



Detection of *Chilo Suppressalis* using Smartphone Images and Deep Learning

M. Fallah¹, E. Ghanbari Parmehr^{1,2*}

1- BSc Student, Department of Geomatics, Babol Noshirvani University of Technology, Babol, Iran

2- Assistant Professor, Department of Geomatics, Babol Noshirvani University of Technology, Babol, Iran

(*- Corresponding Author Email: parmehr@nit.ac.ir)

<https://doi.org/10.22067/jam.2022.72647.1064>

Received: 21 September 2021

Revised: 19 January 2022

Accepted: 31 January 2022

Available Online: 31 January 2022

How to cite this article:

Fallah, M., & Ghanbari Parmehr, E. (2023). Detection of *Chilo Suppressalis* using Smartphone Images and Deep Learning. *Journal of Agricultural Machinery*, 13(2), 195-211. (in Persian with English abstract). <https://doi.org/10.22067/jam.2022.72647.1064>

Introduction

Rice is one of the most important main food sources in Iran and the world. The correct identification of the type of pest in the early stages of preventive action has a significant role in reducing the damage to the crop. Traditional methods are not only time-consuming but also provide inaccurate results. As a result, precision agriculture and its associated technology systems have emerged. Precision agriculture utilizes information technology such as GPS, GIS, remote sensing, and machine learning to implement agricultural inter-farm technical measures to achieve better marginal benefits for the economy and environment. Machine learning is a division of artificial intelligence that can automatically progress based on experience gained. Deep learning is a subfield of machine learning that models the concepts of using deep neural networks with several high-level abstract layers. This capability has led to careful consideration in agricultural management. The diagnosis of disease and predicting the time of destruction, with a focus on artificial intelligence, has been the subject of much research in precision agriculture. This article presents, in the first step, a trained model of the *Chilo suppressalis* pest using data received from the smartphone, validated with the opinion of experts. In the second step, we introduce the developed system based on the smartphone. By using this system, farmers can share their pest images through the Internet and learn about the type of pest on their farm, and finally, take the necessary measures to combat it. This operation is done quickly and efficiently using the developed artificial intelligence. In the continuation of the article, the second part introduces the materials and methods, and the third part presents the results. The fourth section also discusses and concludes the research.

Materials and Methods

Chilo suppressalis is one of the most important pests of rice in temperate and subtropical regions of Asia. The conventional approach employed by villagers to gather the *Chilo suppressalis* pest entails setting up a light source above a pan filled with water infused with a pesticide. At sunset, these insects are attracted to the light and fall into the water in the pan. This method is known as optical trapping. After catching the pest using optical traps, they are collected from the water surface, and their photo is taken with a mobile phone based on the location of the optical trap.

The proposed method in this research consists of three main steps. Firstly, the farmer utilizes the software provided by the extended version known as Smart Farm. The farmer captures an image of the *Chilo suppressalis* pest and sends it along with its location to the system. The Smart Farm software program carries out image processing and pest range detection operations. The user then verifies the accuracy of the pest detection. In the second step, the images sent by the farmer are processed by the pre-trained model within the system. The model analyzes the images and determines the presence of the pest. Finally, after identifying the type of pest, the results, along with recommended methods for pest control, are sent back to the farmer.

In summary, in this method, farmers employ the Smart Farm software to capture and transmit images of the *Chilo suppressalis* pest. The captured images then undergo image processing and pest range detection as the next steps in the process. The results, including pest identification and control methods, are then returned to the farmer.

Results and Discussion

The model has been designed with 400 artificial neural network processing units (APCs), achieving accuracy percentages of 88% and 92%. To conduct a more detailed study of the proposed model, the statistical criteria of recall and F-score were used. Based on the calculations, the trained model demonstrated a recall score of 91%. This criterion shows that the model was able to identify a large percentage of what was expected to be identified by the model. Additionally, the F-score, with an acceptable percentage of 88%, confirmed the accuracy of the trained model.

Conclusion

Researchers have always been highly interested in the valuable data freely provided by farmers for their studies and analyses. In this study, an intelligent system was designed for identifying types of pests such as worms and stalk eaters, which can automatically determine the pest type from the image sent by the farmer using artificial intelligence and deep learning. By utilizing the developed system, farmers can be informed of the type of pest present on their farm in the shortest possible time, with minimal required software training.

Keywords: Automatic pest detection, Intelligent agriculture, Machine learning, Smartphone

مقاله پژوهشی

جلد ۱۳، شماره ۲، تابستان ۱۴۰۲، ص ۲۱۱-۱۹۵

تشخیص کرم ساقه‌خوار برنج (*Chilo suppressalis*) با کمک تصاویر تلفن هوشمند و یادگیری

عمیق

محمد فلاح^۱، عبادت قنبری پرمهر^{۲*}

تاریخ دریافت: ۱۴۰۰/۰۶/۳۰

تاریخ پذیرش: ۱۴۰۰/۰۱/۱۱

چکیده

در بین محصولات کشاورزی، برنج یکی از اصلی‌ترین منابع غذایی در کشورهای خاورمیانه، به‌ویژه ایران است. مقابله موثر و به‌هنگام با آفات مزارع برنج، یکی از بزرگ‌ترین چالش‌های پیش رو در زمینه زراعت این محصول است. کرم ساقه‌خوار برنج (*Chilo suppressalis*) از آفات کلیدی گیاه برنج در شمال ایران می‌باشد. در حال حاضر، تشخیص نوع آفت‌هایی که به مزارع برنج هجوم می‌برند به نیروی انسانی و تجربه کافی متکی است. تشخیص آفت در مراحل اولیه به‌منظور به حداقل رساندن خسارت به‌عنوان اقدام پیشگیرانه ضروری است. توسعه هوش مصنوعی و الگوریتم‌های یادگیری ماشین، دریچه جدیدی را در صنایع مختلف از جمله کشاورزی صنعتی ایجاد کرده است. با استفاده از یادگیری ماشین می‌توان تا حدود زیادی از خطاهای موجود در شناسایی آفت جلوگیری کرد. از طرف دیگر در سال‌های اخیر همگانی شدن استفاده از تلفن همراه هوشمند و توسعه شیوه دریافت اطلاعات داوطلبانه، امکان پایش خودکار به‌منظور کاهش نیروی انسانی برای کشاورزان فراهم شده است. هدف از این تحقیق، شناسایی خودکار کرم ساقه‌خوار برنج با استفاده از تصاویر تلفن همراه و معرفی و توسعه یک برنامه کاربردی برای کشاورز جهت شناسایی دقیق آفت است. از برنامه کاربردی توسعه‌داده شده برای کشاورز به‌منظور دریافت تصاویر کرم ساقه‌خوار برنج برای آموزش شبکه عصبی عمیق استفاده شد. سپس، با استفاده از تکنیک‌های یادگیری عمیق به آموزش مدل پرداخته شد. نتایج حاصل نشان داد که مدل آموزش‌دیده با استفاده از تصاویر تلفن هوشمند با دقت ۹۲ درصد و صحت ۸۸ درصد عملکرد مناسبی در تشخیص آفت کرم ساقه‌خوار دارد.

واژه‌های کلیدی: تشخیص خودکار آفات، تلفن همراه هوشمند، کشاورزی هوشمند، یادگیری ماشین

مقدمه

طرفی قسمت اعظم کنترل این آفت به‌وسیله آفت‌کش‌های شیمیایی (حشره‌کش‌های گرانول) صورت می‌گیرد. بنابراین شناسایی صحیح نوع آفت در مراحل اولیه برای اقدام پیشگیرانه نقش به‌سزایی در کاهش میزان خسارت وارده به محصول دارد. کرم ساقه‌خوار برنج^۳ یکی از مهم‌ترین آفات برنج در مناطق معتدل و نیمه‌استوایی آسیا است (Dale, 1994). این آفت از راسته *Lepidoptere* و خانواده *Pyralidae* اولین بار در دنیا در سال ۱۸۶۳ توسط واکر^۴ شناسایی و نام‌گذاری شد. لارو این آفت بر روی گیاه برنج در مرحله رشد منجر به زردی و خشکی گیاه می‌شود که به خسارت نسل اول^۵ معروف است. در این مرحله با رشد ساقه‌های جانبی، گیاه در مقابل آفت عکس‌العمل نشان داده و با ایجاد ساقه‌های جدید از خسارت آفت تا حدی جلوگیری می‌کند. اما در مرحله خوشه‌دهی، تغذیه لارو منجر به

برنج یکی از مهم‌ترین و اصلی‌ترین منابع غذایی در ایران و جهان به‌شمار می‌رود. با توجه به این که کمیت و کیفیت برنج بر اثر آفات مختلف کاهش می‌یابد، بنابر گزارش‌های جهاد کشاورزی در سال گذشته دو میلیون و ۶۰۰ هزار تن برنج در سطح زیرکشت ۸۰۰ هزار هکتار تولید شد که این میزان از برنج تولیدی ۸۵ درصد نیاز کشور را تأمین می‌کند. کرم ساقه‌خوار برنج از آفات مهم مزارع برنج محسوب می‌شود، سالانه خسارت زیادی به محصول برنج وارد می‌سازد، از

۱- دانشجوی کارشناسی، گروه مهندسی نقشه‌برداری، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

۲- استادیار، گروه مهندسی نقشه‌برداری، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

(Email: parmehr@nit.ac.ir)

*- نویسنده مسئول:

<https://doi.org/10.22067/jam.2022.72647.1064>

3- *Chilo suppressalis*

4- Walker

5- Dead Hearts

خشکی گیاه می‌شود که این علامت را خسارت نوع دوم^۱ می‌نامند. مرحله دوم خسارت گیاه تقریباً در پایان مرحله رویش است و امکان ترمیم خسارت از طریق رشد ساقه‌های جانبی وجود ندارد. ساقه‌های آلوده به آفت در این زمان در اثر وزش باد شکسته و باعث خرابی و از بین رفتن ساقه‌های سالم مجاور می‌گردد (Pathak, 1968).

