

چارچوبی برای استخراج آناتومی و طبقه بندی تصاویر پشه با رویکرد یادگیری عمیق

مرضیه زارع نظری^۱، محسن سرداری زارچی^{۲*}، سیما عمادی^۳ و هادی پورمحمدی^۴

اطلاعات مقاله	چکیده
<p>نوع مقاله: پژوهشی دریافت مقاله: ۱۴۰۱/۱۱/۲۵ بازنگری مقاله: ۱۴۰۱/۰۲/۰۳ پذیرش مقاله: ۱۴۰۱/۰۲/۱۸</p>	<p>پشه‌ها عامل اصلی انتشار بیماری‌های خطرناک مانند مالاریا، تب زرد، تب دانگ و زیکا هستند. موثرترین روش کنترل این دسته از بیماری‌ها، شناسایی صحیح انواع گونه‌های پشه است. در روش شناسایی پشه‌ها به شیوه سنتی، تعیین هویت بر اساس تشخیص‌های مرفولوژیکی توسط انسان‌های متخصص با مهارت‌های خاص صورت می‌گیرد. مهمترین چالش طبقه‌بندی کاهش تعداد افراد خبره و تنوع زیاد گونه‌های مختلف پشه است. به منظور غلبه بر این چالش، توسعه یک روش خودکار بر اساس معماری‌های یادگیری عمیق برای شناسایی و طبقه‌بندی پشه‌ها منبع ارزشمندی برای افراد غیرمتخصص خواهد بود. هدف از این پژوهش، ارائه مدلی از نوع شبکه کانولوشنی به‌منظور طبقه‌بندی تصاویر پشه با ادغام معماری ResNet101 و تکنیک Mask_RCNN می‌باشد. ۲۳۵۴ تصویر پشه از سه گونه آنوفل، آندس و کولکس با یکدیگر مقایسه می‌شوند. در مدل پیشنهادی به جای ورودی شبکه به صورت تصویر کامل پشه ابتدا تصاویر طبقه‌بندی شده و سپس قسمت‌های مختلف شکم، پا، بال و سر به عنوان ورودی به شبکه داده می‌شود. ماسک باینری متناظر از اجزای تشریح شده بدن پشه توسط شبکه کانولوشن جهت استخراج ویژگی برای هر قسمت مجزا تولید می‌شود و سپس مقدار زبان بین مقادیر طبقه‌بندی شده و برچسب تصاویر محاسبه می‌شود. نتایج ارزیابی نشان داد استخراج تصاویر آناتومی پشه بر طبقه‌بندی سریع‌تر تصاویر تأثیر می‌گذارد و شبکه با دقت ۹۷/۸۴ درصد نسبت به حالت معمولی بهتر عمل کرده است.</p>
<p>واژگان کلیدی: یادگیری عمیق، شبکه عصبی کانولوشن، Mask-RCNN، دسته بندی، قطعه بندی، پشه.</p>	

۱-مقدمه

هم هر ساله باعث مرگ بیش از چندین هزار نفر در سراسر جهان می‌شود. این حشرات، میلیون‌ها سال است که با انسان زندگی می‌کنند. در واقع آن‌ها در پیدا کردن انسان‌ها و انتقال بیماری‌هایی که ناقل آن هستند بسیار ماهرند و کنترل این پشه‌ها برای انسان‌ها بسیار پیچیده است [۲].
 مهمترین چالش شناسایی و طبقه‌بندی پشه‌ها کاهش تعداد افراد متخصص با مهارت تشخیص و دشواری شناسایی گونه‌های مختلف پشه به روش سنتی می‌باشد [۳].

طبق گفته‌ی سازمان بهداشت جهانی، پشه‌ها بدترین ناقل بیماری هستند که موجب شیوع بیماری‌هایی از جمله مالاریا، تب دنگی و تب زرد می‌شوند و سالانه میلیون‌ها انسان جان خود را در اثر ابتلا به این بیماری‌ها از دست می‌دهند [۱]. به‌عبارت دیگر، مردم دنیا دائم با بیماری‌هایی تهدید می‌شوند که پشه‌ها ناقل آن هستند. پشه‌ها علت بسیاری از مشکلات در جهان هستند. بیماری‌هایی شبیه مالاریا هنوز

*پست الکترونیک نویسنده مسئول: sardari@meybod.ac.ir

۱. دانشجوی دکتری، دانشکده تحصیلات تکمیلی، گروه مهندسی کامپیوتر، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران

۲. استادیار، دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر، دانشگاه میبد، میبد، ایران

۳. استادیار، دانشکده تحصیلات تکمیلی، گروه مهندسی کامپیوتر، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران

۴. استادیار، دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر، دانشگاه حایری، میبد، ایران

تشخیص از طریق تصاویر پشه و چشم‌انداز آن تهیه نرم‌افزار تلفن همراه به منظور تشخیص آنی پشه‌های ناقل جهت کنترل بیماری می‌باشد. نوآوری این تحقیق ایجاد تصاویر آناتومی بدن پشه بر اساس تقسیمات مرفولوژیکی و دریافت قطعات بدن به عنوان ورودی شبکه به جای تصویر کامل پشه می‌باشد.

در تکنیک پیشنهادی به جای استفاده از تصاویر کامل پشه ابتدا با روش Mask-RCNN تصاویر قطعه‌بندی می‌شوند و دور لبه‌های هر قطعه از تصویر لنگرهای مشخصی قرار می‌گیرد. سپس استخراج ویژگی از پیکسل‌های درون هر لنگر انجام می‌شود. در مرحله بعد بر اساس ویژگی‌های استخراج شده برچسب کلاس مشخص می‌شود. در این روش علاوه بر سرعت بالاتر تشخیص، شبکه با دقت بالاتری کار طبقه‌بندی را نسبت به معماری‌های مشابه انجام می‌دهد.

برای این منظور، جهت شناسایی و طبقه‌بندی گونه‌ها از تصاویر سه گونه از ناقل‌های اصلی بیماری‌های پشه، از جمله آنوفل^۵، آئدس^۶ و کولکس^۷ استفاده می‌شود. برای تسهیل بازیابی تصویر، ما از یک مجموعه داده استفاده کردیم با حدود ۲۳۵۴ تصویر از ۳ گونه پشه از نمونه‌های فوق با ویژگی‌ها، شرایط و شکل‌های قرارگیری متفاوت که در دیتاست انتخابی موجود می‌باشد [۱۰].

ساختار این تحقیق به شرح زیر است: در بخش ۲ تاریخچه طبقه‌بندی تصاویر حشرات به ویژه پشه با تکنیک‌های شبکه عصبی و یادگیری عمیق بررسی می‌شود. در بخش ۳ مواد و روش‌های مورد استفاده برای طبقه‌بندی تصاویر با رویکردهای مختلف بررسی می‌شود. بخش ۴ به بررسی تکنیک‌ها و روش‌های بخش‌بندی و قطعه‌بندی می‌پردازد. بخش ۵ شرح فنی رویکرد پیشنهادی برای طبقه‌بندی تصاویر با استفاده از قطعه‌بندی را توضیح می‌دهد. بخش ۶ روش پیاده‌سازی و بحث در مورد نتایج ارزیابی مدل پیشنهادی و مقایسه معیارهای ارزیابی را بیان می‌کند. و سرانجام در بخش ۷ نتیجه‌گیری نهایی از تحقیق و پیشنهاد‌های آینده‌ی طرح عنوان می‌شود.

۲- تاریخچه

در پژوهش حاضر از گونه‌های مختلف پشه‌ها، سه گونه از

یک سیستم طبقه‌بندی کارآمد برای تشخیص و تمایز گونه‌ها باید در مرحله اول ویژگی‌های مرتبط و مفید را از داده‌های بیولوژیکی با حداقل یا بدون خطا استخراج کند [۴].

یک راه پیشنهادی برای مقابله با این چالش‌ها، روش‌های شناسایی و طبقه‌بندی اتوماتیک با استفاده از تکنیک‌های بینایی کامپیوتری است [۵]. تکنولوژی بینایی کامپیوتر یکی از کاربردی‌ترین موضوعات تحقیقاتی در زمینه هوش مصنوعی و علوم کامپیوتر است. کاربرد شبکه‌های عصبی مصنوعی در زمینه‌های گوناگون زندگی بشری به وفور یافت می‌شود [۶]. با استفاده از بینایی کامپیوتر می‌توان اطلاعات بصری مهم موجود در تصویر را ضبط، درک و تفسیر کرد. داده‌های تصویری و ویدئویی بسیاری از مطالعات استدلال می‌کنند که الگوریتم‌های یادگیری ماشینی^۱ مبتنی بر یادگیری نظارت شده، بهترین انتخاب برای انجام طبقه‌بندی خودکار گونه‌ها هستند [۷]. در واقع از مهمترین رویکردهای کاربردی در یادگیری ماشین پردازش تصاویر دیجیتالی است که امروزه بسیار مورد توجه قرار گرفته است.

