را برای ورود به لایه بعدی آماده می‌نماید. عملگر کلیدی که در روند کانولوشن مورد استفاده قرار گرفته است ضرب ماتریسی می‌باشد که بر روی مقادیر فیلترها و پیکسل‌ها اعمال شده و نتایج ضرب‌ها تحت عنوان نقشه ویژگی حاصل شناخته می‌شوند.

پس از روند کانولوشن، تابع فعال‌سازی ReLU روی نقشه‌های ویژگی استخراج شده اعمال می‌شود تا به عنوان یک تابع رایج با سرعت محاسبات بالا از مشکلات محو شدن گرادینت<sup>۶</sup> جلوگیری نماید [۲۸]. سپس، لایه برداشت حداکثر مقدار<sup>۷</sup> (مانند شکل ۵-الف) برای کاهش ابعاد نقشه

صورت برخط معرفی خواهد شد. علاوه بر این، این مدل‌ها که هر کدام عملکرد مناسبی در شرایط خاص دارند با هم ترکیب خواهند شد و برای حصول یک عملکرد کلی مناسب مورد بررسی قرار می‌گیرند. در ادامه، معماری مدل پیشنهادی HCNN ابتدا معرفی می‌شود و پس از آن نحوه تنظیم مجدد (اصلاح) شبکه‌های از پیش آموزش دیده تشریح خواهند شد.



شکل ۴- ساختار مدل HCNN

#### ۴-۱- مدل HCNN

با توجه به عملکرد این سیستم و نیاز به پاسخگویی مدل به صورت برخط، قطعاً نیاز به یک مدل سریع و با پیچیدگی کم وجود دارد که بتواند در کمترین زمان ممکن طبقه‌بندی‌هایی با دقت بالا انجام دهد. مدل پیشنهادی HCNN شامل لایه‌های کانولوشن<sup>۵</sup>، pooling، ReLU، fully connected و طبقه‌بندی است و برای هر دو کاربرد طبقه‌بندی محصول-هرز و تشخیص نوع علف هرز آموزش داده می‌شود. معماری این مدل در شکل (۴) نشان داده شده است که در آن لایه اول مربوط به دریافت تصویر RGB با ابعاد  $128 \times 128$  به عنوان لایه ورودی است. در این شبکه عصبی کانولوشنی، ۹ لایه کانولوشن وجود دارد و هر لایه کانولوشنی توسط یک لایه pooling با روش برداشت حداکثر مقدار یا max-pooling دنبال می‌شود. لایه‌های کانولوشن در حقیقت ویژگی‌ها را استخراج می‌کنند و لایه‌های pooling برخی از ویژگی‌های استخراج شده را حذف کرده و حجم محاسبات را کنترل می‌کنند.


<sup>7</sup> Max-pooling

<sup>5</sup> Convolutional

<sup>6</sup> vanishing gradient problems




16 (شکل ۶)، VGG19، GoogleNet و ResNet مورد استفاده قرار گرفته است [۳۰]. مدل‌های آموزش دیده عمیق در کاربردهای مختلف برای رسیدن به حداکثر کارایی نیاز به آموزش دوباره دارند که باید توسط یک سیستم با توانایی پردازشی قابل توجه انجام شود [۳۱].



شکل ۶- معماری VGG-16

به عنوان راه حلی برای غلبه بر این چالش، از Transfer learning یا انتقال یادگیری استفاده می‌شود تا همزمان با استفاده از دانش قبلی و داده‌های جدید یک طبقه‌بندی جدید در کاربردی جدید انجام شود [۲۸]. به عبارت دیگر این تکنیک برای آماده‌سازی یک مدل آموزش دیده برای کاربردهای طبقه‌بندی جدیدی است که حجم کمی از داده‌های آموزشی برای آنها در دسترس است. وزن‌های موجود این مدل‌های از پیش آموزش دیده می‌توانند به عنوان وزن اولیه مدل در کاربردهای دیگر استفاده شوند و با استفاده از انتقال یادگیری بهبود یافته و برای طبقه‌بندی جدید مورد استفاده قرار گیرند [۳۲]. در این مقاله، دو مدل معروف CNN برای تشخیص محصولات کشاورزی از علف‌های هرز و همچنین نوع علف هرز مورد استفاده قرار خواهند گرفت که عبارتند از VGG-16 و Inception-v3 (شکل ۷) [۳۳ و ۳۴]. دلیل اصلی استفاده از این دو مدل عملکرد قابل توجه آنها در کارهای پیشین بوده است تا به عنوان شبکه‌هایی مناسب بتوان در مقایسه با آنها به ارزیابی عملکرد HCNN پرداخت.



شکل ۷- معماری Inception-V3 [۱۳]

ویژگی، کاهش محاسبات و ایجاد پایداری نسبت به تصویر ورودی اعمال می‌شود [۲۹]. در ادامه دو لایه فوقانی به رویه کانولوشن اضافه می‌شوند که در شکل (۵-ب) نشان داده شده است. در این مرحله نقشه ویژگی به یک بردار تبدیل شده و وارد یک لایه fully connected یا کاملاً متصل می‌شود و در نهایت خروجی در یک لایه soft-max برای نشان دادن نتیجه یا همان کلاس طبقه‌بندی ایجاد می‌شود. در این مدل یک لایه dropout بین لایه‌های کاملاً متصل قرار داده می‌شود تا به کنترل overfitting یا بیش از اندازه آموزش دیدن بپردازد و همچنین باعث افزایش عمومیت شود.

لازم به ذکر است که ساختار پیشنهادی برای طبقه‌بندی علف‌های هرز به ۹ کلاس نیز آماده می‌شود. در این کاربرد به دلیل کم بودن نسبی تعداد تصاویر علف‌های هرز در مجموعه آموزشی، تعداد لایه‌های کانولوشن و به تبع آن لایه‌های Max-pooling (برداشت حداکثر مقدار) از نه لایه به پنج لایه کاهش یافته است تا از بیش برآزش جلوگیری کرد. به عبارت دیگر، لایه‌های L6 تا L9 حذف خواهند شد. در نهایت لایه خروجی softmax به گونه‌ای تغییر خواهد کرد که حالات طبقه‌بندی به تعداد ۹ کلاس انواع علف‌های هرز باشد.