در حال حاضر، آسیب‌شناسان گیاهی از یک روش قدیمی که به‌طور عمده متکی به پیش‌بینی با چشم غیرمسلح است، برای درجه‌بندی شدت خسارت وارده به گیاهان استفاده می‌کنند. روش‌های سنتی نه تنها زمان‌بر هستند، بلکه نتایج غیردقیقی را نیز ارائه می‌دهند (Deshpande, Sengupta, & Raghuvanshi, 2014). تغییر روش‌های کشاورزی از سنتی به صنعتی و حمایت از فناوری‌های نوپهور باعث افزایش سرمایه‌گذاری و تبدیل آن به یک صنعت پررونق شده است. از اواخر دهه ۱۹۸۰ به‌منظور حل مشکلات کشاورزی سنتی، از قبیل آلودگی محیط‌زیست، هدر دادن منابع و همین‌طور برای تحقق توسعه کشاورزی، محققان سراسر جهان شروع به بررسی کاربرد کشاورزی دقیق و سیستم‌های ارتباطی هوشمند کرده‌اند. کشاورزی دقیق می‌تواند از فناوری اطلاعات مانند فناوری سیستم اطلاعات جغرافیایی، فناوری سنسور از دور و یادگیری ماشین استفاده کند تا به‌منظور دستیابی به منافع بهتر اقتصادی و کاهش خطرات محیط‌زیستی، از اقدامات فنی کشاورزی در میان مزارع استفاده کند (Zhu, Zhang, & Sun, 2009).

مفهوم مشترک سیستم اطلاعات جغرافیایی (GIS) ساده نبوده و بسیاری از مردم آن را به‌عنوان ابزار تولید نقشه می‌شناسند. در واقع، سیستم اطلاعات جغرافیایی یک محیط پیچیده متشکل از نمایش دیجیتالی مناظر، سنسور از دور، محیط پایگاه داده است (Opara, 2004; Soomro, Naqvi, & Zheng, 2001). نقش سیستم اطلاعات جغرافیایی در کشاورزی در حال افزایش است چرا که فناوری برای کسب، تحلیل و مدیریت داده‌های مرتبط با مکان بر روی محصولات کشاورزی در حال پیشرفت است (Soomro, 2015). فن‌آوری GIS نقش مهمی در کشاورزی دقیق را با ارزیابی شرایط محصول و پیش‌بینی بازده، کشف بیماری‌ها و آفات، نقشه‌برداری و محل وقوع فاجعه، اطلاعات مدیریت تامین آب، مدیریت حیات‌وحش و پیش‌بینی آب و هوا بازی می‌کند (Praveen & Sharma, 2020). در مالزی برای حمایت از تصمیم‌گیری و نظارت بر افزایش پایداری کشتزار روغن نخل، از GIS استفاده شده است. در این پژوهش از تصاویر چند طیفی و راداری سنسور از دور و تلفیق آن با GIS استفاده شد تا به‌صورت موثر این‌پایش انجام گردد (Pohl, 2016; Kanniah, & Loong, 2016). در ارتباط با نقش مهم اطلاعات جغرافیایی داوطلبانه می‌توان به تحقیقات موردی که در شهر

کشاورزی به‌صورت روزانه با چالش‌های زیادی از زمان کاشت بذر تا برداشت محصول مانند تخریب محصول توسط آفات، استفاده بی‌رویه آفت‌کش‌ها، عدم مدیریت صحیح علف‌های هرز و فقدان امکانات آبیاری و زهکشی روبه‌رو است. برای به حداقل رساندن تلفات محصولات کشاورزی، تشخیص نوع و شدت خسارت در مراحل اولیه برای اقدام پیشگیرانه مورد نیاز است. با توجه به قابلیت‌های هوش مصنوعی و یادگیری ماشین در حل مسائل پیچیده، می‌توان از این روش در بخش‌های مذکور استفاده نمود (Karabatak & Ince, 2009). استفاده از روش‌های هوش مصنوعی به‌جای تصمیم‌گیری‌های سنتی علاوه بر این که سبب افزایش بهره‌وری می‌گردد، از دقت بالایی نیز برخوردار است. امروزه صنعت کشاورزی به شدت نیازمند محاسبات و انجام عملیات تشخیص خودکار آفات با استفاده از هوش مصنوعی است (Jha, Doshi, Patel, & Shah, 2019).

در طول ۵۰ سال گذشته، به دلیل سودمندی زیاد و کاربرد فراوان، هوش مصنوعی به‌طور مداوم توسعه یافته و در حوزه‌های مختلف از جمله کشاورزی مورد استفاده قرار گرفته است. نوآوری‌های فنی مانند کامپیوترها، اینترنت و گوشی‌های هوشمند ابتدا در مراکز پرجمعیت شهری و سپس در مناطق روستایی مورد استفاده وسیع قرار گرفته ولی یک زیرساخت دیجیتال با عملکرد خوب در مناطق روستایی به‌منظور غلبه بر عدم دسترسی به امکانات شهری و جلوگیری از مهاجرت روستاییان به مناطق شهری ضروری است (Opara, 2004; Soomro et al., 2001). با توجه به آماری که مرکز تحقیقات Pew منتشر کرده است. میانگین ضریب نفوذ گوشی همراه هوشمند در سطح جهانی، تا پایان سال ۲۰۱۸، ۶۶ درصد است (Pew Research Center, Feb. 05, 2019). افزایش نفوذ تلفن همراه هوشمند و رایانش ابری به نشر اطلاعات مرتبط به کشاورزی به کشاورزان کمک شایانی خواهد کرد. یکی از مزایای جریان اطلاعات این است که کشاورز می‌تواند تصمیمات مدیریتی بهتری را اتخاذ نماید.

برای شناسایی گونه‌های آفت بر اساس تصاویر، از ترکیب مناسب شکل، رنگ، بافت و ویژگی‌های عددی استخراج‌شده برای توصیف پروانه استفاده کردند. سپس تکنیک³ IpSDAE برای شبکه عصبی عمیق طراحی شد که توانسته است پروانه‌های ایجادشده (پروانه‌هایی که توسط شبکه به صورت مصنوعی تولید شد) و پروانه‌های طبیعی را با دقت ۹۸/۱۳٪ شناسایی کند. در تحقیق لو و همکاران (Lu, Rustia, & Lin, 2019)، مدل طبقه‌بندی شبکه کانولوشن (CNN) را در ترکیب با تکنیک⁴ GAN پیشنهاد دادند که برای این روش از یک دوربین Raspberry Pi v2 استفاده شد و حشرات مگس سفید و تریپس مورد تجزیه و تحلیل قرار گرفتند و تصاویر مصنوعی از طریق افزایش داده مبتنی بر GAN ایجاد شد تا طبقه‌بندی CNN با داده‌های تصویری محدود افزایش یابد. در این روش شناسایی گونه حشره مگس با دقت ۸۵ تا ۹۵ درصد انجام شد. پیشرفت‌ها در شبکه‌های عصبی کانولوشن مبتنی بر یادگیری عمیق دقت طبقه‌بندی تصویر را تا حد زیادی بهبود بخشیده است با توجه به این که شبکه‌های کانولوشن در طبقه‌بندی تصاویر موفق بوده‌اند، رویکردهای مبتنی بر یادگیری عمیق در این مقاله برای تشخیص بیماری‌ها و آفات از تصاویر گیاه برنج توسعه داده شده است (Ngugi et al., 2020).

همان‌طور که تحقیقات جدید نشان می‌دهد با اضافه شدن تکنیک‌های شبکه عصبی عمیق روند شناسایی آفات گیاهی با دقت بیشتری انجام پذیرفت. تحقیقاتی که به آن اشاره شد برای اخذ تصویر نیاز به فرد متخصص و وجود شرایط نوری مناسب و یا استفاده از فناوری‌های مختلف برای شناسایی آفت وابسته هستند که امکان اجرای آن‌ها برای کشاورزان وجود ندارد. زیرا علاوه بر هزینه زیاد ساخت این دستگاه‌ها و استخدام نیروی کارآمد، زمان برای مبارزه با آفت برنج از دست خواهد رفت. نکته دیگری در این تحقیقات جدا بودن بخش تشخیص آفت و تحلیل‌های مکانی مبتنی بر GIS است. همواره عدم اطمینان از داده‌های ارسالی از داوطلب در VGI وجود خواهد داشت. بنابراین، نیاز به اعتبار داده‌های مکانی داوطلبانه همواره مورد توجه قرار گرفته است.

در پژوهش حاضر، در گام اول با استفاده از داده‌های دریافتی از تلفن هوشمند و اعتبارسنجی آن با نظر کارشناسان مدل آموزش دیده‌ای از آفت کرم ساقه‌خوار ارائه می‌شود. سپس، در گام دوم سامانه توسعه‌یافته بر پایه تلفن هوشمند معرفی می‌شود. با استفاده از این سامانه کشاورزان می‌توانند با به اشتراک‌گذاری تصاویر آفت از طریق اینترنت، به نوع آفت زمین زراعی خود آگاهی یابند و اقدامات لازم جهت مقابله با آفت را انجام دهند. این عمل در کمترین زمان ممکن

یادگیری ماشین¹ شاخه‌ای از هوش مصنوعی است که قابلیت پیشرفت خودکار بر اساس تجربه‌های کسب شده را دارد (Mitchell, Carbonell, & Michalski, 1986). به عبارت دیگر، یادگیری ماشین برای یافتن الگوها و جستجوی تغییرات کوچک، بر پایه‌ی بررسی و مقایسه‌ی داده‌هایی از مقادیر کوچک تا حجم عظیمی از داده استوار است و یکی از راه‌های دستیابی به هوش مصنوعی محسوب می‌شود. یادگیری عمیق یک زیر شاخه از یادگیری ماشین است که مفاهیم استفاده از گرافی با یال‌های زیاد و پیچیده با چندین لایه انتزاعی سطح بالا را مدل می‌کند.

