



## مقاله علمی-پژوهشی

## پیش بینی ویژگیهای بافتی پنیر موزارالای کم چرب با استفاده از تصویربرداری فراطیفی به کمک روش - های یادگیری ماشین

طاهره جهانی<sup>۱</sup>، مهدی کاشانی نژاد<sup>۲\*</sup>، امان محمد ضیائی فر<sup>۳</sup>، علیرضا سلیمانی پور<sup>۴</sup>، ناصر بهنام پور<sup>۵</sup>

- ۱- دانشجوی دکتری مهندسی صنایع غذایی، دانشکده صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
- ۲- کارشناس مرکز تحقیقات سلامت فرآورده های غذایی، دارویی و طبیعی دانشگاه علوم پزشکی گلستان
- ۳- \*استاد گروه مهندسی صنایع غذایی، دانشکده صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
- ۴- دانشیار گروه مهندسی صنایع غذایی، دانشکده صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
- ۵- استادیار گروه مهندسی مکانیک بیوسیستم، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
- ۶- استادیار مرکز تحقیقات مدیریت سلامت و توسعه اجتماعی، گروه آمار زیستی و اپیدمیولوژی، دانشگاه علوم پزشکی گلستان

## چکیده

## اطلاعات مقاله

با تغییر در شدت عملیات مکانیکی-حرارتی متفاوت، تنوع فرمولاسیون و شرایط نگهداری، ۳۶ نمونه پنیر موزارالا کم چرب تهیه و سختی چسبندگی، انسجام، فنریت، حالت صمغی و قابلیت جویدن آنها توسط تجزیه و تحلیل مشخصات بافت اندازه گیری و با استفاده از تجزیه و تحلیل تک متغیره در قالب فاکتوریل در نرم افزار SPSS با یکدیگر مقایسه شد. سپس تصویربرداری از همان نمونه ها با دوربین فراطیفی در محدوده ۱۰۰۰-۴۰۰ نانومتر با دوربین فراطیفی انجام و پس از پیش پردازش طیف ها و جداسازی طول موج های مؤثر به کمک الگوریتم های انتخاب ویژگی، مدل سازی با الگوریتم رگرسیون خطی چندگانه، رگرسیون حداقل مربعات جزئی، ماشین بردار پشتیبان با کرنل خطی، شبکه عصبی پرسپترون چندلایه، جنگل های تصادفی و الگوریتم رأی اکثریت در نرم افزار پایتون انجام و کارائی مدل های ارزیابی گردید. نتایج نشان داد که با تشدید عملیات مکانیکی-حرارتی، سختی، فنریت، حالت صمغی و قابلیت جویدن و انسجام افزایش و چسبندگی کاهش پیدا کرد ( $P < 0/05$ ). افزودن اسید و جانشین شونده های چربی سبب کاهش سختی، انسجام، فنریت و قابلیت جویدن شده و حالت صمغی و چسبندگی را افزایش دادند. الگوریتم رأی اکثریت، بیشترین کارایی را در پیش بینی سختی ( $R^2p=0/878$ ,  $RMSEp=2606752$  و  $RPD=2/12$ ) بروز داد و توانست انسجام موزارالا را با کارائی بالاتری نسبت به سایر الگوریتم ها پیش بینی نماید. رگرسیون خطی چندگانه در پیش بینی چسبندگی کارائی نداشت، اما روش جنگل های تصادفی با عملکرد بالا این ویژگی را پیش بینی نمود ( $R^2p=0/808$ ,  $RMSEp=56749$  و  $RPD=1/90$ ). شبکه عصبی پرسپترون چندلایه با کمترین خطا، توانست فنریت ( $R^2p=0/84$ ,  $RMSEp=111721$  و  $RPD=2/12$ ) و قابلیت جویدن ( $R^2p=0/84$ ,  $RMSEp=111721$  و  $RPD=1/96$ ) موزارالا را با عملکرد مناسب پیش بینی نماید. تمام روش ها به جز جنگل های تصادفی توانستند با کارائی بالا حالت صمغی را پیش بینی کنند. در این مطالعه مشخص شد عوامل فرایند تأثیر معنی داری بر ویژگی های بافتی داشتند و روش تصویربرداری فراطیفی یک روش جایگزین مناسب برای تخمین ویژگی های بافتی پنیر موزارالا تشخیص داده شد.

## تاریخ های مقاله :

تاریخ دریافت: ۱۴۰۲/۷/۱۵

تاریخ پذیرش: ۱۴۰۲/۹/۱

## کلمات کلیدی:

موزارالا کم چرب،  
ویژگی های بافتی،  
تصویربرداری فراطیفی،  
یادگیری ماشین

DOI:10.22034/FSCT.21.151.13.

\* مسئول مکاتبات:

[kashani@gau.ac.ir](mailto:kashani@gau.ac.ir)

## ۱- مقدمه

موزارلا متعلق به خانواده پاستافیلاتا است که در لغت به معنای خمیر ریسیده<sup>۱</sup> یا لخته کشش داده شده است. این مفهوم، به یک فرایند انعطاف‌پذیر و کشش منحصر به فرد اشاره دارد که بین همه پنیرهای این خانواده مشترک است و به این گروه متنوع، هویت مشترک می‌دهد. پس از ایجاد لخته در عملیات مرسوم، مهمترین مرحله، عملیات مکانیکی - حرارتی است که طی آن لخته چداری شده در آب داغ کشسانی و حرارت‌دهی شده، به حالت پلاستیکی درآمده و شکل پنیر موزارلا را به خود می‌گیرد [۱]. در میان انواع پنیر این خانواده، موزارلای بدون چربی و با رطوبت کم بیشترین سهم مصرف را به خود اختصاص داده که به‌عنوان تاپینگ پیتزا مورد مصرف قرار می‌گیرد. گرچه در حال حاضر هیچ استاندارد بین‌المللی تعریف شده‌ای برای پنیر کم‌چرب وجود ندارد، کمسیون بین‌المللی کدکس حداقل کاهش برابر ۵۰٪ چربی در ماده خشک را برای تولید یک پنیر کم‌چرب مدنظر قرار داده است [۲]. چربی موجود در پنیر موزارلا با ایجاد یک اثر روان‌کنندگی در هنگام ذوب به عملکردهایی مانند کشش و روان شدن کمک می‌کند؛ اما مصرف بیش‌ازحد چربی در رژیم غذایی ممکن است در بروز برخی از بیماری‌ها مانند بیماری‌های قلبی عروقی، چاقی و دیابت نقش داشته باشد. به همین دلیل امروزه، مصرف فرآورده‌های لبنی کم‌چرب طرفداران زیادی پیدا کرده است. باین‌حال، کاهش محتوای چربی در پنیر موزارلا کیفیت و عملکرد کلی آن را تحت تأثیر قرار می‌دهد [۳، ۴، ۵، ۶، ۷]. از سویی دیگر، پنیر یک محصول گران‌قیمت است و همین موضوع سبب شده است محققین و تولیدکنندگان به سمت یافتن و معرفی روش‌های اصلاح بافت این محصول و راهکارهای نوین در این رابطه هستند. ویژگی‌های بافتی موزارلا شامل سختی، چسبندگی، فنریت، انسجام، حالت صمغی و قابلیت

جویدن تحت تأثیر عوامل متعددی از قبیل چربی، رطوبت، مدت‌زمان ماندگاری، شرایط پخت، ترکیب اولیه شیر، میزان کلسیم پنیر و روش تولید قرار می‌گیرند؛ اما هنگامی که رطوبت و چربی در ماده خشک موزارلا بالا می‌رود، این ویژگی‌ها بهبود می‌یابند [۸، ۹، ۱۰، ۱۱].

باین‌حال شکل‌گیری ساختار پنیر در بخش پخت، مستقیماً تحت تأثیر دمای پخت و نیروهای برشی اعمال‌شده در طول فرآیند عملیات خاص مکانیکی - حرارتی و شرایط اعمال نیروی برشی بر روی لخته نیز قرار می‌گیرد [۱۱]. در این رابطه، با وجود آنکه برخی محققین مانند Yu و Gunasekaran (۲۰۰۵) و Mulvaney و همکاران (۱۹۹۷) و Banville (۲۰۱۶)، ثابت کردند که افزایش دما و تشدید عملیات مکانیکی سبب افزایش فنریت موزارلا می‌شود، در مطالعه‌ای که Merrill و همکاران (۱۹۹۴) انجام دادند، پیش - اسیدی کردن شیر، کاهش دمای پاستوریزاسیون و کشسانی لخته به مدت ۲ دقیقه در آب پخت، منجر به کاهش سختی و لاستیکی بودن موزارلای کم‌چرب گردید [۱۲، ۱۳، ۱۴، ۱۵].

ویژگی‌های بافتی موزارلا توسط روش‌های رایج همانند تجزیه و تحلیل مشخصات بافت، آزمایش‌های فشرده‌سازی و پانکچر کردن قابل اندازه‌گیری است. اما این آزمون‌ها را نمی‌توان به‌طور روتین در صنعت به کار گرفت. زیرا وقت‌گیر، مخرب و اغلب تجربی می‌باشند. همچنین تنها برای ارزیابی یک نمونه قابل‌استفاده هستند. از سویی دیگر ارزیابی‌های حسی نیز وابسته به ادراکات حسی پانلیست‌ها بوده و خسته‌کننده، پرهزینه و زمان‌بر می‌باشند [۱۶، ۱۷، ۱۸]. از این‌رو روش‌های جدید غیر مخرب، مانند رنومترهای ارتعاشی، طیف‌سنجی مادون قرمز مرئی/نزدیک/میانه رزونانس مغناطیسی هسته‌ای و سامانه‌های بینایی رایانه‌ای، برای ارزیابی خواص مواد غذایی در حال ظهور هستند. این روش‌های غیر مخرب، ارزیابی آنلاین کارآمد غذا را

1- "Spun paste" or Stretched Curd

و تجزیه و تحلیل سریع تصاویر فرا طیفی و در برخی موارد ایجاد یک کتابخانه طیفی این امکان فراهم شده است تا کل سیستم تصویربرداری فرا طیفی بتواند به صورت آنلاین و بلادرنگ کار کند. این الگوریتم‌ها با کاهش زمان و فرایند محاسبات، سبب بهبود عملکرد مدل شده و با کاهش متغیرهای نامربوط و داده‌های پرت در قالب افزودگی به استحکام مدل کمک می‌کنند [۲۷، ۲۸].

از آنجا که تا کنون مطالعه‌ای در مورد مدل‌سازی پیش-بینی ویژگی‌های بافتی در پنیر موزارلای کم‌چرب به کمک روش غیر تخریبی تصویربرداری فراطیفی با استفاده از الگوریتم‌های یادگیری ماشین انجام نشده است، در این تحقیق پس از تولید موزارلای کم‌چرب و بررسی تأثیر عملیات مکانیکی-حرارتی و عوامل فرایند بر ویژگی‌های بافتی، خصوصیات بافتی پنیر موزارلای کم‌چرب شامل سختی، چسبندگی، فنریت، انسجام، حالت صمغی و قابلیت جویدن، با استفاده از تصویربرداری فراطیفی مدل‌سازی و مورد پیش‌بینی قرار گرفت.

