

مقاله پژوهشی

پیش‌بینی محتوی چربی و طبقه‌بندی گوشت شتر مبتنی بر ترکیب روش غیر مخرب پردازش تصویر و شبکه‌های عصبی مصنوعی

زهرة مولایی^۱، مجید دولتی^{۲*}، ایمان گلپور^۳، حمید قاسم‌خانی^۴

۱. دانش‌آموخته کارشناسی ارشد، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه جیرفت
۲. استادیار، گروه علوم و مهندسی صنایع غذایی، دانشکده فنی و منابع طبیعی تویسرکان، دانشگاه بوعلی سینا
۳. دانش‌آموخته دکتری، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه ارومیه
۴. استادیار، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه جیرفت

(تاریخ ارسال: ۱۴۰۰/۰۷/۰۹، تاریخ آخرین بازنگری: ۱۴۰۰/۰۸/۲۲، تاریخ پذیرش: ۱۴۰۰/۰۸/۲۹)

چکیده

گوشت شتر به دلیل داشتن کلسترول و چربی کم و میزان پروتئین مناسب، می‌تواند جایگزین مناسبی برای سایر انواع گوشت قرمز در رژیم غذایی انسان باشد. هدف از این تحقیق، بررسی و ارزیابی تازگی و مقدار محتوی چربی گوشت شتر با استفاده از فن‌آوری غیر مخرب ماشین بینایی است؛ بنابراین، با استفاده از پردازش تصویر به عنوان یکی از روش‌های غیر مخرب و دستگاه سوکسله به عنوان روش مخرب، به پیش‌بینی مقدار محتوی چربی و طبقه‌بندی تازگی گوشت شتر پرداخته شد. در روش پردازش تصویر ۱۰۸ ویژگی بافتی و ۳۹ ویژگی رنگی در فضاهای رنگی RGB، HSV، HIS و CIElab از تصاویر نمونه‌ها استخراج شد. همچنین برای تخمین این پارامترها، از شبکه عصبی پیش‌خور با الگوریتم پس‌انتشار با یک و دو لایه پنهان، تعداد نرون و توابع انتقال مختلف استفاده شد. با توجه به نمودار رگرسیونی چربی به دست آمده از روش مخرب (چربی به دست آمده از دستگاه سوکسله) با چربی حاصله از روش غیر مخرب (ماشین بینایی) ضریب تبیین و دقت بین آن‌ها ۰/۸۴۱ به دست آمد. نتایج ارزیابی شبکه‌های عصبی نشان داد که مطلوب‌ترین شبکه برای طبقه‌بندی بر اساس تازگی، شبکه با یک لایه پنهان با توپولوژی ۱-۳-۱۴۷، با توابع انتقال تانژانت سیگموئید-خطی به ترتیب در لایه پنهان اول و لایه خروجی و با ضریب تبیین ۰/۹۹۶ و میانگین خطای مربعات 2×10^{-22} و همچنین برای پیش‌بینی مقدار محتوی چربی، شبکه با دو لایه پنهان با توپولوژی ۱-۳-۱۴۷ با تابع انتقال خطی-لگاریتم سیگموئید-لگاریتم سیگموئید در لایه‌های پنهان اول، دوم و لایه خروجی با ضریب تبیین و میانگین خطای مربعات به ترتیب ۰/۹۹ و ۰/۴۰۲ به دست آمد؛ بنابراین نتایج به دست آمده از این تحقیق، نشان می‌دهد که سامانه پیشنهادی با کمک فن‌آوری ماشین بینایی قادر است با دقت بسیار خوبی تازگی و مقدار چربی گوشت شتر را پیش‌بینی کند.

واژه‌های کلیدی: گوشت شتر، تازگی، چربی، طبقه‌بندی، پردازش تصویر، شبکه‌های عصبی مصنوعی (ANNs)

۱. مقدمه

کنندگان و مصرف‌کنندگان توجه ویژه‌ای به آن دارند به طوری که با خرید و فروش این محصول بطور مستقیم مرتبط است [۷]. فاکتورهای مهم کیفی در ارزیابی و طبقه‌بندی تازگی گوشت شامل رنگ، شکل، بافت، استحکام، عطر و طعم هستند که رنگ به عنوان یکی از ویژگی‌های اولیه و مهم گوشت در درجه‌بندی، ارزیابی کیفیت گوشت و بازار پسندی آن توسط مصرف‌کنندگان، نقش بسزایی را در تازگی و ماندگاری آن ایفا می‌کند [۸]. هر کدام از این فاکتورها به انواع مختلف تقسیم می‌شود، مثلاً ویژگی‌های رنگی به سه نوع المان رنگی، هیستوگرام رنگی و میانگین RGB تقسیم می‌شوند [۹]. ویژگی بافتی نیز به عنوان یکی دیگر از ویژگی‌های ارزیابی کیفی، دارای الگوی اطلاعات یا نظم ساختاری در یک تصویر است که در آنالیز ویژگی‌ها و شرح تصویر استفاده می‌شود. در تحلیل تصویر، بافت ویژگی‌ای است که نشان‌دهنده آرایش مکانی سطوح خاکستری پیکسل‌های نواحی مختلف است و یکی از ویژگی‌های مهمی است که در تشخیص اشیا یا مناطق مورد نظر در یک تصویر کاربرد دارد. بافت از منظر دیداری، الگوی یکنواختی است که از حضور بیش از یک رنگ یا درجه خاکستری به دست می‌آید [۱۰].

با این حال، روش پردازش تصویر با استخراج ویژگی‌های مختلف تصویر و با کمک روش شبکه عصبی مصنوعی، می‌تواند در ایجاد سامانه‌ای هوشمند مناسب در جهت تشخیص تازگی و کیفیت گوشت در صنایع غذایی نقش بسزایی را ایفا کند. شبکه عصبی پرسپترون چندلایه (MLP)^۱، به عنوان رایج‌ترین و پرکاربردترین شبکه‌های عصبی، جزو شبکه‌های عصبی پیشخور است که می‌تواند با انتخاب مناسب لایه‌ها و نرون‌ها، یک نگاشت غیر خطی را با دقت مناسب انجام دهند [۱۱]. شیراینیتا و همکاران به درجه‌بندی کیفیت گوشت به وسیله مدل‌های شبکه عصبی پرداختند. آن‌ها یک سیستم درجه‌بندی گوشت با استفاده از خصوصیات ظاهری گوشت و به کمک مدل‌های شبکه عصبی مصنوعی را طراحی کردند. نتایج نشان داد که بهترین شبکه برای پیش‌بینی کیفیت گوشت، شبکه سه لایه با دقت ۰/۹۶

گوشت، نقش بسیار مهمی در رژیم غذایی انسان ایفا می‌کند و شامل ترکیبات اصلی‌ای مانند آب، چربی، پروتئین و مواد ریزمغذی است و با داشتن مقدار پروتئین لازم، نقش بسیار حیاتی در مدیریت وزن دارد و دارای عناصر ریزمغذی مانند آهن و روی است که در توسعه اولیه مغز و حمایت از سیستم ایمنی بدن اهمیت دارد [۱]. از میان ۲۵ میلیون نفر شتر موجود در دنیا، ۸۵٪ آن در قاره آفریقا و بقیه آن‌ها در قاره آسیا زندگی می‌کنند [۲]. گوشت شتر با داشتن پروتئین‌هایی با ارزش غذایی بالا، کیفیت تغذیه‌ای بالایی دارد که نه تنها با گوشت گاو قابل مقایسه است بلکه حتی در مواردی مانند میزان چربی، کلسترول کمتر و ترکیب اسیدهای چرب غیر اشباعی بهتر توانسته است از آن بهتر باشد و به طور کلی آن می‌تواند جایگزین مناسبی برای گوشت گوساله باشد [۳].

علم پردازش تصویر، به عنوان یکی از علوم پرکاربرد و مهم در فنون مهندسی، از جمله شاخه صنایع غذایی جهت تعیین کیفیت مواد غذایی محسوب می‌شود که یکی از کاربردهای ارزشمندی که می‌توان از آن استفاده نمود در پیش‌بینی تازگی گوشت‌ها و محتویات چربی در گوشت است. امروزه میزان مصرف گوشت قرمز به خاطر بالا بودن درصد چربی آن نسبت به گوشت سفید کمتر توصیه می‌شود و سعی می‌شود در صورت مصرف آن جهت جلوگیری از بروز بیماری‌های قلبی و عروقی میزان چربی مصرفی آن کنترل شود. یکی از مهم‌ترین روش‌هایی که می‌تواند در کنترل تازگی گوشت و چربی مورد استفاده قرار گیرد، سیستم ماشین‌بینایی است. مزیت این روش، سرعت بالای آن و پاسخ‌گویی در کوتاه‌ترین زمان و غیر مخرب بودن آن می‌باشد [۴، ۵]. سیستم ماشین‌بینایی به طور همزمان در خط فرآوری مواد غذایی و برای کارهایی از قبیل تعیین ترکیبات، ارزیابی اندازه و حجم، اندازه‌گیری پارامترهای شکل، رنگ گوشت و تشخیص عیب آن مورد استفاده قرار می‌گیرد [۵، ۶]. با وجود بهبود و توسعه الگوهای زندگی به ویژه از جنبه اقتصادی، مشخصه کیفیت و سلامت مواد غذایی از اهمیت بسیار بالایی برای مردم جهان برخوردار می‌باشد. از جمله مهم‌ترین پارامترهای کیفی، برای فرآورده‌های گوشتی، مربوط به تازگی است که تولید

1. Multilayer Perceptron

۲. مواد و روش‌ها

۱.۱.۲. آماده‌سازی نمونه‌ها

برای انجام آزمایش‌ها، مقدار ۴ kg گوشت ران شتر تازه ذبح شده از کشتارگاه خاتون‌آباد واقع در حومه شهرستان جیرفت تهیه شد. نمونه‌ها با ضخامت ۳-۴ cm و وزنی حدود ۱۰۰ gr جهت تصویربرداری و انجام آزمایش‌های مخرب آماده‌سازی شدند. در طول دوره آزمایش‌ها، نمونه‌ها در یخچال با دمای ۴°C نگهداری شدند.


