

مدل‌سازی روند تغییرات شاخص‌های فیزیکوشیمیایی، بافتی و حسی ماست غنی‌شده با آهن و روی توسط شبکه‌های عصبی مصنوعی

محمود حسین‌نژاد^۱، سیدمهدی جعفری^{۲*}، محمد گنجه^۳

۱- دانش‌آموخته کارشناسی ارشد، صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

۲- دانشیار، دانشکده صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

* نویسنده مسئول (smjafari@gau.ac.ir)

۳- دانشجوی دکتری، صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

تاریخ دریافت: ۱۳۹۳/۱۰/۰۶

تاریخ پذیرش: ۱۳۹۵/۰۴/۰۵

چکیده

در این پژوهش جهت تعیین مدلی برای پیش‌بینی روند تغییرات خصوصیات مختلف ماست غنی‌شده با آهن و روی، محصول مایه‌خورده با غلظت‌های برابر ۲۰، ۴۰ و ۶۰ میلی‌گرم این املاح به ازای یک کیلوگرم شیر غنی‌سازی شدند و نمونه‌ها در دوره‌های زمانی ۱، ۷ و ۱۴ روز مورد آزمون قرار گرفتند. ویژگی‌های فیزیکوشیمیایی (اسیدیته، pH، آب‌دهی، ظرفیت نگهداری آب و ویسکوزیته)، ویژگی‌های بافتی (سختی، فنریت، نیروی چسبندگی و پیوستگی) و حسی (طعم، بو، رنگ، بافت و پذیرش کلی) نمونه‌ها مورد بررسی قرار گرفت و جهت پیش‌بینی روند تغییرات از ابزار شبکه‌های عصبی مصنوعی در نرم‌افزار MATLAB R2013a استفاده شد. با بررسی شبکه‌های مختلف به ترتیب برای ماست غنی‌شده با آهن و روی شبکه‌های پسانتشار پیش‌خور با توپولوژی‌های ۲-۳-۱۴ و ۲-۴-۱۴ با ضرایب همبستگی ۰/۹۹۷ و ۰/۹۹۱ و میانگین مربعات خطای ۰/۴۰۹۰ و ۰/۱۰۴۰ با به‌کارگیری تابع فعال‌سازی تانژانت سیگموئید هیپربولیکی، الگوی یادگیری لونیگ-مارکوات و چرخه یادگیری ۱۰۰۰ به‌عنوان بهترین مدل‌های عصبی مشخص گردیدند. نتایج حاصل از مدل‌های بهینه انتخاب‌شده نیز ارزیابی گردید و این مدل‌ها با ضرایب همبستگی بالا (بیش از ۰/۹۸) و انحراف معیار میانگین بسیار پایین قادر به پیش‌بینی روند تغییرات بودند.

واژه‌های کلیدی

آنالیز بافت

شبکه عصبی مصنوعی

غنی‌سازی

مدل‌سازی

مقدمه

ماست از پرمصرف‌ترین فراورده‌های تخمیری شیر است که به دلیل ارزش تغذیه‌ای بالا تأثیر مثبتی در سلامتی انسان دارد (Rosemont, 1990). ویژگی‌های کلی ماست نظیر اسیدیته، میزان اسید چرب آزاد همراه با خصوصیات حسی و تغذیه‌ای از ویژگی‌های مهم در ماست هستند. Hardi و Slacanac (۲۰۰۰) خصوصیات رئولوژیکی و بافت فراورده‌های تخمیری شیر را تحت تأثیر ترکیب شیر اولیه، میزان ماده خشک، عملیات حرارتی شیر، نوع کشت آغازگر، دمای اینکوباسیون، ویسکوزیته اولیه شیر، سینتیک تخمیر و

هموزنی‌اسیون دانستند.

غنی‌سازی مواد غذایی به صورت افزودن یک یا چند ماده مغذی ضروری در سطوحی بالاتر از آنچه که به طور طبیعی در آن ممکن است وجود داشته باشد یا نداشته باشد، انجام می‌گردد. طبق برآورد سازمان بهداشت جهانی از هر ۵ نفر حداقل ۱ نفر در دنیا از کمبود عناصر ید، روی، آهن، اسیدفولیک، کلسیم، ویتامین آ و ب رنج می‌برند (Krebs et al., 1995). در بسیاری از جوامع به علت شیوع وسیع کم‌خونی ناشی از فقر آهن، نیاز به افزایش جذب آهن در رژیم غذایی وجود دارد (Johnson et al., 2004)، همچنین براساس

نمونه‌های کنترل طی مدت زمان ۷ روز نگهداری ۶/۶۷ ارزیابی گردید که این مقدار برای ماست غنی‌شده با فروس‌بیس‌گلیسینات و فروس‌لاکتات به ترتیب ۵/۶۳ و ۶ گزارش گردید که نشان‌دهندهٔ اختلاف معنی‌دار در این زمینه می‌باشد.

استفاده از شبکه‌های عصبی مصنوعی^۱ در تعیین و پیش‌بینی زمان ماندگاری و خصوصیات مختلف مواد غذایی، به‌عنوان یک روش سریع و کارآمد شناخته‌شده و امروزه استفاده از آن درحال توسعه و گسترش است. از دلایل استفاده روزافزون از این تکنیک می‌توان به این امر اشاره کرد که معمولاً اندازه‌گیری خصوصیات مواد غذایی در آزمایشگاه یک فرایند طاقت‌فرسا، هزینه‌بر و طولانی مدت می‌باشد درحالی‌که این روش سیستمی حساس، قابل اعتماد، سریع، ساده و کم‌هزینه برای نظارت بر محصولات تولیدی است (Goyal & Kumar Goyal, 2012). استفاده از شبکه‌های عصبی در مواد غذایی از آن جهت حائز اهمیت و حیاتی می‌باشد که باتوجه‌به پیچیدگی ارتباط‌های فاکتورهای مؤثر بر کیفیت مواد غذایی و عدم توانایی روش‌های معمول در تجزیه‌وتحلیل این رابطه‌ها، این تکنیک می‌تواند راه‌حلی برای این مشکل باشد و برای پیش‌بینی کیفیت مواد غذایی طی فرایند و بعد از آن به‌کار رود (Ni & Gunasekaran, 1998).

Cruz و همکاران (۲۰۰۹) از شبکه‌های عصبی مصنوعی بر پایهٔ آنالیزهای دستگاهی ساده مانند pH، رنگ و سختی (ورودی‌ها) برای طبقه‌بندی ماست‌های تجاری در دو دستهٔ کم‌چربی و چربی‌گرفته (خروجی‌ها) استفاده کردند. همهٔ ۱۰۸ نمونهٔ ماست حاوی طعم توت‌فرنگی (۴۸ ماست کم‌چرب) پروبیوتیک، ۳۶ ماست کم‌چرب و ۲۴ ماست پرچرب) با نمونه‌های تجاری متعددی مخلوط شدند و تیمارهای متفاوتی را برای استفاده در این مطالعه ایجاد کردند. آنالیزهای آماری ویژگی‌های متفاوتی را برای هر یک از طبقه‌های تعریف‌شده نشان داد. بدین ترتیب، داده‌های به‌دست‌آمده و مدل شبکهٔ عصبی با الگوریتم یادگیری لونیگ-مارکوات و با استفاده از جعبهٔ ابزار نرم‌افزار متلب ایجاد شد. مقایسهٔ

آمار، حدود ۲۰ درصد جمعیت جهان در خطر کمبود فلز روی هستند (Rosemont, 1990). از نظر متخصصان علوم تغذیه، یکی از بهترین راه‌های دریافت ریزمغذی‌ها غنی‌سازی مواد خوراکی و آشامیدنی است (برنجی‌اردستانی و همکاران ۱۳۸۶).

