



پیش‌بینی رطوبت و دانسیته در میگو طی سرخ‌کردن هوای داغ با مدل شبکه‌های عصبی مصنوعی

بهاره معروف پور^۱، امان محمد ضیائی فر^{۲*}، محمد قربانی^۳، حسن صباغی^۴، سعید یلقی^۵

^۱ دانشجوی دکتری علوم و مهندسی صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

^{۲*} استاد گروه مهندسی صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

^۳ استاد گروه شیمی مواد غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

^۴ استادیار گروه علوم و مهندسی مواد غذایی، دانشکده کشاورزی و دامپروری، مجتمع آموزش عالی تربت جام، خراسان رضوی، ایران

^۵ استادیار گروه شیلات، مرکز تحقیقات شیلات استان گلستان، گرگان، ایران

اطلاعات مقاله

چکیده

تاریخ‌های مقاله:

تاریخ دریافت: ۱۴۰۳/۵/۲۵

تاریخ پذیرش: ۱۴۰۳/۷/۱۶

کلمات کلیدی:

شبکه‌های عصبی مصنوعی،

رطوبت،

دانسیته،

میگو،

سرخ کردن هوای داغ.

DOI: 10.22034/FSCT.22.161.121.

* مسئول مکاتبات:

ziaiifar@gau.ac.ir

در این پژوهش، شبکه‌های عصبی مصنوعی (ANN) برای پیش‌بینی تغییرات رطوبت و دانسیته میگو طی فرآیند سرخ‌کردن هوای داغ (در سه دمای ۱۴۰، ۱۶۰ و ۱۸۰ درجه سانتی‌گراد به مدت ۱۵ دقیقه) ارائه گردید. شبکه‌های عصبی به صورت پرسپترون چند لایه (MLP) با تابع انتقال تانژانت سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی برای پیش‌بینی رطوبت (با دو ورودی: دما و زمان) و دانسیته (با سه ورودی: دما، زمان و رطوبت) در نرم افزار MATLAB طراحی شد. الگوریتم‌های مختلف پراشار شامل لونیبرگ-مارکوارت، گرادیان نزولی، گرادیان نزولی با نرخ تطبیقی یادگیری، انتشار برگشتی با نرخ یادگیری متغیر، گرادیان نزولی با مومنتم و گرادیان مزدوج مقیاس‌شده بودند. ساختار مدل‌ها با محاسبه ضریب تبیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) اعتبار سنجی شد. در نهایت، اهمیت ورودی‌ها از نظر تاثیر بر متغیر خروجی برای پیش‌بینی رطوبت و دانسیته با طراحی شبکه‌های عصبی پیش فرض تانژانت هایپربولیک در نرم افزار SPSS بررسی گردید. نتایج نشان داد که با کاهش رطوبت و توسعه منافذ در میگو، دانسیته محصول نیز طی سرخ‌کردن هوای داغ به تدریج کاهش یافت و با افزایش دمای فرآیند کاهش بیشتری در دانسیته مشاهده شد. در مدل رطوبت، الگوریتم پس انتشار گرادیان نزولی با مومنتم ($R^2=0.989$, RMSE=0.171, MAE=0.131) و در مدل دانسیته، الگوریتم لونیبرگ-مارکوارت ($R^2=0.974$, RMSE=0.0096, MAE=0.0066) کمترین میزان خطا را در آموزش نشان دادند. در محاسبات عصبی رطوبت، اهمیت متغیر زمان و دما به ترتیب برابر با ۰/۸۸۳ و ۰/۱۱۷ بود. در محاسبات عصبی دانسیته نیز اهمیت متغیر رطوبت، زمان و دما به ترتیب برابر با ۰/۵۸۸، ۰/۲۷۸ و ۰/۱۳۴ بود. از یافته‌های این پژوهش در طراحی هوش مصنوعی برای کنترل و ایجاد اتوماسیون در سرخ‌کن‌های هوای داغ می‌توان استفاده کرد.

۱-مقدمه

در سال‌های اخیر، به دلیل خطرات رژیم غذایی پرچرب، تمایل فزاینده‌ای در مصرف کنندگان وجود دارد که به جای مواد غذایی سرخ‌شده به دنبال غذاهای مغذی‌تر و ایمن باشند. همچنین، کاهش مصرف روغن در غذاهای سرخ‌شده به یک ضرورت تبدیل شده است. در این رابطه، جایگزینی فرآیند سرخ‌کردن سنتی با سیستم‌هایی که می‌توانند خواصی شبیه به غذاهای سرخ‌شده ارائه دهند و در عین حال علاوه بر سهولت دسترسی، کیفیت غذایی بالاتری را برای محصول ایجاد نمایند، در حال پژوهش است. بنابراین، سرخ‌کردن با هوای داغ به عنوان یک فرآیند جایگزین برای سرخ‌کردن عمیق معرفی شده است. تجهیزات با تکنولوژی سرخ‌کردن با هوای داغ در بازار موجود است [1] که برخی به طور مداوم با هوادهی مداوم و تماس مستقیم با سطوح ضد چسبندگی در حال تکامل هستند، اما تمامی طراحی‌ها نرخ انتقال حرارت یکنواخت میان هوا و محصول در حال سرخ‌شدن را فراهم نمی‌نمایند [2]. در این روش، محصول با قطرات روغن پخش شده در هوای داغ در تماس مستقیم قرار می‌گیرد و از این طریق محصول آبدایی شده و پوسته به تدریج روی محصول سرخ شده ظاهر می‌گردد [3]. افزودن روغن می‌تواند قبل یا طی فرایند با پوشش اندک روی سطح ماده غذایی با هدف ایجاد طعم، بافت و ظاهر مطلوب محصولات سرخ‌شده انجام گیرد [4]. سرخ‌کن‌های با هوای داغ، انتقال حرارتی یکنواخت بین هوا و محصول در حال سرخ‌شدن را فراهم می‌کنند [2] که در نتیجه تغییرات کیفی در سراسر محصول به صورت یکنواخت صورت می‌گیرد [4]. در سرخ‌کردن با هوای داغ در نهایت ماده غذایی سرخ‌شده با مقدار روغن بسیار پایین و سطح رطوبتی مشابه با سرخ‌کردن عمیق بدست می‌آید [3]. در روش سرخ‌کردن با هوای داغ محصول از تمامی جهات در یک زمان حرارت داده می‌شود و در بیشتر موارد نیاز به افزودن روغن نیست [1]. محصول سرخ شده توسط هوای داغ، ۸۰٪ روغن کمتری در مقایسه

با سرخ‌کردن عمیق دارد [5] و ذخیره ۷۰٪ انرژی و کاهش انتشار پساب‌های ناشی از سرخ‌کردن را به دنبال دارد [6].