۲.۲. پردازش تصویر

۱.۲.۲. تصویربرداری

پس از آماده‌سازی نمونه، نمونه‌های گوشت شتر به اتافک تصویربرداری از چیدمان موجود در کارگاه طراحی و تحقیق گروه مهندسی مکانیک بیوسیستم دانشگاه جیرفت انتقال داده شد و تصاویر مورد نظر جهت عملیات پیش‌پردازش تصاویر تهیه شد (شکل ۱). این چیدمان از سامانه تصویربرداری شامل دوربین دیجیتال، سیستم نورپردازی، محفظه نورپردازی، مجموعه رایانه و متعلقات آن، نرم‌افزار تصویربرداری خودکار و سایر نرم‌افزارهای پردازش تصویر و قسمت قرارگیری نمونه‌ها تشکیل شده است. منبع ایجاد نور شامل دو عدد لامپ فلورسنت مونوکروم (مهتابی سفید) با توان ۲۰ W بود تا از جهات مختلف به نمونه نور تابیده شود تا از تشکیل سایه در تصویر جلوگیری شود. جهت تصویربرداری نیز از دوربین نوع Canon EOS kiss x4 دیجیتالی با وضوح ۱۸ مگاپیکسل استفاده شد. کلیه تصاویر نمونه‌ها از فاصله ثابت ۳۰ cm لنز دوربین تا سطح نمونه‌ها و در شرایط نورپردازی یکسان تهیه شدند. وجود یک پس‌زمینه یکنواخت سبب افزایش تضاد بین پیش‌زمینه (در اینجا گوشت) و پس‌زمینه شده و کیفیت نتایج به دست آمده بعد از عملیات قطعه‌بندی تصاویر را افزایش می‌دهد. در نهایت تعداد ۱۴۰ تصویر رنگی (۲۰ تصویر برای هر نمونه) تهیه شد که برای عملیات پردازش تصویر مورد استفاده قرار گرفت.

بوده است [۱۲]. در تحقیقی با تجزیه و تحلیل ارتباط بین مقادیر نقاط سفید حاصل از تصاویر ران و عضلات بوقلمون با روش کامپیوتر بینایی و تعیین درصد چربی با دستگاه سوکسله، نتیجه گرفتند که ماشین بینایی می‌تواند درصد چربی را با دقت ۶۵٪ تخمین بزند [۱۳]. محققین در تحقیقی که روی پیش‌بینی محتوای چربی گوشت گاو با استفاده از تکنیک پردازش تصویر پرداختند، دریافتند که این روش می‌تواند بافت گوشت و محتوای چربی را به ترتیب با دقت ۹۹/۶۵٪ و ۹۹/۲۱٪ تخمین بزند [۱۴]. ماشین بینایی به عنوان یک ابزار کارآمد برای ارزیابی کیفیت در تولید مواد غذایی شناخته شده است و کاربرد آن به طرز قابل توجهی افزایش یافته است. تحقیقات انجام گرفته در زمینه بکارگیری ماشین بینایی و پردازش تصویر در ارزیابی کیفیت محصولات گوشتی مانند گوشت خوک، گوشت گاو، گوسفند، مرغ و ماهی نشان می‌دهد که این روش به دلیل فناوری‌های رایانه‌ای و سرعت پردازش بالای الگوریتم‌ها، دارای تمام پتانسیل‌های لازم برای تبدیل شدن به یک فرایند اساسی در صنعت کیفیت غذا می‌باشد [۱۵، ۱۶]. پنینگ و همکاران از دو روش مختلف پردازش تصویر و روش طیف سنجی جرمی جهت درجه‌بندی کیفیت گوشت استفاده کردند. نتایج آنها نشان داد که روش پردازش تصویر باعث افزایش سرعت و دقت تشخیص کیفیت می‌شود [۱۷].

بنابراین، با توجه به اهمیت تشخیص تازگی گوشت شتر به دلیل حفظ کیفیت، کنترل و پیش‌بینی تازگی و محتوای چربی گوشت شتر از اهمیت خاصی برخوردار می‌شود که تا به حال در هیچ تحقیقی گزارش نشده است. با این حال، در این تحقیق سعی شده است که با کمک روش‌های پردازش تصویر و شبکه عصبی مصنوعی به پیش‌بینی مدت زمان گذشته از ذبح و به عبارتی طبقه‌بندی گوشت شتر بر اساس تازگی و پیش‌بینی محتوای چربی آن پرداخته شود که علاوه بر استفاده از روش غیر مخرب ماشین‌بینایی از روش مخرب آزمایشگاهی نیز برای تشخیص چربی استفاده شد.

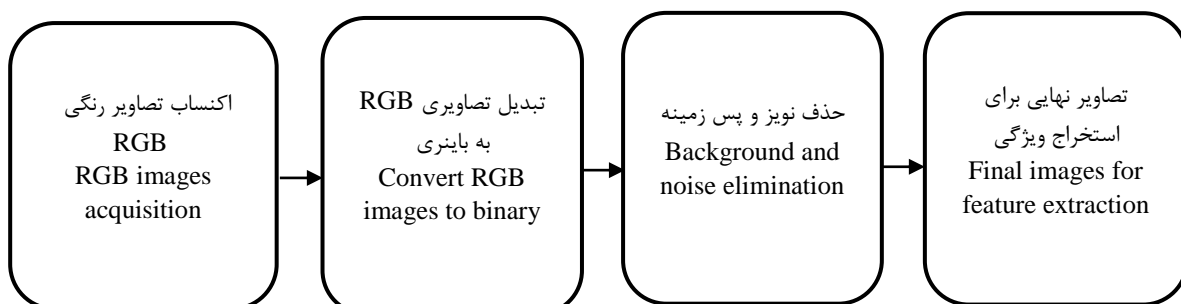


شکل (۱) چیدمان تصویربرداری: ۱- رایانه ۲- دوربین ۳- صفحه قوسی شکل ۴- نمونه ۵- لامپ فلورسنت مونوکروم (مهتابی سفید)
Fig 1. Imaging Set-up: 1- Computer 2- Camera 3- Arched Sheet 4- Sample 5- Monochrome fluorescent lamp (white moonlight)

۲.۲.۲. پیش‌پردازش تصاویر

مشخص و تبدیل تصاویر بین فضاهای رنگی و حذف پس‌زمینه است که در نهایت این تصویر با حذف پس‌زمینه برای استخراج ویژگی‌ها استفاده شد. لازم به ذکر است بیان گردد که تمامی عملیات پیش‌پردازش تصاویر با استفاده از برنامه‌نویسی در نرم افزار متلب (۲۰۱۴ b) صورت پذیرفت.

در این مرحله، پس از تهیه تصاویر، گام بعدی جهت استخراج ویژگی‌های مورد نظر، پیش‌پردازش تصاویر می‌باشد (شکل ۲). مرحله پیش‌پردازش شامل عملیاتی مانند بخش‌بندی تصاویر همچون انتقال تصاویر از فضای رنگی RGB به فضای باینری سیاه و سفید با حد آستانه $0/5$

