



University of Tehran Press

Development of machine vision system for periodic evaluation of honey production efficiency by deep learning method

Mohammad Shojaaddini¹ | Ashkan Moosavian¹ | Sakineh Babaei²

1. Department of Agricultural Engineering, Technical and Vocational University (TVU), Tehran, Iran. E-mail: shojaaddini@tvu.ac.ir
2. Corresponding Author, Department of Agricultural Engineering, Technical and Vocational University (TVU), Tehran, Iran. E-mail: a_moosavian@tvu.ac.ir
3. Department of Agricultural Engineering, Technical and Vocational University (TVU), Tehran, Iran. E-mail: babaei.sara@tvu.ac.ir

Article Info

ABSTRACT

Article type:

Research Article

Article history:

Received: 04 May 2022

Received in revised form:

22 November 2022

Accepted: 24 November 2022

Published online:

24 December 2022

Keywords:

Deep learning,

Honey production efficiency,

Machine vision,

Semantic segmentation method,

YOLOv5 algorithm.

This study was conducted to intelligent and rapid assessment of the status of colonies in terms of honey production efficiency during foraging period, and presenting a method based on machine vision system. By using the deep learning method, at first, their comb frame and then the geometric, textural and color pattern of honey were identified. After that, the percentage of honey area was calculated. To do this, the imaging test of bee colonies using digital camera was designed and performed in such a way that different states of cells were present on the combs. In the image analysis stage, the convolutional neural network with YOLOv5 algorithm and semantic segmentation method were used. The results showed that the present intelligent system has the ability to detect the comb frame from the surrounding environment of the image with an accuracy of more than 88%. Also, honey-related areas in each comb were identified with almost 83% accuracy and about 240 times quicker that of an expert beekeeper. These results were simultaneously confirmed with manual counting by a skilled beekeeper. Due to increase in the estimation speed, reduction of human error and consequently reduction of disruption time in colony activity, the proposed method can be a proper alternative to the traditional method of using framing technique for regular visits and evaluation of honey production efficiency.

Cite this article: Shojaaddini, M., Moosavian, A., & Babaei, S. (2022). Development of machine vision system for periodic evaluation of honey production efficiency by deep learning method. *Journal of animal Production*, 24 (4), 511-521. DOI: <http://doi.org/10.22059/jap.2022.342545.623690>



© The Author(s).

DOI: <http://doi.org/10.22059/jap.2022.342545.623690>

Publisher: University of Tehran Press.



توسعه سامانه بینایی ماشین برای ارزیابی دوره‌ای بازده تولید عسل با روش یادگیری عمیق

محمد شجاع الدینی^۱ | سید اشکان موسویان^{۲*} | سکینه بابایی^۲

۱. گروه مهندسی کشاورزی، دانشگاه فنی و حرفه‌ای، تهران، ایران. رایانمای: shojaaddini@tvu.ac.ir
۲. نویسنده مسئول، گروه مهندسی کشاورزی، دانشگاه فنی و حرفه‌ای، تهران، ایران. رایانمای: a_moosavian@tvu.ac.ir
۳. گروه مهندسی کشاورزی، دانشگاه فنی و حرفه‌ای، تهران، ایران. رایانمای: babaei.sara@tvu.ac.ir

اطلاعات مقاله

چکیده	نوع مقاله: مقاله پژوهشی
این پژوهش، به منظور سنجش هوشمند و سریع وضعیت کلی‌ها از نظر بازده تولید عسل در طی دوره چرا و ارائه یک روش مبتنی بر سامانه بینایی ماشین انجام شد. با بهره‌گیری از روش یادگیری عمیق، در ابتدا محدوده شان و سپس الگوی هندسی، بافتی و رنگی عسل تشخیص داده شد. پس از آن، مقدار درصد مساحت عسل محاسبه شد. برای این کار، آزمون عکس‌برداری توسط دوربین دیجیتال از کلی‌های زنبور عسل به نحوی طراحی و اجرا شد که طی آن وضعیت‌های مختلف عسل روی شان قرار داشت. در مرحله تحلیل تصاویر، از شبکه عصبی کانولوشنی با الگوریتم YOLOv5 و روش بخش‌بندی معنایی استفاده شد. نتایج نشان داد که سامانه هوشمند ارائه شده توانایی شناسایی قاب از محیط پیرامونی تصویر را با دقت بیش از ۸۸ درصد دارد. همچنین نواحی مربوط به عسل در هر شان با دقت حدود ۸۳ درصد و با سرعت حدود ۲۴۰ برابر زنبوردار خبره شناسایی شد. این نتایج بهطور هم‌زمان با شمارش دستی توسط یک زنبوردار ماهر مورد تأیید قرار گرفت. با توجه به افزایش سرعت تخمین، کاهش خطای انسانی و در نتیجه کاهش زمان اختلال در فعالیت کلی، روش ارائه شده می‌تواند جایگزین مناسبی برای روش سنتی استفاده از کادرگذاری به منظور بازدهی‌های دوره‌ای و برآورد بازدهی تولید عسل باشد.	تاریخ دریافت: ۱۴۰۱/۰۲/۱۴ تاریخ بازنگری: ۱۴۰۱/۰۹/۰۱ تاریخ پذیرش: ۱۴۰۱/۰۹/۰۳ تاریخ انتشار: ۱۴۰۱/۱۰/۰۳
کلیدواژه‌ها:	الگوریتم YOLOv5، بازده تولید عسل، بینایی ماشین، روش بخش‌بندی معنایی، یادگیری عمیق.