سیستم‌های بینایی کامپیوتری، با استفاده از تکنیک‌ها و روش‌هایی به کامپیوترها قابلیت شناسایی و تشخیص محتوای تصاویر را می‌دهند. بینایی کامپیوتر الگوریتم‌هایی با رویکرد یادگیری عمیق^۲ دارد که در دنیای واقعی بسیار کارآمد هستند. سیستم‌های یادگیری عمیق می‌توانند مغز انسان را شبیه‌سازی کنند و یک ابزار جایگزین قابل اعتماد برای شناسایی و طبقه بندی تصاویر باشند [۸].

یکی از محبوب‌ترین شبکه‌های عصبی عمیق، شبکه‌های عصبی کانولوشن^۳ است. این شبکه‌ها عمدتاً در داده‌های با ابعاد بالا مانند تصاویر استفاده می‌شود. از این رو، آن‌ها به استانداردهای شناخته شده برای طبقه‌بندی تصویر تبدیل می‌شوند [۹].

در این مطالعه، بهره‌گیری از یادگیری عمیق را با مقایسه بین دو معماری مختلف ارزیابی و آنالیز می‌کنیم. در حالت اول از معماری ResNet101 در حالت معمولی استفاده می‌شود. در حالت دوم چارچوبی با استفاده از Mask-RCNN^۴ با معماری ResNet101 ادغام می‌شود.

هدف از این پژوهش ارائه روشی خودکار برای طبقه‌بندی و

⁵ Anopheles

⁶ Aedes

⁷ Culex


¹ Machine Learning

² Deep Learning


³ Convolution Neural Network

⁴ Mask Region-based Convolutional Neural Network

یا دوربین‌های عکاسی صورت می‌گیرد و پشه‌ها هنگام عکسبرداری زنده هستند. زمینه‌ی این نوع تنظیمات معمولاً مربوط به حوزه‌ی کشاورزی یا سلامت انسان با هدف شناسایی و میزان تعلق یک پشه به یک گونه‌ای از طبقه مخرب یا ناقل بیماری می‌باشد [۱۲].



(الف)



(ب)

شکل (۱): طبقه‌بندی تصاویر پشه. (الف) نمونه میدانی، نمونه موجود در طبیعت. (ب) نمونه آزمایشگاهی

درسال‌های اخیر مطالعات فراوانی بر روی تصاویر پشه با استفاده از انواع مختلف شبکه‌های عصبی صورت گرفته است. از جمله یک تکنیک شبکه عصبی برای شناسایی و دسته‌بندی پشه‌های آنوفل پیاده‌سازی شد. در این تکنیک دو مدل شبکه پیاده‌سازی و ارزیابی شدند. نتایج نشان داد شبکه چند لایه $MISON^1$ عملکرد بهتری نسبت به شبکه $MIMONN^2$ در تشخیص و شناسایی پشه‌های ناقل دارد [۱۳].

در مطالعه دیگری کارایی شبکه عصبی مصنوعی^۳ که یک مدل تجربی محبوب برای پیش‌بینی فراوانی پشه است مورد

پشه‌های شناخته شده از نوع آنوفل، کولکس و آندس به عنوان ناقلان اصلی بیماری انتخاب شدند. نمونه‌های آنوفل ناقل بیماری خطرناک مالاریا هستند. یک روش گام به گام برای توصیف فرآیند تشخیص و شناسایی گونه‌های پشه بر اساس تصاویر سه مرحله متوالی ثبت تصویر، استخراج ویژگی و طبقه‌بندی تصویر می‌باشد [۱۱].

در مرحله ثبت تصویر از دیتاست انتخابی موجود استفاده شد. مجموعه‌ای از معیارها برای تجزیه و تحلیل تصاویر از دیدگاه‌های مختلف برای طبقه‌بندی در این پژوهش انتخاب شده است. از جمله این معیارها عبارتند از:

این که آیا تصاویر با یا بدون محدودیت، در طبیعت یا در آزمایشگاه گرفته شده است؟ چه ویژگی‌هایی از دیدگاه دانشمندان علم کامپیوتر و یا حشره‌شناسان خبره به عنوان ویژگی متعارف برای شناسایی گونه‌های پشه تعریف شده است؟ چه طبقه‌بندی کننده‌هایی برای طبقه‌بندی تصاویر استفاده می‌شود؟ تعداد کلاس یا اندازه‌ی مجموعه داده‌های تصویری چه عددی باشد؟ و اینکه آیا مجموعه داده‌ها در دسترس عموم بوده است یا خیر؟

همه این معیارها را می‌توان به عنوان ابعاد یا جنبه‌های مختلف برای دسته‌بندی، شناسایی و طبقه‌بندی گونه‌های پشه در نظر گرفت.

مرفولوژیست‌ها تصاویر پشه را به دو دسته کلی تقسیم می‌کنند: تصاویر آزمایشگاهی و تصاویر میدانی.

این دسته‌بندی در شکل (۱) نشان داده شده است. در تصاویر آزمایشگاهی، تصویر در یک محیط آزمایشگاهی گرفته می‌شود که یک پروتکل ثابت برای دسترسی به تصویر وجود دارد. این پروتکل مربوط به روش‌های به دام انداختن پشه‌ها، مکان آنها و مواد مورد استفاده برای دسترسی به آنها (مانند سنسورهای ضبط، سیستم‌های روشنایی و غیره) می‌باشد. تنظیمات مبتنی بر آزمایشگاه عمدتاً توسط حشره‌شناسان خبره برای آزمایش و شناسایی پشه‌هایی که به آزمایشگاه منتقل می‌شوند، صورت می‌گیرد. از این رو، آنها توانایی مدیریت سیستم جمع‌آوری تصویر را دارند.

در یک محیط میدانی (که یک محیط مبتنی بر زمینه است) پشه‌ها مستقیماً از طبیعت یا مزارع هدف جمع‌آوری می‌شوند. تصویربرداری از این دسته از پشه‌ها بدون محدودیت خاصی و معمولاً توسط دستگاه‌های تلفن همراه و

³Artificial neural network(ANN)

¹ Multi-Input Single-Output Neural Network

² Multi-Input Multi-Output Neural Network

قطعه‌بندی در دو کلاس خوش خیم و بدخیم با دقت ۹۴/۳۵ انجام شد [۱۹]. روش پیشرفته شبکه‌های عصبی کانولوشنی با رویکرد استخراج خودکار ویژگی در [۲۰] بر روی مجموعه داده‌ای با ۳۶۰۰ تصویر از ۸ گونه پشه با وضعیت‌های مختلف و شرایط تغییر شکل مورد مطالعه قرار گرفت. نتایج ارزیابی دقت بالا را مشروط به استفاده از روش‌های افزایش داده ۶ و تکنیک تنظیم دقیق ۷ کرد.

با بررسی مطالب فوق به این نتیجه می‌رسیم که طبقه‌بندی خودکار پشه‌های ناقل مبتنی بر تصویر برای دهه‌ها برای کاربردهای عملی آن مانند تشخیص زود هنگام بیماری‌های بالقوه منتقله از پشه مورد بررسی قرار گرفته است. با این حال، دقت طبقه‌بندی رویکردهای قبلی هرگز به متخصصان انسانی نزدیک نبوده است و اغلب برای دستیابی به عملکرد طبقه‌بندی خوب، تصاویر پشه‌ها با وضعیت‌ها و قسمت‌های خاص بدن مانند بال، مورد نیاز است. در [۲۱] از بال به عنوان عضوی با قابلیت بیشترین وجه تمایز در بین اجزای بدن پشه استفاده شد و ابزار WGM^۸ یک ابزار قابل اعتماد برای شناسایی گونه‌های پشه از نوع کولکس معرفی گردید.

۳- روش‌های طبقه‌بندی

طبقه‌بندی فرآیندی است برای دسته‌بندی اشیاء به گونه‌ای که بتوان آن‌ها را از دیگران متمایز کرد. به طور کلی، طبقه‌بندی یک فعالیت یادگیری تحت نظارت است که به توسعه‌ی مدل‌هایی مربوط می‌شود که می‌تواند برچسب کلاس بردارهایی که کلاس‌هایشان ناشناخته هست را به دقت پیش‌بینی کند. متداول‌ترین طبقه‌بندی‌کننده‌ها عبارتند از: الگوریتم نزدیک‌ترین همسایه^۹، مدل مخلوط گاوسی^{۱۰}، مدل پنهان مارکوف^{۱۱} ماشین‌های بردار پشتیبان و شبکه‌های عصبی مصنوعی [۲۲].