انجمن قلب آمریکا مصرف انواع ماهی، صدف و میگو را حداقل دو بار در هفته توصیه می‌کند [7]. مطالعات اپیدمیولوژی نشان داده است که در آن دسته از جوامعی که فرهنگ مصرف غذاهای دریایی را دارند، شیوع کم حملات قلبی مشاهده می‌شود [8]. گوشت میگو به دلیل قابلیت هضم آسان (۸۵٪) در مقایسه با بسیاری از منابع پروتئینی دیگر ارزش بیولوژیکی بالایی دارد. ارزش غذاهای دریایی برای انسان حفظ وضعیت مثبت سلامتی و عملکرد مطلوب با تامین تمام مواد مغذی ضروری در مقادیر کافی است تا از بیماری‌های ناشی از کمبود مواد مغذی و همچنین اختلالات مزمن مرتبط با رژیم غذایی جلوگیری نماید [9]. میگو غنی از پروتئین با کیفیت بالا، کلسیم، ترکیبات معدنی و انواع مواد قابل استخراج برای بدن انسان است که کم کالری و کم چرب هستند. میگو دارای ترکیبات با کیفیتی شامل پروتئین، چربی و اسیدهای آمینه است که حضور آن‌ها به عنوان شاخص وجود شرایط فیزیولوژیکی و بیوشیمیایی مطلوب در نظر گرفته می‌شود. زیرا چربی‌های جانوران آبزی منابع خوبی از اسیدهای چرب ضروری هستند که نمی‌توانند در بدن انسان تولید شوند و برای حفظ رشد، تولید مثل و سنتز ویتامین‌ها مورد نیاز هستند. بنابراین فرآوری این محصولات بایستی به نحوی باشد که ارزش غذایی بالای آن برای مصرف‌کننده حفظ شود [10; 11; 12; 13].

یکی از مهمترین الزامات جهت کنترل یک پارامتر کیفی آشنایی با روند تغییرات آن طی سرخ‌کردن است و هر گونه نوسان در شرایط فرآیند سرخ‌کردن می‌تواند منجر به تغییرات کیفی نامطلوب شود [14]. مطالعه تغییرات رطوبت و یک شاخص بیوفیزیکی محصول مانند بافت یا دانسیته می‌تواند در کنترل این فرآیند نوین موثر باشد. آنجایی که میگو یک ماده زیستی با شکل نامنظم است و در هنگام

است [18]. شبکه‌های عصبی مصنوعی (ANN) یک مدل براساس یادگیری ماشین^۱ می‌باشد که مشابه سیستم عصبی بیولوژیکی شامل نورون^۲، دندریت^۳، آکسون^۴ طراحی شده است و می‌تواند فرآیندهای پیچیده غیر خطی در صنایع غذایی را مدل‌سازی نماید. این روش یک رویکرد نوین در حل مسائل مهندسی و ایجاد فناوری است که مزایایی را نسبت به مدل‌سازی ریاضی دارد و می‌تواند در حل مسائل مهندسی در شرایط واقعی پیاده‌سازی شود و کاهش قابل توجه زمان و صرف هزینه را به دنبال خواهد داشت [19].

پژوهشگران در رابطه با تاثیر سرخ کردن هوای داغ در کیفیت محصولات دریایی مانند ماهی ساردین [20]، کتلت ماهی [21]، لیپیدومی^۵ سوریمی^۶ (محصول ماهی) [22] و ماهی [23] تحقیقاتی انجام دادند که نتایج نشان می‌دهد روش سرخ کردن هوای داغ با کاهش تخریب چربی موجود در محصولات دریایی موجب حفظ خصوصیات کیفی و ارزیابی حسی مطلوب‌تر از نظر مصرف‌کننده شد. بررسی منابع نشان می‌دهد که مطالعه سرخ کردن هوای داغ برای محصول میگو تاکنون انجام نشده است. همچنین، در زمینه سرخ کردن با هوای داغ به ارائه مدل شبکه عصبی مصنوعی با هدف پیش‌بینی رطوبت و دانسیته توجه نشده است. اگر چه در پژوهشی، پارامترهای کیفیت فیزیکی میگو فریز شده توسط روش شبکه عصبی مصنوعی و الگوریتم ژنتیکی بررسی شد [24]. متغیرهای ورودی شامل سرعت انجماد، سرعت انجمادزدایی، زمان نگهداری، ضخامت میگو و متغیرهای خروجی شامل رنگ و بافت بودند. نتایج نشان داد که مدل GANN با کمترین RMSE و بالاترین R^2 در مقایسه با رگرسیون خطی چند متغیره^۷ (MLR) و پس‌انتشار^۸ (BP) پیش‌بینی بهتری دارد.

آبزدایی و سرخ کردن به شدت متقبض می‌گردد. طی آبزدایی، رطوبت از طریق حفرات میگو خارج می‌شود و این امر باعث کاهش حجم حفرات و حجم ظاهری میگو و تغییرات پارامتر کیفی دانسیته محصول می‌گردد. اگر چه شیب رطوبت در داخل میگو منجر به چروکیدگی غیر یکنواخت نیز خواهد شد که تغییر شکل غیریکنواخت را به دنبال دارد و تغییرات رطوبت و دانسیته می‌تواند روی بافت و رفتار آبزدایی محصول طی فرآیند تاثیر داشته باشد [15]. آشنایی با شرایط بافتی محصول می‌تواند در پیش‌بینی آسیب پذیری آن طی حمل و نقل نیز موثر باشد [16]. از طرفی پخت میگو می‌تواند موجب افت بازدهی تولید به عنوان یک عامل اقتصادی مهم ناشی از تغییرات در محتوی رطوبت گردد. در واقع طی فرآوری حرارتی، پروتئین‌های میگو دچار دناتوراسیون می‌شوند و در نتیجه از دست دادن توانایی نگهداری آب می‌تولند موجب کاهش بازدهی تولید میگو و تغییرات ابعادی محصول شود. افت بازدهی تولید یک معیار مهم در به کارگیری برنامه‌ریزی مناسب پخت برای میگو است و بررسی تغییرات رطوبتی و ابعادی میگو یک رویکرد آگاهانه در رابطه با بهینه‌سازی فرآیند پخت ایجاد می‌کند. تمام این موارد ممکن است با استفاده از مدل‌های ریاضی و مدل‌های هوشمند برای کمک به متخصصان در صنعت با هدف بهینه‌سازی فرآوری حرارتی میگو و افزایش کیفیت، تخمین زده شوند و جهت بررسی رابطه بین متغیرهای مختلف و موثر ساده‌سازی گردند. به عنوان مثال، "نمودارهای پخت" برای انواع بزرگ، متوسط و کوچک میگو با دستیابی به سطح میکروبی هدف با استفاده از مدل‌های ریاضی توسعه یافته ایجاد شده است [17]. در مجموع، مدیریت خصوصیات کیفی محصولات غذایی از مرحله تولید با هدف کنترل آن‌ها کار پیچیده‌ای

4- Axon

5-Lipidomic

6-Surimi

7-Multiple Linear Regression

8-Back Propagation

1-Machine learning

2-Neuron

3-Dendrite

ترازوی حساس آزمایشگاهی با دقت 0.001 (Sartorius GCA803S) انجام گرفت.