استناد: شجاع الدینی، م، موسویان، س. ا. و بابایی، س (۱۴۰۱). توسعه سامانه بینایی ماشین برای ارزیابی دوره‌ای بازده تولید عسل با روش یادگیری عمیق. نشریه تولیدات دامی، ۲۴ (۴)، ۵۱۱-۵۲۱. DOI: <http://doi.org/10.22059/jap.2022.342545.623690>



© نویسنده‌ان

ناشر: مؤسسه انتشارات دانشگاه تهران.

۱. مقدمه

زنبور عسل دارای تولیدات متنوعی است که هر کدام از آن‌ها می‌تواند منبع درآمدی برای زنبوردار باشد از جمله این تولیدات می‌توان از عسل، گرده گل، موم، بره موم، ژله رویال و زهر نام برد و عسل مهم‌ترین تولید اقتصادی زنبور عسل در دنیا به ویژه در ایران است. از روش‌های اندازه‌گیری میزان عسل تولید شده، استفاده از شاخص اندازه‌گیری است که این شاخص، یک کادر یا قالب خالی است که توسط نخ موم کشی شده با مربع‌های 5×5 سانتی متر مربعی است. در داخل هر مربع در حدود ۱۰۰ حجم‌ه قرار دارد. این کادر برای اندازه‌گیری میزان عسل مورد استفاده قرار می‌گیرد و بعد از احتساب وزن عسل بهازای هر مربع از شاخص اندازه‌گیری مشخص می‌شود که هر کندو حاوی چه میزان عسل است [۷].

در سال‌های اخیر فناوری‌های جدید شامل بینایی ماشین و پردازش تصویر در حوزه‌های مختلف بخش‌های کشاورزی و دامپروری کاربردهای فراوانی داشته است. بینایی ماشین یکی از انواع سامانه‌های خودکار است که از بینایی انسان تعیت می‌کند. یکی از ازارهای تحلیل که به تازگی جایگاه مقبولی در میان سامانه‌های هوشمند منجمله سامانه‌های بینایی ماشین پیدا کرده است، روش یادگیری عمیق است. یادگیری عمیق زیر شاخه‌ای از یادگیری ماشین است که با الگوریتم‌هایی الهام گرفته شده از ساختار و عملکرد مغز به نام شبکه‌های عصبی مصنوعی مرتبط است. از طریق انواع خاصی از شبکه‌های عصبی که شبکه‌های عصبی کانولوشنی (CNN) نامیده می‌شوند، امکان استخراج اطلاعات از داده‌های بصری وجود دارد [۱۲]. با توجه به متنوع بودن الگوهای رنگی، بافتی و شکلی عسل روی شان کندوهای مختلف، استفاده از روش‌های صرفاً پردازش تصویر نمی‌تواند نتایج خوبی دهد. در شرایط تنوع زیاد اشیایی که قرار است تشخیص داده شوند، استفاده از روش‌های هوش مصنوعی نظریه یادگیری عمیق، عملکردهای درخشنای داشته است. با توجه به بررسی پژوهش‌های پیشین، می‌توان گفت که در حوزه توسعه روش‌های نوین برای شناسایی وضعیت شان‌های کلنی‌های زنبور عسل که یکی از معیارهای اصلی در تعیین بازده تولید عسل برای زنبورداران است، پژوهش‌های کمی صورت گرفته است. به‌طور مثال، پژوهش [۱۸] روشی برای محاسبه خودکار مساحت اشغال شده توسط سلول‌های سرپوشیده و سر باز را توسعه داد. در پژوهش [۴]، روشی برای ارزیابی تصویر شان با توسعه یک روش نیمه‌خودکار که به جای اندازه‌گیری مساحت اشغال شده، تعداد سلول‌های شفیره را شمارش می‌کرد ارائه شد. پژوهش [۹] به ارائه یک نرمافزار تجاری به نام HiveAnalyzer به منظور تحلیل محتواهای سلول‌های شان، بر پایه ترکیبی از طبقه‌بندی‌های مختلف مانند ماشین بُردار پشتیبان خطی و هیستوگرام رنگی پرداخت. در پژوهش‌های جدیدتر، پژوهش [۱۷] روشی برای تشخیص و شمارش خودکار سلول‌های سرپوشیده با استفاده از مفهوم ریاضی همگشت دایره‌ای را توسعه داد. نحوه کار بدین صورت بود که این همگشت به اندازه یک سلول شان بود و در هر موقعیت سلول متوقف شده و کنتراست بین پیکسل‌های لبه سلول و داخل آن را محاسبه می‌کرد. با توجه به مقدار کنتراست و آستانه‌های رنگی تعریف شده، سلول‌های سرپوشیده از سلول‌های سر باز تمایز می‌شوند. پژوهش [۳] نرمافزاری تحت عنوان CombCount برای ارزیابی عسل سربسته و شفیره برپایه به کارگیری از روش‌های پردازش تصویر نظریه گلوریتم تشخیص دایره گرادیان هاف (Hough) را توسعه داد. به تازگی در پژوهش [۲]، به ارائه یک روش هوشمند برای تشخیص و طبقه‌بندی سلول‌های شان کندوی زنبور عسل با استفاده از شبکه‌های عصبی کانولوشنی پرداختند. در این مطالعه، یک تونل چوبی برای عکس‌برداری از شان‌ها ساخته شد که درون آن، یکسری LED‌ها با زوایای خاص تعییه شد تا تصاویر گرفته شده از شان، مستقل از اثرات نور محیطی باشد. باوجود دقت بالایی که در تشخیص وضعیت سلول‌های شان بدست آمد، یکی از نواقص این پژوهش که کاربرد آن را در عمل محدود می‌کند، الزام استفاده از تونل چوبی و سامانه نورپردازی خاص برای فرایند عکس‌برداری است. این امر باعث افزایش زمان و هزینه اجرای آن می‌شود.