این قابلیت موجب شده تا در مدیریت کشاورزی دقیق مورد توجه قرار گیرد. در کشاورزی دقیق اطلاعات مواد شیمیایی و تخریب آفات از نظر زمان و مکان مورد بررسی قرار می‌گیرند. تشخیص بیماری و پیش‌بینی بازده زمان تخریب، با محوریت هوش مصنوعی عنوان مقالات و پژوهش‌های زیادی در حوزه کشاورزی بوده است. تکنیک‌های یادگیری عمیق در طبقه‌بندی تصویر بسیار نویدبخش ظاهر شده‌اند در سال‌های اخیر، این تکنیک‌ها برای تجزیه و تحلیل بیماری‌های چای، سیب، گوجه‌فرنگی، انگور، هلو و گلابی مورد استفاده قرار گرفته است (Ngugi, Abdelwahab, & Abo-Zahhad, 2020). از جمله این پژوهش‌ها می‌توان به مقاله پنتازی و همکاران اشاره کرد که برای تشخیص ماریتغال² سالم و آلوده به سیاهک در طول رشد گیاه انجام شد (Pantazi et al., 2017). در تحقیق دیگری یک روش جدید براساس روند پردازش تصویر برای طبقه‌بندی و تشخیص خودکار قارچ گیاه توت‌فرنگی در محیط گلخانه توسعه داده شد که به صورت به‌هنگام اقدام به شناسایی و طبقه‌بندی انواع قارچ‌های این گیاه می‌کند (Ebrahimi, Khoshtaghaza, Minaei, & Jamshidi, 2017). در تحقیقی مشابه نیز برای تشخیص و غربالگری بیماری پوسیدگی طوقه برنج، از پردازش تصویر برای تشخیص دقیق پاتوژن‌های قارچ فوزاریوم برای دو وارته برنج استفاده شد (Chung et al., 2016). با توجه به تحقیقات انجام شده، تشخیص خودکار آفت محصول علاوه بر افزایش میزان تولید محصول، زمان تشخیص بیماری را نسبت به روش‌های سنتی کاهش می‌دهد. در استفاده از تکنیک یادگیری ماشین، محققان (Silveira & Monteiro, 2009) ابزاری را برای شناسایی خودکار الگوهای نقطه چشم پروانه *Bicyclus anynana*، با استفاده از یک الگوریتم یادگیری ماشین با ویژگی‌های مبتنی بر دایره‌ای و تقارن برای تشخیص نقاط چشمی روی تصاویر ایجاد کردند. این نرم‌افزار همچنین توانست الگوهای سایر گونه‌های پروانه را با موفقیت تشخیص دهد. ون و همکاران (Wen, Wu, Hu, & Pan, 2015)،

3- Improved Pyramidal Stacked De-noising AutoEncoder (IpSDAE)
4- Generative adversarial network

1- Machine Learning (ML)
2- *Silybum marianum*


با استفاده از هوش مصنوعی توسعه داده شده انجام می‌شود.

مواد و روش‌ها

منطقه مورد مطالعه

زمین‌های کشاورزی واقع در روستای چالیکیاده شهرستان آمل از توابع امامزاده عبدالله برای جمع‌آوری داده‌های آفت مورد مطالعه مطابق شکل ۱ انتخاب شد. در این روستا هر ساله در دو نوبت کشت

برنج انجام می‌شود. اقلام برنج تولیدی شامل گونه‌های پر محصول (فجر) و بومی (طارم هاشمی) بوده و فرآیند کشت محصول از اواخر اسفند ماه شروع و برداشت محصول در تیر ماه انجام می‌شود. این روستا در طول جغرافیایی $13^{\circ} 17' 56''$ و عرض جغرافیایی $36^{\circ} 8'$ قرار گرفته است. شکل ۲ موقعیت منطقه مورد مطالعه را نشان می‌دهد.



شکل ۲- موقعیت جغرافیایی منطقه

Fig.2. Geographical location of the region



شکل ۱- تصویر ماهواره‌ای از زمین‌های کشاورزی

Fig.1. Satellite image of agricultural lands

جمع‌آوری داده

برای جمع‌آوری تصاویر کرم ساقه‌خوار به تعداد کافی برای آموزش شبکه از روش سنتی اهالی روستا استفاده شد. در این روش مطابق شکل ۳ یک منبع نور را در بالای تشتت پر از آب حاوی مقداری آفت کش قرار داده و هنگام غروب آفتاب این حشرات به دنبال نور جذب می‌شوند و بعد از چرخش زیاد به داخل آب موجود در

تشت سقوط می‌کنند. این روش به تله نوری (فرولایت) معروف است. بعد از شکار آفت با استفاده از تله نوری آن‌ها را از سطح آب جمع‌آوری کرده و با گوشی همراه اقدام به عکس‌برداری از این حشره با توجه به موقعیت مکانی تله نوری می‌شود نمونه‌ای از این تصویر در شکل ۴ قابل مشاهده است.



شکل ۳- تله نوری مورد استفاده برای شکار آفت

Fig.3. Optical traps used for pest hunting



شکل ۴- نمایش حشرات کامل به تله‌افتاده کرم ساقه‌خوار برنج
Fig.4. Display of trapped insects of *Chilo suppressalis*

آموزش دیده را توسعه داده و پس از ساخت مدل که شامل وزن‌های آموزش دیده است در سرور بارگذاری می‌شود سپس زمانی که کشاورز تصویر آفت را در برنامه بارگذاری کند تصویر برای تشخیص در سرور فراخوانی می‌شود و توسط مدل توسعه داده شده نوع آفت تشخیص داده می‌شود و نتیجه برای کشاورز ارسال می‌شود. کل این مراحل در سرور انجام می‌پذیرد و این امکان باعث می‌شود نتایج به‌هنگام به دست کشاورز برسد و در نهایت برای بررسی دقت نتایج حاصل، شبکه عصبی براساس معیارهای ارزیابی مورد بررسی قرار می‌گیرد.

دریافت اطلاعات از کشاورز

محیط گرافیکی نرم‌افزار مطابق شکل ۵ نشان داده شده است. کشاورز برای استفاده از نرم‌افزار بایستی ابتدا مشخصات خود را به همراه موقعیت تقریبی زمین کشاورزی وارد نماید. سپس، برای تشخیص آفت، عکسی از آفت را همراه با برچسب موقعیت مکانی مطابق شکل ۶ برای این سامانه ارسال می‌کند.

روش پیشنهادی

روش پیشنهادی در این تحقیق شامل سه مرحله اصلی است. ابتدا کشاورز با استفاده از نرم‌افزار توسعه‌یافته (مزرعه هوشمند) عکس دریافت شده از آفت کرم ساقه‌خوار را همراه با موقعیت مکانی آن برای سامانه ارسال می‌کند. عملیات پردازش تصویر و شناسایی محدوده آفت در برنامه نرم‌افزار مزرعه هوشمند انجام می‌پذیرد و کاربر صحت شناسایی آفت را تایید می‌کند. در گام دوم تصاویر ارسالی کشاورز در مدل از پیش‌آموزش دیده سامانه مورد تصمیم‌گیری قرار می‌گیرد و در گام نهایی بعد از تشخیص نوع آفت نتایج همراه با روش‌های مبارزه با این آفت برای کشاورز ارسال خواهد شد. تمرکز اصلی این تحقیق بررسی امکان تشخیص آفت کرم ساقه‌خوار برنج با استفاده از تصاویر به‌دست آمده از تلفن همراه است. اما برای توسعه این روش سامانه‌ای طراحی شد تا کشاورز بتواند نیازهای کشاورزی خود را با صرف کمترین زمان برآورده کند. بنابراین، ابتدا با استفاده از تصاویر به‌دست آمده از تلفن هوشمند و صحت داده‌ها و تایید آن توسط کارشناسان کشاورزی مدل

InfoCamera :Date & Time: 2021:02:22 19:34:38
 Flash: 16
 Focal Length: 1600/1000
 GPS Datestamp: 16
 GPS Latitude: 36/1,26/1,20043/10000
 GPS Latitude Ref: N
 GPS Longitude: 52/1,17/1,198560/10000
 GPS Longitude Ref: E
 GPS Processing Method: null
 GPS Timestamp: 16:04:22
 Image Length: 1440
 Image Width: 2560
 Camera Make: LG Electronics
 Camera Model: LG-M700
 Camera Orientation: 8
 Camera White Balance: 0

شکل ۶- اطلاعات دریافتی از درخواست کشاورز
Fig.6. Information received from the farmer's request




شکل ۵- قسمتی از ورود اطلاعات کشاورز هوشمند
Fig.5. Part of smart farmer information entry

پردازش تصاویر و شبکه عصبی عمیق

پیش‌پردازش داده‌های دریافتی

پردازش تصاویر دریافتی از کشاورز برای تشخیص کرم ساقه‌خوار از آفت‌های مشابه ضروری است. روشی که در این تحقیق پیشنهاد شده شامل پیش‌پردازش، بخش‌بندی و استخراج ویژگی است. ویژگی‌های تولیدشده از این مراحل برای تصمیم‌گیری و طبقه‌بندی به شبکه آموزش‌دیده ارسال خواهد شد تا عارضه یا آفت را تشخیص دهد. ابتدا عملیات پیش‌پردازش انجام می‌شود، تا علاوه بر انتخاب محدوده مورد نظر فیلترهای استاندارد مانند فیلترهای نرم‌کننده برای حذف نویز احتمالی هم روی داده‌ها انجام پذیرد. این کار می‌تواند در

تلفن همراه هوشمند کاربر انجام شود و فایل بعد از انجام پیش‌پردازش در سرور بارگذاری شود. با این عمل سرعت بارگذاری داده بیشتر خواهد شد و کاربر هزینه کمتری بابت انتقال اطلاعات می‌پردازد. پردازش تصویر باعث می‌شود تا کیفیت تصویر بهبود یافته و تصحیحات هندسی مورد نظر بر روی تصویر اعمال شود (Hornberg, 2017). برای شناسایی و طبقه‌بندی تصاویر با پیچیدگی زیاد می‌توان از شبکه‌های عصبی استفاده نمود. تصاویر دریافتی از کاربر مطابق شکل ۷ به تصویر خاکستری تبدیل می‌شوند تا عملیات پردازش با سرعت بیشتری انجام پذیرد. سپس پس‌زمینه تصویر از تصویر با استفاده از رابطه (۱) حذف می‌شود.



