

تخمین تازگی گوشت مرغ مبتنی بر تکنیک‌های پردازش تصویر و هوش مصنوعی

سودابه فتاحی^۱، امین طاهری گراوند^{۲*}، فیض اله شهبازی^۳

۱. دانشجوی کارشناسی ارشد، گروه مهندسی مکانیک بیوسیستم، دانشگاه لرستان

۲. استادیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه لرستان

۳. دانشیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه لرستان

(تاریخ دریافت: ۱۳۹۶/۲/۱۹ - تاریخ بازنگری: ۱۳۹۶/۵/۱۸ - تاریخ تصویب: ۱۳۹۶/۵/۲۸)

چکیده

در پژوهش حاضر روش‌های نوین نظیر پردازش تصویر و هوش مصنوعی برای ارزیابی سریع، غیر مخرب و آنلاین تازگی گوشت مرغ بکار گرفته شده است. پس از تهیه تصاویر گوشت مرغ و عملیات پیش پردازش، تصاویر به کانال‌های رنگی مختلف منتقل و ویژگی‌های آماری بافت تصاویر استخراج گردید. عملیات انتخاب ویژگی با ترکیب دو روش الگوریتم ازدحام ذرات و طبقه‌بند شبکه‌های عصبی مصنوعی به منظور کاهش حجم محاسبات و ارتقای شاخص‌های طبقه‌بندی انجام شد. با توجه به تعداد ویژگی‌های منتخب، تعداد نرون‌های موجود در لایه ورودی ۲۲ عدد به دست آمد و تعداد نرون‌های موجود در لایه خروجی براساس طبقه‌بندی تصاویر به صورت ۵ کلاس؛ روز اول، روز دوم،... و روز پنجم، ۵ عدد تعیین شد. در نهایت ساختار ۲۲-۸-۵ به عنوان ساختار بهینه طبقه‌بند مورد نظر حاصل شد. به منظور ارزیابی عملکرد طبقه‌بند جهت تخمین تازگی گوشت مرغ، شاخص‌های آماری نظیر دقت، صحت، حساسیت، اختصاصی بودن و سطح زیر منحنی محاسبه شدند که مقادیر این شاخص‌ها برای طبقه‌بندی بر اساس ویژگی‌های منتخب به ترتیب برابر ۹۲، ۸۰/۰۲، ۸۰/۶۸، ۸۰/۸۹ و ۸۷/۸۳ درصد می‌باشند. نتایج حاصل از این مطالعه نشان می‌دهد که سامانه پیشنهادی توانایی تشخیص میزان تازگی گوشت مرغ با دقت مناسب را دارد.

واژه‌های کلیدی: گوشت مرغ، تشخیص تازگی، پردازش تصویر، شبکه‌های عصبی مصنوعی (ANNs)، الگوریتم ازدحام ذرات (PSO).

مقدمه

گوشت به عنوان یک ماده غذایی فسادپذیر، مغذی و گران در رژیم غذایی انسان در سراسر جهان حائز اهمیت است (Pu et al., 2015). گوشت سرشار از پروتئین‌ها، ویتامین‌ها، مواد معدنی و سایر موادمغذی می‌باشد که در حفظ سلامت انسان نقش بسزایی دارد. همچنین گوشت و فرآورده‌های گوشتی منبع اصلی تامین پروتئین حیوانی مورد نیاز بشر در زندگی روزانه، به شمار می‌روند (Xiong et al., 2017). میزان مصرف گوشت در کشورهای توسعه یافته بالاست و در کشورهای در حال توسعه نیز مصرف گوشت روند رو به رشدی دارد (Ma et al., 2016). با توجه به تنوع گوشت، بیشترین نوع گوشتی که در جهان مصرف می‌شود بعد از گوشت خوک مربوط به گوشت مرغ می‌باشد، که میزان مصرف سالانه آن حدوداً ۳۰ کیلوگرم برای هر نفر گزارش شده است (به میزان بیش از ۷۵ میلیون تن در سال). تقاضای بالا برای گوشت مرغ به دلیل ارزان تر و سالم تر بودن، سرعت رشد بالا، طعم ساده و منبع ارزان

پروتئین آن می‌باشد (Salinas, Y et al., 2012). همینطور از معایب گوشت مرغ می‌توان به فساد پذیری بالا و عمر مفید کوتاه آن (به مدت ۷۲ ساعت در دمای ۴°C یخچال) اشاره کرد (Vasconcelos et al. 2014). با بهبود الگوهای زندگی و توسعه اقتصادی، کیفیت و سلامت غذا برای مردم بسیار با اهمیت شمرده می‌شود. مهمترین فاکتور کیفی برای فرآورده‌های گوشت مرغ، مربوط به تازگی است، که تولیدکنندگان و مصرف‌کنندگان توجه ویژه‌ای به آن دارند و این فاکتور به طور مستقیم با فروش و مصرف محصول ارتباط دارد (Xiong et al., 2015). روش‌های سنتی که برای تخمین تازگی گوشت مرغ به کار رفته است عبارتند از اندازه‌گیری‌های فیزیکی، شیمیایی، میکروبیولوژیکی و ارزیابی حسی. از معایب ارزیابی حسی می‌توان به هزینه بالای آن اشاره کرد. سایر روش‌ها مانند اندازه‌گیری‌های میکروبیولوژیکی و روش‌های شیمیایی، بسیار وقت گیر، پرهزینه و مخرب هستند. بنابراین بکارگیری روش‌هایی که عیوب مطرح شده در روش‌های فوق را نداشته باشد برای ارزیابی تازگی گوشت مرغ، بسیار ضروری است (Chen et al., 2014). اخیراً روش‌های سریع و

می‌باشند بهم گره خورده اند تشکیل یافته است (Karray & Silva, 2004). بنابراین، با توجه به قابلیت‌ها و مزایای استفاده از این روش‌ها در ارزیابی خواص کیفی انواع مختلف گوشت، در این تحقیق از ترکیب فناوری‌های پردازش تصویر و هوش مصنوعی برای ارزیابی تازگی گوشت مرغ استفاده شده است.

مواد و روش‌ها

آماده سازی نمونه‌ها

پس از تهیه تعداد ۳۰ عدد لاشه مرغ کشتار روز از یک کشتارگاه محلی، ران مرغ از لاشه‌ها جدا شده و در مدت زمان کمتر از ۲۰ دقیقه، درون فیبرهای حاوی یخ، به آزمایشگاه مکانیک بیوسیستم دانشگاه لرستان انتقال یافت. ران‌ها پس از شستشو، به مدت ۲۰ دقیقه در معرض هوا قرار گرفتند. هر تکه ران داخل زیپ پک‌های جداگانه قرار گرفت و (هر دو سمت آن با پوست و بدون پوست) نام گذاری شد. در نهایت تمامی زیپ پک‌ها در داخل یخچال و در دمای ۴°C به مدت ۵ روز نگهداری شدند.

ساخت بستر تصویربرداری

بستر تصویربرداری ساخته شده شامل سه بخش اصلی: منبع روشنایی، دوربین، کامپیوتر و نرم افزار برای پردازش تصاویر می‌باشد. برای ساخت بدنه از ورقه‌های چوبی سفید رنگ استفاده شد (Ghiasi et al., 2014). منبع روشنایی متشکل از ۴ عدد لامپ هالوژن (هر لامپ ۳ وات، با دمای رنگ ۶۵۰۰ درجه کلون)، در چهار نقطه سقف با قابلیت چرخش ۱۸۰ درجه نصب شدند. در ضمن به منظور ایجاد نوردهی غیرمستقیم (Ghiasi et al., 2014) یک عدد ورق آکرلیک بصورت قوس رو به پایین در زیر لامپ‌ها قرار گرفت. فاصله بین سطح نمونه و منبع روشنایی حدوداً ۵۰ سانتیمتر در نظر گرفته شد. در بالای جعبه پایه‌ای برای نصب دوربین قرار گرفت. همچنین سوراخی به اندازه لنز دوربین در بالای جعبه و در ورق آکرلیک ایجاد شد به طوری که لنز دوربین کاملاً عمود به سطح نمونه و در فاصله ۴۰ سانتیمتری از آن قرار گرفت. ضمناً برای قرار دادن نمونه، ورقه‌ی چوبی با قابلیت جابجایی در راستای عمودی، درون جعبه تعبیه شد. درب جعبه از جنس فیبر و برای درزبندی بهتر، برای جلوگیری از ورود نور به داخل آن، بصورت عمودی باز و بسته می‌شود. در شکل ۱ بستر تصویربرداری مورد نظر نشان داده شده است.

