

Ones Using Deep Designing a Hardware System to separate Defective Pistachios From Healthy Neural Networks

ALI DINI¹, HOSSEIN GHAYOUMI ZADEH^{2*}, ALIAKBAR RAHIMIFARD², ALI FAYAZI², MOHAMMADALI EFTEKHARI², MEHDI ABBASZADEH²

1. Pistachio Safety Research Center, Rafsanjan University of Medical Sciences, Rafsanjan, Iran.

2. Dept. of Electrical Engineering, Faculty of Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran.

(Received: May. 4, 2019- Revised: Oct. 23, 2019- Accepted: Nov. 22, 2019)

ABSTRACT

The aim of this study is to develop imaging algorithms to improve the grade of nuts with shell defects such as oily stains, dark stains, adhering hull, damage seed defects, and fungal decay. All these defects indicate the risk of Aflatoxin contamination. Convolutional Neural Networks (CNNs) have become prominent in various fields of machine vision and image classification. In this study, a laboratory hardware setup based on a convolutional neural network is designed for sorting pistachios. The total number of collected data is 958 images, which includes 276 images of defective pistachios and 682 images of healthy pistachios. The classification of healthy and defective images has been accomplished by 3 types of deep convolutional neural networks including Google net, resnet18 and vgg16. The accuracy and specificity of the results obtained using the pre-trained deep neural network models of Google net, resnet18 and vgg16 are 95.8% -97.1%, 97.2% -96.7%, and 95.83% -97.08%, respectively.

Keywords: Aflatoxin, Pistachio, Deep Neural Network, Convolution, Classification.

طراحی یک سامانه سخت افزاری جهت جداسازی پسته‌های معیوب از سالم با استفاده از شبکه‌های عصبی

عمیق

علی دینی^۱، حسین قیومی زاده^{۲*}، علی اکبر رحیمی فرد^۲، علی فیاضی^۲، محمدعلی افتخاری^۲، مهدی عباس زاده^۲

۱. علوم و صنایع غذایی، مرکز تحقیقات سلامت پسته، دانشگاه علوم پزشکی رفسنجان، رفسنجان، ایران.

۲. گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران.

(تاریخ دریافت: ۱۳۹۸/۲/۱۴ - تاریخ بازنگری: ۱۳۹۸/۸/۲۳ - تاریخ تصویب: ۱۳۹۸/۹/۱۱)

چکیده

هدف از این مطالعه توسعه الگوریتم‌های تصویربرداری، جهت بهبود درجه‌بندی آجیل‌ها با نقص‌های پسته از جمله لکه‌های چربی، لکه‌های تیره، بدنه چسبیده، نقص‌های هسته‌ای آسیب و پوسیدگی قارچی می‌باشد. همه این نقص‌ها نشان‌دهنده خطر آلودگی به آفلاتوکسین هستند. شبکه‌های عصبی کانولوشن در زمینه‌های مختلف بینایی ماشین و طبقه‌بندی تصویر برجسته شده‌اند. در این پژوهش یک مدل سخت‌افزار آزمایشگاهی بر مبنای شبکه عصبی کانولوشن جهت طبقه‌بندی پسته‌ها طراحی شده است. داده‌های جمع‌آوری شده ۹۵۸ تصویر، شامل ۲۷۶ تصویر از پسته‌های معیوب و ۶۸۲ تصویر از پسته‌های سالم می‌باشند. طبقه‌بندی تصاویر شامل سالم و معیوب بر اساس ۳ نوع شبکه عصبی کانولوشن عمیق شامل Google net، resnet18 و vgg16 انجام شده است. میزان دقت و ویژگی نتایج به دست آمده با استفاده از مدل‌های شبکه‌های عصبی عمیق از پیش آموزش داده شده Google net، resnet18 و vgg16 به ترتیب برابر ۹۵/۸٪، ۹۷/۱٪، ۹۷/۲٪، ۹۷/۷٪ و ۹۶/۸٪ است.

واژه‌های کلیدی: آفلاتوکسین، پسته، شبکه عصبی عمیق، کانولوشن، طبقه‌بندی.

مقدمه

کرده و قارچ را تولید می‌کند و قارچ‌ها نیز سم تولید می‌کنند. اگر چه تعداد معدودی از پسته‌ها، آلوده به آفلاتوکسین هستند ولی سرعت انتشار آلودگی زیاد بوده و توده بزرگی از پسته آلوده خواهد شد (Bond et al., 2017).

تشخیص پسته‌های پوک در میان پسته نامطلوب عمدتاً توسط اپراتورهای انسانی انجام می‌شود (Omid, 2011). استفاده از اپراتورهای انسانی با برخی معایب در این فرآیند همراه است. به علت نزدیکی ابعاد فیزیکی و مشخصات نوری دانه‌های پسته، یک سامانه جداسازی مؤثر نمی‌تواند توسط اپراتور و یا سامانه‌های مکانیکی یا نوری-الکتریکی صورت گیرد و همچنین استفاده از نیروی انسانی، باعث کاهش دقت و بازده در عمل جداسازی و افزایش هزینه نسبت به کارگیری ماشین بینایی در مدت زمان خواهد شد. واضح است که درجه‌بندی مکانیزه پسته مزایای زیادی از جمله حذف دستمزدها از طریق درجه‌بندی دستی، یکنواختی بیشتر و تولید بیشتر بهداشتی در مقایسه با روش‌های دستی را آشکار می‌سازد (Nouri-Ahmadabadi et al., 2017 and Omid et al., 2017). علاوه بر این طراحی ماشین‌های مرتب‌سازی خودکار می‌تواند مشتریان بیشتری را جذب کند و از موقعیت

