

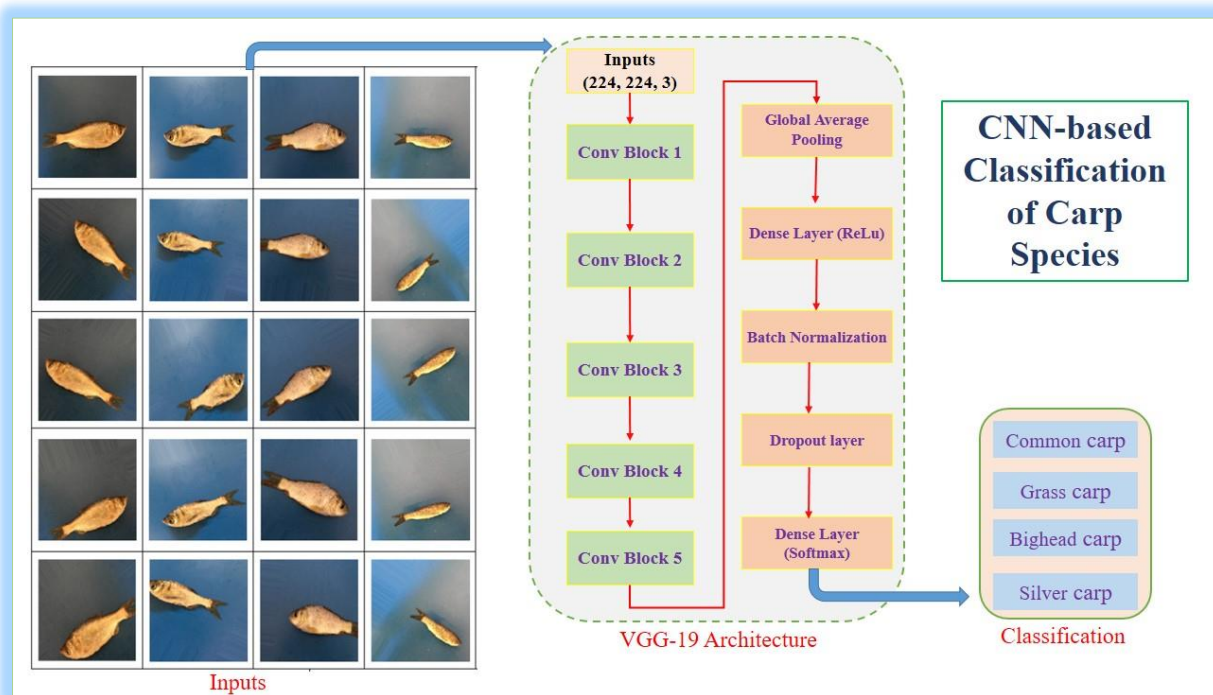
Deep Learning Algorithm Development for Intelligent Detection and Classification of Carp Species

Amin Taheri-Garavand^{1*}, Amin Nasiri², Ashkan Banan³

1. Mechanical Engineering of Biosystems Department, Lorestan University, Khorramabad, Iran.

2. Department of Mechanical Engineering of Agricultural Machinery, University of Tehran, Karaj, Iran.

3. Department of Animal Science, Lorestan University, Khorramabad, Iran.
(Received: May 30, 2020- Revised: July 10, 2020- Accepted: Aug. 20, 2020)



ABSTRACT: Identifying fish species is critical for aquaculture and fishery industries, managing aquatic stocks and environmental monitoring of aquatics. In this study, deep learning neural network as a non-destructive and real-time approach was developed and used to identify four economically important species of carp family including common carp, grass carp, bighead carp and silver carp. For this purpose, the architecture of pre-trained VGG19 (Visual Geometry Group-19) was updated by pooling, fully-connected, normalization and dropout layers. 409 images were used for training and evaluating the developed model. The mean value of accuracy, precision, sensitivity, specificity and AUC parameters was calculated as 98.39, 96.87, 96.87, 98.96, and 97.92%, respectively. The obtained high level of accuracy is due to the ability of the proposed deep model in constructing a hierarchy of self-learned features which was consistent with the hierarchy of fish identification keys.

Keywords: Deep learning, classification, Cyprinidae, Feature visualization

توسعه الگوریتم یادگیری عمیق به منظور تشخیص و طبقه‌بندی هوشمند گونه‌های ماهی کپور

امین طاهری گراوند^{۱*}، امین نصیری^۲، اشکان بنان^۳

۱. گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه لرستان، خرم

آباد، ایران

۲. گروه مهندسی مهندسی مکانیک ماشین‌های کشاورزی، دانشکده مهندسی و

فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

۳. گروه علوم دامی، دانشکده کشاورزی، دانشگاه لرستان، خرم آباد، ایران

(تاریخ دریافت: ۱۳۹۹/۳/۱۰ - تاریخ بازنگری: ۱۳۹۹/۴/۲۰ - تاریخ تصویب: ۱۳۹۹/۶/۱)

چکیده: شناسایی گونه‌های ماهیان برای صنایع آبی پروری و صید، مدیریت ذخایر پهنه‌های آبی و نظارت زیست محیطی آبزیان حیاتی می‌باشد. در این مطالعه، شبکه عصبی یادگیری عمیق به عنوان روشی غیرمخرب و برخط جهت تشخیص چهار گونه مهم و اقتصادی خانواده کپورماهیان شامل کپور معمولی، کپور علفخوار، کپور سرگنده و کپور نقره‌ای ایجاد و مورد استفاده قرار گرفت. به این منظور، ساختار شبکه پیش آموزش دیده VGG-19 (Visual Geometry Group-19) توسط لایه‌های پولینگ، تماما متصل، نرمال‌سازی و رهاسازی برورسانی گردید. از ۴۰۹ تصویر برای آموزش و ارزیابی مدل توسعه داده شده استفاده گردید. مقادیر میانگین دقت، صحت، حساسیت، اختصاصی بودن و سطح زیر منحنی به ازای هر کلاس به ترتیب برابر با ۹۸/۳۹، ۹۶/۸۷، ۹۶/۸۷، ۹۸/۹۶ و ۹۷/۹۲ درصد حاصل شد. سطح بالای دقت بدست آمده بدلیل توانایی مدل عمیق پیشنهادی در ساخت ویژگی‌های خودآموز سلسله مراتبی است که در تطابق با ویژگی‌های مورد استفاده در شناسایی ماهیان بود.

واژه‌های کلیدی: یادگیری عمیق، طبقه‌بندی، خانواده کپورماهیان، تجسم ویژگی

مقدمه

شناسایی گونه‌های ماهی از کاربرد بالایی برای زیست‌شناسان دریا جهت فهم بوم‌شناسی دریا و رفتار ماهیان به همراه بررسی ذخایر گونه‌های در معرض خطر انقراض و نیز برای صنعت آبی پروری و تولید غذاهای دریایی برخوردار است که از این‌رو به مدیریت شیلاتی کمک می‌نماید (Tharwat et al., 2018). در حقیقت، تعیین فراوانی، اندازه و پراکنش ماهیان جهت مدیریت و حفاظت مناسب اکوسیستم‌های دریایی الزامی می‌باشد. از طرف دیگر، دانش طبقه‌بندی گونه‌ها (تاکسونومیک) محدود به مرزهای جغرافیایی و متخصصان این دانش می‌باشد (Hernandez-Serna & Jimenez-Segura, 2014). از این‌رو، عدم دسترسی عموم به دانش طبقه‌بندی گونه‌ها موجب پدید آمدن اصطلاح "بحران طبقه‌بندی" گردیده است (Dayrat, 2005).

تشخیص و تعیین گونه‌های جانوری می‌تواند به طرق مختلفی شامل روش‌های الکترونیکی، مکانیکی و بیومتریکی صورت گیرد (Gaber et al., 2016). مثال - های زیادی در ارتباط با روش‌های مکانیکی همانند نشانه‌گذاری (Tagging) باله و آرواره‌ها وجود دارد. اما این روش‌ها نواقصی دارند، از جمله این که برای شناسایی در مقیاس وسیع مناسب نیستند و نسبت به سایر روش‌ها بسیار زمان‌بر هستند (Rusk et al., 2006). روش‌های الکترونیک نظیر تشخیص فرکانس رادیویی (Radio Frequency Identification) نیازمند اتصال یک قطعه فرستنده امواج به موجود و دستگاه خوانش آن می‌باشد. آن قطعه ممکن است آسیب ببیند و یا جدا گردد (Gaber et al., 2016). این محدودیت‌ها در روش‌های مکانیکی و الکترونیکی می‌تواند توسط روش‌های بر پایه بیومتری مرتفع گردند.