## ۲- مواد و روش‌ها

### ۲-۱- تولید موزارلای کم‌چرب

تولید پنیر بر اساس روش اصلاح شده Ah و Tagalpallewar (۲۰۱۷)، MCMahon و همکاران (۱۹۹۶) و Jahani و Azar (۲۰۱۶) در سه فرمولاسیون، با افزودن کنسانتره پروتئینی آب پنیر (۵/۵ گرم در کیلوگرم؛ لاکتومین ۸۰<sup>۹</sup> از تهیه شده از شرکت لاکتوپروت آلمان) به عنوان جانشین چربی، کازئینات سدیم (۱/۰ درصد) به عنوان امولسیفایر و اسیدسیتریک (۲۰ درصد) برای پیش‌اسیدی کردن شیر در بهره‌های ۱۰ لیتری، در شرکت شیر پاستوریزه پگاه گلستان آغاز شد [۲۹، ۹، ۳۰]. لخته‌های موزارلا با استفاده از آغاز گر ترموفیل مخصوص انواع پنیر پاستافیلاتا و موزارلا<sup>۶</sup> شامل باکتری‌های «ستریپتوکوکوس ترموفیلوس و لاکتوباسیلوس هلویتیکوس» از شرکت کریستین هانسن

امکان‌پذیر می‌کند. برخی از این روش‌های غیر مخرب، از جمله روش‌های مبتنی بر سامانه‌های بینایی رایانه‌ای، مانند تصویربرداری فرا طیفی<sup>۲</sup> برای ارزیابی بافت پنیرهای نیمه سخت در دوران رسیدن مورد آزمون قرار گرفته‌اند [۱۹، ۲۰، ۲۱]. این روش علاوه بر ارائه اطلاعات شیمیایی و مولکولی (آب، چربی، پروتئین و غیره) ویژگی‌های فیزیکی و ریخت‌شناسی نمونه‌های غذا (رنگ، اندازه، شکل و بافت) را در سطح پیکسل ثبت می‌کند. بدین ترتیب که با شناسایی باندهای ملکولی با کمک مادون قرمز، ردپای این ترکیبات در ارتباط با ویژگی‌های خاص ماده غذایی قابل ثبت کردن می‌باشد [۲۲، ۱۸، ۲۳، ۲۴]. سیستم تصویربرداری فرا طیفی در محدوده مرئی و نزدیک مادون قرمز ۱۰۰۰-۴۰۰ نانومتر بیشترین کاربرد را در تجزیه و تحلیل مواد غذایی دارد [۲۵]. سامانه تصویربرداری فرا طیفی با استفاده از طیف مادون قرمز یکی از کارآمدترین روش‌های نوین است که با کمک پرتو مادون قرمز هم اطلاعات طیفی را فراهم می‌کند و هم با مجهز شدن به یک دوربین CCD، داده‌های مکانی موردنظر را نیز در اختیار قرار می‌دهد. [۲۶]. بر همین اساس، Darnay و همکاران (۲۰۱۷) این امکان را با بررسی تأثیر آنزیم ترانس گلوتامیناز بر روی ویژگی‌های پنیر نیمه سخت توسط فناوری تصویربرداری فرا طیفی مورد مطالعه قرار داده و با کمک رگرسیون حداقل مربعات جزئی<sup>۳</sup> و رگرسیون مؤلفه‌های اصلی<sup>۴</sup>، طول موج‌های مؤثر در پیش‌بینی ویژگی‌های بافتی را به کمک تجزیه و تحلیل مشخصات بافت تعیین نمودند [۲۳]. همچنین، سختی پنیر موزارلا با کمک رگرسیون حداقل مربعات جزئی و شبکه عصبی مصنوعی توسط Vásquez و همکاران (۲۰۱۸) تخمین زده شد و نتایج این پژوهش کارایی تصویربرداری فرا طیفی را به منظور پیش‌بینی خواص بافتی پنیر سوئیسی اثبات نمود [۱۸].

یادگیری ماشین شامل الگوریتم‌هایی است که توانایی یادگیری از داده‌ها را بدون تکیه بر برنامه‌نویسی صریح دارند. با گسترش روش‌های یادگیری ماشین در طول دهه‌های اخیر

5- Lactomin80

6- TCC-20

2- Hyper Spectral Imaging (HIS)

3- Partial Least Square Regression (PLSR)

4- Principal component regression (PCR)

دانمارک و آنزیم رنت میکروبی کالزاکلمته<sup>۷</sup> بر پایه کپک موکور<sup>۸</sup> بود که از شرکت کالزا ایتالیا تهیه شد. با کمک اسیدسیتریک و تا رسیدن به pH=5/1، در سرعت ثابت ماریچ (حدود 8-10 RPM) و دمای ثابت آب داغ، یک دسته از لخته‌های موزارلا در مدت‌زمان ۸ الی ۱۰ دقیقه [۶، ۳۱، ۲۹] و دسته دیگر در مدت‌زمان ۲ دقیقه (۱۰) در آب داغ °۸۲C ورز داده شدند. سپس از ۳۶ نمونه پنیر، نیمی به دمای °۴C منتقل و نیمی دیگر بلافاصله بعد از تولید در دمای °۱۸C منجمد و همه نمونه‌ها به مدت ۷ روز نگهداری شدند.

## ۲-۲- تجزیه و تحلیل مشخصات بافت (TPA)

ویژگی‌های بافتی موزارلای کم‌چرب بر اساس روش اصلاح یافته Gimenez و همکاران (۲۰۲۳) و به کمک دستگاه تحلیل‌گر بافت موجود در دانشگاه علوم کشاورزی و منابع طبیعی گرگان (A TA.XT Plus (kg, Stable (Microsistem, UK) به عنوان مقادیر واقعی و جهت مقایسه با روش تصویربرداری فراطیفی تعیین شدند. پس از قرارگیری در دمای محیط (°۲۵C) و رسیدن به تعادل دمایی، ۳ قطعه نمونه از بخش‌های مختلف قالب گرد پنیر به اندازه-های ۱/۵Cm × ۲/۲Cm × ۳/۴Cm (طول، عرض، ضخامت) در زیر پروب استوانه‌ای (قطر ۳۶ میلی متر) دستگاه قرار داده و تا ۳۰ درصد ارتفاع اولیه با سرعت ۱ میلی متر بر ثانیه فشرده شدند. سختی (بیشترین نیرو در اولین چرخه فشرده‌سازی)، انسجام (نسبت مساحت ناحیه گاز زدن مثبت دوم به مساحت ناحیه گاز زدن مثبت اول)، چسبندگی (ناحیه نیروی منفی در گاز زدن اول)، فنریت (ارتفاعی که نمونه به آن بازگشت می‌کند)، حالت صمغی (حاصل ضرب سختی و میزان انسجام) و قابلیت جویدن (حاصل ضرب حالت صمغی و فنریت) با استفاده از نرم‌افزار دستگاه (Exponent

## ۳-۲- اخذ تصاویر فراطیفی

بر اساس روش Shan و همکاران (۲۰۲۰) مشخصات طیفی همان نمونه‌هایی که مشخصات بافتی آنها سنجش گردید، با استفاده از دستگاه تصویربرداری رومیزی فراطیفی مرئی-مادون قرمز نزدیک با سرعت ۱۰۰ فریم بر ثانیه مدل HSI-Vis-NIR-100fps مجهز به یک دوربین CCD واقع در آزمایشگاه شرکت دانش‌بنیان پرتو افزار صنعت مستقر در پارک علم و فن آوری زنجان تعیین و در نرم‌افزار دستگاه (LabView V8.6) ثبت و ذخیره گردید. هر یک از تصاویر ذخیره‌شده در داخل پوشه دارای دو بُعد بودند که X بُعد مکانی اول و λ بُعد طیفی است. در این شرایط با حرکت سکوی حمل و ثبت تصاویر متوالی از نمونه، بُعد مکانی دوم یعنی Y به دست آمده و بدین ترتیب ابرمکعب با سه بُعد ساخته شد [۱۹، ۳۳، ۳۴].

## ۴-۲- پیش‌پردازش داده‌های طیفی

جهت استخراج داده‌های طیفی به صورت طول موج قابل شناسایی توسط الگوریتم‌های توسعه مدل، ناحیه مورد نظر<sup>۹</sup> با استفاده از الگوریتم تشخیص لبه اُتسو<sup>۱۰</sup>، [۳۵]، ریخت-شناسی و عملیات فرسایش [۳۶] و ترسیم کانتور، انتخاب گردید. داده‌های طیفی به‌عنوان متغیر مستقل X و خصوصیات بافتی و عملکردی به‌عنوان متغیر وابسته Y در نظر گرفته شدند [۳۷، ۱۸، ۳۸، ۳۹، ۴۰]. به منظور کاهش نویز و پراکندگی‌های ناخواسته و پس از تعیین متغیرهای پنهان<sup>۱۱</sup>، ۶ روش پیش‌پردازش (هموارسازی با فیلتر ساویتزکی گولی، مشتق درجه اول همراه با فیلتر ساویتزکی گولی، مشتق درجه دوم همراه با فیلتر ساویتزکی گولی، تصحیح پراکندگی چندگانه، متغیر نرمال استاندارد و یک روش تصحیح طول‌موج چندجمله‌ای مرتبه دوم) با توسعه

10- Otsu-Canny edge detection algorithm  
11-Latent Variable (LV)

7- ASTROMICROBIAL2700G  
8- *Rhizomucor Miehei*  
9- Region of Interest (ROI)

ترسیم گردید. بدین منظور از طول موج کامل<sup>۲۱</sup> استفاده شد [۴۳، ۴۴، ۴۵، ۴۶، ۴۷، ۴۸، ۴۹، ۵۰، ۵۱].

یک مدل رگرسیون حداقل مربعات جزئی<sup>۱۲</sup> برای هر یک از ویژگی‌های بافتی با یکدیگر به رقابت گذاشته شدند.

## ۲-۵- توسعه مدل‌های رگرسیونی با استفاده از

### روش‌های یادگیری ماشین

در ابتدا مدل‌های کالیبراسیون اولیه با طیف خام ایجاد شد و دقت مدل‌ها در پیشگویی ویژگی‌های بافتی و عملکردی تخمین زده شد. پس از اطمینان از کارایی مناسب الگوریتم‌های انتخاب‌شده، روش‌های انتخاب ویژگی (رگرسیون بتا، الگوریتم ژنتیک، وزن دهی پیش‌بینی کننده تکراری حداقل مربعات جزئی<sup>۱۳</sup>، تجزیه و تحلیل جایگشت پنجره فرعی همراه با حداقل مربع جزئی<sup>۱۴</sup> و جنگل‌های تصادفی<sup>۱۵</sup>) با توسعه یک مدل PLSR برای هر یک از ۸ خصوصیت بافتی و عملکردی به رقابت گذارده شد و هر روشی که با طول موج‌های منتخب، برازش بیشتری با مدل ایجاد نمود، به عنوان روش بهینه برای انتخاب طول موج‌های مؤثر، برگزیده شد [۴۱، ۴۲، ۴۴]. این مراحل برای تک تک ویژگی‌های بافتی و عملکردی، تکرار شد. سپس با وارد کردن طول موج‌های جداسازی شده، مدل‌های مختلف کالیبراسیون توسط روش‌های یادگیری ماشین (رگرسیون خطی چندگانه<sup>۱۶</sup>، رگرسیون حداقل مربعات جزئی (PLSR)، ماشین بردار پشتیبان همراه کرنل خطی<sup>۱۷</sup>، شبکه عصبی پرسپترون چندلایه<sup>۱۸</sup> و الگوریتم رأی اکثریت<sup>۱۹</sup> با ادغام مدل‌های MLR، SVM، RF و مطابق معادله شماره (۱) توسعه داده شدند. قبل از توسعه مدل‌ها، نمونه‌های موزارلای تولیدی طبق الگوی بازتابش طیفی بر اساس عوامل فرایند و به کمک تجزیه و تحلیل مؤلفه‌های اصلی<sup>۲۰</sup> دسته‌بندی شدند. به عبارت دیگر برای پاسخ به این پرسش که آیا تصویربرداری فرا طیفی توانسته است تفکیک طیفی بر اساس عوامل یادشده ایجاد نماید یا خیر، نمودارهای بازتابش بر اساس طول موج برای هر یک از متغیرهای مذکور با استفاده از ماژول پایتون