میوه‌های خشک حاوی مواد مغذی غنی هستند، از این رو در معرض آلودگی با قارچ‌های سمی و آفلاتوکسین‌ها می‌باشند. از جمله دلایل آسیب‌پذیری آن‌ها، آب و هوای ضعیف، فرآوری و شرایط نگهداری می‌باشد. پسته یکی از مهم‌ترین آجیل‌های جهان است. آجیل پسته به علت خواص تغذیه‌ای بالا و طعم مطلوب، عمدتاً به صورت خام، نمکی و برشته‌شده مصرف می‌شود. در عین حال آجیل پسته به طور گسترده در صنایع غذایی از قبیل میان‌وعده، بستنی و شیرینی استفاده می‌شود (Kola et al., 2018). طبق گزارش سازمان غذا و مواد غذایی (۲۰۱۲)، ایران با تولید ۴۷۲۰۹۷ تن، بزرگ‌ترین تولیدکننده پسته در جهان است (Gupta et al., 2009). این نقش مهمی در صادرات و اقتصاد ایران به عنوان یک محصول غیر نفتی است. آفلاتوکسین به عنوان عضو خانواده میکوتوکسین‌ها، از متابولیت‌های ثانویه کپک‌هایی چون آسپرژیلوس فلاوس و آ. پارازیتیکوس است. قارچ‌های مذکور هم روی درخت و هم طی مراحل فرآوری و انبارمانی می‌توانند محصول را آلوده کنند و در صورت آلوده شدن محصول به هاگ آن‌ها و فراهم شدن شرایط دمایی و رطوبتی مطلوب، هاگ رشد

یادگیری عمیق به کامپیوتر اجازه می‌دهد که با استفاده از تجربیات و درکی که از محیط پیرامون خود به دست می‌آورد، به صورت سلسله‌مراتبی، مفاهیم پیچیده‌تر را به کمک مفاهیم ساده‌تر مدل کند. ضعف شبکه‌های عصبی سنتی این است که اگر به‌طور فرض برای انجام کاری پیچیده از آن استفاده شود، به‌ناچار بایستی پارامترهایی مانند تعداد نرون‌ها را زیاد انتخاب کرد. با این کار ممکن است تعداد وزن‌های یک شبکه عصبی چندین میلیون و یا حتی بیشتر بشود. محاسبه این تعداد وزن‌ها نیازمند سخت‌افزارهای بسیار قدرتمند هستند و بسیار زمان‌بر می‌باشد. همچنین، باید حافظه زیادی برای ذخیره این وزن‌ها اختصاص داده شود. علاوه بر این بایستی مرحله استخراج و انتخاب ویژگی را خود کاربر انجام داده و به شبکه اعمال نماید. در نهایت نقص دیگر این شبکه‌ها انتشار خطا در این شبکه‌ها می‌باشد (Bengio, et al. 2015). یکی از مهم‌ترین ضعف‌های شبکه‌های عصبی سنتی مرحله استخراج ویژگی می‌باشد که بنا به نوع کار بایستی کاربر بهترین ویژگی‌ها را استخراج نموده و به شبکه عصبی وارد نماید اما شبکه‌های عصبی عمیق خودشان بهترین ویژگی‌های مورد نیاز را جهت رسیدن به پاسخ مطلوب به دست می‌آورند. در (Farazi, Abbas-Zadeh et al., 2017) نویسندگان از شبکه عصبی عمیق Alex Net برای درجه‌بندی پسته‌ها استفاده کردند.

شبکه‌های عصبی عمیق در سالیان اخیر به‌وفور در زمینه مرتب کردن و جداسازی غلات و حبوبات استفاده می‌شود. افزایش ارزش قهوه به‌طور مؤثر در محل تولید مورد نظر است. نویسندگان در (pinto et al., 2017) یک سامانه طبقه‌بندی لوبیا قهوه برای تولیدکنندگان قهوه در تیمور شرقی ارائه دادند. آن‌ها از طریق شبکه‌های عصبی عمیق، به دقت ۹۸/۷ درصد جهت دسته‌بندی پسته‌ها بر اساس نقص‌های آن، دست پیدا کردند. در (Tri, Van Hoai et al., 2016) یک چارچوب جدید مبتنی بر تکنیک‌های پیشرفته یادگیری عمیق، برای ارزیابی کیفیت مزارع برنج ویتنام ارائه شد. آن‌ها ابتدا از مزارع برنج در ارتفاعات کم به‌وسیله پهباد عکس‌برداری نمودند. سپس به کمک شبکه‌های عصبی عمیق تصاویر را در بسیاری از کلاس‌های مرتبط با کیفیت‌های کم و زیاد مزارع برنج طبقه‌بندی نمودند که دقت حاصل شده برابر ۷۲٪ بوده است. همچنین در (Rong et al., 2019) به تشخیص سریع اجسام خارجی در گردو با استفاده از دید کامپیوتری پرداختند. در این مطالعه، دو ساختار شبکه عصبی مختلف برای جداسازی خودکار تصاویر و تشخیص اشیای خارجی با اندازه مختلف (به عنوان مثال، خرده‌های برگ، خرده‌های برگ خشک و گردوغبار)

ایران در صادرات این تولید ارزشمند حمایت کند. بنابراین وظیفه-ی دسته‌بندی باید به‌طور مؤثری توسط یک سامانه ماشین‌بینایی با توانایی پردازشی چندگانه‌ی ویژگی‌های پسته صورت گیرد (Omid, Firouz et al., 2017).

از میان روش‌های بسیاری که برای ارزیابی کیفیت محصولات کشاورزی وجود دارد سامانه ماشین‌بینایی به‌عنوان قدرتمندترین آن‌ها اثبات شده است. به همین جهت، در سال‌های اخیر، دیدگاه کامپیوتری بر اساس پردازش تصویر یکی از تکنیک‌های جایگزین مدرن است که توجه بسیاری را به خود جلب کرده است. شناخت شی‌از اهداف اولیه و در عین حال چالش‌برانگیز در سامانه‌های مبتنی بر بینایی ماشین بوده است. سامانه دسته‌بندی‌کننده‌ی مصنوعی کامپیوتری که برای شبیه‌سازی تصمیم‌گیری‌های انسان برای کیفیت محصول در نظر گرفته شده اخیراً به شدت مورد بررسی قرار گرفته است (Shahabi et al., 2014). در (Omid, 2011) یک روش مبتنی بر چشم‌انداز ماشینی برای طبقه‌بندی مغز پسته پوست‌کنده، استفاده شد. از سیگنال‌های آکوستیک برای طبقه‌بندی آجیل نزدیک پوسته و پوسته باز استفاده کرد. در این مطالعه، چارچوب مبتنی بر دید ماشین به کار گرفته شده است که شامل تقسیم‌بندی شی اولیه و تکنیک یادگیری ماشین برای طبقه‌بندی اشیاء به گروه‌های مورد نظر است. یک سامانه دسته‌بندی هوشمند برای پسته‌های خندان و غیرخندان طراحی شده است (Kavdir and Guyer, 2008). سامانه شامل یک تغذیه، یک بخش آوایی، یک واحد کنترل الکترونیک، یک مکانیسم بادی برای حذف پسته‌های غیرخندان و یک دسته‌بندی‌گر شبکه‌های عصبی مصنوعی بود. شناسایی، بر اساس روش ترکیب تحلیل مؤلفه‌های اصلی آوایی برخورد پسته‌ها با استفاده از شبکه‌های عصبی مصنوعی صورت گرفت. برای به دست آمدن ویژگی‌های مفید برای استفاده در شبکه عصبی، از هر دو حوزه‌ی زمان و فرکانس سیگنال صدای ثبت شده، استفاده شد. در تحقیق دیگری که اخیراً صورت گرفت یک روش جدیدی برای تقسیم‌بندی کشمش توسعه داده شده است. در این روش از سامانه ماشین‌بینایی و روش‌های مختلف دسته‌بندی‌کننده‌ها، برای طبقه‌بندی کشمش به چهار کلاس استفاده شد. برای ایجاد یک نورپردازی یکنواخت و حذف نویزهای محیط، آنها از دولامپ فلوروسنت در بالای نمونه‌ها استفاده کردند و پس زمینه‌ی قسمت عکس برداری را مشکی انتخاب کردند (Mollazade et al., 2012 and Omid et al., 2017).