غیرمخرب مانند: بینایی کامپیوتر (Dowlati et al., 2012)، روش‌های طیف سنجی (مرئی/ فرو سرخ نزدیک/ مادون قرمز میانی/ طیف‌سنجی بیرونی) (Cozzolino & Murray, 2012; Grau et al., 2011; Nilsen et al., 2002; Liu et al., 2011) تصویربرداری بویایی (Salinas et al., 2014)، بینی الکترونیک (Zhang et al., 2014) و زبان الکترونیک (Huang et al., 2014) به کار رفته است.

با توجه به بررسی‌های انجام گرفته در منابع قابل دسترس، از روش‌های پردازش تصویر، ماشین بینایی و شبکه عصبی مصنوعی به عنوان روش‌های جدید در تعیین برخی خواص کیفی انواع مختلف گوشت استفاده شده است که در ادامه به تعدادی از این مطالعات اشاره می‌شود: با استفاده از روش ماشین بینایی و ماشین بردار پشتیبان بافت چربی گوشت درجه‌بندی شده است (Chen et al., 2010). همچنین محتوی چربی گوشت طیور با روش پردازش تصویر تخمین زده شده است (Chmiel et al., 2011). در پژوهشی تازگی گوشت خوک بر مبنای ماشین بینایی مورد بررسی قرار گرفته است (Xiao et al., 2014). روش بینایی مصنوعی نیز برای ارزیابی کیفیت گوشت خوک بکار رفته است (El Barbri et al., 2014). شاخص تازگی گوشت خوک (TVB-N) را با روش‌های طیف سنجی مادون قرمز نزدیک، بینایی کامپیوتر و بینی الکترونیک بررسی شده است (Huang et al., 2014). همین‌طور ارزیابی رنگ گوشت توسط سیستم بینایی کامپیوتر انجام گرفته است (Girolami et al., 2013).

سیستم بینایی کامپیوتر از یک دوربین دیجیتال که مشابه چشم انسان عمل می‌کند و یک الگوریتم یادگیری که کار مغز انسان را انجام می‌دهد، تشکیل شده است. دوربین اطلاعات تصویر را با حداقل اغتشاش ثبت کرده و الگوریتم یادگیری، این اطلاعات را به سطح کیفیت مطلوب می‌رساند (Jackman et al., 2011). این علم عیوب روش‌های ارزیابی سنتی را برطرف نموده و بعنوان یک روش سریع، آسان، غیرمخرب و حساس برای ارزیابی کیفیت گوشت و فرآورده‌های گوشتی به کار می‌رود (Ma et al., 2016). شبکه‌های عصبی مصنوعی نیز از جمله مدل‌های یادگیری ماشینی هستند که رفتاری شبیه مغز انسان دارند. این شبکه‌ها از تعداد زیادی عناصر پردازش به هم پیوسته که همانند نرون‌های بیولوژیکی کار می‌کنند و با اتصالات وزن که به سیناپس مغز مربوط

در این تحقیق، پیش‌پردازش تصاویر شامل بخش‌بندی تصاویر، تغییر شکل و اندازه تصاویر و فیلتر کردن آن‌ها جهت حذف اغتشاش‌های احتمالی، انجام گرفت. اهداف کلی این عملیات را می‌توان ارتقاء تصویر و حذف داده‌های غیر ضروری از تصویر دانست. با انجام عملیات پیش‌پردازش مناسب تصویر، دقت تشخیص و کارایی طبقه‌بندی افزایش می‌یابد (Shi & He, 2010). در بخش‌بندی تصاویر، با کد نویسی انجام شده، تصویر ران مرغ به صورت خودکار از پس زمینه برش داده شده و به عنوان تصویر ورودی برای سایر مراحل پردازش بکار رفت. عملیات برش خودکار به این ترتیب انجام گرفت که با انتخاب مقدار حد آستانه ایده‌آل (0/5) از کانال‌های R, G, B تصاویر باینری ایجاد شد. سپس با استفاده از عملگرهای باز و بسته نوشته شده در نرم افزار متلب حفره‌های ناخواسته ایجاد شده پر شده و تصویر کلی گوشت مرغ به دست آمد. در نهایت با ضرب تصاویر باینری در کانال‌های R, G, B و ترکیب آن‌ها، پس زمینه تصویر اصلی حذف و تصویر نهایی حاصل شد. به منظور استخراج ویژگی‌های مختلف از تصاویر، نخست باید آن‌ها را به فضاهای رنگی مختلف منتقل و پس از محاسبه کانال‌های مربوطه، ویژگی‌های مورد نظر را استخراج نمود، که در ادامه نحوه به دست آوردن این کانال‌ها و استخراج ویژگی‌ها شرح داده می‌شود:


محاسبه کانال‌های R, G و B:

کانال‌های R, G, B به ترتیب نشان دهنده کانال‌های قرمز و سبز و آبی بوده و به طور مستقیم از تصاویر RGB استخراج شدند.

محاسبه کانال‌های H, S و I:

در فضای رنگ HSI، مولفه رنگ (Hue) توصیف کننده رنگ خالص، اما مولفه اشباع (Saturation) میزان رقیق شدن رنگ خالص توسط نور سفید را نشان می‌دهد. مزایای اصلی این مدل رنگ این است که مولفه شدت (Intensity)، مجزا از اطلاعات رنگ در تصویر می‌باشد. ضمناً مولفه‌های رنگ و اشباع بیانگر همان روشی هستند که انسان رنگ را درک می‌کند (El Barbri et al., 2014). با توجه به اینکه سازگاری فضای رنگ HSI با سیستم بینایی انسان بسیار بیشتر از فضای رنگ RGB می‌باشد، فضای رنگ مذکور با استفاده از الگوریتم‌ها در پردازش تصویر و ماشین بینایی به کار می‌رود (Zhou et al., 2015). با استفاده از معادلات زیر می‌توان کانال‌های H, S, I را محاسبه نمود (Chaudhary et al., 2012).

$$H = \begin{cases} \theta & \text{if } B \leq G \\ 360 - \theta & \text{if } B > G \end{cases} \quad (\text{رابطه ۱})$$




شکل ۱ بستر تصویربرداری

تهیه و ذخیره تصاویر به صورت دیجیتالی

در بررسی حاضر، تصویربرداری از نمونه‌ها ۶ ساعت پس از کشتار آغاز و برای بررسی بیشتر، به مدت ۵ روز و هر ۶ ساعت یکبار ادامه یافت. پس از بیرون آوردن نمونه‌ها از داخل یخچال، رطوبت سطح آنها با استفاده از دستمال گرفته شد. سپس (از هر دو طرف نمونه با پوست/ بدون پوست به صورت جداگانه)، با استفاده از دوربین (CANON, SX-260, Made in Japan, 12.1MP, zoom and flash off) عکسبرداری شد و تصاویر در اندازه ۴۰۰۰ * ۳۰۰۰ پیکسل، با فرمت JPEG ذخیره شدند.

پیش‌پردازش و استخراج ویژگی از تصاویر

تصاویر گرفته شده برای شرایط زمانی مختلف مورد پردازش قرار گرفتند. برای این کار، از کد نویسی در محیط نرم‌افزار متلب ۲۰۱۵ استفاده شد. مراحل پردازش تصاویر، پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی، طبقه‌بندی و نهایتاً تشخیص تازگی گوشت مرغ به صورت اجمالی در شکل (۲) نشان داده شده است.



شکل ۲ مراحل مختلف نرم‌افزاری سامانه تشخیص هوشمند تازگی گوشت مرغ

$$h(x) = \begin{cases} x^{\frac{1}{3}} & , x > \left(\frac{6}{29}\right)^3 \\ \frac{1}{3\left(\frac{29}{6}\right)^2}x + \frac{4}{29} & , x \leq \left(\frac{6}{29}\right)^3 \end{cases} \quad \text{(رابطه ۱۱)}$$

جایی که X_R, Y_R, Z_R مقادیر tristimulus مرجع روشنایی D65 را نشان می‌دهد، که ضرایب سه رنگی سفید $X_R = 0.3127, Y_R = 0.3290$ و یک مقدار روشنایی $Y_R = 100$ را دارد. مقادیر X_R و Z_R با استفاده از رابطه (۱۲) به دست می‌آیند (M. Goñi & O. Salvadori, 2016).

$$\begin{cases} X_R = \frac{x_R}{y_R} Y_R \\ Z_R = \frac{z_R}{y_R} Y_R \end{cases} \quad \text{(رابطه ۱۲)}$$

یافتن یک تبدیل سیگنال یا تصویر ساده و موثر برای تشخیص خطا و نظارت بر شرایط، هدف اصلی استخراج ویژگی می‌باشد. غالباً برای استخراج ویژگی از روش مبتنی بر خصوصیات استاتیکی هیستوگرام تصویر استفاده می‌شود (Gonzalez & Woods, 2004) ویژگی‌های هیستوگرام بنیادی‌ترین روش استخراج ویژگی بافت بوده و نمایش دهنده اطلاعاتی مرتبط با مشخصات توزیع سطح خاکستری برای تصویر می‌باشد. هیستوگرام نرمال روی تصاویر مقیاس خاکستری با استفاده از رابطه زیر بدست می‌آید:

$$P(z_i) = H(z_i)/N \quad \text{(رابطه ۱۳)}$$

که در آن z متغیر تصادفی نشان‌دهنده شدت، $H(z_i)$ هیستوگرام متناظر تصویر، N تعداد کل درایه‌های موجود در ماتریس تصویر مقیاس خاکستری و $P(z_i)$ هیستوگرام نرمال شده تصویر مقیاس خاکستری می‌باشد (Taheri-Garavand *et al.*, 2015). با توجه به ماهیت مستطیلی تصاویر دیجیتال (ماتریس پیکسل‌ها) و شکل نامنظم تصویر ران مرغ لذا به ناچار مقادیری از پیکسل‌های پس زمینه در تصویر با شدت صفر وجود دارد، برای عدم حضور این پیکسل‌های ناخواسته (که به خواص گوشت مرغ وابسته نمی‌باشند) در محاسبات استخراج ویژگی این پیکسل‌ها با شدت صفر از هیستوگرام تصاویر مربوطه حذف گردیدند.