در روش‌های بیومتریکی، شاخص‌های مختلفی برای شناسایی گونه‌های جانوری ارائه گردیده است (Tharwat et al., 2016). استفاده از DNA هم جهت

تعیین گونه در مواجهه با گوشت و محصولات جانوری از دقت بالایی برخوردار می‌باشد (Jimenez-Gamero et al., 2006).

تمامی این روش‌ها، زمان‌بر، پرهزینه، نیازمند نیروی انسانی زیاد و متخصص می‌باشد. از این‌رو، فراهم آوردن روشی اتوماتیک جهت تشخیص ماهیان و شناسایی گونه‌های آن‌ها می‌تواند فواید ارزنده‌ای برای مدیریت اکوسیستم‌های آبی به ارمغان بیاورد. این فرآیند می‌تواند توسط ماشین بینایی انجام گردد که در آن یک کامپیوتر می‌تواند تصاویر را بررسی نموده و گونه‌های ماهی مورد نظر را شناسایی نماید.

روش‌های دسته‌بندی ماهیان بر اساس شکل (Lee et al., 2004)، بافت (Rova et al., 2007) یا رنگ (Chambah et al., 2004) برای کاربردهای مختلفی همانند مدیریت صید، تاثیر بوم‌شناختی سدها، مدیریت مزارع تجاری پرورش ماهی، بهبود نظارت بر مهاجرت ماهیان و یا ارائه اطلاعات در مورد گونه‌های زینتی (آکواریومی) مورد استفاده قرار گرفته‌اند (Khalifa et al., 2018). علیرغم کاربرد موفقیت‌آمیز تکنیک‌های مبتنی بر مهندسی ویژگی در زمینه طبقه‌بندی، این روش‌ها به دلیل انجام جداگانه مراحل سه‌گانه‌ی استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی، دارای پیچیدگی‌های خاصی می‌باشند. با هدف غلبه بر این پیچیدگی‌ها، روش‌های یادگیری عمیق در سال‌های اخیر برای انجام خودکار وظایفی مانند تشخیص الگو، طبقه‌بندی تصویر و سایر وظایف مبتنی بر بینایی توسعه یافته‌اند.

یادگیری عمیق یکی از زیر شاخه‌های یادگیری ماشین است که به‌طور گسترده در دامنه‌های مختلفی از هوش مصنوعی مورد استفاده قرار گرفته است. در این روش سعی می‌شود با استفاده از معماری سلسله‌مراتبی انتزاعات و ویژگی‌های سطح بالای موجود در داده‌ها فراگرفته شود (Hasanpour Mati Kalaei & Saadati, 2016).

ملل متحد (FAO, 2018)، بیشترین تولید آبی پروری را در جهان به خود اختصاص می‌دهند شامل کپور معمولی (*Cyprinus carpio*)، کپور علفخوار (*Ctenopharingodon idella*)، کپور سرگنده (*Hypophthalmichthys nobilis*) و کپور نقره‌ای (*Hypophthalmichthys molitrix*) برای تشخیص گونه بر اساس تصویر گرفته شده استفاده قرار خواهند گرفتند. این انتخاب از آن جهت با اهمیت می‌باشد که این چهار گونه درصد اعظم تولید آبیان در کشور را به خود اختصاص می‌دهند (Iran Fisheries Organization, 2017 statistical yearbook). نتایج تحقیق حاضر می‌تواند در مدیریت مزارع پرورش ماهی کشور مثرتر باشد چراکه روش پرورش گونه‌های ذکر شده شامل پرورش چندگونه‌ای (Polyculture) آنان در استخرهای حاکی که آب غنی از لحاظ جمعیت پلانکتونی دارند می‌گردد (آب غیرشفاف)، از این رو پس از معرفی این گونه‌ها به استخرها امکان مشاهده یا شمارش ماهیان از محیط خارج از آب وجود ندارد. همچنین، این چهار گونه از لحاظ طبقه‌بندی متعلق به یک خانواده از ماهیان یعنی کپورماهیان (Cyprinidae) می‌گردند و از این رو از لحاظ ظاهری به خصوص دو گونه کپور نقره‌ای و سرگنده در مرحله بچه ماهی بسیار شبیه می‌باشند و از آن جا که از لحاظ قیمت بچه ماهی نیز متفاوت می‌باشند، اشتباه در تعیین گونه می‌تواند لطمات اقتصادی برای پرورش دهندگان مبتدی به همراه داشته باشد.

بنابراین با توجه به اهمیت تشخیص و شناسایی گونه‌های ماهیان در صنعت شیلات و همچنین بالا بودن شباهت ظاهری گونه‌های کپور ذکر شده و با در نظر گرفتن پتانسیل و قابلیت بیش‌تر روش یادگیری عمیق نسبت به روش‌های معمول مدل‌سازی مانند شبکه عصبی پرسپترون، از این رو پژوهش پیش‌رو با هدف ارائه روشی نوین بر پایه یادگیری عمیق برای تشخیص

یادگیری عمیق تکنیکی مبتنی بر شبکه‌های عصبی است که دارای ویژگی منحصر به فرد استخراج خودکار ویژگی‌ها و انتخاب برترین‌های آن‌ها می‌باشد. شبکه عصبی کانولوشن، شبکه باور عمیق و شبکه عصبی بازگشت کننده از معماری‌های یادگیری عمیق می‌باشند که در زمینه‌های متنوعی همچون شناسایی چهره، تشخیص اشیاء تصویر و پردازش زبان طبیعی به کار گرفته شده‌اند (Javanmardi & Zare Chahooki, 2018).

در سال‌های اخیر از یادگیری عمیق در حوزه‌های مختلف همچون کشاورزی، صنایع غذایی و شیلات مورد استفاده قرار گرفته است. (Lu & Kuo, 2019) با استفاده از شبکه عصبی عمیق به تعیین گونه‌های رایج ماهیان دریایی که به روش رشته قلاب‌های طولی (Longline) صید می‌شوند، پرداختند. آمار صید ماهی توسط ادوات صید از اطلاعات ضروری برای مدیریت منابع دریایی محسوب می‌گردد. این اطلاعات که شامل گونه ماهی، زمان و مکان صید می‌باشد بطور سنتی توسط ماهیگیران ثبت می‌گردد. در سال‌های اخیر، شبکه عصبی عمیق بطور فزاینده‌ای برای حل اعمال پیچیده ماشین بینایی بکار رفته است و از این رو در این تحقیق برای شناسایی هوشمند ۱۱ گونه از ماهیان دریایی از این روش استفاده نمودند و به دقت ۹۵/۸۲ درصد در شناسایی دست یافتند. (Tung et al., 2017) جهت دسته‌بندی تصاویر گرفته شده از ماهیان و طبقه‌بندی آن‌ها در سه گروه تن‌ماهیان، کوسه‌ها و منقار ماهیان به استفاده از شبکه عصبی عمیق پرداختند. نتایج حاصل از این تحقیق نشان داد که شناسایی این سه گروه (در حد راسته) با درجه بالایی از دقت ۹۴/۵ درصد با استفاده از طبقه‌بندی‌ساز VGG-16 امکان پذیر می‌باشد.

در پژوهش پیش‌رو، چهار گونه از ماهیان آب شیرین که بر اساس آمارهای سازمان خواربار و کشاورزی

