

## ارزیابی تردی گوشت گاو توسط مدل‌های مبتنی بر یادگیری عمیق

سلیمان حسین‌پور<sup>۱\*</sup> و پویا رضوانی اصل<sup>۲</sup>

### چکیده

گوشت گاو با دارا بودن انواع آمینواسیدهای ضروری انسان، به‌عنوان یکی از اصلی‌ترین منابع تأمین‌کننده پروتئین جوامع بشری است. حفظ سلامت جامعه، تأمین مواد غذایی سالم و باکیفیت را بیش از هرزمانی ضروری‌تر کرده است. از مهم‌ترین و کاربردی‌ترین روش‌های ارزیابی کیفیت گوشت گاو بررسی ویژگی‌های ظاهری و فیزیکی آن است. در این پژوهش با هدف ارزیابی کیفیت گوشت گاو از نظر سفتی و تردی بر اساس ویژگی‌های تصویر به طراحی و اجرای مدلی بر پایه شبکه‌های عصبی پیچشی مبتنی بر سه ساختار Inception، MobileNet و VGG۱۶ پرداخته شده است. اطلاعات ورودی این مدل، تصاویر دیجیتالی از نمونه‌های گوشت مهره کمر گاو بود که مقادیر مقاومت برشی آن‌ها با روش وارنر-براتزله اندازه‌گیری شد. در پایان مدل‌های طراحی‌شده توانستند با دقت قابل قبولی به دسته‌بندی نمونه‌های اولیه بر اساس ویژگی‌های استخراج شده بپردازند. عملکرد مدل‌های طراحی‌شده با شاخص‌های آماری از جمله دقت، صحت، حساسیت و اختصاصی بودن بررسی شد و بهترین مدل طبقه‌بند، مدل مبتنی بر ساختار MobileNet بود که این مدل توانست با دقت ۹۲٪ تصاویر را طبقه‌بندی کند.

**واژه‌های کلیدی:** بینایی ماشین، وارنر-براتزله، شبکه عصبی پیچشی، Inception، MobileNet، VGG۱۶.

ارجاع: حسین‌پور س. و رضوانی اصل پ. ۱۴۰۲. ارزیابی تردی گوشت گاو توسط مدل‌های مبتنی بر یادگیری عمیق. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۱۰۰-۹۳: ۲۸. <https://dx.doi.org/10.22034/JRMAM.2023.14095.625>

۱- دانشجوی کارشناسی ارشد گروه مهندسی ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی پردیس کشاورزی و منابع طبیعی دانشگاه تهران، کرج، ایران.  
۲- دانشیار، گروه مهندسی ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی پردیس کشاورزی و منابع طبیعی دانشگاه تهران، کرج، ایران.

\*نویسنده مسئول: [shosseinpour@ut.ac.ir](mailto:shosseinpour@ut.ac.ir)

تاریخ دریافت: ۱۴۰۱/۰۸/۱۰ تاریخ پذیرش: ۱۴۰۱/۱۲/۱۲

## مقدمه

بینایی ماشین یکی از سامانه‌های هوشمندی است که به‌عنوان شاخه‌ای از هوش مصنوعی، بینایی انسان را شبیه‌سازی می‌کند. در سال‌های اخیر بینایی ماشین بیشتر مورد توجه بخش تحقیق و توسعه صنایع کشاورزی و غذایی قرار گرفته است و به‌کارگیری آن در بازرسی کیفی، طبقه‌بندی و ارزیابی طیف وسیعی از محصولات کشاورزی و غذایی روزبه‌روز در حال افزایش است و ارزیابی مناسب، سریع، اقتصادی موجب هموارتر شدن این به‌کارگیری شده است.

کیفیت مواد غذایی اهمیت اساسی برای تولیدکنندگان و مصرف‌کنندگان دارد. معمولاً مصرف‌کنندگان توجه خود را بر سلامت مواد غذایی، کیفیت و مقدار مواد مغذی موجود گذاشته و خرید خود را بر این مبنا انجام می‌دهند. در فرآورده‌های گوشتی کیفیت، عامل مهمی در تصمیم‌گیری مشتری برای خرید محصول است تا آنجا که مصرف‌کننده حاضر است هزینه‌ای اضافی برای اطمینان از کیفیت محصول پرداخت کند. کیفیت گوشت عبارتی است که برای توصیف محدوده‌ای از ویژگی‌های گوشت به کار می‌رود و شامل تازگی، تردی، آبدار بودن، طعم و ویژگی‌های ظاهری مانند رنگ، مقدار چربی و ساختار بافتی آن است (Li et al., 2001).