در این تحقیق، ۶*۹ ویژگی برای هر تصویر (۶ ویژگی * ۹ کانال رنگ) بدست آمد. به این ترتیب که، کانال قرمز، سبز، آبی از فضای رنگ RGB، رنگ، اشباع، شدت از فضای رنگ HIS و روشنایی، a و b از فضای رنگ $L^*a^*b^*$ محاسبه شدند. سپس از هر کدام از کانال‌های رنگ، ۶ ویژگی آماری شامل

$$\theta = \cos^{-1} \left\{ \frac{1}{2} [(R-G) + (R-B)] / \sqrt{[(R-G)^2 + (R-B)(G-B)]} \right\} \quad \text{(رابطه ۲)}$$

$$saturation(S) = 1 - \frac{3 * \min(R, G, B)}{(R + G + B)} \quad \text{(رابطه ۳)}$$

$$Intensity(I) = 1/3 (R + G + B) \quad \text{(رابطه ۴)}$$

محاسبه کانال‌های L^*, a^*, b^* :

مسیون بین‌المللی d'Eclairage (CIE) در سال ۱۹۷۶ فضای رنگ $L^*a^*b^*$ یا CIE LAB را که غالباً برای اندازه‌گیری رنگ به کار می‌رود به عنوان یک استاندارد بین‌المللی معرفی نمود (Leo'n *et al.*, 2006). در این فضای رنگ L^*, a^*, b^* به ترتیب معرف روشنایی، دامنه رنگ از سبز به قرمز و دامنه رنگ از آبی به زرد می‌باشد (Chaudhary *et al.*, 2012). مدل تبدیل مستقیم از ساده‌ترین مدل‌های تبدیل، بدون نیاز به کالیبراسیون می‌باشد که بیشتر در سیستم‌های ایده‌آل کاربرد دارد (Gonzalez & Woods, 2002) و مراحل آن به این ترتیب است: تصویر رنگی n بیتی توسط لایه رنگ به فاصله [0.1] و طبق معادله ۵ مقیاس گذاری می‌کنیم. به طوری که RGB_0 و RGB_S به ترتیب شامل مولفه‌های قرمز، سبز و آبی هر پیکسل از تصویر اصلی و تصویر مقیاس گذاری شده می‌باشند. در این بررسی از ۸ بیت استفاده شده است.

$$RGB_S = RGB_0 / 2^n \quad \text{(رابطه ۵)}$$

تصویر مقیاس بندی شده با استفاده از تابع g به مقادیر XYZ tristimulus تبدیل می‌شود.

$$XYZ = \begin{pmatrix} 0.4124 & 0.3575 & 0.1804 \\ 0.2126 & 0.7151 & 0.0721 \\ 0.0193 & 0.1191 & 0.9504 \end{pmatrix} g(RGB_S) \quad \text{(رابطه ۶)}$$

$$g(x) = 100 \begin{cases} \left(\frac{x + 0.055}{1.055}\right)^{2.4}, & x > 0.04045 \\ \frac{x}{12.92}, & x \leq 0.04045 \end{cases} \quad \text{(رابطه ۷)}$$

مقادیر XYZ tristimulus با استفاده از تابع h بر طبق روابط (۱۱-۸) به مقادیر $L^*a^*b^*$ تبدیل می‌شود.

$$L^* = 116h(Y/Y_R) - 16 \quad \text{(رابطه ۸)}$$

$$a^* = 500[h(X/X_R) - h(Y/Y_R)] \quad \text{(رابطه ۹)}$$

$$b^* = 200[h(Y/Y_R) - h(Z/Z_R)] \quad \text{(رابطه ۱۰)}$$

مکان ذرات در فضای مسئله به جستجو می‌پردازند. در صورتی که فضای جستجو D بعد داشته باشد، موقعیت مکانی و سرعت ذره i ام به ترتیب با بردار D بعدی به صورت $X_i=(x_{i1}, x_{i2}, \dots, x_{iD})^T$ و $V_i=(v_{i1}, v_{i2}, \dots, v_{iD})^T$ نشان داده می‌شود. بردار $Pbest_i=(p_{i1}, p_{i2}, \dots, p_{iD})^T$ بهترین موقعیت‌های مکانی قبلی ذره i ام و بردار $Gbest_i=(g_{i1}, g_{i2}, \dots, g_{iD})^T$ بهترین موقعیتی که ذره i ام در بین تمامی ذرات بدست آورده است. پارامتر g بیانگر بهترین ذره در بین جمعیت می‌باشد. موقعیت سرعت و مکان هر ذره بعد از یافتن دو مقدار بهترین (P_i و G_i) به کمک روابط زیر محاسبه می‌شود (Goldberg, 1989):

$$V_{i,d}^{t+1} = wV_{i,d}^t + c_1 \text{Rand}(0,1)(Pbest_{i,d} - X_{i,d}^t) + c_2 \text{rand}(0,1)(Gbest_{i,d} - X_{i,d}^t) \quad (\text{رابطه } ۲۰)$$

$$X_{i,d}^{t+1} = X_{i,d}^t + V_{i,d}^{t+1} \quad (\text{رابطه } ۲۱)$$

$i=1,2,\dots,N \quad d=1,2,\dots$

که در آن: V_i^{t+1} سرعت ذره i در تکرار جدید، V_i^t سرعت ذره i در تکرار فعلی، X_i^t موقعیت کنونی ذره i ، X_i^{t+1} موقعیت ذره i تا کنون اختیار کرده است و $Gbest_i$ بهترین موقعیت ذره (بهترین موقعیتی که تمام ذرات تا کنون اختیار کرده اند) است. همچنین w اینرسی وزنی و پارامتری برای تضمین همگرایی در دسته ذرات بوده و مقدار مناسب آن بین 0.4 و 0.7 است. C_1 و C_2 پارامترهای شناختی و اجتماعی هستند که با انتخاب مقدار مناسب برای این پارامترها همگرایی الگوریتم سریعتر و از همگرایی زودرس در بهینه‌های محلی جلوگیری می‌شود. انتخاب مقادیر بزرگتری برای پارامتر شناختی C_1 نسبت به پارامتر اجتماعی C_2 مناسب تر است در صورتیکه شرط $c_1 + c_2 \leq 4$ برقرار باشد (Goldberg, 1989) و rand و Rand اعداد تصادفی در بازه $[0, 1]$ و N بیان کننده تعداد ذرات است. برای پایان الگوریتم باید شروط زیر برقرار باشد: الگوریتم همگرا شود و یا بعد از تعداد معینی تکرار الگوریتم متوقف شود. مقدار نهایی سرعت هر ذره برای جلوگیری از واگرایی الگوریتم با یک بازه محدود مشخص می‌شود $v_{id} \in [-v_{max}, v_{max}]$ (Nezamabadi-pour et al., 2008). با توجه به ماهیت گسسته فرایند انتخاب بردار ویژگی، در این پژوهش از الگوریتم بهینه سازی ازدحام ذرات باینری برای انتخاب بهترین زیر مجموعه ویژگی از بین مجموعه ویژگی‌های استخراج شده از تصاویر استفاده شده است. الگوریتم بهینه سازی ازدحام ذرات باینری، با باز-تعریف مفهوم سرعت، از الگوریتم فضای پیوسته منشعب

میانگین، انحراف معیار، همواری، چولگی، انرژی و آنروپی استخراج گردید که با استفاده از معادلات (۱۴-۱۹) بدست می‌آیند و ۵۴ متغیر ویژگی حاضر می‌تواند تغییرات گوشت مرغ را در طول بررسی نشان دهد.

$$m = \sum_{i=0}^{L-1} p(z_i) \quad (\text{رابطه } ۱۴)$$

$$\mu_3 = \sum_{i=0}^{L-1} (z_i - m)^3 p(z_i) \quad (\text{رابطه } ۱۵)$$

$$\delta = \sqrt{\sum_{i=0}^{L-1} (z_i - m)^2 p(z_i)} \quad (\text{رابطه } ۱۶)$$

$$R = 1 - 1/(1 + \delta^2) \quad (\text{رابطه } ۱۷)$$

$$U = \sum_{i=0}^{L-1} p^2(z_i) \quad (\text{رابطه } ۱۸)$$

$$e = - \sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i) \quad (\text{رابطه } ۱۹)$$

z_i یک متغیر تصادفی نشان‌دهنده شدت، $P(z_i)$ هیستوگرام سطوح شدت در یک ناحیه، L تعداد سطوح شدت ممکن. m سطح میانگین شدت تصویر مورد بررسی، μ_3 اندازه چولگی هیستوگرام، δ مقدار کنتراست متوسط، R اندازه همواری نسبی شدت در یک ناحیه، U اندازه یکنواختی و e اندازه تصادفی بودن را نشان می‌دهند (Khulal et al., 2016).