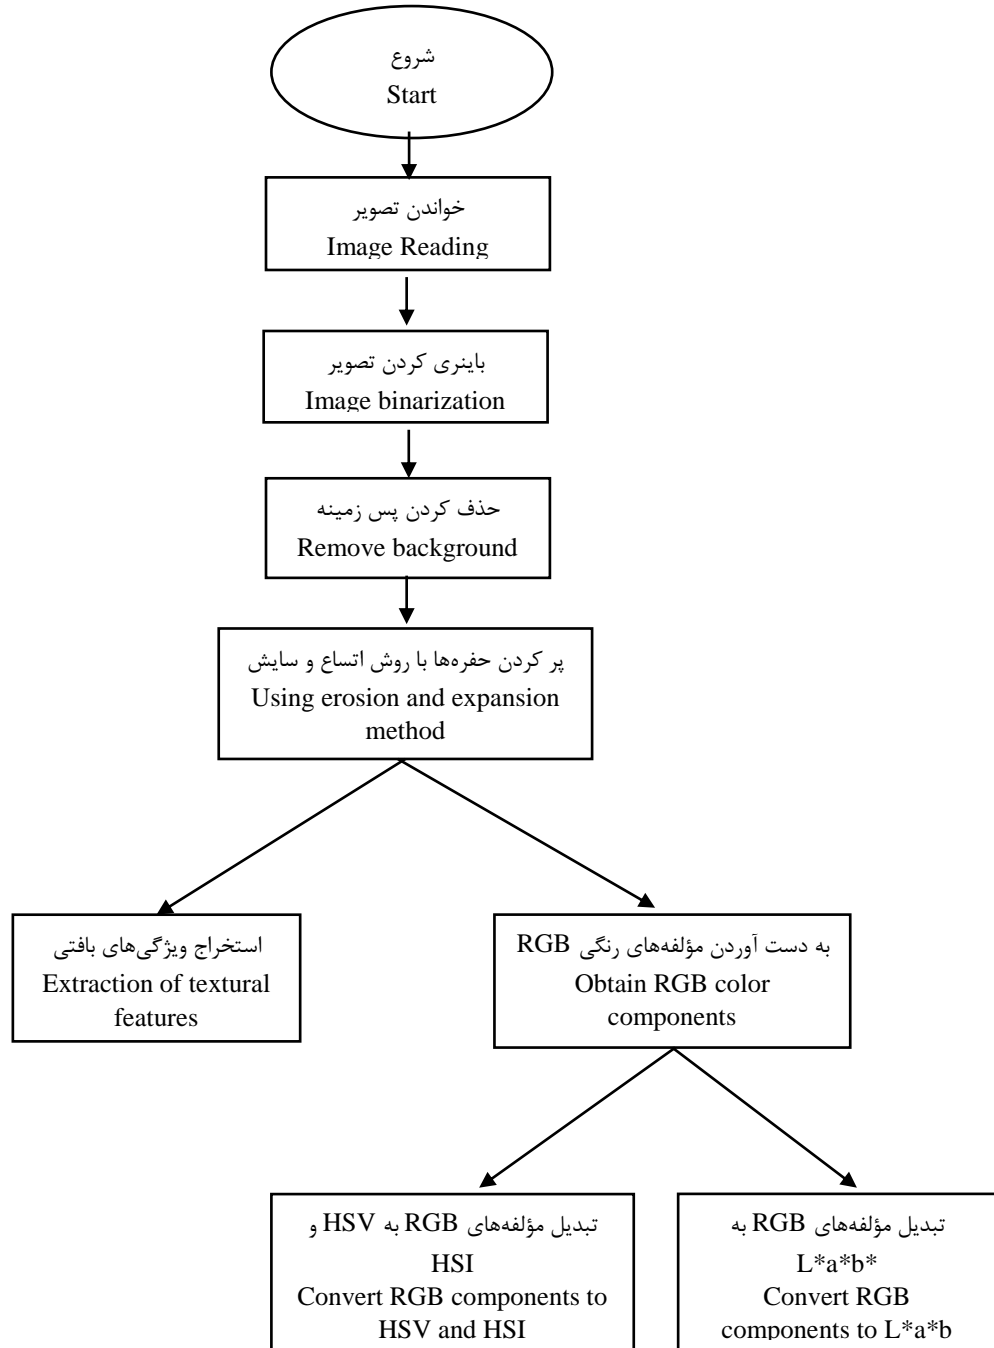


شکل (۲) مراحل پیش‌پردازش تصاویر
Fig 2. Image preprocessing steps

تصاویر مطابق فلوجارت زیر انجام شد (شکل ۳).

۳.۲.۲. استخراج ویژگی‌های تصویر

به طور کلی فرآیند استخراج ویژگی‌های رنگی و بافتی



شکل (۳) فلوجارت استخراج ویژگی‌های بافتی و رنگی

Fig 3. Flowchart diagram for images features extraction (color and texture)

۴.۲.۲. استخراج ویژگی‌های رنگی

پس از تهیه تصاویر و استخراج مؤلفه‌های رنگی R، G و B، مؤلفه شدة از میانگین مقادیر این سه مؤلفه محاسبه شد. مقادیر ترکیبات رنگی RGB در محدوده (۱،۰) می‌باشند و مؤلفه‌های اصل رنگ^۱، اشباع^۲ و شدت رنگ^۳ نیز از تبدیل هندسی بین مؤلفه‌های رنگ با استفاده از روابط (۱) تا (۸) محاسبه شدند:

$$H_{hsi} = \arccos\left\{\frac{[(R-G) + (R-B)]/2}{[(R-G)^2 + (R-B)(G-B)]^{1/2}}\right\} \quad (1)$$

$$S_{hsi} = 1 - \frac{3}{(R+G+B)}[\min(R, G, B)] \quad (2)$$

$$I = \frac{1}{3}(R+G+B) \quad (3)$$

$$V = \max(R, G, B) \quad (4)$$

$$S_{hsv} = V - \min(G, B)/V \quad (5)$$

$$H_{hsv} = (G-B)/6S, \quad \text{if } V=R \quad (6)$$

$$H_{hsv} = 1/3 + (B-R)/6S, \quad \text{if } V=G \quad (7)$$

$$H_{hsv} = 2/3 + (R-G)/S, \quad \text{if } V=B \quad (8)$$

در روابط فوق:

H_{hsi} مؤلفه اصل رنگ در مدل رنگی hsi

S_{hsi} مؤلفه اشباع در مدل رنگی hsi

H_{hsv} مؤلفه اصل رنگ در مدل رنگی hsv

S_{hsv} مؤلفه اشباع در مدل رنگی hsv

V ارزش (روشنایی) در مدل رنگی hsv

I مؤلفه شدت رنگ در مدل‌های رنگی hsi و hsv می‌باشد.

در نهایت، تصاویر رنگی به وسیله تعیین توزیع رنگی از طریق

تصاویر، تغییر در رنگ با توجه به میانگین و تفاوت بین بیشترین و کمترین مقادیر رنگی مشخص شدند. این مشخصه به وسیله محاسبه میانگین، واریانس، محدوده تغییرات و انحراف معیار برای تصاویر رنگی داده شده، به دست آمدند که برای محاسبه این ویژگی‌ها از تصاویر نمونه‌ها از رابطه‌های (۹) تا (۱۲) استفاده شد [۱۸]. در نهایت تعداد ۳۶ ویژگی (۴ پارامتر 3×3 فضای رنگی 3×3 مؤلفه) از تصاویر به دست آمد. لازم به ذکر است که این‌گونه بیان شود این ۳۶ ویژگی به همراه سه ویژگی $(L^*a^*b^*)$ که از تصاویر اصلی به صورت مستقیم با استفاده از برنامه‌نویسی در فضای نرم‌افزار MATLAB استخراج شدند و در مجموع ۳۹ ویژگی رنگی به دست آمد که برای ورودی شبکه عصبی مورد استفاده قرار گرفتند.

$$\mu = \frac{1}{N} \sum_{y=1}^N P_{xy} \quad (9)$$

$$\text{Variance} = \left(\frac{1}{N} \sum_{y=1}^N (P_{xy} - \mu_x)^2 \right)^{\frac{1}{2}} \quad (10)$$

$$\text{Range} = \text{Max}(P(x,y)) - \text{min}(P(x,y)) \quad (11)$$

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (12)$$

۵.۲.۲. استخراج ویژگی‌های بافتی

ابتدا سه تصویر سطوح خاکستری تشکیل‌دهنده هر تصویر رنگی به مؤلفه‌های مستقل تفکیک شدند، سپس برای استخراج ویژگی‌ها، از ماتریس‌های هم‌رخدادی سطح خاکستری استفاده شد. به طور کلی در این تحقیق، ۹ ویژگی ساختاری از هر مؤلفه‌های رنگ و در چهار زاویه (۰، ۴۵، ۹۰ و ۱۳۵ درجه) محاسبه شد (جدول ۱). با در نظر گرفتن هر سه مؤلفه رنگ و تعداد زوایا، در نهایت ۱۰۸ پارامتر به کمک دستورات موجود در نرم‌افزار متلب و برنامه‌نویسی مناسب حاصل شد. از ویژگی‌های استخراج شده در این تحقیق پس از عملیات پیش پردازش، می‌توان به آنتروپی^۴، انرژی^۵

4. Entropy
5. Energy

1. Hue
2. Saturation
3. Intensity

کنتراست^۱، همگنی^۲، میانگین^۳، واریانس^۴، همبستگی^۵، دست آمدند. در نهایت، پارامترهای اندازه‌گیری شده (پارامترهای بافتی و رنگی) به صورت پارامترهای ورودی در شبکه عصبی مصنوعی مورد استفاده قرار گرفتند [۱۹].