با توجه به افزایش جمعیت، لزوم تهیه و تأمین پروتئین حیوانی به مقدار مورد نیاز جامعه و اطمینان از سلامت و کیفیت آن و همچنین ضرورت مطالعه و تحقیق در راستای ایجاد و توسعه روش‌های نوین ارزیابی کیفیت محصول گوشت خوراکی به‌صورت کاربردی و دقیق احساس می‌شود (Damez et al., 2008).

در بسیاری از مواقع امکان ایجاد شرایط کنترل‌شده برای بررسی کیفیت محصول وجود ندارد یا در صورت امکان پرهزینه، زمان‌بر و نیازمند فرد متخصص است. برای بکارگیری سامانه‌های بینایی ماشین و پردازش تصویر محدودیت‌هایی وجود دارد که از آن جمله می‌توان به تغییرات روشنایی صحنه، چرخش و تغییر فاصله دوربین از هدف موردنظر، اشاره کرد. تغییر هر یک از این عوامل تأثیر مجزا و خاص خود را بر نتایج سامانه بینایی می‌گذارد و موجب ایجاد عدم قطعیت در نتایج سامانه در شرایط غیرکنترلی می‌شوند. اما امروزه با گسترش

روش‌های نوین بینایی ماشین این مشکلات تا حدودی بر طرف شده‌اند.

از میان روش‌های مختلف بینایی ماشین، یادگیری عمیق<sup>۱</sup> بیشتر به‌کارگرفته می‌شود. این روش زیرمجموعه هوش مصنوعی است و از مزایای بسیار مهم آن عدم وابستگی به شرایط محیطی، سرعت بالای پردازش، خطای کم، هزینه اولیه پائین و کاربری آسان است (Jia et al., 2022). در پژوهش‌های مختلفی از این روش برای شناسایی و ارزیابی محصولات کشاورزی و صنایع غذایی استفاده شده است و کاربردی بودن خود را به اثبات رسانده است.

(Al-Sarayeh et al., 2018) از روش پردازش تصویر و شبکه‌های عصبی مصنوعی برای شناسایی سه گونه متفاوت گوشت گاو، گوسفند و خوک استفاده کردند.

(Taheri et al., 2020) از یک معماری VGG۱۶ دوبعدی برای استخراج ویژگی‌های تصویر RGB ماهی کپور معمولی با چهار سطح تازگی مختلف استفاده کردند.

(Nasiri et al., 2020) از مجموعه داده‌ای شامل ۳۰ عدد تخم‌مرغ که در ۳ زاویه مختلف تصویربرداری شده بودند برای اجرایی مدل مبتنی بر یادگیری عمیق استفاده کردند و با توجه به تعداد تصویر ورودی کم مدل، با دقت ۹۴/۸۴٪ به کلاس‌بندی تخم‌مرغ‌های سالم و معیوب در ۵ دسته پرداختند.

هدف کلی این مطالعه بررسی عملکرد شبکه عصبی پیچشی<sup>۲</sup> در طبقه‌بندی نمونه‌های گوشت گاو بر اساس مقدار مقاومت برشی آن‌ها است. در این تحقیق سعی شده است ویژگی‌های بافتی نمونه‌های گوشت گاو استخراج و با استفاده از مدل‌های از پیش آموزش‌دیده شده در کلاس‌های تعیین‌شده طبقه‌بندی شوند.

## مواد و روش‌ها

برای تعیین تردی گوشت گاو به‌وسیله بینایی ماشین باید اطلاعات فیزیکی مرتبط با تردی گوشت در دسترس باشند تا بتوان با بررسی ارتباط بین این داده‌های فیزیکی و داده‌های حاصل از پردازش تصاویر، تردی گوشت را برآورد کرد. در این پژوهش از داده‌های تحقیق (Hosseinpour et al., 2019) که مقدار مقاومت برشی نمونه‌های گوشت را به روش وارنر-براتزلر<sup>۳</sup> اندازه‌گیری

1- Deep Learning

2- Convolutional neural network (CNN)

3- Warner Bratzler


برای استخراج ویژگی‌های بصری و ارزیابی و طبقه‌بندی نمونه‌های گوشت گاو از مدل مبتنی بر شبکه‌های عصبی پیچشی استفاده شد. شبکه‌های عصبی پیچشی اساس الگوریتم‌های بینایی رایانه نوین را تشکیل می‌دهند که در مقایسه با الگوریتم‌های پردازش تصویر سنتی، بهبود چشم‌گیری در عملکرد این سامانه‌ها به‌وجود آورده‌اند (Goodfellow *et al.*, 2016).