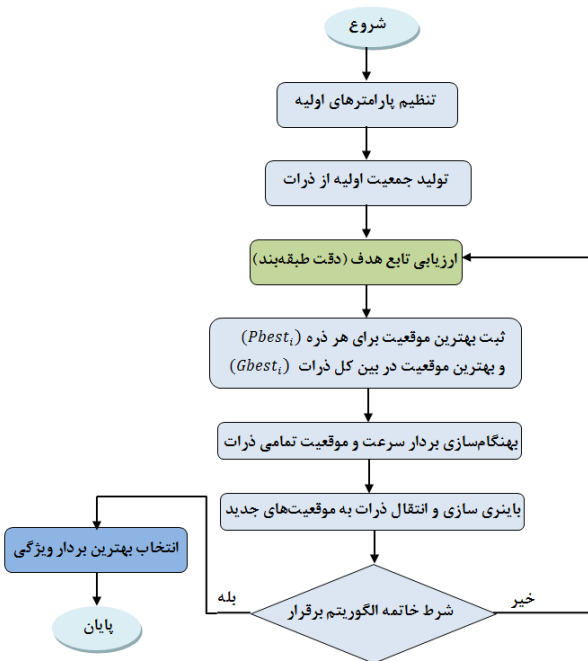
انتخاب ویژگی

برخی از ویژگی‌های موجود در یک مجموعه داده آموزنده نیستند و برخی قدرت تشخیص بالایی ندارند. هدف اصلی از انتخاب ویژگی، حذف ویژگی‌های زائد و نامربوط از مجموعه داده می‌باشد که عملکرد الگوریتم طبقه بندی را بهبود می‌بخشد. (Tsai et al., 2013). پس از استخراج ویژگی‌های مورد نظر از تصاویر گوشت مرغ، اندازه ماتریس داده‌های ورودی برابر با ۵۴×۹۰۰ (تصویر، ۵۴ ویژگی) بدست آمد. در این بررسی، برای انتخاب ویژگی، از روش محاسباتی هوشمند ازدحام بر مبنای الگوریتم PSO استفاده شد، از مزایای این روش در مقایسه با سایر روش‌ها می‌توان به تعداد عامل‌های کمتر، سرعت همگرایی بیشتر، حجم محاسبات کمتر ودقت بالای آن اشاره نمود (Banka & Dara, 2014). فعالیت الگوریتم بهینه سازی ازدحام ذرات با یک گروه تصادفی از جواب‌ها (ذرات) آغاز می‌شود و برای یافتن پاسخ بهینه با به روز کردن

شکل ۳ مراحل اجرای الگوریتم ازدحام ذرات در این تحقیق را نشان می‌دهد. یکی از مراحل الگوریتم ازدحام ذرات ارزیابی جواب‌های حاصل در هر مرحله می‌باشد. تابع هدف شاخصی از نحوه عملکرد جواب‌های حاصل در فضای مساله است. در نتیجه انتخاب تابع برازندگی مناسب، یکی از مهمترین مراحل در پیاده سازی این الگوریتم می‌باشد، هر چه که یک جواب مناسب‌تر باشد مقدار تابع هزینه کمتر خواهد بود. با توجه به هدف این تحقیق که طبقه‌بندی گوشت مرغ براساس تازگی می‌باشد لذا تابع برازندگی در این پژوهش خروجی طبقه‌بندی می‌باشد. رابطه (۲۵) تابع هزینه الگوریتم بهینه ساز می‌باشد.

$$CF = 1 - CR \quad (\text{رابطه ۲۵})$$

که در آن CF تابع هزینه (برازندگی) و CR دقت طبقه‌بندی (شبکه عصبی) می‌باشد. در بخش طبقه‌بندی تصاویر، دقت طبقه‌بندی توضیح داده خواهد شد (Taheri-Garavand et al., 2017)



شکل ۳ مراحل اجرای فرآیند انتخاب ویژگی در الگوریتم ازدحام ذرات

طبقه‌بندی تصاویر بر اساس تازگی

با توجه به قابلیت بالای شبکه‌های عصبی در استنتاج نتایج از داده‌های پیچیده، این شبکه‌ها همچنین می‌توانند در استخراج الگوها و شناسایی گرایش‌های مختلفی که شناسایی آنها برای انسان‌ها و کامپیوتر بسیار دشوار است، بکار روند. قابلیت یادگیری، قابلیت تعمیم و پردازش موازی از دیگر ویژگی‌های

می‌شود. در این الگوریتم موقعیت هر ذره در هر بعد با مقدار صفر و یک مشخص می‌شود. در فضای جستجو، ذرات از یک راس به راس دیگر یک ابر مکعب حرکت می‌کنند. همچنین با تغییر مفهوم سرعت به مفهوم احتمال و v_{id} به معنای احتمال یک بودن x_{id} می‌باشد. در واقع مقدار v_{id} به یک مقدار بین $[0, 1]$ نگاشت شده که این مقدار احتمال یک بودن x_{id} را بیان می‌کند. برای یابری سازی الگوریتم، ابتدا سرعت ذره در هر بعد را با استفاده از رابطه (۲۰) به دست آورده، سپس با استفاده از تابع محدود کننده سیگموئید رابطه (۲۲) آن را به مقداری بین صفر و یک نگاشت و در نهایت با رابطه (۲۳) موقعیت ذره i ام در بعد d ام به دست می‌آید (Kennedy & Eberhart., 1997).

$$\begin{aligned} (v_{id}) &= Sigmoid(v_{id}) \quad (\text{رابطه ۲۲}) \\ &= 1 / (1 + e^{(-v_{id})}) \end{aligned}$$

$$f \text{ rand} < S(v_{id}(t+1)) \text{ then } x_{id}(t+1) = 1 \quad (\text{رابطه ۲۳})$$

$$x_{id}(t+1) = 0 \quad \text{Else}$$

از آنجایی که مقدار v_{id} در الگوریتم پیوسته در یک بازه متقارن قرار دارد، در الگوریتم یابری نیز v_{id} محدود به مقدار بی‌شیمی نه v_{max} است، که معمولا برابر با ۶ در نظر گرفته می‌شود. با انتخاب این مقدار، خروجی تابع احتمال محدود به بازه $[0.0025, 0.9975]$ شده اما این محدودیت همگرایی الگوریتم را بهبود می‌بخشد. در صورت وجود تعداد زیادی ذرات با توزیع یکسان در فضای جستجو، تنوع میان ذرات بیشتر شده و راندمان الگوریتم افزایش می‌یابد. اما وجود تعداد زیاد ذرات موجب پیچیدگی الگوریتم می‌شود. در بررسی حاضر اندازه گروه ذره ۳۰ در نظر گرفته شده است.