هدف از انجام مطالعه، ارائه روشی نوین برای شناسایی میزان عسل داخل هر شان از کلنی‌های زنبور عسل و به دست آوردن مقدار درصد عسل در هر شان با هدف تعیین بازده تولید آن، بر پایه روش بینایی ماشین و یادگیری عمیق است. سامانه بینایی ماشین طراحی شده، قادر است به طور خودکار، قاب شان را از دیگر بخش‌های پیرامونی تصویر جدا کرده و سپس به شناسایی نواحی مربوط به عسل سرساخته بپردازد. بر همین اساس، فرایند تحلیل به دو دسته تشخیص قاب و شناسایی عسل سرساخته تقسیم شده است. شکل (۱) مراحل کار در این مطالعه را نشان می‌دهد.



شکل ۱. نمونه روند نمای مطالعه حاضر

۲. مواد و روش‌ها

برای انجام این پژوهش، تعداد ۳۰ کلنی زنبورستان متعلق به زنبورداران یکی از اعضای اتحادیه زنبورداران ایران واقع در استان البرز انتخاب شد. نژاد غالب زنبوران عسل در این زنبورستان، نژاد ایرانی مدا بود. برای انجام آزمون عکس‌برداری، از یک دوربین دیجیتال مدل Samsung SM-A307F، ۲۵ مگاپیکسل با لنز پهنه ۲۷ میلی‌متر، دیافراگم ۱۰۰-۸۰۰ f/1.7 ISO ۱/۴۰۰۰، تنظیم خودکار فاصله کانونی، بدون فلاش و با پسوند ذخیره‌سازی JPEG استفاده شد. فاصله دوربین از شان‌ها، ۲۰ سانتی‌متر و رزولوشن تصاویر روی ۲۴,۸۸ مگاپیکسل (۵۷۶۰×۴۳۲۰ px) تنظیم شد. طی بازدید صورت گرفته، تعداد ۸۰ عکس از وضعیت‌های مختلف شان در بازه زمانی ۱۱ صبح الی ۱۲ ظهر گرفته شد.

به منظور تحلیل تصاویر گرفته شده از شان کلنی‌های زنبور عسل، از شبکه عصبی کانولوشنی با الگوریتم YOLOv5 و شبکه Mask-RCNN استفاده شد. یک CNN شامل سه نوع اصلی از لایه‌های عصبی است که عبارتند از لایه‌های کانولوشنی، لایه‌های Pooling و لایه Fully-connected، که هر نوع لایه نقش متفاوتی دارد. هر لایه CNN حجم ورودی را به حجم خروجی از فعال‌سازی نورون تبدیل می‌کند و در نهایت به لایه‌های کاملاً متصل نهایی منجر می‌شود و در نتیجه، داده‌های ورودی به بردار ویژگی یک بعدی نگاشت می‌شود. شبکه‌های عصبی کانولوشنی به دلیل استفاده‌هایی که در تشخیص و ردیابی اشیا دارند، در زمینه‌های مختلفی در حوزه پردازش تصویر و بینایی ماشین کاربرد داشته و بسیار موفق نیز بوده‌اند. یک نسخه توسعه‌یافته از شبکه‌های عصبی کانولوشنی، الگوریتم شبکه عصبی R-CNN

است [۵]. الگوریتم تشخیص شی RCNN، یک تصویر را به چندین ناحیه تقسیم می‌کند و هر یک را برای چندین تکرار پردازش می‌کند. این روش بهدلیل نحوه عملکردی آن، برای مسائل بلاذرنگ قابل اجرا نبود، لذا اصلاح شد. بهدلیل زمان موردنیاز برای آموزش الگوریتم و شناسایی و طبقه بنده اشیا، دو تغییر سریعتر ایجاد شد که Fast R-CNN بود [۶]. فرایند آموزش سرتاسر سریع‌تر را ارائه می‌کند، اما هنوز برای شناسایی بلاذرنگ مناسب نیست. Faster R-CNN [۱۶] که از یک CNN جدا شده برای پیش‌بینی و شکل‌دادن به مناطق موردنظر که به شبکه تقدیم می‌شود، استفاده می‌کند، بهدلیل زمان بسیار کوتاه موردنیاز برای تشخیص روی یک تصویر، برای کاربردهای بلاذرنگ و دستیابی به دقت‌های زیاد مناسب است [۱۴].

شبکه‌های عصبی عمیق نیز برای بخش‌بندی معنایی تصاویر بسیار کارا هستند، که هر ناحیه یا پیکسل را با کلاسی از اشیا/ غیر اشیا برچسب‌گذاری می‌کنند. بخش‌بندی معنایی نقش مهمی در درک تصویر ایفا می‌کند و برای کارهای تجزیه و تحلیل تصویر ضروری است. نسخه توسعه یافته Faster-RCNN، یعنی Mask R-CNN [۸] از نظر تقسیم‌بندی تصویر پیشرفت‌ه است. این روش، پیکسل‌های دقیق هر شی را به جای جعبه‌های محصور‌کننده مشخص می‌کند. این نوع از شبکه عصبی عمیق، اشیا را در یک تصویر شناسایی می‌کند و برای هر نمونه یک ماسک تقسیم‌بندی با کیفیت بالا ایجاد می‌کند. Mask R-CNN با استفاده از Faster R-CNN ساخته شده است. در حالی که Faster R-CNN دارای دو خروجی برای هر شی منتخب، برچسب کلاس و آفست جعبه محصور‌کننده است، Mask R-CNN افزودن شاخه سومی است که ماسک شی را خروجی می‌دهد.