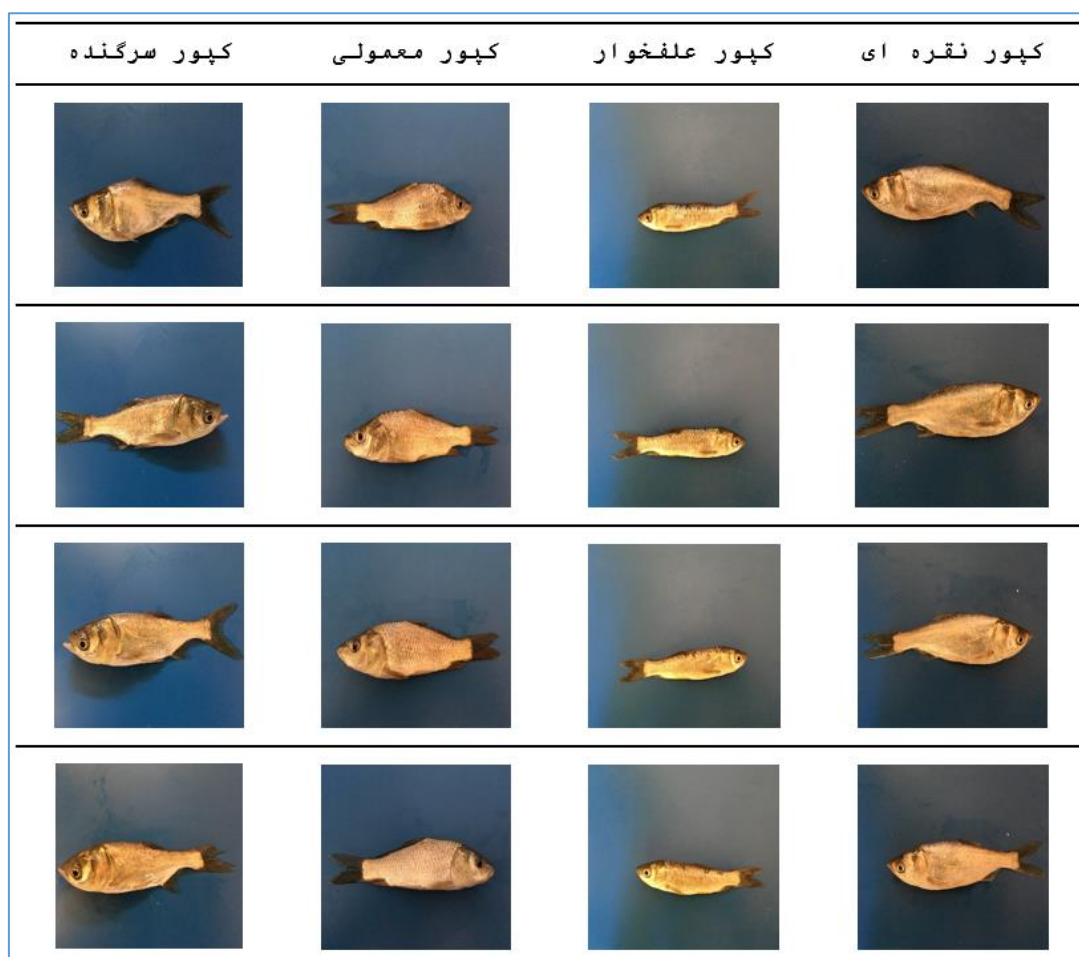
و طبقه‌بندی چهار گونه کپور اجرا شد.

مواد و روش‌ها

آماده‌سازی نمونه‌های ماهی

در مرحله اول، تصویربرداری از گونه‌های ماهیان مورد بررسی کپور معمولی، کپور علفخوار، کپور سرگنده و کپور نقره‌ای انجام گرفت. بدین منظور، ابتدا ماهیان با استفاده از عصاره گل میخک در گروه‌های ۲۰ عددی بیهوش گردیده، با استفاده از پارچه‌ای پنبه‌ای رطوبت

آن‌ها گرفته شده و سپس فوراً مورد تصویربرداری قرار گرفتند. بعد از تصویربرداری، ماهیان به حوضچه‌های نگهداری‌شان بازگردانده شدند. دوربین گوشی هوشمند آیفون 6S همراه با یک پس‌زمینه ثابت برای تصویربرداری استفاده گردید، در حالی که سایر پارامترها از جمله فوکوس، زاویه تصویربرداری، شرایط نوری و فاصله دوربین از نمونه‌ها متغیر بود. نمونه‌ای از تصاویر تهیه شده از گونه‌ها مورد بررسی در شکل ۱ ارائه شده است.






















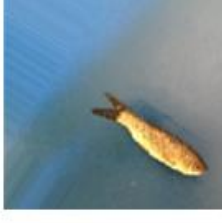




شکل ۱- نمونه‌ای از تصاویر تهیه شده از چهار گونه مختلف کپور مورد استفاده در تحقیق

برچسب‌گذاری بیش‌تر استفاده می‌کنند (Wu et al., 2015). با توجه به بالا بودن تعداد پارامترهای موجود در شبکه‌های کانولوشنی عمیق در این شبکه‌ها برای آموزش وزن‌ها و پارامترها نیاز به تعداد بالای تصاویر

پردازش تصویر و افزایش داده‌ها معمولاً زمانی که از یک شبکه عصبی کانولوشنی (CNN)^۱ برای تشخیص شیء استفاده می‌شود از افزایش داده‌ها برای تولید داده‌های اضافی بدون تحمیل هزینه

جدید با همان برچسب یا کلاس بدون هزینه برچسب گذاری بیش تر استفاده می گردد. بنابراین تعداد داده های آموزشی را به کمک روش های ذکر شده می توان چند برابر کرد. نتایج حاصل از اجرای فرایند افزایش داده ها بر روی تصاویر در شکل ۲ آورده شده است.

آموزشی می باشد در غیر شبکه دچار بیش برآزش می شود، اما به دلیل هزینه بالا امکان افزایش تعداد تصاویر آموزشی وجود ندارد، به همین دلیل معمولاً زمان استفاده از شبکه های CNN از روش های مختلف پردازش تصویر از جمله افزایش شدت رنگ، چرخاندن تصویر، بزرگنمایی و افزودن نویز، برای ایجاد تصاویر

کیپور نقره ای	کیپور سرگنده	کیپور معمولی	کیپور علفخوار	کلاس
				تصاویر اصلی
				نتایج حاصل از فرایند افزایش داده ها
				
				
				
				

شکل ۲- نتیجه اجرای فرایند افزایش داده ها بر روی تصاویر نمونه از هر کلاس ماهی مورد بررسی در تحقیق جاری

ساختار شبکه CNN

شبکه عصبی کانولوشنی برای اولین بار در سال ۱۹۹۸ معرفی شده است (Baldominos *et al.*, 2018). این شبکه‌ها نسخه بهبود یافته شبکه عصبی مصنوعی سنتی می‌باشد و برای استخراج خودکار ویژگی‌های سلسله مراتبی توسعه یافته است. بنابراین در حالت کلی یک شبکه عصبی کانولوشن یک شبکه عصبی سلسله مراتبی است که از لایه‌های کانولوشنی برای استخراج ویژگی‌ها (Zeiler, 2013)، لایه‌های پولینگ^۱ برای کاهش اندازه نقشه‌های ویژگی و پارامترهای شبکه (Boureau *et al.*, 2010) و لایه تماماً متصل برای تبدیل نقشه‌های ویژگی ۲ بعدی را به بردار ویژگی یک بعدی ساخته شده‌اند. لایه‌های تماماً متصل همانند هم‌تایان خود در شبکه‌های عصبی مصنوعی سنتی عمل می‌کنند و تقریباً ۹۰ درصد پارامترهای یک شبکه CNN را شامل می‌شوند (Girshick *et al.*, 2014).

شبکه‌های مختلف کانولوشنی پیش آموزش دیده مانند VGGNet، AlexNet، ResNet و GoogleNet برای استفاده در زمینه‌های متنوعی توسعه داده شده‌اند. عمق شبکه‌های کانولوشنی روی دقت طبقه‌بندی تأثیر مستقیم دارد به گونه‌ای که با افزایش عمق شبکه، خطای طبقه‌بندی کاهش می‌یابد (Simonyan & Zisserman, 2014). بنابراین، در سال‌های اخیر، معماری‌های عمیق‌تر CNN برای بهبود دقت طبقه‌بندی و حل مسائل پیچیده مورد کاوش قرار گرفته است (Banan *et al.*, 2020).

شبکه VGGNet^۲ یک شبکه عصبی کانولوشنی همگن را پیشنهاد داد تا از مزیت افزایش عمق شبکه استفاده کند (Ghazi *et al.*, 2017). ساختار VGG در ابتدا برای کارهای طبقه‌بندی اشیاء در نظر گرفته شده است و اکنون به عنوان یک شبکه کانولوشنی با کارایی بالا مورد استفاده قرار می‌گیرد (Lim *et al.*, 2017; Liu

(*et al.*, 2017). پیچیدگی ساختاری VGGNet کم است، و ویژگی‌های ایجاد شده توسط VGGNet از CNNهای دیگر مانند AlexNet و GoogLeNet کارآمدتر می‌باشد (Simonyan & Zisserman, 2014; Sa *et al.*, 2016). VGG19 یکی از دو ساختار VGGNet می‌باشد. این شبکه دارای ۱۹ لایه وزن دار و ۱۴۴ میلیون پارامتر آموزشی می‌باشد. ساختار این شبکه شامل پنج بلوک مختلف است که به صورت پشت سر هم قرار گرفتند و خروجی هر بلوک به عنوان ورودی بلوک بعدی تعریف می‌شود. با این تکنیک، شبکه می‌تواند ویژگی‌های بسیار قوی شامل شکل، رنگ و بافت را از تصاویر ورودی به شکلی بهینه استخراج نماید و در لایه‌های بعدی مناسب‌ترین آن‌ها را که بیشترین همبستگی با کلاس داده‌ها دارند، انتخاب نماید. عمق بردارهای ویژگی در این شبکه به ترتیب در بلوک اول ۶۴، بلوک دوم ۱۲۸، بلوک سوم ۲۵۶، بلوک چهارم و پنجم نیز ۵۱۲ می‌باشد. در انتها سه لایه تماماً متصل به بلوک پنجم وصل می‌شوند و گام^۳ و حاشیه‌گذاری^۴ ۱۶ لایه کانولوشنی به ترتیب ۳×۳ و یک پیکسل می‌باشد (Simonyan & Zisserman, 2014).