۲-۲- عملیات سرخ کردن با هوای داغ

عملیات سرخ کردن هوای داغ با پاشش 0.1 گرم روغن روی برش‌های میگو در سه دمای 140 ، 160 و 180 درجه سانتی‌گراد در یک دستگاه سرخ‌کن هوای داغ (Geepas-Gaf2708) به مدت 15 دقیقه انجام گرفت. حداکثر سرعت جریان هوای داغ در سرخ‌کن برابر با $6/5$ متر بر ثانیه بود که توسط دستگاه بادسنج (hot wire anemometer TES 1341) اندازه‌گیری شد. نمونه‌ها با فاصله زمانی سه دقیقه از سرخ‌کن خارج شدند. پس از اتمام فرآیند سرخ کردن، نمونه حدود 2 دقیقه روی کاغذ جاذب قرار گرفت تا روغن سطحی جزئی آن خارج شود. سپس میگوی سرخ شده با هوای داغ توزین شد. عملیات سرخ کردن در سه تکرار انجام شد.

۲-۳- اندازه‌گیری محتوی رطوبت محصول

جهت اندازه‌گیری محتوی رطوبت نمونه‌های سرخ‌شده مطابق با دستورالعمل مخصوص اندازه‌گیری رطوبت برای نمونه‌های چرب عمل شد و خشک کردن در آون هوای داغ با دمای 103 درجه سانتی‌گراد و به مدت 16 ساعت تا رسیدن به وزن ثابت انجام گرفت [25]. بعد از اتمام خشک شدن، ظرف حاوی نمونه پس از سرد شدن توزین گردید. با استفاده از رابطه (۱) میزان رطوبت میگو بر مبنای وزن خشک بدون روغن محاسبه شد. در این رابطه، M جرم نسبی رطوبت بر مبنای وزن خشک بدون روغن ($g/g, db$)، W وزن ثابت ظرف فلزی، W_1 وزن ظرف به همراه نمونه قبل از خشک کردن، W_2 وزن ظرف به همراه نمونه بعد از خشک کردن و W_{oil} وزن روغن پاشش شده (برابر با 0.1 گرم) همگی بر حسب گرم می‌باشند [26].

هدف از این پژوهش استفاده از شبکه عصبی مصنوعی با هدف پیش‌بینی رطوبت و دانسیته محصول به عنوان دو معیار کیفی مهم در افت تولید اسنک میگو است. مدل شبکه‌های عصبی مصنوعی اول برای پیش‌بینی محتوی رطوبت (یک متغیر خروجی) میگو تحت تاثیر زمان و دمای فرآیند سرخ کردن هوای داغ (دو متغیر ورودی) طراحی شد. مدل شبکه‌های عصبی دوم نیز برای پیش‌بینی دانسیته (یک متغیر خروجی) تحت تاثیر زمان و دمای فرآیند و محتوی رطوبت محصول (سه متغیر ورودی) بر اساس داده‌های آزمایشگاهی طراحی شد. اهمیت هر یک از متغیرهای ورودی نیز در ساختار شبکه‌های عصبی مصنوعی مورد ارزیابی قرار گرفت. در این پژوهش، با هدف ایجاد شرایط معین در بررسی فرآیند سرخ کردن هوای داغ، ترکیب شیمیایی و مقطع عرضی برای هر میگو یکسان فرض گردید و به دلیل کم بودن میزان روغن افزوده شده به میگو (0.1 گرم برای هر نمونه) اختلاف جذب آن در محصول در نظر گرفته نشد.

۲- مواد و روش‌ها

۲-۱- آماده سازی میگو

از پرورش میگوی گرگان در شمال ایران (شهرک صنعتی بندر ترکمن، شرکت شیل آبی گلستان) مقدار لازم میگوهای تازه و هم اندازه (میگوی پاسبید^۱) خریداری شد و در بسته‌بندی از جنس پلی‌اتیلن در داخل سردخانه در دمای انجماد قرار گرفت. قبل از آماده‌سازی نمونه‌ها، میگوها در دمای اتاق به مدت 10 دقیقه به منظور انجماد زدایی قرار گرفتند. میگوها پس از شستشو به صورت قطعاتی تقریباً استوانه‌ای با قطر 9 میلی‌متر و ارتفاع 15 میلی‌متر جداسازی و برش داده شد. قبل از عملیات سرخ کردن هوای داغ، توزین اولیه و ثبت وزن میگو توسط

۲-۵- طراحی مدل شبکه‌های عصبی مصنوعی

$$M = \frac{W_1 - W_2}{W_2 - W_0 - W_{oil}} \quad (1)$$

۲-۵-۱- ساختار شبکه

۲-۴- اندازه‌گیری حجم و دانسیته

شکل (۱) ساختار یک شبکه عصبی به صورت پرسپترون چند لایه^{۱۱} (MLP) را نشان می‌دهد. مشابه کار پژوهشگران [30]، در توضیح این مدل می‌توان گفت که در لایه ورودی به داده‌های ورودی وزن داده می‌شود و سپس در لایه پنهان این داده‌های وزن‌دار مطابق رابطه (۴) با یکدیگر جمع می‌شوند و یک تابع فعال‌سازی متناسب با ورودی‌ها، یک خروجی را می‌دهد. در این رابطه، y_i متغیر وابسته، x_i متغیر مستقل، w_{ij} وزن اتصال بین نورون i و نورون j و b_j اتصال بایاس با نورون j است [24]. تعداد نورون‌ها در لایه پنهان از ۱ تا ۲۵ بسته به خطای لایه خروجی متغیر می‌باشد، در حالی که تعداد لایه‌ها بین ۱ تا ۳ متغیر است. تمام داده‌ها به سه گروه داده‌های آموزش^{۱۲}، داده‌های آزمون^{۱۳} و داده‌های اعتبارسنجی^{۱۴} تقسیم شدند.

$$y_i = \sum_{j=1}^n f(w_{ij}x_j) + b_j \quad (4)$$

محاسبه حجم نمونه‌ها با روش جابه‌جایی حلال^{۱۰} تولوئن با اندازه‌گیری اختلاف وزن حلال موجود در یک فلاسک ۱۵۰ میلی‌لیتری در حضور و غیاب نمونه انجام شد. پس از توزین، نمونه‌های سرخ‌شده در فلاسک قرار گرفت. حجم نمونه از رابطه (۲) قابل محاسبه است. در این رابطه، V حجم نمونه (cm^3)، V_f حجم فلاسک (cm^3)، M_s جرم حلال (g) اضافه‌شده به فلاسک و ρ_s دانسیته حلال (0.866 g/cm^3) است [27; 28].

$$V = V_f - \frac{M_s}{\rho_s} \quad (2)$$

به منظور تخمین دانسیته (ρ) نمونه‌ها، از طریق رابطه (۳) عمل شد. واحد جرم (m) برحسب گرم و حجم (V) برحسب سانتی‌متر مکعب در نظر گرفته شد. دانسیته برحسب (g/cm^3) محاسبه شد [29].

$$\rho = \frac{m}{V}$$

(۳)




Figure 1- Schematic diagram on the structure of artificial neural networks as multilayer perceptron (MLP)

مشابه مطالعه پژوهشگران [31]، شبکه عصبی به صورت پرسپترون چند لایه (MLP) با تابع بهینه در پیش‌بینی دقیق میزان متغیر مورد مطالعه (رطوبت و دانسیته) با استفاده از

۲-۵-۲- طراحی شبکه

13- Testing Dataset
14 -Validation Dataset

10 -Solvent displacement technique
11 -Multilayer perceptron
12 -Training Dataset

برای تشکیل شبکه، ۴۵ داده برای ورودی‌ها و خروجی‌ها به صورت مستقل و وابسته بود.