Köse و Ocak (۲۰۱۰) آهن، روی و مس را به شیر و ماست افزودند و آثار آن را بر خصوصیات بافتی ماست بررسی کردند (۰/۰۵ تا ۰/۴ میلی‌گرم مس، ۰/۰۵ تا ۰/۶ میلی‌گرم بر لیتر آهن و ۱/۷۵ تا ۵ میلی‌گرم بر لیتر روی). طبق گزارش این محققین افزودن آهن به شیر باعث افزایش میزان سفتی و به‌هم‌پیوستگی ماست می‌شود. حضور مس و روی آثار بازدارندگی روی تخمیر در کشت آغازگر ماست داشتند. مدت انکوباسیون ماست غنی‌شده با مس و روی طولانی‌تر از نمونه‌های کنترل و نمونه‌های غنی‌شده با آهن بود.

Askary و Bolandi (۲۰۱۳) آثار غنی‌سازی روی خصوصیات حسی و فیزیکی‌شیمیایی ماست را بررسی کردند. طبق گزارش این محققین اسیدیته در تمام نمونه‌های غنی‌شده طی دورهٔ نگهداری افزایش و میزان pH کاهش یافت. همچنین ظرفیت نگهداری آب در تمام نمونه‌های غنی‌شده با آهن بهبود یافت. Sendra و همکاران (۲۰۱۰) نیز بهبود حفظ آب طی انبارداری در ماست غنی‌شده با آهن را گزارش کرده‌اند و آن را به افزایش کیفیت شبکهٔ ژل محصول و همچنین افزایش هیدراته‌شدن آب در پروتئین‌ها نسبت داده‌اند.

El-Kholy Amira و همکاران (۲۰۱۱) گزارش دادند غنی‌سازی شیر با غلظت ۲۰ میلی‌گرم آهن بر میزان اکسیداسیون ماست تولیدی اثر معنی‌داری دارد. به‌طوری‌که غنی‌سازی ماست با آمونیوم فریک‌سولفات و آمونیوم فروس‌سولفات سبب افزایش اکسیداسیون در مقایسه با نمونه‌های کنترل شده است.

بررسی اثر غنی‌سازی ماست با ریز مغذی‌های فروس‌بیس‌گلیسینات (۶۳ mg/kg) و فروس‌لاکتات (۷۹ mg/kg) توسط Nkhata و همکاران (۲۰۱۵) نشان داده که افزودن این ترکیبات برای غنی‌سازی ماست سبب کاهش امتیاز ارزیابی حسی نسبت به نمونه‌های کنترل شده است. به‌طورمثال امتیاز طعم

¹ Artificial neural network

شیرخشک بدون چربی از شرکت پارسا مهر آراین (تهران) همچنین سولفات روی هپتا هیدراته (سولفات روی ۷ آبه)، آمونیوم آهن ۳ سولفات، و هیدروکسید سدیم از شرکت مرک آلمان تهیه گردیدند. استارتر^۱ DVS BV-08 مورد استفاده شامل دو باکتری استرپتوکوکوس ترموفیلوس^۲ و لاکتوباسیلوس دلبروکی زیرگونه بولگاریکوس^۳ بود که از شرکت اسپانیایی Caminox تهیه گردید. برای انجام عمل غنی‌سازی، نمونه‌های شیر مایه‌خورده به ۷ قسمت تقسیم گردیدند (۳ ظرف برای غنی‌سازی با آهن، ۳ ظرف برای غنی‌سازی با روی و ۱ نمونه نیز به‌عنوان کنترل). عمل غنی‌سازی با غلظت‌های برابر آهن و روی یعنی ۲۰، ۴۰ و ۶۰ میلی‌گرم به ازای هر کیلوگرم شیر انجام پذیرفت (نیاز تغذیه‌ای مردان و زنان به آهن ۱۰ میلی‌گرم در روز می‌باشد، این در حالی است که این مقدار برای ریزمغذی روی در زنان و مردان بالغ به‌ترتیب ۱۲ و ۱۵ میلی‌گرم در روز در نظر گرفته می‌شود (kesler, 1994)). سپس نمونه‌ها به داخل ظروف ۱۰۰ گرمی منتقل و در گرم‌خانه با دمای ۴۵ درجه سانتی‌گراد قرار گرفتند و پس از رسیدن pH به ۴/۴-۴/۵ به سردخانه با دمای ۴ درجه سانتی‌گراد انتقال یافتند. برای بررسی اثر غنی‌سازی بر ویژگی‌های ماست تولیدی، نمونه‌ها بعد از مدت زمان ۱، ۷ و ۱۴ روز مورد ارزیابی قرار گرفتند. همچنین تأثیر مقادیر مختلف آهن و روی با مقایسه میانگین‌ها در سطح ۵ درصد با استفاده از روش دانکن بررسی شد.

تعیین خصوصیات فیزیوشیمیایی و حسی

میزان آب‌دهی نمونه‌های ماست به روش Salvador و Fizman (۲۰۰۴) با اندکی تغییرات تعیین گردید. در این روش بسته‌های ۱۰۰ گرمی ماست برای جلوگیری از ایجاد هرگونه فشار بر ساختار ژلی ماست و ممانعت از جمع شدن پروتئین‌های سرمی بر سطح آن روی یک سطح صاف در دمای اتاق (۲۵ درجه سانتی‌گراد) قرار گرفتند. میزان سرم جداشده بعد از گذشت ۱ ساعت، با استفاده از یک سرنگ حذف گردید و میزان

نتایج به‌دست‌آمده نشان داد که این مدل قادر است بادقت کامل و صحت ۱۰۰ درصد نمونه‌های به‌کاررفته در آموزش شبکه را پیش‌بینی کند. این محققین نتیجه‌گیری کردند که باتوجه به هزینه‌بر بودن این تست‌ها در آزمایشگاه‌های صنایع لبنی و همچنین به جا گذاشتن باقی‌مانده‌های شیمیایی، و ازطرفی سرعت و دقت بسیار بالای این تکنیک مدلسازی در تعیین این پارامترها می‌توان از آنها در نظارت بر تولید و انبارداری این محصول و محصولات مشابه استفاده کرد.