#### الگوریتم ۱- شبه کد روش پیشنهادی

```

Input: crop-weed image dataset (images)
Output: Weed types (final_weed_type_labels)

1: Plant Localization: def plant_localization(images) using
Tiny-YOLOV3:
    plant_bboxes = tiny_yolov3.detect(images)
    return plant_bboxes
2: Crop-Weed Classification: def crop_weed_classification
(plant_bboxes) using pre-trained model:
    crop_weed_labels =
crop_weed_model.predict(plant_bboxes)
    return crop_weed_labels
3: Weed Type Classification: def weed_type_classification
(weed_bboxes) using CNN models and Combining
predictions from the models:
    weed_type_labels = []
    for model in [en_inception_v3, en_vgg16, hcnn]:
        weed_type_labels.append(model.predict(weed_bboxes))
    final_weed_type_labels = ensemble(weed_type_labels)
    Return final_weed_type_labels

```

#### ۴-۲- استفاده مجدد از مدل‌های از پیش آموزش دیده

مدل‌های مبتنی بر یادگیری عمیق برای آموزش صحیح نیاز به داده‌های زیادی دارند و جمع‌آوری و برچسب‌گذاری این حجم از داده‌ها سخت است. بعنوان مثال ImageNet به عنوان یک مجموعه داده بزرگ شامل تصاویری از حوزه‌های مختلف است که برای آموزش چندین مدل مانند VGG-

Inception-V3 شامل هفت بلوک Inception است که از نظر شامل بودن پیچش‌ها، pooling میانگین، pooling حداکثر، concatenated، لایه‌های dropout و لایه‌های کاملاً متصل انواع مختلفی دارد [۳۸ و ۳۹]. Inception-V3 شامل ۲۲ لایه مختلف در این بلوک‌ها است و در انتهای هر ماژول Inception از pooling میانگین سراسری استفاده می‌کند (مانند شکل ۷). Inception-V3 تصاویر با ابعاد  $299 \times 299$  را به عنوان ورودی دریافت می‌کند. این مدل از یک طبقه‌بند فرعی در لایه‌ها استفاده می‌کند تا با جلوگیری از افزایش پارامترها، قابلیت تمایز در لایه‌های پایین را به عنوان یک تنظیم کننده یا regularizer افزایش دهد. با وجود اینکه Inception-V3 دارای پارامترهای کمتری است، ویژگی‌های عمیق‌تری از داده‌ها استخراج کرده و یاد می‌گیرد [۴۰].

Inception-V3 دارای ۱۰۰۰ کانال خروجی است که به دلیل نیاز به انجام دسته‌بندی دودویی در تشخیص گیاه سیب‌زمینی-علف هرز و طبقه‌بندی کردن علف‌های هرز به ۹ گونه، سه لایه آخر آن با سه لایه سبک<sup>۹</sup> جدید در دو مدل مجزا جایگزین می‌شوند. دو لایه اول لایه‌هایی کاملاً متصل با ۱۰۰ و ۵۰ واحد پنهان هستند و لایه دیگر لایه dropout با نرخ ۰.۲ است. در نهایت ساختار شبکه‌های تغییر یافته با استفاده از تکنیک انتقال یادگیری مجدداً آموزش خواهند دید.

به منظور ارزیابی پیچیدگی روش ارائه شده در این مقاله که شامل استفاده از شبکه‌های CNN است باید به این نکته اشاره کرد که پیچیدگی محاسباتی مدل‌های یادگیری عمیق مانند HCNN، VGG-16 و غیره به دلیل معماری عمیق و لایه‌های متعددی دارند، می‌تواند بسیار بالا باشد. به طور کلی، یک شبکه عمیق با داشتن  $n$  ورودی،  $h$  لایه و  $m$  خروجی پیچیدگی معادل  $O((n+m)*h)$  دارد. حال با توجه به اینکه پارامتر  $h$  در شبکه HCNN مقدار بسیار کمتری نسبت به سایر شبکه‌ها دارد، پیچیدگی به طور کلی در این شبکه پایین‌تر است. البته زمانی نیز که از خروجی هر سه شبکه برای نتیجه‌گیری نهایی استفاده می‌شود، پیچیدگی نهایی به دلیل قابلیت اجرای موازی این شبکه‌ها برابر با  $O((n+m)*h)$  است. الگوریتم ۱ نیز به نمایش رویه روش در تشخیص گیاه سیب‌زمینی-علف‌هرز و نوع علف‌هرز پرداخته است.

معماری شبکه عصبی عمیق VGG-16 به طور متداول در کاربردهای مختلف مورد استفاده قرار می‌گیرد. ورودی VGG-16 یک تصویر RGB با ابعاد  $224 \times 224$  است که تصویر پس از ورود به شبکه از چندین لایه پیوسته پیچشی<sup>۸</sup> عبور می‌کند. این مدل از ۱۳ لایه پیچشی و فیلترهای  $3 \times 3$  با اندازه گام یک در لایه‌های پیچشی استفاده می‌کند و از  $2 \times 2$  Padding در لایه‌های Pooling با گام دو بهره می‌برد. هر لایه Pooling اندازه نقشه ویژگی را کاهش می‌دهد و آخرین نقشه ویژگی قبل از لایه‌های کاملاً متصل  $7 \times 7$  با ۵۱۲ کانال هستند که باعث تولید یک بردار با  $25088$  ( $512 \times 7 \times 7$ ) عنصر می‌شوند. سه لایه آخر شبکه شامل سه لایه کاملاً متصل است که دو لایه اول دارای  $4096$  کانال و لایه سوم دارای  $1000$  کانال است. معماری کلی VGG-16 در شکل (۶) نشان داده شده است.