$$f(VR) = f_{MLR} + f_{SVML} + f_{RF} \quad \text{معادله شماره (۱)}$$

## ۲-۶- تجزیه و تحلیل آماری و اعتبارسنجی مدل‌ها

از آنجایی که تنظیم نمونه‌ها بر اساس روش فاکتوریل صورت گرفته و سنجش تأثیر هم‌زمان چند متغیر مستقل بر روی چند متغیر وابسته مدنظر بوده است، از تجزیه و تحلیل داده‌ها به صورت طرح کاملاً تصادفی در قالب فاکتوریل با روش GLM و تجزیه و تحلیل واریانس تک متغیره<sup>۲۲</sup> در نرم افزار IBM SPSS Statistics، 26 جهت مقایسه میانگین-ها از آزمون تعقیبی حداقل اختلاف معنی داری (LSD) در سطح معنی داری  $\alpha=0/05$  استفاده شد. همچنین به منظور پردازش داده‌های طیفی<sup>۲۳</sup> از ماژول Pandas و NumPy، انتخاب ناحیه مورد نظر (ROI) از ماژول OpenCv، الگوریتم‌های یادگیری ماشین از ماژول Scikit Learn و جهت ترسیم نمودارها از Matplotlib در نرم افزار پایتون استفاده شد. پس از توسعه مدل‌های کالیبراسیون، جهت اعتبارسنجی مدل‌ها با استفاده از روش اعتبارسنجی متقابل چندلایه<sup>۲۴</sup>، داده‌ها به دو بخش آموزش و آزمایش تقسیم شده و مدل‌ها آموزش داده شدند. بدین ترتیب که اعتبارسنجی با محاسبه میانگین مربعات خطای مربوط به داده‌های آزمایش آغاز و بخش دوم با ۱۵ داده تصادفی دیگر به عنوان داده آزمایش در نظر گرفته شد و مدل با ۸ بخش باقیمانده آموزش گرفت و میانگین مربعات خطا مجدداً برای بخش دوم محاسبه شد. سپس خطای مربعات، برای کل مجموعه  $(k=10)$  حساب شد و برای به دست آوردن خطای کل مدل، متوسط میانگین مربعات خطای به دست آمده در هر بخش محاسبه گردید [۳۴، ۵۲، ۵۳]. در نهایت پس از تنظیم

18- Multilayer Perceptron Neural Network (MLPNN)  
19- Majority Vote Regression Algorithm (VOTING)  
20- Principal Component Analysis (PCA)  
21- Full Spectrum  
22- Univariate Analysis  
23- Data manipulation  
24- K-fold Cross Validation

12- Partial Least Squares Regression (PLSR)  
13- Iterative predictor weighting Partial Least Square (IPW-PLS)  
14- Sub-window permutation analysis Coupled with PLS (SwPA-PLS)  
15- Random Forest  
16- Multiple Linear Regression (MLR)  
17- Support Vector Machine (SVML)

امکان‌پذیر است و مقداری بین ۳ و ۵ یا بالاتر به ترتیب با دقت پیش‌بینی خوب و عالی مطابقت دارد [۵۲، ۳۴]. این مقدار از طریق معادله زیر قابل محاسبه است:

$$RPD = \frac{SD}{RMSEP} \quad \text{معادله شماره (۴)}$$

### ۳- نتایج و بحث

#### ۳-۱- تأثیر نوع فرمولاسیون بر ویژگی‌های بافتی

نتایج تأثیر فرمولاسیون‌های مختلف بر ویژگی‌های بافتی و عملکردی پنیر موزارلای تولیدی در جدول ۱ آورده شده است. نتایج نشان داد که سختی و قابلیت جویدن در تمامی نمونه‌ها تفاوت معناداری داشت ( $P < 0/05$ ). اما بر اساس آزمون حداقل تفاوت معنی‌داری، اختلافات میانگین ویژگی‌ها در تمام نمونه‌ها معنی‌دار نبود ( $P > 0/05$ ). بر اساس تفاوت در نوع فرمولاسیون، چربی نقش تعیین‌کننده‌ای در تفاوت ویژگی‌های بافتی داشت. به‌نحوی که نمونه شاهد کم‌چرب کمترین چسبندگی و شاهد پرچرب بیشترین چسبندگی را بروز داد و کمترین میزان سختی مربوط به نمونه پرچرب حاوی اسید (B) و بیشترین میزان سختی مربوط به نمونه کم‌چرب شاهد (C) بود. اختلاف معنی‌دار میان نمونه‌های پرچرب و کم‌چرب در حالت صمغی نیز مشاهده گردید ( $P < 0/05$ ). این نتیجه با یافته‌های Esen و همکاران (۲۰۲۳) مطابقت داشت [۵۴]. در حقیقت از آنجایی که چربی ماتریکس پروتئین را شکسته و نقش روان‌کننده دارد، نرمی و بافت نرم‌تری ایجاد می‌کند ( $P > 0/05$ ). این موضوع با نتایج مطالعه To و همکاران (۲۰۲۰)، همسو بود. آنها اظهار کردند تزریق  $CO_2$  سبب کاهش pH تا ۶/۲ موجب حفظ رطوبت و کاهش سختی پنیر موزارلا شد [۵۵]. همچنین همراستا با نتایج مطالعات متعدد [۱۵، ۵۵، ۴، ۳، ۳۱] که افزودن اسیدهای آلی را به‌عنوان یکی از روش‌های اصلاح ساختار و بافت پنیر موزارلای کم‌چرب معرفی کرده‌اند، اسیدسیتریک سختی، فنری و انسجام نمونه‌ها را کاهش داد. زیرا برابر تحقیقات انجام شده، افزودن اسید سبب کاهش کلسیم و افزایش پروتئولیز در طی دوره نگهداری شده و از

فرآیندهای مدل، به منظور ارزیابی کارایی مدل‌ها از آماره‌های زیر استفاده شد:

#### ۲-۶-۱- ریشه میانگین مربع خطا برای پیش‌بینی

از این آماره به‌عنوان تقریبی از میزان خطای مدل در مقادیر پیش‌بینی شده نسبت به مقادیر واقعی اندازه‌گیری شده استفاده می‌گردد که از طریق رابطه زیر محاسبه می‌شود.

$$RMSEP = \sqrt{\frac{\sum_i^N = 1 (\hat{y}_i - y_i)^2}{N}} \quad \text{معادله شماره (۲)}$$

که در آن  $N$  تعداد نمونه،  $\hat{y}_i$  مقدار پیش‌بینی شده هر پارامتر برای نمونه  $i$  ام و  $y_i$  مقدار اندازه‌گیری شده برای نمونه  $i$  ام می‌باشد.

#### ۲-۶-۲- ضریب تعیین

این آماره به‌منظور ارزیابی میزان همبستگی میان مقادیر پیش‌بینی و مقادیر واقعی مورد استفاده قرار می‌گیرد. مقدار ضریب تبیین بین «صفر» و «یک» قرار دارد و هرچه به ۱ نزدیک‌تر باشد نشان می‌دهد که درصد بیشتری از تغییرات داده‌ها، توسط مدل رگرسیونی و درصد کمتری توسط خطاهای تصادفی (نویز) قابل پیش‌بینی است که از طریق رابطه زیر قابل محاسبه است:

$$R^2 = 1 - \left(\frac{RMSEP}{SD}\right)^2 \quad \text{معادله شماره (۳)}$$

که در آن  $SD$  میزان انحراف معیار را نشان می‌دهد. در این مطالعه شاخص ضریب تعیین با مقدار  $R^2$  گزارش شد.

#### ۲-۶-۳- انحراف پیش‌بینی باقیمانده

مقدار انحراف پیش‌بینی باقیمانده با نسبت انحراف استاندارد متغیر پاسخ به  $RMSEP$  یا  $RMSECV$  تعریف می‌شود.  $RPD$  بین ۱/۵ و ۲ به این معنی است که مدل می‌تواند مقادیر کم و زیاد واریانس متغیر پاسخ را تشخیص دهد. مقدار بین ۲ و ۲/۵ نشان می‌دهد که پیش‌بینی‌های کمی بهتر

این طریق سبب کاهش سختی پنیر موزارلا می‌گردد. به عبارت دیگر، اسیدی شدن مستقیم شیر باعث جدا شدن کلسیم و سایر مواد معدنی (فسفر و منیزیم) از میسل‌های کازئین شده و این امر منجر به تورم و آب‌گیری بیشتر ماتریکس پاراکازئین بعد از گذشت یک روز از تولید پنیر می‌شود. همچنین افزودن کنسانتره پروتئینی آب پنیر و کازئینات سدیم سبب کاهش سختی، فنریت، انسجام و قابلیت جویدن شد. اما موزارلای کم‌چرب تولید شده با این ترکیبات، حالت صمغی و چسبندگی بالاتری داشت. این موضوع با نتایج مطالعه Amador-Espejo و همکاران (۲۰۲۱) و Abd Elkader و همکاران (۲۰۱۹)، Ismail و همکاران (۲۰۱۱)، Zisu و Shah (۲۰۰۵)، Nateghi و همکاران، ۲۰۱۵ مطابقت داشت [۵۶، ۵۷، ۵۸، ۵۹]. زیرا افزودن کنسانتره پروتئینی آب پنیر به همراه ترکیبات روان‌کننده از طریق بالا بردن رطوبت و حالت روان‌کنندگی یا خامه‌ای، خصوصیات بافتی را بهبود می‌بخشد.