مدل‌های شبکه عصبی پیچشی برای بهبود عملکرد نیاز به تعداد داده بالایی دارند و همچنین ویژگی مهم و مثبت به‌کارگیری شبکه‌های CNN، مستقل بودن آن‌ها در آموزش توسط داده‌هایی با شرایط تصویر غیریکسان است. شبکه CNN به کمک ساختار سلسله‌مراتبی خود در استخراج ویژگی‌ها، توانایی آموزش توسط داده‌های غیرهمسان را دارد. که برای ایجاد چنین مجموعه داده‌ای از روش‌های داده‌افزایی<sup>۱</sup> استفاده شد (Perez *et al.*, 2017) در حالت کلی از روش داده‌افزایی با هدف تعمیم و بهبود عملکرد مدل و برای داده‌های آموزشی اجرا می‌شود. در برخی حالات که از تعداد داده‌های محدود و مجموعه داده اولیه کوچک برای ارزیابی مدل استفاده می‌شود، به شرط اینکه تصاویری که برای آموزش استفاده شده‌اند در مجموعه تصاویر آزمون تکرار نشوند می‌توان روش‌های داده‌افزایی را برای کل مجموعه داده به کار برد (Shorten *et al.*, 2019). روش‌های مورد استفاده در این پژوهش شامل الگوهای چرخش عمودی، چرخش افقی، تغییر زاویه، تغییر شدت نور، جابه‌جایی عرضی، جابه‌جایی طولی، بزرگ‌نمایی، تغییر مقیاس و نیز برش بود. تعداد کل داده‌ها پس از انجام داده‌افزایی برابر ۱۰۰۷ شد که از این تعداد ۶۰٪ تصاویر برای آموزش شبکه، ۲۰٪ برای ارزیابی شبکه و ۲۰٪ نیز برای آزمون عملکرد مدل استفاده شد.

به‌منظور بهبود عملکرد مدل و کاهش میزان محاسبات برای آموزش مدل روش یادگیری انتقالی به کار گرفته شد. یادگیری انتقالی به روشی اطلاق می‌شود که در آن از یک مدل قبلاً آموزش دیده شده با داده‌های متفاوتی برای اهداف دیگری اما مرتبط استفاده می‌شود. در واقع این روش به دنبال پیدا کردن نقطه شروع مناسبی برای وزن‌های شبکه عصبی است. این روش در مدل‌های مبتنی

کرده‌اند بودند استفاده شد.

نمونه‌ها از فروشگاه‌های محلی در روزهای مختلف جمع‌آوری شد و در مجموع از ۱۰ لاشه، گوشت کمر مهره ۱۲ از هر لاشه گاو انتخاب گردید و به وسیله گوشتی همراه هوشمند LG G4 H815 در شرایط کنترل نشده و مستقل از محیط تصویربرداری شد و در مجموع تعداد ۱۳۷ تصویر دیجیتال به دست آمد (شکل ۱).



شکل ۱- نمونه‌ای از تصاویر به‌دست آمده با استفاده از تلفن همراه

مقدار مقاومت برشی نمونه‌ها توسط دستگاه آزمونگر بافت مدل Santam STM-5 مجهز به تیغه برشی وارنر-براتزلر اندازه‌گیری شد. بازه مقاومتی به‌دست آمده برای نمونه‌ها بر اساس استاندارد تعریف شده است. نمونه‌هایی با نیروی برشی بیشتر از ۵۲/۶۸ نیوتن در طبقه سفت (شکل ۱- الف) و نمونه‌هایی با مقاومت برشی بین ۴۲/۸۷ و ۵۲/۶۸ در دسته گوشت‌های نیمه سفت (شکل ۱- ب) و نمونه‌هایی با مقاومت برشی کمتر از ۴۲/۸۷ نیوتن در دسته گوشت ترد (شکل ۱- ج) قرار گرفتند (Destefanis *et al.*, 2008).


جدول ۱- طبقه‌بندی تصاویر نمونه‌های گوشت بر اساس مقدار مقاومت برشی

طبقه	تعداد تصویر	بازه مقاومت برشی (نیوتن)
ترد	۵۳	۱۲/۲۵ - ۴۵/۶۸
نیمه سفت	۴۵	۴۵/۶۸ - ۵۲/۶۸
سفت	۳۹	۵۲/۶۸ - ۶۸/۲۳
مجموع	۱۳۷	

همان‌طور که در جدول ۱ قابل مشاهده است، مجموع داده اولیه برای آموزش مدل شامل ۱۳۷ تصویر است که شاخص طبقه‌بندی هر تصویر مقدار مقاومت برشی اندازه‌گیری شده آن نمونه گوشت و طبق بازه‌های تعریف شده بود (Destefanis *et al.*, 2008). از این تعداد ۵۳ تصویر متعلق به دسته ترد، ۴۵ تصویر در دسته نیمه سفت و ۳۹ تصویر در طبقه سفت بودند.