جدول (۱) استخراج ویژگی‌های بافتی
Table 1. Extraction of textural features

رابطه Formula	خواص بافتی Textural Features
$\sum_{i=1}^{N_g-1} \sum_{j=1}^{N_g-1} p(i,j) \ln p(i,j)$	آنترپی Entropy
$\sum_{i=1}^{N_g-1} \sum_{j=1}^{N_g-1} \{p(i,j)\}^2$	انرژی Energy
$\sum_{ i-j =0}^{N_g-1} (i-j)^2 \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j)$	کنتراست Contrast
$\sum_{i=1}^{N_g-1} \sum_{j=1}^{N_g-1} \frac{1}{1+(i+j)^2} p(i,j)$	همگنی Homogeneity
$\sum_{i=0}^{N_g-1} i p_x(i)$	میانگین Mean
$\sum_{i,j=0}^{N_g-1} (i-\mu_i)^2 p_x(i)$	واریانس Variance
$\frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} ij p(i,j) - R_{51}^2}{R_{61}}$	همبستگی Solidarity
$\max(p_{ij})$	ماکزیمم احتمال Maximum probability
$\max(p_{ij}) - \min(p_{ij})$	محدوده تغییرات Range

1. Contrast
2. Homogeneity
3. Mean
4. Variance
5. Correlation
6. Maximum Probability
7. Range

۳.۲. آزمایش مخرب

۱.۳.۲. اندازه‌گیری چربی به روش مخرب

در این تحقیق، برای اندازه‌گیری چربی نمونه گوشت شتر از دستگاه سوکسله^۱ استفاده شد. ابتدا، نمونه‌ها در آون در دمای °C ۶۵ به مدت ۴۸ hr قرار داده شد و خشک شدند. سپس نمونه‌های خشک شده در هاون کوبیده شده و به صورت پودر درآمدند. سپس یک گرم از نمونه خشک شده داخل کاغذ صافی ریخته شد و داخل کارتوش^۲ قرار داده شد تا در معرض (حلال) هگزان قرار گیرد. سپس ۶۰ ml هگزان در داخل کاپ‌ها^۳ (ظرف‌های شیشه‌ای مندرج) ریخته و به کارتوش مربوطه وصل شد و به مدت ۲۵ min نمونه‌ها داخل هگزان جوشانده شدند، سپس کارتوش‌ها را بالا آورده و شیرها بسته شده تا هگزان جمع‌آوری شود. کاپ‌ها از دستگاه جدا و به آون منتقل شدند و به مدت ۳۰ min در دمای °C ۱۰۰ جهت تبخیر هگزان قرار داده شدند و پس از آن جهت از بین بردن رطوبت به مدت ۱۵ min در دیسکاتور^۴ قرار داده شدند و با یک ترازوی دیجیتال وزن کاپ‌ها اندازه‌گیری و یادداشت شد. در نهایت، برای محاسبه چربی نمونه، وزن کاپ خالی را از وزن کاپ با نمونه چربی کم شد و سپس بر وزن نمونه خشک تقسیم و درصد چربی نمونه به دست آورده شد [۲۰].

۲.۳.۲. اندازه‌گیری چربی به روش غیر مخرب

برای پیش‌بینی چربی نیز با برنامه‌نویسی در نرم‌افزار MATLAB (نسخه ۲۰۱۴)، ابتدا تصاویر رنگی به حالت تصاویر خاکستری درآورده شدند و سپس با دستور object و bwarea مساحت کل گوشت و مساحت گوشت بدون چربی محاسبه شد، سپس مساحت گوشت بدون چربی از مساحت کل گوشت کم شد تا مساحت قسمت چربی گوشت به دست آید و در پایان با تقسیم مساحت چربی به مساحت کل، درصد چربی به دست آمد.

۴.۲. شبکه‌های عصبی مصنوعی

در این بخش تحقیق، برای طراحی و ارزیابی شبکه‌های

مختلف از جعبه ابزار شبکه عصبی^۵ در نرم‌افزار MATLAB استفاده شد به طوری که به منظور پردازش داده‌های گوناگون، از شبکه عصبی پرسپترون چندلایه^۶ (MLP) با الگوریتم آموزشی پس‌انتشار پیشخور (FFBP) با یک و دو لایه پنهان و توابع انتقال مختلف با تعداد نرون‌های متفاوت استفاده شد. در این شبکه، تابع آموزش لونبرگ-مارکواریت (LM) برای بهنگام‌سازی وزن‌های شبکه عصبی مصنوعی مورد استفاده قرار گرفت. این الگوریتم، آموزش شبکه را بسیار سریع انجام داده و سطح خطای موجود را حداقل می‌سازد. در نهایت، با توجه به ساختار شبکه، ۳۹ ویژگی‌های رنگی و ۱۰۸ ویژگی بافتی به عنوان ورودی شبکه در نظر گرفته شد و عامل بیوشیمیایی محتوی چربی و فاکتور تازگی (روز) نیز به عنوان خروجی شبکه به صورت جداگانه استفاده شدند (شکل ۴). در نهایت، ۱۴۰ الگو (۲۰ تصویر از هر نمونه) برای آموزش و آزمون شبکه استفاده شدند (۷۰٪ برای آموزش و ۳۰٪ برای تست شبکه).

برای یافتن شبکه‌ای با توپولوژی مناسب به کمک الگوریتم‌های آموزشی، از معیار میانگین مربعات خطا (MSE) استفاده شد که هدف آن کمینه شدن خطای مذکور است و با رابطه^(۱۳) تعریف می‌شود:


$$MSE = \frac{1}{MN} \sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2 \quad (13)$$

که در آن MSE، میانگین مربعات خطا در مرحله ارزیابی، S_{ip} خروجی شبکه در نرون i ام و الگوی p ام، T_{ip} خروجی هدف در نرون i ام و الگوی p ام، N تعداد نرون‌های لایه‌ی خروجی و M تعداد الگوهای ارزیابی است. از معیار ضریب تعیین (R^2) نیز برای ارزیابی شبکه طبق رابطه^(۱۴) برای داده‌های پیش‌بینی شده در حین آموزش شبکه استفاده شد. پس از آموزش شبکه، شبکه‌ای که کم‌ترین میانگین مربعات خطا (MSE) و بیشترین مقدار R^2 را داشت، به عنوان بهترین شبکه انتخاب شد.

$$R^2 = 1 - \frac{\sum_{i=1}^M [S_{ip} - T_{ip}]^2}{\sum_{i=1}^M [\bar{S}_{ip} - \bar{T}_{ip}]^2} \quad (14)$$

5. Neural Network Toolbox
6. Multilayer Perceptron

1. Soxhlet
2. Cartouche
3. Caps
4. Desiccator



شکل (۴) ساختار شبکه‌های عصبی MLP

Fig 4. Structure of MLP neural networks

پس از عملیات پیش پردازش، تصاویر نهایی مطابق با شکل (۵) حاصل شد. با توجه به نتایج به دست آمده، پس از فراخوانی تصاویر رنگی RGB (شکل ۵-الف)، در نهایت به روش آستانه‌گیری با حد آستانه $0/5$ به تصاویر باینری تبدیل و ذخیره شد (شکل ۵-ب) سپس، عملیات حذف نویز و پس زمینه نقاطی که نور را منعکس و دقت کار را کم می‌کرد، انجام شد و تمامی اجزای شکل که مساحت آن کمتر از حد خاص بود حذف شدند (شکل ۵-ج)، با توجه به اینکه تصاویر گرفته شده توسط دوربین در فضای رنگی (RGB) که یک فضای رنگی وابسته به دستگاه می‌باشد، تصاویر به فضاهای رنگی (HSI, HSV و $L^*a^*b^*$) مستقل از دستگاه منتقل شدند (شکل ۵-ج).

برای افزایش دقت و سرعت شبکه عصبی و همچنین قابل مقایسه بودن داده‌ها در دامنه‌های مختلف، داده‌های به دست آمده از نرم‌افزار متلب قبل از ورود به شبکه عصبی مصنوعی با استفاده از رابطه (۱۵) نرمال‌سازی شدند. در این رابطه، X_{min} ، X_{max} به ترتیب مقادیر بیشینه و کمینه داده‌ها، X داده‌های آزمایشی و X_n مقدار نرمال شده می‌باشد. BU و BL به ترتیب کران بالا و کران پایین و محدوده نرمال‌سازی [۱ -۱] اعمال شد [۲۱].

$$MSE = \frac{1}{MN} \sum_P \sum_{i=1}^N (S_{ip} - T_{ip})^2 \quad (15)$$

۳. نتایج و بحث

۱.۳. خروجی تصویر عملیات پیش‌پردازش



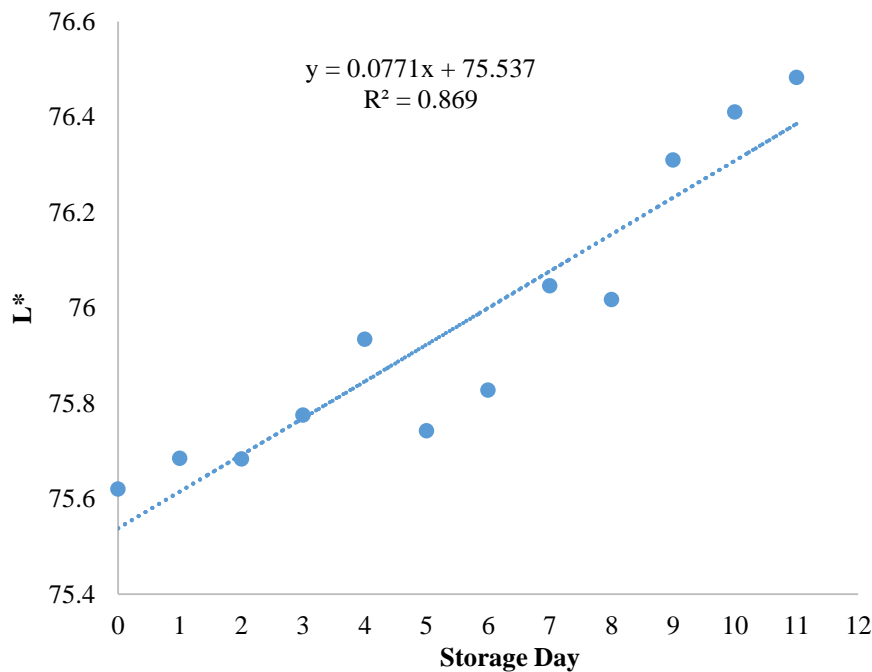
شکل (۵) از راست به چپ تصویر اصلی رنگی، تصویر باینری و حذف پس‌زمینه

Fig 5. From right to left: Original color image, Binary image and Background elimination

مؤلفه رنگی L^* روند افزایشی داشته است. یکی از دلایل افزایش L^* در طول دوره نگهداری می‌تواند به این علت باشد که گوشت در روزهای اولیه شفاف‌تر است و با گذشت زمان که گوشت به مرحله فساد نزدیک‌تر شد، رنگ آن تیره‌تر می‌شود. همان‌طور که از شکل (۶) مشخص است L^* در روز صفر تا روز یازدهم روندی افزایشی داشته و به ترتیب دارای مقادیر $75/62$ و $76/48$ است به طوری که ضریب تبیین برای آن $R^2 = 0/869$ به دست آمد.