در محصولات لبنی از شبکه عصبی مصنوعی برای آنالیز و تعیین روند متغیرهای مختلفی استفاده شده است که از آن جمله می‌توان به تعیین میزان پروتئین در شیر خام توسط Etzion و همکاران (۲۰۰۴)، پیش‌بینی میزان رطوبت طی تولید صنعتی پنیر توسط Jimenez Marquez و همکاران (۲۰۰۵)، مدلسازی آفت کیفیت ماست و پیش‌بینی زمان ماندگاری آن توسط He و همکاران (۲۰۰۶)، تعیین میزان پاتوژن‌های پستانی توسط Hetinga و همکاران (۲۰۰۸)، کنترل فرایند کره‌سازی طی فرایند پیوسته صنعتی توسط Funahashi و Horiuchi (۲۰۰۸)، مشخص کردن پنی‌های امثال باتوجه به مشخصات جغرافیایی منطقه تولیدشده توسط Pillonel و همکاران (۲۰۰۵) و تعیین کمی میزان پروتئین در ماست توسط Khanmohammadi و همکاران (۲۰۰۹) اشاره کرد.

هدف از این پژوهش مدلسازی روند تغییرات خصوصیات فیزیوشیمیایی، بافتی و حسی ماست غنی‌شده با آهن و روی با استفاده از شبکه‌های عصبی مصنوعی به‌منظور دست‌یابی به مدلی ساده، سریع، دقیق و کارآمد، که با استفاده از آن بتوان بادقت بالایی خصوصیات فیزیوشیمیایی محصول را بدون انجام آزمون‌های معمول آزمایشگاهی پیش‌بینی نماید، می‌باشد.

مواد و روش‌ها

آماده‌سازی نمونه

شیر تازه گاو با چربی ۲/۵ درصد از شرکت فرآورده‌های لبنی شادشیر شهرستان بابل تهیه گردید.

¹ Lyophilized-mixed starter cultures

² Streptococcus thermophilus


³ Lactobacillus delbrueckii spp. bulgaricus

حسی داده شده و از آنها خواسته شد برای جلوگیری از تداخل طعم، بعد از ارزیابی یک نمونه، دهان خود را با آب شست‌وشو دهند.

آنالیز بافت

آنالیز بافت با استفاده از دستگاه (Texture Analyzer Brookfield Model CT3 Texture Analyzer-USA) به روش Supavitipatana و همکاران (۲۰۰۸) انجام شد. ویژگی‌های بافتی نمونه‌ها با بارگذاری سلولی به وزن ۵ کیلوگرم و با استفاده از پروب استوانه‌ای به قطر ۱/۸۳ میلی‌متر و سرعت ۱ میلی‌متر بر ثانیه و عمق نفوذ ۱۵ میلی‌متر در نمونه ماست بلافاصله بعد از خروج بسته‌های ۱۰۰ گرمی از دمای ۱۰ درجه سانتی‌گراد انجام پذیرفت. سختی، نیروی چسبندگی، پیوستگی و فنریت شاخص‌های تعیین‌شده در این آزمون بودند. باتوجه به نمودار شکل (۱)، سختی حداکثر نیروی لازم برای تغییر شکل مورد نظر در سیکل اول فشردن است. از دیدگاه حسی، سختی حداکثر نیروی لازم برای فشردن ماده غذایی بین دندان آسیاب تا حصول تغییر شکل معین است. میزان شاخص سختی، بالاترین نیرویی که در سیکل فشردن اعمال می‌شود. نیروی چسبندگی نشان‌دهنده حداکثر نیروی منفی مورد نیاز برای خارج نمودن پروب از ماده غذایی است که واحد آن گرم است، و از قسمت منفی نمودار (شکل ۱) به دست می‌آید (A3).

آب‌دهی به ازای ۱۰۰ گرم نمونه گزارش شد. همچنین تعیین ظرفیت نگهداری آب با دستگاه سانتریفیوژ (Hettich Universal 320R – Germany) و به روش گزارش‌شده توسط Sahin و همکاران (۲۰۰۸) با اندکی تغییر صورت گرفت که طی آن ۱۰ گرم از نمونه ماست با سرعت ۴۵۰۰ دور در دقیقه برای ۲۰ دقیقه در دمای ۱۰ درجه سانتی‌گراد سانتریفیوژ گردید و بعد از عمل سانتریفیوژ و حذف سوپرناتانت، رسوب حاصل وزن و ظرفیت نگهداری آب محاسبه گردید. ویسکوزیته با استفاده از دستگاه ویسکومتر بروکفیلد (MYR viscometers, model v2, type:R-Spain) تعیین گردید. اسیدیته نمونه‌های ماست به روش Kim و Liu (۲۰۰۲) برحسب درصد اسیدلاکتیک با انجام تیتراسیون با سود ۰/۱ نرمال در حضور فنل فتالئین به عنوان معرف مشخص گردید. همچنین pH با استفاده از دستگاه pH-Meter (Sabalanazmai) (Tehran; model: SAT-2100) که قبلاً توسط بافرهای ۴ و ۷ کالیبره شده بود، مشخص شد. ویژگی‌های حسی نمونه‌های ماست نیز از نظر طعم، بو، رنگ و بافت و همچنین پذیرش کلی توسط ۱۲ پانلیست (۶ مرد و ۶ زن، ۲۱-۴۵ سال) و با استفاده از آزمون هدونیک ۵ امتیازی مورد ارزیابی قرار گرفتند (۱=حداقل امتیاز، ۵=حداکثر امتیاز). همچنین به پانلیست‌ها آموزش مقدماتی درمورد نحوه ارزیابی



شکل ۱ - نمودار عمومی پروفایل بافت مواد غذایی

فنریت نیز مقدار برگشت ماده به حالت اولیه پس از برداشتن نیرو است، که باتوجه به شکل (۱) با رابطه (۲) تعریف می‌شود (Bourne et al., 1978; Bourne et al., 1966).

پیوستگی که به عنوان مقاومت درونی بافت مواد غذایی در برابر نیروی اعمال‌شده تعریف می‌شود، نسبت سطح مثبت سیکل دوم به سطح مثبت سیکل اول است (شکل ۱) و از رابطه (۱) به دست می‌آید.

رابطه (۱) Y_i خروجی نرون i ام و b_j مقدار بایاس نرون لایه j ام است.

$$= \frac{A_2}{A_1}$$

رابطه (۲)

$$= \frac{L_2}{L_1}$$

مقادیر L_1, L_2, A_1 و A_2 باتوجه به نمودار ارائه شده در شکل (۱) مشخص است.

مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی

براساس ارزیابی‌های انجام شده، شبکه عصبی با ویژگی‌های: شبکه پسانتشار پیش‌خور، تابع فعال‌سازی تانژانت سیگموئید هیپربولیکی^۱ (که به صورت رابطه (۳) تعریف می‌شود)، الگوی یادگیری لونیبرگ-مارکوات^۲، چرخه یادگیری ۱۰۰۰ و دو معیار ارزیابی ضریب همبستگی^۳ (R^2) و میانگین مربعات خطا^۴ (MSE) که به ترتیب از رابطه‌های (۵) و (۶) به دست می‌آیند، برای شبکه تعریف شد. جهت ایجاد و ارزیابی شبکه، ۶۰ درصد داده‌ها به صورت تصادفی و از تیمارهای گوناگون اعمالی انتخاب گردیده و جهت آموزش شبکه استفاده شدند. ۱۵ درصد داده‌ها نیز به منظور اعتبارسنجی و نهایتاً ۲۵ درصد باقی‌مانده داده‌ها که در مراحل آموزش و اعتبارسنجی استفاده نشده بودند، برای تست شبکه طراحی شده به کار رفتند.