یادگیری عمیق از حوزه‌های نسبتاً جدیدی هست که در طی چند سال اخیر به‌شدت مورد استقبال قرار گرفته است.

یک شبکه عصبی عمیق از نوع کانولوشن جهت طبقه‌بندی پسته‌های سالم از معیوب می‌باشد.

مواد و روش‌ها

سامانه پیشنهادی شامل قسمت سخت‌افزار و نرم‌افزار هست. قسمت سخت‌افزار شامل یک نوار نقاله (که توان خود را از یک موتور DC دریافت می‌کند)، دو سنسور IR، یک سروموتور و یک raspberry pi مدل B+ به همراه دوربین مخصوص آن هست. نمونه سخت‌افزار ساخته شده در شکل ۱ نشان داده شده است. روند کار به این صورت است که در ابتدا پسته به صورت دستی بر روی نوار نقاله قرار می‌گیرد و پس از قرار گرفتن در مقابل سنسور اول، دوربین عکس گرفته و پسته با استفاده از شبکه‌ی عصبی به‌عنوان سالم و یا معیوب دسته‌بندی می‌شود. سپس به سمت سنسور دوم حرکت می‌کند و پس از رسیدن به آن، اگر پسته معیوب باشد توسط سروموتور از نوار نقاله حذف شده و در غیر این صورت، به بخش بعدی فرآیند منتقل خواهد شد.

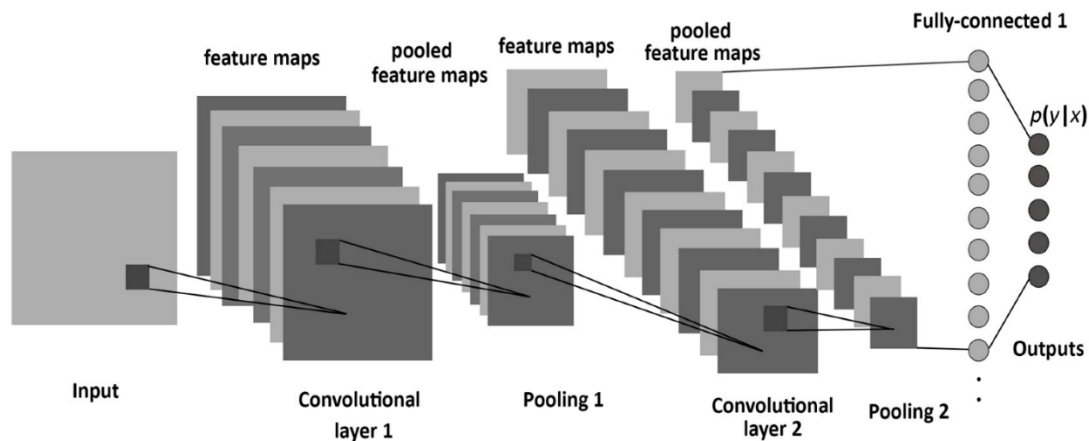
و اشیا خارجی ساخت انسان (به عنوان مثال، تکه‌های کاغذ، مواد بسته‌بندی، خرده‌های پلاستیکی و قطعات فلزی) ارائه شد. روش پیشنهادی قادر به بخش‌بندی صحیح ۹۹٫۵ درصد از مناطق هدف در میان ۱۰۱ تصویر تست و طبقه‌بندی صحیح ۹۵ درصد از اهداف خارجی در تصاویر ۲۷۷ اعتبار سنجی بود. با توجه به مطالعات انجام شده، علی‌رغم بسیاری از الگوریتم‌های معرفی شده در حوزه بینایی ماشین برای تشخیص و طبقه‌بندی، تعریف دستی ویژگی‌های منحصر به فرد جهت رسیدن به طبقه‌بند مطلوب ممکن است اما برای سایر وظایف قابل اجرا نیست. علاوه بر این، سطح عمیق استخراج ویژگی ممکن است با استفاده از روش‌های استخراج ویژگی مرسوم به دست نیاید. برای این منظور، شبکه عصبی کانولوشن عمیق برای پرداختن به چنین محدودیت‌هایی معرفی شده است. علاوه بر این، با استفاده از پیش افزایش تصاویر، ویژگی‌های عمیق نهایی نسبت به پارامترهای بسیاری چون مقیاس گذاری، چرخش، شرایط روشنایی تصویر ثابت و مقاوم خواهد بود. به همین علت پیشنهاد مقاله استفاده از



شکل ۱- سخت‌افزار طراحی شده جهت پیاده‌سازی شبکه عصبی

یک معماری شبکه عصبی کانولوشن در شکل ۲ نمایش داده شده است. به‌طور کلی، یک شبکه عصبی کانولوشن از سه لایه اصلی که عبارت‌اند از: لایه کانولوشن، لایه Pooling و لایه تماماً متصل تشکیل می‌شود. لایه‌های مختلف وظایف مختلفی را انجام می‌دهد. در هر شبکه عصبی کانولوشن دو مرحله پیش‌خور و پس‌انتشار برای آموزش وجود دارد.