1- Data augmentation


لایه‌های تماماً متصل استفاده می‌شود. آخرین لایه تماماً متصل حاوی خروجی نظیر امتیاز دسته‌ها است (Pranav *et al.*, 2020).



شکل ۲- ساختار کلی شبکه‌های عصبی پیچش و نحوه قرارگیری لایه‌ها

برای آموزش شبکه و اجرای مدل پیچشی در این پژوهش از محیط برنامه‌نویسی گوگل تحت عنوان Google-Colab استفاده شد. برای بهره‌مندی از سخت‌افزار قدرتمندی که Google-Colab در اختیار کاربران قرار می‌دهد، ابتدا باید داده‌ها در فضای ابری بارگذاری شوند.

در این پژوهش به بررسی نتیجه سه ساختار مختلف و رایج برای ایجاد مدل‌های شبکه عصبی پیچشی پرداخته شد. اولین مدل ایجاد شده بر اساس ساختار MobileNet بود. مدل طراحی شده در این پژوهش بر اساس این ساختار در مجموع از ۱۳ لایه پیچشی تشکیل شده است که وظیفه استخراج ویژگی را به عهده دارد (Pranav *et al.*, 2020). و با توجه به تعداد دسته‌های تعیین شده برای کلاس‌بندی داده‌های خروجی از یک لایه Dens با سه نرون استفاده شد. در پیاده‌سازی مدل برای تشخیص کلاس‌های تعریف شده، در لایه آخر از تابع Softmax استفاده شد (شکل ۳).



شکل ۳- دیاگرام ساختار مدل مبتنی بر MobileNet اجرا شده و ترتیب قرارگیری لایه‌ها با یک لایه Dense

بر CNN بسیار پرکاربرد است؛ چرا که سبب آسانی و سرعت بخشیدن به فرآیند یادگیری می‌شود و همین‌طور قابلیت تعمیم مدل را بهبود می‌بخشد (Hendrycks *et al.*, 2019). در این پژوهش برای وزن‌دهی اولیه مدل از وزن‌های داده‌های ImageNet استفاده شده است.

مدل‌های شبکه عصبی CNN در حالت کلی ترکیبی از سه لایه پیچش، ادغام<sup>۱</sup> و لایه‌های کاملاً متصل<sup>۲</sup> است که با جایگذاری و جابجایی محل این لایه‌ها در طراحی، بهترین مدل به‌منظور دستیابی به دقت موردنظر توسعه داده می‌شود.

استخراج ویژگی داده‌های ورودی در داخل لایه‌های پیچش که هسته مرکزی مدل‌های CNN هستند صورت می‌گیرد. عملگرهای استخراج ویژگی (هسته یا فیلتر) موجود در لایه پیچش روی تصویر ورودی اعمال می‌شوند و نقشه ویژگی را تشکیل می‌دهند که در لایه‌های بعدی به‌عنوان ورودی استفاده می‌شود (Kiranyaz *et al.*, 2021).

هدف اصلی از ایجاد لایه ادغام کوچک کردن تصویر ورودی و کاهش میزان محاسبات یادگیری است. کاهش اندازه تصویر ورودی همچنین باعث می‌شود که حساسیت شبکه عصبی نسبت به جابجایی تصویر (مستقل از موقعیت) کمتر بشود. در معماری CNN معمولاً چندین لایه پیچش و ادغام روی هم چیده می‌شوند، تا نداشت‌های انتزاعی‌تری از ویژگی‌های تصویر استخراج کنند (Christlein *et al.*, 2019).

عموماً آخرین لایه‌های یک شبکه عصبی پیچش برای طبقه‌بندی را لایه‌های کاملاً متصل تشکیل می‌دهند. یکی از کاربردهای اصلی لایه کاملاً متصل در شبکه پیچش، استفاده به‌عنوان طبقه‌بند است. یعنی مجموعه ویژگی‌های استخراج شده با استفاده از لایه‌های پیچشی تبدیل به یک بردار می‌شوند. در نهایت این بردار ویژگی به یک طبقه‌بند با لایه کاملاً متصل داده می‌شود تا کلاس درست را شناسایی کند (Matsumura *et al.*, 2021).