۲-۵-۳- اعتبار سنجی

در اعتبار سنجی کارایی مرحله آموزش و آزمون در طراحی شبکه‌های عصبی مصنوعی با در نظرگیری انواع الگوریتم آموزشی مورد استفاده و ساختار مدل مورد مطالعه با محاسبه ضریب تبیین (R^2) مطابق رابطه (۵)، ریشه میانگین مربعات خطا^{۲۱} (RMSE) مطابق رابطه (۶) و میانگین خطای مطلق^{۲۲} (MAE) مطابق رابطه (۷) بررسی شد [32].

در این روابط، O_i مقدار مشاهده شده نمونه i ام، P_i مقدار برآورد شده همان نمونه، n تعداد تعداد داده‌ها، $\bar{O}$ میانگین مقادیر مشاهده شده و $\bar{P}$ میانگین نظیر برای مقادیر برآورد شده است. هر چه مقادیر RMSE و MAE به صفر نزدیکتر باشد، شرایط پیش‌بینی مطلوب‌تر است و نشان‌دهنده این است که مدل از قابلیت پیش‌بینی مطلوبی برخوردار است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^N (O_i - P_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (6)$$

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\left[\sum_{i=1}^n (O_i - \bar{O})^2 \right] \left[\sum_{i=1}^n (P_i - \bar{P})^2 \right]}} \right)^2 \quad (7)$$

فرض تانژانت هایپر بولیک^{۲۳} در نرم افزار SPSS نسخه ۱۹ بررسی شد. جعبه ابزار شبکه عصبی در نرم افزار SPSS با طراحی تعداد زیادی شبکه عصبی در کوتاه‌ترین زمان ممکن،

جعبه ابزار اختصاصی در نرم افزار MATLAB نسخه 2018a طراحی شد. در این پژوهش سه لایه از شبکه‌های الگوریتم پس انتشار با تابع انتقال تانژانت سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی به کار گرفته شد. الگوریتم-های مختلف پس انتشار استفاده شده در این مطالعه، لونیگ-مارکوارت^{۱۵}، گرادیان نزولی^{۱۶}، گرادیان نزولی با نرخ تطبیقی یادگیری^{۱۷}، گرادیان نزولی با مومنتم^{۱۸}، انتشار برگشتی با نرخ یادگیری متغیر^{۱۹} و گرادیان مزدوج مقیاس شده^{۲۰} می‌باشند. در شبکه عصبی پیش‌بینی رطوبت، متغیرهای ورودی، دما برحسب درجه سانتی‌گراد و زمان برحسب ثانیه است. متغیر خروجی، رطوبت برحسب گرم بر گرم ماده خشک می‌باشد. در شبکه عصبی پیش‌بینی دانسیته، متغیرهای ورودی دما برحسب درجه سانتی‌گراد، زمان برحسب ثانیه و رطوبت برحسب گرم بر گرم ماده خشک است. متغیر خروجی دانسیته برحسب گرم بر سانتی‌متر مکعب می‌باشد. ۳۰ داده در قسمت آموزش (۶۷ درصد از داده‌ها) و ۱۵ داده در مرحله آزمون (۳۳ درصد از داده‌ها) استفاده شد. تعداد کل داده‌ها

۲-۵-۴- بررسی اهمیت ورودی‌ها در طراحی شبکه

اهمیت ورودی‌ها از نظر تاثیر بر متغیر خروجی برای پیش‌بینی رطوبت و دانسیته با طراحی شبکه عصبی پیش

21- Root mean square error
22 -Mean absolute error
23 -Hyperbolic tangent

15 -Levenberg-Marquardt
16 -Gradient descent
17 -Gradient descent with adaptive learning rate
18 -Gradient descent with momentum
19 -Adaptive learning rate backpropagation
20 -Scaled conjugate gradient

تبخیر آب در دماهای بالای سرخ کردن هوای داغ سریع‌تر اتفاق می‌افتد و شدت آن در ۳ دقیقه ابتدایی فرآیند بیشتر است که به دلیل تبخیر ناگهانی آب آزاد سطحی^{۲۶} محصول می‌باشد. در حین سرخ کردن هوای داغ اختلاف فشار بخار جزئی بین محصول و هوای داغ باعث تبخیر آب می‌شود. این اختلاف فشار جزئی مسلماً در ابتدای فرآیند بیشتر می‌باشد. این مشاهدات با نتایج بسیاری از محققین سازگاری دارد [33; 34; 35; 36; 37]. پژوهشگران روند مشابهی را در کاهش رطوبت میگو طی سرخ کردن تحت خلاء مشاهده کردند و با افزایش دما سطح رطوبتی محصول کاهش بیشتری را طی زمان نشان داد [37]. محققین در مطالعه‌ای که روی سرخ کردن میگو داشتند، بیان نمودند که بعد از سرخ کردن میزان رطوبت میگو تحت تاثیر شرایط بستر سرخ کردن متغیر است [38]. پژوهشگران بیان کردند که طی سرخ کردن نرخ کاهش آب تا تکمیل خشک شدن سطحی محصول به طور افزایشی است و سپس کاهش می‌یابد [39]. در مطالعات مشابه بیان کردند که حداکثر نرخ کاهش رطوبت در زمان‌های ابتدایی فرآیند سرخ کردن بود [26; 40].

بهترین حالت را پیشنهاد می‌دهد که با فرض این شبکه می‌توان اهمیت ورودی‌ها را ارزیابی نمود. در این مرحله تعداد کل داده‌ها برای تشکیل شبکه ۵۴ داده برای ورودی‌ها و خروجی‌ها به صورت مستقل و وابسته بود. همچنین تعداد داده‌های لازم برای مرحله آموزش و آزمون توسط نرم افزار محاسبه شد. اعتبارسنجی مرحله آموزش و آزمون به طور خلاصه با استفاده از مجموع مربعات خطا^{۲۴} (SSE) و خطای نسبی^{۲۵} (RE) مطابق گزارش نرم افزار بررسی شد.