**Table 1.** The effect of different treatments on the textural and functional characteristics of mozzarella cheese

Treatments	Textural & Functional Properties					
	Hardness	Adhesiveness	Springiness	Cohesiveness	Gumminess	Chewiness
(A)	4498.4 <sup>b</sup> ±612.58	187.78 <sup>a</sup> ±45.66	0.506 <sup>f</sup> ±0.05	0.301 <sup>f</sup> ±0.12	1439 <sup>g</sup> ±245.92	919.9 <sup>h</sup> ±217.95
(B)	1766.4 <sup>a</sup> ±140.85	181.14 <sup>b</sup> ±27.97	0.392 <sup>g</sup> ±0.01	0.231 <sup>g</sup> ±0.006	496.8 <sup>b</sup> ±31.38	192 <sup>a</sup> ±17.15
(C)	13613.7 <sup>a</sup> ±1304.63	2.31 <sup>g</sup> ±0.20	0.748 <sup>d</sup> ±0.05	0.391 <sup>d</sup> ±0.20	4797.87 <sup>d</sup> ±337.48	3650.72 <sup>f</sup> ±428.11
(D)	11056.5 <sup>f</sup> ±962.26	31.32 <sup>d</sup> ±9.94	0.665 <sup>e</sup> ±0.26	0.48 <sup>a</sup> ±0.12	4282.63 <sup>f</sup> ±623.02	2351.65 <sup>g</sup> ±338.08
(E)	14584.4 <sup>b</sup> ±756.41	12.93 <sup>e</sup> ±0.70	0.838 <sup>b</sup> ±0.15	0.402 <sup>c</sup> ±0.20	6334.06 <sup>c</sup> ±464.85	5063.14 <sup>b</sup> ±475.49
(G)	11156.3 <sup>c</sup> ±830.4	9.62 <sup>f</sup> ±1.04	0.774 <sup>c</sup> ±0.29	0.447 <sup>b</sup> ±0.24	6397.36 <sup>b</sup> ±988.41	4321.73 <sup>c</sup> ±472.12
(J)	12775.1 <sup>d</sup> ±713.93	2.88 <sup>g</sup> ±0.24	0.845 <sup>a</sup> ±0.004	0.347 <sup>e</sup> ±0.16	4360.98 <sup>e</sup> ±71.15	3733.99 <sup>d</sup> ±66.42
(K)	9759.35 <sup>g</sup> ±726.49	39.83 <sup>c</sup> ±19.66	0.791 <sup>b</sup> ±0.20	0.394 <sup>c</sup> ±0.03	4346.23 <sup>e</sup> ±514.84	3691.24 <sup>e</sup> ±535.53
(L)	17459.5 <sup>a</sup> ±726.49	2.47 <sup>g</sup> ±0.24	0.837 <sup>a</sup> ±0.004	0.391 <sup>d</sup> ±0.23	7361.95 <sup>a</sup> ±218.39	5638.74 <sup>a</sup> ±177.63

Numbers with the same letters in each column have no significant difference at the 5% significance level (P<0.05). Adjusted R squared for univariate analysis in all variables= 0.964.

(A): Control High Fat; (B): Control Low Fat; (C): Control Low Fat; (D): Control Low Fat + Acid; (E): Control Low Fat + Acid + Caseinate; (G): Control Low Fat + Acid + WPC; (J): Control Low Fat + WPC; (K): Control Low Fat + WPC + Caseinate

کردند که شدت عملیات حرارتی با افزایش سرعت ماریچ، افزایش یافته، به گونه‌ای که در سرعت بالا و تنش برش بالاتر، ممکن است لخته دچار فروپاشی شده و فرصت کافی برای رسیدن به دمای لازم برای کشسانی مناسب را پیدا نکند [۱۳]. از سوی دیگر، نتایج مشخص نمود که انجماد به سبب آسیب ساختاری در پنیر باعث افزایش سختی، انسجام، فنریت گردید. این نتایج یافته‌های به دست آمده در مورد ویژگی سختی را تأیید نمود. زیرا پنییری که سخت‌تر بود، بات منسجم‌تر و فنریت بالاتری داشت. این نتایج با یافته‌های Tunik و همکاران (۱۹۹۱)، Alinovi و همکاران، ۲۰۲۰، Topcu و همکاران (۲۰۲۰)، Esen و همکاران (۲۰۲۳) همسو بود [۶۱، ۶۲، ۶۳، ۵۴].

### ۲-۳- تأثیر تغییر در عملیات مکانیکی-حرارتی و شرایط

#### نگهداری بر ویژگی‌های بافتی

نتایج تجزیه و تحلیل واریانس تک متغیره نشان داد که تأثیر مدت‌زمان کشسانی در آب داغ، دمای نگهداری و نوع فرمولاسیون بر تمام ویژگی‌ها بافتی و عملکردی موزارلای تولیدی معنی‌دار بود (P < ۰/۰۵). به طوری که با افزایش مدت زمان کشسانی در آب داغ و به عبارت دیگر، تشدید عملیات مکانیکی-حرارتی، سختی، انسجام، فنریت و قابلیت جویدن افزایش یافت. همسو با این یافته‌ها، Kindstedt و همکاران (۱۹۹۲)، با ثابت نگه‌داشتن دمای پخت، ثابت کردند که در سرعت کمتر ماریچ، سختی موزارلا کاهش یافت [۶۰]. درحالی که Mulvaney و همکاران (۱۹۹۷) بیان

### ۳-۳- نتایج دسته‌بندی پنیر موزارلا بر اساس داده‌های طیفی

پس از تصویربرداری فرا طیفی در جستجوی الگوی طیفی در اثر فرایندهای اعمال شده به‌عنوان متغیرهای مستقل، نمودارهای میانگین بازتابش برحسب طول‌موج در اثر فرایندهای یادشده ترسیم گردید (شکل ۱). مشخص شد

عوامل فرایند، همان‌گونه که بر ویژگی‌های بافتی و عملکردی تأثیر معنی‌دار داشتند، توانستند به‌خوبی طیف‌ها را جداسازی نمایند. این موضوع ثابت می‌کند طیف‌ها قادر هستند ویژگی‌های بافتی و عملکردی را تخمین بزنند. نتایج این مطالعه با یافته‌های Shan و همکاران (۲۰۲۰) همسو بود [۳۳]. زیرا آن‌ها نیز توانستند، تمایز طیفی را بر اساس شدت بازتابش در پنیر پروسس مشاهده نمایند.

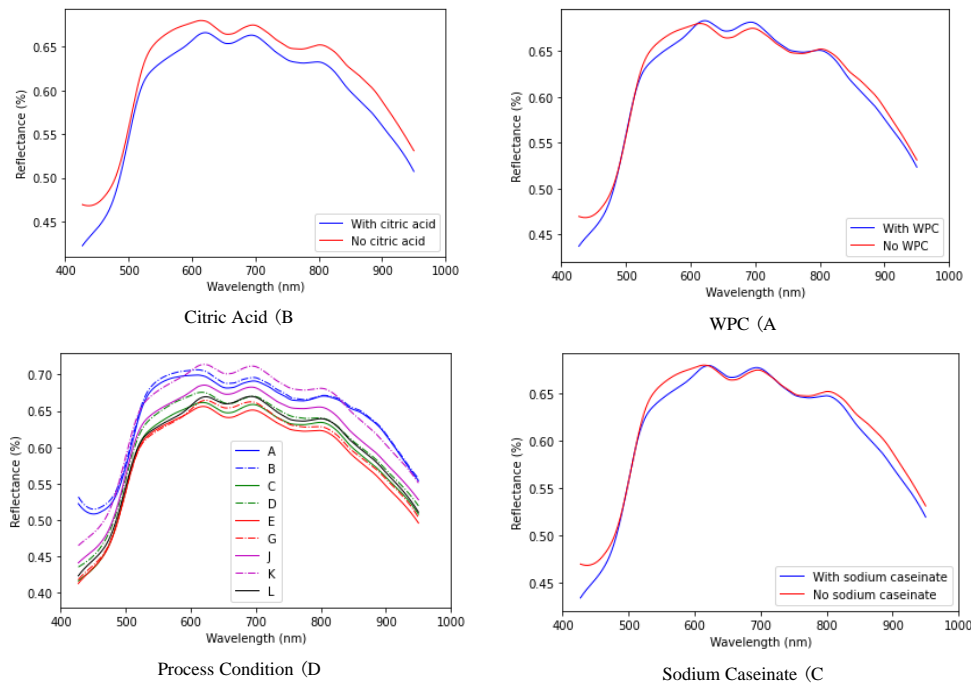



FIG 1. The effect of process conditions on the reflection pattern in mozzarella based on Hyperspectral imaging


دسته‌بندی بر اساس تنوع در فرمولاسیون، به دلیل همپوشانی فرمول ترکیبی در نمونه‌ها به‌راحتی قابل تفکیک نبود. این موضوع به ماهیت تولید و تنظیم فرمولاسیون نمونه‌ها در این تحقیق مربوط است.

با توجه به تفکیک طیفی مشاهده شده در طبقه‌بندی فوق، نتایج طبقه‌بندی نمونه‌های موزارلا بر اساس تجزیه و تحلیل مؤلفه‌های اصلی نشان داد که دسته‌بندی بر اساس چربی از پراکندگی مناسبی برخوردار بوده به‌نحوی که پنیرهای کم-چرب و پرچرب به‌راحتی قابل تفکیک هستند (شکل ۲)؛ اما



(A): Classification of mozzarella cheeses based on fat percentage





(B): Classification of mozzarella cheeses based on treatment formula

FIG 2. Mozzarella cheese classification results using PCA

نتایج رقابت روش‌های پیش‌پردازش برای هر یک از ویژگی‌های بافتی بر اساس مدل PLSR در جدول ۲ آمده است.

۳-۴- نتایج مقایسه روش‌های پیش‌پردازش در داده‌های

طیفی مرتبط با ویژگی‌های بافتی

Table 2. The optimal pre-processing selected method in textural properties of Mozzarella based on PLSR

Textural Properties	Selected Pre-Processing methods	Latent Variable	R <sup>2</sup> c	RMSEc	R <sup>2</sup> p	RMSEp
Hardness	SG_Smoothing	7	0.855	2867.115	0.846	2911.290
Adhesiveness	SG_FD	4	0.802	57.480	0.809	56.390
Springiness	SG_Smoothing	9	0.890	0.081	0.850	0.094
Cohesiveness	SNV-Detrend	4	0.644	0.076	0.654	0.071
Gumminess	SNV	9	0.842	1473.950	0.835	1446.520
Chewiness	MSC	12	0.920	836.013	0.817	1186.170

به‌طور مشابه، Jajromi و همکاران (۲۰۱۵)، روش‌های پیش‌پردازش متعدد شامل فیلتر ساویتزکی-گولی، تصحیح پراکندگی چندگانه، متغیر نرمال استاندارد، مشتق درجه اول و دوم را با کمک ایجاد یک مدل PLSR، جهت پیشگویی مواد جامد محلول و اسیدیته لیموترش با یکدیگر مقایسه و ثابت کردند که روش‌های پیش‌پردازش در تبیین مدلی با صحت و دقت بالا به‌منظور پیش‌بینی کیفیت لیموترش تأثیر بالایی دارند [۶۵]. همچنین، هم‌راستا با مطالعات Park و همکاران، ۲۰۲۳؛ Zou و همکاران، ۲۰۲۳، مشخص گردید که روش تصحیح پراکندگی چندگانه (MSC) با حذف تفاوت‌های ناشی از اثرات پراکندگی عملکرد مدل را از طریق افزایش همبستگی بین داده‌های طیفی و متغیرهای پاسخ افزایش داده و به عنوان روش بهینه برای کاهش نویز در

روش هموارسازی با فیلتر ساویتزکی گولی با کارایی بالا به عنوان روش بهینه جهت کاهش نویز برای ویژگی سختی و فنریت برگزیده شد ( $R^2p = 0.846$ ,  $RMSE = 2911.29$ ) و به خوبی بر اعوجاج طیف خام غلبه کرد. در حالی که همین فیلتر به همراه مشتق درجه اول (SG\_FD) به عنوان روش بهینه برای کاهش نویز در داده‌های مرتبط با چسبندگی انتخاب شد. همانند یافته‌های این مطالعه، با کاربرد فیلتر ساویتزکی-گولی، Shafiee و همکاران (۲۰۱۶) با استفاده از چندجمله‌ای دومرتبه‌ای و قرار دادن نقاط همسایگی برابر با ۳ در فیلتر ساویتزکی-گولی، توانستند تقلبات عسل را با ایجاد مدل و تصویربرداری فرا طیفی شناسایی کنند [۶۴].