۲.۳. تغییرات ویژگی L^* گوشت شتر در طول دوره نگهداری

در این بخش، نمودارهای تغییرات مؤلفه‌های اصلی رنگ در فضای CIELab در مدت زمان نگهداری گوشت شتر در دمای چهار درجه سلسیوس در یخچال تا رسیدن به مرحله فساد مورد بررسی قرار گرفته است. شکل (۶)، تغییرات پارامتر رنگی L^* در طول دوره نگهداری گوشت شتر در یخچال را به مدت ۱۲ روز نشان می‌دهد. همان‌طور که در شکل (۶) مشاهده می‌شود نتایج نشان داد که با گذشت زمان

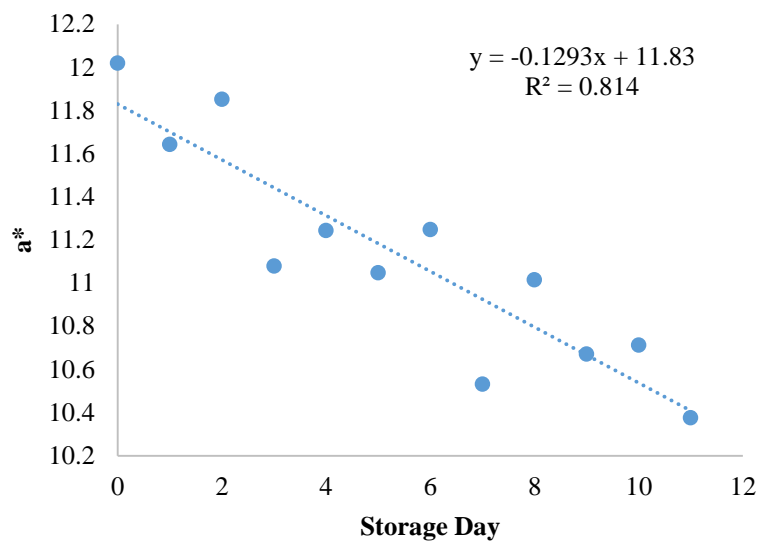


شکل (۶) تغییرات پارامتر رنگی L^* گوشت شتر در طول دوره نگهداری در یخچال
Fig 6. Variation of L^* of camel meat during the refrigeration storage

زمان مقدار قرمزی گوشت شتر از $12/01$ در روز صفر به $10/37$ در روز یازدهم کاهش یافته است. فاکتور a^* دارای ضریب تبیین $0/814$ است. علاوه بر واکنش‌های شیمیایی که منجر به تغییر رنگ گوشت می‌شود، خارج شدن خون از گوشت خود دلیلی بر کاهش فاکتور a^* است.

۳.۳. تغییرات ویژگی a^* گوشت شتر در طول دوره نگهداری

شکل (۷) روند تغییرات مؤلفه رنگی a^* در مدت نگهداری گوشت شتر در دمای $4^\circ C$ (دمای یخچال) را نشان می‌دهد که بیانگر روند نزولی مقدار a^* در طول زمان نگهداری است. فاکتور a^* نشان‌دهنده قرمزی گوشت است که با گذشت




شکل (۷) تغییرات پارامتر رنگی a^* گوشت شتر در طول دوره نگهداری در یخچال

Fig 7. Variation of a^* of camel meat during the refrigeration storage

۴.۳. تغییرات ویژگی b^* گوشت شتر در طول دوره نگهداری

نتایج این تحقیق نشان داد که با گذشت زمان، فاکتور b^* افزایش یافت همان طور که از شکل (۸) مشخص است، این فاکتور از مقدار ۱۲/۸۳- در روز صفر به مقدار ۱۲/۱۱- در روز یازدهم رسیده است. ضریب تبیین b^* طبق شکل زیر ۰/۸۶۳ است.

طبق شکل (۸) نتایج نشان داد که با گذشت زمان فاکتور b^* در طول دوره نگهداری در یخچال روندی افزایشی داشته است. فاکتور b^* مقدار زردی رنگ گوشت را نشان می‌دهد،



شکل (۸) تغییرات پارامتر رنگی b^* گوشت شتر در طول دوره نگهداری در یخچال

Fig 8. Variation of b^* of camel meat during the refrigeration storage

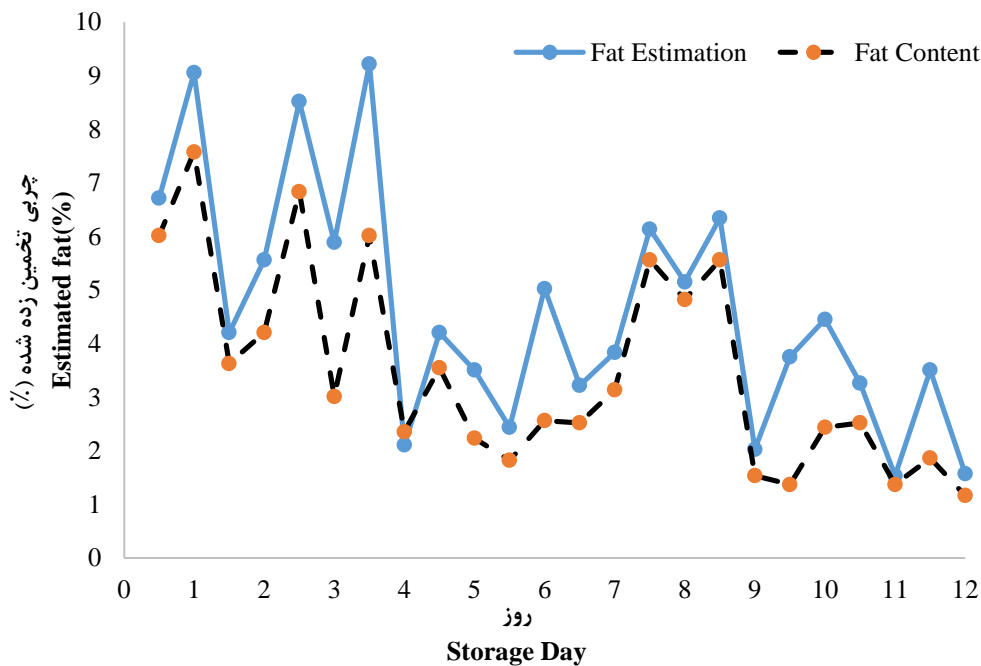
شیبانی و همکاران در سال ۱۳۹۴ در تحقیقی که روی گوشت شترمرغ انجام دادند به این نتیجه رسیدند که با گذشت زمان ۱۱ روز، فاکتورهای رنگی L^* و a^* و b^* روند کاهشی داشتند [۲۲]. در تحقیقی دیگر که روی تغییرات رنگ و اکسیداسیون گوشت شترمرغ در طول ذخیره‌سازی انجام شد، نتایج نشان داد با گذشت زمان ۱۸ روز، مقدار L^* و b^*

پیش‌بینی شده با استفاده از روش پردازش تصویر به صورت خط ممتد آورده شده است. با توجه به نتایج به دست آمده، مشخص شد که در تمامی نمونه‌ها، مقدار چربی پیش‌بینی شده از مقدار چربی واقعی بیشتر بوده است. با توجه به شکل (۹)، نتایج به دست آمده از دستگاه سوکسله در روز اول دارای مقدار چربی ۶/۰۲ و در روز آخر دارای مقدار چربی ۱/۱۸ است و همچنین نتایج به دست آمده از پردازش تصویر در روز اول دارای مقدار ۶/۷۵ و در روز آخر دارای مقدار ۱/۵۹ بود. با توجه به نمودارهای مشخص شد که اندازه‌گیری چربی با استفاده از دستگاه سوکسله و ماشین بینایی نتایج مشابهی دارد و این دو روش دارای روندی ثابت با هم هستند اما روش ماشین بینایی به علت کم هزینه و کم زمان بودن نسبت به روش آزمایش با دستگاه سوکسله بهتر است.

افزایش یافته و a^* کاهش یافته است. در این تحقیق افزایش L^* به دلیل روشن‌تر شدن رنگ گوشت در مدت نگهداری بود و افزایش b^* به دلیل افزایش زردی و کاهش a^* به دلیل کاهش قرمزی رنگ گوشت بود [۲۳]. پژوهش‌های انجام شده روی ماهی نشان می‌دهد که با گذشت زمان تغییراتی روی رنگ آبشش ماهی ایجاد می‌شود که در این تغییرات مقادیر L^* و b^* افزایش و مقدار a^* کاهش می‌یابد [۲۱، ۲۴].