شکل ۷- تبدیل عکس رنگی به درجه خاکستری


Fig.7. Converting a color photo to a gray degree

رابطه (۱) مورد استفاده قرار گرفت (Miranda, Gerardo, & Tanguilig, 2014):

$$O_{RI}(x,y) = \begin{cases} 255 & \text{if } R(x,y) = I(x,y) \\ I(x,y) & \text{if } R(x,y) \neq I(x,y) \end{cases} \quad (1)$$


در این رابطه، مختصات x ، y پیکسل‌های خروجی در عکس اولیه یعنی عکس رنگی جاگذاری شده و شکل حشره به صورت رنگی مطابق تصاویر شکل ۸ از عکس خام اولیه جدا می‌شود.

روش مورد استفاده برای تشخیص آفت حشرات در تصویر ساده و در عین حال کارآمد است. دو تصویر در تشخیص تفاوت، مورد استفاده قرار می‌گیرد. تصویر اول به عنوان تصویر مرجع عمل کرده و تصویر دوم به عنوان تصویر ورودی عمل می‌کند. این دو تصویر با هم مقایسه شده و تفاوت در مقادیر پیکسل تعیین می‌شود. اگر مقادیر پیکسل ورودی برابر با مقادیر پیکسل مرجع نباشد مقدار پیکسل ورودی به عنوان پیکسل خروجی ذخیره خواهد شد و اگر مقدار پیکسل تصویر ورودی برابر با تصویر مرجع باشد، پس‌زمینه سفید خواهد شد. برای مشخص کردن تفاوت تصویر مرجع و ورودی،



شکل ۸- مراحل پردازش

Fig.8. Processing steps



شکل ۹- تولید داده‌های آموزشی مصنوعی
Fig.9. Production of artificial train data

آموزش مدل برای تشخیص آفت

در این مقاله به دلیل محدودیت تعداد عکس‌های مورد نیاز برای تولید ساختارهای شبکه‌ای فقط از عکس‌های پروانه کرم ساقه‌خوار استفاده شده است. این عکس‌ها از منابع مختلفی از جمله گوگل و جمع‌آوری میدانی مورد استفاده قرار گرفته است. روش پیشنهادی با کتابخانه TensorFlow 1.13.1 و چارچوب نرم‌افزاری Keras 2.2.4 مورد استفاده قرار گرفت. نمونه مورد استفاده دارای ۹۰ تصویر کرم ساقه‌خوار و ۶۰ تصویر شامل دیگر حشرات بوده است. اما این تعداد نمونه برای آموزش شبکه کافی نمی‌باشد. از طرف دیگر، دریافت نمونه‌های زیاد، نیازمند صرف هزینه و زمان زیادی است. عموم مدل‌های یادگیری عمیق به‌خاطر پارامترهای زیادی که دارد نیازمند حجم زیادی از داده‌های آموزشی هستند که همیشه این حجم زیاد داده آموزشی در دسترس نیست. یکی از روش‌های استفاده شده برای افزایش تعداد نمونه‌های آموزشی شیوهی «داده‌افزایی» است. انعکاس، اضافه کردن نویز، تغییر رنگ، تغییر اندازه و برش تصاویر از جمله شیوه‌های داده‌افزایی هستند (Ba & Frey, 2013). در این مقاله از تابع سازنده Image Data Generator برای تولید نمونه‌های تصادفی استفاده شد. یکی از تکنیک‌های مورد استفاده تکنیک شیفته عمودی و افقی تصاویر می‌باشد. این کار به معنای هل دادن تمامی پیکسل‌های تصویر در یک جهت مشخص است در حین این عمل اندازه تصویر ثابت است. تکنیک دیگری که مورد استفاده قرار گرفته است تکنیک چرخش تصویر به مقدار تصادفی می‌باشد. این روش جهت تقویت دیتاست از چرخش و دوران تصاویر استفاده می‌شود و هر تصویر به مقداری تصادفی در جهت عقربه‌های ساعت می‌چرخد. تکنیک آخری که برای تولید نمونه‌های مصنوعی مورد استفاده قرار گرفت تکنیک برگرداندن تصاویر از چپ به راست و بالا به پایین می‌باشد. برگرداندن تصویر به معنای معکوس کردن جهت ردیف‌ها یا ستون‌های پیکسل‌های یک تصویر است که در نهایت موجب می‌شود

محورها عمودی یا افقی تصویر برعکس شوند (شکل ۹). در نهایت ۱۲۱۳ تصویر برای آموزش شبکه و ۵۲۱ تصویر برای آزمایش شبکه که مقدار ۳۰ درصد از داده آموزشی است به منظور اعتبارسنجی^۲ مورد استفاده قرار گرفت. استفاده از تکنیک افزایش داده‌های آموزشی امری رایج در آموزش شبکه‌های عمیق است. به‌عنوان مثال کاسرینی و همکاران (Kusrini et al., 2020) برای شناسایی آفت‌های درخت انبه با استفاده از تکنیک افزایش داده تعداد داده‌های آموزشی را از ۵۱۰ تصویر به ۶۲۰۴۷ تصویر افزایش دادند. از طرف دیگر، خان رمکی و همکاران (Khanramaki, Askari Asli-) از تکنیک افزایش داده با چرخش تصاویرها با زوایای مختلف و همین‌طور از تکنیک برگرداندن تصاویر از چپ به راست و بالا به پایین اقدام به تولید داده‌های مصنوعی کردند که موجب بهبود دقت شبکه طراحی شده گردید. استفاده از تکنیک‌های دیگر برای تولید داده‌های مصنوعی احتمال ایجاد تصاویری که در واقعیت وجود ندارند را زیاد می‌نماید. به‌عنوان مثال، استفاده از تکنیک تغییر فضای رنگی احتمال تولید یک کرم ساقه‌خوار با رنگ غیر واقعی را افزایش می‌دهد که موجب تمایز بین داده‌هایی می‌شود که در دنیای واقعی وجود ندارند. راهکار دیگر برای جلوگیری از بیش‌برازش در شبکه یادگیری عمیق و افزایش کارایی مدل استفاده از «نظم‌دهی»^۳ است. اضافه کردن پارامتر نظم‌دهی، مقادیر درون ماتریس وزن را کاهش خواهد داد و این موضوع شبکه عصبی را همگرا می‌کند. در یادگیری عمیق هدف به حداقل رسانی تابع هزینه رابطه (۲) است.

$$J(\mathbf{w}^{[1]}, \mathbf{b}^{[1]}, \dots, \mathbf{w}^{[L]}, \mathbf{b}^{[L]}) = \frac{1}{m} \sum_{i=1}^m L(\hat{\mathbf{y}}^{(i)}, \mathbf{y}^{(i)}) \quad (2)$$

در رابطه (۲)، L می‌تواند هر تابع هزینه باشد. حال، برای نظم‌دهی L_2 پارامتری به‌منظور تنظیم وزن‌ها اضافه می‌شود که رابطه

(۳) حاصل خواهد شد.

$$J(\mathbf{w}^{[1]}, \mathbf{b}^{[1]}, \dots, \mathbf{w}^{[L]}, \mathbf{b}^{[L]}) = \frac{1}{m} \sum_{i=1}^m L(\hat{\mathbf{y}}^{(i)}, \mathbf{y}^{(i)}) + \frac{\lambda}{2m} \sum_{l=1}^L \|\mathbf{w}^{[l]}\|_F^2 \quad (3)$$

در این جا که λ (لاندا) پارامتر نظم‌دهی می‌باشد، F به‌عنوان پارامتر نرمال Frobenius شناخته می‌شود و در واقع برابر با مجذور نرمال یک ماتریس می‌باشد. لاندا پارامتری است که وابسته به شرایط می‌تواند تنظیم شود یعنی مقدار بالای وزن‌ها با در نظر گرفتن مقدار بالایی برای لاندا قابل کنترل خواهد بود و به‌طور مشابه مقدار کم برای لاندا به‌منظور تنظیم مقدار کم وزن‌ها در نظر گرفته می‌شود. از آنجایی که تابع هزینه باید حداقل‌رسانی شود، تناسب مطرح‌شده منطقی به نظر می‌رسد و با اضافه کردن مجذور نرمال ماتریس وزن‌ها و ضرب آن در پارامتر نظم‌دهی، وزن‌های زیاد به نوعی تنظیم و تابع هزینه کاهش می‌یابد. معمولاً برای کاهش بیش‌برازش مدل در شبکه‌های کانولوشن از عملگر «رهاسازی» استفاده می‌شود. رهاسازی روشی برای منظم‌سازی است و خطای تعمیم‌پذیری را با کاهش گنجایش مدل کمتر می‌کند؛ بدین ترتیب که در هر دور آموزشی، به جای استفاده از همه نورون‌ها، تنها برخی از نورون‌ها (با احتمال p) فعال می‌شوند. هنگام آموزش، بعضی از نورون‌ها خاموش می‌شود تا در هر تکرار، شبکه‌ها باهم متفاوت باشند. شکل ۱۰ نحوه خاموش کردن نورون‌ها را نشان می‌دهد که هر ورودی \mathbf{y}_i را در یک نورون r_i که یک توزیع دوقطه‌ای با خروجی ۰ و ۱ (با توزیع برنولی) است، ضرب می‌شود.

