



ارائه مدل کامپیوتری جهت پیش‌بینی ماندگاری لاکتوباسیلوس اسیدوفیلوس در ماست پروبیوتیک

* غلامعلی شریفی عرب^۱، روشنک رفیعی نظری^۲، حسین جلالی^۲ و مجید عرب‌عامری^۳

^۱ دانشجوی کارشناسی‌ارشد گروه مهندسی علوم و صنایع غذایی دانشگاه آزاد دامغان، استادیار دانشگاه آزاد اسلامی گروه مهندسی علوم و صنایع غذایی واحد دامغان، ^۲ کارشناس‌ارشد مهندسی علوم و صنایع غذایی، دانشگاه علوم پزشکی شاهرود، معاونت غذا و دارو

تاریخ دریافت: ۹۱/۱۰/۱۱؛ تاریخ پذیرش: ۹۲/۴/۲۳

چکیده

در سال‌های اخیر، استفاده از شبکه‌های عصبی مصنوعی (شبکه‌های عصبی) در بسیاری از بخش‌های صنایع غذایی افزایش یافته و از شبکه‌های عصبی مصنوعی در حل بسیاری از مشکلات کنترل کیفیت استفاده شده است. هدف از این مطالعه توسعه شبکه‌های عصبی جهت ارزیابی کیفیت ماست پروبیوتیک می‌باشد. در این مطالعه، شبکه عصبی پس انتشار با الگوریتم لونیگ-مارکواریت به عنوان مدل استفاده شد. پارامترهای مختلف از جمله: اسیدیته، pH، آب‌اندازی، رنگ و شمارش باکتریایی (استریتوکوک ترموفیلوس، لاکتوباسیلوس بولگاریکوس) به عنوان عوامل موثر بر زنده ماندن باکتری لاکتوباسیلوس اسیدوفیلوس در نظر گرفته شد. کارایی مدل توسعه یافته از طریق محاسبه میانگین مربعات خطا، ضریب تبیین مورد ارزیابی قرار گرفت. همچنین تحقیقات نشان داده است نوع تابع تحریک نیز در کارایی مدل شبکه عصبی موثر است بنابراین دو نوع تابع تحریک تانژانت سیگموئید و خطی در مرحله پیش پردازش برای بهینه سازی مدل به کار گرفته و با هم مقایسه شدند براساس نتایج^۱ به دست آمده، تابع تحریک تانژانت سیگموئید با ۱۰ نرون در لایه مخفی در روزهای ۱، ۷، ۱۴ به ترتیب دارای بیشترین ضریب ۰/۹۹۷، ۰/۹۹۴ و ۰/۹۹۳ و میانگین مربعات خطا (MSE) ۰/۰۰۰۵۶، ۰/۰۰۰۷۵ و ۰/۰۰۰۸۴ بود. البته به‌طور کلی بیشتر مدل‌ها از دقت تخمین مناسبی جهت پیش

*مسئول مکاتبه: sharifi268@gmail.com

بینی قابلیت زنده‌مانی باکتری لاکتوباسیلوس اسیدوفیلوس در سه دوره زمانی برخوردار بودند. بنابراین بهترین ساختار شبکه عصبی ۳-۱۰-۳۴ برای پیش‌بینی زنده‌مانی بود.

واژه‌های کلیدی: ماست پروبیوتیک، شبکه عصبی، لاکتوباسیلوس اسیدوفیلوس

مقدمه

فرآورده‌های لبنی پروبیوتیک به دلیل تاثیرات زیادی که بر سلامت مردم دارد از اهمیت خاصی برخوردار است باکتری‌های پروبیوتیک با تاثیر مثبتی که بر روی فلور مفید روده دارد باعث جلوگیری از رشد باکتری‌های مضر شده و اثر مثبتی بر عملکرد دستگاه گوارش دارند. آنها همچنین سبب افزایش هضم بهتر غذاها، بالابردن عملکرد سیستم ایمنی بدن و افزایش پایداری، مقاومت در برابر عفونت و سرایت بیماری‌ها می‌شوند (راسدهاری و همکاران، ۲۰۰۸؛ یگانه زاد و همکاران، ۲۰۰۷).