۵.۳. مقایسه اندازه‌گیری چربی به روش مخرب و غیر مخرب

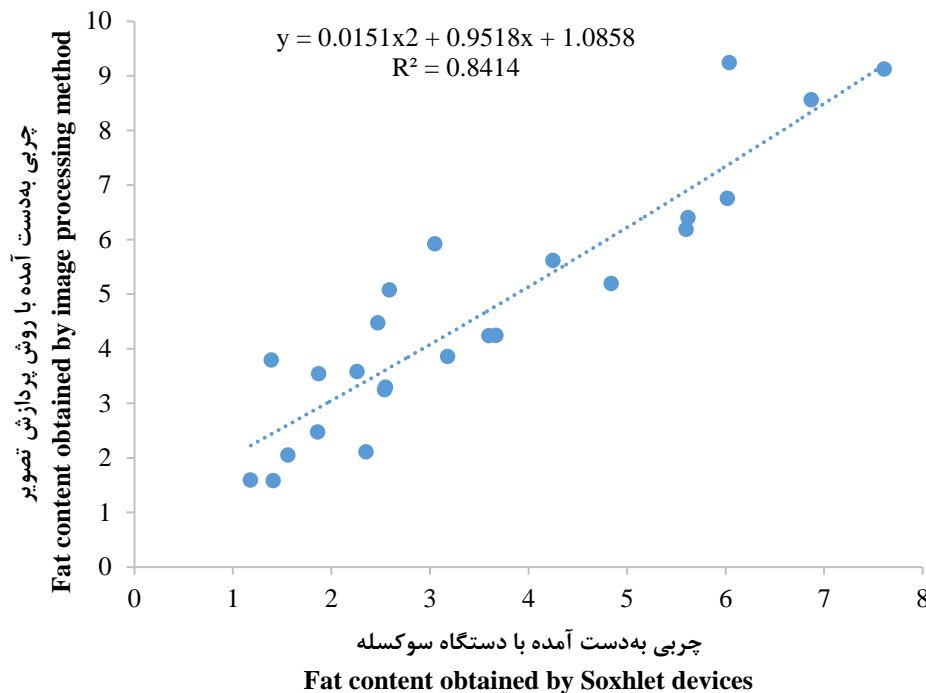
شکل (۹)، نمودار پیش‌بینی چربی به روش پردازش تصویر و روش مخرب نمونه گوشت شتر با استفاده از دستگاه سوکسله را نشان می‌دهد. در شکل (۹)، مقدار چربی به دست آمده از دستگاه سوکسله، با خط چین و مقدار چربی



شکل (۹) مقایسه چربی پیش‌بینی شده با استفاده از دستگاه سوکسله و چربی پیش‌بینی شده با استفاده از روش پردازش تصویر
 Fig 9. Comparison between estimated fat content using Soxhlet device and estimated fat content using image processing method

حاصله از روش غیر مخرب (ماشین بینایی) ضریب تبیین و دقت بین آن‌ها ۰/۸۴۱ به دست آمد (شکل ۱۰).

با توجه به نمودار رگرسیونی چربی به دست آمده از روش مخرب (چربی به دست آمده از دستگاه سوکسله) با چربی



شکل (۱۰) مدل رگرسیونی چربی به دست آمده از دستگاه سوکسله و روش ماشین بینایی
Fig 10. Regression model of fat content obtained from Soxhlet device and image processing method

شبکه با یک لایه پنهان با تعداد چرخه آموزش یک و تابع انتقال تانژانت سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی با بیشترین دقت پیش‌بینی در داده‌های آزمایش با مقدار $R^2 = 0.996$ و همچنین با کمترین مقدار میانگین مربعات خطا (MSE) برابر با 2.3×10^{-22} ، تشخیص داده شد. پس از ارزیابی شبکه سه لایه با دو لایه پنهان، مشخص شد که بهترین ساختار شبکه برای پیش‌بینی تازگی گوشت، مربوط به توپولوژی ۱-۴-۹-۱۴۷ با توابع انتقال تانژانت سیگموئید-خطی-خطی با تعداد چرخه آموزش یک و با دقت آزمایش ۰/۹۹ حاصل شد (جدول ۲). با توجه به نتایج حاصله، مشخص شد که شبکه عصبی با یک لایه پنهان نسبت به شبکه عصبی با دو لایه پنهان عملکرد بهتری برای پیش‌بینی تازگی گوشت شتر دارد. نتایج این تحقیق با نتایج تحقیقات دولتی و همکاران در سال ۱۳۹۲ روی تازگی گوشت ماهی با دقت ۹۸/۴۸٪ و شیبانی در سال ۱۳۹۴ بر روی تازگی گوشت شتر مرغ با دقت ۹۸/۹۹٪ و لیائو و همکاران در سال ۱۴۰۰ همخوانی دارد [۲۴، ۲۲، ۲۱].

محققین میزان چربی گوشت گاو به دست آمده از روش آنالیز تصویر و چربی حاصله از دستگاه سوکسله را با یکدیگر مقایسه کردند و ضریب همبستگی بین آن‌ها را در حدود ۰/۸۱ گزارش کردند [۱۷]. بر اساس تحقیقی که روی تعیین میزان چربی گوشت مرغ بر اساس روش ماشین بینایی انجام شده است میزان همبستگی بین چربی به دست آمده از روش ماشین بینایی و دستگاه سوکسله جهت اندازه‌گیری چربی دارای ضریب همبستگی ۰/۶۵ بوده است [۱۳].

۶.۳. طبقه‌بندی گوشت براساس تازگی با استفاده از شبکه‌های عصبی مصنوعی

جدول (۲)، نتایج شبکه عصبی با یک و دو لایه پنهان با میانگین دقت پیش‌بینی تازگی گوشت شتر با استفاده از ترکیب ویژگی‌های بافت و رنگ را نشان می‌دهد. بر اساس نتایج به دست آمده، شبکه با یک و دو لایه پنهان با تعداد نرون‌های متفاوت در این لایه، بهترین ساختار در تابع یادگیری لونبرگ-مارکوارت و توپولوژی ۱-۳-۱۴۷ برای

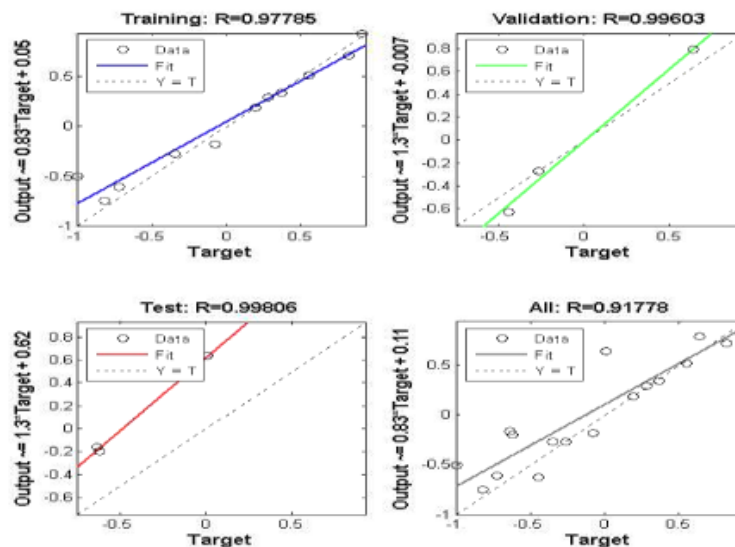
جدول (۲) تغییر تابع انتقال در لایه‌های پنهان و خروجی شبکه عصبی پس‌انتشار و تأثیر آن در پیش‌بینی تازگی (روز) با استفاده از ویژگی‌های رنگی - بافتی

Table 2. Alteration of the transfer function in the output and hidden layers of the back propagation neural network and its effect on estimating the freshness (day) based on color-textural features

R ² Test	R ² Training	میانگین مربعات خطا MSE	تعداد چرخه آموزش Number of training epoch	توپولوژی Topology	توابع انتقال (لایه پنهان - لایه خروجی) Transfer functions (Hidden layer - output layer)
0.996	0.954	2.30e ⁻²²	1	147-3-1	تانزانانت سیگموئید - خطی Tangent Sigmoid-Linear
0.90	0.715	0.112	12	147-3-1	تانزانانت سیگموئید - تانزانانت سیگموئید Tangent Sigmoid - Tangent Sigmoid
0.893	0.996	2.27 ⁻⁰⁷	3	147-3-1	لگاریتم سیگموئید - لگاریتم سیگموئید Log Sigmoid - Log Sigmoid
0.961	0.801	0.110	6	147-3-1	تانزانانت سیگموئید - لگاریتم سیگموئید Tangent Sigmoid- Log Sigmoid
0.99	0.387	1.37e ⁻²⁷	1	147-9-4-1	تانزانانت سیگموئید - خطی - خطی Tangent Sigmoid- Linear - Linear
0.601	0.466	7.28e ⁻⁰⁸	2	147-3-7-1	تانزانانت سیگموئید-لگاریتم سیگموئید - خطی Tangent Sigmoid - Log Sigmoid-Linear
0.986	0.427	0.241	8	147-9-3-1	خطی - خطی - لگاریتم سیگموئید Linear-Linear- Log Sigmoid

آزمایش ۰/۹۹۶ برای پیش‌بینی تازگی به دست آمد. این نمودار نشان می‌دهد که شبکه عصبی با دقت خوبی قادر به پیش‌بینی تازگی در گوشت شتر با استفاده از ۱۴۷ ویژگی ترکیبی بافت و رنگ شده است.