با توجه به انتخاب روش‌های بینایی مашین و استفاده از شبکه‌های عصبی عمیق و کانولوشنی، تعدادی مدل از قبل آموزش‌دیده که از نظر محاسباتی مناسب و عملکرد فوق العاده بالایی دارند وجود دارد. در این بین سیستم‌های تشخیص اشیای RCNN [۵] و خانواده YOLO [۱۵]، جزو معروف‌ترین روش‌ها هستند. طبق بررسی‌های انجام‌شده، ثابت شده است که YOLOv5 [۱۰] از سایر سیستم‌های تشخیص اشیا عملکرد بهتر [۱۱] و زمان پردازش شبکه‌های عمیق در آن به میزان قابل توجهی کمتر است. این ویژگی هنگامی که تحلیل به سمت مجموعه داده‌های بزرگ‌تر و شناسایی بلاذرنگ سوق پیدا می‌کند، اهمیت بالاتر دارد. YOLOv5 در مجموعه داده‌های COCO، یک مجموعه داده گسترده برای تشخیص اشیا شامل بانک داده بزرگ حاوی دو میلیون عکس از ۸۰ کلاس مختلف است که تمام شبکه‌های معروف برای پیش‌پردازش، از این بانک داده برای وزن‌دهی اولیه لایه‌های شبکه خود استفاده می‌کنند [۱۳]. بنابراین YOLOv5 می‌تواند به عنوان نقطه شروعی برای یک مدل تغییریافته برای تشخیص ویژگی‌های آن باشد.

در پژوهش حاضر، شبکه CNN با الگوریتم YOLOv5 و شبکه Mask-RCNN مطابق با متغیرهای پیکربندی Number_Mask_Pool_Size، Learning_Rate، Learning_Momentum، Backbone_Strides، Backbone_Number، Mask_Pool_Size، Learning_Rate، Learning_Momentum، Backbone_Strides، Backbone_Number، Loss Function، Pool_Size، Steps_per_Epoch، Epochs، Resnet101، به ترتیب با مقادیر [۴، ۸، ۱۶، ۳۲، ۱۰۱، ۰/۰۹، ۰/۰۱، ۱۴، ۳۰۰، ۱۰، ۰/۰۷، ۰/۰۱، هفت، ۰/۰۱]، استفاده شد. بر همین اساس، پس از آن که تصویربرداری از شان‌ها به‌طور کامل صورت گرفت، این تصاویر به شبکه‌های عصبی کانولوشنی داده شد تا فرایند یادگیری آن‌ها انجام شود. شایان ذکر است که مدل در ابتدا باید بتواند قاب (چارچوب) شان در تصویرها را به درستی تشخیص دهد، سپس به شناسایی میزان عسل سربسته پردازد. این کار به‌ویژه برای کاربردهای عملی، بسیار حائز اهمیت است.

۳. نتایج و بحث

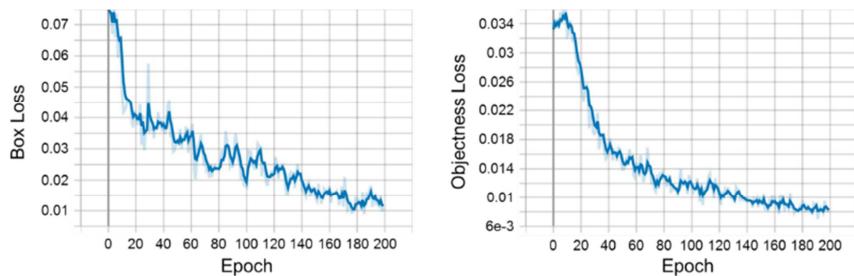
برای تشخیص قاب شان، در فرایند آموزش، از مجموع ۴۷ تعداد تصاویر اخذ شده، حدود ۸۰ درصد یعنی ۳۸ تصویر به

آموزش شبکه و نه تصویر برای اعتبارسنجی در نظر گرفته شد. شایان ذکر است غنای موجود برای آموزش شبکه با تعداد ۴۷ تصویر در حد کفايت بود. در ادامه، بهمنظور ایجاد پایگاه داده‌های آموزش، کلیه تصاویر با روش جعبه محصور کننده، برچسب‌گذاری شدن بدین ترتیب که به صورت دستی، بخشی از تصویر که مربوط به قاب شان بود، مطابق با شکل (۲) توسط جعبه محصور کننده، از دیگر قسمت‌های تصویر جداسازی و سپس قسمت جداسده با نام frame، نام‌گذاری شد. این کار برای کلیه تصاویر آموزش انجام شد تا مشخصات رنگی، بافتی و شکلی قاب، به مدل شبکه عصبی عمیق، آموزش داده شود.