پروبیوتیک‌ها همچنین با تولید اسیدلاکتیک و پر اکسید هیدروژن و اسیداستیک سبب متعادل شدن اسیدیته روده شده و از تولید و تکثیر باکتری‌های پاتوژن جلوگیری می‌کنند برخی از پروبیوتیک‌ها ترکیبات آلی بنام باکتریوسین تولید می‌کند که این ترکیبات یک آنتی‌بیوتیک طبیعی می‌باشد (دایو و همکاران، ۱۹۹۷). مصرف لبنیات پروبیوتیک می‌تواند در جلوگیری از اسهال مسافرتی و عفونت‌های ناشی از هلیکوباکتری پیلوری در معده موثر باشد. ماست به‌علت دارا بودن پارامترهای خاص فیزیکوشیمیایی می‌تواند محیط مناسبی برای نگهداری و انتقال باکتری‌های پروبیوتیک به بدن باشد (باری و همکاران، ۲۰۰۹؛ دایو و همکاران، ۱۹۹۷).

استارترهای مورد استفاده در ماست پروبیوتیک، استرپتوکوکوس ترموفیلوس و لاکتو باسیلوس بولگاریکوس و سوش‌های مختلفی از باکتری‌های پروبیوتیک مانند لاکتوباسیلوس اسیدوفیلوس، بیفیدو باکتریوم لاکتیس و بیفیدو باکتریوم بیفیدیوم می‌باشد (تارمراج و شاه، ۲۰۰۳). پارامترهای مختلف فیزیکوشیمیایی ماست می‌تواند در طی نگهداری بر بقای باکتری‌های پروبیوتیک تاثیرگذار باشد از جمله این پارامترها pH، اسیدیته، میزان باکتری‌های ماست، زمان دمای نگهداری، وجود اکسیژن، زمان گرمخانه‌گذاری و آغازگر اولیه می‌باشد (باری و همکاران، ۲۰۰۹، دنکور و همکاران، ۲۰۰۷). در این مطالعه قابلیت زیستی باکتری پروبیوتیک در طی روزهای ۱، ۷ و ۱۴ بررسی و با استفاده از مدل شبکه عصبی مقدار آن پیش‌بینی گردید.

شبکه‌های عصبی مصنوعی، برای اولین بار در سال ۱۹۴۳ معرفی، اما این روش برای مدت‌های طولانی بدون استفاده بود که بعدها با توسعه رایانه‌ها و همچنین ظهور الگوریتم آموزش پس انتشار برای شبکه‌های پیش‌خور در سال ۱۹۸۶ استفاده از آنها وارد مرحله تازه‌ای گردید (البرزی، ۱۳۸۳).

مدل شبکه عصبی از مجموعه‌ای عناصر محاسباتی بنام نرون تشکیل شده است که عملکرد آنها شبیه به نرون‌های زیستی می‌باشد این مدل‌ها قادر می‌باشند بدون هیچ دانش قبلی از یک مسئله یا فرآیند مورد نظر، روابط ذاتی بین داده‌ها را کشف نمایند (مهناج، ۱۳۸۷).