نمودار ضریب همبستگی بهترین شبکه برای پیش‌بینی تازگی توسط شبکه عصبی در داده‌های آزمایش در شکل (۱۱) نشان داده شده است که طبق نتایج حاصله، مقدار ضریب همبستگی، در حالت ۱۴۷ ویژگی برای داده‌های



شکل (۱۱) نمودار رگرسیونی پیش‌بینی تازگی با استفاده از ویژگی‌های رنگی و بافتی

Fig 11. Regression diagram of freshness prediction based on color and texture Features

در تحقیقی که در مورد تشخیص کیفیت گوشت شترمرغ با استفاده از تکنیک ماشین بینایی انجام شد، محققین به این نتیجه رسیدند که ماشین بینایی و شبکه عصبی قادر است تازگی گوشت را با دقت ۹۸/۹۹٪ تخمین بزند [۲۲]. لو و همکاران با تحقیقی که روی تعیین پتانسیل ماشین بینایی جهت پیش‌بینی رنگ گوشت خوک انجام دادند، به این نتیجه رسیدند که شبکه عصبی مصنوعی جهت پیش‌بینی رنگ گوشت بهتر از روش‌های آماری MIR است [۲۵]. باکوس در تحقیقی به طبقه‌بندی کیفیت گوشت خوک با استفاده از روش پردازش تصویر و یادگیری عمیق پرداخت. این محقق موفق شد با دقت کلی ۸۷/۹۳ طبقه‌بندی کیفی گوشت خوک را در سه گروه تازه، نیمه تازه و تقلبی انجام دهد [۲۶]. نتایج این تحقیقات با تحقیق حاضر همخوانی دارند.

۷.۳. پیش‌بینی میزان چربی با استفاده از شبکه عصبی

مصنوعی
ارزیابی شبکه با استفاده از ۱۴۷ ویژگی ترکیبی رنگی-بافتی به عنوان ورودی به شبکه و با توابع انتقال متفاوت در لایه پنهان و خروجی انجام شد که در این مدل از شبکه با یک و دو لایه پنهان استفاده شده است که در جدول (۳) نشان داده شده است. بر اساس نتایج حاصل شده از شبکه با یک لایه پنهان، شبکه با تابع انتقال خطی-تانژانت سیگموئید به ترتیب در لایه پنهان و لایه خروجی و با توپولوژی ۱-۶-۱۴۷ و تعداد چرخه آموزش دو، بهترین ساختار با ضریب تبیین داده‌های آزمایش ۰/۸۳۱ را برای پیش‌بینی چربی گوشت شتر حاصل نمود. با ارزیابی شبکه عصبی با دو لایه پنهان، بهترین ساختار با تابع انتقال خطی- لگاریتم سیگموئید در لایه‌های پنهان اول و دوم و تابع انتقال لگاریتم سیگموئید در لایه خروجی با چرخه آموزش ۸ و با ضریب تبیین آزمایش ۰/۹۹ بهترین نتایج را حاصل کرد (جدول ۳).

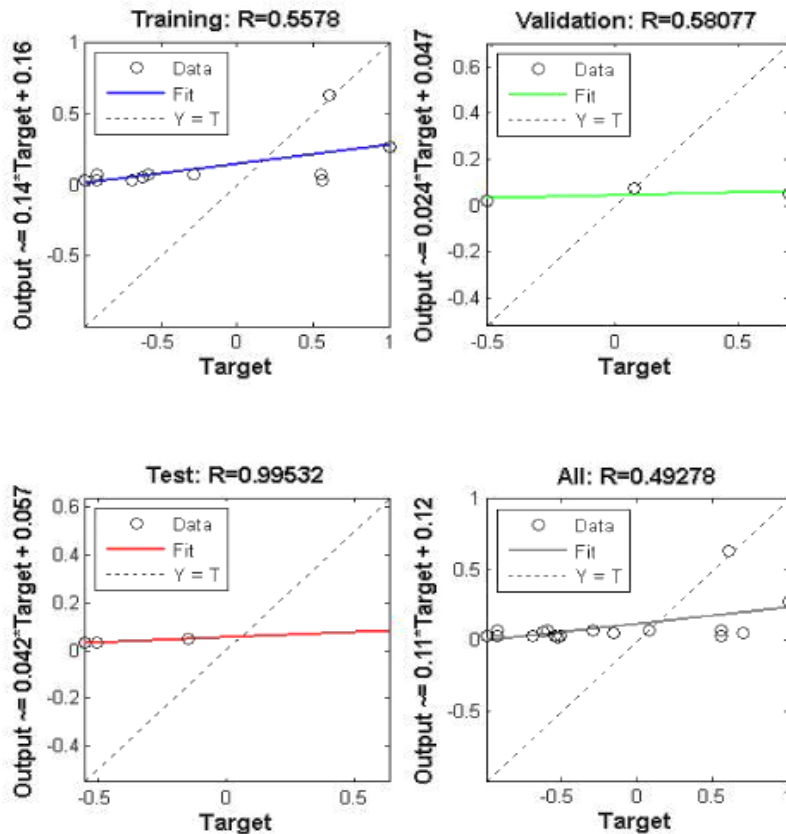
جدول (۳) تغییر تابع انتقال در لایه‌های پنهان و خروجی شبکه عصبی پس‌انتشار با یک و دو لایه پنهان و تأثیر آن در میانگین دقت تشخیص چربی با استفاده ویژگی‌های رنگی-بافتی

Table 3. Alteration of the transfer function in the output and hidden layers of the backpropagation neural network with one and two hidden layers and it's effect on accuracy of fat content prediction based on color-textural features

R ² Test	R ² Training	میانگین مربعات خطا MSE	تعداد چرخه آموزش Number of training epoch	توپولوژی Topology	توابع انتقال (لایه پنهان - لایه خروجی) Transfer functions (Hidden layer - output layer)
0.81	0.014	5.54e ⁻²¹	1	147-14-1	خطی - خطی Linear- Linear
0.82	0.124	4.13e ⁻²²	0	147-24-1	تانژانت سیگموئید- خطی Tangent Sigmoid-Linear
0.552	0.739	0.0199	3	147-6-1	تانژانت سیگموئید- تانژانت سیگموئید Tangent Sigmoid - Tangent Sigmoid
0.831	0.518	0.072	2	147-6-1	خطی- تانژانت سیگموئید Linear -Tangent Sigmoid
0.99	0.305	0.402	8	147-3-3-1	خطی- لگاریتم سیگموئید- لگاریتم سیگموئید Linear - Log Sigmoid - Log Sigmoid
0.951	0.826	0.346	14	147-15-10-1	لگاریتم سیگموئید- تانژانت سیگموئید- لگاریتم سیگموئید Log Sigmoid - Tangent Sigmoid - Log Sigmoid
0.892	0.40	4.27e ⁻⁰⁶	4	147-15-10-1	لگاریتم سیگموئید- خطی- تانژانت سیگموئید Log Sigmoid - linear - Tangent Sigmoid

عصبی با دو لایه پنهان را نشان می‌دهد. همان‌طور که مشاهده می‌شود بیشترین مقدار ضریب همبستگی (R) برای داده‌های آموزش چربی ۰/۹۹۵ است که این نمودار نشان می‌دهد که شبکه عصبی با دقت خوبی قادر به پیش‌بینی مقدار محتوای چربی در گوشت شتر است.

با توجه به نتایج جدول (۲) مشخص شد که شبکه عصبی با دو لایه پنهان نسبت به شبکه عصبی با یک لایه پنهان در پیش‌بینی میزان چربی گوشت شتر عملکرد بهتری را داشت. شکل (۱۲) مقدار ضریب همبستگی برای پیش‌بینی مقادیر چربی واقعی با مقادیر چربی پیش‌بینی شده توسط شبکه



شکل (۱۲) نمودار رگرسیونی پیش‌بینی چربی با استفاده از ویژگی‌های رنگی و بافتی
 Fig 12. Regression diagram of fat content prediction based on color and texture Features

با یک لایه پنهان با توپولوژی ۱-۳-۱۴۷ و با استفاده از ویژگی‌های بافتی و رنگی به عنوان ورودی شبکه، با بیشترین دقت ۰/۹۹۶ محسوب شد و همچنین شبکه دو لایه دارای بیشترین دقت ۰/۹۹ بود. با این حال برای طبقه‌بندی گوشت شتر بر اساس تازگی (روز)، شبکه عصبی با یک لایه پنهان عملکرد بهتری نسبت به شبکه دو لایه داشت. همچنین با توجه به نتایج به دست آمده از شبکه عصبی مصنوعی با استفاده از حالت ۱۴۷ ویژگی بافتی-رنگی برای پیش‌بینی چربی، بهترین ساختار شبکه ساختاری با توپولوژی ۱-۴-۹-۱۴۷ با دو لایه پنهان با بیشترین دقت ۰/۹۹ همچنین شبکه

۴. نتیجه‌گیری

این تحقیق روشی برای طبقه‌بندی میزان تازگی و پیش‌بینی ویژگی بیوشیمیایی محتوای چربی در گوشت شتر با استفاده از روش‌های پردازش تصویر و شبکه‌های عصبی مصنوعی بود. نتایج نمودار رگرسیونی چربی نشان داد که با استفاده از روش مخرب (چربی به دست آمده از دستگاه سوکسله) با چربی حاصله از روش غیر مخرب (ماشین بینایی)، ضریب تبیین و دقت بین آن‌ها ۰/۸۴۱ به دست آمد. بهترین ساختار شبکه عصبی برای پیش‌بینی تازگی (بر اساس روز) گوشت شتر با استفاده از شبکه عصبی، ساختاری

شتر، امیدوار کننده است.