### ۳-۵- نتایج توسعه مدل‌های کالیبراسیون جهت پیش‌بینی

#### ویژگی‌های بافتی

در این مطالعه پس از جداسازی طول موج‌های مؤثر برای هر یک از ویژگی‌ها با الگوریتم‌های انتخاب ویژگی، مدل‌های کالیبراسیون با طول موج‌های مهم، برای هر یک از ویژگی‌های بافتی توسعه داده شدند.

#### ۳-۵-۱- سختی

نتایج ارزیابی روش‌های یادگیری ماشین در مورد پیش‌بینی سختی پنیر موزارلای تولیدی با استفاده از طول موج‌های جداسازی شده در جدول ۳ به نمایش در آمده است. نتایج حاکی از آن بود که در نتیجه استفاده از روش‌های یادگیری ماشین مذکور مدلی به دست آمد که در قالب آن الگوی طیفی پنیر موزارلای تولیدی در این تحقیق به خوبی ویژگی سختی پنیر را پیش‌بینی نمود. زیرا همان‌گونه که از جدول مشخص است، تمامی روش‌های یادگیری ماشین توانسته‌اند با دقت مناسب، ویژگی بافتی سختی را به کمک مدل‌های توسعه داده‌شده پیش‌بینی نمایند؛ اما مدل توسعه داده‌شده با الگوریتم رأی‌گیری اکثریت، با کمترین خطا، بالاترین کارایی را بروز داده است.

داده‌های طیفی مرتبط با ویژگی مورد قابلیت جویدن برگزیده شد ( $R^2p = 0/817$ ,  $RMSE = 1187/170$ ) [67, 66]. این تفاوت در پراکندگی نور و اثرات نویز با پیچیدگی اندازه ذرات در نمونه‌های بیولوژیک مرتبط است؛ به گونه‌ای که روش‌هایی همانند MSC قادر به حذف پراکندگی از طیف جذبی خالص و مطلوب می‌باشند [68]. با مقایسه روش‌ها، مشخص گردید که روش متغیر نرمال استاندارد بالاترین کارایی را در کاهش نویز داده‌های مرتبط با حالت صمغی بروز داد ( $R^2p = 0/835$ ,  $RMSE = 1447/520$ ). اگرچه مطالعات در این خصوص اندک است، اما مشابه با یافته‌های این تحقیق، پژوهشگرانی همچون Priyashantha و همکاران (2020)، با به کارگیری روش متغیر نرمال استاندارد توانستند زمان رسیدن پنیرهای سخت را با استفاده از یک مدل PLSR و سنجش کارایی آن با استفاده از داده‌های فرا طیفی به خوبی تخمین بزنند [20]. اما بر اساس نتایج مدل PLSR، روش متغیر نرمال استاندارد به همراه تصحیح طول موج چندجمله‌ای مرتبه دوم (Detrend)، بهترین گزینه برای کاهش نویز در ویژگی انسجام بود؛ در حالی که سایر روش‌ها کارایی مناسبی از خود نشان ندادند. زیرا این روش با حذف انحنای خطی و تصحیح تغییر خط مبنا در طیف‌ها سبب افزایش همبستگی داده‌های طیفی و متغیرهای پاسخ و بالارفتن دقت مدل می‌گردد.

**Table 3.** Results of calibration models development on Mozzarella texture using Machine learning algorithms

Textural Properties	Selected wavelengths number	Feature selection algorithm	ML algorithms	$R^2p$	RMSEp	RPDp
Hardness	31	IPW-PLS	MLR	0.826	307.37	1.8
			PLSR	0.844	292.5	1.99
			SVML	0.841	295.7	1.92
			MLPNN	0.868	270.5	2.14
			RF	0.807	322.9	1.71
			VOTING	0.878	260.5	2.22
Adhesiveness	24	Genetic Algorithm	MLR	0.669	71.19	1.36
			PLSR	0.779	60.11	1.81
			SVML	0.746	63.85	1.7
			MLPNN	0.764	61.79	1.78
			RF	0.808	56.49	1.90

Springiness	25	Genetic Algorithm	VOTING	0.772	60.93	1.99
			MLR	0.802	0.106	1.79
			PLSR	0.821	0.102	1.97
			SVML	0.838	0.097	2.05
			MLPNN	0.848	0.094	2.12
			RF	0.725	0.123	1.67
			VOTING	0.826	0.1	1.96
Cohesiveness	32	$\beta$ -Coefficient	MLR	0.581	0.076	1.2
			PLSR	0.661	0.07	1.35
			SVML	0.617	0.074	1.28
			MLPNN	0.66	0.07	1.34
			RF	0.655	0.071	1.34
			VOTING	0.7	0.067	1.91
Gumminess	22	SWPA_PLS	MLR	0.813	1530.67	1.8
			PLSR	0.814	1528.28	1.8
			SVML	0.815	1522.63	1.81
			MLPNN	0.793	1602.22	1.76
			RF	0.56	2177.16	1.22
			VOTING	0.81	1542.5	1.79
Chewiness	27	Genetic Algorithm	MLR	0.813	1198.4	1.79
			PLSR	0.819	1181.3	1.8
			SVML	0.822	1170	1.89
			MLPNN	0.84	1117.2	1.96
			RF	0.468	1817.2	1.14
			VOTING	0.81	1207	1.8

استفاده از تبدیل فوریه مادون قرمز و مدل سازی رگرسیون مربعات جزئی اذعان کردند که استفاده از طیف سنجی مادون قرمز به همراه پردازش تصویر روش قابل اعتمادی برای سنجش مشخصات بافتی پنیر بوده و می تواند به عنوان ابزار اندازه گیری کنترل کیفیت آن مورد استفاده قرار گیرد [۶۲].

بعلاوه نتایج این تحقیق با یافته های Vasquez و همکاران (۲۰۱۸)، همچنین Shan و همکاران (۲۰۲۰) که با به کارگیری مدل رگرسیون مربعات جزئی سختی پنیر را با دقتی برابر  $R^2=0.76$  پیش بینی کردند، مطابقت داشت [۱۸]. [۳۳]

#### ۲-۵-۳- چسبندگی

مطابق نتایج ذکر شده در جدول ۳ و با مشاهده آماره های به دست آمده (ضریب تعیین پیش بینی، انحراف باقیمانده پیش بینی و خطای مربعات پیش بینی)، مشخص گردید که تمامی مدل ها به جز MLR، در پیش بینی چسبندگی، از

الگوریتم رأی گیری اکثریت، در اکثر اوقات دقت بیشتری نسبت به بهترین طبقه بند یا الگوریتم رگرسیونی دارد. زیرا اگر همه الگوریتم ها یک یادگیرنده ضعیف<sup>۲۵</sup> داشته باشند (فقط مقدار کمی بهتر از حدس تصادفی عمل کرده باشند) تجمیع آن ها با یکدیگر یک یادگیرنده قوی<sup>۲۶</sup> تشکیل می دهد [۴۷]. مطابق جدول مذکور، مدل توسعه داده شده با این روش، بالاترین RPD را گزارش کرده است ( $RPD=2/22$ ). یعنی اینکه کارایی بالاتری نسبت به سایر مدل ها در پیش بینی سختی بروز داده است. مشابه با یافته های این پژوهش، Zhou و همکاران (۲۰۲۱)، توانستند دانه های ذرت را با کمک یک مدل سازی شبکه عصبی پیچشی همراه با الگوریتم رأی اکثریت با دقت بالاتر از ۹۸٪ شناسایی کنند [۵۰]. همچنین همسو با تحقیق حاضر، Alinovi و همکاران (۲۰۱۹) در تعیین مشخصات بافتی نوعی از پنیر پروسس با

داده‌ها از میزان مناسبی برخوردار باشد [۲۸]. در این شرایط، هدف از آموزش در این روش، کمینه نمودن خطاست. در این مطالعه، با توجه به تعداد مناسب داده‌های طیفی، همان‌گونه که از جدول فوق مشخص است، MLPNN با خطای مربعات پیش‌بینی اندک، بیشترین انحراف باقیمانده پیش‌بینی و بالاترین ضریب تعیین پیش‌بینی بالاترین کارایی را در میان روش‌های یادگیری ماشین برای پیشگویی فنریت پنیر موزارلای تولیدی را داشته است. در نتیجه این موضوع نشان می‌دهد مدل، به‌خوبی آموزش دیده و انحرافات پیش‌بینی به میزان مناسبی محاسبه گردیده است. نتایج این تحقیق با یافته‌های Ni و همکاران (۲۰۱۹) مطابقت داشت. آن‌ها با طیف‌سنجی فیبر نوری و مقایسه الگوریتم شبکه عصبی پرسپترون چندلایه و شبکه عصبی بازگشتی همراه با مربعات جزئی به این نتیجه رسیدند که MLPNN با دقت بسیار بالاتر (۹۹٪/۹) توانست تردی چپس سیب اندازه‌گیری شده با روش تجزیه و تحلیل بافت را پیش‌بینی نموده و به‌طور مؤثری طول‌موج‌های مهم را در این رابطه جداسازی نماید. همچنین با توجه به جدول، مدل SVM بعد از شبکه عصبی پرسپترون چندلایه بیشترین ضریب تعیین و کمترین خطا را بروز داد. بنابراین این روش یادگیری ماشین نیز، کارایی بسیار خوبی در پیش‌بینی فنریت داشته است. استفاده از کرنل در تقویت روش ماشین بردار پشتیبان توسط محققین مختلف در تجزیه و تحلیل تصاویر فرا طیفی توصیه شده است [۳۴، ۷۱، ۴۷، ۷۲]. زیرا نزدیکی مکانی و همچنین طیفی را برای هموارسازی تصاویر فرا طیفی در نظر می‌گیرد. بنابراین، ماشین بردار پشتیبان قادر خواهد بود هموارسازی بهتری را در ناحیه همگن فراهم کرده و جزئیات تصویر را حفظ نماید که به‌نوبه خود تفکیک‌پذیری بین گروه‌ها را بهبود می‌بخشد. مشابه با روش اعمال شده در مطالعه حاضر، Sahadevan و همکاران (۲۰۱۶) با کاربرد یک کرنل شعاعی بر روی ماشین بردار پشتیبان، اثبات نمودند که این اقدام دقت مدل ایجاد شده را تا بیش از ۹۹٪ افزایش داد [۷۱].

#### ۳-۵-۴- انسجام

کارایی مناسبی برخوردار بودند؛ اما مدل‌های تهیه شده با الگوریتم جنگل‌های تصادفی، رگرسیون حداقل مربعات جزئی و رأی اکثریت کارایی مناسب‌تری را نسبت به سایرین در پیش‌بینی ویژگی بافتی چسبندگی ارائه نمودند. مطالعات در خصوص پیش‌بینی ویژگی بافتی چسبندگی در پنیر و یا استفاده از الگوریتم جنگل‌های تصادفی در برآورد شاخص‌های مواد غذایی با استفاده از تصویربرداری بسیار اندک هستند؛ اما مشابه با مطالعه حاضر، Teixido-Orries و همکاران (۲۰۲۳)، با استفاده از روش رگرسیون حداقل مربعات جزئی، میزان دی اکسی لیوانول موجود در جو را با روش کروماتوگرافی مایع با کارایی بالا را اندازه‌گیری نموده و سپس با کاربرد روش جنگل‌های تصادفی با کارایی مناسب (۰/۷۷/۸) جو آلوده را از جو سالم جداسازی کردند و اذعان داشتند که تصویربرداری فرا طیفی یک ابزار امیدوارکننده برای تشخیص این سم در جو می‌باشد [۶۹]. هم‌راستا با این پژوهش، Pu و همکاران (b2023) مدلی را با استفاده از شبکه عصبی پیچشی و جنگل‌های تصادفی با دقت خوب ( $R^2=0/86/11$ ) جهت پیش‌بینی خواص بافتی گوشت گوساله ارائه نمودند [۱۹].