شکل ۲. نمونه تصویر برچسب‌گذاری شده برای تشخیص قاب شان

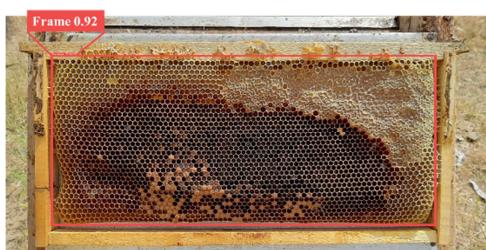
فرایند یادگیری این مدل، توسط Google Collab انجام شد که دسترسی آزاد به GPU‌های رایگان را فراهم می‌کند. بدین ترتیب از شبکه YOLOv5 با وزن‌های از پیش آماده شده COCO برای شروع یادگیری روی داده‌های آموزش، استفاده شد. فرایند یادگیری تا ۲۰۰ بار تکرار شد. کل این فرایند آموزش حدود ۳۰ دقیقه به طور انجامید. یکی از معیارهای اصلی ارزیابی آموزش شبکه، متغیر loss است. سه نوع مختلف این متغیر که برای ارزیابی احتمال وجود شی بررسی می‌شود، متغیرهای box loss، Classification loss و Objectness loss است. متغیر box loss نشان می‌دهد که چگونه الگوریتم می‌تواند مرکز یک جسم را تعیین کند و چگونه جعبه محصور کننده پیش‌بینی شده، یک شی را به خوبی پوشش می‌دهد. متغیر Objectness loss در اصل معیاری از احتمال وجود یک شی در یک ناحیه پیشنهادی است. اگر objectivity زیاد باشد، این بدان معناست که تصویر احتمالاً حاوی یک شی است. Classification loss نیز به این منظور می‌پردازد که الگوریتم چقدر می‌تواند کلاس صحیح یک شی را پیش‌بینی کند. شکل (۳) نمودار تغییرات سه متغیر loss برای فرایند آموزش شبکه طراحی شده برای تشخیص قاب شان را نشان می‌دهد. همان‌طور که در این شکل دیده می‌شود، متغیرهای box loss، Classification loss و Objectness loss در ابتدا کمترین مقدار را دارند و با افزایش این مقدارها، در مراحل بعدی این مقدارها افزایش می‌یابند. پس از ۲۰۰ اپیک، بهترتیب به مقادیر 0.011×10^{-3} ، صفر و 0.008×10^{-3} رسیدند. با توجه به این مقادیر، مدل از نظر دقت برای تشخیص قاب شان بسیار مناسب بود.



شکل ۳. نمودار متغیرهای مختلف ارزیابی فرایند آموزش شبکه طراحی شده برای تشخیص قاب شان

پس از اتمام فرایند آموزش شبکه و به دست آوردن معیارهای مربوطه که مقادیر آن‌ها در شکل (۳) نشان داده شده است، ارزیابی این فرایند روی مجموعه داده‌های اعتبارسنجی شامل نه تصویر انجام شد. نمونه‌ای از نتیجه این فرایند برای یک نمونه از تصاویر، در شکل (۴) نشان داده شده است. همان‌طور که در شکل ملاحظه می‌شود، قاب شان به درستی و با دقت مناسبی تشخیص داده شده است. ارزیابی عملکرد کلی آموزش شبکه نشان داد که شبکه طراحی شده توانست قاب شان‌ها را با دقت حدوداً ۸۸ درصد به درستی از محیط پیرامونی تشخیص دهد و آن را جداسازی کند. بنابراین می‌توان از این مدل در به دست آوردن چارچوب شان و جداسازی آن از محیط پیرامون استفاده کرد. بدین ترتیب که پس از تشکیل چارچوب تشخیص داده شده حول جسم مورد نظر که در این مدل قاب شان است، مختصات گوشه‌های چارچوب به فرمت YOLO استخراج می‌شود. باید دقت شود که این مختصات همان مختصات موقعیتی نقاط گوشه‌های داخلی قاب شان است. با داشتن داده‌های این مختصات مکانی، می‌توان قاب شان را از دیگر نواحی تصویر جداسازی کرد. برهمین اساس، سامانه هوشمند طوری طراحی شد که با گرفتن تصویر، اولاً قاب شان را برای هر تصویر به درستی تشخیص دهد و سپس داده مختصات موقعیتی قاب را به عنوان خروجی تحويل دهد تا بتوان براساس آن، مجموعه قاب و محتويات شان را از دیگر قسمت‌های تصویر جدا کرد. شکل (۵) نمونه‌ای از فرایند جداسازی شان از نواحی دیگر تصویر را نشان می‌دهد.

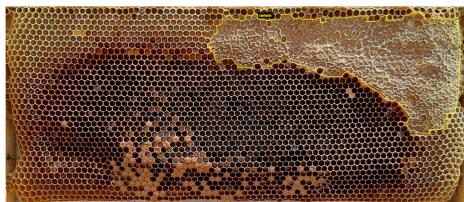
پس از جداسازی موفق مجموعه شان از محیط پیرامون آن در تصویر، به تشخیص نواحی مربوط به عسل داخل شان پرداخته شد. یک مدل یادگیری عمیق توسط تصاویر مختلف شان جداسازی شده به وسیله مدل یادگیری عمیق قبلی که حاوی شرایط گوناگون عسل تولیدی بود، مورد آموزش قرار گرفت. برای این کار، از مجموع ۶۹ تعداد تصاویر، حدود ۵۳ تصویر به آموزش شبکه و ۱۴ تصویر برای اعتبارسنجی در نظر گرفته شد. در مرحله آموزش، کلیه تصاویر به روش جعبه محصور کننده برچسب‌گذاری شدند بدین ترتیب که به صورت دستی، بخشی از تصویر شان که مربوط به نواحی عسل بود، مطابق با شکل (۶) از دیگر سلول‌های داخل شان، جداسازی و سپس قسمت جداسده با نام sarbaste، نام‌گذاری شد. این کار برای کلیه تصاویر آموزش انجام شد تا مشخصات رنگی، بافتی و شکلی عسل، به مدل شبکه عصبی عمیق، آموزش داده شود.