رابطه (۳)

$$Y_j = \frac{2}{1 + \exp(-2x_j)} - 1$$

که Y_j خروجی نرون مورد نظر در لایه j و X_j مجموع ورودی‌های وزن‌دار آن نرون است و از رابطه (۴) محاسبه می‌شود:

رابطه (۴)

$$x_j = \sum_{i=1}^m w_{ij} \times Y_i + b_i$$

که m تعداد نرون لایه خروجی، وزن بین لایه i و

رابطه (۵)

$$R^2 = 1 - \frac{\sum_{i=1}^N (X_{pi} - X_{ei})^2}{\sum_{i=1}^N (X_{pi} - \bar{X})^2}$$

رابطه (۶)

$$MSE = \frac{1}{N} \sum_{i=1}^N (X_{pi} - X_{ei})^2$$

در این رابطه‌ها X_{pi} متغیر پیش‌بینی شده توسط شبکه X_{ei} مقدار واقعی حاصل از انجام آزمایش‌ها و \bar{X} میانگین مقادیر آزمایشگاهی و N تعداد کل مشاهده‌ها می‌باشد.

علاوه بر این، شاخص‌های آماری که توسط خود نرم‌افزار متلب محاسبه و ارائه می‌شود، در انتها برای هریک از مدل‌های بهینه انتخاب شده مقدار انحراف معیار میانگین (E) که با استفاده از رابطه (۷) تعریف می‌شود (Antonio *et al.*, 2008)، نیز تعیین گردید.

رابطه (۷)

$$E(\%) = \frac{1}{n_e} \sum_{i=1}^n \left\| \frac{V_E - V_P}{V_E} \right\| \times 100$$

که E انحراف معیار میانگین، n_e تعداد آزمایش‌های انجام شده، V_E نتایج به دست آمده در آزمایش‌ها و V_P مقادیر پیش‌بینی شده توسط مدل می‌باشد.

نتایج و بحث

نحوه تأثیر غلظت‌های گوناگون آهن و روی بر ویژگی‌های شیمیایی، بافتی و حسی ماست در جدول‌های (۱) و (۲) آورده شده است. در جدول (۱) تأثیر تغییرات غلظت آهن و روی، روی ویژگی‌های شیمیایی و بافتی و در جدول (۲) تأثیر این تغییرات بر ویژگی‌های حسی در سطح ۵ درصد مورد بررسی قرار گرفته است.

¹ Hyperbolic tangent sigmoid transfer function

² Levenberg-Marquardt

³ Correlation coefficient

⁴ Mean Square Error

جدول ۱ - بررسی تأثیر غلظت‌های مختلف آهن و روی بر تغییرات شیمیایی و بافتی ماست

ریز مغذی افزوده شده	غلظت (میلی گرم بر لیتر)	اسیدیته	pH	ویسکوزیته سینرسیس	ظرفیت نگهداری آب	سختی	نیروی چسبندگی	پیوستگی فنریت
آهن	۲۰	۰/۷۶ ^a	۴/۰۴ ^a	۱۲۴۴/۴۴ ^{ab}	۰/۱۲ ^b	۵۲/۲۲ ^a	۱۸۷/۶۷ ^{ab}	۰/۷۲ ^b
	۴۰	۰/۷۴ ^a	۴/۰۷ ^a	۱۴۲۲/۲۱ ^a	۰/۲۰ ^b	۵۲/۷۱ ^a	۱۹۵/۰۰ ^a	۰/۹۳ ^a
	۶۰	۰/۷۴ ^a	۴/۰۹ ^a	۱۴۷۷/۷۷ ^a	۰ ^b	۵۲/۷۳ ^a	۱۹۴/۶۷ ^a	۰/۹۴ ^a
روی	۲۰	۰/۷۲ ^a	۴/۱۱ ^a	۱۰۲۲/۲۲ ^b	۰/۲۸ ^b	۵۲/۱۳ ^a	۱۷۴/۶۷ ^{ab}	۰/۹۵ ^a
	۴۰	۰/۷۰ ^a	۴/۱۷ ^a	۱۲۴۴/۴۴ ^{ab}	۰/۴۶ ^b	۵۰/۵۱ ^a	۱۶۵/۰۰ ^b	۰/۹۵ ^a
	۶۰	۰/۷۰ ^a	۴/۲۰ ^a	۱۰۲۲/۲۱ ^b	۱/۸۵ ^a	۵۲/۸۱ ^a	۱۲۶/۰۰ ^c	۰/۹۳ ^a

حروف مشابه در یک ستون از نظر آماری در سطح معنی داری ۵ درصد با هم اختلاف معنی دار ندارند.

جدول ۲ - بررسی تأثیر غلظت‌های گوناگون آهن و روی بر تغییرات حسی ماست

ریز مغذی افزوده شده	غلظت (میلی گرم بر لیتر)	پذیرش کلی	بافت	رنگ	بو	طعم
آهن	۲۰	۳/۳۳ ^{ab}	۴/۰۸ ^a	۴/۱۳ ^a	۳/۶۵ ^{ab}	۳/۰۴ ^{ab}
	۴۰	۳/۳۴ ^{ab}	۴/۲۵ ^a	۴/۲۰ ^a	۳/۷۴ ^{ab}	۳/۱۲ ^{ab}
	۶۰	۲/۷۸ ^b	۴/۰۱ ^a	۳/۸۰ ^a	۳/۲۷ ^b	۲/۶۲ ^b
روی	۲۰	۳/۴۵ ^{ab}	۳/۸۳ ^a	۳/۹۹ ^a	۴/۱۳ ^a	۳/۷۵ ^a
	۴۰	۳/۹۵ ^a	۳/۹۹ ^a	۳/۹۳ ^a	۳/۸۲ ^{ab}	۳/۷۱ ^a
	۶۰	۳/۵۴ ^{ab}	۴/۲۳ ^a	۴/۰۶ ^a	۳/۹۴ ^{ab}	۳/۴۳ ^{ab}

حروف مشابه در یک ستون از نظر آماری در سطح معنی داری ۵ درصد با هم اختلاف معنی دار ندارند.