پژوهشگران زیادی دیگر از شبکه عصبی مصنوعی برای دستیابی به اهداف مورد نظر در زمینه صنایع غذایی استفاده کرده‌اند که برخی از آنها عبارتند از پیش‌بینی رشد میکروبی مواد غذایی (گاریسا-گیمنو و همکاران، ۲۰۰۲)، ارزیابی تقلب روغن زیتون (گوداکره وکل، ۱۹۹۲)، پیش‌بینی ماندگاری آرد گندم در پخت نان (هاریموتو و همکاران، ۱۹۹۵)، پیش‌بینی اثر ترکیبی دما، pH و فعالیت آبی در غیرفعال کردن حرارتی باکتری‌ها (لو و ناکائی، ۲۰۰۱)، ویژگی‌های حسی رشته فرنگی (تولبک و همکاران، ۲۰۰۳)، رطوبت به‌عنوان تابعی از هدایت حرارتی مواد غذایی (سابلانی شیم و شافیور رحمان، ۲۰۰۳)، پیش‌بینی برآورد زمان ماندگاری نوشیدنی‌های قهوه فوری و کیفیت حسی نوشیدنی قهوه فوری (سامیت گویال، ۲۰۱۱). در گذشته برخی از پژوهشگران اقدام به ارائه مدل‌های مختلف جهت پیش‌بینی میزان رشد باکتری‌های پروبیوتیک کردند که بیشتر آنها دارای نتایج نزدیک به هم می‌باشد کیوی‌هارجو و همکاران (۲۰۰۵) برای بهینه‌سازی و تعیین ضرایب رشد بیفیدوباکتریوم لانگوم ATCC از مدل RSM استفاده کردند. پارامترهای دما (۳۶ تا ۴۰ درجه سانتی‌گراد) و زمان، pH را به‌عنوان پارامترهای موثر بر رشد در نظر گرفتند نتایج حاصل از این مدل نشان داد که RSM برای استفاده در تخمین تقریبی ضریب رشد مناسب است، ضریب ثابت رشد برای تولید ماست توسط این مدل با ضریب تبیین حدود $R^2 = 0/806$ پیش‌بینی شد.

همچنین سوفو و ایکنجی (۲۰۰۷) مطالعه‌ای را تحت عنوان تخمین زمان ماندگاری ماست با استفاده از مدل هوش مصنوعی انجام دادند. در این پژوهش، تغییرات فیزیکوشیمیایی و میکروبی و بافت ماست در طی زمان‌های ۱-۷-۱۴ روز نگهداری برای تعیین بهترین زمان ماندگاری بررسی شد سپس اطلاعات به‌دست آمده با استفاده از مدل هوش مصنوعی برای تعیین بهترین زمان ماندگاری ماست استفاده شد. اطلاعات ورودی در این مدل ریاضی، pH، شمارش میکروب‌های هوازی، مخمر،

کپک بود. و اطلاعات خروجی تغییرات زمان ماندگاری ماست بود با انجام این پژوهش مشخص شد که نتایج حاصل از پیش‌بینی مدل ریاضی تقریباً منطبق بر نتایج حاصل از کار تجربی بود. هدف این پژوهش ارائه یک مدل شبکه عصبی برای پیش‌بینی زنده‌مانی باکتری پروبیوتیک در ماست بر اساس داده‌های pH و اسیدیته اولیه، ثانویه و نهایی، سینرسیس، تعداد باکتری‌های استرپتوکوکوس ترموفیلوس و لاکتوباسیلوس بولگاریکوس و لاکتوباسیلوس اسیدوفیلوس می‌باشد که در پایان به منظور بررسی همبستگی نتایج مشاهدات تجربی و نتایج حاصل از شبکه عصبی از ضریب R2 استفاده می‌کنیم.

مواد و روش‌ها

آغازگرهای مصرفی: باکتری‌های استارتر ماست با مشخصه ۱۱ YC-x حاوی لاکتوباسیلوس دلبروکی زیر گونه بولگاریکوس و استرپتوکوکوس ترموفیلوس و کشت تک سویه پروبیوتیکی لاکتوباسیلوس اسیدوفیلوس LA-5 هر دو به صورت خشک شده انجمادی و از نوع DVS از نمایندگی شرکت کریستین‌هانسن دانمارک تهیه گردید.