بدون اجرای رهاسازی، گذر رو به جلو در مرحله آموزشی چنین شکلی خواهد داشت:

$$\mathbf{z}_i^{(l+1)} = \mathbf{w}_i^{(l+1)} \mathbf{y}^l + \mathbf{b}_i^{(l+1)}, \mathbf{y}_i^{(l+1)} = f(\mathbf{z}_i^{(l+1)}) \quad (4)$$

در این رابطه، ورودی تابع فعال‌سازی f در واقع همان حاصل ضرب جمع وزن‌ها (w) در ورودی (y) است. اما بعد از اجرای رهاسازی، گذر رو به جلو بدین شکل خواهد بود.

$$\mathbf{r}_i^{(l)} \sim \text{Bernoulli}(p), \hat{\mathbf{y}}^{(l)} = \mathbf{r}^{(l)} * \mathbf{y}^{(l)}, \mathbf{z}_i^{(l+1)} = \mathbf{w}_i^{(l+1)} \hat{\mathbf{y}}^l + \mathbf{b}_i^{(l+1)} \quad (5) \mathbf{y}_i^{(l+1)} = f(\mathbf{z}_i^{(l+1)})$$

در خط دوم این معادله یک نورون r به معادله اضافه می‌شود که یا (به احتمال p) با ضرب وزن در ۱ آن را نگه می‌دارد یا این که (به احتمال $p-1$) با ضرب آن در ۰ آن را خاموش می‌کند؛ ادامه گذر رو به

جلو، مشابه زمانی است که از تکنیک رهاسازی استفاده نشود (Baldi & Sadowski, 2014)

الگوریتم آموزش شبکه عصبی کانولوشن

شبکه‌های عصبی کانولوشن از این واقعیت که ورودی شامل تصاویر است استفاده کرده و معماری شبکه را به روش منطقی محدود می‌کند. یک شبکه کانولوشن از چند لایه تشکیل می‌شود و هر لایه شیوه کار ساده‌ای دارد که در آن یک توده سه‌بعدی ورودی را دریافت کرده و با استفاده از توابعی مشتق‌پذیر^۲ به یک توده سه‌بعدی خروجی تبدیل می‌کند. قرارگیری یک لایه تجمیع^۳ بین چندین لایه کانولوشن امری رایج است. وظیفه‌ی این لایه کاهش اندازه مکانی (عرض و ارتفاع) تصویر (ورودی) به جهت کاهش تعداد پارامترها، محاسبات و کنترل بیش‌برازش در داخل شبکه است. لایه تجمیع به‌صورت مستقل بر روی هر برش عمقی از توده ورودی عمل کرده و آن را با استفاده از عملیات بیشینه‌سنجی^۴ از لحاظ مکانی تغییر اندازه می‌دهد. خلاصه‌ای از این معماری را می‌توان در شکل ۱۱ مشاهده کرد.


رایج‌ترین شکل استفاده از این لایه کاهش به‌صورت فیلترهای با اندازه 2×2 به همراه اندازه گام ۲ است که هر برش عمقی در ورودی را با حذف ۲ عنصر از عرض و ۲ عنصر از ارتفاع کاهش داده و باعث حذف ۷۵٪ مقادیر موجود در آن برش عمقی می‌شود. در این عملیات بعد عمق بدون تغییر باقی می‌ماند. به‌طور کلی لایه تجمیع یک توده با اندازه $W \times H \times D$ را به‌عنوان ورودی دریافت می‌کند و با توجه به اندازه پنجره و اهداف شبکه، مقدار میانگین یا بیشینه موجود در آن را در خروجی ارائه می‌دهد. اعمال این لایه بر روی لایه ورودی، باعث می‌شود که ابعاد ورودی به تدریج کاهش یابد (Tajbakhsh et al., 2016).

شبکه کانولوشنی پیشنهادی


آموزش شبکه به معنی به حداقل رساندن تابع هزینه بر حسب خروجی‌های واقعی شبکه در مقایسه با خروجی‌های مطلوب شبکه است. این کار از طریق اصلاح وزن‌ها و بایاس‌ها صورت می‌گیرد. شبکه کانولوشنی دارای معماری‌های مختلفی هستند که برای اهداف خاصی طراحی شده‌اند که می‌توان AlexNet, GoogleNet, VGG را نام برد. اما شبکه‌های کانولوشنی همراه از معماری‌های آماده پیروی نمی‌کنند و با سعی و خطا طراحی می‌شوند. در این مقاله هم پارامترها، تعداد تکرار، تعداد لایه‌های کانولوشنی^۵ و نوع تابع فعال‌سازی^۶ تا حدود زیادی با سعی و خطا اعمال شده است.

- 2- Differentiable Function
- 3- Pooling
- 4- Max pooling
- 5- Convolutional layer
- 6- Activation Function

- 1- Dropout




شکل ۱۰- سمت چپ شبکه اصلی با یک لایه پنهان و سمت راست نحوه عملکرد تکنیک رهاسازی در این شبکه
Fig.10. The left is a basic hidden layer network, and the right is how dropout work on this network



شکل ۱۱- معماری کلی شبکه
Fig.11. General network architecture

استفاده می‌شود که اگر به‌طور مجدد به شبکه همان ورودی‌ها داده شود، خروجی شبکه به خروجی مطلوب نزدیک‌تر شود (Najaf-Zadeh & Ghaffari, 2020). در این روش تصاویر به‌صورت دسته‌های ۱۶ تایی به شبکه وارد می‌شود. معماری روش پیشنهادی در تصویر شماره ۱۲ نشان داده شده است و سپس در ادامه مهم‌ترین لایه‌های این معماری به‌صورت خلاصه توضیح داده شده است.

بنابراین روش آموزش مورد استفاده در ساختار پیشنهادی، روش آموزش نظارت‌شده است. در این روش یک سرپرست بر رفتار یادگیرنده نظارت می‌کند و نحوه عملکرد صحیح را به او یادآور می‌شود. به بیان دیگر، سیستم یادگیرنده، مجموعه‌ای از زوج‌های داده متشکل از ورودی شبکه و خروجی مطلوب است. پس از اعمال ورودی شبکه، خروجی آن با خروجی مطلوب مقایسه شده و خطای یادگیری محاسبه و از آن برای اصلاح پارامترهای شبکه به‌گونه‌ای



شکل ۱۲- شبکه کانولوشنی پیشنهادی
Fig.12. Proposed convolutional network

نورون‌های موجود در این لایه به دنبال ویژگی‌های خاصی هستند. اگر آن‌ها ویژگی‌های مورد نظر خود را پیدا کنند، تابع فعال‌ساز آن‌ها فعال می‌شود. عملیات کانولوشن در تصویر این‌گونه عمل می‌کند که فیلتر با

شبکه کانولوشنی شامل لایه‌های کانولوشنی، لایه‌های کاهش اندازه، لایه Flatten و لایه‌های تمام‌متصل Dense است. لایه کانولوشنی را می‌توان چشم‌های شبکه کانولوشن دانست به‌طوری که

سیگموئید (رابطه ۷) می‌تواند برای تولید مشتق آن مورد استفاده قرار بگیرد. با توجه به مزایای ذکر شده، در این مقاله در لایه تمام‌متصل از الگوریتم طبقه‌بندی sigmoid استفاده شده است.

تابع هزینه تفاوت نتیجه واقعی و نتیجه پیش‌بینی شده را مشخص می‌کند و با استفاده از این تابع هزینه مقادیر وزن‌های شبکه عصبی به‌روزرسانی می‌شود و شبکه را به سمت جواب‌های بهتر سوق می‌دهد. توابع هزینه مختلفی برای شبکه‌های عمیق معرفی شد یکی از رایج‌ترین تابع‌های هزینه Cross Entropy است که در طبقه‌بندی مورد استفاده قرار می‌گیرد و دارای دو نوع اختلاف آنتروپی دو دویی^۱ و اختلاف آنتروپی موضوعی^۲ می‌باشد که در این مقاله به دلیل تعداد خروجی مورد نظر تابع هزینه به‌صورت binary_crossentropy انتخاب شد. استفاده از تابع بهینه‌ساز و نرخ یادگیری و همچنین از تابع Adamax برای بهینه‌سازی تابع هزینه با نرخ یادگیری $1e-5$ استفاده شد.

ارسال اطلاعات به کشاورز

برای استفاده از این سامانه لازم است کشاورز عکسی از آفت مورد نظر را برای سامانه ارسال نماید. سپس، سامانه با استفاده از مدل آموزش دیده خود مطابق شکل ۱۳ نوع آفت را تشخیص می‌دهد و دستورالعمل‌های مبارزه با این آفت برای کشاورز ارسال می‌کند تا در سریع‌ترین زمان ممکن به مبارزه با این آفت پرداخته شود.