در تحقیقات مختلف، روش‌های ترکیبی طبقه‌بندی‌کننده ابزارهای موثری برای افزایش عملکرد تشخیص و طبقه‌بندی الگو هستند. ایده طبقه‌بندی‌کننده ترکیبی استفاده از ترکیبی از طبقه‌بندی‌کننده‌های ضعیف برای به دست آوردن یک طبقه‌بندی قوی است که در آن طبقه‌بندی‌کننده‌ها به صورت تدریجی آموزش می‌بینند. خطا مطابق با خطای

آزمایش قرار گرفت. برای مقایسه از یک مدل رگرسیون خطی چندگانه^۱ استفاده شد. نتایج نشان داد شبکه عصبی مصنوعی قادر به پیش‌بینی تنوع بالا در مقایسه با MLR است و روابط بین متغیرهای ورودی از جمله داده‌های هواشناسی شامل دما، سرعت باد، رطوبت و بارش و فراوانی پشه به خوبی قابل ارزیابی است. در نتیجه ANN‌ها پتانسیل پیش‌بینی نوسانات در تعداد پشه‌ها را دارند (به ویژه مقادیر) و می‌تواند این کار را بهتر از تکنیک‌های آماری سنتی انجام دهند [۱۴].

استفاده از یادگیری ماشین برای اتوماتیک کردن انتخاب ویژگی در ماشین بردار پشتیبان^۲ برای مدل‌سازی رابطه بین توزیع یک گونه پشه مهاجم خاص و داده‌های آب و هوایی در [۱۵] مورد بررسی قرار گرفت.

اولین نمونه نرم افزار شناسایی اتوماتیک نوع پشه با قابلیت نصب و اجرا بر روی موبایل با تشخیص داده‌های صوتی و با استفاده از الگوریتم‌های یادگیری ماشین ساخته شد. هدف از این مطالعه جایگزین کردن تشخیص حضور و شناسایی نوع پشه‌ها از طریق تله حشرات و عملیات انسانی با نرم‌افزار موبایلی با قابلیت کار با داده‌های بزرگ بود [۱۶].

همچنین برای شناسایی و دسته‌بندی گروهی از پشه‌های نوع آندس چهار روش یادگیری ماشین از جمله جنگل تصادفی^۳، رگرسیون خطی^۴ درخت تصمیم‌گیری^۵ و ماشین‌بردار پشتیبان با دو معیار صحت و دقت مورد ارزیابی قرار گرفت. از نتایج ارزیابی نتیجه گرفته شد که ترکیبی خاص از دو تا سه مدل در پیش‌بینی توزیع بالقوه گونه‌های پشه بهتر از یک مدل واحد یا ترکیب تصادفی مدل‌ها عمل می‌کند [۱۷].

قطعه‌بندی تصاویر پشه با استفاده از شبکه عصبی کانولوشن مبتنی بر منطقه ماسک MaskR-CNN آموزش داده شد تا به طور خودکار اجزای تشریحی بدن پشه‌ها از جمله قفسه سینه، بال‌ها، شکم و پاها را از تصاویر شناسایی و استخراج کند. ورودی شبکه ۱۶۰۰ تصویر کامل پشه از ۲۳ گونه مختلف که توسط تلفن هوشمند گرفته شده بود [۱۸].

از روش‌های قطعه‌بندی تصاویر در مطالعات بسیاری برای تشخیص برچسب کلاس استفاده شده است. به منظور کاهش خطای متخصصان پاتولوژیست و صرفه‌جویی در هزینه‌های پزشکی، مطالعه‌ای بر روی تصاویر سرطان معده با روش

⁷ Fine-Tune

⁸ Wing geometric morphometrics

⁹ K- nearest Neighbors (KNN)

¹⁰ Gaussian Mixture Model(GMM)

¹¹ Hidden Markov Model-(HMM)

¹ Multiple Linear Regression(MLR)

² Support Vector Machine(SVM)

³ Random forest

⁴ Logistic Regression

⁵ Decision Tree

⁶ Data Augmentation

جدول ۲: مقایسه معیار دقت در روش SVM و CNN [۲۵]

Data set	SVM-Linear	CNN
Indian Pines	٪۸۸	٪۹۰
Salinas	٪۹۰	٪۹۲
U Pavia	٪۹۲	٪۹۸
Chikusei	٪۹۷	٪۹۴

مزیت اصلی CNN این است که به طور خودکار ویژگی‌های مهم را بدون هیچ نظارت انسانی تشخیص می‌دهد. CNN همچنین از نظر محاسباتی بسیار کارآمد است و با استفاده از لایه‌های Convolution و pooling قادر است تا تصاویر را بهتر از انسان‌ها طبقه‌بندی کند [۲۶]. در تکنیک پیشنهادی این مقاله از روش قطعه‌بندی برای استخراج ویژگی و سپس دسته‌بندی تصاویر استفاده می‌شود.

۴- تکنیک‌های بخش‌بندی

بخش‌بندی تصویر فرآیندی است که در آن تصویر قطعه‌بندی و به چند بخش تقسیم می‌شود. در حالت کلی دو روش بخش‌بندی برای تصویر وجود دارد: بخش‌بندی معنایی و بخش‌بندی نمونه‌ای [۲۷].

در روش بخش‌بندی معنایی کلیه اشیایی که از نوع یکسان هستند، با برچسب یکسان مشخص می‌شوند و در یک کلاس قرار می‌گیرند. در روش بخش‌بندی نمونه‌ای، اشیاء مشابه در تصویر از یکدیگر جدا می‌شوند و هر کدام برچسب مختص خود را دریافت می‌کنند. در معماری‌های بخش‌بندی تصاویر ویژگی‌های مختص هر تصویر به وسیله فیلترها استخراج می‌شود. سپس یک ماسک بخش‌بندی‌کننده، طرح کلی شیء را مشخص می‌کند و خروجی نهایی را ایجاد می‌کند. الگوریتم‌های بخش‌بندی به دو روش سنتی و روش یادگیری عمیق مطابق شکل (۲) تقسیم می‌شود [۲۸].

با توجه به اینکه تصاویر پشه در جهت‌های گوناگون عکس برداشته‌اند و دارای پس‌زمینه‌های مختلف و شرایط نوری متفاوتی هستند باید الگوریتمی جهت بخش‌بندی استفاده شود که از قدرت تشخیص و سرعت بالایی برخوردار باشد. بنابراین استفاده از روش سنتی منسوخ شده است. علاوه بر آن در سال‌های اخیر، روش‌های یادگیری عمیق نتایج علمی قابل قبولی در حوزه تشخیص اشیاء دست یافته است.

طبقه‌بندی‌کننده قبلی وزن داده می‌شود تا بتواند در جاهایی که ضعیف‌تر بوده است بیشتر آموزش یابد [۲۳]. برای مثال، چهار طبقه‌بندی‌کننده از نوع الگوریتم نزدیکترین همسایه بر روی توصیف‌گرهای مختلف آموزش داده شده‌اند. تصمیمات آن‌ها با اکثریت وزنی ترکیب می‌شوند. این طبقه‌بندی‌کننده، ترکیبی از طبقه‌بندی‌کننده‌های k-NN برای طبقه‌بندی حشرات است [۲۴]. در مطالعات بسیاری مقایسه بین انواع مختلف طبقه‌بندی‌کننده‌ها صورت گرفته است. در [۱۷] برای شناسایی و طبقه‌بندی تصاویر پشه‌های نوع آندس چهار روش طبقه‌بندی از جمله جنگل تصادفی^۱، رگرسیون خطی^۲ درخت تصمیم‌گیری^۳ و ماشین بردار پشتیبان با دو معیار صحت و دقت مورد ارزیابی قرار گرفت. از نتایج ارزیابی نتیجه گرفته شد که در بین این چهار مدل، ماشین بردار پشتیبان مطابق جدول ۱ بهترین کارایی را دارد و در رتبه اول در این مقایسه قرار می‌گیرد.

جدول ۱: مقایسه روش‌های مختلف طبقه‌بندی بر روی تصاویر پشه [۱۷]

Time [s]	Precision	Recall	Classifier name	Model name
۵۱۸	٪۷۴	٪۴۲	Random Forest(RF)	جنگل تصادفی
۹۱	٪۶۸	٪۷۰	Decision Tree(DT)	درخت تصمیم‌گیری
۱۷۱	٪۸۲	٪۷۷	SVM.	ماشین بردار پشتیبان
۶۹	٪۷۲	٪۷۵	Logistic Regression(LR)	رگرسیون

در پژوهش حاضر از طبقه‌بندی‌کننده CNN استفاده شده است. با توجه به اینکه در شبکه‌های کانولوشن فاز استخراج ویژگی به صورت خودکار انجام می‌شود، انتخاب نوع طبقه‌بندی‌کننده نقش مهمی در شناسایی و تشخیص تصویر به کلاس مورد نظر دارد. در [۲۵] مقایسه‌ای بین کلاسیفایر SVM و روش CNN بر روی تصاویر چهار مجموعه داده صورت گرفت و نتایج نشان داد در تمامی دیتاست‌های انتخابی مطابق جدول ۲ روش شبکه عصبی کانولوشن دقت بالاتری را کسب نموده است.