روش تهیه مایه کشت اولیه: برای تهیه کشت اولیه، ابتدا دو لیتر شیر ۲/۵ درصد چربی تحت فرآیند حرارتی ۸۵-۸۰ درجه سانتی‌گراد به مدت ۲۰-۱۵ دقیقه قرار گرفت، سپس شیر حرارت دیده به دو ارلن مایر یک لیتری انتقال داده شده، پودر مایه Unit 50 حاوی استارترهای ماست به یک ارلن و بسته ۲۵ گرمی حاوی باکتری پروبیوتیک لاکتوباسیلوس اسیدوفیلوس به ارلن دیگر منتقل گردید، ارلن‌ها به مدت ۱۲ ساعت در دمای ۴۰ درجه گرم‌خانه‌گذاری شدند در پایان ظروف به سردخانه منتقل گردید. **روش تولید ماست پروبیوتیک:** جهت تولید ماست پروبیوتیک، مقدار ۱۵۰-۱۲۰ میکرولیتر از استارترهای ماست و ۱۴۰ میکرولیتر از باکتری پروبیوتیک به طور همزمان به ظروف استریل حاوی ۲۵۰ میلی لیتر شیر پاستوریزه ۲/۵ درصد چربی که ۱/۵ درصد شیر خشک بدون چربی به آن، اضافه گردیده، تلقیح شد. سپس نمونه‌ها در دمای ۴۲-۴۰ درجه سانتی‌گراد گرم‌خانه‌گذاری گردید. بعد از آنکه pH نمونه‌ها به ۴/۷-۴/۵ رسید، از گرم‌خانه خارج و به سردخانه منتقل گردیدند.

فاکتورهای مورد آزمون

اندازه‌گیری pH: نمونه‌ها با استفاده از pH متردیجیتال HANNA مدل H18314 اندازه‌گیری شد. pH نمونه‌ها در دمای ۲۵ درجه سانتی‌گراد بر اساس روش (AOAC:2002.981.12) اندازه‌گیری شد (AOAC, 2002).

اندازه‌گیری اسیدیته: اسیدیته بر اساس درجه دورنیک و با استفاده از سود ۱/۹ نرمال و معرف فنل فتالین محاسبه گردید (AOAC, 2002).

سنجش آب اندازی یا جدا شدن سرم: جهت اندازه‌گیری میزان آب‌اندازی، ابتدا ۲۵ گرم نمونه ماست در لوله‌های سانتریفیوژ وزن شد و سپس لوله‌ها در سانتریفیوژ با دور G350 به مدت ۳۰ دقیقه در دمای ۱۰ درجه سانتی‌گراد سانتریفیوژ شدند. مایع جدا شده از نمونه که در قسمت بالای لوله جمع شده بود، خارج گردید و لوله‌ها مجدداً وزن شدند. مقدار آب‌اندازی به صورت وزن آب از دست رفته در ۱۰۰ گرم ماست گزارش گردید (AOAC, 2002).

آزمون میکروبی: برای شمارش باکتری پروبیوتیک لاکتو باسیلوس اسیدوفیلوس در ماست، مقدار ۱۰ گرم از نمونه ماست در ۱۰۰ میلی‌لیتر از بافر سترات سدیم ۱ درصد وزنی / حجمی پراکنده شده و بعد به مدت ۱۰ دقیقه در دمای اتاق با استفاده از هم‌زن مغناطیسی هم‌زده شد. سپس ۱ میلی‌لیتر از محلول فوق به رقت‌های بعدی افزوده شده، یک میلی‌لیتر از رقت‌های ۶، ۷ و ۸ در داخل پلیت قرار داده و سپس با محیط کشت MRS-BILE Agar کشت داده شد و به مدت ۴۸ تا ۷۲ ساعت در دمای ۳۷ درجه سانتی‌گراد تحت شرایط بی‌هوازی گرمخانه‌گذاری شدند و روش پورپلیت استفاده گردید به این شکل که ابتدا رقت‌های مناسبی از نمونه در محلول رینگر استریل تهیه شده و بعد از انجام کشت، پلیت‌ها به گرمخانه ۳۷ درجه سانتی‌گراد منتقل شدند و سپس شمارش کلنی تعداد پرگنه‌ها بعد از ۷۲ ساعت گرمخانه‌گذاری انجام گردید (تارماراج و شاه، ۲۰۰۳).