در این پژوهش سه لایه بالاتر با لایه‌های جدید تعویض می‌شوند. دو لایه کاملاً متصل اول شامل ۱۰۰ واحد پنهان با نرخ ۰.۵ و ۰.۳ هستند که به دنبال آنها لایه‌های حذفی قرار می‌گیرند. لایه سوم مربوط به دو کلاس خروجی محصولات کشاورزی و علف‌های هرز است. این لایه همچنین برای دسته‌بندی علف‌های هرز به نه کلاس نیز تغییر داده می‌شود. برای وظیفه دسته‌بندی علف‌های هرز لایه آخر این مدل باید ۹ کلاس خروجی متناظر با ۹ نوع علف هرز را شامل شود. این دو شبکه اصلاح شده VGG-16 برای دسته‌بندی محصولات کشاورزی و تشخیص نوع علف هرز به طور جداگانه با تکنیک انتقال یادگیری به کمک مجموعه داده جمع‌آوری شده بهبود یافته‌اند. در ادامه این مقاله از این مدل با نام EN-VGG-16 یاد خواهد شد.

Inception-V3 یا GoogLeNet به عنوان یک شبکه عصبی عمیق توسط پژوهشگران گوگل معرفی شده که در چالش دسته‌بندی و تشخیص تصاویر ILSVRC-2014 عملکرد قابل توجهی داشته است. این معماری یک مدل بهبود یافته است که نیاز به استفاده از منابع کمتری دارد. این مدل با افزایش عمق و عرض شبکه، دسته‌بندی تصاویر را به شکل بهبود یافته‌ای انجام می‌دهد [۳۵]. مدل GoogLeNet سه نسخه به نام‌های Inception-V1، Inception-V2 و Inception-V3 دارد که شبکه Inception-V3 عملکرد بهتری داشته و در این پژوهش مورد استفاده قرار خواهد گرفت [۳۶ و ۳۷].

<sup>۹</sup> light

<sup>۸</sup> Convolutional

## ۵- نتایج آزمایشات

مجموعه داده‌ای که در این پژوهش استفاده شده، از خرداد تا مرداد ۱۳۹۹ جمع‌آوری شده است. برای ارزیابی این روش، عملکرد آن در طبقه‌بندی گیاهان به دو دسته گیاه سیب‌زمینی- علف هرز و طبقه‌بندی علف‌های هرز بررسی شده و نتایج در این بخش توضیح داده می‌شود. برای انجام این آزمایش‌ها مجموعه داده‌ای از ۸۰۰۰ تصویر برای طبقه‌بندی گیاه سیب‌زمینی- علف‌هرز در نظر گرفته شده و همچنین یک زیرمجموعه ۳۵۱۳ تصویری برای تشخیص نوع علف هرز لحاظ شده است. در آزمایش‌های این پژوهش سه طبقه‌بند معرفی شده به صورت مستقل برای طبقه‌بندی گیاهان به گیاه سیب‌زمینی- علف‌هرز و تشخیص نوع علف‌هرز استفاده شده‌اند. باید توجه داشت که مکان گیاهان نیز با استفاده از مدل Tiny-YOLO-V3 تعیین می‌گردد. به طور کلی در هر آزمایش ۸۰ درصد از مجموعه داده‌ها به عنوان داده آموزشی استفاده می‌شود و ۲۰ درصد باقیمانده برای آزمون مورد استفاده قرار می‌گیرد. ارزیابی روش در دو مرحله آموزش و آزمون انجام می‌شود و عملکرد روش پیشنهادی با استفاده از معیارهای دقت (Accuracy)، صحت (Precision)، بازیابی (Recall)، امتیاز F1 (F1-Score) و میانگین دقت متوسط (mAP) ارزیابی می‌شود. این روش با استفاده از پایتون ۳.۶ و کتابخانه Keras با TensorFlow پیاده‌سازی شده است. آزمایش‌ها نیز بر روی یک سیستم با پردازنده Intel Core i7-7500 با سرعت ۳.۴۰ گیگاهرتز، ۸ گیگابایت حافظه و حافظه جانبی ۵۰۰ گیگابایتی در سیستم عامل Ubuntu 18.04.1 LTS اجرا شده‌اند. در اینجا ابتدا عملکرد روش در تعیین مکان گیاه مورد بررسی قرار می‌گیرد. بدین منظور از مدل Tiny-YOLOV3 که با استفاده از ۴۰۰ تصویر از مجموعه داده در ۵۰۰۰ تکرار آموزش دیده استفاده می‌شود. در این پژوهش نیز همانند مطالعات پیشین آستانه IOU برابر با ۰.۵ در نظر گرفته شده است [۴۱]. شکل ۸ نمونه‌هایی از نتایج مکان‌یابی را نشان می‌دهد که تصویر تعیین شده از گیاه پس از اصلاح ابعاد به اندازه مورد نیاز ورودی مدل تعیین گیاه سیب‌زمینی- علف هرز به آن تحویل می‌گردد. از این شکل مشخص است که روش قادر است به خوبی گیاهان را مکان‌یابی نماید. بعد از یافتن موقعیت گیاهان، باید طبقه‌بندی گیاه سیب‌زمینی- علف هرز انجام شود که برای ارزیابی مدل‌های پیشنهادی دو سناریوی آزمون در نظر گرفته شده

است. در سناریوی اول تمام تصاویر آزمون برای ارزیابی مورد استفاده قرار می‌گیرند. در سناریو دیگر نیز تصاویری با شرایط مشابه (فاصله دوربین از زمین و زمان گرفتن عکس) برای ارزیابی استفاده می‌شوند. جدول ۱ عملکرد مدل‌های EN-Inception-V3، EN-VGG-16 و HCNN را در تعیین گیاه سیب‌زمینی- علف هرز نشان می‌دهد و عملکرد آنها را با هم مقایسه می‌نماید. از آنجا که این مدل‌ها از ساختار عمیق استفاده می‌کنند عملکرد کلی طبقه‌بندها به اندازه کافی مناسب است و می‌توان با اطمینان از آنها برای کاربردهای واقعی استفاده کرد. در این میان مدل HCNN که هم معماری ساده‌تری دارد و می‌تواند در زمان کمتری به نتیجه نهایی دست یابد عملکردی بین دو مدل EN-Inception-V3 و EN-VGG-16 داشته است و عملکرد آن حدود ۱.۲ درصد بهتر از EN-VGG-16 و حدود ۱.۲ درصد بدتر از EN-Inception-V3 می‌باشد.