ضرایب C_1 و C_2 ، مولفه‌های اجتماعی و شناختی سرعت ذره، در راندمان ذره بسیار موثرند. در این تحقیق این ضرایب برابر با ۱/۵ در نظر گرفته شد. وزن اینرسی، ضریب سرعت قبلی ذره، میزان تاثیر سرعت قبلی در محاسبه سرعت فعلی ذره را نشان می‌دهد. در بررسی حاضر روش کاهش خطی وزن اینرسی برای تنظیم این پارامتر بکار رفت. در شروع الگوریتم وزن اینرسی برابر ۰/۹۹ تعیین شد و پس از گذشت زمان مقدار آن با استفاده از رابطه (۲۴) کاهش یافت (Taheri-Garavand, 2015).

$$w(t) = (w(0) - w(n_t)) ((n_t - t)) / n_t + w(n_t) \quad (\text{رابطه ۲۴})$$

نداشتند) کمتر باشد، قدرت تعمیم شبکه بالاست. اگرچه امکان کاهش مداوم خطا در طول آموزش وجود دارد اما پایان آموزش با کاهش خطای مجموعه اعتبارسنجی به یک حداقل و سپس افزایش آن انجام می‌گیرد و وزن‌ها و بایاس‌ها به حداقل خطای اعتبارسنجی باز می‌گردند. در نهایت ارزیابی شبکه با استفاده از داده‌های گروه آزمون انجام می‌گیرد (Kheiralipour., 2012). تصاویر گوشت مرغ نگهداری شده در دمای یخچال به مدت ۵ روز به صورت ۵ کلاس؛ روز اول، روز دوم، ... روز پنجم طبقه بندی شد. با استفاده از این طبقه بندی و تشخیص وضعیت مختلف تازگی گوشت مرغ، می‌توان عملکرد سامانه تشخیص تازگی را به کمک مدل‌های طبقه‌بند مورد ارزیابی قرار داد. ارزیابی طبقه‌بند توسط شاخص‌های آماری که از ماتریس اغتشاش استخراج شده انجام شد. ماتریس اغتشاش شامل اطلاعات (کلاس‌های) مطلوب یا واقعی و اطلاعات تخمین زده توسط طبقه‌بند می‌باشد. جدول (۱) ماتریس اغتشاش برای یک طبقه‌بند پنج کلاسه را نشان می‌دهد، که ستون‌ها نشان دهنده کلاس‌های مطلوب و ردیف‌ها کلاس‌های تخمین زده داده‌ها توسط طبقه‌بند می‌باشند.

جدول ۱ ماتریس اغتشاش برای طبقه‌بندی ۵ کلاسه

	C_1	...	C_5
C_1^*	n_{11}	...	n_{15}
⋮	⋮	⋮	⋮
C_5^*	n_{51}	...	n_{55}


ماتریس اغتشاش به عنوان روشی کارآمد در ارزیابی چگونگی عملکرد طبقه‌بندی در تشخیص داده‌ها یا مشاهدات کلاس‌های مختلف بکار می‌رود. اگر داده‌ها در M کلاس قرار گرفته باشند، ماتریس طبقه‌بندی جدولی با حداقل اندازه $M \times M$ است. حالت ایده‌آل این است که اکثر داده‌های مربوط به مشاهدات روی قطر اصلی ماتریس قرار گیرند و بقیه مقادیر ماتریس صفر یا نزدیک به صفر باشند (Ameri et al., 2013). عضو n_{ij} مشخص کننده تصاویری است که توسط طبقه‌بند (C_i^*) در کلاس i طبقه‌بندی شده‌اند اما در طبقه‌بندی واقعی (C_j) متعلق به کلاس j می‌باشند. در نتیجه اعضای قطری اصلی ماتریس $(i=j)$ نشان دهنده تصاویری هستند که درست طبقه‌بندی شده‌اند، اما اعضای خارج از قطر اصلی $(i \neq j)$ نمونه‌هایی هستند که درست توسط طبقه‌بند، طبقه‌بندی نشده‌اند. هر یک از ارزیابی‌های طبقه‌بند شامل ۴ حالت مختلف زیر است: تصمیمات مثبت صحیح (TP)، نمونه‌هایی که درست

شبکه‌های عصبی مصنوعی می‌باشد (Nasrollahzade et al., 2016). در این پژوهش از شبکه عصبی مصنوعی برای تشخیص و طبقه بندی تازگی گوشت مرغ استفاده شد، بنابراین این شبکه که شامل انتخاب نوع مدل، تعداد لایه‌های شبکه، تعداد نرون‌ها در هر لایه، نوع تابع انتقال در هر لایه و مدل آموزش می‌باشد، در نرم افزار متلب ۲۰۱۵ طراحی شد. در طراحی شبکه برای یک سری داده خاص روش مشخصی موجود نیست. در بررسی حاضر فقط تعداد ورودی‌ها (بردار ویژگی‌های منتخب) و تعداد نرون‌های لایه خروجی (۵ کلاس) مربوط به روزهای مختلف نگهداری گوشت مرغ مشخص می‌باشند. برای تشخیص میزان تازگی گوشت مرغ در طی روزهای مختلف نگهداری، شبکه‌های طبقه بند مختلفی طراحی شد تا مناسب‌ترین و کاراترین شبکه بدست آمد. در ابتدا شبکه‌های عصبی آموزش داده شدند، سپس شبکه اعتبارسنجی شده و در نهایت مورد ارزیابی قرار گرفت. در این بررسی ۶۰ درصد داده‌های حاصل برای آموزش شبکه، ۲۰ درصد برای اعتبار سنجی و ۲۰ درصد برای آزمون و ارزیابی شبکه استفاده گردید. در ضمن شبکه عصبی پرسپترون چندلایه (MLP) در این تحقیق استفاده شد و به منظور بهنگام سازی وزن‌های شبکه عصبی الگوریتم لوبز-مارکوات بکار رفت، این الگوریتم آموزش شبکه را سریع‌تر و سطح خطا را حداقل می‌نماید (Hosseinzadeh Samani, & Hourijafari, 2015) و نیز داده‌های ورودی کمتری برای آموزش نیاز دارد (Taheri Garavand, 2015). برای به حداقل رساندن خطا از تنظیم وزن‌های شبکه استفاده می‌شود و میزان محاسبات لازم برای به حداقل رساندن خطا به الگوریتم به شیوه آموزش شبکه بستگی دارد. اغلب از الگوریتم پس انتشار استفاده می‌شود در این الگوریتم پس از محاسبه میزان خطا در لایه خروجی، مقادیر وزن‌ها در لایه پنهان به منظور کاهش خطا تنظیم می‌شود (Singh et al., 2007). در شبکه‌های عصبی چند لایه پرسپترون (MLP) با کاربرد پیش بینی از تابع غیر خطی سیگموئید در لایه‌های پنهان لایه خروجی استفاده می‌شود (Khazaei et al., 2016). پس از آموزش، شبکه طراحی شده باید قابل تعمیم به کل مجموعه ورودی- خروجی‌ها (حتی اگر تحت آموزش قرار نگرفته اند) باشد. به منظور آزمایش قابلیت تعمیم شبکه، داده‌ها (جفت‌های ورودی-خروجی) به سه گروه تفکیک می‌شود. بعد از اینکه شبکه آموزش داده شد، برای ارزیابی قدرت تعمیم شبکه، داده‌های مجموعه اعتبارسنجی به شبکه داده می‌شود. هر چه اختلاف بین خروجی واقعی و مطلوب در مجموعه اعتبارسنجی (که در آموزش شبکه شرکت

در طی ۵ روز عکسبرداری شد. سپس عملیات پیش پردازش، تغییر فضاهای رنگ و استخراج ویژگی‌های آماری بافت با استفاده از کانال‌های مختلف فضاهای رنگی انجام گرفت.

انتخاب ویژگی

اندازه ماتریس ویژگی‌های استخراج شده از تصاویر گوشت مرغ در طول دوره نگهداری برای طبقه‌بندی ۵۴×۹۰۰ (۹۰۰ تصویر، ۵۴ ویژگی) بدست آمد. برای کاهش تعداد ویژگی‌ها و انجام محاسبات کمتر، افزایش دقت یادگیری طبقه‌بندی، از ترکیب روش بهینه سازی الگوریتم ازدحام ذرات و شبکه‌های عصبی مصنوعی برای انتخاب زیر مجموعه بهینه از ویژگی‌ها استفاده شد. ویژگی‌های منتخب در جدول (۲) آمده است. در میان این ویژگی‌های آماری استخراج شده از تصاویر، ویژگی میانگین بیشترین تعداد و ویژگی‌های همواری و چولگی کمترین تعداد را در بین ویژگی‌های منتخب داشتند. منحنی عملکرد همگرایی الگوریتم ازدحام ذرات برای مقادیر تابع هزینه (برازندگی) رابطه (۲۵) با طبقه‌بندی شبکه عصبی‌های مصنوعی در شکل (۴) نشان داده شده است.



شکل ۴ منحنی عملکرد همگرایی الگوریتم ازدحام ذرات برای مقادیر تابع هزینه (دقت طبقه‌بندی تازگی گوشت مرغ با شبکه‌های عصبی مصنوعی)

طبقه‌بندی تصاویر

پس از استخراج ویژگی‌های مورد نظر از تصاویر گوشت مرغ، بهترین زیر مجموعه از میان ویژگی‌های آماری استخراج شده انتخاب شد، در نهایت برای طبقه‌بندی تصاویر به منظور ارزیابی تازگی گوشت مرغ در طول دوره نگهداری که شامل ۵ کلاس؛ روز اول، روز دوم،... و روز پنجم می باشد، استفاده شد. پس از ۵۰ بار اجرای طبقه‌بندی با استفاده از بردار تمامی ویژگی‌های استخراج شده از تصاویر به عنوان ورودی آن، بهترین عملکرد طبقه‌بندی بدست آمد و ماتریس اغتشاش نشان داده شده در جدول (۲) با توجه به آن تشکیل شد.