قسمت اعظم و مهم کار قسمت هوش مصنوعی سخت‌افزار هست. برای قسمت هوش مصنوعی نرم‌افزار از شبکه‌های عصبی عمیق استفاده شده است. شبکه‌های عصبی کانولوشن یکی از مهم‌ترین روش‌های یادگیری عمیق هستند که در آن‌ها چندین لایه با روشی قدرتمند آموزش می‌بینند (Chambolle, De Vore et al. 1998). این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی کامپیوتر است. تصویر کلی



شکل ۲- یک طرح کلی از معماری یک شبکه عصبی کانولوشن

پیش آموزش دیده را در نظر گرفت و از آن به عنوان یک ویژگی ورودی برای یادگیری یک کار طبقه بندی استفاده کرد. طبقه بندی تصویر با استفاده از استخراج ویژگی معمولاً سریع تر و کم تر از یک فرآیند یادگیری انتقالی است که شامل تنظیم وزن و بایاس در لایه های عمیق است. می توان به سرعت یک طبقه بندی کننده برای یک کار جدید با استفاده از ویژگی استخراج شده در لایه الحاقی به عنوان بردار ستون آموزشی ساخت (Géron, 2017). همچنین سامانه قادر به بارگذاری شبکه ای از پیش آموزش دیده نظیر Google NeT, resnet18 و vgg16 می باشد. مشخصه های خروجی از یک لایه الحاقی به عنوان ورودی مدل طبقه بندی بردار پشتیبان با دو کلاس پسته سالم و معیوب مورد استفاده قرار می گیرند. مشخصات هر یک از این شبکه های پیش آموزش دیده شده در جدول ۲ نمایش داده شده است.

با پیشرفت های اخیر استفاده شبکه های عصبی کانولوشن در حوزه بینایی کامپیوتر، مدل های معروفی از شبکه های عصبی کانولوشن از جمله GoogleNet, VGG, ResNet و غیره به وجود آمدند. در این بخش مدل هایی که بیشتر متداول بوده، مورد مطالعه قرار گرفت و در تشخیص پسته های معیوب از آن ها استفاده شد. اما یکی از مهم ترین چالش ها در یادگیری عمیق و شبکه های عصبی کانولوشن آموزش آن ها هست. به دلیل حجم بالای لایه ها و وزن های این شبکه، آموزش آن ها بسیار مشکل بوده و نیاز به پردازنده های قوی با سرعت بالا هست. به همین منظور در حال حاضر برای استفاده از شبکه های یادگیری عمیق دیگر کل شبکه را از ابتدا آموزش نداده بلکه از الگوریتم ها و مدل های پیش آموزش داده شده استفاده می کنند. بنابراین به جای اینکه یک شبکه عصبی کانولوشن عمیق را از پایه طراحی شود، می توان یک شبکه

جدول ۱- مقایسه مشخصات برخی از شبکه های عصبی عمیق پیش آموزش دیده

مدل شبکه	عمق	تعداد پارامترها (میلیون)
Google net	۲۲	۷
resnet18	۱۸	۱۱/۷
vgg16	۱۶	۱۳۸

آموزش این الگوریتم همان طور که بیان شد ابتدا مدل با پایگاه داده image net اجرا شده و وزن های اولیه به دست می آید (Wang et al., 2015). پس از آن بر اساس پایگاه داده موجود در مسئله، الگوریتم مورد نظر آموزش می بیند. در این آموزش معمولاً بر اساس پایگاه داده موجود تعدادی از لایه ها که کلیات تصاویر را بیان می کنند به صورت یخ زده درآمده تا در طول آموزش وزن های

این الگوریتم های از پیش آموزش دیده در چالشی به نام image net که یک رقابت سالانه است مطرح شده و از لحاظ ساختار داخلی، سرعت و دقت مورد مقایسه قرار می گیرند. در این چالش شرکت کننده ها الگوریتم های خود را بر پایه پایگاه داده image net ارائه می دهند. پایگاه داده image net شامل ۱۴ میلیون تصویر طبقه بندی شده به همراه برچسب هست. برای

درصد از داده‌ها به‌عنوان آموزش و ۳۰ درصد به‌عنوان تست در نظر گرفته شده است. شکل ۳ یک نمونه از انواع پسته به‌کاررفته در این پژوهش را نشان می‌دهد. همان‌طور که قابل‌مشاهده است تصاویر در قالب الگوهای متفاوتی می‌باشد. اصول این پژوهش استفاده از شبکه عصبی کانولوشن عمیق بر روی این تصاویر جهت طبقه‌بندی می‌باشد.

آن‌ها تغییر نکنند. حال اگر تعداد داده‌های استفاده شده در مقایسه با تعداد داده‌های پایگاه image net کم باشد فقط لایه آخر بلوک تمام متصل شده آموزش می‌بیند در غیر این صورت لایه‌های بیشتری از لایه‌ی آخر، آموزش پیدا می‌کنند. تعداد ۹۵۸ نمونه پسته شامل ۲۷۶ تصویر از پسته‌های معیوب و خراب و ۶۸۲ تصویر از پسته‌های سالم می‌باشند. ۷۰



شکل ۳- نمونه‌ای از تصاویر پسته‌های سالم و معیوب جمع‌آوری شده

تعیین‌شده، کانولوشن می‌شود. مقدار و ابعاد این کرنل‌های کانولوشنی بسته به نوع شبکه کانولوشنی مورد‌استفاده با یکدیگر متفاوت می‌باشد. همچنین بسته به تعداد صفر گذاری تصویر، ابعاد خروجی می‌تواند هم‌اندازه تصویر ورودی باشد و یا کوچک‌تر و بزرگ‌تر باشد. همچنین می‌توان در اینجا از چند کرنل کانولوشنی استفاده نمود (Seyfollahzadeh Bandi, 2017). عملگر کانولوشن برای داده‌ها در اینجا به معنی عملگری است که محلی بوده و تغییرناپذیر با جابجایی باشد. نگاشت ورودی به خروجی برای عملگر کانولوشنی در اینجا با رابطه ۱ نشان داده شده است.

$$f : R^{M \times N \times K} \rightarrow R^{M' \times N' \times K'} \quad (\text{رابطه ۱})$$