³ Decision Tree

¹ Random forest

² Logistic Regression

۴-۱- قطعه بندی مبتنی بر شبکه کانولوشن

(R-CNN)^۱

در این روش ابتدا باید موقعیت کادرهای حاوی اشیاء مشخص شود. به این کادرها، پیشنهادهای ناحیه^۲ گفته می شود. در واقع پیشنهادهای ناحیه لیستی از کادرهایی با احتمال وجود شی هستند. R-CNN از روش جستجوی انتخابی برای استخراج این نواحی استفاده می کند. در حالت کلی چهار قسمت اصلی برای یک شی وجود دارد که عبارت است از مقیاس، اندازه، رنگ، بافت و محفظه.

جستجوی انتخابی این الگوها را در تصویر مشخص می کند و بر اساس آن نواحی را پیشنهاد می دهد. در واقع یک الگوریتم پیشنهاد ناحیه لیستی از چند کادر در مقیاس ها، موقعیت ها و نسبت های مختلف تولید می کند. در R-CNN هر کادر به طور جداگانه توسط کلاس بندی تصویر طبقه بندی می شود. ۲۰۰۰ پیشنهاد ناحیه در R-CNN وجود دارد و کلاس بندی تصویر برای هر پیشنهاد ناحیه یک نقشه ویژگی^۳ محاسبه می کند.

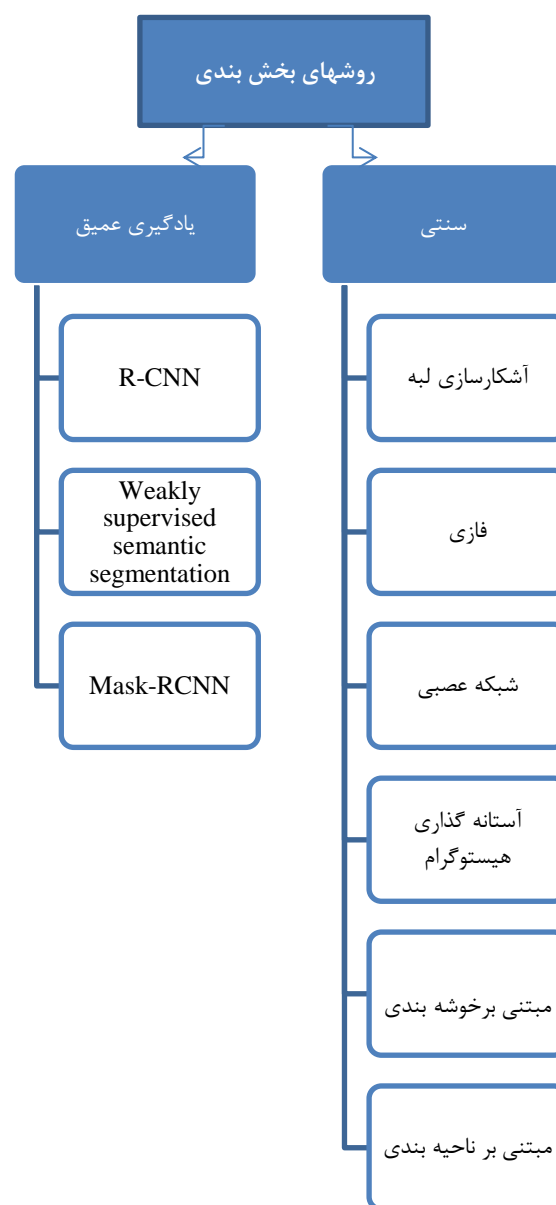
در روش تکمیلی Fast R-CNN سرعت تشخیص اشیاء به طور قابل توجهی افزایش یافت. بدین صورت که به جای ۲۰۰۰ نقشه ویژگی برای ۲۰۰۰ پیشنهاد ناحیه، یک نقشه ویژگی واحد برای کل تصویر محاسبه شد. سپس برای هر پیشنهاد ناحیه، یک ناحیه مطلوب (RoI^۴). لایه تجمعی (pooling) و یک بردار ویژگی با طول ثابت از نقشه ویژگی استخراج شد. این روش علیرغم توانایی قطعه بندی تصاویر ورودی با اندازه دلخواه، موجب کاهش رزولوشن تصویر می شد [۲۸].

۴-۲- قطعه بندی نظارت شده ضعیف^۵

همان طور که قبلاً بیان شد در قطعه بندی معنایی هر قطعه مشخص شده در تصویر معنای خاص خودش را دارد. یعنی هر قطعه برچسبی دارد که مشخص می شود مربوط به کدام شی می باشد. در روش نظارت شده ضعیف، برای انجام قطعه بندی معنایی از جعبه های محاطی استفاده می شود. الگوریتم های گوناگونی در این دسته قرار می گیرند. محفظه های شناسایی^۶ یک روش بخش بندی خودکار و سریع است که موقعیت شی و اندازه تقریبی آن را مشخص می کند و با روش برچسب های سطح تصویر^۷ که برای آموزش مدل هایی استفاده می شود که تصاویر را به دسته های گوناگون طبقه بندی می کنند. برچسب سطح تصویر نشان می دهد که یک تصویر حاوی یک شی، صحنه یا مفهوم است [۲۹].


۴-۳- Mask-RCNN

در این تکنیک، با استفاده از روش بخش بندی معنایی پیکسل های تصویر در دسته های مختلف قرار می گیرد و با استفاده از یک کادر محاطی اشیاء مختلف طبقه بندی و مکان یابی می شوند. هر بخش در تصویر یک ماسک بخش بندی خواهد داشت. در خروجی نهایی شبکه یک



شکل (۲): تقسیم بندی روش های قطعه بندی

^۵ Weakly supervised semantic segmentation^۶ bounding boxes^۷ image-level labels^۱ Region-Based Convolutional Neural Network^۲ Region Proposals^۳ feature map^۴ Region Of Interest



شکل (۳): معماری شبکه Mask RCNN

در جدول شماره ۳ عنصرهای مختلف و مزایا و معایب روش های قطعه بندی با یکدیگر مقایسه شده است.

۵- روش پیشنهادی

از نظر آناتومی اجزای تشریحی پشه ها شامل قفسه سینه، شکم، بال ها و پاها هستند. تکنیکی در این مقاله ارائه می شود که از هر تصویر پشه فقط پیکسل های متشکل از اجزای تشریحی بدن را استخراج می کند. در این روش ابتدا نقشه های ویژگی از مجموعه داده آموزشی شامل ۲۳۵۴ تصویر پشه استخراج می شود. برای استخراج نقشه های ویژگی از معماری ReseNet101 استفاده می شود. معماری این شبکه به گونه ای است که می تواند تصاویر را در مقیاس های مختلف مدیریت کند و برای مشکل ما مناسب است. اولین مرحله شناسایی اجزای تشریحی جداسازی تصویر از پس زمینه می باشد. پس از آن، فقط اجزای تشریحی (که به عنوان پیش زمینه مشخص می شود) در تصاویر شناسایی و بومی سازی می شود. این اجزا به شکل لنگرهای مستطیل رنگی مطابق شکل (۴) دیده می شوند.

برچسب کلاس و یک کادر محاطی تولید می شود. این معماری مشابه روش Faster R-CNN عمل می کند ولی کامل تر است. معماری Faster R-CNN به روش زیر عمل می کند:

مرحله اول: در این مرحله به منظور استخراج یک نقشه ویژگی تصویر ورودی از تعدادی لایه کانولوشن عبور می کند. یعنی یک تصویر ورودی به یک تصویر با ابعاد مکانی بسیار کوچکتر و تعداد کانال های بیشتر تولید می شود.

مرحله دوم: در این مرحله با استفاده از روش RPN^۱ برای آموزش شبکه ای که نواحی اشیای محصور را پیشنهاد می دهد از خروجی لایه های کانولوشن استفاده می شود.

مرحله سوم: برای اینکه همه تصاویر به اندازه یکسان تبدیل شوند، یک لایه RoI pooling روی خروجی مرحله قبل اجرا می شود. در واقع لایه ROI از هر لنگر یک نقشه ویژگی با اندازه ثابت استخراج می کند.

مرحله چهارم: از نقشه ویژگی برای آموزش کلاسه بندی که یک برچسب را به شی درون کادر اختصاص می دهد استفاده می شود. در پایان، تصاویر هم اندازه به یک شبکه عصبی تمام متصل داده می شود تا با کمک یک لایه softmax و یک لایه رگرسیون خطی، تصاویر دسته بندی شوند.


معماری Mask R-CNN علاوه بر ارسال نقشه ویژگی به RPN و کلاسه بند مطابق شکل (۳) برای پیش بینی یک ماسک باینری برای شی درون کادر محصور کننده نیز از نقشه ویژگی استفاده می کند [۳۰].

جدول ۳: مقایسه روشهای مختلف قطعه بندی [۳۱]. [۳۲]. [۳۳]. [۳۴].