مدل سازی شبکه عصبی: به‌طور کلی شبکه‌عصبی یک تکنیک هوش مصنوعی بوده که مشابه سیستم عصبی مغز طراحی شده است از پرکاربردترین آنها مدل پرسپترون چند لایه می‌باشد. این مدل اغلب از یک لایه ورودی یک لایه خروجی و یک یا چند لایه پنهان تشکیل شده است. هر لایه می‌تواند شامل چندین نرون باشد سیگنال ورودی نرون‌ها Xi به وسیله مجموعه ورودی‌های وزندهی شده بیان می‌شود.

$$h_i = \sum_{\substack{i=1 \\ i \neq j}}^N x_i \cdot w_{j,i} + \theta \quad (1)$$


که X_i مین سیگنال از لایه قبلی است. w_{ij} وزن ارتباطی بین نرون‌ها و θ میزان بایاس می‌باشد. بردار h_i نتیجه حاصل از شبکه می‌باشد (اریکاینن، ۱۹۹۳). در این مطالعه از توابع تحرک تانژانت سیگموئید و خطی استفاده شده است پس از فرآیند آموزش شبکه عصبی با ساختار مناسب، لازم است کارایی آن بررسی شود برای این کار ما از مقدار میانگین مربع خطاها و میزان R^2 جهت برآزش در نمودار نمونه‌های پیش‌بینی شده در مقابل نمونه‌های واقعی استفاده کردیم.

انتخاب بهترین آرایش شبکه: اساس آموزش شبکه‌های عصبی بر مبنای آزمون و خطا می‌باشد تا بهترین آرایش شبکه با تغییر تعداد لایه‌های پنهان و نرون‌های آنها، تابع تحریک، الگوریتم آموزش و تعداد تکرار در مرحله آموزش جهت برآورد پارامتر خروجی مورد نظر ارائه شود مبنای تصمیم‌گیری برای انتخاب بهترین شبکه در هر بار اجرای برنامه پارامتر ضریب همبستگی R_2 و کمترین میزان مربعات خطا (mean squared error) می‌باشد که فرمول آن در زیر ارائه شده است:

$$R^2 = 1 - \left[\sum_1^N \left(\frac{Q_{exp} - Q_{cal}}{Q_{exp}} \right)^2 \right] \quad (2)$$

$$MSE = \left[\sum_1^N \left(\frac{Q_{exp} - Q_{cal}}{n} \right)^2 \right] \quad (3)$$

در روابط بالا Q_{exp} : مقادیر مشاهده شده، Q_{cal} : مقادیر پیش‌بینی تعداد، N : نمونه‌ها در لایه خروجی، n : تعداد داده‌ها می‌باشد (هوآنگ و همکاران، ۲۰۰۷).



شکل ۱- شمایک شبکه عصبی پس انتشار چند لایه با توپولوژی های ۳-۱۰-۳۴ پارامتر فیزیوشیمیایی ورودی و تغییرات شمارش لاکتوباسیلوس اسیدوفیلوس (زنده‌مانی) در لایه خروجی.

برای مدل‌سازی از نرم‌افزار متلب نسخه ۷ استفاده شد، نوع شبکه طراحی شده پرسپترون چندلایه (FF) بود که در این مدل از ۱۰ نرون در لایه ورودی شامل pH ساعت‌های (۰،۱،۲،۳،۴) روز (۱،۷،۱۴) و همچنین اسیدیته ساعت‌های (۰،۱،۲،۳،۴) روز (۱،۷،۱۴) و آب‌اندازی (سینرسیس) روزهای (۱،۷،۱۴)، اندازه‌گیری رنگ روزهای (۱،۷،۱۴) و شمارش باکتری استرپتوکوکوس ترموفیلوس و لاکتوباسیلوس بولگاریکوس روز ۱،۷،۱۴ و سه نرون تعداد باکتری‌های لاکتوباسیلوس اسیدوفیلوس در روز (۱،۷،۱۴) به‌عنوان لایه خروجی در نظر گرفته شد در شکل ۱ ساختار این شبکه چند لایه را نشان می‌دهد.