برای برآورد اهداف تحقیق پیش‌رو، سه لایه تماماً متصل ساختار VGG19 با لایه پولینگ^۵، لایه تماماً متصل با ۲۵۶ نرون و تابع فعال‌ساز رلو^۶، لایه نرمال‌سازی^۷ برای نرمال کردن داده‌ها، لایه رهاسازی^۸ به عنوان یک روش منظم‌سازی برای کاهش خطر بیش‌برازش^۹ و لایه تماماً متصل با تابع فعال‌ساز سافت‌مکس^{۱۰} جایگزین شدند. لایه تماماً متصل آخر دارای ۴ نرون متناسب با تعداد کلاس‌های تحقیق حاضر می‌باشد. ساختار مدل مبتنی بر VGG19 در شکل ۳ نشان داده شده است. در این شکل اعداد داخل براکت‌ها ابعاد کرنل‌های مورد استفاده در لایه‌های کانولوشنی و پولینگ و عمق بردارهای ویژگی را نشان می‌دهند. همچنین براکت‌های

6 - ReLu

7 - Batch normalization

8 - Dropout

9 - Over-fitting

10 - Softmax

1 - Pooling

2 - Visual Geometry Group Network (VGGNet)

3 - Stride

4 - Padding

5 - Global Average Pooling

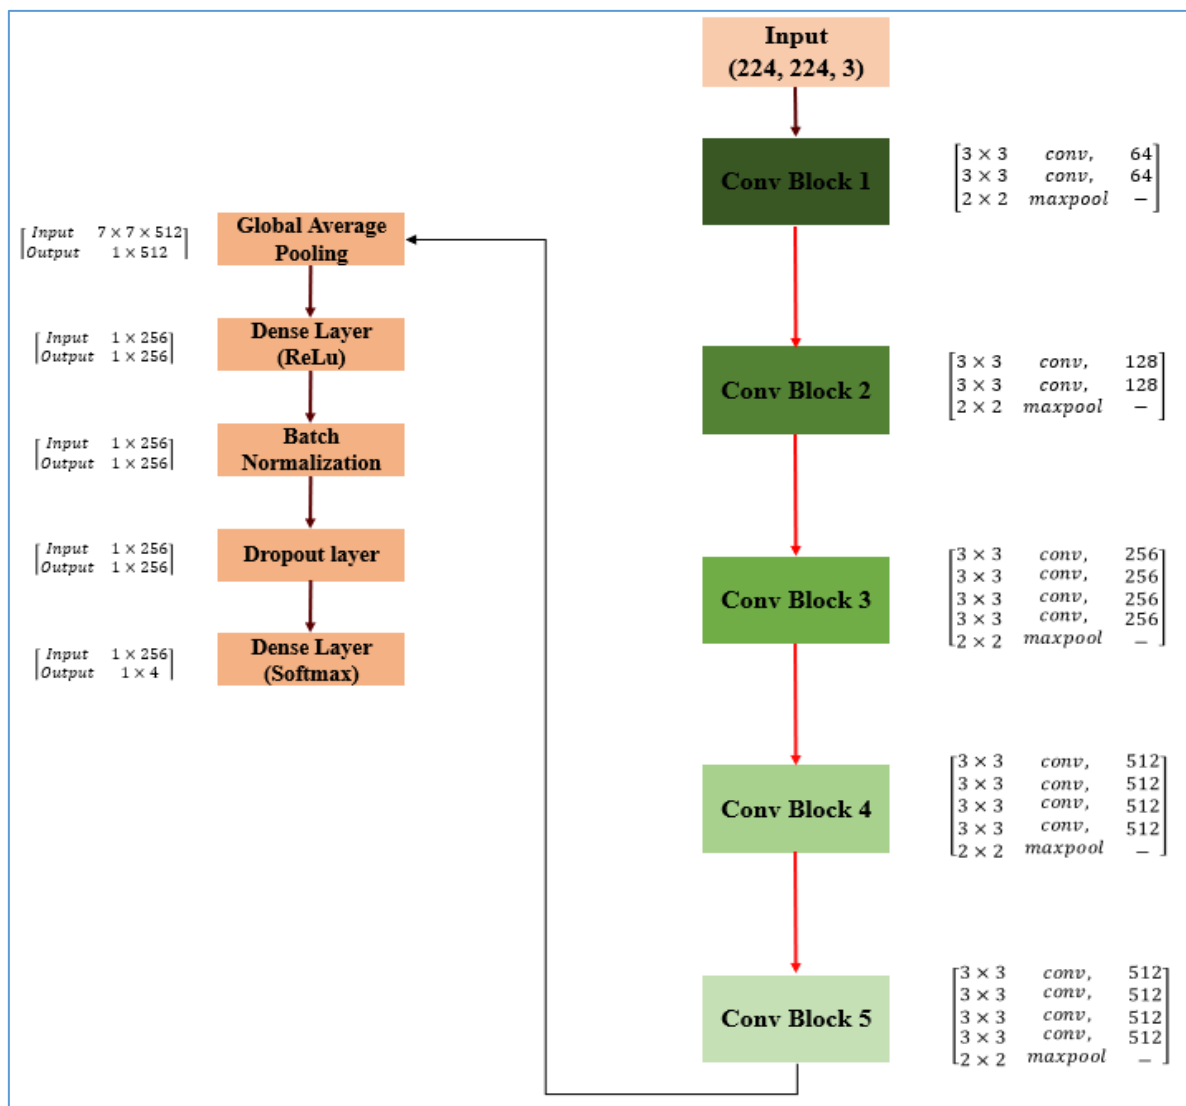
مربوط به لایه‌های اضافه شده به ساختار VGG19 ابعاد ورودی و خروجی هر لایه را نمایش می‌دهند. فرایند آموزش سریع‌تر و نرخ همگرایی بیش‌تر از مزایای تابع رلو نسبت به توابع دیگر است و همچنین خروجی تابع سافت‌مکس توزیعی احتمالی کلاس‌های خروجی است و حاصل جمع آن بر روی تمامی نرون‌های خروجی برابر یک است.

پیش آموزش، تنظیم دقیق^۱ و آموزش شبکه پیش آموزش به معنای آماده‌سازی (مقدار اولیه دادن) شبکه با پارامترهای از قبل آموزش داده شده بجای پارامترهای تصادفی است. این روش در مدل‌های مبتنی بر CNN بسیار محبوب است چرا که فرآیند یادگیری را تسریع کرده و همین‌طور قابلیت تعمیم را بهبود می‌بخشد (Erhan et al., 2010). در بیشتر تحقیقات علمی در این زمینه از وزن‌های بدست آمده از داده‌های آموزشی استاندارد ایمجنت^۲ استفاده شده و فرایند آموزش شبکه با انتخاب این وزن‌ها برای نرون‌ها آغاز گردید. نتایج تحقیقات مختلف نشان داده است، دقت خروجی بدست آمده در این روش بسیار بهتر از آموزش شبکه با پارامترهای تصادفی است. به عبارات دیگر در این روش تمامی لایه‌های شبکه به جز لایه آخر توسط وزن‌های داده‌های ایمجنت مقدار گذاری شده و تنها وزن‌های لایه‌های تماما متصل به صورت تصادفی مقداردهی می‌گردند. بنابراین برای آموزش شبکه بعد از وزن‌دهی تمامی لایه‌های کانولوشنی و پولینگ توسط وزن‌های مربوط به ایمجنت، لایه‌های تماما متصل اضافه شده به ساختار VGG19 برای ۱۰ دوره آموزش داده شد. در طول این دوره آموزش وزن تمامی لایه‌های کانولوشنی و پولینگ ثابت بودند و در فرایند آموزش به روزرسانی نمی‌گردیدند. بعد از ۱۰ دوره آموزش، وزن

تمام لایه‌های شبکه برای ۵۰ دوره آموزش داده شد. در فرایند آموزش، به ترتیب از ۲۸۵ و ۶۲ تصویر برای آموزش و اعتبارسنجی استفاده شده است. همچنین از ۶۲ تصویر برای اجرای فرایند تست استفاده گردید. با توجه به تعداد دوره‌های آموزش و فرایند افزایش داده‌ها از هر تصویر ورودی ۵۰ تصویر جدید ایجاد گردید و بنابراین مجموعه داده تصویر آموزش ۵۱ برابر بزرگتر از مجموعه داده اصلی بود. برای آموزش شبکه از تابع خطای کراس آنترابی^۳ و تابع بهینه‌ساز Adam استفاده گردید.