جدول ۱- عملکرد مدل‌های معرفی شده در مراحل آموزش و

طبقه بند		درصد			میانگین دقت
		Precision	Recall	F1-score	
EN-Inception-V3	گیاه	99	98	99	99.42
	علف	99	100	99	
EN-VGG-16	گیاه	95	98	96	97.02
	علف	99	96	97	
HCNN	گیاه	98	98	98	98.22
	علف	98	99	99	

در بررسی بعدی تصاویر بر اساس شرایط گرفتن عکس گروه‌بندی شده و عملکرد طبقه‌بندها به ازای هر کدام از گروه‌ها ارزیابی می‌شوند. تصاویر در بازه‌های زمانی مختلف (بازه‌های یک تا چهار) و با ارتفاع‌های مختلف از زمین (۲۰، ۴۰، ۶۰، ۸۰ و ۱۰۰ سانتی‌متر) گرفته شده‌اند که در کل ۲۰ زیرمجموعه از تصاویر بعنوان گروه‌های مختلف ارزیابی حاصل می‌شود. جداول ۲، ۳، ۴، ۵ و ۶ مربوط به بررسی عملکرد روش روی گروه‌های مختلف از تصاویر است. این جداول نشان می‌دهند که EN-Inception-V3 عملکرد بهتری نسبت به سایر طبقه‌بندها دارد. اما HCNN نتایجی قابل مقایسه با EN-Inception-V3 دارد که با در نظر گرفتن پیچیدگی محاسباتی کم این روش می‌توان در نهایت آن را بعنوان بهترین روش قابل استفاده انتخاب نمود. بطور کلی مدل‌ها بر روی تصاویری که در میانه روز و با ارتفاع کم

گرفته شده‌اند عملکرد ضعیف‌تری دارند که دلیل آن سایه گیاهان است که در ارتفاع کم عکس‌برداری می‌تواند شکل گیاه را تحت تاثیر قرار دهد. همچنین در عکس‌برداری در ارتفاع کم ساختار گیاه به صورت مناسب ثبت نمی‌گردد.

جدول ۲- طبقه بندی محصول-علف هرز برای تصاویر ثبت شده در ارتفاع ۲۰ سانتی متری

زمان	روش	نتیجه				
		precision	recall	f1-score	Accuracy	
8:11	EN-Inception-V3	گیاه	0.98	1.00	0.99	۰.۹۹۲۰
		علف	1.00	0.98	0.99	
	EN-VGG-16	گیاه	0.82	1.00	0.90	۰.۹۲۸۰
		علف	1.00	0.89	0.94	
	HCNN	گیاه	0.89	1.00	0.94	۰.۹۶
		علف	1.00	0.94	0.97	
11:14	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.91	0.89	0.90	۰.۹۰۷۸
		علف	0.90	0.93	0.90	
	HCNN	گیاه	0.97	0.97	0.97	۰.۹۷
		علف	0.97	0.97	0.97	
15:18	EN-Inception-V3	گیاه	0.95	1.00	0.98	۰.۹۸۴۶
		علف	1.00	0.98	0.99	
	EN-VGG-16	گیاه	0.95	1.00	0.98	۰.۹۸۴۶
		علف	1.00	0.98	0.99	
	HCNN	گیاه	0.90	0.95	0.93	۰.۹۵۳۸
		علف	0.98	0.96	0.97	
18:20	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.84	1.00	0.91	۰.۹۴
		علف	1.00	0.91	0.95	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	

توجهی برای HCNN کمتر است. HCNN تعادل مناسبی بین منابع مورد نیاز و نتایج خروجی در این برنامه را دارد تا برای کاربردهای واقعی به کار برده شود. از آنجا که هر طبقه‌بند عملکرد بهتری در شرایطی خاص دارد، ترکیب آن‌ها می‌تواند در دستیابی به بهترین عملکرد کلی مفید واقع شود.

نتایج نشان می‌دهند که مدل‌ها عملکرد خوبی دارند و نتایج آن‌ها قابل قبول است. در هر صورت می‌توان از این جداول استنباط کرد که EN-Inception-V3 نتایج نسبتاً بهتری نسبت به سایر مدل‌ها دارد. طبقه‌بند HCNN عملکرد قابل مقایسه‌ای با EN-Inception-V3 روی گروه‌های مورد اشاره از تصاویر دارد در حالی که تعداد پارامترهای مورد استفاده و متعاقباً نیاز به منابع در طول اجرا به صورت قابل

جدول ۳- طبقه بندی محصول-علف هرز برای تصاویر ثبت شده در ارتفاع ۴۰ سانتی متری


زمان	روش	نتیجه				
		precision	recall	f1-score	Accuracy	
8:11	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
11:14	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.91	0.97	0.94	۰.۹۴۵۹
		علف	0.98	0.93	0.95	
	HCNN	گیاه	0.91	0.97	0.94	۰.۹۷۲۹
		علف	0.98	0.93	0.95	
15:18	EN-Inception-V3	گیاه	0.97	1.00	0.98	۰.۹۸۷۵
		علف	1.00	0.98	0.99	
	EN-VGG-16	گیاه	0.97	1.00	0.98	۰.۹۸۷۵
		علف	1.00	0.98	0.99	
	HCNN	گیاه	1.00	0.93	0.97	۰.۹۵۳۸
		علف	0.96	1.00	0.98	
18:20	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.88	1.00	0.94	۰.۹۵۹۱
		علف	1.00	0.94	0.97	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	

گیاه سیب‌زمینی-علف هرز تا ۹۹.۶۸ درصد به عنوان یک نتیجه بسیار قابل توجه می‌شود. البته باید به این نکته نیز اشاره نمود که با توجه به اختلاف زمان پردازش هر یک از این مدل‌ها، ترکیب این سه مدل برای کاربردهای واقعی عملاً مقدور نیست و صرفاً برای کارهای آفلاین چنین ترکیبی می‌تواند مد نظر قرار گیرد.