نتایج و بحث

در بیشتر موارد با گذشت زمان زنده‌مانی (viability)، باکتری‌های پروبیوتیک در محصولات لبنی کاهش می‌یابد. این تغییر شمارش باکتری‌های پروبیوتیک در ماست می‌تواند تا حد زیادی تحت تاثیر شرایط قبل و بعد از تولید قرار گیرد که این شرایط در پارامترهای شیمیایی فیزیکی و میکروبی مورد ارزیابی قرار می‌گیرد. با توجه به بررسی نتایج این مطالعه، با کاهش pH و افزایش اسیدیته ماست‌های پروبیوتیک در طی زمان میزان زنده‌مانی باکتری پروبیوتیک کاهش یافت، (جدول ۱) که این با سایر مطالعات از جمله یافته‌های ساهادوا و همکارانش مطابقت داشت (ساهادوا و همکاران، ۲۰۱۱؛ تایلاندر و همکاران، ۱۹۹۶).

همچنین با افزایش زمان نگهداری میزان آب‌اندازی ماست افزایش یافت که نشان‌دهنده بهبود بافت ماست می‌باشد (جدول ۲). با توجه به بررسی انجام شده میزان زنده‌مانی باکتری پروبیوتیک

لاکتوباسیلوس اسیدوفیلوس با گذشت زمان در طی روزهای یک، هفت و چهارده کاهش یافت که این با مطالعه ساهاداها و همکارانش مطابقت داشت (ساهادوا و همکاران، ۲۰۱۱).

جدول ۱- خلاصه نتایج متغیرهای کمی پارامترهای شیمیایی ۹۰ تیمار ماست پروبیوتیک.

متغیر	میانگین	مینیموم	ماکزیمم
pH (ساعت ۰)	۶/۵۷	۶/۳۹	۶/۶۹
pH (ساعت ۱)	۶/۴۸	۶/۳۱	۶/۶۱
pH ساعت ۲	۶/۰۷	۵/۶۶	۶/۴۷
pH ساعت ۳	۵/۱۸	۴/۹۹	۵/۸۹
pH ساعت ۴	۴/۷	۴/۳۸	۵/۱۶
pH روز ۱	۴/۵۷	۴/۳۸	۵/۶۶
pH روز ۷	۴/۵۶	۴/۴۱	۵/۷۲
pH روز ۱۴	۴/۴۵	۴/۳۷	۴/۵۹
اسیدیته (ساعت ۰)	۰/۱۷	۰/۱۳	۰/۱۹
ساعت ۱	۰/۱۸	۰/۱۴	۰/۲
ساعت ۲	۰/۲۶	۰/۱۷	۰/۳۳
ساعت ۳	۰/۴۲	۰/۳۰	۰/۵
ساعت ۴	۰/۵۸	۰/۴۹	۰/۶۹
روز ۱	۰/۷۱	۰/۶۴	۰/۸۶
روز ۷	۰/۷۴	۰/۶۸	۰/۸
روز ۱۴	۰/۷۴	۰/۶۸	۰/۸

شمارش میکروبی در طول گرمخانه‌گذاری و ماندگاری محصول به‌منظور تشخیص سرعت رشد باکتری‌ها انجام گرفت. باکتری‌های لاکتوباسیلوس اسیدوفیلوس به روش شمارش مستقیم مورد شمارش قرار گرفتند. نتایج نشان می‌دهد که تعداد باکتری‌های آغازگر پس از ۷ و ۱۴ روز نسبت به روز اول به‌طور معنی‌داری کاهش یافت باکتری‌های پروبیوتیکی برای این که خواص خود را در بدن مصرف‌کننده مواد غذایی به‌وجود بیاورند باید به میزان 10^7 (Log CFU/mL) به‌صورت زنده وجود داشته باشند که در این

پژوهش میزان باکتری‌های لاکتو باسیلوس اسیدوفیلوس در اغلب تیمارهای مورد آزمایش در این محدوده بود (جدول ۳). بنابراین خواص موردنظر میکروب‌های پروبیوتیکی را در مصرف کننده به وجود می‌آورند.