همان‌طور که دیده می‌شود عملگر کانولوشن در اینجا یک نگاشت از یک داده سه‌بعدی به یک داده سه‌بعدی دیگر و در مجموعه اعداد حقیقی می‌باشد. رابطه ۲ نحوه اعمال عملگر کانولوشن مورد‌استفاده را به‌صورت ریاضی نمایش می‌دهد:

$$y_{i'j'k'} = \sum_{ijk} w_{ijk} x_{i+i', i+j', k} \quad (\text{رابطه ۲})$$

در اینجا w بانک فیلتر کانولوشنی است و یک داده چهاربعدی است. در حقیقت بعد چهارم شماره فیلتر در بانک فیلتر است و خود فیلتر یک توده وزنی سه‌بعدی است. به عبارت بهتر، در ابتدا فیلتر شماره اول سه‌بعدی کانولوشنی بر روی داده سه‌بعدی می‌لغزد و در هر موقعیتی که قرار گرفت بین درایه‌های متناظر ضرب نقطه‌ای صورت گرفته و حاصل تمام ضرب‌ها با

حال اگر طبق این پیش آموزش‌ها، بخواهیم روند را انجام دهیم بایستی به‌صورت مراحل زیر پیاده‌سازی نماییم. در مرحله اول تصویر ورودی به شبکه اعمال می‌شود اما قبل از اینکه تصاویر به‌عنوان ورودی به شبکه‌های کانولوشنی داده شوند، باید پیش‌پردازش بر روی آن‌ها صورت گرفته و آماده پردازش شوند. این آماده‌سازی می‌تواند شامل برش، تغییر اندازه، نرمالیزه‌سازی تصویر، صفر گذاری و ... باشد. به همین منظور در ابتدا باید تصویر ورودی، در صورت لزوم تغییر اندازه داده شود و منطبق بر ابعاد لایه ورودی شبکه گردد. لذا در مرحله اول تصاویر ورودی باید به‌اندازه استاندارد این شبکه‌های پیش آموزش‌دیده دربیایند. در این مرحله تصاویر رنگی جمع‌آوری شده را به‌اندازه $3 \times 224 \times 224$ تغییر اندازه می‌دهیم. بعد سوم مربوط به کانال‌های رنگ‌های پایه قرمز، سبز و آبی می‌باشد. هرکدام از درایه‌های این ماتریس سه‌بعدی مقداری بین 0 تا ۲۵۵ دارند که 0 نشان‌دهنده کمترین میزان روشنایی و ۲۵۵ نشان‌دهنده بیشترین مقدار روشنایی هست (Seyfollahzadeh Bandi, 2017).

پس از اینکه پیش‌پردازش بر روی تصویر انجام شد و تصاویر به‌اندازه استاندارد تغییر داده شدند، تصویر به ورودی لایه اول کانولوشنی داده می‌شود. حالا باید در مرحله دوم با کرنل‌های^۲ (هسته یا فیلتر) کانولوشنی لایه اول عملیات کانولوشن انجام شوند. هر لایه کانولوشنی شامل سه زیر لایه می‌باشد. در زیر لایه اول تصویر پیش‌پردازش شده با کرنل‌های کانولوشنی از پیش

کانولوشنی مورد استفاده این مرحله به تعداد معینی، تکرار می‌شود. بعد از اتمام لایه‌های کانولوشنی می‌توان از یک یا چند لایه تمام-متصل برای نگاشت نهایی ویژگی‌ها به دست آمده استفاده کرد. یک لایه تمام متصل دقیقاً مانند یک لایه کانولوشنی است با این تفاوت که در اینجا تعاملات پراکنده صورت نمی‌گیرد و دقیقاً مانند شبکه‌های عصبی سنتی یک اتصال کامل بین این لایه و لایه پیش از آن برقرار می‌شود. خروجی آخرین لایه بردار یک بعدی است و تعداد اعضای این بردار برابر با تعداد کلاس‌های دسته‌بندی است. این لایه در حقیقت کار دسته‌بندی را انجام می‌دهد. در تمامی ساختارهای کانولوشنی آخرین لایه تمام متصل به یک لایه softmax متصل می‌شود. در حقیقت لایه softmax کار طبقه‌بندی در شبکه‌های کانولوشنی را انجام می‌دهد. این لایه شامل تعدادی نورون برابر با تعداد کلاس‌های مسئله دسته‌بندی است و برای نگاشت نهایی ویژگی و اعمال دسته‌بندی استفاده می‌شود (Seyfollahzadeh Bandi, 2017).

در اینجا به منظور تنظیم پارامترهای شبکه و یا به عبارت دیگر همان آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود. برای این کار خروجی شبکه را با استفاده از یک تابع خطا با پاسخ صحیح مقایسه کرده و این طور میزان خطا محاسبه می‌شود. نحوه محاسبه خطای تجربی به صورت رابطه ۵ می‌باشد:

$$L(w) = \frac{1}{n} \sum_{i=1}^n l(Z_i; f(X_i; w)) \quad (\text{رابطه ۵})$$

در این رابطه $l(Z; \hat{Z})$ یک تابع تلفات است که مقدار جریمه را به هنگام پیش‌بینی اشتباه \hat{Z} به جای Z تعیین می‌کند. در مرحله بعدی بر اساس میزان خطای محاسبه شده مرحله پس انتشار آغاز می‌شود. در این مرحله گرادینان هر پارامتر با توجه به قاعده chain rule محاسبه می‌شود و تمامی پارامترها با توجه به تأثیری که بر خطای ایجاد شده در شبکه دارند تغییر پیدا می‌کنند. نحوه به‌روزرسانی وزن‌ها (پارامترها) به صورت رابطه ۶ بیان می‌شود:

$$w^{t+1} = w^t - \rho_t \frac{\partial f}{\partial w}(w^t) \quad (\text{رابطه ۶})$$

بعد از بروز آوری شدن پارامترها مرحله بعدی پیش‌خور شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل آموزش شبکه پایان می‌یابد.