در ادامه، مدل‌های معرفی شده (با تغییرات مورد اشاره برای تشخیص نوع علف هرز) به تعیین نوع علف هرز در هر تصویری که به عنوان تصویر علف هرز طبقه بندی می‌شود، می‌پردازند. در اینجا هر تصویر از علف هرز به یکی از ۹ نوع علف هرز باید نسبت داده شود. جدول ۸ به مقایسه مدل‌ها در این راستا پرداخته که EN-Inception-V3 به نتایج بهتری نسبت به HCNN و EN-VGG-16 دست یافته است. دقت کلی EN-VGG-16، EN-Inception-V3 و HCNN در تشخیص ۹ نوع علف هرز به ترتیب ۰.۹۶۶۹، ۰.۳۲ و ۰.۸۲۶۷ است. لازم به ذکر است که ترکیب

تصویر اصلی

تصویر گیاه و نتیجه طبقه‌بندی



شکل ۸- نتیجه مکان‌یابی گیاهان

همانطور که در جدول ۷ نشان داده شده است، ترکیب خروجی طبقه‌بندیها باعث افزایش دقت نهایی در طبقه‌بندی

شبکه های معرفی شده در این مقاله برای تشخیص نوع علف هرز باعث بهبود عملکرد تا ۹۸.۲۲ درصد شده است.

جدول ۴- طبقه بندی محصول-علف هرز برای تصاویر ثبت شده در ارتفاع ۶۰ سانتی متری

زمان	روش		نتیجه			
			precision	recall	f1-score	Accuracy
8:11	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.96	1.00	0.98	۰.۹۸۵۱
		علف	1.00	0.98	0.99	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
11:14	EN-Inception-V3	گیاه	0.97	1.00	0.98	۰.۹۸۶۶
		علف	1.00	0.98	0.99	
	EN-VGG-16	گیاه	0.94	0.97	0.95	۰.۹۶
		علف	0.98	0.95	0.97	
	HCNN	گیاه	0.94	1.00	0.97	۰.۹۷۳۳
		علف	1.00	0.95	0.98	
15:18	EN-Inception-V3	گیاه	0.97	1.00	0.98	۰.۹۸۷۵
		علف	1.00	0.98	0.99	
	EN-VGG-16	گیاه	0.94	1.00	0.97	۰.۹۷۵
		علف	1.00	0.96	0.98	
	HCNN	گیاه	0.94	0.97	0.95	۰.۹۶۲۵
		علف	0.98	0.97	0.96	
18:20	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.96	1.00	0.98	۰.۹۸۳۳
		علف	1.00	0.97	0.99	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	

جدول ۵- طبقه بندی محصول-علف هرز برای تصاویر ثبت شده در ارتفاع ۸۰ سانتی متری

زمان	روش		نتیجه			
			precision	recall	f1-score	Accuracy
8:11	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	HCNN	گیاه	0.98	1.00	0.99	۰.۹۹۲۵
		علف	1.00	0.99	0.99	
11:14	EN-Inception-V3	گیاه	0.97	0.97	0.97	۰.۹۷۵۰
		علف	0.97	0.97	0.97	
	EN-VGG-16	گیاه	0.97	0.95	0.96	۰.۹۶۲۵
		علف	0.95	0.97	0.96	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
15:18	EN-Inception-V3	گیاه	0.97	1.00	0.99	۰.۹۸۹۰
		علف	1.00	0.98	0.99	
	EN-VGG-16	گیاه	0.95	1.00	0.97	۰.۹۷۸۰
		علف	1.00	0.96	0.98	

	HCNN	گیاه	0.97	1.00	0.99	۰.۹۸۸۰
		علف	1.00	0.98	0.99	
	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
18:20	EN-VGG-16	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	

جدول ۶- طبقه بندی محصول-علف هرز برای تصاویر ثبت شده در ارتفاع ۱۰۰ سانتی متری

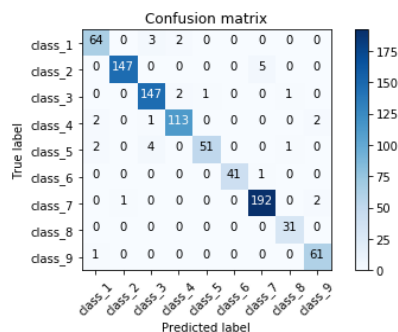
زمان	روش	نتیجه				
		precision	recall	f1-score	Accuracy	
8:11	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.97	1.00	0.98	۰.9857
		علف	1.00	0.97	0.99	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
11:14	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	0.95	0.95	0.95	۰.۹۵
		علف	0.95	0.95	0.95	
	HCNN	گیاه	0.95	1.00	0.98	۰.۹۷۵۰
		علف	1.00	0.95	0.97	
15:18	EN-Inception-V3	گیاه	0.97	1.00	0.99	۰.۹۸۸۰
		علف	1.00	0.98	0.99	
	EN-VGG-16	گیاه	0.97	0.97	0.97	۰.۹۷۷۷
		علف	0.98	0.98	0.98	
	HCNN	گیاه	0.98	1.00	0.99	۰.۹۸۸۸
		علف	1.00	0.98	0.99	
18:20	EN-Inception-V3	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	EN-VGG-16	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	
	HCNN	گیاه	1.00	1.00	1.00	1.00
		علف	1.00	1.00	1.00	

جدول ۷- ترکیب طبقه‌بندها برای تشخیص محصول از علف هرز

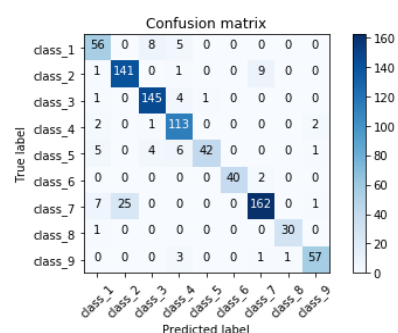
ارتفاع/زمان	20	40	60	80	100	میانگین
8:11	99.20	1.00	1.00	1.00	1.00	99.84
11:14	1.00	1.00	98.66	1.00	1.00	99.73
15:18	98.46	1.00	98.75	98.90	98.88	98.99
18:20	1.00	1.00	1.00	1.00	1.00	1.00
میانگین	99.41	1.00	99.35	99.72	99.72	99.64




آن در تفکیک انواع علف‌های هرز، این مدل را می‌توان بعنوان مدلی کارا نام برد.