رایج‌ترین شکل یک معماری شبکه عصبی پیچشی ترکیب چند لایه پیچشی است که بعد از آن‌ها لایه‌های ادغام قرار می‌گیرند و این قالب یا طرح آن قدر تکرار می‌شود تا تصویر ورودی به‌اندازه دلخواه کوچک شود و در نهایت از

1- Pooling Layer  
2- Fully Connected Layer

اصلی ماتریس ( $i=j$ ) نمونه‌هایی هستند که به درستی طبقه‌بندی شده‌اند و نمونه‌های خارج از قطر به درستی طبقه‌بندی نشده‌اند. برای هر تخمین طبقه‌بند ۴ حالت وجود دارد:

(TP): پیش‌بینی مثبت صحیح<sup>۳</sup>

(FP): پیش‌بینی مثبت کاذب<sup>۴</sup>

(TN): پیش‌بینی منفی صحیح<sup>۵</sup>

(FN): پیش‌بینی منفی ناصحیح<sup>۶</sup>

از نتایج حاصل از ماتریس اغتشاش چندین شاخص آماری به دست می‌آیند که شامل دقت، صحت، حساسیت، اختصاصی بودن و سطح زیر نمودار هستند. این شاخص‌ها برای بررسی عملکرد یک طبقه‌بند استفاده می‌شوند (Sokolova et al., 2009). معادلات (۱) تا (۵) نحوه محاسبه این شاخص‌ها را بیان می‌کنند:

دقت: معادله (۱) که عملکرد کلی طبقه‌بند را نشان می‌دهد و بیان‌کننده میزان تشخیص صحیح طبقه‌بند در تمامی طبقه‌ها است.

$$\text{Accuracy} = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{TN} + n_{FP} + n_{FN}} \quad (1)$$

صحت: عملکرد طبقه‌بند در تشخیص هر طبقه را نشان می‌دهد و میزان تشخیص صحیح طبقه‌بند در هر طبقه است. فرمول محاسبه صحت عملکرد مدل در معادله (۲) بیان شده است.

$$\text{Precision} = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (2)$$

حساسیت: بیانگر آن است که طبقه‌بند چه تعداد از داده‌های متعلق به طبقه  $i$  ام را به درستی به همان طبقه اختصاص داده است (معادله (۳)).

$$\text{Sensitivity} = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (3)$$

اختصاصی بودن: عملکرد یک طبقه‌بند در شناسایی برچسب‌های نادرست را نشان می‌دهد و بیان می‌کند که عملکرد طبقه‌بند در تشخیص داده‌هایی که متعلق به طبقه  $i$  ام نبوده‌اند، چگونه بوده است (معادله (۴)).

$$\text{Specificity} = \frac{n_{TN}}{n_{TN} + n_{FP}} \quad (4)$$

سطح زیر نمودار: میزان توانایی طبقه‌بند برای جلوگیری از طبقه‌بندی نادرست را نشان می‌دهد (معادله (۵)).

$$\text{ACU} = \frac{n_{TP}}{n_{TP} + n_{FP}} + \frac{n_{TN}}{n_{TN} + n_{FN}} \quad (5)$$

دومین ساختار شبکه‌های عصبی بر اساس ساختار Inception بود که همچون ساختارهای مبتنی بر MobileNet از هسته‌های پیچشی کانالی<sup>۱</sup> و نقطه‌ای<sup>۲</sup> استفاده می‌کند (Ebrahim et al., 2018). در مدل بکار گرفته شده همانند مدل MobileNet برای کلاس‌بندی داده‌های خروجی از یک لایه Dens با سه نرون استفاده شد ولی از تابع Relu به عنوان فعال‌ساز در آخرین لایه استفاده شد.

آخرین ساختار مورد استفاده ساختار VGG۱۶ بود. ساختار شبکه مبتنی بر VGG۱۶ شامل ۱۶ لایه پیچشی یا ۱۶ لایه پارامتری است. شبکه VGG۱۶، شامل دو لایه پیچشی با ۶۴ فیلتر ۳×۳ هست که پشت سر هم قرار گرفته‌اند. سپس، یک لایه ادغام حداکثر به ابعاد ۲×۲ با گام به اندازه ۲ قرار گرفته است (Lu et al., 2018). این لایه ادغام حداکثر علاوه بر نمونه‌برداری وظیفه کاهش تعداد پارامترها را نیز بر عهده دارد. و برای طبقه‌بندی داده‌ها از دو لایه Dens با سه نرون و فعال‌ساز Softmax استفاده شد.

برای ارزیابی الگوریتم طبقه‌بندی از ماتریس اغتشاش استفاده شد. ماتریس اغتشاش با بیان رابطه بین برچسب اصلی داده‌ها (طبقه واقعی) و برچسب پیش‌بینی شده به وسیله طبقه‌بند عملکرد شبکه را ارزیابی می‌کند، و نتایج طبقه‌بندی را به صورت طبقه به طبقه مقایسه می‌کند (Patro et al., 2014).