پس از تشکیل ماتریس اغتشاش، جدول (۳) با توجه به

توسط طبقه‌بندی (C_i^*) در کلاس نام طبقه‌بندی شده‌اند. تصمیمات مثبت ناصحیح (FP)، نمونه‌هایی که اشتباها توسط طبقه‌بندی (C_i^*) در کلاس نام طبقه‌بندی شده‌اند. تصمیمات منفی صحیح (TN)، نمونه‌هایی که درست توسط طبقه‌بندی (C_i^*) در کلاس نام طبقه‌بندی نشده‌اند. تصمیمات منفی ناصحیح (FN) نمونه‌هایی که اشتباها توسط طبقه‌بندی (C_i^*) به کلاس نام تعلق نگرفته‌اند. که $n_{FP} = n_{i,+} -$ ، $n_{TP} = n_{i,i}$ ، $n_{TN} = n - n_{TP} - n_{FP} - n_{FN}$ و $n_{FN} = n_{+,j} - n_{i,i}$ ، $n_{i,i}$ می‌باشد. $n_{i,+}$ مجموع اعضای تمامی ستون‌های متعلق به سطر نام و $n_{+,j}$ مجموع اعضای تمامی سطرهای متعلق به ستون نام در ماتریس اغتشاش می‌باشد (Labatut & Cheri, 2011). همچنین از شاخص‌های آماری مستخرج از ماتریس اغتشاش نظیر درصد اختصاصی بودن، حساسیت، صحت، دقت و ناحیه زیر منحنی (AUC) برای ارزیابی سامانه طبقه‌بندی پیشنهادی استفاده شد (Taheri-Garavand et al., 2015):

$$\text{Accuracy} = \frac{(n_TP + n_TN)}{(n_TP + n_TN + n_FP + n_FN)} \quad (\text{رابطه ۲۶})$$

$$\text{Sensitivity(Recall)} = \frac{n_TP}{(n_TP + n_FN)} \quad (\text{رابطه ۲۷})$$

$$\text{Specificity} = \frac{n_TN}{n_TN + n_FP} \quad (\text{رابطه ۲۸})$$

$$\text{Precision} = \frac{n_TP}{n_TP + n_FP} \quad (\text{رابطه ۲۹})$$

$$\text{AUC} = 1/2 \left(\frac{n_TP}{(n_TP + n_FN)} + \frac{n_TN}{(n_TN + n_FP)} \right) \quad (\text{رابطه ۳۰})$$

دقت روی تاثیر کلی طبقه‌بندی ANN تمرکز می‌کند. صحت، شرط کلاس برچسب داده‌ها با برچسب‌های مثبت مشخص شده توسط طبقه‌بندی را ارزیابی می‌کند. حساسیت تاثیر طبقه‌بندی ANN بر برچسب‌های مثبت و چگونگی تاثیر طبقه‌بندی با برچسب منفی را تشخیص می‌دهد. AUC توانایی طبقه‌بندی برای اجتناب از طبقه‌بندی غلط می‌باشد (Sokolova & Lapalme, 2009).

نتایج و بحث

در ساعات معین از گوشت مرغ نگهداری شده در دمای یخچال،

کمک طبقه‌بند شبکه‌های عصبی مصنوعی با استفاده از بردار ویژگی‌های منتخب به روش الگوریتم ازدحام ذرات برای ۵ کلاس مختلف تشکیل شده و در جدول (۶) مقادیر شاخص‌های آماری محاسبه شده برای تمام کلاس‌های روزهای مختلف نگهداری نمایش داده شده است. با توجه به جدول (۶) مقادیر میانگین به ازای هر کلاس دقت، حساسیت، اختصاصی بودن و ناحیه زیر منحنی (AUC) به ترتیب برابر با ۰.۹۲، ۰.۸۰/۰۲، ۰.۸۰/۶۸، ۰.۹۴/۸۹ و ۰.۸۷/۸۳ درصد می‌باشد.

مقادیر شاخص‌های آماری محاسبه شده برای تمام کلاس‌های روزهای مختلف نگهداری گوشت مرغ بدست آمد. با توجه به جدول (۴)، مقادیر میانگین به ازای هر کلاس دقت، صحت، حساسیت، اختصاصی بودن و ناحیه زیر منحنی (AUC) به ترتیب برابر با ۰.۸۸، ۰.۷۰/۷۸، ۰.۷۱/۵۲، ۰.۹۲/۴۱ و ۰.۸۱/۹۶ درصد می‌باشد. برای کاهش حجم محاسبات و افزایش دقت طبقه‌بندی از بردار ویژگی‌های مستخرج توسط ترکیب الگوریتم ازدحام ذرات و شبکه‌های عصبی مصنوعی به عنوان ورودی طبقه‌بند استفاده شد. در جدول (۵) ماتریس اغتشاشی که به

جدول ۲. ویژگی‌های آماری منتخب توسط ترکیب الگوریتم بهینه ساز ازدحام ذرات و طبقه‌بند شبکه‌های عصبی مصنوعی

تصاویر	ویژگی‌های آماری	میانگین	انحراف معیار	همواری	چولگی	یکنواختی (انرژی)	آنتروپی
تصویر کانال R	۱	۰	۰	۱	۰	۰	۱
تصویر کانال G	۰	۰	۰	۰	۰	۱	۱
تصویر کانال B	۱	۰	۰	۰	۰	۰	۰
تصویر کانال H	۱	۰	۰	۰	۰	۱	۱
تصویر کانال S	۰	۰	۰	۱	۱	۰	۱
تصویر کانال I	۰	۱	۱	۰	۰	۰	۱
تصویر کانال L*	۱	۰	۱	۰	۰	۰	۱
تصویر کانال a*	۰	۰	۰	۱	۰	۱	۰
تصویر کانال b*	۱	۱	۱	۰	۰	۰	۱

* عدد ۱ نشان‌دهنده ویژگی‌های آماری منتخب توسط طبقه‌بند و عدد ۰ نشان‌دهنده ویژگی‌های حذف شده می‌باشد.

ارزش نقش بسزایی در حفظ سلامت انسان دارد. گوشت مرغ به این دلیل که سالم‌تر بوده و منبع ارزانی برای تامین پروتئین حیوانی است، مصرف بالایی در جوامع بشری دارد و تازگی مهمترین مشخصه کیفی گوشت مرغ محسوب می‌شود. لذا در این پژوهش با بکارگیری روش‌های مبتنی بر تکنیک پردازش تصویر و شبکه‌های عصبی مصنوعی تازگی گوشت مرغ مورد ارزیابی قرار گرفت. بدین ترتیب که از ۳۰ نمونه گوشت مرغ به مدت ۵ روز هر ۶ ساعت یکبار (از هر دو سمت نمونه‌ها با پوست/ بدون پوست) عکسبرداری شد. پس از انجام عملیات پیش پردازش، تصاویر به فضاهای رنگی RGB، HSI و $L^*a^*b^*$ انتقال یافت و سپس ویژگی‌های آماری مربوط به بافت تصاویر از کانال‌های مربوطه استخراج گردید. برای انتخاب ویژگی‌های طبقه‌بند، ترکیب دو روش الگوریتم بهینه‌سازی ازدحام ذرات و طبقه‌بند شبکه‌های عصبی مصنوعی بکار رفت. تعداد نرون‌های موجود در لایه ورودی براساس تعداد ویژگی‌های منتخب،

همانگونه که در جداول (۴) و (۶) قابل مشاهده است تمام شاخص‌های آماری مذکور در مقایسه با شاخص‌های آماری طبقه‌بند شبکه عصبی بدون انتخاب ویژگی عملکرد بهتری داشته و همچنین زمان پاسخ به مراتب کمتری داشت (در این حالت زمان پاسخ نصف زمان پاسخ در حالت طبقه‌بندی شبکه عصبی بدون انتخاب ویژگی می‌باشد).

پس از بررسی ساختارهای مختلف شبکه، بهترین ساختار (شبکه با یک لایه مخفی ۸ نرون در آن لایه) برای تخمین و تشخیص تازگی گوشت مرغ در طی دوره نگهداری استفاده شد. ساختار شبکه عصبی به کار رفته در شکل (۵) نشان داده شده است.