در این تحقیق برای پیاده‌سازی تمامی مراحل پردازش تصویر، توسعه و آموزش شبکه عصبی عمیق از محیط برنامه‌نویسی پایتون و کتابخانه‌های کراس و تنسورفلو استفاده گردید.

ارزیابی شبکه طراحی شده با شاخص‌های آماری به منظور ارزیابی شبکه کانولوشنی طراحی شده از شاخص‌های آماری مستخرج از ماتریس اغتشاش شامل دقت، صحت، حساسیت و اختصاصی بودن، استفاده شد. ماتریس اغتشاش برای یک طبقه‌بند چهارکلاسه در شکل ۴ نشان داده شده است. در این شکل ستون‌ها نشان دهنده کلاس‌های مطلوب و ردیف‌ها، کلاس‌های تخمین زده داده‌ها توسط طبقه‌بند می‌باشند. ماتریس اغتشاش شامل اطلاعات (کلاس‌های) مطلوب یا واقعی و اطلاعات تخمین زده توسط طبقه‌بند می‌باشد. با استفاده از این طبقه بندی و تشخیص گونه‌های مختلف ماهی، می‌توان عملکرد سامانه تشخیص گونه را به کمک مدل طبقه‌بند مورد ارزیابی قرار داد. ارزیابی طبقه‌بند توسط شاخص‌های آماری که از ماتریس اغتشاش استخراج شده انجام شد.



شکل ۳- ساختار مدل پیشنهادی مبتنی بر شبکه عصبی کانولوشنی VGG19

نتیجه اعضای قطری اصلی ماتریس ($i=j$) نشان دهنده تصاویری هستند که درست طبقه‌بندی شده‌اند، اما اعضای خارج از قطر اصلی ($i \neq j$) نمونه‌هایی هستند که درست توسط طبقه‌بند، طبقه‌بندی نشده‌اند. هر یک از ارزیابی‌های طبقه‌بند، شامل ۴ حالت مختلف زیر است. تصمیمات مثبت صحیح (TP): نمونه‌هایی که درست توسط طبقه‌بند (C^*i) در کلاس i ام طبقه‌بندی شده‌اند؛ تصمیمات مثبت ناصحیح (FP): نمونه‌هایی که اشتباها توسط طبقه‌بند (C^*i) در کلاس i ام طبقه‌بندی شده‌اند؛ تصمیمات منفی صحیح (TN): نمونه‌هایی که درست توسط طبقه‌بند (C^*i) در کلاس i ام طبقه‌بندی نشده‌اند؛ تصمیمات منفی ناصحیح (FN): نمونه‌هایی که اشتباها



شکل ۴- ساختار ماتریس اغتشاش برای طبقه‌بندی چهار کلاس

عضو n_{ij} مشخص کننده تصاویری است که توسط طبقه‌بند (C^*_i) در کلاس i طبقه‌بندی شده‌اند اما در طبقه‌بندی واقعی (C_j) متعلق به کلاس j می باشند. در

بندی نادرست می باشد (Sokolova & Lapalme., 2009).

نتایج و بحث

ارزیابی کمی شبکه در اجرای فرایند طبقه‌بندی در این تحقیق از مدل مبتنی بر VGG19 برای شناسایی خودکار گونه های ماهی استفاده شد که ساختار این مدل با لایه پولینگ، لایه تماما متصل با ۲۵۶ نرون، لایه نرمال سازی، لایه رهاسازی و لایه تماما متصل با ۴ نرون برورسانی گردید. این شبکه برای ۵۰ دوره آموزش داده شد و کمترین مقدار تابع خطا برای ذخیره کردن ماتریس وزنی مدل بدون بیش برازش مورد استفاده قرار گرفت.

شکل ۵، مقادیر خطا و دقت طبقه‌بندی برای داده-های آموزش و اعتبارسنجی در هر دوره آموزش را به تصویر می کشد. بهترین عملکرد مدل، در دوره ۲۸ آموزش به دست آمد و وزن های شبکه طراحی شده در این نقطه ذخیره گردیدند. بر اساس جدول ۱، مقادیر دقت طبقه‌بندی و تابع خطای کراس آنروپی داده‌های آموزش به ترتیب برابر ۰/۹۹۷۰ و ۰/۰۱۷۳ می باشد، در حالی که مقادیر این پارامترها برای داده‌های اعتبارسنجی معادل ۱ و ۰/۰۰۰۹ حاصل شد. همچنین، دقت پیش‌بینی و مقدار تابع خطا برای داده‌های تست به ترتیب ۰/۹۶۷۷ و ۰/۲۲۳۶ محاسبه گردید.

توسط طبقه‌بند (C*i) به کلاس نام تعلق نگرفته‌اند؛ که $n_{FN} = n_{+,j} - n_{FP} = n_{i,+} - n_{i,i}$ ، $n_{TP} = n_{i,i}$ و $n_{i,+}$ می باشد. $n_{TN} = n - n_{TP} - n_{FP} - n_{FN}$ مجموع اعضای تمامی ستون های متعلق به سطر نام و $n_{+,z}$ مجموع اعضای تمامی سطرهای متعلق به ستون نام در ماتریس اغتشاش می باشد (Labatut & Cherifi, 2012).

ارزیابی طبقه‌بند توسط شاخص های آماری مستخرج از ماتریس اغتشاش نظیر دقت (Ac)، حساسیت (Se)، اختصاصی بودن (Sp)، صحت (Pr) و سطح زیر منحنی (AUC) انجام شد:

$$Ac = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{TN} + n_{FP} + n_{FN}} \quad (\text{رابطه ۱})$$


$$Se = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (\text{رابطه ۲})$$

$$Sp = \frac{n_{TN}}{n_{TN} + n_{FP}} \quad (\text{رابطه ۳})$$

$$Pr = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (\text{رابطه ۴})$$

$$AUC = \frac{1}{2} \left(\frac{n_{TP}}{n_{TP} + n_{FN}} + \frac{n_{TN}}{n_{TN} + n_{FP}} \right) \quad (\text{رابطه ۵})$$

دقت، شاخصی است که عملکرد کلی طبقه‌بند را نشان می دهد. صحت، کسری از پیش بینی های صحیح را از میان کل برچسب های مثبت پیش بینی شده نشان می دهد. حساسیت، توانایی یک طبقه‌بند را برای یافتن تمامی برچسب های مرتبط در یک مجموعه داده نشان می دهد. شاخص اختصاصی بودن، توانایی طبقه‌بند در تشخیص صحیح برچسب‌های منفی را نشان می دهد. سطح زیر منحنی توانایی طبقه‌بند برای اجتناب از طبقه



شکل ۵- روند یادگیری شبکه عصبی کانولوشنی توسعه داده شده در دوره های مختلف آموزش

جدول ۱- مقادیر دقت و خطای شبکه عصبی کانولوشنی توسعه داده شده بر روی داده‌های آموزش، اعتبارسنجی و تست

تست		اعتبارسنجی		آموزش	
خطا	دقت	خطا	دقت	خطا	دقت
۰/۲۲۲۶	۰/۹۶۷۷	۰/۰۰۰۹	۱	۰/۰۱۷۳	۰/۹۹۷۰

شده‌اند. می‌توان علت کاهش دقت در این کلاس را در تشابه ویژگی‌های بصری دانست. همچنین جدول ۳ مقادیر مربوط به شاخص‌های آماری محاسبه شده برای تمام کلاس‌های ماهی را نشان می‌دهد. با توجه به جدول ۳، مقادیر میانگین به ازای هر کلاس دقت، صحت، حساسیت، اختصاصی بودن و سطح زیر منحنی به ترتیب برابر با ۹۸/۳۹، ۹۶/۸۷، ۹۶/۸۷، ۹۶/۸۷، ۹۸/۹۶ و ۹۷/۹۲ درصد است. همچنین دقت کلی طبقه‌بندی مدل ۹۶/۷۷ درصد می‌باشد.