شکل ۴. نمونه‌ای از تشخیص قاب شان توسط مدل شبکه عمیق آموزش دیده



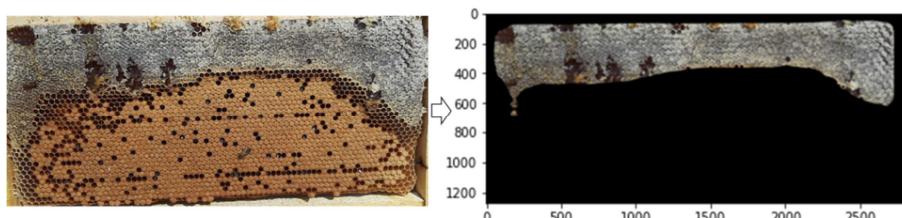
شکل ۵. نمونه فرایند جداسازی شان از تصویر؛ (الف) تصویر اصلی، (ب) قاب تشخیص داده شده، (ج) جداسازی قاب از دیگر نواحی



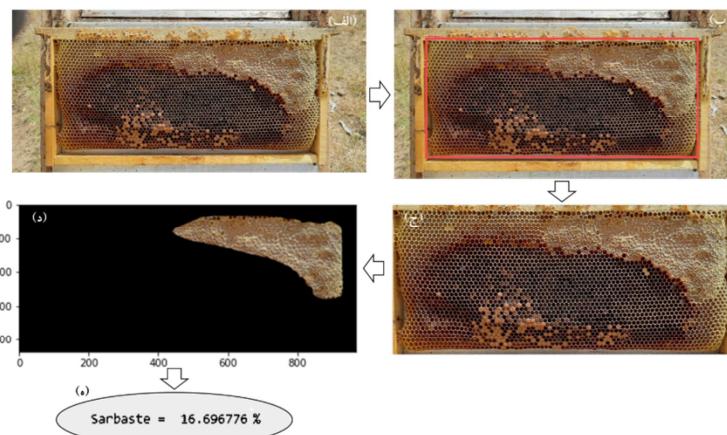
شکل ۶. نمونه تصویر برچسب‌گذاری شده برای تشخیص عسل داخل شان

فرایند یادگیری این مدل، همانند مدل تشخیص قاب، توسط Google Collab و از طریق شبکه Mask-RCNN با شبکه کانولوشنی Resnet ۱۰۱ و روش بخش‌بندی معنایی با تعداد تکرار ۳۰۰ ایپاک برای شروع یادگیری روی داده‌های آموزش، انجام شد. شایان ذکر است به منظور افزایش داده‌های آموزش و تقویت یادگیری شبکه، از فرایند افزونگی تصادفی داده که یکی از روش‌های مرسوم در آموزش‌های شبکه‌های کانولوشنی است [۲]، توسط کتابخانه IMGAUG استفاده شد. با این کار، تعداد داده‌های آموزش در هر ایپاک هشت تا ۱۰ برابر شد. کل فرایند آموزش در این مرحله، حدود ۲۰ ساعت به طور انجامید. پس از سپری شدن ۳۰۰ ایپاک، متغیرهای عملکردی آموزش شبکه [۱] شامل loss، mrcnn_mask_loss و mrcnn_bbox_loss، mrcnn_class_loss، rpn_bbox_loss، rpn_class_loss به ترتیب به مقادیر $۰.۰/۰.۱۱۶۴$ ، $۰.۰/۰.۱۳۹$ ، $۰.۰/۰.۱۵۹$ و $۰.۰/۰.۴۱۳$ رسید. با توجه به این مقادیر، مدل از نظر دقت، برای شناسایی عسل داخل شان بسیار قابل قبول بود.

نمونه‌ای از نتیجه ارزیابی فرایند آموزش شبکه برای یک نمونه شان، در شکل (۷) نشان داده شده است. همان‌طور که در شکل ملاحظه می‌شود، نواحی مربوط به عسل به درستی و با دقت مناسبی تشخیص داده شده است. نتایج ارزیابی عملکرد کلی آموزش شبکه نشان داد که شبکه طراحی شده توانست عسل داخل شان‌های مختلف را با دقت ۸۳ درصد به درستی شناسایی کند. بنابراین می‌توان از این مدل در به دست آوردن مساحت عسل داخل شان استفاده کرد. بدین ترتیب که پس از شناسایی و مربنده نواحی تشخیص داده شده مربوط به عسل، مختصات و تعداد تمامی پیکسل‌هایی که در این ناحیه قرار دارند، استخراج می‌شود. از طرف دیگر، تعداد کل پیکسل‌های مجموعه داخل قاب شان با مساحت واقعی آن که با خطکش اندازه‌گیری شده است، متناسب می‌شود. لذا با انجام عملیات نسبت‌گیری، مساحت نواحی اشغال شده توسط عسل، به دست می‌آید. همچنین با تقسیم تعداد پیکسل‌های نواحی مربوط به عسل، به کل پیکسل‌های مجموعه داخل شان، درصد مساحت اشغال شده از شان توسط عسل نیز قابل محاسبه است. بر همین اساس، سامانه هوشمند طوری طراحی شد که با گرفتن تصویر شان، اولاً عسل داخل شان را برای هر تصویر به درستی تشخیص دهد و سپس مختصات موقعیتی پیکسل درون ناحیه عسل را تحويل دهد تا بتوان براساس آن، مساحت و درصد مساحت اشغال شده توسط عسل را تعیین کرد. شکل (۸) نمونه‌ای از کل فرایند تعیین درصد مساحت عسل داخل شان با استفاده از شبکه‌های طراحی شده را نشان می‌دهد.



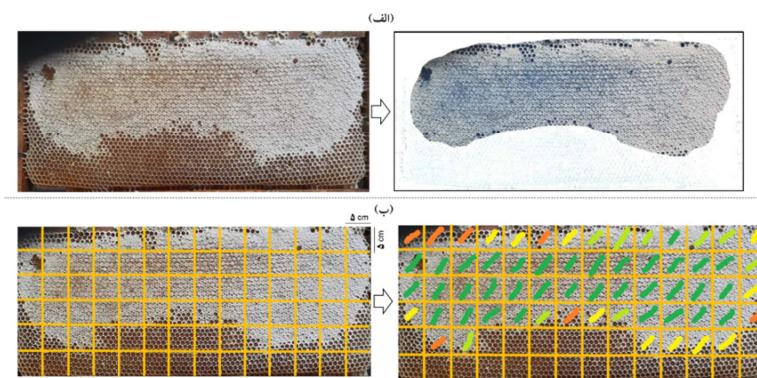
شکل ۷. نمونه‌ای از شناسایی عسل داخل شان توسط مدل شبکه عمیق آموزش دیده



شکل ۸. فرایند تعیین درصد مساحت عسل برای یک نمونه تصویر شان: (الف) تصویر اصلی، (ب) تشخیص محیط داخلی قاب شان، (ج) جداسازی قاب از کل تصویر، (د) شناسایی نواحی عسل داخل شان، (ه) درصد مساحت محاسبه شده عسل.