۳- نتایج و بحث

۳-۱- تغییرات رطوبت محصول در حین سرخ کردن

هوای داغ

در شکل (۲) تغییرات محتوی رطوبت میگو در حین سرخ کردن هوای داغ به همراه انحراف معیار داده‌های آزمایشی به عنوان تابعی از زمان فرآیند نشان داده شده است. با شروع فرآیند سرخ کردن هوای داغ نرخ کاهش رطوبت محصول زیادتر است و با کاهش رطوبت محصول به تدریج تغییرات رطوبتی به میزان ثابت می‌رسد. همان طور که انتظار می‌رود،




Figure 2- Changes in shrimp moisture content during hot air frying at different temperatures

۳-۲- تغییرات دانسیته میگو

شکل (۳) تغییرات دانسیته میگو طی سرخ کردن با هوای داغ را نشان می‌دهد. همان طور که مشخص است، دانسیته میگو طی زمان سرخ کردن به تدریج کاهش یافت. با افزایش دمای سرخ کردن با هوای داغ دانسیته میگو کاهش یافت. در زمان‌های طولانی فرآیند اختلاف میان دانسیته محصول در دماهای مختلف بیشتر شد. پژوهشگران بیان کردند که دانسیته تا حد زیادی تحت تأثیر متغیرهای فرآیند است و در حین سرخ کردن کاهش می‌یابد که به دلیل تبخیر آب و توسعه




Figure 3- Changes in shrimp density during hot air frying

الگوریتم آموزشی در مرحله آزمون به ترتیب ۰/۹۸۹، ۰/۱۷۱ (g/g, db) و ۰/۱۳۱ (g/g, db) است. برای تایید دقت مدل و ساختار انتخابی (گرادیان نزولی با مومنتم) مطابق شکل (۴) از نمودار پراکنش برای مرحله آموزش (شکل ۴-۱) و آزمون (شکل ۴-۲) استفاده شد. در این نمودارها مقدار واقعی رطوبت در برابر مقدار پیش‌بینی شده رطوبت توسط شبکه عصبی نشان داده است و نحوه در نظرگیری ضریب تصحیح‌سازی با برازش خط روی داده‌های تجربی متناظر با داده‌های مدل مشخص است.

۳-۳- مدل شبکه‌های عصبی مصنوعی در پیش‌بینی محتوی رطوبت

جدول (۱) نتایج مربوط به مدل‌سازی رطوبت توسط شبکه عصبی مصنوعی برای مرحله آموزش و آزمون را به تفکیک نشان می‌دهد. همان طور که مشخص است، کمترین مقدار برای شاخص‌های خطا در مرحله آزمون مربوط به الگوریتم آموزشی گرادیان نزولی با مومنتم است. در این حالت، ساختار مدل به صورت ۱-۱۶-۲ است که نشان دهنده دو ورودی در لایه اول، ۱۶ نرون در لایه پنهان و یک خروجی در لایه سوم است. مقادیر R^2 ، RMSE و MAE در این

Table 1- The results of the training and testing stages of the neural networks for moisture prediction

Training algorithm	Model structure	Training stage			Testing stage		
		R ²	RMSE (g/g, db)	MAE (g/g, db)	R ²	RMSE (g/g, db)	MAE (g/g, db)
Levenberg-Marquardt	1-2-2	0.9891	0.0877	0.0697	0.9720	0.1843	0.1454
Gradient descent	1-16-2	0.9892	0.0873	0.0682	0.9786	0.1714	0.1319
Gradient descent with adaptive learning rate	1-2-2	0.9854	0.1017	0.0842	0.9750	0.1758	0.1432
Gradient descent with momentum	1-16-2	0.9891	0.0878	0.0686	0.9787	0.1711	0.1317
Adaptive learning rate backpropagation	1-3-2	0.9904	0.0822	0.0583	0.9727	0.1830	0.1456
Scaled conjugate gradient	1-3-2	0.9909	0.0804	0.0574	0.9725	0.1836	0.1474




Figure 4- The actual values of moisture (g/g, db) versus the predicted values by the artificial neural networks in the training (A) and test (B) stages

است. مقادیر R^2 ، RMSE و MAE در این الگوریتم آموزشی در مرحله آزمون به ترتیب ۰/۹۷۴۰، ۰/۰۰۹۶ (g/cm^3) و ۰/۰۰۶۶ (g/cm^3) است. برای تایید دقت مدل و ساختار انتخابی (لونبرگ-مارکوارت) مطابق شکل (۵) از نمودار پراکنش برای مرحله آموزش (شکل ۵-A) و آزمون (شکل ۵-B) استفاده شد. در این نمودارها مقدار واقعی دانسیته در برابر مقدار پیش‌بینی شده دانسیته توسط شبکه عصبی نشان داده است و نحوه در نظرگیری ضریب تصحیح‌سازی با برازش خط روی داده‌های تجربی متناظر با داده‌های مدل مشخص است.

Table 2- The results of the training and testing stages of the neural networks for density prediction

Training algorithm	Model structure	Training stage			Testing stage		
		R ²	RMSE (g/cm^3)	MAE (g/cm^3)	R ²	RMSE (g/cm^3)	MAE (g/cm^3)
Levenberg-Marquardt	1-1-3	0.9356	0.0123	0.0089	0.9740	0.0096	0.0066

۳-۴- مدل شبکه‌های عصبی مصنوعی در پیش‌بینی دانسیته

جدول (۲) نتایج مربوط به مدل‌سازی دانسیته توسط شبکه عصبی مصنوعی برای مرحله آموزش و آزمون را به تفکیک نشان می‌دهد. همان‌طور که مشخص است، کمترین مقدار برای شاخص‌های خطا در مرحله آزمون مربوط به الگوریتم آموزشی لونبرگ-مارکوارت است. در این حالت، ساختار مدل به صورت ۱-۱-۳ است که نشان دهنده سه ورودی در لایه اول، ۱ نرون در لایه پنهان و یک خروجی در لایه سوم

Gradient descent	1-20-3	0.9385	0.0121	0.0090	0.9692	0.0102	0.0071
Gradient descent with adaptive learning rate	1-1-3	0.9328	0.0126	0.0089	0.9647	0.0107	0.0067
Gradient descent with momentum	1-20-3	0.9385	0.0121	0.0090	0.9686	0.0102	0.0071
Adaptive learning rate backpropagation	1-1-3	0.9344	0.0124	0.0089	0.9685	0.0101	0.0066
Scaled conjugate gradient	1-1-3	0.9354	0.0124	0.0089	0.9728	0.0097	0.0066




Figure 5- The actual values of density (g/cm^3) versus the predicted values by the artificial neural networks in the training (A) and test (B) stages

۳-۵- اهمیت ورودی‌های شبکه در پیش‌بینی رطوبت

شکل (۶) ساختار شبکه عصبی مصنوعی برای پیش‌بینی رطوبت میگو با تعداد دو متغیر در لایه ورودی، یک لایه پنهان با تابع تانژانت هایپربولیک و یک متغیر در لایه خروجی است. ۷۲/۲ درصد از داده‌ها برای مرحله آموزش و ۲۷/۸ درصد برای مرحله آزمون استفاده شد. در تشکیل شبکه

عصبی رطوبت با هدف بررسی اهمیت متغیرهای ورودی با توجه به محاسبات دقیق که توسط نرم افزار SPSS انجام شد، مجموع مربعات خطا (SSE) و خطای نسبی (RE) برای مرحله آموزش به ترتیب برابر با ۰/۱۸ و ۰/۰۰۹ بود و برای مرحله آزمون به ترتیب برابر با ۰/۰۷ و ۰/۰۰۸ برآورد شد که بسیار مطلوب بود.