نتایج و بحث

در این بخش از مقاله مجموعه داده، معیارهای ارزیابی و نتایج

یکدیگر جمع می‌شود. با هر موقعیت قرارگیری تنها مقدار یک پیکسل به دست می‌آید، لذا با لغزش فیلتر شماره یک بر روی کل داده یک نقشه ویژگی دوبعدی حاصل می‌شود (Seyfollahzadeh Bandi, 2017). به همین ترتیب فیلترهای بعدی اعمال شده و به ازای هر کدام از آن‌ها یک نقشه ویژگی دوبعدی به دست می‌آید که با پشت سر هم قرار دادن این نقشه ویژگی‌ها در بعد سوم، نقشه ویژگی نهایی که سه بعدی است حاصل خواهد شد.

بعد از اعمال زیرلایه اول کانولوشنی، خروجی زیرلایه اول به زیرلایه غیرخطی داده می‌شود. در این مرحله تابع فعال‌ساز غیرخطی برای به دست آوردن ویژگی‌های سطح بالاتر بر روی مقادیر به دست آمده اعمال خواهد شد. در تمامی این سه مدل از تابع یکسوساز به عنوان تابع غیرخطی استفاده شده است. به طور کلی در شبکه‌های کانولوشنی عمیق تمایل به استفاده از تابع یکسوساز نسبت به دیگر توابع غیرخطی بیشتر است زیرا تابع یکسوساز نحوه محاسبه ساده‌ای دارد و منابع محاسباتی زیادی را درگیر نمی‌کند و در عین حال تجربه نشان داده است که استفاده از این تابع منجر به رسیدن به دقت‌های قابل قبولی می‌گردد (Seyfollahzadeh Bandi, 2017). رابطه ۳ تعریف تابع یکسوساز را نمایش می‌دهد:

$$f(x) = \begin{cases} x & x > 0 \\ 0 & \text{else} \end{cases} \quad (\text{رابطه ۳})$$

در نهایت، مقادیر حاصل شده به زیرلایه سوم برای انجام عملیات ادغام داده می‌شود. در زیرلایه ادغام، خلاصه آماری پیکسل‌های همسایه پیکسل مرکزی، جایگزین مقدار پیکسل مرکزی پنجره ادغام می‌شود. اعمال ادغام باعث پایدارتر شدن ویژگی‌ها و کاهش حساسیت نسبت به تغییرات ناخواسته می‌باشد. ابعاد داده خروجی این زیرلایه بسته به مقدار ابر پارامترهای گام و صفر گذاری می‌تواند برابر با ابعاد داده ورودی باشد و یا اینکه دارای ابعاد متفاوتی باشد. از این رو اگر کاهش ابعادی در مرحله ادغام صورت بگیرد، می‌توان کاربرد دیگر این زیرلایه را نگه داشتن ویژگی‌های ارزشمندتر و دور ریختن ویژگی‌های کم‌اهمیت دانست (Seyfollahzadeh Bandi, 2017). نوع‌های مختلفی از ادغام وجود دارد که محبوب‌ترین آن‌ها ادغام نوع max pooling می‌باشد، می‌توان به صورت رابطه ۴ بیان نمود:

(رابطه ۴)

$$y_{ijk} = \max\{y_{i'jk} : i \leq i' < i + p, j \leq j' < j + p\}$$

اکنون یک لایه کانولوشنی به طور کامل بر روی تصویر پیش‌پردازش شده اعمال شده است. حال بسته به نوع شبکه

استفاده شد. این پارامترها به صورت روابط ۷-۹ تعریف می‌شوند:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{رابطه ۷})$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (\text{رابطه ۸})$$

$$Specificity = \frac{TN}{TN + FP} \quad (\text{رابطه ۹})$$

متغیرهای Accuracy، Sensitivity و Specificity به ترتیب صحت، حساسیت (نسبتی از موارد مثبت است که آزمایش آن‌ها را به درستی به عنوان مثبت علامت‌گذاری می‌کند) و ویژگی (نسبتی از موارد منفی است که آزمایش آن‌ها را به درستی به عنوان منفی علامت‌گذاری می‌کند) تشخیصی مدل می‌باشند. متغیرهای TP مثبت صحیح (پسته ناسالم، به درستی ناسالم تشخیص داده شده)، FP مثبت کاذب (پسته سالم، به اشتباه ناسالم تشخیص داده شده)، TN منفی صحیح (پسته سالم، به درستی سالم تشخیص داده شده) و FN منفی کاذب (پسته ناسالم، به اشتباه سالم تشخیص داده شده) می‌باشند. بنابراین، اگر هم حساسیت و هم ویژگی بالا باشند، دقت بالا خواهد بود. از مجموع ۹۵۸ تصویر موجود ۷۰ درصد داده‌ها به‌عنوان داده‌های آموزش و ۳۰ درصد به‌عنوان تست در نظر گرفته شده است. نتایج مربوط به حساسیت، صحت و ویژگی به‌دست‌آمده در داده‌های تست در جدول ۳ نشان داده شده است.

جدول ۳- ارزیابی ویژگی‌های استخراج شده با استفاده از طبقه کننده‌ها

مدل شبکه پیش آموزش دیده	TP	TN	FP	FN	Accuracy	Specificity	Sensitivity
Google net	۷۷	۱۹۹	۶	۶	۹۵٪/۱۸	۹۷٪/۱	۹۳٪/۱۸
resnet18	۷۶	۲۰۴	۷	۱	۹۷٪/۲	۹۶٪/۷	۹۸٪/۷
vgg16	۷۶	۲۰۰	۶	۶	۹۵٪/۱۸۳	۹۷٪/۱۰۸	۹۳٪/۱۶۸

را می‌توان در پردازنده‌های مختلف سخت‌افزاری پیاده‌سازی نمود. درحالی‌که VGG به‌درستی بر روی مجموعه داده ImageNet دست می‌یابد، استقرار آن به دلیل الزامات محاسباتی عظیم، هم از لحاظ حافظه و هم زمان، یک مشکل است. GoogLeNet یک ماژول به نام ماژول راه‌اندازی را ابداع کرد که یک شبکه تنک CNN با ساختار متراکم طبیعی را تخمین می‌زند. الگوریتم ResNet نسبت به الگوریتم VGG دارای عمق بیشتری است. الگوریتم بیان شده شامل یک فیدبک نیز هست. علت وجود این فیدبک در الگوریتم ResNet، برای الگوریتم آموزش پس انتشار خطا است. هر چه الگوریتم عمیق‌تر شده و تعداد لایه‌ها افزایش

به‌دست‌آمده معرفی می‌شوند. پیاده‌سازی‌های انجام‌شده در زبان برنامه‌نویسی matlab بر روی سامانه پردازشی فوق‌سریع HPC که از چندین کلاستر محاسباتی تشکیل شده و یکپارچگی بین آن‌ها منجر به مدیریت کارها به‌صورت متمرکز می‌گردد، انجام گرفته است. سخت‌افزاری با مشخصات: تعداد نودها ۲، کارت گرافیک 2x NVIDIA® Tesla K80 GPUs، حافظه 8x 16 GB و پردازنده 2 x Intel® Xeon® E5-2695 v3 @ 2.30 GHz انجام شده است. لازم به ذکر است، تمامی نتایج به‌دست‌آمده از روش‌های متفاوت، از یک مدل مشخصات بر روی یک سامانه HPC استفاده شده است. مشخصات مربوط به پارامترهای تنظیم شبکه عصبی در جدول ۲ نمایش داده شده است.