	$C_1$	...	$C_4$
$C_1$	$n_{11}$	$n_{12}$	$n_{13}$
	$n_{21}$	$n_{22}$	$n_{23}$
	$n_{31}$	$n_{32}$	$n_{33}$
$C_4$	$n_{41}$	$n_{42}$	$n_{44}$

شکل ۴ - ماتریس اغتشاش برای طبقه‌بندی چهار کلاس

همان‌طور که در شکل ۲ نمایش داده شده است، ترم  $(n_{ij})$  بر تصاویری که توسط طبقه‌بند  $(C_i^*)$  در کلاس (i) طبقه‌بندی شده دلالت می‌کند، در حالی که در طبقه‌بندی واقعی  $(C_j)$  به کلاس (j) تعلق دارد. بنابراین اعضای قطر

3- True Positive

4- False Positive

5- True False

6- False False

1- Depth wise

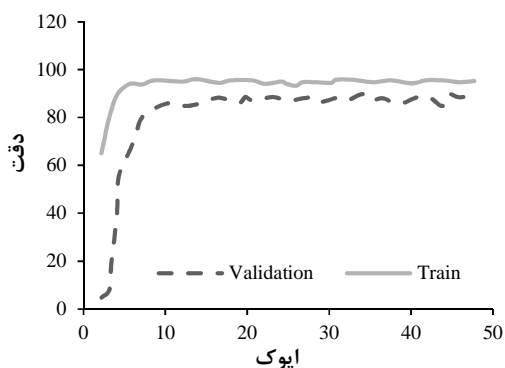
2- pointwise

## نتایج و بحث

مدل‌های طراحی شده برای طبقه‌بندی داده‌ها در چند نوبت و با تغییر عوامل قابل کنترل مانند نحوه قرارگیری لایه‌ها، اندازه تصویر ورودی و تعداد تکرار استفاده از هر لایه و در هر نوبت به تعداد ۵۰ تکرار اجرا شدند.

نتایج بهترین عملکرد برای هر مدل مبتنی بر ساختارهای Inception، MobileNet و VGG۱۶ در جداول ۲ تا ۴ قابل مشاهده است. همان‌طور در شکل ۴ نشان داده شده است، دقت مدل با افزایش تکرار افزایش یافته است. با توجه به این‌که از وزن‌های ImageNet برای آموزش شبکه‌ها استفاده شده، این روند کلی افزایش دقت، نشان‌دهنده آن است که شبکه عصبی پیچشی، ویژگی طبقه‌های مختلف را برای طبقه‌بندی آن‌ها، از تصاویر ورودی استخراج کرده است. ماتریس اغتشاش تشکیل شده برحسب نتایج طبقه‌بندی داده‌ها در جدول ۲ نشان داده شده است. قرارگیری اکثر داده‌ها بر روی قطر اصلی ماتریس بیان‌گر دقت مدل در تشخیص صحیح کلاس مربوط به هر تصویر است.

شکل ۵ دقت مدل طبقه‌بندی بر اساس ساختار Inception را پس از اجرای ۵۰ تکرار نشان می‌دهد. بر اساس نمودار نشان داده شده، دقت به تدریج در حال افزایش است و بهترین دقت ثبت شده برای تفکیک داده‌های ارزیابی ۹۱٪ در تکرار ۴۲ است.



شکل ۶- دقت شبکه در روند آموزش مدل برحسب تکرار در معماری Inception


همان‌طور که در جدول ۳ ماتریس اغتشاش برای داده‌های آزمون نیز قابل مشاهده است، اکثر داده‌ها به درستی طبقه‌بندی شده‌اند.

جدول ۳- شاخص‌های آماری شبکه روی داده‌های آزمون مدل

Inception			
شاخص‌های آماری	کلاس‌ها		
	ترد	نیمه سفت	سفت
حساسیت (%)	۸۰	۸۶	۹۰
اختصاصی بودن (%)	۸۳	۷۷	۹۵
صحت (%)	۸۷	۷۰	۹۰
سطح زیر نمودار (%)	۹۳	۹۷	۹۷
دقت کل (%)	۹۱		

برای طبقه‌بندی داده‌ها توسط مدل مبتنی بر ساختار VGG۱۶ مدل برای ۵۰ تکرار اجرا شد. بهترین دقت در تشخیص طبقه‌های تعریف شده در تکرار ۴۷ به دست آمده است. بهترین دقت برای طبقه‌بندی داده‌های ارزیابی در این مدل ۹۰٪ بود. شکل ۶ نتایج عملکرد مدل مبتنی بر ساختار VGG۱۶ را نشان می‌دهد.