نتیجه‌گیری کلی

با بهبود استانداردهای زندگی مردم توجه ویژه‌ای به کیفیت و ایمنی مواد غذایی دارند. گوشت بعنوان یک ماده غذایی با

جدول ۴. مقادیر شاخص‌های آماری مربوط به ماتریس اغتشاش به دست آمده برای پنج کلاس تازگی گوشت مرغ با طبقه‌بند شبکه‌های عصبی مصنوعی با استفاده از کلیه

ویژگی‌های مستخرج (بدون انتخاب ویژگی)

شاخصه‌های آماری (%)	دقت طبقه‌بندی	صحت	حساسیت	اختصاصی بودن	سطح زیر منحنی
روز اول	۹۷/۷۷	۸۸/۴۶	۹۵/۸۳	۹۸/۰۸	۹۶/۹۶
روز دوم	۸۵/۵۶	۶۴/۸۶	۶۴/۸۶	۹۰/۹۱	۷۷/۸۹
روز سوم	۸۰	۵۲/۵	۵۵/۲۶	۸۶/۶۲	۷۰/۹۴
روز چهارم	۸۳/۸۹	۶۲/۸۶	۵۷/۸۹	۹۰/۸۵	۷۴/۳۷
روز پنجم	۹۲/۷۷	۸۵/۷۱	۸۳/۷۲	۹۵/۶۲	۸۹/۶۷
میانگین به ازای هر کلاس	۸۸	۷۰/۷۸	۷۱/۵۲	۹۲/۴۱	۸۱/۹۶

جدول ۳. ماتریس اغتشاش به دست آمده برای پنج کلاس تازگی گوشت مرغ با طبقه‌بند شبکه‌های عصبی مصنوعی با استفاده از کلیه ویژگی‌های

مستخرج (بدون انتخاب ویژگی)

کلاس‌های واقعی تازگی گوشت مرغ	روز اول	روز دوم	روز سوم	روز چهارم	روز پنجم
روز اول	۲۳	۳	۰	۰	۰
روز دوم	۱	۲۴	۱۰	۲	۰
روز سوم	۰	۱۰	۲۱	۹	۰
روز چهارم	۰	۰	۰	۲	۰
روز پنجم	۰	۰	۶	۲	۷
میانگین	۰	۰	۱	۵	۳۶

جدول ۶. مقادیر شاخص‌های آماری مربوط به ماتریس اغتشاش به دست آمده برای پنج کلاس تازگی گوشت مرغ با طبقه‌بند شبکه‌های عصبی مصنوعی با استفاده از ویژگی‌های منتخب توسط

الگوریتم ذرات

شاخصه‌های آماری (%)	دقت طبقه‌بندی	صحت	حساسیت	اختصاصی بودن	سطح زیر منحنی
روز اول	۹۶/۶۷	۸۹/۹	۹۴/۲۹	۹۷/۲۴	۹۵/۷۶
روز دوم	۸۸/۳۳	۷۵	۶۹/۳۳	۹۳/۶۲	۸۱/۴۲
روز سوم	۸۸/۳۳	۷۶/۳۲	۷۰/۷۳	۹۳/۵۲	۸۲/۱۳
روز چهارم	۹۱/۶۷	۷۴/۲۹	۸۱/۲۵	۹۳/۹۲	۸۷/۵۹
روز پنجم	۹۵	۸۵/۲۹	۸۷/۸۸	۹۶/۶	۹۲/۲۴
میانگین به ازای هر کلاس	۹۲	۸۰/۰۲	۸۰/۶۸	۹۴/۸۹	۸۷/۸۳

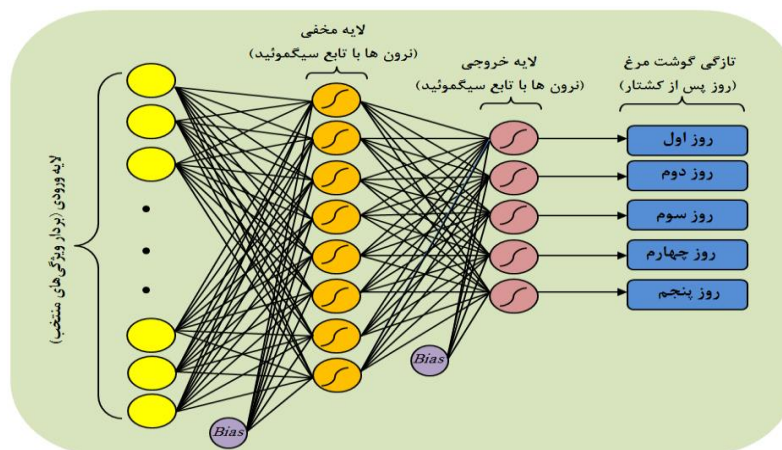
جدول ۵. ماتریس اغتشاش به دست آمده برای پنج کلاس تازگی گوشت مرغ با طبقه‌بند شبکه‌های عصبی مصنوعی با استفاده از ویژگی‌های منتخب توسط

الگوریتم ذرات

کلاس‌های واقعی تازگی گوشت مرغ	روز اول	روز دوم	روز سوم	روز چهارم	روز پنجم
روز اول	۳۳	۴	۰	۰	۰
روز دوم	۲	۲۷	۷	۰	۰
روز سوم	۰	۷	۲۹	۲	۰
روز چهارم	۰	۱	۴	۲۶	۴
روز پنجم	۰	۰	۱	۴	۲۹

منتخب برای هر کلاس به دست آمده از ماتریس اغتشاش، به ترتیب برابر ۹۲، ۸۰/۰۲، ۸۰/۶۸، ۹۴/۸۹ و ۸۷/۸۳ درصد محاسبه شد. در پایان این مطالعه مشاهده شد که این سیستم با دقت طبقه‌بند مناسبی توانست میزان تازگی گوشت مرغ را در طی مدت زمان نگهداری گوشت تشخیص و طبقه‌بندی نماید. بنابراین استفاده از تکنیک پردازش تصاویر مبتنی بر هوش مصنوعی برای تخمین و تشخیص تازگی گوشت مرغ امیدوار کننده است.

۲۲ عدد و با توجه به طبقه‌بندی ۵ کلاس تصاویر، تعداد نرون‌های موجود در لایه خروجی ۵ عدد تعیین شد. در نهایت طبقه‌بند با ساختار بهینه ۵-۸-۲۲ بدست آمد. همینطور از شبکه عصبی مصنوعی نیز برای طبقه‌بندی تصاویر به کمک بردار ویژگی‌های مستخرج و منتخب استفاده شد. ارزیابی طبقه‌بند به کمک شاخص‌های آماری نظیر دقت، صحت، حساسیت و اختصاصی بودن انجام گرفت که مقادیر میانگین این شاخص‌های آماری برای طبقه‌بندی به کمک ویژگی‌های



شکل ۵ بهترین ساختار برای تخمین و تشخیص تازگی گوشت مرغ

REFERENCES

- Ameri, H., Alizade, S. & Barzegari, A. (2013). Knowledge Extraction of Diabetics Data by Decision Tree Method. *Journal of Health Administration Iran University of Medical Sciences*, 16(53), 58-72.
- Banka, H. & Dara, S. (2014). Hamming distance based binary PSO for feature selection and classification from high dimensional gene expression data. In: *Proceedings of 2nd International Work-Conference on Bioinformatics and Biomedical Engineering*, 7-9 April., Garanda, Spain, pp. 507-514.
- Chaudhary, P., Chaudhari, A. K., Dr. Cheeran, A. N. & Godara., Sh. (2012). Color Transform Based Approach for Disease Spot Detection on Plant Leaf. *International Journal of computer science and telecommunications*, 3(6), 65-70.
- Chen, K., Sun, X., Qin, Ch. & Tang, X. (2010). Color grading of beef fat by using computer vision and support vector machine. *Computers and Electronics in Agriculture*, 70, 27-32.
- Chen, Q., Hui, Zh., Zhao, J. & Ouyang, Q. (2014). Evaluation of chicken freshness using a low-cost colorimetric sensor array with AdaBoost-OLDA classification algorithm. *LWT - Food Science and Technology*, 57(2), 502-507.
- Chmiel, M., Sowinski, M. & Dasiewicz, K. (2011). Application of computer vision systems for estimation of fat content in poultry meat. *Food Control*, 22, 1424-1427.
- Cozzolino, D. & Murray, I. (2012). A review on the application of infrared technologies to determine and monitor composition and other quality characteristics in raw fish, fish products, and seafood. *Applied Spectroscopy Reviews*, 47(3), 207-218.
- Dowlati, M., Mohtasebi, S. S., & de la Guardia, M. (2012). Application of machine vision techniques to fish-quality assessment. *TrAC-Trends in Analytical Chemistry*, 40, 168-179.
- El Barbri, N., Halimi, A & Rhofir, K. (2014). A Nondestructive Method Based on an Artificial Vision for Beef Meat Quality Assesement. *International journal of innovative research in electrical, electronics, instrumentation and control engineering*. 2(10), 2060-2063.
- Ghiasi, H., Jebraeili, Sh., Jafari, S.M & Maghsoudlou, Y. (2014). Design and Calibration of a Software-based Food Colorimeter System, *Iranian Food Science and Technology Research Journal*, 9(4), 314-322.
- Girolami, A., Napolitano, F., Faraone, D. & Braghieriv, A. (2013). Measurement of meat color using a computer vision system. *Meat Science*, 93, 111-118.
- Goldberg, D. (1989). Genetic algorithms in optimization, search and machine learning. Reading: Addison-Wesley.
- Gonzalez, R.C., Woods, R.E. & Eddins, S.L. (2002). Digital Image Processing (2nd ed.). Prentice Hall: New Jersey.
- Gonzalez, R.C., Woods, R.E. & Eddins, S.L. (2004). Digital Image Processing Using MATLAB, Pearson Prentice Hall: New Jersey, USA.
- Grau, R., Sanchez, A. J., Giron, J., Iborra, E., Fuentes, A., & Barat, J. M. (2011). Nondestructive assessment of freshness in packaged sliced chicken breasts using SW-NIR spectroscopy. *Food Research International*, 44(1), 331-337.
- Hosseinzadeh Samani, B & Hourijafari, H. (2015). Modeling and forecasting of energy consumption in food and processing industry using artificial neural networks. *Modares Mechanical Engineering*, 15(6), 16-22. (In Farsi).
- Huang, L., Zhao, J., Chen, Q. & Zhang, Y. (2014). Nondestructive measurement of total volatile basic nitrogen (TVB-N) in pork meat by