در گام نهایی، پس از دست‌یابی به دقت مطلوب برای تشخیص قاب شان و عسل داخل آن، به منظور اعتبارسنجی شبکه برای به کاربردهای عملی، نتایج خروجی شبکه با نتایج روش سنتی کادربندی که توسط یک زنبوردار خبره به دست آمد، مقایسه شد. بدین منظور تصویر گرفته شده از یک نمونه شان به شبکه داده شد، و به موازات همان شان در اختیار زنبوردار خبره قرار گرفت تا هر دو، درصد مساحت نواحی پوشیده شده از عسل در شان را تعیین کند.

شکل (۹) خروجی شبکه و شماتیک تحلیل زنبوردار خبره به روش کادرگذاری را نشان می‌دهد. با توجه به نتایج، مقدار عسلی که شبکه در داخل این شان شناسایی کرده است، $53/9$ درصد از کل مساحت شان بود. از طرف دیگر زنبوردار خبره تشخیص داد که $59/5$ درصد از مساحت کل شان، از عسل پوشیده شده است. مقایسه اعداد نشان می‌دهد که یک اختلاف نه درصدی میان نتایج شبکه و زنبوردار خبره وجود دارد. اما مدت زمانی که شبکه برای شناسایی عسل در شان سپری کرد، $0/25$ ثانیه بود، درحالی که این زمان برای زنبوردار خبره به حدود سه تا چهار دقیقه رسید. به بیان دیگر، شبکه توانست نتیجه تحلیل زنبوردار خبره را حدود 240 برابر سریع‌تر تشخیص دهد. این نتایج حاکی از برتری روش ارائه شده نسبت به استفاده از نیروی انسانی ماهر است، زیرا این روش می‌تواند بسیار سریع‌تر از یک زنبوردار ماهر، مقدار عسل هر شان را به دقت تشخیص دهد. بنابراین می‌توان نتیجه گرفت که روش ارائه شده قادر است به طور قابل اطمینانی در شناسایی مقدار عسل موجود در کلنی‌های زنبور عسل استفاده شود. استفاده از این روش می‌تواند برتری‌های نسبی در ابعاد زمان، دقت، هزینه و نیروی انسانی ایجاد کند.



شکل ۹. شناسایی مقدار عسل در شان توسط (الف) روش هوشمند طراحی شده، (ب) زنبوردار خبره به روش کادرگذاری.

در انتهای این بخش، روش ارائه شده در پژوهش حاضر، با روش‌های گزارش شده در پژوهش‌های گذشته مقایسه می‌شود، اگرچه این مقایسه ممکن است به موجب عدم یکسان بودن اندازه مجموعه داده‌ها، تعداد حالت (کلاس) سلول‌های شان و روش‌های تحلیل به کار گرفته شده، همواره منصفانه نباشد. در پژوهش [۴]، روشی نیمه‌خودکار برای شمارش و تحلیل سلول‌های حاوی شفیره ارائه شد که شامل بخش‌بندی دستی ناحیه شفیره و به دنبال آن شمارش خودکار تعداد سلول‌ها بود. این فرایند نیمه‌خودکار زمانی در حدود ۱۹ ثانیه برای گرفتن تصویر و ۳۰ ثانیه برای پردازش تصویر لازم داشت. درحالی که مدت زمان پردازش تصویر شان در مطالعه حاضر، حدوداً یک ثانیه می‌باشد. در پژوهش [۲] که جزو جدیدترین پژوهش‌های این حوزه است، با آزمون‌های تصویربرداری کاملاً کنترل شده شامل طراحی و به کارگیری یک تونل مجهز به دوربین و نورپردازی خاص، دقت حدوداً ۹۴ درصد در تشخیص حالت‌های مختلف سلول‌های شان گزارش شد. درحالی که در پژوهش حاضر، با تجهیزات آزمون ساده‌تر و در دسترس شامل دوربین گوشی همراه و بدون بهره‌گیری از شرایط نورپردازی کنترل شده و تنها تحت شرایط نوری محیطی که زنبوردار با آن مواجه است، دقت تشخیص ۸۳ درصد به دست آمد. به علاوه روش ارائه شده در پژوهش حاضر دارای قابلیت جداسازی خودکار قاب شان از دیگر نواحی تصویر است به بیان دیگر لازم نیست زنبوردار شان را همانند پژوهش [۲]، در یک موقعیت و زاویه ثابت تحت نورپردازی خاص تنظیم کرده و سپس عکس‌برداری را انجام دهد، بلکه در هر شرایطی که قادر به عکس‌برداری باشد، این روش قادر به تحلیل کامل آن شان با دقت بالا است. بنابراین سامانه بینایی ماشین طراحی شده در این پژوهش، منطبق بر شرایط واقعی کاری زنبورداران بوده و نسبت به پژوهش‌های گذشته، کاربردی‌تر و کم هزینه‌تر می‌باشد. نتایج مطالعه حاضر نشان داد که روش شبکه عصبی کانولوشنی با الگوریتم YOLOv5 برای تشخیص قاب شان و روش بخش‌بندی معنایی با مدل شبکه عصبی کانولوشنی Resnet101 برای شناسایی سلول‌های حاوی عسل، به ترتیب با دقت‌های ۸۸ و ۸۳ درصد عملکرد مناسبی داشتند.