نتایج ماتریس اغتشاش برای داده‌های آموزشی مدل VGG۱۶ در جدول ۴ نشان داده شده است. همان‌طور که در جدول ماتریس اغتشاش برای داده‌های آزمون قابل مشاهده است، دقت مدل در طبقه‌بندی داده‌ها برابر با ۸۸٪ بود.



شکل ۵- دقت شبکه در روند آموزش مدل برحسب تکرار در معماری MobileNet

جدول ۲- شاخص‌های آماری شبکه روی داده‌های آزمون


MobileNet			
شاخص‌های آماری	کلاس‌ها		
	ترد	نیمه سفت	سفت
حساسیت (%)	۸۳	۹۴	۹۰
اختصاصی بودن (%)	۸۵	۸۷	۹۴
صحت (%)	۹۳	۸۶	۹۹
سطح زیر نمودار (%)	۱۰۰	۹۷	۹۷
دقت کل (%)	۹۲		

نتایج به‌دست‌آمده در پژوهش پیش‌رو همپوشانی خوبی با نتایج حاصل از مدل طراحی‌شده توسط (Al-Sarayreh *et al.*, 2018) نشان داد. آن‌ها با استفاده از تصاویر فراطیفی به الگوریتمی برای تشخیص سه گونه متفاوت گوشت قرمز پرداختند. در تحقیق آن‌ها از مجموعه‌ی تصاویر عضلات گوسفند، گاو و خوک با درنظرگرفتن وضعیت آن‌ها از نظر تازگی، منجمد بودن، بسته‌بندی یا باز بودن برای استخراج ویژگی‌های طیفی و چندبعدی به‌صورت دستی با استفاده از مدل ماشین‌های بردار پشتیبان<sup>۲</sup> (SVM) و یک مدل شبکه عصبی پیچش عمیق استفاده کردند. نتایج نشان داد که مدل CNN با دقت ۹۴/۴٪ در طبقه‌بندی کلی و کاملاً مستقل از وضعیت محصولات به بهترین عملکرد دست می‌یابد.

### نتیجه‌گیری

تحقیق حاضر به‌منظور بررسی عملکرد مدل‌های شبکه عصبی پیچشی در طبقه‌بندی تصاویر نمونه گوشت گاو صورت گرفت. مدل‌های طراحی‌شده برخلاف روش‌های سنتی پردازش تصویر، استخراج ویژگی و ارزیابی داده‌ها را بدون دخالت طراح انجام داده‌اند و با نتایج تحقیقات مشابه در زمینه کاربرد شبکه‌های عصبی پیچشی برای ارزیابی و طبقه‌بندی محصولات کشاورزی و غذایی اختلاف کمتری داشت. باتوجه به ساختار سلسله‌مراتبی شبکه‌های عصبی پیچشی و مجموعه داده استفاده شده در این تحقیق که به صورت تصادفی و از مراکز عرضه گوشت محلی به دست آمده است، امکان تعمیم روش کار اجرا شده برای این مجموعه داده، به تصاویر مربوط به دیگر نمونه‌های گوشت وجود دارد.

نتایج به‌دست‌آمده قابلیت این روش در کیفیت‌سنجی و طبقه‌بندی محصول گوشت گاو بر اساس ویژگی‌های تصویری و بدون وابستگی به شرایط محیطی را ثابت کرد. باتوجه به تعداد داده‌های اولیه و شباهت ظاهری بسیاری که طبقه‌بندی‌های اولیه داشتند، مدل‌های طراحی‌شده توانستند با دقت خوبی کلاس‌های تعریف‌شده را کلاس‌بندی کنند.



شکل ۷- دقت شبکه در روند آموزش مدل برحسب تکرار در معماری ۱۶ VGG

جدول ۴- شاخص‌های آماری شبکه روی داده‌های آزمون معماری ۱۶ VGG

شاخص‌های آماری	کلاس‌ها		
	ترد	نیمه سفت	سفت
حساسیت (%)	۷۸	۸۵	۹۰
اختصاصی بودن (%)	۸۱	۷۸	۹۵
صحت (%)	۸۴	۷۲	۹۰
سطح زیر نمودار (%)	۹۵	۹۷	۹۷
دقت کل (%)	۸۸		

مقایسه نتایج حاصل از این تحقیق با پژوهش‌های پیشین بیانگر عملکرد بهتر این مدل و تأیید کارایی آن در مقایسه با روش‌های سنتی ارزیابی و طبقه‌بندی داده‌های تصویری است.