عنصر	R-CNN	Fast R-CNN	Faster R-CNN	Mask R-CNN
روش پیشنهاد منطقه	الگوریتم جستجوی انتخابی	الگوریتم جستجوی انتخابی	شبکه عصبی RPN	شبکه عصبی RPN
زمان پیش بینی	۴۰-۵۰ ثانیه	۲ ثانیه	۰,۲ ثانیه	بیشتر از ۰,۲ ثانیه
زمان محاسبات	زیاد	زیاد	کم	کم
طبقه بند	SVM	SVM	Softmax	Softmax
فرایند بخش بندی	چند مرحله ای	تک مرحله ای	تک مرحله ای	تک مرحله ای
تعداد پارامتر	زیاد	کم	کم	کم
مصرف حافظه	زیاد	کم	کم	کم
عیب	سرعت کم و حافظه زیاد	محاسبات پیچیده و زمان بر	کارایی کلی سیستم وابسته به توالی بین لایه ها	عدم مدیریت طبقه بند در اندازه متغیر ورودی
مزیت	توانایی اخذ تصاویر با اندازه ها و ابعاد دلخواه	پارامتر کمتر و کیفیت تشخیص MAP بالاتر	انتخاب منطقه با شبکه RPN	استفاده از Align RoI و تشخیص دقیق تر

^۱ Region Proposal Network

مرحله‌ی بعد، تصاویر آموزشی و اعتبارسنجی با استفاده از ابزار^۱ VIA قسمت‌بندی می‌شوند. برای انجام این کار، به صورت دستی (و با دقت) چند ضلعی‌های محدودکننده در اطراف هر جزء تشریحی در تصاویر مطابق شکل (۷) قرار می‌گیرد. پیکسل‌های درون چندضلعی‌ها (مانند قفسه سینه، شکم، بال یا پا) به عنوان اجزای اصلی آناتومی بدن در نظر گرفته می‌شود.




شکل (۷): قسمت‌بندی اجزای بدن پشه با استفاده از ابزار VIA

سپس، شبکه، ویژگی‌های مهم معنایی را در مجموعه داده‌های تصویر آموزشی یاد می‌گیرد تا اجزای تشریحی پشه را تشخیص دهد. در مرحله سوم، با استفاده از نتایج حاصل از دو مرحله قبل، یک CNN طراحی می‌شود تا شبکه نقشه‌های ویژگی مربوط به اجزای آناتومی واقعی را در تصاویر آموزشی یاد بگیرد. هدف نهایی، قرار دادن لنگرها (جعبه‌های مستطیلی) این است که اجزای تشریحی شناسایی شده‌ی مهم در تصویر محصور شود. در نهایت، نقشه‌های ویژگی لنگرها (یعنی منطقه مورد نظر) که از مرحله بالا آموزش دیده است، با اندازه ثابت به عنوان ورودی شبکه عمل می‌کنند. به طور خلاصه، معماری شبکه به صورت زیر خلاصه و در شکل (۸) نمایش داده شده است:

- الف) لنگرها با جزء تشریحی برچسب زده می‌شود.
 - ب) فقط پیکسل‌های درون لنگرها استخراج می‌شود که یک جزء تشریحی را نشان می‌دهند.
 - ج) لنگرها برای افزایش دقت باید ثابت شوند.
- این سه مرحله به صورت موازی انجام می‌شود.

نتایج ارزیابی پس از آموزش مدل معماری، دقت بسیار خوبی در استخراج ویژگی از بال‌ها و تا حدی قفسه سینه را نشان داد. از این رو این تکنیک می‌تواند برای بسیاری از کلاس‌های حشرات عمومیت داشته باشد.



شکل (۴): لنگرهای مشخص شده روی تصویر

مرحله‌ی بعدی، قطعه‌بندی اجزای پیش‌زمینه و افزودن یک شاخه به ماسک برای استخراج پیکسل‌های هر جزء موجود در پیش‌زمینه است. این کار به موازات دو شاخه دیگر برای طبقه‌بندی لنگرهای مستطیلی استخراج شده و ثابت کردن آنها برای بهبود دقت انجام می‌شود. شکل (۵) نشان می‌دهد چگونه اجزای تشریحی به طور واضح از داده‌های تصویر اصلی بیرون می‌آیند.



شکل (۵): اجزای تشریحی بدن پشه [۱۸]

ما یک شبکه عصبی کانولوشن مبتنی بر منطقه ماسک Mask R-CNN را آموزش دادیم تا به طور خودکار شناسایی و به طور جداگانه اجزای تشریحی پشه‌ها شامل قفسه سینه، بال‌ها، شکم و پاها را از تصاویر استخراج کند. در این پژوهش، مجموعه داده ما ۲۳۵۴ تصویر پشه بود. این تصاویر به ۱۷۰۰ تصویر برای آموزش شبکه عصبی و ۱۳۴ تصویر برای اعتبارسنجی و ۵۰۰ تصویر برای مجموعه آزمایش تقسیم شدند. در مجموع داده‌ها ۲۳۵۴، تصویر از قفسه سینه، ۲۳۵۴ تصویر از شکم، ۴۶۵۷ تصویر از بال‌ها و ۷۰۰۲ تصویر از پاها به دست آمد.

۵-۱- آماده‌سازی تصاویر

با توجه به اینکه در این پژوهش از تصاویر میدانی استفاده می‌شود و این تصاویر بر خلاف تصاویر آزمایشگاهی، پس زمینه شلوغی دارند، اولین مرحله، جداسازی تصویر پس زمینه از تصویر بدن پشه و سپس حذف آن است. در

^۱ VGG Image Annotator

۶- پیاده‌سازی

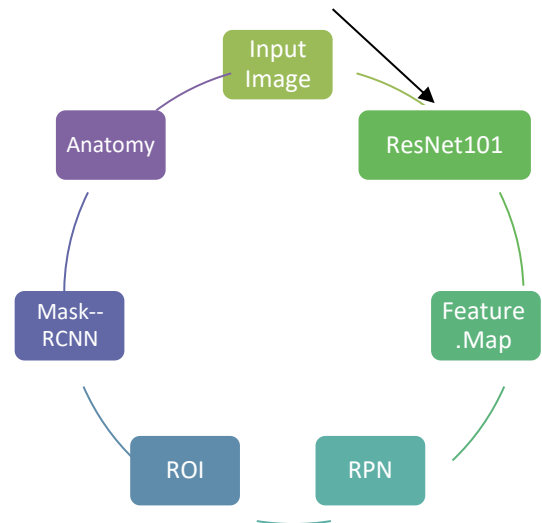
مطالعه حاضر در مجموع ۲۳۵۴ تصویر در دیتاست انتخابی دارد که شامل ۹۵۰ نمونه آنوفل، ۸۱۰ نمونه آندسو، ۵۹۴ نمونه کولکساز سویه‌های میدانی و موجود در طبیعت است [۱۰]. جدول ۴ خلاصه‌ای از داده‌ها و نمونه‌ها و تعداد گونه‌های پشه و انواع بیماری‌هایی که شامل می‌شود را نشان می‌دهد.

جدول ۴: انواع پشه و تعداد آنها در دیتاست انتخابی

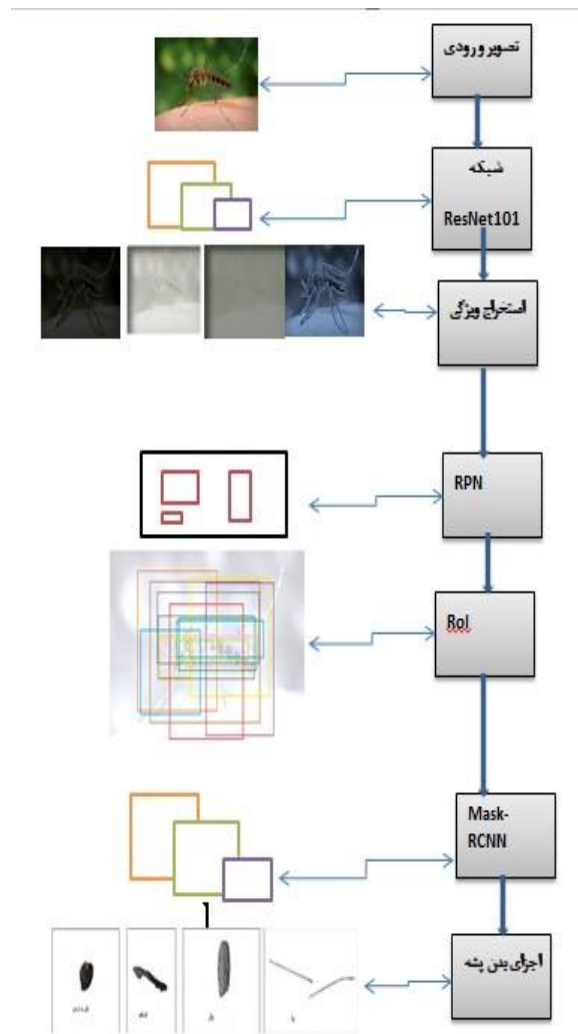
بیماری	تعداد تصویر	تعداد نمونه	نوع پشه
مالاریا	۹۵۰	۴۳۶	آنوفل
زیکا- تب زرد- چیکونگونیا- دانگ	۸۱۰	۴۷۵	آندس
تب دره ریفت	۵۹۴	۲۷۹	کولکس
	۲۳۵۴	۱۱۹۰	مجموع

مجموعه تصاویر در دیتاست انتخابی به نسبت ۸۰-۲۰ برای مجموعه آموزش و مجموعه داده تست تقسیم می‌شود. فرآیند آموزش فقط بر روی مجموعه داده‌های آموزشی صورت می‌گیرد و ۲۰ درصد مجموعه داده باقی مانده برای آزمایش رزرو می‌شود. معماری پیشنهادی در این پژوهش شامل دو فاز اصلی می‌باشد که در فاز اول تصاویر از طریق تکنیک Mask R-CNN قطعه‌بندی می‌شوند و در فاز دوم قطعات تشریح شده به عنوان تصاویر ورودی به شبکه وارد می‌شوند.