جدول ۲- پارامترهای تنظیم شده شبکه عصبی کانولوشن عمیق

پارامتر	مقدار
اندازه دسته های کوچک ^۱	۵
حداکثر دوره	۱۰
نرخ یادگیری اولیه	۰/۰۰۰۱
تکرار	۱۳۴۰
اعتبارسنجی	۳
روش بهینه سازی	گرادیان نزولی با گشتاور


برای تسهیل ارزیابی عملکرد سامانه تشخیص ناهنجاری پسته پیشنهادشده، سه معیار ارزیابی دقت، حساسیت و ویژگی

اگرچه مقالات زیادی درباره معماری‌های جدید از نظرگاه ترکیب لایه‌ها و عملکرد شناسایی وجود دارد، مقالاتی وجود دارند که جنبه‌های مربوط به هزینه محاسباتی (استفاده از حافظه، زمان استنتاج و غیره) را تحلیل می‌کنند و از همه مهم‌تر اینکه چگونه هزینه محاسباتی بر دقت تشخیص تأثیر می‌گذارد (Bianco, Cadene et al. 2018)

VGG16 شامل ۵ بلوک کانولوشن و یک بلوک متصل شده با چهار لایه هست. این روش با جایگزینی فیلترهای بزرگ با اندازه هسته (به ترتیب ۱۱ و ۵ در لایه اول و دوم) با استفاده از فیلترهای سبک‌تر یکی پس از دیگری بهبود می‌یابد. این الگوریتم

برای سه مدل شبکه عصبی استفاده شده در شکل ۴ نمایش داده شده است. همان گونه که مشخص است اگرچه سرعت همگرایی شبکه GoogLeNeT و VGG نسبت به ResNet بالاتر است اما دقت شبکه ResNet در مقایسه با آن دو شبکه بیشتر می باشد.


پیدا می کند به دلیل وجود تابع گرادیان در تابع آموزش با وارد شدن به عمق جایی ممکن است اثر وزن ها و لایه ها صفر شوند به همین منظور الگوریتم های ResNet که شامل فیدبک می باشند مطرح و مورد استفاده قرار گرفته اند (Szegedy, Ioffe et al. 2017). نمودار مربوط به مقدار دقت در مورد داده های اعتبارسنجی



شکل ۴- نمودار مقدار دقت اندازه گیری شده در هر مرحله از یادگیری بر روی داده های اعتبارسنجی

رسیدن به مقدار مطلوب و همگرایی شبکه، مقدار خطا با افزایش تعداد تکرارهای آموزش در حال کاهش می باشد.

نمودار مربوط به مقدار خطا در مورد داده های اعتبارسنجی برای سه مدل شبکه عصبی استفاده شده در شکل ۵ نمایش داده شده است. همان گونه که در نمودار مشخص است به علت



شکل ۵- نمودار مقدار خطای اندازه گیری شده در هر مرحله از یادگیری بر روی داده های اعتبارسنجی

هر چه داده های آموزش شبکه بیشتر می شود، مدل بیشتر خود را بر روی داده آموزش منطبق می سازد. اگر داده هایی که پشت سر هم به شبکه داده می شوند همه متعلق به یک کلاس نباشد، شبکه در طول آموزش خودش را به گونه ای تطبیق می دهد که بتواند

ترتیب قرار گرفتن داده در هنگام آموزش شبکه کانولوشنی، همانند سایر شبکه های عصبی بر روی نحوه آموزش دیدن شبکه تأثیرگذار است. اساس به روزرسانی وزن ها بر پایه محاسبه خطای بین مقدار پیش بینی شده و مقدار مورد انتظار است. طبیعی است

تصاویر، عملیات طبقه‌بندی محصولات را به خوبی انجام دهد. توسعه یافته‌ترین روش‌ها برای جداسازی و به دست آوردن سریع اطلاعات میوه‌های آلوده، روش‌های استفاده‌شده در بررسی آفلاتوکسین است.

این کار یک راه‌حل مهندسی برای جداسازی خودکار پسته‌های سالم از معیوب توصیف کرد. در حال حاضر شبکه‌های عصبی کانولوشن، از زیرشاخه‌های معروف و پرکاربرد یادگیری عمیق بوده که امروزه بسیار مورد استفاده هست و در عین حال از دقت و سرعت نسبتاً مناسبی برخوردار است. شبکه‌های عصبی کانولوشن دارای الگوریتم‌های متفاوت و متنوع می‌باشند که بر اساس ورودی‌ها و پایگاه داده، الگوریتم مناسب مشخص می‌شود. شبکه عصبی کانولوشن معمولاً برای پایگاه داده‌های تصویر قدرت پاسخگویی بهتری داشته و معمولاً داده‌های ورودی آن‌ها به صورت تصویر می‌باشند. این مقاله یک برنامه برای طبقه‌بندی پسته در تصاویر مبتنی بر ۳ معماری پیش آموزش دیده پیشنهاد می‌کند. این نتایج برای یک مجموعه داده مشتمل بر ۹۵۸ تصویر اعمال شد. مشخص شد که طبقه‌بندی کننده پسته بر اساس resnet 18 با دقتی معادل ۰.۹۷/۰۲٪ امیدوارکننده است. نتیجه‌گیری طراحی شبکه‌های عصبی عمیق با افزایش پیچیدگی قادر به بهبود عملکرد رقابت و همچنین سایر وظایف چشم‌انداز ایفا می‌کند. کارهای آینده را می‌توان با در نظر گرفتن تعداد زیادی از نمونه‌ها انجام داد.