#### ۳-۵-۳- فنریت

نتایج به‌کارگیری روش‌های یادگیری ماشین جهت مدل‌سازی قابلیت پیش‌بینی ویژگی بافتی فنریت نشان داد که تمامی مدل‌های تهیه شده با روش‌های یادگیری ماشین مورد استفاده، کارایی مناسبی در پیش‌بینی فنریت پنیر موزارلا داشته و شبکه عصبی پرسپترون چندلایه، بالاترین عملکرد را در میان مدل‌ها به خود اختصاص داده است (جدول ۳)، ( $RPD = 2/12$ ،  $R^2p = 0/848$  و  $RMSEP = 0/094$ ) مطالعات نشان داده است که شبکه عصبی پرسپترون چندلایه با دقت بالای ۹۰٪ قادر به طبقه‌بندی یا پیش‌بینی متغیر مورد نظر با استفاده از داده‌های حاصل از تصویربرداری فرا طیفی است. این در حالی است که برای ساخت یک مدل قوی نیاز به آموزش مناسب داشته و ضروری است تعداد

(۲۰۲۲) در بررسی ویژگی‌های بافتی گوشت گوسفند، دریافتند که استفاده از ماشین بردار پشتیبان حداقل مربعات عملکرد عالی در پیش‌بینی سختی و صمغی با  $RMSEP$  برابر  $۰/۹۸۶$  و  $۵/۲۵$  و  $۳/۰۳$ ، همچنین ضریب تعیین پیش‌بینی برابر  $۰/۹۸۶$  و  $۰/۹۸۴$  ارائه نمود. همسو با این یافته، Zhang و همکاران (۲۰۲۳)، با کاربرد این الگوریتم توانستند با دقت مناسب، مدلی را جهت تخمین میزان نیتروژن فرار در گوشت گاو توسعه دهند [۷۴]. با این وجود، Wu و همکاران (۲۰۱۴) با استفاده از مدلی بر پایه حداقل مربعات جزئی نتوانستند با دقت مناسب، ویژگی‌های بافتی و به‌ویژه حالت صمغی را در گوشت خوک تخمین بزنند [۲۷]؛ اما تصویربرداری فرا طیفی را به‌عنوان یک جایگزین قابل‌اعتماد و سریع به‌جای استفاده از دستگاه‌های متداول سنتی برای اندازه‌گیری توزیع فضایی مشخصات بافتی (TPA)، معرفی کردند.

#### ۳-۵-۶- قابلیت جویدن

همان‌گونه که از جدول ۳ مشخص است، همه روش‌های یادگیری ماشین به‌استثنای جنگل‌های تصادفی با کارایی مناسب توانستند ویژگی بافتی قابلیت جویدن پنیر موزارلای تولیدی در این تحقیق را پیش‌بینی نمایند؛ اما روش شبکه عصبی چندلایه پرسپترون و پس‌از آن ماشین بردار پشتیبان با کرنل خطی کارایی بیشتری را در مقایسه با سایر روش‌ها در پیش‌بینی ویژگی جویدن نشان دادند. نتایج به‌دست‌آمده از این تحقیق با یافته‌های Shan و همکاران (۲۰۲۰) که نتوانستند با دقت مناسب ( $R^2=۰/۸۴$ ) با توسعه مدل رگرسیون حداقل مربعات جزئی و تصویربرداری فرا طیفی، قابلیت جویدن پنیر پروسس را پیش‌بینی نمایند، مطابقت داشت [۳۳]. علاوه بر موارد یادشده، اگرچه مطالعات در خصوص پیش‌بینی این ویژگی بافتی در پنیر با استفاده از تصویربرداری فرا طیفی بسیار اندک است، اما یافته‌های González-Martín و همکاران (۲۰۱۱) ویژگی‌های بافتی از قبیل قابلیت جویدن، سختی و خامه‌ای بودن پنیر گوسفندی را با استفاده از طیف‌سنجی مادون‌قرمز به کمک رگرسیون حداقل مربعات جزئی با دقت بالا پیش‌بینی نمودند [۷۶].

همان‌گونه که از جدول ۳ مشخص است هیچ کدام از روش‌های یادگیری ماشین مورد‌استفاده به‌جز الگوریتم رأی اکثریت ( $R^2p=۰/۰۷$ ،  $RMSEP=۰/۰۶۷$ ) نتوانستند مدلی با کارایی مناسب برای پیش‌بینی ویژگی بافتی انسجام ارائه نمایند. مطالعات زیادی در خصوص مدل‌سازی پیش‌بینی انسجام پنیر موزارلا با استفاده از روش‌های یادگیری ماشین و تصویربرداری فرا طیفی صورت نگرفته است. با این وجود در تأیید با نتایج این پژوهش، Shan و همکاران (۲۰۲۰) نتوانستند انسجام اندازه-گیری شده با روش تجزیه و تحلیل بافت را در پنیر پروسس با استفاده از رگرسیون حداقل مربعات جزئی با دقتی نه‌چندان بالا برابر  $R^2cv=۰/۶۷۷$  پیش‌بینی نمایند [۳۳]. همچنین، الگوریتم رأی‌گیری اکثریت که با ایجاد تابعی از الگوریتم‌های  $PLSR$ ،  $MLR$  و  $RF$  تشکیل شد، توانست عملکرد مناسبی را نسبت به هر یک از الگوریتم‌ها به‌تنبهایی، در پیش‌بینی ویژگی انسجام ارائه نماید. نتایج این تحقیق در مورد کارایی روش رأی‌گیری اکثریت با یافته‌های Zhou و همکاران (۲۰۲۱) در استفاده از VOTING جهت تفکیک دانه‌های ذرت، همسو بود [۷۳].

#### ۳-۵-۵- حالت صمغی

روش‌های یادگیری ماشین مورد‌استفاده در این مطالعه، به‌جز جنگل‌های تصادفی نتوانستند مدل مناسبی را جهت پیش‌بینی ویژگی حالت صمغی در پنیر موزارلای کم‌چرب تولیدی ارائه نمایند و در این میان، ماشین بردار پشتیبان با کرنل خطی و بعداً آن رگرسیون مربعات جزئی کارایی بالاتری داشتند (جدول ۳). نتایج این تحقیق در مورد پیش‌بینی ویژگی حالت صمغی، به کمک مدل رگرسیون حداقل مربعات جزئی، با یافته‌های Shan و همکاران (۲۰۲۰) که حالت صمغی را با مدل رگرسیون حداقل مربعات جزئی با دقت  $R^2=۰/۸۱۷$  پیش‌بینی نمودند، مطابقت داشت [۳۳]. از سوی دیگر، یافته‌های به‌دست‌آمده از برازش مدل  $SVML$  بر روی ویژگی بافتی حالت صمغی، با نتایج به‌دست‌آمده از پژوهش Sahadevan و همکاران (۲۰۱۶) همسو بود [۷۱]. بعلاوه، مشابه با یافته‌های این پژوهش Zhang و همکاران

## ۴- نتیجه‌گیری

پنیر موزارلای کم‌چرب با کمک جانشین شونده‌های چربی تولید شد و تأثیر عملیات مکانیکی- حرارتی، شرایط نگهداری و تنوع فرمولاسیون بر ویژگی‌های بافتی (سختی، چسبندگی، فنریت، انسجام، حالت صمغی و قابلیت جویدن) مورد سنجش قرار گرفت. آزمون‌های تخریبی با روش تجزیه و تحلیل مشخصات بافت انجام و نتایج در نرم‌افزار SPSS، تجزیه و تحلیل گردید. هم‌زمان با انجام آزمایش‌های تخریبی، تصویربرداری از همان نمونه‌ها با دوربین فرا طیفی در محدوده طیف انعکاسی مادون‌قرمز نزدیک (۱۰۰۰-۴۰۰ نانومتر) انجام شد. با بازخوانی تصاویر توسط ماژول‌های مختلف نرم‌افزار پایتون، داده‌های طیفی استخراج گردید. جهت کاهش نویز، ۶ روش پیش‌پردازش و به منظور تسهیل در مدل‌سازی و کاهش ابعاد داده‌ها، ۵ الگوریتم انتخاب ویژگی، با استفاده از رگرسیون حداقل مربعات جزئی برای هر یک از ویژگی‌های بافتی به رقابت گذارده شد و طول موج‌های مهم در پیش‌گویی خصوصیات بافتی، جداسازی گردید. مدل‌های کالیبراسیون (رگرسیون خطی چندگانه، رگرسیون حداقل مربعات جزئی، ماشین بردار پشتیبان همراه کرنل خطی، شبکه عصبی پرسپترون چندلایه و الگوریتم رأی اکثریت) توسعه داده شد و کارایی مدل‌ها در پیش‌بینی ویژگی‌ها بر اساس آماره‌های مدل، تعیین شد. نتایج تجزیه و تحلیل آزمون بافت نشان داد تحت تأثیر افزایش شدت عملیات مکانیکی-حرارتی سختی، فنریت، حالت صمغی و قابلیت جویدن و انسجام افزایش یافت، در حالی که چسبندگی کاهش پیدا کرد ( $P < 0.05$ ). چربی نقش تعیین‌کننده‌ای در تفاوت ویژگی‌های بافتی داشت و افزودن اسید، کنسانتره پروتئینی آب پنیر و کازئینات سدیم سبب کاهش سختی، فنریت، انسجام و قابلیت جویدن شد. نتایج دسته-بندی موزارلا بر اساس داده‌های طیفی به کمک تجزیه و تحلیل مؤلفه‌های اصلی حاکی از آن بود که تصویربرداری فرا طیفی در طبقه‌بندی پنیر بر اساس چربی، کارآمد است. توسعه

مدل‌های کالیبراسیون برای پیش‌بینی ویژگی‌های بافتی نشان داد تمامی روش‌های یادگیری ماشین توانستند ویژگی بافتی سختی را با دقت مناسبی پیش‌بینی نمایند؛ اما مدل توسعه داده‌شده با الگوریتم رأی‌گیری اکثریت با کمترین خطا، بالاترین کارایی را بروز داد. اگرچه هیچ یک از الگوریتم‌ها نتوانستند انسجام را به خوبی پیش‌بینی نمایند، الگوریتم رأی اکثریت کارایی بالاتری در تخمین این ویژگی نشان داد. درحالی‌که روش رگرسیون خطی چندگانه نتوانست به خوبی ویژگی چسبندگی پنیر را پیش‌بینی نماید، سایر الگوریتم‌های ماشینی با کارایی مناسب، چسبندگی موزارلا را پیش‌گویی نموده و بهترین روش، مدل توسعه داده‌شده با الگوریتم جنگل‌های تصادفی بود. مدل ایجادشده توسط روش شبکه عصبی پرسپترون چندلایه با خطای مربعات پیش‌بینی اندک، بیشترین انحراف باقیمانده پیش‌بینی و بالاترین ضریب تعیین پیش‌بینی، بالاترین کارایی را در پیش‌بینی فنریت و قابلیت جویدن نشان داد. درحالی‌که تمامی روش‌های یادگیری ماشین مورد استفاده در این مطالعه، به جز جنگل‌های تصادفی نتوانستند با عملکرد مناسب، ویژگی حالت صمغی در پنیر موزارلای کم‌چرب تولیدی را پیش‌بینی نمایند، روش ماشین بردار پشتیبان با کرنل خطی به‌عنوان روش برتر با کارایی بالا جهت پیش‌بینی حالت صمغی پنیر موزارلا تشخیص داده شد. به طور خلاصه عوامل فرایند علاوه بر تأثیر بر محتوای رطوبت و چربی، به سبب تأثیر بر ساختار پروتئین و چربی پنیر موزارلا، نقش تعیین‌کننده‌ای در ویژگی‌های بافتی و عملکردی دارند. به طوری‌که با تغییر بهینه عملیات مکانیکی-حرارتی می‌توان پنیر موزارلای کم‌چرب با ویژگی‌های بافتی مناسب‌تری تولید نمود. همچنین تصویربرداری فرا طیفی به همراه روش‌های یادگیری ماشین قادر بود ویژگی‌های بافتی پنیر موزارلای کم‌چرب را به نحو مناسبی پیش‌بینی نموده و به‌عنوان یک روش جایگزین امیدبخش به جای روش‌های تخریبی همانند تجزیه و تحلیل مشخصات بافت عمل کند.