Figure 6- Artificial neural network for predicting moisture content of shrimp during hot air frying: input variables: temperature and time and output variable: moisture content.

شکل (۷) اهمیت متغیرهای مستقل در تشکیل شبکه عصبی پیش‌بینی رطوبت را نشان می‌دهد. اهمیت متغیر دما برابر با ۰/۱۱۷ و اهمیت متغیر زمان برابر با ۰/۸۸۳ بود. اهمیت نرمال‌شده بر حسب درصد با فرض اینکه زمان ۱۰۰ درصد

برای پیش‌بینی رطوبت اهمیت دارد، برای دما برابر با ۱۳/۲ درصد بود. محققین به طور مشابهی اهمیت زمان سرخ‌کردن را در پیش‌بینی رطوبت طی سرخ‌کردن عمیق را نسبت به سایر ورودی‌ها بیشتر معرفی نمودند [43].




Figure 7- The importance of independent variables (Temperature “T” and time “t”) in the formation of artificial neural network for moisture prediction

۲۲/۲ درصد برای مرحله آزمون استفاده شد. در تشکیل شبکه عصبی دانسیته با هدف بررسی اهمیت متغیرهای ورودی با توجه به محاسبات دقیق که توسط نرم افزار SPSS انجام شد، مجموع مربعات خطا (SSE) و خطای نسبی (RE) برای مرحله آموزش به ترتیب برابر با ۰/۱۶۱ و ۰/۰۰۸ بود و برای مرحله آزمون به ترتیب برابر با ۰/۱۴ و ۰/۰۳۷ برآورد شد که بسیار مطلوب بود.

۳-۶- اهمیت ورودی‌های شبکه در پیش‌بینی دانسیته

شکل (۸) ساختار شبکه عصبی مصنوعی برای پیش‌بینی دانسیته میگو با تعداد سه متغیر در لایه ورودی، یک لایه پنهان با تابع تانژانت هایپربولیک و یک متغیر در لایه خروجی است. ۷۷/۸ درصد از داده‌ها برای برای مرحله آموزش و




Figure 8- Artificial neural network for predicting density of shrimp during hot air frying: input variables: temperature, time and moisture and output variable: density.

فرآیند به شدت تبخیر آب و زمان فرآیند مرتبط دانستند. به طوری که با افزایش شدت تبخیر یا طولانی شدن زمان فرآیند دانسیته کاهش می‌یابد. آن‌ها نیز بیان کردند در دماهای بالا به دلیل افت شدید رطوبت محصول کاهش بیشتری در دانسیته اتفاق می‌افتد که دلیل بر اهمیت رطوبت محصول در تخمین دانسیته است [28].

پژوهشگران با استفاده از مدل‌های مشابه، به نتایج امیدوارکننده‌ای در پیش‌بینی ویژگی‌های کیفی و متغیرهای فرآیندی دست یافته‌اند. توسعه سیستم‌های فازی برای پیش‌بینی ویژگی‌های کیفی و خصوصیات حسی محصولات سرخ‌شده با هوای داغ، همچنین شبیه‌سازی مدل‌ها برای خودکارسازی فرآیند، اهمیت این یافته‌ها را برای تحقیقات آینده بیشتر برجسته می‌کند [46؛ 45].

شکل (۹) اهمیت متغیرهای مستقل در تشکیل شبکه عصبی پیش‌بینی دانسیته را نشان می‌دهد. اهمیت متغیر رطوبت، زمان و دما به ترتیب برابر با ۰/۵۸۸، ۰/۲۷۸ و ۰/۱۳۴ بود. اهمیت رطوبت در پیش‌بینی دانسیته در استفاده از هوش مصنوعی به خوبی مشخص شد. اهمیت نرمال‌شده بر حسب درصد با فرض اینکه رطوبت ۱۰۰ درصد برای پیش‌بینی دانسیته اهمیت دارد، برای زمان و دما به ترتیب برابر با ۴۷/۳ و ۲۲/۸ درصد بود. در همین راستا، پژوهشگران تاثیر رطوبت را روی دانسیته در تعیین شرایط بهینه برای محصول سرخ‌شده مهم دانستند. آن‌ها اشاره کردند که طی سرخ‌کردن با افزایش دما، زمان و بیا به عبارتی ادامه قرار گیری محصول در شرایط سرخ‌کردن، به دلیل تبخیر و کاهش رطوبت توسعه منافذ هوا و افزایش انبساط محصول مشاده شد که این امر منجر به افزایش حجم مخصوص و کاهش دانسیته گردید [43]. در سایر مطالعات نیز محققین تغییرات دانسیته محصول را طی




Figure 9- The importance of independent variables (Temperature "T", time "t" and Moisture "M") in the formation of artificial neural network for density prediction

۴- نتیجه‌گیری

به خوبی توانست این خصوصیات کیفی را پیش‌بینی نماید. زمان فرآیند نسبت به دمای فرآیند در طراحی مدل پیش‌بینی‌کننده رطوبت اهمیت بیشتری نشان داد. به ترتیب متغیر رطوبت، زمان و دما در پیش‌بینی دانسیته بیشترین اهمیت را نشان دادند. تاکنون میزان اهمیت عوامل مختلف در پیش‌بینی رطوبت و دانسیته محصول به صورت کمی ارائه نشده بود و نتایج این مطالعه در تخمین و تحلیل افت تولید میگو می‌تواند به تولیدکنندگان کمک نماید. در به کارگیری هر روش فرآوری نوین در صنایع غذایی، آشنایی با پارامترهای فرآیندی موثر بر کیفیت محصول می‌تواند

در این پژوهش مدل شبکه‌های عصبی مصنوعی برای پیش‌بینی تغییرات رطوبت و دانسیته میگو طی سرخ‌کردن هوای داغ بررسی شد. در ابتدای فرآیند سرخ‌کردن به دلیل اختلاف فشار بخار جزئی بین محصول و هوای داغ و در نتیجه خروج ناگهانی آب آزاد سطحی، تبخیر آب شدیدتر مشاهده شد. به همین ترتیب با کاهش رطوبت و توسعه منافذ در میگو، دانسیته محصول نیز طی سرخ‌کردن هوای داغ به تدریج کاهش یافت که با افزایش دمای فرآیند کاهش بیشتری در دانسیته اتفاق افتاد. مدل‌سازی شبکه‌های عصبی مصنوعی

خصوصیات کیفی مانند رنگ بایستی بیشتر مورد توجه قرار گیرد.