هریک از ریز مغذی‌های آهن و روی، و باتوجه به مشخص بودن معادله‌های مربوط به توابع انتقال (رابطه ۳) و همچنین مقادیر وزن که جهت استفاده در رابطه (۴) برای تعیین خروجی هر نرون در شبکه لازم است و در ادامه ارائه خواهد شد، می‌توان سیستم هوشمند کامپیوتری را تعریف کرد که با گرفتن زمان و غلظت این ریز مغذی‌ها به عنوان ورودی، با دقت بسیار بالایی میزان خروجی‌های تعریف شده برای این مدل‌ها (اسیدیته، pH، ویسکوزیته، آب دهی، ظرفیت نگهداری آب، سختی، نیروی چسبندگی، پیوستگی، فنریت، طعم، بو، رنگ، بافت و پذیرش کلی) را تعیین کند. استفاده از مدل‌های مشابه (شبکه عصبی پسانتشار پیش‌خور با الگوریتم یادگیری لوبرگ-مارکوات و اکثراً با یک یا دو لایه پنهان) برای تعیین ویژگی‌های فیزیکی شیمیایی مواد غذایی گوناگون توسط محققینی مانند امیری چایجان و همکاران (۱۳۸۸)، شریفی و همکاران (۱۳۸۷)، Islam و همکاران (۲۰۰۳)، بهروزی خزایی و همکاران (۱۳۸۶) نیز گزارش شده است.

در جدول (۳) مقایسه اثر تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه بر دقت پیش‌بینی ویژگی‌های گوناگون ماست غنی شده با آهن و روی ارائه شده است. باتوجه به مقادیر MSE و R² ارائه شده در جدول (۳) در توپولوژی‌های گوناگون، برای پیش‌بینی ویژگی‌های گوناگون در ماست غنی شده با آهن، توپولوژی ۲-۲-۳-۱۴ (یک لایه ورودی با دو نرون، دو لایه پنهان به ترتیب با ۲ و ۳ نرون و یک لایه خروجی با ۱۴ نرون) با حداکثر ضریب همبستگی (R²=۰/۹۹۷) و حداقل میانگین مربعات خطا (MSE=۰/۴۰۹۰) به عنوان توپولوژی بهینه انتخاب شد. در مورد ماست غنی شده با روی نیز توپولوژی ۲-۴-۱۴ (یک لایه ورودی با دو نرون، یک لایه پنهان با ۴ نرون و یک لایه خروجی با ۱۴ نرون) با حداکثر ضریب همبستگی (R²=۰/۹۹۱) و حداقل میانگین مربعات خطا (MSE=۰/۱۰۴۰) به عنوان توپولوژی بهینه انتخاب شدند. با مشخص شدن این توپولوژی‌های بهینه (ساختار شبکه‌های بهینه) برای

جدول ۳ - مقایسه اثر تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه بر دقت پیش‌بینی ویژگی‌های ماست غنی‌شده با آهن و روی

آهن			روی						
MSE	R ²	تعداد نرون‌های لایه پنهان			MSE	R ²	تعداد نرون‌های لایه پنهان		
		سوم	دوم	اول			سوم	دوم	اول
۰/۶۳۷۰	۰/۹۷۹	-	-	۲	۰/۶۰۲۰	۰/۹۷۵	-	-	۲
۰/۱۶۷۷	۰/۹۶۳	-	-	۳	۰/۷۸۹۷	۰/۹۸۷	-	-	۳
۰/۷۹۲۴	۰/۹۵۹	-	-	۴	۰/۱۰۴۰	۰/۹۹۱	-	-	۴
۰/۳۹۳۸	۰/۹۷۵	-	-	۵	۰/۸۵۹۰	۰/۹۴۶	-	-	۵
۰/۸۵۹۰	۰/۹۶۷	-	۲	۲	۰/۵۲۷۱	۰/۹۶۲	-	۲	۲
۰/۵۲۰۷	۰/۹۵۷	-	۳	۳	۰/۱۹۵۰	۰/۹۳۸	-	۳	۳
۰/۸۹۹۰	۰/۹۸۷	-	۲	۱	۰/۸۳۴۰	۰/۹۵۷	-	۲	۱
۰/۸۳۳۰	۰/۹۷۰	-	۳	۱	۰/۶۳۴۰	۰/۹۷۰	-	۳	۱
۰/۴۰۹۰	۰/۹۹۷	-	۳	۲	۰/۹۲۰۴	۰/۹۶۷	-	۳	۲
۰/۳۸۱۰	۰/۹۶۲	۲	۲	۲	۰/۴۳۷۹	۰/۹۷۳	۲	۲	۲
۰/۳۰۴۰۰	۰/۹۹۱۸	۳	۳	۳	۰/۳۹۳۵	۰/۹۷۹	۳	۳	۳
۰/۴۱۹۰	۰/۹۷۳	۲	۲	۱	۰/۳۵۹۰	۰/۹۶۰	۲	۲	۱
۰/۷۶۹۷	۰/۹۶۰	۳	۲	۲	۰/۳۶۱۰	۰/۹۶۳	۳	۲	۲
۰/۳۷۲۰	۰/۹۴۶	۳	۳	۱	۰/۴۴۹۰	۰/۹۵۹	۳	۳	۱

الگوریتم یادگیری لونیون-مارکوات در جعبه ابزار نرم‌افزار MATLAB طراحی شد. ارزیابی مدل به‌دست‌آمده نشان داد که داده‌های حاصل از سیستم عصبی با داده‌های آزمایشگاهی کاملاً و به‌صورت ۱۰۰ درصد همخوانی دارند. با توجه به نتایج گزارش‌شده توسط این محققین و همچنین نتایج حاصل از جدول (۳) که دقت بالای مدل‌های شبکه‌های عصبی طراحی‌شده (بخصوص مدل‌های بهینه انتخاب‌شده) را نشان می‌دهد، می‌توان استفاده از این سیستم‌های هوشمند را در صنعت لبنیات و بخصوص در تولید و ارزیابی ماست، بسیار مفید و کارا دانست.

جهت اتصالات بین نرون‌ها در لایه‌های گوناگون شبکه‌های انتخاب‌شده به‌عنوان شبکه بهینه نیاز به مقادیر وزن و همچنین بایاس می‌باشد، که با توجه به تعداد لایه‌ها و تعداد نرون‌ها در هر یک از این لایه‌ها، توسط نرم‌افزار تعیین می‌گردد. جداول (۴) تا (۸) این مقادیر وزن و بایاس را نشان می‌دهد. در واقع ورودی هر نرون، مجموع خروجی‌های وزن‌دار شده نرون‌های لایه قبلی است. همان‌طور که قبلاً نیز ذکر شد برای تعیین خروجی هر نرون، مقدار ورودی آن نرون، در تابع فعال‌سازی مورد نظر قرار گرفته و خروجی نرون تعیین می‌گردد (رابطه ۳). ورودی هر نرون (X_j) ، از