EN-Inception-V3



EN-VGG-16



HCNN

شکل ۹. ماتریس در هم ریختگی مدل‌ها برای طبقه‌بندی علف‌های هرز

همچنین در مقایسه با روش‌های دیگر نیز مشخص است که روش پیشنهادی عملکرد مناسب‌تری دارد (جدول ۹). در این جدول مطالعه قدیمی‌تر آقای سبزی به همراه همکارشان [۴۲] نیز آورده شده است که در آن از ترکیب شبکه عصبی و روش جستجوی PSO به صورت ترکیبی استفاده شده است و با توجه به داده‌های ساده مورد استفاده، نتایج مطلوب قلمداد نمی‌شوند (دقت کلی ۹۸.۱ درصد). دلیل برتری روش ما می‌تواند به ساختار مناسب شبکه و

جدول ۸- نتایج طبقه‌بندها برای تشخیص نوع علف هرز

مدل‌ها	دقت آموزش	دقت آزمون	دقت ترکیب
EN-Inception-V3	99.82	96.69	
EN-VGG-16	99.89	90.32	98.2
HCNN	92.83	82.67	

شکل (۹) ماتریس درهم ریختگی مدل‌ها برای تعیین نوع علف هرز را نشان می‌دهد. مشخص است که مدل‌ها از دقت کمتری نسبت به مرحله طبقه‌بندی گیاه سیب‌زمینی-علف هرز برخوردارند که دلیل اصلی آن هم زیاد بودن تعداد کلاس‌ها و هم شباهت میان گیاهان علف‌های هرز است. همچنین تعداد نمونه‌های آموزشی این حالت نسبت به طبقه‌بندی گیاه سیب‌زمینی-علف هرز کمتر است؛ چراکه کل نمونه‌های این کلاس‌های ۹ گانه همگی در یک کلاس علف هرز قرار داشته‌اند. شکل (۱۰) نشان می‌دهد که علف هرز کلاس ۲ تا حدودی شبیه به علف هرز کلاس ۷ است و دو مدل از پیش آموزش دیده آنها را با هم اشتباه در نظر می‌گیرند اما مدل HCNN این اختلاف را به حداقل می‌رساند (مطابق ماتریس در هم ریختگی).

از سوی دیگر، HCNN دارای اشتباهاتی در طبقه‌بندی علف‌های هرز کلاس-۳ و کلاس-۴ به جای کلاس-۱، کلاس-۴ به جای کلاس-۸، و کلاس-۷ به جای کلاس-۹ است و این در حالی است که فقط علف‌های هرز کلاس-۱ و کلاس ۳ به هم شباهت دارند.

از مهمترین دلایل این اتفاق کم بودن تعداد تصاویر در دسترس برای آموزش HCNN که یک مدل بدون آموزش پیشین و خام است (به طور متوسط حدود ۴۰۰ تصویر در هر کلاس وجود دارد) می‌باشد. به عبارت دیگر مدل‌های از پیش آموزش دیده که با Transfer Learning به خوبی تنظیم شده‌اند با تعداد کمی تصویر آموزشی نیز آماده عملکردی مناسب برای کاربردی که تعداد کلاس‌ها آن زیاد باشد خواهند بود.

اما به طور کلی با توجه به عملکرد مناسب مدل HCNN در تفکیک گیاه سیب‌زمینی از علف هرز با پیچیدگی کمتر با توجه به ساختار ساده آن و همچنین عملکرد قابل قبول

## ۶- نتیجه‌گیری

از بین بردن علف‌های هرز با کمترین مصرف منابع یکی از اهداف اصلی در کشاورزی پایدار است. بنابراین در این پژوهش سه مدل مبتنی بر یادگیری عمیق برای توسعه یک سیستم بینایی ماشین معرفی شدند تا با شناسایی علف‌های هرز در مزرعه سیب‌زمینی به سمپاشی موثر و دوستدار محیط کمک نمایند. در این راستا تعداد زیادی تصویر از گیاه سیب‌زمینی و علف‌های هرز در مراحل مختلف رشد، زمان‌های مختلف روز و ارتفاع‌های مختلف در یک مجموعه داده گردآوری شد و برای آموزش سه شبکه عصبی کانولوشنی مورد استفاده قرار گرفتند. دو مورد (EN-Inception-V3 و EN-VGG-16) شبکه‌هایی از پیش آموزش دیده بودند که با انتقال یادگیری برای طبقه‌بندی بندی‌های مورد نظر آماده شدند. یک مدل جدید (HCNN) نیز که شامل ساختاری ساده و قابل اجرا بر روی سیستم‌های برخط به دلیل پیچیدگی مناسب آن معرفی شد تا بتواند در زمان مناسب نتیجه‌ی قابل قبول بدنبال داشته باشد.


مقایسه دو سناریو مختلف از ارزیابی‌ها نشان داد که مدل EN-Inception-V3 عملکرد قابل قبولی در تشخیص گیاه سیب‌زمینی-علف هرز دارد و دقت آن برابر با ۹۹.۴۲٪ بوده است. پر واضح است که این عملکرد نسبت به مدل‌های آموزش دیده در سایر مطالعات که در آن شرایط نوری و ارتفاع تصویربرداری یکسان است بهتر می‌باشد. مقایسه عملکرد مدل‌های EN-Inception-V3، EN-VGG-16 و HCNN در طبقه‌بندی ۹ گونه مختلف علف هرز رایج در مزارع سیب‌زمینی نیز نشان می‌دهد که عملکرد مدل معرفی شده EN-Inception-V3 به طور قابل توجهی بهتر است که دقت آن برابر با ۹۶.۶۹٪ می‌باشد. اما ترکیب این مدل‌ها باعث رسیدن به دقت ۹۸.۲ درصدی در تشخیص نوع علف هرز می‌شود.