۵-منابع

- متخصصین را در بهبود کنترل فرآیند راهنمایی نماید. در پژوهش‌های آینده، مطالعات مدل‌سازی هوشمند فرآیند سرخ کردن هوای داغ با هدف طراحی و توسعه دستگاه‌های دارای اتوماسیون در مقیاس صنعتی متناسب با سایر
- [1] Zaghi, A. N., Barbalho, S. M., Guiguer, E. L., & Otoboni, A. M. (2019). Frying Process: From Conventional to Air Frying Technology. *Food Reviews International*, 35(8), 763-777.
 - [2] Santos, C. S., Cunha, S. C., & Casal, S. (2017). Deep or air frying? A comparative study with different vegetable oils. *European Journal of Lipid Science and Technology*, 119(6), 1600375.
 - [3] Andrés, A., Argüelles, Á., Castelló, M. L., & Heredia, A. (2013). Mass transfer and volume changes in French fries during air frying. *Food and Bioprocess Technology*, 6(8), 1917-1924.
 - [4] Teruel, M. D. R., Gordon, M., Linares, M. B., Garrido, M. D., Ahromrit, A., & Niranjana, K. (2015). A comparative study of the characteristics of french fries produced by deep fat frying and air frying. *Journal of Food Science*, 80(2), E349-E358.
 - [5] Heredia, A., Castelló, M. L., Argüelles, A., & Andrés, A. (2014). Evolution of mechanical and optical properties of French fries obtained by hot air-frying. *LWT-Food Science and Technology*, 57(2), 755-760.
 - [6] Giovanelli, G., Torri, L., Sinelli, N., & Buratti, S. (2017). Comparative study of physico-chemical and sensory characteristics of French fries prepared from frozen potatoes using different cooking systems. *European Food Research and Technology*, 243(9), 1619-1631.
 - [7] Czech, A., Grela, E. R., & Ognik, K. (2015). Effect of frying on nutrients content and fatty acid composition of muscles of selected freezing seafoods. *Journal of Food and Nutrition Research*, 3(1), 9-14.
 - [8] Akuamo, F., Odamtten, G. T., & Kortei, N. K. (2018). Nutritional and shelf-life studies of dry smoked and gamma irradiated shrimps (*Penaeus notialis*) from three different water sources in Ghana. *Cogent Food & Agriculture*, 4(1), 1505803.
 - [9] Jeyasanth, K. I., & Patterson, J. (2017). Effect of formulated feed on the biochemical composition of cultured shrimp, *Penaeus monodon* (Fabricius, 1798). *International Journal of Fisheries and Aquatic Research*, 2, 15-22.
 - [10] Ali, S. S. R., Ramachandran, M., Chakma, S. K., & Sheriff, M. A. (2017). Proximate composition of commercially important marine fishes and shrimps from the Chennai coast, India. *International Journal of Fisheries and Aquatic Studies*, 5(5), 113-119.
 - [11] Dincer, M. T., & Aydin, I. (2014). Proximate composition and mineral and fatty acid profiles of male and female jinga shrimps (*Metapenaeus affinis*, H. Milne Edwards, 1837). *Turkish Journal of Veterinary & Animal Sciences*, 38(4), 445-451.
 - [12] Dayal, J. S., Ponniah, A. G., Khan, H. I., Babu, E. M., Ambasankar, K., & Vasagam, K. K. (2013). Shrimps—a nutritional perspective. *Current science*, 1487-1491.
 - [13] Peralta, E. M., Hatate, H., Watanabe, D., Kawabe, D., Murata, H., Hama, Y., & Tanaka, R. (2005). Antioxidative activity of Philippine salt-fermented shrimp and variation of its constituents during fermentation. *Journal of Oleo Science*, 54(10), 553-558.
 - [14] Sabbaghi, H., Ziaifar, A. M., Sadeghi, A. R., Kashaninejad, M., and Mirzaei, H. (2017). Kinetic modeling of color changes in french fries during frying process. *Journal of Food Technology and Nutrition*, 14(1), 65-76.
 - [15] Niamnuy, C., Devahastin, S., Soponronnarit, S., & Raghavan, G. V. (2008). Modeling coupled transport phenomena and mechanical deformation of shrimp during drying in a jet spouted bed dryer. *Chemical Engineering Science*, 63(22), 5503-5512.
 - [16] Sabbaghi H, Ziaifar, AM, and Kashaninejad M. (2017). Mechanical study for texture degradation of potato strip during frying process. *Iranian Food Science and Technology Research Journal*, 13(1): 92-104.
 - [17] Erdoğan, F., Balaban, M. O., & Otwell, W. S. (2003). Construction of shrimp cooking charts using previously developed mathematical models for heat transfer and yield loss predictions. *Journal of food engineering*, 60(1), 107-110.
 - [18] Sabbaghi H, Ziaifar AM, and Kashaninejad M. (2020). Textural profile analysis (TPA) of dried apple slices using infrared radiation with intermittent heating method. *Iranian Food Science and Technology Research Journal* 16(1): 57-72.
 - [19] Bhagya Raj, G. V. S., & Dash, K. K. (2022). Comprehensive study on applications of artificial neural network in food process modeling. *Critical reviews in food science and nutrition*, 62(10), 2756-2783.
 - [20] Ferreira, F. S., Sampaio, G. R., Keller, L. M., Sawaya, A. C., Chávez, D. W., Torres, E. A., &