- integrating near infrared spectroscopy, computer vision and electronic nose techniques. Food Chemistry*, 145, 228–236.
- Jackman, P., Sun, D.-W. & Allen, P. (2011). Recent advances in the use of computer vision technology in the quality assessment of fresh meats. *Trends in Food Science & Technology*, 22(4), 185-197.
- Karray, F.O. & Silva, C.D. (2004). *Soft Computing and Intelligent Systems Design: Theory, Tools and Applications*. Addison Wesley Pearson Press, New York, USA.
- Kennedy, J. & Eberhart, R. C. (1997). A discrete binary version of the particle swarm algorithm. *IEEE International Conference on Computational Cybernetics and Simulation*. Volume 5. pp. 4104–4108.
- Khazaei, M., Banakar, A., Ghobadian, B., Mirsalim, M., Minaei, S., Jafari, S. M. & Sharghi, P. (2016). Analysis of Timing Belt Vibrational Behavior During a Durability Test Using Artificial Neural Network (ANN). *Modares Mechanical Engineering*. 16 (3), 311 -318. (In Farsi).
- Kheiralipour, k. (2012). Implementation and construction of fungal contamination of kernel of pistachio detection system based on thermography and image processing technology, PhD. Thesis, Agriculture machinery engineering University of Tehran, Iran,. (In Farsi).
- Khulal, U., Zhao, J., Hu, W. & Chen, Q. (2016). Nondestructive quantifying total volatile basic nitrogen (TVB-N) content in chicken using hyperspectral imaging (HSI) technique combined with different data dimension reduction algorithms. *Food Chemistry*, 197, 1191-1199.
- Labatut, V. & Cheri, H. (2011). Accuracy Measures for the Comparison of Classifiers. Al-Dahoud Ali. The 5th International Conference on Information Technology, Amman, Jordan.
- Leo'n, K., Mery, D., Pedreschi, F. & Leo'n, J. (2006). Color measurement in L*a*b* units from RGB digital images. *Food research international*, 39(10), 1084-1091.
- Liu, F., He, Y., Wang, L., & Sun, G. (2011). Detection of organic acids and pH of fruit vinegars using near-infrared spectroscopy and multivariate calibration. *Food and Bioprocess Technology*, 4(8), 1331–1340.
- M. Goñi, S. & O. Salvadori, V. (2016). Color measurement: comparison of colorimeter vs. computer vision system. *Food Measurement and Characterization*, 1–10.
- Ma, J., Sun, D.-W., Qu, J.-h., Liu, D., Pu, H., Gao, W.-h & Zeng, X.a. (2016). Applications of computer vision for assessing quality of agri-food products: a review of recent research advances. *Critical Reviews in Food Science and Nutrition*, 56(1), 113-127.
- Nasrollahzade, M., Shabbazi Karami, J., Moslemi Naeini, H., Hashemi, S.J., Mohammadi Najafabadi, H. (2016). Multiobjective optimization of hot metal gas forming process to production of square parts. *Modares Mechanical Engineering*, 16(10), 364-374. (In Farsi).
- Nezamabadi-pour, H., Rostami-sharbabaki, M. & Maghfoori-Farsangi, M. (2008). Binary Particle Swarm Optimization: Challenges and New Solutions. *The Journal of Computer Society of Iran (CSI) On Computer Science and Engineering (JCSE)*, 6(1-A), 21-32. (In Farsi).
- Nilsen, H., Esaiassen, M., Heia, K., & Sigernes, F. (2002). Visible/near-infrared spectroscopy: A new tool for the evaluation of fish freshness. *Journal of Food Science*, 67(5), 1821–1826.
- Pu, H., Xie, A., Sun, D.-W., Kamruzzaman, M. & Ma, J. (2015). Application of Wavelet Analysis to Spectral Data for Categorization of Lamb Muscles. *Food Bioprocess Technol*, 8(1), 1–16.
- Salinas, Y., Ros-Lis, J. V., Vivancos, J. -L., Dolores Marcos, M., Aucejo, S., Herranz, N & Lorente, I. (2012). Monitoring of chicken meat freshness by means of a colorimetric sensor array. *Analyst*, 137(16), 3635–3643.
- Salinas, Y., Ros-Lis, J. V., Vivancos, J. -L., Martínez-Mañez, R., Marcos, M. D., Aucejo, S., Herranz, N. & Lorente, I. (2014). A novel colorimetric sensor array for monitoring fresh pork sausages spoilage. *Food Control*, 35(1), 166–176.
- Shi, Z. & He, L. (2010). Application of neural networks in medical image processing, *Proceedings of the Second International Symposium on Networking and Network Security*, April 2-4., Jingtangshan, China.
- Singh, V., Gupta, I. & Gupta, H. (2007). ANN-based estimator for distillation using Levenberg–Marquardt approach, *Engineering Applications of Artificial Intelligence*, 20(2), 249-259.
- Sokolova, M. & Lapalme, Guy. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437.
- Taheri-Garavand, A. (2015). Implementation and development fault diagnosis of cooling system radiator using combined thermography and artificial intelligence techniques, *PhD. Thesis, University of Tehran, Iran,*. (In Farsi).
- Taheri-Garavand, A., Ahmadi, H., Omid, M., Mohtasebi, S.S., Mollazade, K., Russell Smith, A. J. & Carlomagno, G. M. (2015). An intelligent approach for cooling radiator fault diagnosis based on infrared thermal image processing technique. *Applied Thermal Engineering*, 87, 434-443.
- Taheri-Garavand, A., Omid, M., Ahmadi, H., Mohtasebi, S.S., Carlomagno, G. M. (2017).

- Intelligent fault diagnosis of cooling radiator based on *thermal image processing and artificial intelligence techniques*. *Modares Mechanical Engineering*, 17(2), 240-250. (In Farsi).
- Tsai, Ch.-F., Eberle, W. & Chu, Ch.-Y. (2013). Genetic algorithms in feature and instance selection. *Knowledge-Based Systems*, 39, 240–247.
- Vasconcelos, H., Saraiva, C., & de Almeida, J. M. M. M. (2014). Evaluation of the spoilage of raw chicken breast fillets using Fourier transform infrared spectroscopy in tandem with chemometrics. *Food and Bioprocess Technology*, 7(8), 2330–2341.
- Xiao, K., Gao, G. & Shou, L. (2014). An Improved Method of Detecting Pork Freshness Based on Computer Vision in On-line System. *Sensors & Transducers*, 169(4), 42-48.
- 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 Chemistry*, 179, 175–181.
- Xiong, Zh., Sun, D.-W., Pu, H., Gao, W. & Dai, Q. (2017). Applications of Emerging Imaging Techniques for Meat Quality and Safety Detection and Evaluation: A Review. *Critical Reviews in Food Science and Nutrition*, 57(4), 755-768.
- Zhang, M.-X., Wang, X.-C., Liu, Y., Xu, X.-L. & Zhou, G.-H. (2012). Isolation and identification of flavour peptides from Puffer fish (*Takifugu obscurus*) muscle using an *electronic tongue and MALDI-TOF/TOF MS/MS*. *Food Chemistry*, 135(3), 1463–1470.
- Zhou, X., Yuan, J & Liu, H. (2015). A Traffic Light Recognition Algorithm Based On Compressive Tracking, *International Journal of Hybrid Information Technology*. 8(6), 323-332.