ساختار اصلی بدنه معماری، شبکه ResNet101 می‌باشد که یک شبکه از پیش آموزش دیده را برای ما فراهم می‌کند. در این معماری هر لایه ورودی خود را از خروجی لایه قبلی دریافت می‌کند که این امر موجب استحکام محتوایی و جلوگیری از کاهش اطلاعات مفید می‌شود. لایه‌های ابتدایی که وارد اولین شبکه می‌شوند معماری مناسبی برای دسته‌بندی تصاویر دارند و در پروژهای دسته‌بندی تصاویر بسیار زیاد استفاده می‌شود که به آن‌ها شبکه پایه گفته می‌شود. ResNet101 به عنوان شبکه پایه معماری پیشنهادی دارای لایه‌های آموزش دیده می‌باشد که به عنوان اولین لایه‌های معماری محسوب می‌شوند. چون در فاز اول برچسب کلاسها، لنگرها و پیکسل‌های درون لنگرها با اعمال فیلترهای لبه‌یابی استخراج شده است، در این مرحله از معماری، فقط از ۱۴۵ لایه کانولوشونی که شامل ۲ لایه



(الف)



(ب)

شکل (۸): (الف): روند کلی معماری پیشنهادی - (ب) نمایش گرافیکی مراحل معماری پیشنهادی

بهینه‌ساز با پارامترهای $Lr=0.01$ و $Momentum=0.9$ ، در هر گام از ۷ دور^۳ و تابع تلفات آنتروپی^۴ عمومی برای فاز آموزش استفاده شده است.

جدول (۵): هایپرپارامترهای شبکه پیشنهادی

مقدار	هایپرپارامترهای شبکه
۱۴۵	تعداد لایه
۱۰۱	عمق
Softmax	طبقه‌بند
۴۳/۸ (MB)	تعداد پارامتر
SGD	بهینه ساز
۰/۰۱	نرخ یادگیری (LR)
۰/۹	Momentum

۶-۱- آزمایش داده‌ها با معماری پیشنهادی

معماری پیشنهادی با استفاده از تمام تصاویر آموزشی موجود در مجموعه داده پشه آموزش داده شد. سپس در مرحله تست، مدل با مجموعه داده انتخابی برای آزمایش تست شد. برای استاندارد کردن تجزیه و تحلیل نتایج، در پلتفرم پایتورچ آزمایش با دسته‌های^۵ ۳۲ تایی انجام شد. برای هر نمونه جدید در مرحله آزمایش، تصاویر ورودی بر روی مدل پیشنهادی معماری مورد آزمایش قرار گرفت. سپس تمام تصاویر با استفاده از معیارهای مشخص شده مورد ارزیابی قرار گرفت. ابتدا از یک مدل ResNet101 برای آموزش داده‌ها استفاده شد. در مرحله بعد تکنیک Mask-RCNN به معماری اضافه و قبل از ورود تصاویر به شبکه ابتدا قطعه‌بندی و سپس دسته‌بندی انجام شد. در فاز قطعه‌بندی، تصویر اصلی از تصویر پس‌زمینه جدا می‌شود. پس از آن اجزای بدن پشه توسط معماری پیشنهادی تفکیک می‌شود و برای دسته‌بندی به کلاسه‌بند ارسال می‌شود.

بهترین نتایج با اندازه $۲۲۴ * ۲۲۴$ پیکسل ارائه شد. شکل (۱۰) نمونه‌ای از تصاویر موجود در مجموعه تست را نشان می‌دهد.

۶-۲- تجزیه و تحلیل و آنالیز نتایج تست داده


آموزش CNN برای طبقه‌بندی پشه‌ها در ۱۱,۲۰ دقیقه بر روی ResNet101 انجام شد. برای ارزیابی کیفیت عملکردی طبقه‌بندی تصاویر پشه، معیارهای زبان^۶ در مجموعه‌های آموزشی و اعتبارسنجی در دوره‌های خود

Fully-connected در انتها هستند استفاده شده است. در پایان به وسیله Softmax کلاس هر نوع پشه تشخیص داده می‌شود. به طور خلاصه می‌توان گفت در گام اول استخراج لایه‌های آموزش دیده، گام دوم تعیین پارامترها، گام سوم آموزش شبکه و گام چهارم شناسایی و تشخیص کلاسه‌ها صورت می‌گیرد.

به منظور ارائه مقادیر عملکرد پایه در برابر رویکرد پیشنهادی، خروجی‌ها از لایه ماقبل آخر شبکه ResNet101 آموزش دیده استخراج می‌شود و از چنین خروجی‌هایی به عنوان بردارهای ویژگی برای آموزش کلاسه‌بند Softmax استفاده می‌شود. فاز اول معماری که شامل قطعه‌بندی است در شکل (۸-ب) مشخص گردیده است. فاز دوم معماری که شامل طبقه‌بندی تصاویر و تشخیص کلاس پشه مورد نظر می‌باشد دارای لایه‌هایی به صورت ذیل است:

تصاویر لایه ورودی با اندازه $۲۲۴ * ۲۲۴$ به شبکه وارد می‌شوند. تعداد ۶۴ لایه کانولوشن، و ۷۴ لایه Pooling در شبکه موجود می‌باشد.

در انتهای شبکه ۲ لایه Fully-connected (Dense) قرار دارد. شکل (۹) نحوه چیدمان لایه‌های شبکه را نشان می‌دهد. بعد از لایه‌های Fully-connected، یک لایه Softmax به عنوان کلاسه‌بند و یک لایه برای خروجی در نظر گرفته شده است. عمق شبکه ۱۰۱ و تعداد ۴۳/۸ مگا بیت پارامتر در این شبکه وجود دارد که در جدول شماره ۵ بیان شده است.



شکل(۹): نحوه چیدمان لایه‌های شبکه

در این مطالعه از نرم‌افزار پایتورچ با پردازنده گرافیکی NVIDIA GeForce GTX TITAN برای پردازش استفاده شده است.

این نرم‌افزار بر روی سیستم عامل لینوکس Ubuntu LTS 16.04 تنظیم شده است. همچنین از SGD^۱ به عنوان یک

^۴ Cross-Entropy

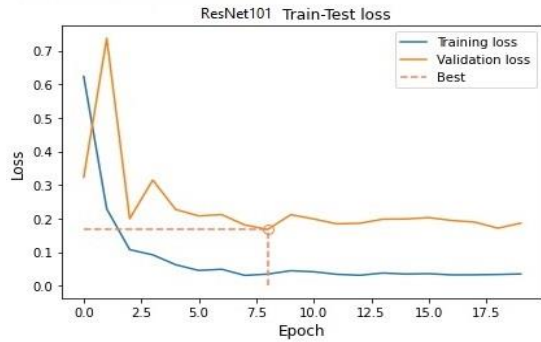
^۵ Batch

^۶ Loss Metric

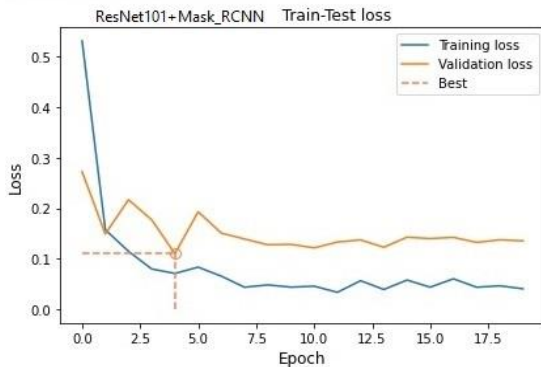
^۱ Stochastic gradient descent

^۲ Learning Rate

^۳ Epoch



(الف) - میزان تابع زیان در معماری ResNet101



(ب) - میزان تابع زیان در معماری ResNet101 که با تکنیک Mask-RCNN ترکیب شده است (معماری پیشنهادی)