محققین گوناگونی نیز استفاده از شبکه‌های عصبی مصنوعی برای تعیین ویژگی‌های گوناگون ماست را گزارش کرده‌اند، که نتایج آنها حاکی از دقت بالای این مدل‌ها در این صنعت بوده است. Ekinci و Sofu (۲۰۰۷) برای پیش‌گویی زمان ماندگاری انواعی از ماست‌ها با اندازه‌گیری میزان آلودگی میکروبی و pH در طی انبارداری در روزهای ۱، ۷ و ۱۴ و به‌طور هم‌زمان عکس‌برداری از ماست با استفاده از ماشین بینایی^۱ برای تعیین تغییرات رنگ در طی انبارداری و استفاده از داده‌های حاصل به مدل‌سازی این تغییرات با شبکه‌های عصبی پرداختند. مدل عصبی طراحی‌شده شامل یک لایه پنهان با تابع فعال‌سازی سیگموئیدی بود. ورودی‌های این مدل pH، تعداد مخمر و کپک و آنالیزهای رنگ حاصل از MVS و خروجی آن زمان ماندگاری محصول بود. نتایج نشان داد انطباق کامل بین داده‌های حاصل از مدل با داده‌های آزمایشگاهی وجود دارد. Cruz و همکاران (۲۰۰۹) نیز از مدل شبکه عصبی مصنوعی برای طبقه‌بندی ماست‌های تجاری مانند ماست‌های کم‌چرب و طعم‌دار با استفاده از داده‌های معمول صنعت لبنیات که به راحتی در آزمایشگاه به‌دست می‌آید، پرداختند. شبکه عصبی با

¹ Machine Vision System (MVS)

(۱۴ نرون) را شامل می‌شود.

جدول ۴ - مقادیر وزن بین نرون‌های لایه ورودی (I) و لایه پنهان اول (H1) در مدل بهینه ۲-۲-۳-۱۴ انتخاب شده برای تیمار آهن

	H ₁₁	H ₁₂
I ₁	-۰/۰۹۸	۰/۷۷۰
I ₂	۳/۲۲	۱/۹۹

جدول ۵ - مقادیر وزن بین نرون‌های لایه پنهان اول (H1) و لایه پنهان دوم (H2) در مدل بهینه ۲-۲-۳-۱۴ انتخاب شده برای تیمار آهن

	H ₂₁	H ₂₂	H ₂₃
H ₁₁	۰/۷۳۱	-۲/۶۸	-۲/۶۳
H ₁₂	-۱/۸۶	-۰/۰۰۹	۱/۳۴

مدل بهینه انتخاب شده برای تیمار روی، شامل یک لایه پنهان می‌باشد و براین اساس مقادیر وزن و بایاس آن توسط سیستم تعیین می‌گردد. جهت اتصال لایه پنهان به خروجی نیز نیاز به یک ماتریس با ۴ سطر و ۱۴ ستون می‌باشد (جدول ۸).

مقادیر بایاس برای نرون‌های لایه خروجی و پنهان مدل بهینه انتخاب شده برای تیمار روی نیز به ترتیب در جداول (۸) و (۹) ارائه شده است.

جدول ۶ - مقادیر وزن بین نرون‌های لایه پنهان دوم (H2) و لایه خروجی (O) و مقادیر بایاس لازم خروجی (O) در مدل بهینه ۲-۲-۳-۱۴ انتخاب شده برای تیمار آهن

	O ₁₄	O ₁₃	O ₁₂	O ₁₁	O ₁₀	O ₉	O ₈	O ₇	O ₆	O ₅	O ₄	O ₃	O ₂	O ₁
H ₂₁	۴/۰۶	۱/۱۸	-۰/۱۱۱	۲/۰۴	۰/۶۹۸	-۰/۸۲۹	۰/۴۸۴	-۰/۳۹۹	-۶/۸۸	۰/۲۴۹	۰/۰۸۳	۴/۲۰	۰/۳۶۱	۰/۷۴۸
H ₂₂	-۰/۲۱۷	۰/۹۹۱	۱/۶۷	۰/۰۳۰	۱/۸۰	-۰/۲۱۵	۰/۴۶۷	-۱/۸۲	۰/۶۸۳	۳/۴۵	۰/۰۷۱	-۲/۹۹	-۰/۲۲۰	۰/۰۸۲
H ₂₃	-۱/۹۲	-۰/۱۳۴	-۱/۳۷	-۰/۲۵۲	-۰/۳۸۹	-۰/۷۵۱	-۰/۲۰۳	-۰/۵۳۲	-۱/۴۰	-۱/۶۸	۰/۴۴۶	۲/۱۰	-۱/۰۷	-۰/۵۴
مقدار بایاس	-۳/۱۵	-۲/۲۳	-۱/۵۸	-۲/۳۴	-۲/۹۹۴	-۰/۲۷۹	-۰/۳۶۹	۱/۴۴	-۵/۶۷	-۴/۰۶	-۰/۸۳۸	-۰/۱۰۵	-۰/۸۵۲	۰/۶۴۹

جدول ۷ - مقادیر بایاس لایه پنهان اول (H1) و پنهان دوم (H2) در مدل بهینه ۲-۲-۳-۱۴ انتخاب شده برای تیمار آهن

نرون مورد نظر	H ₁₁	H ₁₂	H ₂₁	H ₂₂	H ₂₃
مقدار بایاس	-۳/۴۷	-۳/۰۴	۱/۵۵	۰/۳۴۶	-۲/۱۶

جدول ۸ - مقادیر وزن بین نرون‌های لایه پنهان (H) و لایه خروجی (O) و مقادیر بایاس لایه خروجی (O) در مدل بهینه ۲-۴-۱۴ انتخاب شده برای تیمار روی

	O ₁₄	O ₁₃	O ₁₂	O ₁₁	O ₁₀	O ₉	O ₈	O ₇	O ₆	O ₅	O ₄	O ₃	O ₂	O ₁
H ₁	-۱/۲۸	-۰/۵۰۹	-۲/۸۳	-۰/۲۰۰	-۱/۵۷	۰/۷۱۵	۰/۵۱۶	-۰/۸۰۴	۰/۱۸۱	-۱/۴۴	-۱/۳۴	۱/۶۷	-۰/۳۸۴	۰/۲۷۱
H ₂	۰/۲۱۱	۰/۰۱۱	-۲/۵۹	۰/۱۷۶	-۱/۲۲	۱/۲۳	-۱/۰۹	۰/۱۷۰	۰/۵۴۰	۰/۸۶۴	-۰/۳۲۵	۱/۶۳	-۰/۱۵۰	۱/۰۳
H ₃	۰/۱۷۵	۰/۳۸۴	۰/۱۸۸	۰/۴۱۰	۰/۴۸۷	۰/۲۵۴	-۰/۰۱۱	-۰/۸۴۳	۱/۱۲	۰/۰۰۴	۰/۶۲۰	۲/۰۷	-۱/۱۸	۰/۶۸۳
H ₄	۰/۹۹۷	-۱/۰۱	-۱/۰۷	-۰/۸۲۰	-۱/۸۰	۰/۵۵۱	-۰/۲۳۸	۰/۷۷۰	-۰/۱۵۲	-۰/۰۱۲	-۱/۵۰	۰/۰۵۶	۰/۲۲۴	۰/۱۶۵
مقادیر بایاس	-۲/۴۴	-۰/۷۱۹	-۱/۰۱	-۰/۹۰۳	-۱/۰۲	-۰/۹۳۹	-۰/۲۹۰	-۰/۵۹۵	۰/۵۵۴	۰/۷۵۱	-۱/۰۱	۱/۴۸	۰/۳۱۸	-۱/۰۱

مجموع حاصل ضرب خروجی‌های هریک از نرون‌های لایه قبلی (Y_i) در مقادیر وزن مشخص (W_{ij}) و مقادیر بایاس (b_j) که با این مقدار جمع می‌شود تعیین می‌گردد (رابطه ۴).