## ۶- منابع

- [1] Fox, P. F., McSweeney, P. L., Cogan, T. M., & Guinee, T. P. 2004. Cheese: An overview.

- cheese: chemistry, physics and microbiology. *General Asp.* 1: 1226-1232.
- [2] Vásquez, N., Magán, C., Oblitas, J., Chuquizuta, T., Avila-George, H., & Castro, W. 2018. Comparison between artificial neural network and partial least squares regression models for hardness modeling during the ripening process of Swiss-type cheese using spectral profiles. *Journal of Food Engineering.* 219: 8-15.
- [3] Kindstedt, P. 1993. Mozzarella and Pizza Cheese. In "Cheese: Chemistry, Physics and Microbiology, Vol. 2," 2nd Edition (PF Fox, ed.), *Chapman and Hall, London.*
- [4] Zisu, B. and N. Shah. 2005. Low-fat mozzarella as influenced by microbial exopolysaccharides, preacidification, and whey protein concentrate. *Journal of Dairy Science.* 88(6): 1973-1985.
- [5] Fogaça, D. N. L., da Silva, W. S., & Rodrigues, L. B. 2017. Influence of compression parameters on mechanical behavior of mozzarella cheese. *Journal of texture studies.* 48(5): 427-432.
- [6] Dai, S., Jiang, F., Shah, N. P., & Corke, H. 2019. Functional and pizza bake properties of Mozzarella cheese made with konjac glucomannan as a fat replacer. *Food Hydrocolloids.* 92: 125-134.
- [7] Jahani, T. and M. Azar. 2016. Effects of Fat Replacement and homogenization on the Compositional and Sensory properties of low Fat Mozzarella. *Journal of Food Processing and Preservation.* 8(2): 123-142.
- [8] Solorza, F. J., & Bell, A. E. 1995. Effect of calcium, fat and total solids on the rheology of a model soft cheese system. *International journal of dairy technology.* 48(4): 133-139.
- [9] McMahon, D. J., Alleyne, M. C., Fife, R. L., & Oberg, C. J. 1996. Use of fat replacers in low fat Mozzarella cheese. *Journal of Dairy Science.* 79(11): 1911-1921.
- [10] Wang, H.-H. and D.-W. Sun. 2002. Melting characteristics of cheese: analysis of effects of cooking conditions using computer vision technology. *Journal of Food Engineering.* 51(4): 305-310.
- [11] Gonçalves, M. C. and H. R. Cardarelli. 2020. Effect of the stretching temperature on the texture and thermophysical properties of mozzarella cheese. *Journal of Food Processing and Preservation.* 44(9): e14703.
- [12] Yu, C. and S. Gunasekaran. 2005. Modeling of melt conveying and heat transfer in a twin-screw cheese stretcher. *Journal of Food Engineering.* 70(2): 245-252.
- [13] Mulvaney, S., Barbano, D. M., & Yun, J. J. 1997. Systems analysis of the plasticization and extrusion processing of Mozzarella cheese. *Journal of Dairy Science.* 80(11): 3030-3039.
- [14] Banville, V., Chabot, D., Power, N., Pouliot, Y., & Britten, M. 2016. Impact of thermo-mechanical treatments on composition, solids loss, microstructure, and rheological properties of pasta filata-type cheese. *International Dairy Journal.* 61: 155-165.
- [15] Merrill, R. K., Oberg, C. J., & McMahon, D. J. 1994. A method for manufacturing reduced fat Mozzarella cheese. *Journal of Dairy Science.* 77(7): 1783-1789.
- [16] Revilla, I., González-Martín, I., Hernández-Hierro, J. M., Vivar-Quintana, A., González-Pérez, C., & Lurueña-Martínez, M. A. 2009. Texture evaluation in cheeses by NIRS technology employing a fibre-optic probe. *Journal of Food Engineering.* 92(1): 24-28.
- [17] Wu, D., Sun, D. W., & He, Y. 2014. Novel non-invasive distribution measurement of texture profile analysis (TPA) in salmon fillet by using visible and near infrared hyperspectral imaging. *Food Chemistry.* 145: 417-426.
- [18] Vásquez, N., Magán, C., Oblitas, J., Chuquizuta, T., Avila-George, H., & Castro, W. 2018. Comparison between artificial neural network and partial least squares regression models for hardness modeling during the ripening process of Swiss-type cheese using spectral profiles. *Journal of Food Engineering.* 219: 8-15.
- [19] Pu, H., Yu, J., Liu, Z., Paliwal, J., & Sun, D. W. (2023b). Evaluation of the Effects of Vacuum Cooling on Moisture Contents, Colour and Texture of Mushroom (*Agaricus Bisporus*) Using Hyperspectral Imaging Method. *Microchemical Journal:* 108653.
- [20] Priyashantha, H., Höjer, A., Saedén, K. H., Lundh, Å., Johansson, M., Bernes, G., & Hetta, M. 2020. Use of near-infrared hyperspectral (NIR-HS) imaging to visualize and model the maturity of long-ripening hard

- cheeses. *Journal of Food Engineering*. 264: 109687.
- [21] Kang, R., Zhao, M., Fagan, C. C., Methven, L., Oruna-Concha, M. J., & O'Donnell, C. P. 2020. Wavelength selection for rapid identification of different particle size fractions of milk powder using hyperspectral imaging. *Sensors*. 20(16): 4645.
- [22] Downey, G., Sheehan, E., Delahunty, C., O'Callaghan, D., Guinee, T., & Howard, V. 2005. Prediction of maturity and sensory attributes of Cheddar cheese using near-infrared spectroscopy. *International Dairy Journal*. 15(6-9): 701-709.
- [23] Darnay, L., Králik, F., Oros, G., Koncz, Á., & Firtha, F. 2017. Monitoring the effect of transglutaminase in semi-hard cheese during ripening by hyperspectral imaging. *Journal of Food Engineering*. 196: 123-129.
- [24] Lei, T. and D.-W. Sun. 2019. Developments of nondestructive techniques for evaluating quality attributes of cheeses: A review. *Trends in Food Science & Technology*. 88: 527-542.
- [25] Sun, D.-W. 2010. Hyperspectral imaging for food quality analysis and control, Elsevier.
- [26] Khojastehnazhand, M., Khoshtaghaza, M. H., Mojaradi, B., Rezaei, M., Goodarzi, M., & Saeys, W. 2014. Comparison of visible–near infrared and short wave infrared hyperspectral imaging for the evaluation of rainbow trout freshness. *Food Research International*. 56: 25-34.
- [27] Wu, D. and D.-W. Sun. 2013. Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review—Part I: Fundamentals. *Innovative Food Science & Emerging Technologies*. 19: 1-14.
- [28] Saha, D. and A. Manickavasagan. 2021. Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review. *Current Research in Food Science*. 4: 28-44.
- [29] Ah, J., & Tagalpallewar, G. P. 2017. Functional properties of Mozzarella cheese for its end use application. *Journal of food science and technology*. 54(12): 3766-3778.
- [30] Jahani, T. and M. Azar. 2016. Effects of Fat Replacement and homogenization on the Compositional and Sensory properties of low Fat Mozzarella. *Journal of Food Processing and Preservation*. 8(2): 123-142.
- [31] Feng, R., Barjon, S., van den Berg, F. W., Lillevang, S. K., & Ahrné, L. 2021. Effect of residence time in the cooker-stretcher on mozzarella cheese composition, structure and functionality. *Journal of Food Engineering*. 309: 110690.
- [32] Giménez, P., Peralta, G. H., Batistela, M. E., George, G. A., Ale, E. C., Quintero, J. P., & Bergamini, C. V. 2023. Impact of the use of skim milk powder and adjunct cultures on the composition, yield, proteolysis, texture and melting properties of Cremoso cheese. *International Dairy Journal*, 140, 105595.
- [33] Shan, J., Zhang, Y., Liang, J., & Wang, X. 2020. Characterization of the processing conditions upon textural profile analysis (tpa) parameters of processed cheese using near-infrared hyperspectral imaging. *Analytical Letters*. 53(8): 1190-1203.
- [34] Sun, D.-W. 2010. Hyperspectral imaging for food quality analysis and control, Elsevier.
- [35] Monicka, S. G., Manimegalai, D., & Karthikeyan, M. (2022). Detection of microcracks in silicon solar cells using Otsu-Canny edge detection algorithm. *Renewable Energy Focus*, 43, 183-190.
- [36] Le Coënt, A. L., Rivoire, A., Briancon, S., & Lieto, J. 2005. An original image-processing technique for obtaining the mixing time: The box-counting with erosions method. *Powder technology*, 152(1-3), 62-71.
- [37] Zhang, D., Lillevang, S. K., & Shah, N. P. 2021. Influence of pre-acidification, and addition of KGM and whey protein-based fat replacers CH-4560, and YO-8075 on texture characteristics and pizza bake properties of low-fat Mozzarella cheese. *LWT*. 137: 110384.
- [38] ElMasry, G. M., & Nakauchi, S. 2016. Image analysis operations applied to hyperspectral images for non-invasive sensing of food quality—A comprehensive review. *Biosystems engineering*, 142, 53-82.
- [39] Kandpal, L. M., Lee, H., Kim, M. S., Mo, C., & Cho, B. K. 2013. Hyperspectral reflectance imaging technique for visualization of moisture distribution in cooked chicken breast. *Sensors*. 13(10): 13289-13300.