در مطالعه‌ای که (Chandraratne *et al.*, 2006) برای ارزیابی کارایی استخراج ویژگی‌های هندسی و بافتی گوشت خام به‌منظور پیش‌بینی حساسیت گوشت پخته‌شده با استفاده از تحلیل رگرسیون و ANN<sup>۱</sup> انجام دادند، از مجموعه داده‌ای شامل ۱۶۰ تصویر دیجیتال که از گوشت قسمت میانی کمر گوسفند بدست آمده بود استفاده کردند. ویژگی‌های هندسی و بافتی به‌صورت جداگانه و در پیکربندی‌های مختلف برای تشخیص تردی گوشت پخته‌شده استفاده شد. پیش‌بینی تردی با استفاده از روش ANN و تحلیل رگرسیون غیرخطی انجام شد و ضرایب همبستگی محاسبه‌شده برای تجزیه و تحلیل رگرسیون غیرخطی ۰/۶۱ بود، درحالی‌که مقدار حداکثر R<sup>۲</sup> به‌دست‌آمده توسط تجزیه و تحلیل ANN ۰/۷۴ بود.

2- Support vector machine

1- Artificial Neural Network

- of the 20th ACM international conference on multimodal interaction,
- Matsumura, N., Ito, Y., Nakano, K., Kasagi, A., & Tabaru, T. (2023). A novel structured sparse fully connected layer in convolutional neural networks. *Concurrency and Computation: Practice and Experience*, 35(11): e6213.
- Nasiri, A., Omid, M., & Taheri-Garavand, A. (2020). An automatic sorting system for unwashed eggs using deep learning. *Journal of Food Engineering*, 283: 110036.
- Patro, V. M., & Patra, M. R. (2014). Augmenting weighted average with confusion matrix to enhance classification accuracy. *Transactions on Machine Learning and Artificial Intelligence*, 2(4): 77-91.
- Perez, L., & Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*.
- Pranav, E., Kamal, S., Chandran, C. S., & Supriya, M. (2020). Facial emotion recognition using deep convolutional neural network. 2020 6th International conference on advanced computing and communication Systems (ICACCS),
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1): 1-48.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4): 427-437.
- Taheri-Garavand, A., Nasiri, A., Banan, A., & Zhang, Y. D. (2020). Smart deep learning-based approach for non-destructive freshness diagnosis of common carp fish. *Journal of Food Engineering*, 278: 109930.
- منابع
- Al-Sarayreh, M., Reis, M., Qi Yan, W., & Klette, R. (2018). Detection of red-meat adulteration by deep spectral-spatial features in hyperspectral images. *Journal of Imaging*, 4(5): 63.
- Chandraratne, M., Samarasinghe, S., Kulasiri, D., & Bickerstaffe, R. (2006). Prediction of lamb tenderness using image surface texture features. *Journal of Food Engineering*, 77(3): 492-499.
- Christlein, V., Spranger, L., Seuret, M., Nicolaou, A., Král, P., & Maier, A. (2019). *Deep generalized max pooling*. International conference on document analysis and recognition (ICDAR).
- Damez, J. L., & Clerjon, S. (2008). Meat quality assessment using biophysical methods related to meat structure. *Meat science*, 80(1): 132-149.
- Destefanis, G., Brugiapaglia, A., Barge, M. T., & Dal Molin, E. (2008). Relationship between beef consumer tenderness perception and Warner-Bratzler shear force. *Meat science*, 78(3): 153-156.
- Ebrahim, M., Alsmirat, M., & Al-Ayyoub, M. (2018). Performance study of augmentation techniques for hep2 cnn classification. 2018 9th International Conference on Information and Communication Systems (ICICS).
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Hendrycks, D., Lee, K., & Mazeika, M. (2019). Using pre-training can improve model robustness and uncertainty. International conference on machine learning,
- Hosseinpour, S., Ilkhchi, A. H., & Aghbashlo, M. (2019). An intelligent machine vision-based smartphone app for beef quality evaluation. *Journal of Food Engineering*, 248: 9-22.
- Jia, W., Zhang, R., Liu, L., Zhu, Z., Mo, H., Xu, M., Shi, L., & Zhang, H. (2022). Proteomics analysis to investigate the impact of diversified thermal processing on meat tenderness in Hengshan goat meat. *Meat science*, 183: 108655.
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151: 107398.
- Li, J., Tan, J., & Shatadal, P. (2001). Classification of tough and tender beef by image texture analysis. *Meat science*, 57(4): 341-346.
- Lu, C., Zheng, W., Li, C., Tang, C., Liu, S., Yan, S., & Zong, Y. (2018). Multiple spatio-temporal feature learning for video-based emotion recognition in the wild. Proceedings