به طور کلی نتایج نشان می‌دهد که مدل EN-Inception-V3 به اندازه کافی دقیق است و می‌تواند نتایج قابل قبولی در تشخیص و طبقه‌بندی گونه‌های علف‌هرز در شرایط مختلف را ارائه دهد. اما این مدل نمی‌تواند به دلیل ساختار پیچیده در مدت زمان کم خروجی را حاصل نماید و در سیستم‌های بر خط خیلی کارا نخواهند بود. از سوی دیگر HCNN بعنوان یک مدل دارای ساختار ساده می‌تواند با پیچیدگی کمتری خروجی مورد نظر را با دقت قابل قبول

بهبود آنها در کنار آموزش مناسب بازگردد. لازم به ذکر است که در این مطالعه تصاویر مجموعه داده در ساعات مختلف روز و شرایط محیطی متفاوت جمع‌آوری شده‌اند که پایداری و قابلیت اطمینان را بدنبال دارد. همچنین تصاویر در ارتفاع‌های مختلف از سطح زمین گرفته شده است تا در صورت استفاده در کاربرد واقعی، سیستم با تغییر ارتفاع‌های ناگهانی دچار ناپایداری نشود.

جدول ۹- مقایسه روش پیشنهادی با سایر روش‌ها در تشخیص نوع گیاه

تعداد دسته‌های علف هرز	تعداد کل نمونه‌ها	بهترین نتیجه	روش‌ها
۱۱	۹۳۰۰۰	۰.۹۸۰	Peteinatos [24]
۵	۴۲۹۹	۰.۹۸۳	سبزی و همکاران [۱۲]
۳	۳۳۷۶	۰.۹۸۱	سبزی و عباسپور [۴۲]
۹	۸۰۰۰	۰.۹۸۲	روش پیشنهادی



شکل ۱۰. نمونه تصاویر علف‌های هرز مزارع سیب‌زمینی

بدست آورد. لذا بنا به کاربرد مورد نیاز می‌توان از این مدل‌ها  
تشخیص محصول از علف هرز و تشخیص نوع علف هرز با  
اطمینان بالاتر انجام شود. به صورت مستقل یا ترکیب شده استفاده نمود تا دو کاربرد

## مراجع

- [1] FAO, "FAOSTAT database", June 10, 2022, <https://www.fao.org/faostat/en/#data/QCL/visualize>.
- [2] N. Korres, N. Burgos, and S. Duke. "Weed control: sustainability, hazards, and risks in cropping systems worldwide." *CRC Press*, Dec 19, 2018.
- [3] A. Sharshar, E.H. Hassanein, O. ElSaid Shaltout, M. Yousry, and A. El-Gamal. "Effect of Some Weed Control Treatments on Potato (*Solanum tuberosum*, L) Crop." *Journal of the Advances in Agricultural Researches* 20, no. 2 (2015): 238-253.
- [4] P.J. Herrera, J. Dorado, and Á. Ribeiro. "A novel approach for weed type classification based on shape descriptors and a fuzzy decision-making method." *Sensors* 14, no. 8 (2014): 15304-15324.
- [5] "Weed control in potato. Agriculture, Aquaculture, and Fisheries, Government of New Brunswick", 2021, <https://www2.gnb.ca/content/dam/gnb/Departments/10/pdf/Agriculture/WeedControlPotato.pdf>.
- [6] M.P. Rico-Fernández, R. Rios-Cabrera, M. Castelán, H.I. Guerrero-Reyes, and A. Juarez-Maldonado. "A contextualized approach for segmentation of foliage in different crop species." *Computers and Electronics in Agriculture* 156 (2019): 378-386.
- [7] A. Wang, W. Zhang, and X. Wei. "A review on weed detection using ground-based machine vision and image processing techniques." *Computers and Electronics in Agriculture* 158 (2019): 226-240.
- [8] L. Alzubaidi, J. Zhang, A.J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M.A. Fadhel, M. Al-Amidie, and L. Farhan. "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions." *Journal of Big Data* 8 (2021): 1-74.
- [9] M. Dyrmann, H. Karstoft, and H.S. Midthby. "Plant species classification using deep convolutional neural network." *Biosystems Engineering* 151 (2016): 72-80.
- [10] H. Jiang, C. Zhang, Y. Qiao, Z. Zhang, W. Zhang, and C. Song. "CNN feature based graph convolutional network for weed and crop recognition in smart farming." *Computers and Electronics in Agriculture* 174 (2020): 105450.
- [11] M. Mardani, and M. Salarpour. "Measuring technical efficiency of potato production in Iran using robust data envelopment analysis." *Information Processing in Agriculture* 2, no. 1 (2015): 6-14.
- [12] S. Sabzi, Y. Abbaspour-Gilandeh, and J. Ignacio Arribas. "An automatic visible-range video weed detection, segmentation and classification prototype in potato field." *Heliyon* 6, no. 5 (2020).
- [13] F. Lin, D. Zhang, Y. Huang, X. Wang, and X. Chen. "Detection of corn and weed species by the combination of spectral, shape and textural features." *Sustainability* 9, no. 8 (2017): 1335.
- [14] M.A. Molina-Villa, and L.E. Solaque-Guzmán. "Machine vision system for weed detection using image filtering in vegetables crops." *Revista Facultad de Ingeniería Universidad de Antioquia* 80 (2016): 124-130.
- [15] M.R. Golzarian, and R.A. Frick. "Classification of images of wheat, ryegrass and brome grass species at early growth stages using principal component analysis." *Plant Methods* 7 (2011): 1-11.
- [16] A. Bakhshipour, and A. Jafari. "Evaluation of support vector machine and artificial neural networks in weed detection using shape features." *Computers and Electronics in Agriculture* 145 (2018): 153-160.
- [17] H.C. Ngo, U. Raba'ah Hashim, Y.W. Sek, Y. Jaya Kumar, and W. Sing Ke. "Weeds detection in agricultural fields using convolutional neural network." *International Journal of Innovative Technology and Exploring Engineering* 8, no. 11 (2019): 292-296.
- [18] F.J. Knoll, V. Czymmek, S. Poczihoski, T. Holtorf, and S. Hussmann. "Improving efficiency of organic farming by using a deep learning classification approach." *Computers and Electronics in Agriculture* 153 (2018): 347-356.
- [19] T. Sarvini, T. Sneha, S. Gowthami GS, S. Sushmitha, and R. Kumaraswamy. "Performance comparison of weed detection algorithms." *In 2019 International Conference on Communication and Signal Processing (ICCSP)*, pp. 0843-0847. IEEE, 2019.
- [20] G.L. Grinblat, L.C. Uzal, M.G. Larese, and P.M. Granitto. "Deep learning for plant identification using vein morphological patterns." *Computers and Electronics in Agriculture* 127 (2016): 418-424.