REFERENCES

- Bengio, Y., Goodfellow, I.J. and Courville, A. (2015). Deep learning' An MIT Press book in preparation. Draft chapters available at.
- Bianco, S., Cadene, R., Celona, L. and Napoletano, P. (2018). Benchmark Analysis of Representative Deep Neural Network Architectures. IEEE Access, 6, 64270-64277.
- Bond, T.C., Chang, A. and Zhou, J. (2017). Real-time, in-situ detection of volatile profiles for the prevention of aflatoxin fungal contamination in pistachios, Lawrence Livermore National Lab.(LLNL), Livermore, CA (United States).
- Chambolle, A., De Vore, R.A., Lee, N.Y. and Lucier, B.J. (1998). nonlinear wavelet image processing: variational problems, compression, and noise removal through wavelet shrinkage. IEEE Transactions on Image Processing, 7(3), 319-33.
- Farazi, M., Abbas-Zadeh, M.J. and Moradi, H. (2017). A machine vision based pistachio sorting using transferred mid-level image representation of Convolutional Neural Network. 2017 10th Iranian Conference on Machine Vision and Image Processing (MVIP), IEEE.
- Géron, A. (2017). Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems, O'Reilly Media, Inc.
- Gupta, V., Khare, K. and Singh, R.P. (2009). Fpga design and implementation issues of artificial neural network based pid controllers. Advances in Recent Technologies in Communication and Computing, 2009. ARTCom'09. International Conference on, IEEE.
- Kavdir, I., Guyer, D. (2008). Evaluation of different pattern recognition techniques for apple sorting. Biosystems Engineering, 99(2), 211-219.
- Kola, O., Hayoğlu, İ., Türkoğlu, H., Parlıdı, E., Ak, B. E., & Akkaya, M. R. (2018). Physical and chemical properties of some pistachio varieties (Pistacia vera L.) and oils grown under irrigated and non-irrigated conditions in Turkey. Quality Assurance and Safety of Crops & Foods, 10(4), 383-388.
- Mollazade, K., Omid, M. and Arefi, A. (2012). Comparing data mining classifiers for grading raisins based on visual features. Computers and electronics in agriculture, 84, 124-131.

داده‌های این کلاس‌ها را بهتر تمیز دهد. به این دلیل پیش از اینکه داده‌ها به ورودی شبکه کانولوشنی داده بشوند، ترتیب قرارگیری آن‌ها به هم ریخته می‌شود و تمام داده‌های یک کلاس پشت سر هم وارد نمی‌شود.

شبکه پایه‌ای که به منظور آموزش و تنظیم انتخاب می‌شود باید متناسب با امکانات سخت‌افزاری و هدف مشخص باشد. به منظور انجام یک آموزش موفق باید متغیرهای نرخ یادگیری، اندازه دسته و تعداد تکرار عبور داده به درستی انتخاب شوند. بسته به نوع داده و تعداد داده این متغیرها می‌توانند مقدارهای متفاوتی داشته باشند و عمدتاً به روش سعی و خطا باید تعیین گردند. مدل‌های پیچیده‌تر به زمان آموزش زیاد و حافظه سخت‌افزاری بالا برای ذخیره وزن‌ها نیاز دارند.

نتیجه‌گیری کلی

پسته، چه با دست برداشت شود یا با تکاننده باید بعد از پوست‌کنی، خشک و جداسازی شود. جداسازی اولیه پسته‌های باکیفیت پایین معمولاً با شناور کردن آن‌ها در آب و استفاده از جداکننده‌های مکانیکی است. روش‌های تصویربرداری به عنوان ابزار بالقوه برای ارزیابی سریع و غیرتهاجمی و کمی سازی قارچ‌های سمی و آفلاتوکسین‌ها در میوه و میوه‌های خشک استفاده شده‌اند. سامانه ماشین بینایی با استفاده از الگوریتم‌های شبکه عصبی در پردازش تصویر می‌تواند با تحلیل و بررسی آبی

- Nouri-Ahmadabadi, H., Omid, M., Mohtasebi, S.S. and Firouz, M.S. (2017). Design, development and evaluation of an online grading system for peeled pistachios equipped with machine vision technology and support vector machine. *Information Processing in Agriculture*, 4(4), 333-341.
- Omid, M. (2011). Design of an expert system for sorting pistachio nuts through decision tree and fuzzy logic classifier. *Expert Systems with Applications*, 38(4), 4339-4347.
- Omid, M., Firouz, M.S., Nouri-Ahmadabadi, H. and Mohtasebi, S.S. (2017). Classification of peeled pistachio kernels using computer vision and color features. *Engineering in Agriculture, Environment and Food*, 10(4), 259-265.
- Pinto, C., Furukawa, J., Fukai, H., & Tamura, S. (2017, August). Classification of Green coffee bean images based on defect types using convolutional neural network (CNN). In *2017 International Conference on Advanced Informatics, Concepts, Theory, and Applications*, 1-5.
- Rong, D., Xie, L., & Ying, Y. (2019). Computer vision detection of foreign objects in walnuts using deep learning. *Computers and Electronics in Agriculture*, 162, 1001-1010.
- Seyfollahzadeh Bandi, H. (2017). *Medical Signal Analysis using Deep Convolutional Neural Networks*. MS. dissertation, Urmia University, Iran.
- Shahabi, M., Rafiee, S., Mohtasebi, S.S. and Hosseinpour, S. (2014). Image analysis and green tea color change kinetics during thin-layer drying. *Food Science and Technology International*, 20(6), 465-476.
- Szegedy, C., Ioffe, S., Vanhoucke, V. and Alemi, A.A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. *Thirty-First AAAI Conference on Artificial Intelligence*.
- Tri, N. C., Van Hoai, T., Duong, H. N., Trong, N. T., Van Vinh, V., & Snasel, V. (2016). A novel framework based on deep learning and unmanned aerial vehicles to assess the quality of rice fields. In *International Conference on Advances in Information and Communication Technology*. Springer, Cham, 84-93.
- Wang, L., Guo, S., Huang, W. and Qiao, Y. (2015). Places205-vggnet models for scene recognition. *arXiv preprint arXiv,1508.01667*.