سیاسگزاری

نویسندگان این مقاله، مراتب تشکر و قدردانی خود را از دانشگاه جیرفت به جهت حمایت‌های مادی و معنوی از این پژوهش اعلام می‌دارند.

یک لایه دارای بیشترین دقت ۰/۸۳۱ به دست آمدند که از این رو دقت شبکه دولایه برای پیش‌بینی محتوی چربی نسبت به شبکه لایه بهتر بود و عملکرد مناسب‌تری داشت. در نتیجه، انجام این تحقیق نشان داد که استفاده از روش پردازش تصویر مبتنی بر هوش مصنوعی همراه با داشتن دقت طبقه بند مناسب برای پیش‌بینی تازگی و چربی گوشت

منابع

- [1] Mohammed, H. H. H., Jin, G., Ma, M., Khalifa, I., Shukat, R., Elkhedir, A. E., Zeng, Q. & Noman, A. E. (2020). Comparative characterization of proximate nutritional compositions, microbial quality and safety of camel meat in relation to mutton, beef, and chicken. *LWT - Food Sci. Technol.*, 118, 108714 (1-7).
- [2] Ali, A., Baby, B., & Vijayan, R. (2019). From desert to medicine: a review of camel genomics and therapeutic products. *Front. genet.*, 10 (17), 1-20.
- [3] Baba, W. N., Rasool, N., Selvamuthukumara, M., & Maqsood, S. (2021). A review on nutritional composition, health benefits, and technological interventions for improving consumer acceptability of camel meat: an ethnic food of Middle East. *J. Ethn. Foods*, 8(1), 1-13.
- [4] Dowlati, M., de la Guardia, M., & Mohtasebi, S. S. (2012). Application of machine-vision techniques to fish-quality assessment. *TrAC Trends Anal. Chem.*, 40, 168-179.
- [5] Rahman, M.F., Abdullah Iqbal, M., Hashem, A. & Adedeji, A.A. (2020). Quality Assessment of Beef Using Computer Vision Technology. *Food Sci. Anim. Resour.*, 40(6), 896-910.
- [6] Singh, T. P., & Chatli., M. K. (2013). Advances in computer vision technology for foods of animal and aquatic origin. *J. Meat Sci. Technol.* 1(2), 40-49.
- [7] Xiong, Z., Sun, D.W., Pu, H., Xie, A., Han, Z. & Luo, M. (2015). Non-destructive prediction of thiobarbituric acid reactive substances (TBARS) value for freshness evaluation of chicken meat using hyperspectral imaging. *Food Chem.*, 179, 175-181.
- [8] Lawrie, R.A. (2006). *Lawrie's Meat Science (7th ed.)*. Woodhead Publishing Limited, Cambridge, Uk.
- [9] Multan, W. K., Ali, S. K., Aydam, Z. M., & Taher, B. H. (2020). Feature Extraction Methods: A Review. In *Journal of Physics: Conf. Ser. (Vol. 1591, No. 1, p. 012028)*. IOP Publishing.
- [10] Long, F., Zhang, H., & Feng, D. D. (2003). Fundamentals of content-based image retrieval. In: D. Feng, W. C. Siu, & H. J. Zhang, (Eds.) *Multimedia information retrieval and management* (pp. 1-26). Springer, Berlin, Heidelberg.
- [11] Nekoie, N., Dowlati, M. & Golpour, I. (2016). Identification and classification of persian Cumin (*Bunium persicum* Boiss) landraces using image processing in combination with artificial neural networks. *J. Res. Mech. Agric. Mach.*, 5(8), 37. [In Persian]
- [12] Shiranita, K., Hayashi, K., Otsubo, A., Miyajima, T. & Takiyama, R. (2000). Grading meat quality by image processing. *Pattern Recognit.*, 33, 97-104.
- [13] Chmiel, M., Slowinski, M. & Dasiewicz, K. (2011). Application of computer vision systems for estimation of fat content in poultry meat. *Food Control* 22(8), 1424-1427.
- [14] Dousti Irani, A. & Golzarian, M.R. (2013). Design and evaluation of image processing algorithm for estimating red meat fat content. In *8th Natl. Congr. Agric. Mach. Eng. (Biosyst.) Mech. Iran.* (pp. 3036-3046), *Ferdowsi University of Mashhad*. [In Persian]
- [15] Putra, G. B., & Prakasa, E. (2020). Classification of Chicken Meat Freshness using Convolutional Neural Network Algorithms. In *Int. Conf. Innov. Intell. Inform. Comput. Technol. (3ICT)* (pp. 1-6). IEEE.
- [16] Taheri-Garavand, A., Fatahi, S., Omid, M., & Makino, Y. (2019). Meat quality evaluation based on computer vision technique: A review. *Meat sci.*, 156, 183-195.
- [17] Penning, B. W., Snelling, W. M., & Woodward-Greene, M. J. (2020). Machine learning in the assessment of meat quality. *IT Prof.*, 22(3), 39-41.
- [18] Neelamma, K. P., Virendra, S. M. & Ravi, M.Y. (2011). Color and texture based identification and classification of food Grains using different Color Models and Haralick features. *IJCSE*. 3(12), 3669-3680.
- [19] Golpour, I. (2012). Predicting, diagnosing and investigating the drying kinetics of rice cultivars using image processing and artificial neural networks.

Master thesis in Biosystem mechanics. School of Agriculture, Bu-Ali Sina University. [In Persian]

[20] AOAC International 2002. Official methods of analysis, 16th end, AOAC International, Arlington.

[21] Dowlati, M., Mohtasebi, S. S., Omid, M., Razavi, S. H., Jamzad, M., & De La Guardia, M. (2013). Freshness assessment of gilthead sea bream (*Sparus aurata*) by machine vision based on gill and eye color changes. *J. Food Eng.*, 119(2), 277-287.

[22] Sheibani tazrachi, A. (2015). Detection of quality and grading of ostrich meat using artificial technique. *Master thesis Biosyst. mech., Sch. Agric. Jiroft Univ.*, [In Persian]

[23] Jouki, M. & Khazaei, N. (2012). Color and oxidation changes in camel meat during storage. *Int. J. Pharma and Bio Sci.*, 3(1), 164-170.

[24] Liao, Q., Wei, C., Li, Y., & Ouyang, H. (2021). Developing a Machine Vision System Equipped with UV Light to Predict Fish Freshness Based on Fish-Surface Color. *Food Nutr. Sci.*, 12(3), 239-248.

[25] Lu, J., Tan, J., Shatadal, P. & Gerrard, D. (2000). Evaluation of pork color by using computer vision. *Meat Sci.*, 56(1), 57-60.

[26] Bacus, J. A. (2021). Identification of Pork Meat Freshness Using Neural Networks. In 2021 IEEE: *Int. Conf. Electron. Technol. Commun. Inf. (ICETCI)* (pp. 402-405).



Research Article

Application of image processing and artificial neural networks as a non-destructive approach to prediction of fat content and classification of camel meat

Zoherh Molaei¹, Majid Dowlati^{2*}, Iman Golpour³, Hamid Ghasemkhani⁴

- 1. MsC Graduate, Department of Mechanical Engineering of Biosystems, Faculty of Agriculture, University of Jiroft**
- 2. Assistant professor, Department of Food Science and Technology, Tuyserkhan Faculty of Engineering and Natural Resources, Bu-Ali Sina University**
- 3. PhD Graduate, Department of Mechanical Engineering of Biosystems, Faculty of Agriculture, University of Urmia**
- 4. Assistant professor, Department of Mechanical Engineering of Biosystems, Faculty of Agriculture, University of Jiroft**

Abstract

Camel meat can be a suitable alternative for other red meat types in human nutrition, due to its low cholesterol and low-fat content and the appropriate protein content. This research aims to investigate and evaluate the fat content and freshness of camel meat using machine vision technology as a non-destructive method. Therefore, using image processing as a non-destructive method and Soxhlet device as a destructive method, the amount of fat content was predicted, and also the freshness was classified for camel meat. In the image processing section, 108 textual features and 39 color features were extracted in the RGB, HSV, HIS, and CIElab color spaces. Moreover, to predict the freshness and quality of meat, feed-forward back propagation artificial neural networks with one and two hidden layers, a various number of neurons, and threshold functions were used. Also, according to the regression diagram of fat content obtained from the destructive method (fat content obtained from Soxhlet device) with fat content obtained from non-destructive method (machine vision), the coefficient of determination and accuracy between them achieved 0.841. The results of the evaluation of the neural networks showed that the best desirable network for classification based on freshness is a one-hidden layer network with topology 147-3-1, tangent-sigmoid transfer function at hidden layer and purelin transfer function at output layer ($R^2= 0.996$), and also to prete of fat content the best network is two-hidden layer network with linear, log-sigmoid, log-sigmoid transfer function at first hidden layer, second hidden layer and output layer respectively ($R^2= 0.99$). Therefore, the results of this study show that the proposed system with the help of machine vision technology can predict the freshness and fat content of camel meat with acceptable accuracy.

Key words: Camel meat, Freshness, Fat content, Image processing, Classification, Artificial neural networks (ANNs).

* Corresponding Author: m.dowlati@basu.ac.ir