نتایج جدول ماتریس اغتشاش و پارامترهای آماری محاسبه شده بر اساس آن برای بررسی عملکرد مدل مبتنی بر VGG19 با استفاده از داده‌های تست به کار گرفته شدند. نتایج ماتریس اغتشاش در جدول ۲ نشان داده شده است. نتایج این جدول نشان می‌دهد که کلاس‌های کپور معمولی، کپور علفخوار و نقره‌ای به درستی و بدون اشتباه طبقه‌بندی شده‌اند. در مقابل کلاس کپور سرگنده دارای دو تصویر اشتباه می‌باشد که به صورت نادرست در کلاس کپور نقره‌ای طبقه‌بندی

جدول ۲- نتایج ماتریس اغتشاش حاصل از عملکرد شبکه عصبی کانولوشنی توسعه داده شده بر روی داده‌های تست

واقعی				پیش‌بینی شده
کپور نقره‌ای	کپور علفخوار	کپور معمولی	کپور سرگنده	
۰	۰	۰	۱۴	کپور سرگنده
۰	۰	۱۶	۰	کپور معمولی
۰	۱۶	۰	۰	کپور علفخوار
۱۴	۰	۰	۲	کپور نقره‌ای

جدول ۳- شاخص‌های آماری حاصل از ماتریس اغتشاش جهت تعیین کارایی شبکه عصبی کانولوشنی توسعه داده شده برای تمام کلاس‌ها

کلاس	دقت (%)	صحت (%)	حساسیت (%)	اختصاصی بودن (%)	سطح زیر منحنی (%)
کپور سرگنده	۹۶/۷۷	۱۰۰	۸۷/۵	۱۰۰	۹۳/۷۵
کپور معمولی	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
کپور علفخوار	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
کپور نقره‌ای	۹۶/۷۷	۸۷/۵	۱۰۰	۹۵/۸۳	۹۷/۹۲
میانگین به ازای هر کلاس	۹۸/۳۹	۹۶/۸۷	۹۶/۸۷	۹۸/۹۶	۹۷/۹۲

تصاویر صرفاً پوست شش گونه از ماهیان آب شیرین کار کردند. نتایج بدست آمده توسط آن‌ها نشان داد که MSVM توانست به طور موثری گونه‌های ماهی به استثناء کپور نقره‌ای و کپور سرگنده طبقه‌بندی نماید. Storbeck & Daan (2001) جهت تشخیص شش گونه

نتایج ارزیابی مدل توسعه‌یافته نشان می‌دهد که مدل ارائه شده کارایی لازم جهت تشخیص و طبقه‌بندی ماهیان را دارد. Hu et al. (2012) روشی را مبتنی بر ماشین بردار پشتیبان چندکلاسه^۱ (MSVM) برای طبقه‌بندی گونه‌های ماهیان ارائه دادند. آن‌ها روی

توسط فیلترها یا ویژگی‌های استخراج شده از لایه‌های مختلف مدل تعیین می‌گردد و بصری‌سازی فیلترها جهت ارزیابی عملکرد مدل‌ها ضروری می‌باشد.

یکی از روش‌های کاربردی جهت ارزیابی عملکرد مدل در استخراج ویژگی‌های سطح پایین و سطح بالا، مطالعه آرایه‌های بصری حاصل از واکنش فیلترها می‌باشد. در راستای انجام این روش، لایه‌های کانولوشنی مختلف مدل برای استخراج مدل‌ها مورد استفاده قرار گرفتند. شکل ۶، برخی از فیلترهای بکار رفته در لایه‌های کانولوشنی هر بلوک را نشان می‌دهد. همانطور که در این شکل قابل مشاهده است، فیلترهای لایه اول ویژگی‌های رنگی و لبه‌های جهت‌دار را کدگذاری می‌نمایند. بافت‌های ساده شکل گرفته از ترکیب‌های مختلف رنگ‌ها و لبه‌ها توسط فیلترهای لایه کانولوشنی میانی کدگذاری شدند. بافت‌ها و الگوهای خاصی از تصاویر توسط فیلترهای لایه کانولوشنی پایانی استخراج شدند. از این رو، مدل بهینه‌سازی شده، فیلترهای کارآمد مختلفی را بر اساس شکل، رنگ و بافت شبیه‌سازی نمود.

^۳ Grad-CAM به عنوان روشی مفید در اشکال زدایی^۴ فرآیند پیش‌بینی بکار گرفته شد. توسط این روش نواحی مهم تصویر برای استخراج ویژگی‌ها به منظور پیش‌بینی کلاس تصویر که توسط مدل مورد استفاده قرار می‌گیرد مشخص می‌گردد. در این روش، نقشه حرارتی فعال‌سازی کلاس که یک شبکه دو بعدی است^۵ محاسبه می‌گردد که در آن درجه اهمیت و سطح شباهت نواحی هر تصویر مرتبط با کلاسی خاص تعیین می‌گردد. شکل ۷ نتایج استفاده از این روش روی برخی تصاویر از گونه‌های مختلف ماهی را نشان می‌دهد. این شکل نشان می‌دهد که بخش‌های مختلف ماهی شامل بدن، سر و باله جهت استخراج ویژگی و طبقه‌بندی کلاس ماهی‌ها مورد استفاده قرار گرفته‌اند.

ماهی سیستمی متشکل از بینایی کامپیوتر و یک برنامه شبکه عصبی را توصیف نمودند. ارزیابی آن‌ها از شبکه نشان داد که در حدود ۹۵ درصد ماهیان به طور صحیح طبقه‌بندی شدند. (Zhang et al. (2011) یک سیستم ماشین بینایی را برای شناسایی ۴ گونه از ماهیان آب شیرین ارائه نمودند. بعد از پردازش تصاویر، خصوصیات مختلف ماهی توسط مقادیر ویژه استخراج گردیدند. نرخ صحت مدل ارائه شده برای شناسایی ۹۶/۶۷ درصد بود. (Li & Hong (2014)، یک روش پردازش تصویر سنتی با بکارگیری آنالیز مولفه‌های اصلی را برای شناسایی چهار گونه ماهی استفاده نمودند. نتایج بدست آمده توسط آن‌ها نشان داد که میانگین نرخ تشخیص ۹۶/۶۷ درصد بود. به منظور انجام چنین مطالعاتی که مبتنی بر مهندسی ویژگی می‌باشند، علاوه بر شرایط کنترل شده تصویربرداری، انجام مراحل دیگری نیز ضروری می‌باشد: استخراج ویژگی‌ها، انتخاب ویژگی مناسب و تکنیک بهینه طبقه‌بندی. در مقابل با این مطالعات، تصاویر مطالعه حاضر از لحاظ شرایط نوری و ثابت بودن موقعیت و پارامترهای دوربین به صورت کنترل نشده اخذ شده‌اند. همچنین، مراحل استخراج و دسته‌بندی ویژگی‌ها توسط مدل CNN ترکیب شدند. از این رو، روش ارائه شده در این مطالعه نه تنها پیچیدگی کم‌تری جهت اجرا داشت بلکه همچنین دقت کامل و بالاتری به همراه داشته است. این نتایج بیانگر توانایی مدل‌های CNN در تشخیص گونه‌های ماهیان می‌باشد.