بدین ترتیب در مدل بهینه ۲-۲-۳-۱۴ انتخاب شده برای تیمار آهن نیاز به مقادیر وزن بین لایه‌های ورودی و لایه پنهان اول (جدول ۴)، لایه پنهان اول و دوم (جدول ۵)، لایه پنهان دوم و خروجی (جدول ۶) می‌باشد. جهت تعیین تمام مقادیر وزن لازم در مدل‌های بهینه انتخاب شده، این مقادیر وزن، در قالب ماتریس‌هایی که تعداد سطرهای آنها با تعداد نرون‌های لایه مبدأ و تعداد ستون‌های آنها با تعداد نرون‌های لایه مقصد برابر است، ارائه می‌شود.

همان‌گونه که ذکر شد برای تعیین مقادیر ورودی هر نرون علاوه بر مقادیر وزن به مقدار بایاس نیز برای هر لایه (به جزء لایه ورودی) نیاز می‌باشد (رابطه ۴). مقادیر بایاس به صورت یک عدد ثابت برای هریک از نرون‌ها تعریف می‌گردد. جدول (۷) مقادیر بایاس لایه‌های پنهان اول (۲ نرون) و دوم (۳ نرون) مدل بهینه انتخاب شده برای تیمار آهن را نشان می‌دهد. جدول (۶) نیز مقادیر بایاس لایه خروجی این مدل


جدول ۹ - مقادیر بایاس لایه پنهان (H) در مدل بهینه
۱۴-۴-۲ انتخاب‌شده برای تیمار روی

نرون مورد نظر	H _۱	H _۲	H _۳	H _۴
مقادیر بایاس	-۲/۱۶۳	۳/۲۲	-۲/۲۷	-۴/۶۸

جهت تأیید توپولوژی‌های انتخاب‌شده به‌عنوان بهترین توپولوژی‌های توصیف‌کننده ویژگی‌های مدنظر، برای یکی از شرایط آزمایشگاهی شامل دمای ۴۰ درجه سانتی‌گراد در روز ۱۴ نگهداری، داده‌های پیش‌بینی‌شده توسط شبکه در مقابل مقادیر آزمایشگاهی به‌ترتیب برای ماست غنی‌شده با آهن و روی در شکل‌های (۲) و (۳) رسم شده است.



شکل ۲ - نمودار تغییرات ویژگی‌های پیش‌بینی‌شده توسط شبکه در مقابل مقادیر اندازه‌گیری‌شده برای بهترین توپولوژی ماست غنی‌شده با آهن در دمای ۴۰ درجه سانتی‌گراد و روز ۱۴ نگهداری (توپولوژی ۱۴-۳-۲-۲)



شکل ۳ - نمودار تغییرات ویژگی‌های پیش‌بینی‌شده توسط شبکه در مقابل مقادیر اندازه‌گیری‌شده برای بهترین توپولوژی ماست غنی‌شده با روی در دمای ۴۰ درجه سلسیوس و روز ۱۴ نگهداری (توپولوژی ۱۴-۴-۲)

نتیجه‌گیری

علاوه بر وقت‌گیر و هزینه‌بر بودن تحت تأثیر اشتباه‌های اپراتورها می‌باشد، می‌توان از این سیستم‌های هوشمند که با سرعت و دقت بالا می‌توانند ویژگی‌های مدنظر را تعیین کنند، استفاده کرده و صرفه‌جویی قابل توجهی در هزینه و زمان داشت.

باتوجه به دقت شبکه عصبی به‌دست‌آمده و قدرت بالای آن در تخمین و پیش‌بینی ویژگی‌های گوناگون ماست غنی‌شده با آهن و روی، و عنایت به این امر که اندازه‌گیری این ویژگی‌ها در آزمایشگاه‌های صنایع لبنی بر فرآورده‌های تولیدشده و همچنین در حین تولید به‌منظور نظارت هدفمند و با دید باز به فرایند،

منابع

- ۱- امیری چایجان، ر.، خوش تقاضا، م.، منتظر، غ.، مینایی، س. و علیزاده، م. ۱۳۸۸. تخمین ضریب تبدیل شلتوک با استفاده از شبکه‌های عصبی مصنوعی در خشک کردن بستر سیال. مجله علوم و فنون کشاورزی و منابع طبیعی ایران، ۴۸(۱۳):۲۸۵-۲۹۸.
- ۲- برنجی اردستانی، س.، عزیزی، م. و سحری، م. ۱۳۸۶. اثر غنی سازی با آهن، اسید فولیک، روی و کلسیم بر ویژگی‌های رئولوژیکی و شیمیایی آرد ستاره. فصلنامه علوم و صنایع غذایی ایران، ۴(۴):۳۳-۴۳.
- ۳- بهروزی‌خزایی، ن.، امیری‌چایجان، ر.، توکلی‌هشجین، ت. و خوش تقاضا، م. ۱۳۸۶. بررسی شاخص‌های مهم خشک کردن انگور در روش خشک کردن با جریان هوای گرم به کمک شبکه‌های عصبی مصنوعی. مجله پژوهش کشاورزی، ۷(۳):۱۵۴-۱۴۱.
- ۴- شریفی، م.، رفیعی، ش.، کیهانی، ع. و امید، م. ۱۳۸۹. شبیه‌سازی مدل سینتیک خشک شدن بستر نازک پرتقال رقم تامسون با استفاده از شبکه‌های عصبی مصنوعی. فصلنامه علوم و صنایع غذایی، ۷(۱):۳۹-۴۹.
- 5- Antonio, G.C., Alves, D.G., Azoubel, P.M., Murr, F.E.X., & Park, K.J. 2008. Influence of osmotic dehydration and high temperature short time processes on dried sweet potato (*Ipomoea batatas* Lam.). *Journal of Food Engineering*, 84(3):375-382.
- 6- Askary, N., & Bolandi, M., 2013, Assessment of iron fortification influence on organoleptic and physic chemical properties of yogurt. *Journal of Chemical Health Risks*, 3(2):1-8.
- 7- Bourne, M.C., Moyer, J.C., & Hand, D.B. 1966. Measurement of food texture by a universal testing machine. *Food Technology*, 20(4):522.
- 8- Bourne, M.C., Kenny, J.F., & Barnard, J. 1978. Computer-assisted readout of data from texture profile analysis curves. *Journal of Texture Structure*, 9(4):481-494.
- 9- Cruz, A.G., Walter, E.H.M., Cadena, R.S., Faria, J.A.F., Bolini, H.M.A., & Fileti, A.M.F. 2009. Monitoring the authenticity of low-fat yogurts by an artificial neural network. *Journal of Dairy Science*, 92(10):4797-4804.
- 10-El-Kholy Amira, M., Osman, M., Gouda, A., & Ghareeb Wafaa, A. 2011. Fortification of Yoghurt with Iron. *World Journal of Dairy & Food Sciences*, 6 (2):159-165.
- 11-Etzion, Y., Linker, R., Cogan, U., & Shmulevich, I. 2004. Determination of protein concentration in raw milk by mid-infrared Fourier transform infrared/attenuated total reflectance Spectroscopy. *Journal of Dairy Science*, 87:2779-2788.
- 12-Funahashi, H., & Horiuchi, J. 2008. Characteristics of the churning process in continuous butter manufacture and modeling using an artificial neural network. *International Journal of Dairy Technology*, 18:323-328.
- 13-Goyal, S., & Kumar Goyal, G. 2012. Artificial neural networks for dairy industry: A Review. *Journal of Advanced Computer Science and Technology*, 1(3):101-115.
- 14-Hardi, J., & Slacanac, V. 2000. Examination of coagulation kinetics and rheological properties of fermented milk products: Influence of starter culture, milk fat content and addition of inulin. *Mljekarstvo*, 50(3):217-226.