- Saldanha, T. (2017). Impact of air frying on cholesterol and fatty acids oxidation in sardines: Protective effects of aromatic herbs. *Journal of food science*, 82(12), 2823-2831.
- [21] Joshy, C. G., Ratheesh, G., Ninan, G., Kumar, K. A., & Ravishankar, C. N. (2020). Optimizing air-frying process conditions for the development of healthy fish snack using response surface methodology under correlated observations. *Journal of Food Science and Technology*, 1-8.
- [22] Yu, X., Li, L., Xue, J., Wang, J., Song, G., Zhang, Y., & Shen, Q. (2020). Effect of air-frying conditions on the quality attributes and lipidomic characteristics of surimi during processing. *Innovative Food Science & Emerging Technologies*, 60, 102305.
- [23] Fang, M., Huang, G. J., & Sung, W. C. (2021). Mass transfer and texture characteristics of fish skin during deep-fat frying, electrostatic frying, air frying and vacuum frying. *Lwt*, 137, 110494.
- [24] Ahmad, I., Jeenanunta, C., Chanvarasuth, P., & Komolavanij, S. (2014). Prediction of physical quality parameters of frozen shrimp (*Litopenaeus vannamei*): an artificial neural networks and genetic algorithm approach. *Food and bioprocess technology*, 7(5), 1433-1444.
- [25] AOAC. (1995). Official methods of analysis, 16th ed. Association of Official Analytical Chemists, Washington, DC, Unites States.
- [26] Sabbaghi, H., Ziaiifar, A. M., Sadeghi Mahoonak, A., Kashani-Nejad, M., & Mirzaee, H. (2015). Estimation of convective heat transfer coefficient as function of the water loss rate during frying process. *Iranian Food Science and Technology Research Journal*, 11(4), 473-484.
- [27] Yan, Z., Sousa-Gallagher, M. J., & Oliveira, F. A. (2008). Shrinkage and porosity of banana, pineapple and mango slices during air-drying. *Journal of Food Engineering*, 84(3), 430-440.
- [28] Sabbaghi, H., Ziaiifar, A. M., & Kashaninejad, M. (2021). Estimation of shrinkage and rehydration in apple slices dried by infrared radiation using intermittent heating method. *Food Research Journal*, 31(4), 35-49.
- [29] Mayor, L., & Sereno, A. (2004). Modelling shrinkage during convective drying of food materials: a review. *Journal of Food Engineering*, 61(3), 373-386.
- [30] Gouyo, T., Mestres, C., Maraval, I., Fontez, B., Hofleitner, C., & Bohuon, P. (2020). Assessment of acoustic-mechanical measurements for texture of French fries: Comparison of deep-fat frying and air frying. *Food Research International*, 131, 108947.
- [31] Kim, D. S., Lee, J. H., & Shin, H. J. (2023). Optimization of Vacuum Frying Process for Sweet Potato Chip Manufacturing Using Response Surface Methodology and Artificial Neural Network Model. *Biotechnology and Bioprocess Engineering*, 28(4), 554-567.
- [32] Samuel, O. D., & Okwu, M. O. (2019). Comparison of Response Surface Methodology (RSM) and Artificial Neural Network (ANN) in modelling of waste coconut oil ethyl esters production. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 41(9), 1049-1061.
- [33] Duran, M., Pedreschi, F., Moyano, P., and Troncoso, E. (2007). Oil partition in pre-treated potato slices during frying and cooling. *Journal of Food Engineering*, 81:257-265.
- [34] Ziaiifar, A.M., Heyd, B., and Courtois, F. (2009). Investigation of effective thermal conductivity kinetics of crust and core regions of potato during deep-fat frying using a modified Lees method. *Journal of Food Engineering*, 95: 373-378.
- [35] Krokida, M.K., Oreopoulou, V., Maroulis, Z.B., and Marinos-Kouris, D. (2001). Effects of osmotic dehydration pretreatment on quality of French fries. *Journal of Food Engineering*, 49: 339-345.
- [36] Pedreschi, F., Herna' ndez, P., Figueroa, C., and Moyano, P.C. (2005). Modeling water loss during frying of potato slices. *International Journal of Food Properties*, 8: 289-299.
- [37] Pan, G., Ji, H., Liu, S., & He, X. (2015). Vacuum frying of breaded shrimps. *LWT-Food Science and Technology*, 62(1), 734-739.
- [38] Yang, D., Wu, G., Lu, Y., Li, P., Qi, X., Zhang, H., ... & Jin, Q. (2021). Comparative analysis of the effects of novel electric field frying and conventional frying on the quality of frying oil and oil absorption of fried shrimps. *Food Control*, 128, 108195.
- [39] Costa, R.M., Oliveira, F.A.R., Delaney, O., and Gekas, V. (1999). Analysis of the heat transfer coefficient during potato frying. *Journal of Food Engineering*, 39:293-299.
- [40] Farkas, B.E., and Hubbard, L.J. (2000). Analysis of convective heat transfer during immersion frying. *Drying Technology*, 18: 1269-1285.
- [41] Krokida, M. K., Oreopoulou, V., & Maroulis, Z. B. (2000). Effect of frying conditions on shrinkage and porosity of fried potatoes. *Journal of food engineering*, 43(3), 147-154.
- [42] Pinthus, E. J., Weinberg, P., & Saguy, I. S. (1995). Oil uptake in deep fat frying as affected by porosity. *Journal of Food Science*, 60(4), 767-769.
- [43] Mittal, G. S., & Zhang, J. (2001). Artificial neural network for the prediction of temperature, moisture and fat contents in meatballs during deep-fat frying. *International journal of food science & technology*, 36(5), 489-497.

- [44] Math, R. G., Velu, V., Nagender, A., & Rao, D. G. (2004). Effect of frying conditions on moisture, fat, and density of papad. *Journal of Food Engineering*, 64(4), 429-434.
- [45] Sabbaghi, H., Ziaiiifar, A.M., and Kashaninejad, M. (2019). Design of fuzzy system for sensory evaluation of dried apple slices using infrared radiation. *Iranian Journal of Biosystems Engineering*, 50(1), 77-89.
- [46] Sabbaghi, H., Ziaiiifar, A.M., an Kashani-Nejad, M. (2021). Simulation of temperature fuzzy controller during infrared dry blanching and dehydration of apple slices by intermittent heating method. *Iranian Food Science and Technology Research Journal*, 16(6), 133-150.



Journal of Food Science and Technology (Iran)

Homepage: www.fsct.modares.ir

Scientific Research

Prediction of moisture and density in shrimp during hot air frying with artificial neural networks model

Bahareh Maroufpour¹, Aman Mohammad Ziaifar^{*2}, Mohammad Ghorbani³, Hassan Sabbaghi⁴, Saeed Yalghi⁵

¹ Ph.D. student of food industry science and engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

^{2*} Professor, Department of Food Industry Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran (corresponding author)

³ Professor, Department of Food Chemistry, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

⁴ Assistant Professor, Department of Food Science and Technology, Faculty of Agriculture and Animal Science, University of Torbat-e Jam, Razavi Khorasan Province, Iran

⁵ Assistant Professor of Fisheries Department, Golestan Province Fisheries Research Center, Gorgan, Iran

ARTICLE INFO

Article History:

Received: 2024/8/15

Accepted: 2024/10/7

Keywords:

Artificial neural networks,
Moisture,
Density,
Shrimp,
Hot air frying.

DOI: 10.22034/FSCT.22.161.121.

*Corresponding Author E-
ziaifar@gau.ac.ir

ABSTRACT

In this research, artificial neural networks (ANN) was presented to predict changes in moisture and density of shrimp during hot air frying process (at three temperatures of 140, 160 and 180 degrees Celsius for 15 minutes). Neural networks in the form of multilayer perceptron (MLP) with sigmoid tangent transfer function in the hidden layer and linear transfer function in the output layer was designed to predict moisture (with two inputs: temperature and time) and density (with three inputs: temperature, time and moisture) in MATLAB software. Different backpropagation algorithms include Levenberg-Marquardt, Gradient descent, Gradient descent with adaptive learning rate, Adaptive learning rate backpropagation, Gradient descent with momentum, and Scaled conjugate gradient. The structure of the models was validated by calculating the coefficient of determination (R^2), root mean square error (RMSE) and mean absolute error (MAE). Finally, the importance of the inputs in terms of the effect on the output variable for predicting moisture and density was investigated by designing the default hyperbolic tangent neural networks in SPSS software. The results showed that with the decrease in moisture and the development of pores in shrimp, the density of the product gradually decreased during hot air frying, and with the increase in the temperature of the process, a further decrease in density was observed. In the moisture model, the backpropagation algorithm of Gradient descent with momentum ($R^2=0.989$, RMSE=0.171, MAE=0.131) and in the density model, the Levenberg-Marquardt algorithm ($R^2=0.974$, RMSE=0.0096, MAE=0.0066) showed the minimum error in training. In the moisture neurocomputing, the importance of time and temperature variable was equal to 0.883 and 0.117, respectively. In the density neurocomputing, the importance of moisture, time and temperature variables were 0.588, 0.278 and 0.134, respectively. The Findings can be used in the design of artificial intelligence for controlling and creating automation in hot air fryers.