شکل (۱۱): میزان تابع Loss

در آزمایش داده‌های تست مشخص شد مدل پیشنهادی ظرفیت بالاتری برای پیش‌بینی نمونه‌های آموزشی دارد. چندین متغیر آماری در این مدل‌ها با هم مقایسه شدند. برای مقایسه مدل‌ها اطلاعاتی را استخراج می‌کنیم از جمله زمان کل پردازش یک دسته تصویر، درصد دقت، میزان خطا و مدت زمان آموزش مدل. همچنین عملکرد معماری‌های شبکه‌های یادگیری عمیق با چندین معیار مورد ارزیابی قرار می‌گیرد:

معیار دقت، نسبت مشاهدات مثبت پیش‌بینی شده صحیح به کل مشاهدات مثبت پیش‌بینی شده است یعنی مدل تا چه اندازه خروجی را درست پیش‌بینی می‌کند. آیا مدل درست آموزش دیده است یا خیر و کارایی آن به طور کلی چگونه است.

$$\text{فرمول (۱)} \quad \text{دقت}^3 = \frac{TP+TN}{TP+FN+FP+TN}$$

$$\text{فرمول (۲)} \quad \text{صحت}^4 = \frac{TP}{TP+FP}$$

مقایسه شد. نمایش تکامل معیارهای زیان در مجموعه‌های آموزشی و آزمایشی در طول دوره‌ها مطابق شکل (۱۰) نشان داد که معماری پیشنهادی تابع زیان کمتری دارد.



شکل (۱۰): نمونه مجموعه داده تست در دیتاست

۳-۶- تابع زیان

در بسیاری از الگوریتم‌های یادگیری ماشین از کمینه‌سازی توابع هدف به منظور ارزیابی استفاده می‌شود. این توابع اغلب با نام توابع زیان^۱ یا تابع هزینه^۲ شناخته می‌شوند. در این مطالعه از تابع هزینه، به عنوان معیاری برای سنجش مناسب بودن مدل از نظر قابلیت و توانایی در پیشگویی مقادیر جدید استفاده شده است. تابع هزینه تفاوت داده‌های واقعی و خروجی پیش‌بینی شده توسط شبکه را به صورت ریاضی مشخص می‌کند و با استفاده از این تابع هزینه مقادیر وزن‌های شبکه به‌روزرسانی می‌شود و شبکه را به سمت جواب‌های بهتر هدایت می‌کند [۳۵]. در واقع تابع زیان، میزان خطا در هر بار اجرای شبکه‌ی عصبی را برای داده‌های آموزشی نشان می‌دهد و در نتیجه هر چه میزان خطا کمتر باشد نتیجه بهتر است که این امر در شکل (۱۱-ب) مربوط به معماری پیشنهادی کاملاً مشهود است. مهمترین هدف از فرآیندهای یادگیری عمیق این است که مقدار تابع زیان به سمت صفر حرکت کند.

³Accuracy
⁴Precision

¹Loss Function
²Cost Function

وجود ندارد و صرفاً با تکنیک‌های fine-Tuning و Augmentation و ایجاد تصاویر مصنوعی، دقت افزایش یافته است. علاوه بر اینکه تصاویر پشه هم باید به صورت کامل به شبکه داده شوند. اما در معماری پیشنهادی اگر قسمتی از بدن پشه هم از بین برود و یا فقط تصویر قسمتهای خاصی از بدن موجود باشد باز هم امکان طبقه بندی و دسته‌بندی وجود خواهد داشت.

جدول ۶- مقایسه معیارهای ارزیابی

ResNet101	ResNet101+ Mask-RCNN (معماری پیشنهادی)	معیار
۱۱/۲۰ دقیقه	۸/۱۵ دقیقه	زمان پردازش
%۹۴	%۹۷۸	دقت
%۹۴	%۹۷	صحت
%۸۹	%۸۹	پوشش

$$\text{فرمول (۳)} \quad \text{پوشش}^1 = \frac{TP}{TP+FN}$$

تمرکز اصلی معیار صحت، بر روی درستی تشخیص‌های «صحیح» توسط الگوریتم است. در واقع این معیار مشخص می‌کند الگوریتم چند درصد «صحیح»‌هایی را که در خروجی نشان داده واقعا درست بوده است. تمرکز اصلی معیار پوشش، بر خلاف معیار صحت، بر روی داده‌هایی است که واقعا «صحیح» بوده‌اند [۳۶].

معیارهای ارزیابی دو معماری آموزش داده شده در جدول ۶ نشان داده شده است. ما دقت ۰,۹۷۸ را برای معماری پیشنهادی به دست آوردیم.

همچنین با مقایسه دقت به دست آمده از معماری پیشنهادی با معماری‌های پیشین در زمینه دسته‌بندی تصاویر پشه مطابق جدول ۷ به وضوح مشهود است که معماری پیشنهادی دقت بالاتری را کسب کرده است. اگر چه در [۲۰] دقت نزدیک ۹۷ به دست آمده ولی معماری و ایده جدیدی

جدول ۷: مقایسه دقت معماری پیشنهادی با روشهای پیشین

معیار	معماری پیشنهادی	مرجع [۱۸]	مرجع [۲۰]	مرجع [۲۶]	مرجع [۲۱]	مرجع [۳۸]	مرجع [۳۹]
دقت	%۹۷۸	%۹۴	%۹۷	%۹۶	%۷۰	%۸۲	%۸۳

داده شده است، مدل معماری پیشنهادی دقت بالا ۰,۹۷۸ را به دست آورده است و این مقدار مطابق جدول ۴ بالاتر از مقادیر گزارش شده است در مراجع مربوطه می‌باشد. ما پیش‌بینی می‌کنیم که تحقیقات بیشتر در مورد طبقه‌بندی خودکار گونه‌های پشه بر اساس تصویر برای تشخیص زودهنگام بیماری‌های منتقله از طریق پشه مورد نیاز است. ما امیدواریم که در آینده نزدیک تشخیص خودکار نوع پشه به عنوان یک برنامه اندروید موبایل هوشمند برای استفاده عمومی ایجاد شود. این امر تلاش برای کنترل بیماری‌های منتقله از طریق پشه را تسهیل می‌کند.

۷- نتیجه گیری

پژوهش حاضر با هدف ارائه تکنیکی با روش Mask RCNN و پیشنهاد یک مدل معماری یادگیری عمیق بر روی تصاویر پشه به منظور طبقه‌بندی گونه‌های مختلف انجام شد. از یک دیتاست با سه گونه پشه شامل ۳۵۲۴ تصویر از گونه‌های آنوفل، آئدس و کولکس با شرایط تغییر شکل متفاوت استفاده شد. تصویر ورودی قبل از اینکه وارد شبکه کانولوشن شود توسط چارچوب پیشنهادی به قطعات بدن پشه تشریح شد و به جای تصویر کامل، از اجزای بدن پشه به عنوان ورودی شبکه استفاده شد. در این مطالعه، همان‌طور که توسط تجزیه و تحلیل نشان

مراجع

- [1] H.Caraballo and K.King, "Emergency department management of mosquito-borne illness: malaria, dengue, and West Nile virus", *Emergency medicine practice*, Vol. 16, NO.5, May 2014, pp.1-23.
- [2] G.King Jonas, "Developmental and comparative perspectives on mosquito immunity", *Developmental & Comparative Immunology*, Vol. 103, February 2020, pp.103458.