ارزیابی کمی شبکه

مدل‌های CNN در دو مرحله حرکت‌روبه‌جلو^۱ و پس-انتشار^۲ آموزش داده می‌شوند. ویژگی‌های سطح پایین و سطح بالا توسط فیلترهای بهینه شده در مرحله پس انتشار استخراج می‌گردند و برای هر کلاس، فیلترها مهمترین نواحی را برای تشخیص تصاویر ماهیان نشان می‌دهند. بنابراین، دقت نهایی مدل بهینه‌سازی شده


4 - Debugging

5 - Two-dimensional grid class activation heatmap

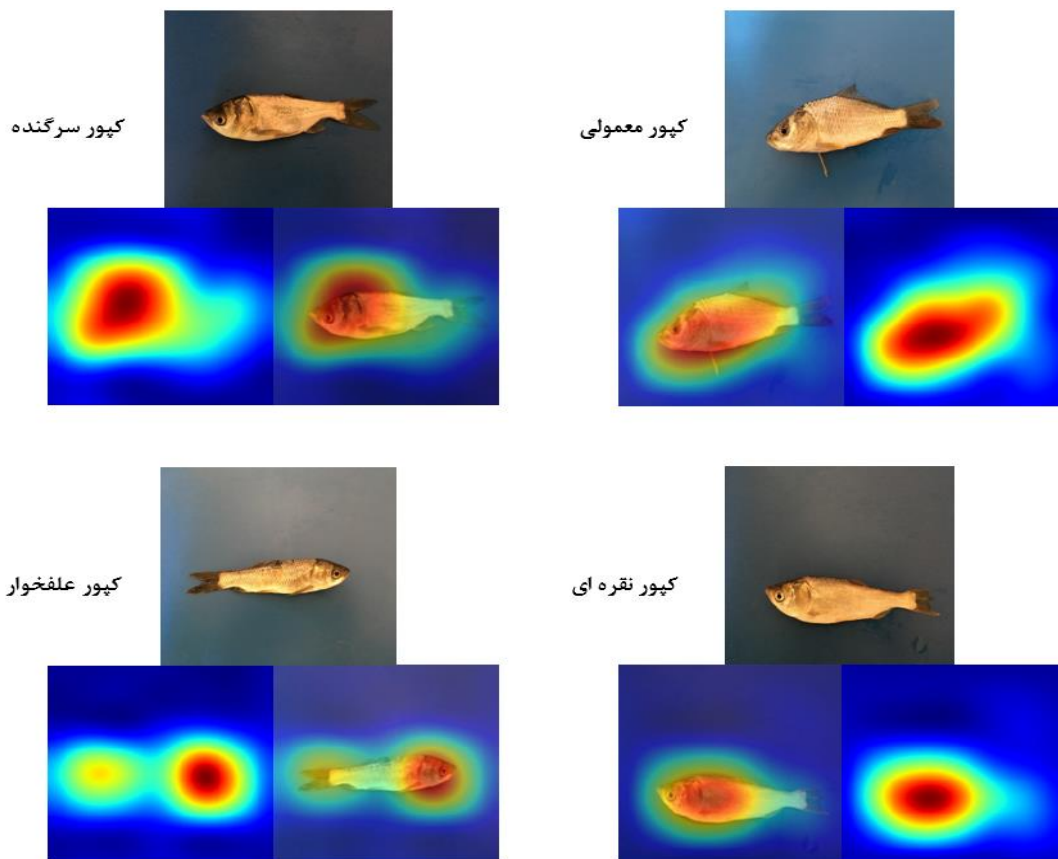
1 - Feed-Forward

2 - Back-Propagation

3 - Gradient-weighted Class Activation Mapping



شکل ۶- نمونه‌ای از لگوهای استخراج شده توسط شبکه عصبی کانولوشنی توسعه داده شده در لایه‌های کانولوشنی هر بلوک



شکل ۷- نتایج اجرای روش Grad-CAM بر روی تصاویر نمونه از هر کلاس ماهی مورد بررسی در تحقیق جاری

بطور نمونه، کپور معمولی یک باله پشتی بزرگ با یک خار دندانه‌دار دارد در حالی که سایر سه گونه، یک باله پشتی کوتاه داشته که فاقد خار دندانه‌دار می‌باشند. همچنین مدل توسعه داده شده ویژگی‌هایی از سر ماهیان را استخراج نموده است. جدای از موقعیت مکانی چشم‌ها در سر ماهیان، محل دهان و همچنین اندازه و شکل آن‌ها جز فاکتورهایی می‌باشند که توسط مدل مورد استفاده قرار گرفته‌اند. شاخص سر که به صورت نسبت طول سر به طول بدن تعریف می‌گردد، در کپور سرگنده نسبت به سایر گونه‌های مورد مطالعه بالاتر می‌باشد. همچنین، کپور سرگنده و کپور نقره‌ای دهان رو به بالا دارند در حالی که دهان در کپور علفخوار اندکی رو به پایین می‌باشد (FAO, 1997; Anderson *et al.*, 2008).

در مجموع اهمیت بخش‌ها مختلف ماهی‌ها شامل بدن، سر و باله برای استخراج ویژگی توسط مدل را می‌توان توسط شکل ۷ دریافت. بر این اساس، مهمترین بخش برای استخراج ویژگی‌ها جهت طبقه‌بندی گونه‌های مورد مطالعه، بخش سر می‌باشد. بنابراین ویژگی‌های سلسله‌مراتبی شامل رنگ و بافت از قسمت‌های مختلف گونه‌های ماهیان استخراج شدند. این ویژگی‌ها در تطابق با ویژگی‌هایی است که برای شناسایی و طبقه‌بندی گونه‌های ماهی اعمال می‌شوند (Fischer, 2014). در نتیجه، درک ویژگی‌های بصری پیچیده گونه‌های ماهیان مورد مطالعه و شناسایی آنها بر اساس این ویژگی‌ها با استفاده از مدل‌های CNN امکان پذیر می‌باشد.

نتیجه‌گیری

این مطالعه کاربرد یک مدل مبتنی بر یادگیری عمیق را برای شناسایی چهار گونه از ماهیان را ارائه می‌دهد. یک مدل یادگیری عمیق پیش‌آموزش دیده VGG19 برای

با توجه به شکل ۷ می‌توان نتیجه گرفت که نوروں‌ها در سطح بدن ماهیان فعال گردیده‌اند چرا که فیلترها ممکن است روی رنگ و الگوهای نقطه‌ای پولکا^۱ بدن ماهیان متمرکز شده باشند. گونه‌های ماهیان مورد مطالعه تفاوت‌های ظاهری مختلفی شامل اختلاف در رنگ بدن دارند. رنگ بدن در گونه کپور معمولی از خاکستری تا برونزی متفاوت بوده و رنگ شکم متمایل به زرد یا متمایل به قرمز می‌باشد، در حالی که در کپور نقره‌ای بطور عمده نقره‌ای با طیف تیره‌تر در پشت می‌باشد. در کپور علفخوار، رنگ بدن سایه‌ای زیتونی رنگ با طیف تیره داشته که در پهلوها زرد متمایل به قهوه‌ای و در شکم سفید متمایل به خاکستری دیده می‌شود. در کپور سرگنده، رنگ بدن در پشت تیره و در ناحیه شکمی متمایل به سفید می‌باشد (FAO, 1997; Anderson *et al.*, 2008). همچنین الگوی نقطه‌ای پولکا ممکن است روی ساختار و شکل پولک ماهیان متمرکز شده باشد (Hu *et al.*, 2012).

همچنین شکل ۷ فعال‌سازی نوروں‌ها در چشم گونه‌های مختلف ماهیان را نشان می‌دهد. تفاوت در موقعیت مکانی چشم برای گونه‌های مورد مطالعه گزارش شده است: در کپور سرگنده و کپور نقره‌ای، چشم‌ها در زیر خط میانی بدن قرار گرفته‌اند در حالی که در کپور علفخوار روی خط میانی و در کپور معمولی بالای خط میانی واقع شده‌اند (Anderson *et al.*, 2002; Asian Carp: Key to Identification, 2008). نتایج حاصل از شکل ۷ نشان می‌دهد که مدل پیشنهادی ویژگی‌هایی را از باله ماهیان استخراج نموده است. کلیدهای شناسایی گوناگون کپور ماهیان آسیایی، تفاوت‌هایی در اندازه، شکل و رنگ باله‌ها در میان گونه‌های مورد مطالعه گزارش نموده‌اند (Asian Carp: Key to Identification, 2002; Anderson *et al.*, 2008).

شیلاتی و آبی‌پروری راهگشا و حائز اهمیت باشد. هیچگونه تعارض منافع بین نویسندگان وجود ندارد.

معرفی نمادها

Ac	دقت طبقه‌بند
AUC	سطح زیر منحنی
C _j	کلاس پیش بینی شده توسط طبقه‌بند
C* _i	کلاس واقعی تصویر
FN	تصمیمات منفی ناصحیح
FP	تصمیمات مثبت ناصحیح
n _{ij}	خروجی شبکه طبقه‌بند
n _{i,+}	مجموع اعضای تمامی ستون‌های متعلق به سطر i ام در ماتریس اغتشاش
n _{+,j}	مجموع اعضای تمامی سطرهای متعلق به ستون j ام در ماتریس اغتشاش
Pr	صحت طبقه‌بند
Se	حساسیت طبقه‌بند
Sp	اختصاصی بودن
TN	تصمیمات منفی صحیح
TP	تصمیمات مثبت صحیح

REFERENCES

Anderson, J., Jensen, D., Gunderson, J. & Zhuiko, M. (2008). A Field Guide to Fish Invaders of the Great Lakes Region: Non-native Fish and Native Look-a-Likes. *University of Minnesota Sea Grant Program*.