- [21] A. dos Santos Ferreira, D. Matte Freitas, G. Gonçalves da Silva, H. Pistori, and M. Theophilo Folhes. "Weed detection in soybean crops using ConvNets." *Computers and Electronics in Agriculture* 143 (2017): 314-324.
- [22] H.K. Suh, J. Ijsselmuiden, J. Willem Hofstee, and E.J. van Henten. "Transfer learning for the classification of sugar beet and volunteer potato under field conditions." *Biosystems Engineering* 174 (2018): 50-65.
- [23] A. Olsen, D.A. Konovalov, B. Philippa, P. Ridd, J.C. Wood, J. Johns, W. Banks et al. "DeepWeeds: A multiclass weed species image dataset for deep learning." *Scientific Reports* 9, no. 1 (2019): 2058.
- [24] G.G. Peteinatos, P. Reichel, J. Karouta, D. Andújar, and R. Gerhards. "Weed identification in maize, sunflower, and potatoes with the aid of convolutional neural networks." *Remote Sensing* 12, no. 24 (2020): 4185.
- [25] J. Gao, A.P. French, M.P. Pound, Y. He, T.P. Pridmore, and J.G. Pieters. "Deep convolutional neural networks for image-based *Convolvulus sepium* detection in sugar beet fields." *Plant Methods* 16 (2020): 1-12.
- [26] C. Shorten, and T.M. Khoshgoftaar. "A survey on image data augmentation for deep learning." *Journal of Big Data* 6, no. 1 (2019): 1-48.
- [27] X. Ying. "An overview of overfitting and its solutions." In *Journal of Physics: Conference Series*, vol. 1168, p. 022022. IOP Publishing, 2019.
- [28] A.A. Binguitcha-Fare, and P. Sharma. "Crops and weeds classification using convolutional neural networks via optimization of transfer learning parameters." *Int J Eng Adv Technol (IJEAT)* 8, no. 5 (2019): 2249-8958.
- [29] Z. Gao, L. Wang, L. Zhou, and J. Zhang. "HEp-2 cell image classification with deep convolutional neural networks." *IEEE Journal Of Biomedical And Health Informatics* 21, no. 2 (2016): 416-428.
- [30] S. Kornblith, J. Shlens, and Q.V. Le. "Do better imagenet models transfer better?." In *Proceedings Of The IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 2661-2671. 2019.
- [31] M.S. Islam, F.A. Foyzal, N. Neehal, E. Karim, and S.A. Hossain. "InceptB: a CNN based classification approach for recognizing traditional bengali games." *Procedia Computer Science* 143 (2018): 595-602.
- [32] M. Shu. "Deep learning for image classification on very small datasets using transfer learning." (2019).
- [33] M. Yani, S.S.M. Budhi Irawan, and S.M. Casi Setiningsih. "Application of transfer learning using convolutional neural network method for early detection of terry's nail." In *Journal of Physics: Conference Series*, vol. 1201, no. 1, p. 012052. IOP Publishing, 2019.
- [34] Z. Jiang. "A novel crop weed recognition method based on transfer learning from VGG16 implemented by Keras." In *IOP Conference Series: Materials Science and Engineering*, vol. 677, no. 3, p. 032073. IOP Publishing, 2019.
- [35] A. Garcia-Perez, F. Gheriss, and D. Bedford. "Measurement, reliability, and validity." In *Designing and Tracking Knowledge Management Metrics*, pp. 163-182. Emerald Publishing Limited, 2019.
- [36] A. Kapoor, R. Shah, R. Bhuvra, and T. Pandit. Understanding inception network architecture For image classification. 2020.
- [37] W. Fang, L. Wang, and P. Ren. "Tinier-YOLO: A real-time object detection method for constrained environments." *Ieee Access* 8 (2019): 1935-1944.
- [38] I. Kandel, and M. Castelli. "Transfer learning with convolutional neural networks for diabetic retinopathy image classification. A review." *Applied Sciences* 10, no. 6 (2020): 2021.
- [39] V. Maeda-Gutiérrez, C.E. Galvan-Tejada, L.A. Zanella-Calzada, J.M. Celaya-Padilla, J.I. Galván-Tejada, H. Gamboa-Rosales, H. Luna-Garcia, R. Magallanes-Quintanar, C.A. Guerrero Mendez, and C.A. Olvera-Olvera. "Comparison of convolutional neural network architectures for classification of tomato plant diseases." *Applied Sciences* 10, no. 4 (2020): 1245.
- [40] K. Avery, J. Pan, C. Carvalho Engler-Pinto, Z. Wei, F. Yang, S. Lin, L. Luo, and D. Konson. "Fatigue behavior of stainless steel sheet specimens at extremely high temperatures." *SAE International Journal of Materials and Manufacturing* 7, no. 3 (2014): 560-566.
- [41] M. Buzzy, V. Thesma, M. Davoodi, and J. Mohammadpour Velni. "Real-time plant leaf counting using deep object detection networks." *Sensors* 20, no. 23 (2020): 6896.
- [42] S. Sabzi, and Y. Abbaspour-Gilandeh. "Using video processing to classify potato plant and three types of weed using hybrid of artificial neural network and particle swarm algorithm." *Measurement* 126 (2018): 22-36.