معیار ارزیابی شبکه عصبی

برای ارزیابی نتایج طبقه‌بندی از معیارهای ارزیابی استاندارد استفاده می‌شود که مشهورترین و عمومی‌ترین معیار برای تعیین کارایی یک الگوریتم طبقه‌بندی معیار دقت^۳، معیار صحت^۴ و معیار حساسیت^۵ است. معیار امتیاز F1 پارامترهای دقت و حساسیت را با هم ترکیب می‌کند تا کارایی یک مدل طبقه‌بندی ارزیابی شود. برای محاسبه پارامتر ارزیابی از روابط (۸) استفاده می‌شود که در این روابط، FP^6 مربوط به تصاویر کرم ساقه‌خواری است که به اشتباه به‌عنوان حشره دیگر طبقه‌بندی شده است. FN^7 تعداد تصاویری که به اشتباه کرم ساقه‌خوار طبقه‌بندی شده‌اند. TP^8 تعداد تصاویری از کرم ساقه‌خوار است که به‌درستی تشخیص داده شده است و TN^9 مربوط تصاویری است که به‌درستی کرم ساقه‌خوار تشخیص داده نشده‌اند.

سایز موردنظر بر روی تصویر اصلی حرکت کرده و در هر لحظه آرایه‌های ماتریس فیلتر روی آرایه‌های پیکسل‌های تصویر قرار گرفته و ضرب می‌شوند. در نهایت حاصل تمام نقاط با یکدیگر جمع می‌شوند و به ازای هر قسمت فیلتر شده یک عدد به‌دست می‌آید. در مرحله بعد، فیلتر یک واحد به سمت راست رفته و مجدد عملیات تکرار می‌شود. این عملیات تا زمانی پیش می‌رود که محاسبات روی کل پیکسل‌های تصویر انجام شوند. در نهایت یک ماتریس جدید تولید می‌شود. در این مقاله از ۴ لایه کانولوشنال با تابع فعال‌ساز ReLU، که در هر لایه ۱۶ فیلتر با ابعاد 3×3 قرار دارد، استفاده شده است. تابع ReLU یک تابع غیرخطی است (رابطه ۶) که با خطاهای پس‌انتشار مواجه نمی‌شود. علاوه بر این، اگر در شبکه‌های عصبی بزرگ‌تر به جای تابع sigmoid از تابع ReLU استفاده شود، سرعت مدل‌سازی بیشتر شده و در نتیجه مدت زمان مدل‌سازی کاهش می‌یابد.

$$f(x) = \text{Max}(x, 0) \quad (6)$$

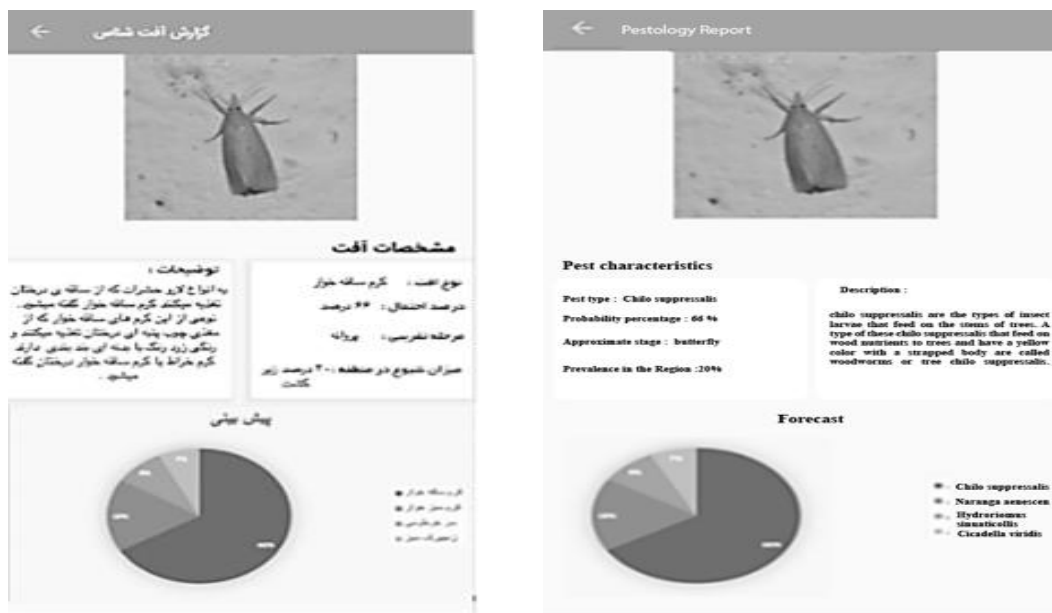
لایه‌های کاهش اندازه به‌صورت دوره‌ای در بین لایه‌های کانولوشن متوالی قرار دارند. قرار دادن یک لایه Pooling معمولاً بین چند لایه کانولوشنی پشت سر هم در یک معماری کانولوشنی امری بسیار رایج است و از آن برای کاهش اندازه نگاشت ویژگی‌ها و پارامترهای شبکه می‌توان استفاده کرد. کارکرد این لایه کاهش اندازه مکانی تصویر به جهت کاهش تعداد پارامترها و محاسبات در داخل شبکه و بنابراین کنترل بیش‌برازش است.

لایه Flatten یک لایه مهم است که بین لایه‌های استخراج ویژگی کانولوشنی و طبقه‌بندی خروجی قرار می‌گیرد. این لایه داده‌هایی که قصد ورود به مرحله طبقه‌بندی دارند را به بردار تبدیل می‌کند.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

آخرین لایه، لایه‌های تمام‌متصل Dense است که بعد از لایه‌های کانولوشنی قرار می‌گیرند. این لایه‌ها تقریباً ۹۰ درصد پارامترهای یک شبکه کانولوشنی را شامل می‌شوند. لایه‌های تماماً متصل نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه می‌کنند. از این بردار برای دسته‌بندی تصاویر استفاده می‌شود و یا این که از آن، جهت ادامه پردازش‌های بعدی بهره‌برد. در بسیاری از شبکه‌های عصبی توصیه می‌شود که از توابعی مانند sigmoid استفاده شود. زیرا خاصیت غیر خطی بودن آن‌ها، در ترکیب با یکدیگر قادر به شناسایی الگوهایی به مراتب پیچیده‌تر منجر می‌شود. این تابع هر مقدار را به یک مقدار از ۰ تا ۱ نگاشت می‌کند و کمک می‌کند تا مجموع وزنی ورودی‌ها نرمال‌سازی شوند (Elfving, Uchibe, & Doya, 2018). بعد از آن، مشتق تابع sigmoid برای کمک به محاسبه تنظیمات اساسی وزن‌ها گرفته می‌شود. خروجی تابع

- 1- Binary Cross-Entropy
- 2- Categorical Cross-Entropy
- 3- Accuracy
- 4- Precision
- 5- Sensitivity
- 6- False Positive
- 7- False Negative
- 8- True Positive
- 9- True Negative



شکل ۱۳- تصویری از محیط برنامه از خروجی تشخیص آفت
 Fig.13. Image of the program environment from the pest detection output

شرایط نوری نامناسب و وجود نویز با استفاده از تولید داده‌های مصنوعی وابستگی مدل آموزش دیده به کیفیت تصاویر ارسالی کاهش یافت. مدل طراحی شده با ۴۰۰ اپک زمانی به دقت ۸۸ درصد و صحت ۹۲ درصد رسیده است. همین‌طور، برای بررسی دقیق‌تر مدل پیشنهادی از معیار آماری یادآوری و معیار F استفاده شد. طبق محاسبات انجام شده مدل آموزش دیده توانست معیار یادآوری ۹۱ درصد را نشان دهد. این معیار نشان می‌دهد که مدل توانسته تا حد خیلی زیادی هر آنچه که انتظار شناسایی توسط مدل بوده را به‌خوبی شناسایی کند. همچنین، معیار F با درصد قابل قبول ۸۸ درصد دقت مدل آموزش دیده را تایید کرد. در جدول ۲ تمام معیارهای محاسبه شده برای این مدل آورده شد.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Sensitivity = \frac{TP}{TP + FN}$$

$$F1 = 2 \times \frac{Sensitivity \times Precision}{Sensitivity + Precision}$$
(۸)

نتایج و بحث

در این تحقیق با استفاده از یادگیری عمیق نوع آفت کرم ساقه‌خوار از سایر آفت‌ها تشخیص داده شد. به دلیل ارسال تصاویر با

جدول ۲- تمام معیارهای آماری به دست آمده از مدل

Table 2- All statistical criteria obtained from the model

Accuracy	Precision	Recall	F1
88%	92%	91%	88%

چندلایه (MLP^2) عملکرد بهتری را در شناسایی آفت نشان می‌دهد. چن و همکاران (Chen, Liu, & Gao, 2021) پتانسیل شبکه‌های عصبی کانولوشن را در شناسایی آفت چای را ارزیابی کردند. آن‌ها با توجه به این که که تصاویر آفات چای در شبکه به اندازه کافی برای

2- Multilayer perceptron

کارایی شبکه‌های یادگیری عمیق و داده‌افزایی

استفاده از شبکه‌های یادگیری عمیق به جای شبکه‌های یادگیری ماشین سنتی مانند ماشین بردار پشتیبان (SVM^1) و پرسپترون


1- Support Vector Machine

این تحقیق، مدل‌های شبکه عصبی کانولوشنی برای تشخیص و شناسایی سه نوع آفت مرکبات متداول در شمال ایران نظیر پروانه مینوز، فوماژین (قارچ دوده مرکبات) و بالشتک با استفاده از تصاویر برگ‌های آلوده از طریق روش‌های یادگیری عمیق توسعه داده شده است. آن‌ها از روش داده‌افزایی برای افزایش تعداد نمونه‌های آموزشی و بهبود تعمیم‌پذیری طبقه‌بندی‌ها استفاده کردند که بر اساس آزمایش‌های انجام شده و استفاده از داده‌افزایی، دقت تشخیص مدل ResNet به ۹۶٪ درصد رسید. در این تحقیق، شبکه با داده‌های واقعی بدون تکنیک افزایش داده و همراه با داده‌های مصنوعی ساخته شده آموزش داده شد که استفاده از تکنیک داده‌افزایی ۰/۲۸ درصد دقت شبکه را افزایش داد (Khan Ramaki et al., 2020).