- 15-He, Y., Feng, S., Deng, X., & Li, X. 2006. Study on lossless discrimination of varieties of yogurt using the visible/NIR spectroscopy. *Food Research International*, 39:645-650.
- 16-Hettinga, K.A., van Valenberg, H.J.F., Lam, T.J.G.M., & van Hooijdonk, A.C.M. 2008. Detection of mastitis pathogens by analysis of volatile bacterial metabolites. *Journal of Dairy Science*, 91(10):3834-3839.
- 17-Islam, M.D.R., Sablani, S.S., & Mujumdar, A.S. 2003. An artificial neural network model for prediction of drying rates. *Journal of Drying Technology*, 21(9):1867-1884.
- 18-Jimenez Marquez, S.A., Thibault, J., & Lacroix, C. 2005. Prediction of moisture in cheese of commercial production using neural networks. *International Journal of Dairy Technology*, 15:1156-1174.
- 19-Johnson, Q., Manner, V., & Ranum, P. 2004. Fortification hand book. The Micronutrient Initiative, 4:1-120.
- 20-Kesler, S.E. 1994. Mineral resources, economics and the environment: New York, Macmillan, 396 p.
- 21-Khanmohammadi, M., Garmarudi, A.B.K., Ghasemi, K., Garrigues, S., & de la Guardia, M. 2009. Artificial neural network for quantitative determination of total protein in yogurt by infrared spectrometry. *Journal of Microchemistry*, 91:47-52.
- 22-Kim, Y.J., & Liu, R.H. 2002. Increase of conjugated linoleic acid content in milk by fermentation with lactic acid bacteria. *Journal of Food Science*, 67(5):1731-1737.
- 23-Krebs, N.F., Reidinger, C.J., Hartley, S., Robertson, A.D., & Hambidge, K.M. 1995. Zinc supplementation during lactation: effects on maternal status and milk zinc concentrations. *Journal of Clinical Nutrition*, 61:1030-1036.
- 24-Ni, H., & Gunasekaran, S. 1998. Food quality prediction with neural networks. *Food Technology*, 52:60-65.
- 25-Nkhata, S.G., Ustunol, Z., & Menevseoglu, A. 2015. Iron fortification of yogurt and pasteurized milk. *Journal of Nutritional Health & Food Science*, 3(3):1-12.
- 26-Ocak, E., & Köse, Ş. 2010. The effects of fortifying milk with Cu, Fe and Zn minerals on the production and texture of yoghurt. *Journal of Food Agriculture & Environment*, 8(2):122-125.
- 27-Pillonel, L., Bütikofer, U., Schlichtherle-Cerny, H., Tabacchi, R., & Bosset, J.O. 2005. Geographic origin of European Emmental. Use of discriminant analysis and artificial neural network for classification purposes. *International Dairy Journal*, 15:557-562.
- 28-Rosemont, L. 1990. Yoghurt-its nutritional and health benefits. *National Dairy Council*, 61(2):7-12.
- 29-Sahin, N., Yasar, K., & Hayaloglu, A.A. 2008. Physical, chemical and flavour quality of non-fat yogurt as affected by ab-glucon hydrocolloidal composite during storage. *Food Hydrocolloids*, 22:1291-1297.
- 30-Salvador, A., & Fiszman, S.M. 2004. Textural and sensory characteristics of whole and skimmed flavored set-type yogurt during long storage. *Journal of Dairy Science*, 87:4033-4041.
- 31-Sendra, E., Kuri, V., Fernández-López, J., Sayas-Barberá, E., Navarro, C., & Pérez-Alvarez, J.A. 2010. Viscoelastic properties of orange fiber enriched yogurt as a function of fiber dose, size and thermal treatment. *LWT-Food Science and Technology*, 43(4):708-714.
- 32-Sofu, A., & Ekinici, F.Y. 2007. Estimation of storage time of yogurt with artificial neural network modeling. *Journal of Dairy Science*, 90(7):3118-3125.
- 33-Supavititpatana, P., Wirjantoro, T.I., Apichartsrangkoon, A., & Raviyan, P. 2008. Addition of gelatin enhanced gelatin of corn-milk yogurt. *Food Chemistry*, 106:211-216.

Modeling of Changes in Physicochemical, Textural and Sensory Properties of Fortified Yoghurt with Zinc and Iron by Artificial Neural Networks

Mahmod Hosseinnejad¹, Seid Mahdi Jafari^{2*}, Mohammad Ganje³

1- M.Sc Graduate, Faculty of Food Science, University of Agricultural Sciences and Natural Resources, Gorgan, Iran

2- Associate Professor, Faculty of Food Science, University of Agricultural Sciences and Natural Resources, Gorgan, Iran

* Corresponding author (smjafari@gau.ac.ir)

3- PhD student, Faculty of Food Science, University of Agricultural Sciences and Natural Resources, Gorgan, Iran

Abstract

In this study, yogurt was fortified with iron and zinc in equal concentrations, 20, 40 and 60 mg per 1 kg of milk and the samples were tested in 1, 7 and 14 days of storage in terms of different properties of product including physicochemical properties (acidity, pH, syneresis, water holding capacity, viscosity), textural properties (hardness, elasticity, firmness, cohesiveness, adhesiveness) and sensory properties (texture, flavor, color, odor and acceptance). For predicting the changes in qualitative indices, neural network tool in MATLAB 2013Ra was used. In different networks, the Feed-Forward-Back-Propagation networks by 2-2-3-14 and 2-4-14 topology, with 0.997 and 0.991 correlation coefficients and 0.4090 and 0.1040 mean square errors, including hyperbolic tangent sigmoid transfer function, Levenberg-Marquardt learning algorithm and 1000 epoch was determined as the best neural models for yoghurt fortified with Fe and Zn, respectively. Optimal models were also investigated and the results of these models with high correlation coefficients (more than 0.98) and very low standard deviation were able to predict trends.

Keywords: Artificial neural network, Fortification, Modeling, Texture analyses