- [40] Ghamisi, P., Couceiro, M. S., Fauvel, M., & Benediktsson, J. A. 2013. Integration of segmentation techniques for classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 11(1), 342-346.
- [41] Khan, A., Munir, M. T., Yu, W., & Young, B. 2020. Wavelength selection for rapid identification of different particle size fractions of milk powder using hyperspectral imaging. *Sensors*, 20(16), 4645.
- [42] Park, B. and R. Lu. 2015. *Hyperspectral imaging technology in food and agriculture*, Springer.
- [43] Wold, S., Sjöström, M., & Eriksson, L. 2001. PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*. 58: 109–130.
- [44] Nicolai, B. M., Beullens, K., Bobelyn, E., Peirs, A., Saeys, W., Theron, K. I., & Lammertyn, J. 2007. Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review. *Postharvest Biology and Technology*. 46(2): 99-118.
- [45] Pan, T. T., Sun, D. W., Cheng, J. H., & Pu, H. (2016). Regression algorithms in hyperspectral data analysis for meat quality detection and evaluation. *Comprehensive reviews in food science and food safety*, 15(3), 529-541.
- [46] Kuhn, M. and K. Johnson. 2013. *Applied predictive modeling*, Springer.
- [47] Geron, A. 2017. *Hands-On Machine Learning with Scikit-Learn & Tensorflow* O'Reilly Media, Inc. 1005 Gravenstein Highway North, Sebastopol, CA 95472: 564.
- [48] Seo, D. K., Kim, Y. H., Eo, Y. D., Lee, M. H., & Park, W. Y. (2018). Fusion of SAR and multispectral images using random forest regression for change detection. *ISPRS International Journal of Geo-Information*, 7(10), 401.
- [49] Yang, H., Li, F., Wang, W., & Yu, K. 2021. Estimating above-ground biomass of potato using random forest and optimized hyperspectral indices. *Remote Sensing*, 13(12), 2339.
- [50] Zhou, L., Zhang, C., Liu, F., Qiu, Z., & He, Y. 2019. Application of deep learning in food: a review. *Comprehensive Reviews in Food Science and Food Safety*. 18(6): 1793-1811.
- [51] Jin, X., Xiao, Z. Y., Xiao, D. X., Dong, A., Nie, Q. X., Wang, Y. N., & Wang, L. F. 2022. Quantitative inversion model of protein and fat content in milk based on hyperspectral techniques. *International Dairy Journal*. 134: 105467.
- [52] Granato, D. and G. Ares. 2014. *Mathematical and statistical methods in food science and technology*, John Wiley & Sons.
- [53] Ashfaq, J. M. and A. Iqbal. 2019. Introduction to support vector machines and kernel methods. publication at <https://www.researchgate.net/publication/332370436>.
- [54] Esen, M. K. and N. Güzeler. 2023. The effects of the use of whey protein as a fat replacer on the composition, proteolysis, textural, meltability, microstructural, and sensory properties of reduced-fat Boru-type Künefe cheese during storage. *International Dairy Journal*. 137: 105519.
- [55] Metzger, L. E., Barbano, D. M., Kindstedt, P. S., & Guo, M. R. 2001. Effect of milk preacidification on low fat Mozzarella cheese: II. Chemical and functional properties during storage. *Journal of Dairy Science*. 84(6): 1348-1356.
- [56] Amador-Espejo, G. G., Ruiz-Lopez, I. I., Gibbens-Bandala, P. J., Delgado-Macuil, R. J., & Ruiz-Espinosa, H. 2021. Thermosonicated whey protein concentrate blends on quality attributes of reduced fat Panela cheese. *Ultrasonics Sonochemistry*. 76: 105621.
- [57] Abd Elkader, R. S. Awaad, R. A., Rizk Hassan, Z. M., & Salama, W. M. 2019. Production of low-fat white soft cheese using sodium caseinate and/or butter milk powder as a fat replacer. *Arab Universities Journal of Agricultural Sciences*. 27(2): 1503-1511.
- [58] Ismail, M., AMMAR, E. T., & El-Metwally, R. A. I. D. 2011. Improvement of low fat mozzarella cheese properties using denatured whey protein. *International journal of dairy technology*. 64(2): 207-217.
- [59] Nateghi, L., Roohinejad, S., Totousaus, A., Rahmani, A., Tajabadi, N., Meimandipour, A., & Manap, M. Y. A. 2012. Physicochemical and textural properties of reduced fat Cheddar cheese formulated with xanthan gum and/or sodium caseinate as fat replacers. *J. Food Agr. Environ*. 10: 59-63.

- [60] Kindstedt, P. S., Kiely, L. J., & Gilmore, J. A. 1992. Variation in composition and functional properties within brine-salted Mozzarella cheese. *Journal of Dairy Science*. 75(11): 2913-2921.
- [61] Tunick, M. H., Mackey, K. L., Smith, P. W., & Holsinger, V. H. 1991. Effects of composition and storage on the texture of Mozzarella cheese. *Nederlands melk en Zuiveltijdschrift*. 45(2): 117-125.
- [62] Alinovi, M., Wiking, L., Corredig, M., & Mucchetti, G. 2020. Effect of frozen and refrigerated storage on proteolysis and physicochemical properties of high-moisture citric mozzarella cheese. *Journal of Dairy Science*. 103(9): 7775-7790.
- [63] Topcu, A., Bulat, T., & Özer, B. 2020. Process design for processed Kashar cheese (a pasta-filata cheese) by means of microbial transglutaminase: Effect on physical properties, yield and proteolysis. *LWT*. 125: 109226.
- [64] Shafiee, S., Polder, G., Minaei, S., Moghadam-Charkari, N., Van Ruth, S., & Kuś, P. M. 2016. Detection of honey adulteration using hyperspectral imaging. *IFAC-PapersOnLine*. 49(16): 311-314.
- [65] Jajromi, A., Taghi Zadeh, M., Sazgar Nia, A., & Behzad, K. 2015. Application of preprocessing techniques for visible/near infrared spectroscopy data in developing a model for the prediction of soluble solid and acidity of lime. *Journal of food science and technology (Iran)*. 13(53): 103-112.
- [66] Park, S., Yang, M., Yim, D. G., Jo, C., & Kim, G. 2023. Industrial freezing and tempering for optimal functional properties in thawed Mozzarella cheese. *Food Chemistry*. 405: 134933.
- [67] Zou, Z., Wu, Q., Long, T., Zou, B., Zhou, M., Wang, Y., & Xu, L. 2023. Classification and Adulteration of Mengding Mountain Green Tea Varieties Based on Fluorescence Hyperspectral Image Method. *Journal of Food Composition and Analysis*: 105141.
- [68] Rinnan, Å., Van Den Berg, F., & Engelsen, S. B. 2009. Review of the most common preprocessing techniques for near-infrared spectra. *TrAC Trends in Analytical Chemistry*. 28(10): 1201-1222.
- [69] Teixido-Orries, I., Molino, F., Femenias, A., Ramos, A. J., & Marín, S. 2023. Quantification and classification of deoxynivalenol-contaminated oat samples by near-infrared hyperspectral imaging. *Food Chemistry*: 135924.
- [70] Ni, F., Zhu, X., Gu, F., & Hu, Y. 2019. Nondestructive detection of apple crispness via optical fiber spectroscopy based on effective wavelengths. *Food Science & Nutrition*. 7(11): 3654-3663.
- [71] Sahadevan, A. S., Routray, A., Das, B. S., & Ahmad, S. 2016. Hyperspectral image preprocessing with bilateral filter for improving the classification accuracy of support vector machines. *Journal of Applied Remote Sensing*. 10(2): 025004-025004.
- [72] Zhang, D., Xu, Y., Huang, W., Tian, X., Xia, Y., Xu, L., & Fan, S. 2019. Nondestructive measurement of soluble solids content in apple using near infrared hyperspectral imaging coupled with wavelength selection algorithm. *Infrared Physics & Technology*. 98: 297-304.
- [73] Zhou, Q., Huang, W., Tian, X., Yang, Y., & Liang, D. 2021. Identification of the variety of maize seeds based on hyperspectral images coupled with convolutional neural networks and subregional voting. *Journal of the Science of Food and Agriculture*. 101(11): 4532-4542.
- [74] Zhang, J., Ma, Y., Liu, G., Fan, N., Li, Y., & Sun, Y. (2022). Rapid evaluation of texture parameters of Tan mutton using hyperspectral imaging with optimization algorithms. *Food Control*, 135, 108815.
- [75] Zhang, J., Guo, Z., Ren, Z., Wang, S., Yin, X., Zhang, D., & Ma, C. 2023. A non-destructive determination of protein content in potato flour noodles using near-infrared hyperspectral imaging technology. *Infrared Physics & Technology*. 130: 104595.
- [76] González-Martín, M. I., Hernández-Hierro, J. M., Revilla, I., Vivar-Quintana, A., González-Pérez, C., García, L. G., & Ortega, I. A. L. 2011. Differentiation of organic and non-organic ewe's cheeses using main mineral composition or near infrared spectroscopy coupled to chemometric tools: A comparative study. *Talanta*. 85(4): 1915-1919.



## Scientific Research

## Prediction of textural characteristics in low-fat mozzarella cheese by Hyperspectral imaging using machine learning methods

Tahereh Jahani<sup>1,2</sup>, Mahdi Kashaninejad<sup>3\*</sup>, Aman Mohamad Ziaifar<sup>4</sup>, Alireza Soleimanipour<sup>5</sup>, Naser Behnampour<sup>6</sup>

1-Ph.D. student, Department of Food Process Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

2-Expert in chief, Food, Drug & Natural Products Health Research Center, Golestan University of Medical Science, Gorgan, Iran

3-Professor, Department of Food Process Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

4-Associated professor, Department of Food Process Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

5-Assistant professor, Department of Biosystems Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

6-Assistant professor, Health Management and Social Development Research Centre, Department of Biostatistics and Epidemiology, Golestan University of Medical Sciences, Gorgan, Iran

## ARTICLE INFO

## ABSTRACT

**Article History:**

Received:2023/10/7

Accepted:2023/11/22

**Keywords:**

low-fat mozzarella,

textural characteristics,

Hyperspectral imaging,

machine learning

**DOI: 10.22034/FSCT.21.151.13.**

\*Corresponding Author E-Mail:  
[kashani@gau.ac.ir](mailto:kashani@gau.ac.ir)

Changing the thermo-mechanical properties, variety of formulation and storage conditions, 36 samples of low-fat mozzarella cheese were produced and their hardness, adhesiveness, cohesiveness, springiness, cohesiveness, gumminess and chewiness were evaluated by TPA followed by analyzing data using completely randomized factorial design with univariate analysis through IBM SPSS Statistics. Then, Imaging of the same samples with a Hyperspectral camera in the range of 400-1000 nm as well as pre-processing the spectra and preferring the important wavelengths by feature selection algorithms to developed the calibration models including multiple linear regression algorithms, partial least squares regression, support vector machine with a linear kernel, multilayer perceptron neural network, random forests and majority voting algorithm was performed in Python software followed by the performance of models were evaluated. Results showed that the more increased the stretching time in hot water from 2 to 8 minutes, the more the hardness, springiness, gumminess and chewiness and cohesiveness increased, but adhesiveness was decreased. The majority vote algorithm (VOTING) revealed the highest performance in hardness prediction ( $R^2_p=0.878$ ,  $RMSE_p=2606.52$  and  $RPD=2.12$ ) and was able to predict the cohesiveness of mozzarella with higher accuracy more than other algorithms. Multiple linear regression couldn't predict the adhesiveness properly, but random forest method with high performance predicted this feature ( $R^2_p=0.808$ ,  $RMSE=56.49$ ,  $RPD=1.90$ ). The multi-layer perceptron neural network with the least error, predicted springiness ( $R^2_p = 0.848$ ,  $RMSE_p = 0.094$ ,  $RPD = 2.12$ ) and chewiness ( $R^2_p = 0.84$ ,  $RMSE_p = 1117.21$ ,  $RPD = 1.96$ ) with high accuracy. All methods except random forest were able to predict the gumminess of mozzarella with high efficiency. In this study, it was cleared that the process conditions had significant effects on the textural characteristics and the Hyperspectral imaging was found to be a suitable alternative method for estimating the textural characteristics of mozzarella cheese.