Asian Carp: Key to Identification. (2002). *National Invasive Species Council materials*, from [https:// digitalcommons.unl.edu/ natlinvasive/7](https://digitalcommons.unl.edu/natinvasive/7).

Baldominos, A., Saez, Y. & Isasi, P. (2018). Evolutionary convolutional neural networks: An application to handwriting recognition. *Neurocomputing*, 283:38-52.

Banan, A., Nasiri, A., & Taheri-Garavand, A. (2020). Deep learning-based appearance features extraction for automated carp species identification. *Aquacultural Engineering*, 89, p.102053.

Boureau, Y.L., Ponce, J. & LeCun, Y. (2010). A theoretical analysis of feature pooling in visual recognition. In *Proceedings of the 27th international conference on machine learning (ICML-10)*, pp. 111-118.

Chambah, M., Semani, D., Renouf. A., Courtellemont, P. & Rizzi, A. (2004). Underwater color constancy:

توسعه شبکه عصبی کانولوشنی مورد استفاده قرار گرفت. ساختار شبکه VGG19 توسط لایه‌های پولینگ، تماماً متصل با ۲۵۶ نرون، لایه نرمال‌سازی، لایه رهاسازی و لایه تماماً متصل با ۴ نرون بروزسانی گردید. مدل CNN ارائه شده ویژگی‌های سلسه مراتبی‌ای را که در تطابق با کلیدهای شناسایی این ماهیان بود بطور خودکار استخراج نمود. مدل پیش‌نهادی توانست با دقت کلی طبقه‌بندی ۹۶/۷۷ درصد کلاس‌های مختلف ماهی کپور را تشخیص و طبقه‌بندی نماید. در پایان، نتایج بدست آمده نشان داد که ویژگی‌های بصری کارآمد ماهی جهت انجام شناسایی گونه‌های مختلف توسط مدل مبتنی بر CNN قابل تعیین می‌باشد. این مدل یک الگوریتم دقیق، غیرمخرب و سریع را برای شناسایی گونه‌های ماهیان ارائه می‌نماید که می‌تواند در مدیریت

enhancement of automatic live fish recognition. *Proceedings of SPIE / IS&T Electronic Imaging*, Jan 18-22, San Jose, California, USA.

Dayrat, B. (2005). Towards integrative taxonomy. *Biological Journal of the Linnean Society*, 85:407-415.

Erhan, D., Bengio, Y., Courville, A., Manzagol, P.A., Vincent, P. & Bengio, S. (2010). Why does unsupervised pre-training help deep learning. *Journal of Machine Learning Research*, 11(Feb): 625-660.

Fischer, J. (2014). Fish identification tools for biodiversity and fisheries assessments: review and guidance for decision-makers. *FAO Fisheries and Aquaculture Technical Paper*, 585, p.I.

Food and Agriculture Organization (FAO). (1997). *FAO Database on Introduced Aquatic Species*, from <http://www.fao.org/fishery/dias/en>.

Food and Agriculture Organization (FAO). (2018). *Fishery and aquaculture statistics*, from <http://www.fao.org/fishery/nems/41266/en>.

Gaber, T., Tharwat, A., Hassanien, A.E. & Snasel, V. (2016). Biometric cattle

- identification approach based on Weber's local descriptor and AdaBoost classifier. *Computers and Electronics in Agriculture*, 122, 55–66.
- Ghazi, M.M., Yanikoglu, B. & Aptoula, E. (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235: 228-35.
- Girshick, R., Donahue, J., Darrell, T. & 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*, pp. 580-587.
- Hasanpour Mati Kalaei, S.H. & Saadati, R. (2016). A review of the applications of convolutional neural network and in-depth learning in computer vision. *Third National Conference on Electrical and Computer Engineering Distributed Systems and Smart Grids*, Kashan, IRAN. (In Farsi).
- Hernández-Serna, A. & Jiménez-Segura, L.F. (2014). Automatic identification of species with neural networks. *PeerJ*, 2, p.e563.
- Hu, J., Li, D., Duan, Q., Han, Y., Chen, G. & Si, X. (2012). Fish species classification by color, texture and multi-class support vector machine using computer vision. *Computers and Electronics in Agriculture*, 88, 133–140.
- Iran Fisheries Organization. (2017). *Iran Fisheries Organization statistical yearbook*. Tehran, IRAN. (In Farsi).
- Javanmardi, S. & Zare Chahooki, M.A. (2018). Refining large scale image annotation via transfer learning in deep convolutional neural network. *Machine Vision and Image Processing*, 5(1), 39-52. In Farsi.
- Jiménez-Gamero, I., Dorado, G., Muñoz-Serrano, A., Analla, M. & Alonso-Moraga, A. (2006). DNA microsatellites to ascertain pedigree-recorded information in a selecting nucleus of Murciano-Granadina dairy goats. *Small Ruminant Research*, 65(3), 266–273.
- Khalifa, N.E.M., Taha, M.H.N. & Hassanien, A.E. (2018) Aquarium Family Fish Species Identification System Using Deep Neural Networks. In *International Conference on Advanced Intelligent Systems and Informatics*, vol 845. Springer, Cham.
- Labatut, V. & Cherifi, H. (2012). Accuracy measures for the comparison of classifiers. *arXiv preprint arXiv*, 1207.3790.
- Lee, D.J., Schoenberger, R., Shiozawa, D., Xu, X. & Zhan, P. (2004). Contour matching for a fish recognition and migration monitoring system. *Proceedings of the SPIE optics east, Two and Three-Dimensional Vision Systems for Inspection, Control, and Metrology II*, Oct 25-28, Philadelphia, PA, USA.
- Li, L. & Hong, J. (2014). Identification of fish species based on image processing and statistical analysis research. In: *2014 IEEE International Conference on Mechatronics and Automation*, August, IEEE, pp. 1155–1160.
- Li, S., Liu, G., Tang, X., Lu, J. & Hu, J. (2017). An ensemble deep convolutional neural network model with improved DS evidence fusion for bearing fault diagnosis. *Sensors*, 17(8), p.1729.
- Lim, K., Jang, W.D., & Kim, C.S. (2017). Background subtraction using encoder-decoder structured convolutional neural network. In *14th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, 1-6.
- Liu, B., Zhang, X., Gao, Z. & Chen, L. (2017). Weld defect images classification with VGG16-Based neural network. In *International Forum on Digital TV and Wireless Multimedia Communications*, Singapore, Springer; 215-223.
- Lu, Y.C., & Kuo, Y.F. (2019). Identifying species of common sea fish harvested by longliner using deep convolutional neural networks. In *American Society of Agricultural and Biological Engineers Annual International Meeting*, p. 1.
- Rova, A., Mori, G., & Dill, L.M. (2007). One fish, two fish, butterfly, trumpeter: Recognizing fish in underwater video.

- Proceedings of the IAPR Conference on Machine Vision Applications*, May 16-18, Tokyo, Japan.
- Rusk, C.P., Blomeke, C.R., Balschweid, M.A., Elliot, S., & Baker, D. (2006). An evaluation of retinal imaging technology for 4-h beef and sheep identification. *The Journal of Extension*, 44(5), 1–33.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., & McCool, C. (2016). Deepfruits: A fruit detection system using deep neural networks. *Sensors*, 16(8):1222.
- Simonyan, K. & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv*, 1409.1556.
- Sokolova, M. & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4): 427–437.
- Storbeck, F. & Daan, B. (2001). Fish species recognition using computer vision and a neural network. *Fisheries Research*, 51(1), 11–15.
- Tharwat, A. (2016). Linear vs. quadratic discriminant analysis classifier: a tutorial. *International Journal of Applied Pattern Recognition*, 3(2), 145–180.
- Tharwat, A., Hemedan, A.A., Hassanien, A.E. & Gabel, T. (2018). A biometric-based model for fish species classification. *Fisheries research*, 204: 324-336.
- Tung, C., Hsieh, C.L. & Kuo, Y.F. (2017). Sea fish identification using convolutional neural network. In *American Society of Agricultural and Biological Engineers Annual International Meeting*, p. 1.
- Wu, R., Yan, S., Shan, Y., Dang, Q. & Sun, G. (2015). Deep image: Scaling up image recognition. *arXiv preprint arXiv*, 1501.02876.
- Zhang, Z., Niu, Z., & Zhao, S. (2011). Identification of freshwater fish species based on computer vision. *Transactions of the Chinese Society of Agricultural Engineering*, 27(11): 388–392.
- Zeiler, M.D. (2013). Hierarchical convolutional deep learning in computer vision. Ph.D dissertation, New York University, New York.