با توجه به نتایج مذکور، روش ارائه شده به دلیل دقت و سرعت زیاد آن، می‌تواند به عنوان جایگزین روش ستی کادربندی و بازدید چشمی شان که علاوه بر صرف زمان و هزینه زیاد، مشقت فراوانی را برای نیروی کارگری به همراه دارد، برای تشخیص خودکار مقدار عسل شان کلینی‌های زنبور عسل به طور قابل اطمینانی استفاده شود. پژوهش‌های اینده می‌تواند حول توسعه نرم‌افزاری سامانه ارائه شده در قالب یک اپلیکیشن، متمرکز شود تا در کاربرد واقعی، زنبورداران بتوانند از طریق گوشی‌های هوشمند از آن استفاده نمایند.

۵. تشکر و قدردانی

از معاونت پژوهش و فناوری دانشگاه فنی و حرفه‌ای برای تأمین هزینه طرح پژوهشی کد ۱۳۲/۴۰۰/۹۹/۲۵ و همچنین از مجموعه تولیدی «عسل مدا» به مدیریت سرکار خانم ریسی و همسر محترم ایشان به موجب در اختیار قراردادن زنبورستان خود برای اجرای آزمون‌های عکس‌برداری و جناب آقای علیرضا حسینی دانشجوی مقطع کارشناسی دانشگاه علم و صنعت به خاطر همکاری صمیمانه در بخش تحلیل داده‌ها، تشکر و قدردانی می‌گردد.

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسنده‌گان وجود ندارد.

۷. منابع مورد استفاده

1. Aljazaeri M, Bazi Y, AlMubarak H and Alajlan N (2020) Faster R-CNN and DenseNet regression for glaucoma detection in retinal fundus images. In: 2020 2nd International Conference on Computer and Information Sciences (ICCIS), IEEE. 1-4.
2. Alves TS, Pinto MA, Ventura P, Neves CJ, Biron DG, Junior AC, de Paula Filho PL and Rodrigues PJ (2020) Automatic detection and classification of honey bee comb cells using deep learning. Computers and Electronics in Agriculture, 170: 105244.
3. Colin T, Bruce J, Meikle WG and Barron AB (2018) The development of honey bee colonies assessed using a new semi-automated brood counting method: CombCount. PLoSOne, 13: e0205816.
4. Cornelissen B, Schmid S, Henning J and Der JV (2009) Estimating colony size using digital photography. In: of 41st International Apicultural Congress. 48.
5. Girshick R, Donahue J, Darrell T and Malik J (2014) Rich feature hierarchies for accurate object detection and semantic segmentation. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 580-587.
6. Girshick R (2015) Fast r-cnn. In: Proceedings of the IEEE International Conference on Computer Vision. 1440-1448.
7. Hajizadeh R, Iraqi M, Safamehr A and Asadi A (2013) Effect of pollen substitutes on honey production performance in bee colonies. National Conference on Livestock and Poultry Nutrition, Islamic Azad University, Maragheh Branch, Iran.
8. He K, Gkioxari G, Dollár P and Girshick R (2017) Mask r-cnn. Proceedings of the IEEE International Conference on Computer Vision. Honolulu. HI, USA.
9. Höferlin B, Höferlin M, Kleinhenz M and Bargen H (2013) Automatic analysis of apis mellifera comb photos and brood development. In: Association of Institutes for Bee Research Report of the 60th Seminar in Würzburg Apidologie. 19.
10. Jocher G, Stoken A and Borovec J (2020) NanoCode012, ChristopherSTAN, L. Changyu, Laughing, tkianai, A Hogan, lorenzomammana, yxNONG, AlexWang1900, L Diaconu, Marc, wanghaoyang0106, ml5ah, Doug, F Ingham, Frederik, Guilhen, Hatovix, J Poznanski, J Fang, L Yu, changyu98, M Wang, N Gupta, O Akhtar, PetrDvoracek, and P Rai, "ultralytics/yolov5: v3 1.
11. Kim JA, Sung JY and Park SH (2020) Comparison of Faster-RCNN, YOLO, and SSD for real-time vehicle type recognition. In: 2020 IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia). IEEE. 1-4.
12. LeCun Y, Bengio Y and Hinton G (2015) Deep learning. Nature, 521: 436-444.
13. Lin TY, Maire M, Belongie S, Hays J, Perona P, Ramanan D, Dollár P and Zitnick CL (2014) Microsoft coco: Common objects in context. In: European Conference on Computer Vision, Springer. 740-755.
14. Nuzzi C, Pasinetti S, Lancini M, Docchio F and Sansoni G (2018) Deep learning based machine vision: first steps towards a hand gesture recognition set up for collaborative robots. In: 2018 Workshop on Metrology for Industry 4.0 and IoT, IEEE. 28-33.
15. Redmon J, Divvala S, Girshick R and Farhadi A (2016) You only look once: Unified, real-time object detection. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 779-788.
16. Ren S, He K, Girshick R and Sun J (2015) Faster r-cnn: towards real-time object detection with region proposal networks. Advances in Neural Information Processing Systems: 28.
17. Rodrigues PJ, Neves C and Pinto MA (2016) Geometric contrast feature for automatic visual counting of honey bee brood capped cells. In: EURBEE 2016: 7th European Conference of Apidology.
18. Yoshiyama M, Kimura K, Saitoh K and Iwata H (2011) Measuring colony development in honey bees by simple digital image analysis. Journal of Apicultural Research, 50: 170-172.