¹ Recall

- [3] G.Hopkins and R.Freckleton, "Declines in the numbers of amateur and professional taxonomists: implications for conservation", *Animal conservation forum*, Vol.5, NO. 3, August 2002, pp. 245-249.
- [4] R.Britz, A.Hundsdoerfer, U.Fritz, "Funding, training, permits—the three big challenges of taxonomy", *Megataxa*, Vol.1, NO.1, January 2020, pp.49-52.
- [5] A. Arista-Jalife, M.Nakano, Z.Garcia-Nonoal, D.Robles-Camarillo, H.Perez-Meana and H.Arista-Viveros, "Aedes mosquito detection in its larval stage using deep neural networks", *Knowledge-Based Systems*, Vol.189, February 2020, pp.104841.
- [۶] زهرا مروج؛ جواد آذرخش، "شبیه سازی و طبقه بندی وقایع کیفیت توان با استفاده از شبکه عصبی"، نشریه مدل سازی در مهندسی، دوره ۱۳، شماره ۴۱، تابستان ۱۳۹۴، صفحه ۱۳۷-۱۴۶.
- [۷] راضیه راستگو؛ کورش کیانی، "شناسایی چهره با استفاده از تنظیم دقیق شبکه های کانولوشنی عمیق و رویکرد یادگیری انتقالی"، نشریه مدل سازی در مهندسی، دوره ۱۷، شماره ۵۸، پاییز ۱۳۹۸، صفحه ۱۰۳-۱۱۱.
- [۸] محمود معلم؛ علی اکبر پویان، "کشف ناهنجاری با استفاده از کد کننده خودکار مبتنی بر بلوک های LSTM"، نشریه مدل سازی در مهندسی، دوره ۱۷، شماره ۵۶، بهار ۱۳۹۸، صفحه ۱۹۱-۲۱۱.
- [9] A.Dhillon and G.K.Verma, "Convolutional neural network: a review of models, methodologies and applications to object detection", *Progress in Artificial Intelligence*, Vol.9, No.2, January 2020, pp.85-112.
- [10] Dataset :<http://www.mosquitoalert.com/en/mosquito-images-dataset/>.
- [11] M. Martineau, D. Conte, R.Raveaux, I.Arnault, D.Munier and G.Venturini, "A survey on image-based insect classification", *Pattern Recognition*, Vol.65, May 2017, pp.273-284.
- [12] N. Jaramilloo, J.P. Dujardin, D.CalleLondoño and I.Fonseca-González, "Geometric morphometrics for the taxonomy of 11 species of Anopheles (N. yssorhynchus) mosquitoes", *Medical and Veterinary Entomology*, Vol.29, NO.1, March 2015, pp.26-36.
- [13] A.K.Banerjee, K.Kiran, U.S.Murty and C.Venkateswarlu, "Classification and identification of mosquito species using artificial neural networks", *Computational Biology and Chemistry*, Vol.32, NO.6, December 2008, pp.442-447.
- [14] K.Y.Lee, N.Chung Nand S.Hwang, "Application of an artificial neural network (ANN) model for predicting mosquito abundances in urban areas", *Ecological Informatics*, Vol. 36, November 2016, pp.172-180.
- [15] R.Wieland, A.Kerkow, L.Früh, H.Kampen and D.Walther, "Automated feature selection for a machine learning approach toward modeling a mosquito distribution", *Ecological Modelling*, Vol.352, May 2017 pp.108-112.
- [16] Y.Li, D.Zilli, H.Chan, I.Kiskin, M.Sinka, S.Roberts and K.Willis, "Mosquito detection with low-cost smartphones: data acquisition for malaria research", *arXiv preprint arXiv:1711.06346*, November 2017.
- [17] L.Früh, L. H.Kampen, A.Kerkow, G.A.Schaub, D.Walther and R.Wieland, "Modelling the potential distribution of an invasive mosquito species: comparative evaluation of four machine learning methods and their combinations", *Ecological Modelling*, NO.388, November 2018, pp.136-144.
- [18] M. Minakshi, P.Bharti, T.Bhuiyan, S.Karie, and S.Chellappan, "A framework based on deep neural networks to extract anatomy of mosquitoes from images", *Scientific Reports*, Vol.10, No.1, August 2020, pp.1-10.
- [۱۹] پانید تیموری؛ مهدی مزینانی؛ راحیل حسینی، "ارایه یک مدل هوشمند قطعه بندی مبتنی بر منطق فازی و تبدیل موجک گسسته در تصاویر دیجیتالی جهت شناسایی سرطان معده"، نشریه مدل سازی در مهندسی، دوره ۱۸، شماره ۶، زمستان ۱۳۹۹، صفحه ۱۳۱-۱۵۰.
- [20] J.Park, D.I.Kim, B.Choi, W.Kang and H.W.Kwon, "Classification and morphological analysis of vector mosquitoes using deep convolutional neural networks", *Scientific reports*, Vol.10, No.1, January 2020, pp.1-12.
- [21] R.F.Simões, A.B.Wilke, C.R.Chagas, R.M.Menezes, L.Suesdek, L.C.Multini, F.S.Silva, M.G.Grech, M.T.Marrelli and K.Kirchgatter, "Wing geometric morphometrics as a tool for the identification of culex subgenus mosquitoes of culex (Diptera: Culicidae)", *Insects*, Vol.11, NO. 9, September 2020, pp.567-580.
- [22] E.Gokcay, "An information-theoretic instance-based classifier". *Information Sciences*, Vol.536, October 2020, pp.263-276.

- [23] L. Früh, H. Kampen, A. Kerkow, G. A. Schaub, D. Walther and R. Wieland, "Modelling the potential distribution of an invasive mosquito species: comparative evaluation of four machine learning methods and their combinations", *Ecological Modelling*, Vol. 388, November 2018, pp.136-144.
- [24] T. Kasinathan and S. R. Uyyala, "Machine learning ensemble with image processing for pest identification and classification in field crops", *Neural Computing and Applications*, Vol.33, No. 13, July 2021, pp.7491-7504.
- [25] Hasan, Hayder, Helmi ZM Shafri, and Mohammed Habshi. "A comparison between support vector machine (SVM) and convolutional neural network (CNN) models for hyperspectral image classification." In *IOP Conference Series: Earth and Environmental Science*, Vol. 357, NO. 1, November 2019, pp. 012035.
- [26] E. Fanioudakis, M. Geismar and I. Potamitis, "Mosquito wingbeat analysis and classification using deep learning", *26th European Signal Processing Conference (EUSIPCO)*, Rome, Italy, September 2018, pp. 2410-2414.
- [27] Y. Guo, Y. Liu, T. Georgiou and M. S. Lew, "A review of semantic segmentation using deep neural networks", *International journal of multimedia information retrieval*, Vol. 7, No. 2, January 2018, pp.87-93.
- [28] H. D. Cheng, X. H. Jiang, Y. Sun and J. Wang, "Color image segmentation: advances and prospects", *Pattern recognition*, Vol.34, NO.12, December 2001, pp.2259-2281.
- [29] Z. Huang, X. Wang, J. Wang, W. Liu and J. Wang, "Weakly-supervised semantic segmentation network with deep seeded region growing", *Proceedings of the IEEE conference on computer vision and pattern recognition*, June 2018, USA, pp. 7014-7023.
- [30] T. D. Júnior, R. Rieder, J. R. Domênico and D. Lau, "InsectCV: A system for insect detection in the lab from trap images", *Ecological Informatics*, Vol.67, March 2022, pp.101516.
- [32] Khalighifar, Ali, Daniel Jiménez-García, Lindsay P. Campbell, Koffi Mensah Ahadji-Dabla, Fred Aboagye-Antwi, Luis Arturo Ibarra-Juárez, and A. Townsend Peterson. "Application of Deep Learning to Community-Science-Based Mosquito Monitoring and Detection of Novel Species." *Journal of medical entomology*, Vol.59, No.1, January 2022, PP. 355-362.
- [33] Xu X, Zhao M, Shi P, Ren R, He X, Wei X, Yang H. "Crack Detection and Comparison Study Based on Faster R-CNN and Mask R-CNN", *Sensors*, Vol.22, No.3, February 2022, p1215.
- [34] Ulku, Irem, and Erdem Akagündüz. "A survey on deep learning-based architectures for semantic segmentation on 2d images." *Applied Artificial Intelligence*, February 2022, PP. 1-45.
- [35] Cao, Xingmei, Jeng-Shyang Pan, Zhengdi Wang, Zhonghai Sun, Anwar ulHaq, Wenyu Deng, and Shuangyuan Yang. "Application of generated mask method based on Mask R-CNN in classification and detection of melanoma", *Computer Methods and Programs in Biomedicine*, Vol. 207, August 2021, PP 106174.
- [36] B. P. Amiruddin and R. E. Kadir, "CNN architectures performance evaluation for image classification of mosquito in Indonesia", *International Seminar on Intelligent Technology and Its Applications (ISITIA)*, July 2020, Surabaya, Indonesia, pp. 223-227.
- [37] V. Kittichai, T. Pengsakul, K. Chumchuen, Y. Samung, P. Sriwichai, N. Phatthamolrat, T. Tongloy, K. Jaksukam, S. Chuwongin, and S. Boonsang, "Deep learning approaches for challenging species and gender identification of mosquito vectors", *Scientific reports*, Vol.11, NO.1, March 2021, pp.1-4.
- [38] Marques, Alan Caio R., Marcos M. Raimundo, Ellen Marianne B. Cavalheiro, Luis FP Salles, Christiano Lyra, and Fernando J. Von Zuben. "Ant genera identification using an ensemble of convolutional neural networks." *Plos one*, Vol. 13, NO. 1, January 2018, pp e0192011.
- [39] Motta, Daniel, Alex Álisson Bandeira Santos, Ingrid Winkler, Bruna Aparecida Souza Machado, Daniel André Dias Imperial Pereira, Alexandre Morais Cavalcanti, Eduardo Oyama Lins Fonseca, Frank Kirchner, and Roberto Badaró. "Application of convolutional neural networks for classification of adult mosquitoes in the field." *PloS one*, Vol.14, No. 1, January 2019, pp e0210829.