در این تحقیق، به علت استفاده از شبکه عصبی کانولوشنی شخصی‌سازی شده برای کرم ساقه‌خوار و همین‌طور برای جلوگیری از بیش‌برازش شبکه و به منظور کاهش اشتباه (تابع هزینه) در وزن‌دهی به پارامترها از L2 استفاده شد و بعد از افزودن این تکنیک‌ها مطابق شکل ۱۴ مشاهده شد که شبکه در تکرارهای بالاتر با مقدار ضرر کمتری در انتخاب وزن‌ها و انحراف مواجه خواهد شد.

آموزش شبکه عصبی کانولوشنال عمیق وجود ندارد، پیشنهاد دادند که شبکه VGGNET-1 را با تنظیم دقیق پارامترها برای آفت چای توسعه دهند. سپس این روش را با طبقه‌بندی‌های سنتی مقایسه نموده‌اند. شبکه عصبی کانولوشنال پیشنهادی دارای دقت طبقه‌بندی تا ۹۷/۷۵ درصد است در حالی که MLP و SVM به ترتیب دارای دقت ۷۶/۰۷ درصد و ۶۸/۸۱ درصد هستند (Chen, Liu, & Gao, 2021). گاتیز و همکاران (Gutierrez et al., 2019) بهترین رویکرد برای شناسایی آفت عسلک پنبه (*Bemisia tabaci*) و سفید بالک گلخانه‌ای (*Trialeurodes vaporariorum*) را مورد بررسی قرار دادند. الگوریتم یادگیری عمیق با دقت ۸۵/۵٪ نسبت به روش نزدیک‌ترین همسایه (KNN) با دقت ۶۳/۸٪ و پرسپترون چندلایه (MLP) با دقت ۶۴/۹٪ عملکرد بهتری را نشان داده است و این بدین معنی است که یادگیری عمیق راه‌حل بهتری نسبت به تکنیک یادگیری ماشین است (Gutierrez et al., 2019).

روش یادگیری عمیق نیازمند داده‌های زیادی است تا مانع بیش‌برازش در شبکه گردد. مرتضی خان رمکی و همکاران در سال ۱۳۹۹ به تشخیص آفات متداول مرکبات در شمال ایران پرداختند در



شکل ۱۴- (a) تابع هزینه بدون استفاده از نظم‌دهی، (b) تابع هزینه با استفاده از نظم‌دهی

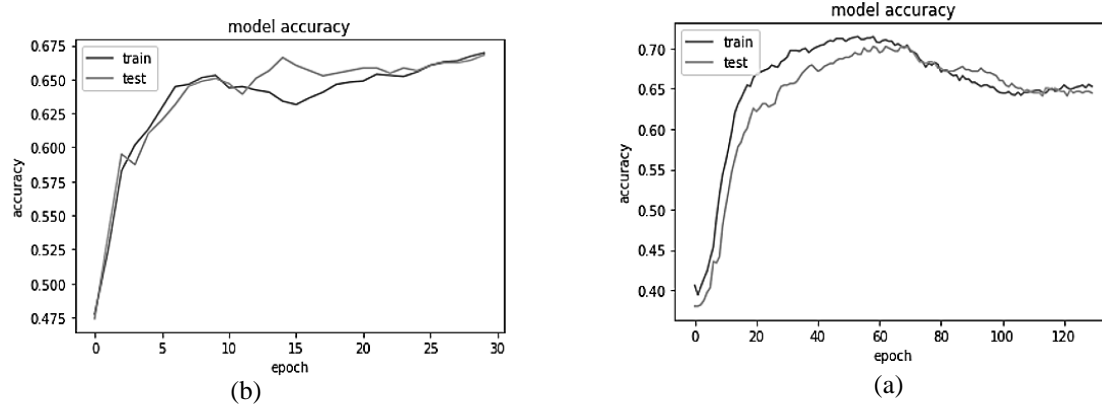
Fig.14. (a) Cost function without the use of regulation, (b) Cost function using regulation

و اضافه نمودن تکنیک‌های نرمال‌سازی L2 و تکنیک رهاسازی سعی گردید تا از وقوع بیش‌برازش جلوگیری شده و سپس، با افزایش اپک‌های زمانی دقت شبکه افزایش یابد.

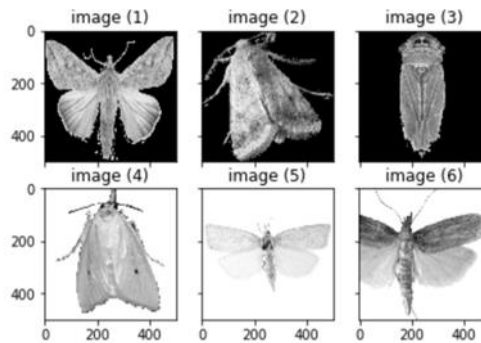
نتایج حاصل از سامانه پیشنهادی

در شکل ۱۶ تعدادی از تصاویر ارسال شده از طریق برنامه برای سامانه نشان داده شده و نتایج مربوطه نیز در جدول ۳ ارائه شده است.

به‌منظور دستیابی به دقت بالاتر افزایش اپک‌های زمانی ضروری است. اما برای جلوگیری از بیش‌برازش یک لایه با تکنیک رهاسازی به شبکه با مقدار احتمال ۰/۵ اضافه شد که این تغییرات به‌خوبی در شکل ۱۵ قابل مشاهده است. پس از اعمال این تکنیک بر روی شبکه دوباره برای رسیدن به دقت بالاتر اپک‌های زمانی افزایش داده شد. اما با افزایش بیشتر از ۳۵۰ اپک تغییر محسوسی در دقت شبکه به‌دست نیامده و آموزش شبکه با ۴۰۰ اپک به پایان رسید. در تحقیق مشابه (Khan Ramaki et al., 2020)، با تنظیم پارامترهای شبکه



شکل ۱۵- (a) تعداد اپک زمانی با ۳۰ اپک بدون تکنیک رهاسازی، (b) تعداد اپک زمانی با ۱۲۰ اپک بدون تکنیک رهاسازی
Fig.15. (a) Number of time 30 APCs (without dropout technique), (b) Number of time 120 APCs (with dropout technique)



شکل ۱۶- تصاویر انتخاب شده به عنوان تست مدل، تصاویر حشرات مختلف (a)، تصاویر کرم ساقه‌خوار برنج (b)
Fig.16. (a) Images selected as a test model of various insect images, (b) images of *Chilo suppressalis*

جدول ۳- پیش‌بینی‌های مدل تولیدشده

Table 3- Predictions of generated model

احتمال حشره کرم ساقه‌خوار Probability of <i>chilo suppressalis</i> insect	احتمال دیگر حشرات Another possibility of insects	تصاویر Images
11%	89%	تصویر ۱ Image 1
22%	78%	تصویر ۲ Image 2
1%	99%	تصویر ۳ Image 3
85%	15%	تصویر ۴ Image 4
70%	30%	تصویر ۵ Image 5
81%	19%	تصویر ۶ Image 6

تصاویر حشرات مشابه دچار اشتباه نشده است. طبق آخرین اطلاع نویسندگان، نرم‌افزار مشابه با سامانه پیشنهادی وجود نداشته و این

همان‌طور که در جدول ۳ نشان داده شده، شناسایی کرم ساقه‌خوار با دقت خوبی صورت گرفته و همچنین برنامه در برابر

سامانه هوشمند شناسایی نوع آفت (کرم ساقه‌خوار) طراحی و توسعه داده شده است. با استفاده از روش هوش مصنوعی و یادگیری عمیق نوع آفت از تصویر ارسالی توسط کشاورز به صورت خودکار شناسایی می‌گردد. نوع آفت تشخیص داده شده از طریق سامانه به کشاورز اطلاع داده می‌شود تا به کنترل آفت بپردازد. با استفاده از این سامانه درصد تشخیص اشتباه نوع آفت توسط کشاورز کاهش می‌یابد. کشاورز با استفاده از سامانه توسعه یافته و فقط با آموزش حداقلی نرم‌افزار در کمترین زمان ممکن از نوع آفت مزرعه خود مطلع می‌شود. سرعت و دقت سامانه موجب کاهش اثر مخرب آفت بر مزرعه می‌گردد. با توجه به امکان دریافت موقعیت مکانی از تصاویر ارسالی کشاورز به سامانه، تهیه نقشه گسترش آفت به صورت منطقه‌ای میسر است. در نتیجه، پیشنهاد می‌شود در تحقیقات آینده تاثیر مکانی این آفت بر مزارع اطراف بررسی شود. همچنین، برای افزایش دقت و بررسی دقیق‌تر مدل آموزش دیده می‌توان گونه‌های دیگری از حشرات مضر یا مفید در کشاورزی را در این دسته بندی لحاظ کرد تا این مدل بهتر بتواند تصمیم‌گیری واقعی تری را اتخاذ کند.

سپاسگزاری

این تحقیق در قالب طرح مزیت استانی با عنوان افزایش بازده و بهبود کیفی مزارع برنج در استان مازندران و با استفاده از اعتبارات ویژه پژوهشی دانشگاه صنعتی نوشیروانی بابل با شماره طرح ۱۰۹۱/م/پ انجام شده است.

نرم‌افزار تنها نرم‌افزار موجود در این حوزه است. به عنوان مثال نرم‌افزار Rice Doctor قابل نصب بر روی گوشی هوشمند بر اطلاعات توصیفی دریافتی از کشاورز از مزرعه استوار بوده و قابلیت پردازش عکس را ندارد (Jearanaiwongkul, Anutariya, Racharak, & Andres, 2021). همان طور که از تحقیقات پیشین به دست آمده استفاده از تکنیک‌های یادگیری ماشین در ارتباط با شناسایی خودکار آفات امری رو به گسترش است اما این تحقیقات پیشین وابسته به سخت‌افزار خاصی مانند بردهای Raspberry Pi می‌باشد (Zhong, Gao, Lei, & Zhou, 2018) که این موضوع باعث محدودیت در استفاده عموم کشاورزان خواهد شد. از طرف دیگر اکثر تحقیقات انجام شده بر اساس اخذ تصویر توسط کارشناس مربوطه بوده و شبکه مورد نظر بر اساس این تصاویر آموزش دیده است. در این تحقیق تصاویر توسط خود کشاورز و با استفاده از واسط کاربری برنامه کشاورز هوشمند برای سامانه ارسال می‌شود. از مزیت ویژه این روش عدم وابستگی به نوع سخت‌افزار مورد استفاده است. از این رو، شبکه عصبی عمیق پیشنهادی در این تحقیق بر اساس داده‌های ارسالی از کشاورز بهینه شده است تا بیشترین همخوانی را با تصاویر تلفن همراه داشته باشد.

نتیجه گیری

استفاده از داده‌های رایگان ارسال شده توسط کشاورزان همواره از جذابیت زیادی برای محققین برخوردار بوده است. در این تحقیق

References

- Ba, J., & Frey, B. (2013). Adaptive dropout for training deep neural networks. *Advances in Neural Information Processing Systems*, 26, 3084-3092.
- Baldi, P., & Sadowski, P. (2014). The dropout learning algorithm. *Artificial Intelligence*, 210, 78-122. <https://doi.org/10.1016/j.artint.2014.02.004>
- Chen, J., Liu, Q., & Gao, L. (2021). Deep Convolutional Neural Networks for Tea Tree Pest Recognition and Diagnosis. *Symmetry*, 13(11), 2140. <https://doi.org/10.3390/sym13112140>
- Chung, C. L., Huang, K. J., Chen, S. Y., Lai, M. H., Chen, Y. C., & Kuo, Y. F. (2016). Detecting Bakanae disease in rice seedlings by machine vision. *Computers and Electronics in Agriculture*, 121, 404-411. <https://doi.org/10.1016/j.compag.2016.01.008>
- Dale, D. (1994). Insect pests of the rice plant—their biology and ecology. *Biology and Management of Rice Insects*, 438, 442.
- Deshpande, T., Sengupta, S., & Raghuvanshi, K. (2014). Grading & identification of disease in pomegranate leaf and fruit. *International Journal of Computer Science and Information Technologies*, 5, 4638-4645.
- Ebrahimi, M., Khoshtaghaza, M. H., Minaei, S., & Jamshidi, B. (2017). Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*, 137, 52-58. <https://doi.org/10.1016/j.compag.2017.03.016>
- Elfwing, S., Uchibe, E., & Doya, K. (2018). Sigmoid-weighted linear units for neural network function approximation in reinforcement learning. *Neural Networks*, 107, 3-11. <https://doi.org/10.1016/j.neunet.2017.12.012>
- Gutierrez, A., Ansuategi, A., Susperregi, L., Tubío, C., Rankić, I., & Lenža, L. (2019). A Benchmarking of Learning Strategies for Pest Detection and Identification on Tomato Plants for Autonomous Scouting Robots Using Internal Databases. *Journal of Sensors*, 5219471. <https://doi.org/10.1155/2019/5219471>
- Hornberg, A. (2017). *Handbook of Machine and Computer Vision: The Guide for Developers and Users*. Wiley-

- VCH. Germany.
11. Jearanaiwongkul, W., Anutariya, C., Racharak, T., & Andres, F. (2021). An Ontology-Based Expert System for Rice Disease Identification and Control Recommendation. *Applied Sciences*, 11(21), 10450. <https://doi.org/10.3390/app112110450>
 12. Jha, K., Doshi, A., Patel, P., & Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2, 1-12. <https://doi.org/10.1016/j.aiia.2019.05.004>
 13. Karabatak, M., & Ince, M. C. (2009). An expert system for detection of breast cancer based on association rules and neural network. *Expert Systems with Applications*, 36, 3465-3469. <https://doi.org/10.1016/j.eswa.2008.02.064>
 14. Khanramaki, M., Askari Asli-Ardeh, E., Kozegar, E., & Loni, R. (2021). Detection of common citrus pests in northern Iran using an artificial neural network. *Journal of Food Science and Technology (Iran)*, 17(109), 143-152. <https://fsc.modares.ac.ir/article-7-43117-en.html>
 15. Kusriani, K., Suputa, S., Setyanto, A., Agastya, I. M. A., Priantoro, H., Chandramouli, K., & Izquierdo, E. (2020). Dataset for pest classification in Mango farms from Indonesia. *Mendeley Data*, VI. <https://doi.org/10.17632/94jf97jzc8.1>
 16. Lu, C. Y., Rustia, D. J. A., & Lin, T. T. (2019). Generative adversarial network based image augmentation for insect pest classification enhancement. *IFAC-PapersOnLine*, 52, 1-5. <https://doi.org/10.1016/j.ifacol.2019.12.406>
 17. Miranda, J. L., Gerardo, B. D., & Tanguilig, B. T. (2014). Pest detection and extraction using image processing techniques. *International Journal of Computer and Communication Engineering*, 3, 189. <https://doi.org/10.7763/IJCCE.2014.V3.317>
 18. Mitchell, T. M., Carbonell, J. G., & Michalski, R. S. (1986). Machine learning: a guide to current research.
 19. Najaf-Zadeh, A., & Ghaffari, H. R. (2020). A Two-Dimensional Convolutional Neural Network for Brain Tumor Detection from MRI. Original. *Quarterly of Horizon of Medical Sciences*, 26(4), 398-413. <https://doi.org/10.32598/hms.26.4.3303.1>
 20. Ngugi, L. C., Abdelwahab, M., & Abo-Zahhad, M. (2020). Tomato leaf segmentation algorithms for mobile phone applications using deep learning. *Computers and Electronics in Agriculture*, 178, 105788. <https://doi.org/10.1016/j.compag.2020.105788>
 21. Opara, L. (2004). *Emerging technological innovation triad for smart agriculture in the 21st century*. Part I. Prospects and impacts of nanotechnology in agriculture.
 22. Pantazi, X. E., Tamouridou, A. A., Alexandridis, T., Lagopodi, A. L., Kontouris, G., & Moshou, D. (2017). Detection of Silybum marianum infection with Microbotryum silybum using VNIR field spectroscopy. *Computers and Electronics in Agriculture*, 137, 130-137. <https://doi.org/10.1016/j.compag.2017.03.017>
 23. Pathak, M. (1968). Ecology of common insect pests of rice. *Annual Review of Entomology*, 13, 257-294.
 24. Pew Research Center. Feb. 05, 2019. Smartphone Ownership Is Growing Rapidly Around the World, but Not Always Equally. www.pewresearch.org/global/2019/02/05/smartphone-ownership-is-growing-rapidly-around-the-world-but-not-always-equally
 25. Pohl, C., Kanniah, K. D., & Loong, C. K. (2016). *Monitoring oil palm plantations in Malaysia*. Pages 2556-2559. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS): IEEE.
 26. Praveen, B., & Sharma, P. (2020). A review: The role of geospatial technology in precision agriculture. *Journal of Public Affairs*, 20, e1968. <https://doi.org/10.1002/pa.1968>
 27. Silveira, M., & Monteiro, A. (2009). Automatic recognition and measurement of butterfly eyespot patterns. *Biosystems*, 95, 130-136. <https://doi.org/10.1016/j.biosystems.2008.09.004>
 28. Soomro, T. R. (2015). GIS enabling smart agriculture. *Smart agriculture: An approach towards better agriculture management*: 1-6.
 29. Soomro, T. R., Naqvi, M. R., & Zheng, K. (2001). GIS: A Weapon to Combat the Crime. Pages 228-230. *Proceedings of the World Multiconference on Systemics, Cybernetics and Informatics: Information Systems Development-Volume I-Volume I*.
 30. Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning? *IEEE Transactions on Medical Imaging*, 35, 1299-1312. <https://doi.org/10.1109/TMI.2016.2535302>
 31. Wen, C., Wu, D., Hu, H., & Pan, W. (2015). Pose estimation-dependent identification method for field moth images using deep learning architecture. *Biosystems Engineering*, 136, 117-128. <https://doi.org/10.1016/j.biosystemseng.2015.06.002>
 32. Yan, Y., Feng, C. C., & Chang, K. T. T. (2017). Towards enhancing integrated pest management based on volunteered geographic information. *ISPRS International Journal of Geo-Information*, 6, 224. <https://doi.org/10.3390/ijgi6070224>
 33. Zhong, Y., Gao, J., Lei, Q., & Zhou, Y. (2018). A Vision-Based Counting and Recognition System for Flying Insects in Intelligent Agriculture. *Sensors*, 18(5), 1489. <https://doi.org/10.3390/s18051489>
 34. Zhu, Z., Zhang, R., & Sun, J. (2009). Research on GIS-based agriculture expert system. Pages 252-255. 2009 WRI World Congress on Software Engineering: IEEE.