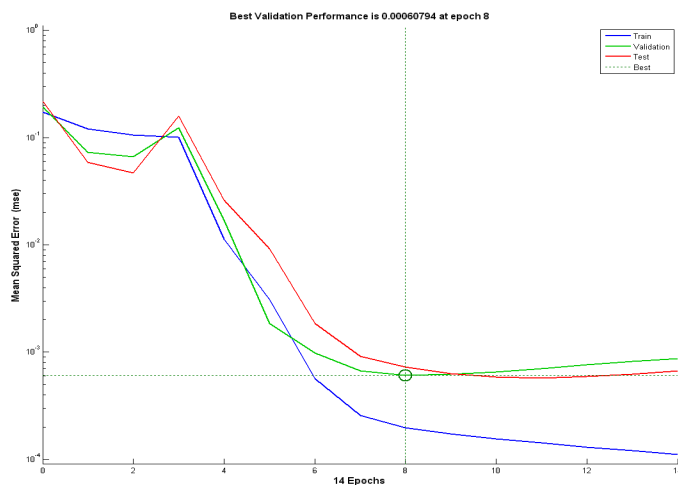
جدول ۲- خلاصه نتایج متغیرهای کمی پارامترهای فیزیکی ۹۰ تیمار ماست پروبیوتیک.

متغیر	میانگین	مینیموم	ماکزیمم
پارامتر رنگ سنجی a در روز ۱	۶۵/۸	۶۳/۴	۶۷/۱
پارامتر رنگ سنجی a در روز ۷	۶۶/۰۵	۶۵	۶۷/۱
پارامتر رنگ سنجی a در روز ۱۴	۶۵	۶۳/۵	۶۶/۶
پارامتر رنگ سنجی b در روز ۱	۴/۸	۴/۱	۵/۴
پارامتر رنگ سنجی b در روز ۷	۴/۵	۴/۱	۵/۳
پارامتر رنگ سنجی b در روز ۱۴	۵/۲	۴/۶	۵/۷
پارامتر رنگ سنجی L در روز ۱	۱۲/۳	۱۱/۲	۱۳/۶
پارامتر رنگ سنجی L در روز ۷	۱۱/۸	۱۰/۸	۱۲/۹
پارامتر رنگ سنجی L در روز ۱۴	۱۳/۲	۱۲	۱۴/۲
آب اندازی در روز ۱	۱۲/۸۴	۶/۱۶	۱۷/۳۴
آب اندازی در روز ۷	۱۴/۸۹	۹/۶۸	۱۷/۸۶
آب اندازی در روز ۱۴	۱۶/۴۴	۱۲/۴۷	۲۰/۰۲

جدول ۳- خلاصه نتایج متغیرهای کمی پارامترهای میکروبی ۹۰ تیمار ماست پروبیوتیک.

متغیر	میانگین	مینیموم	ماکزیمم
شمارش استرپتوکوکوس ترموفیلوس در روز ۱ (Log CFU/mL)	۸/۸۲	۸/۵۸	۹/۰۸
شمارش استرپتوکوکوس ترموفیلوس در روز ۷ (Log CFU/mL)	۸/۶۴	۸/۴۳	۸/۹۲
شمارش استرپتوکوکوس ترموفیلوس در روز ۱۴ (Log CFU/mL)	۸/۷۵	۸/۴۷	۹/۰۹
شمارش لاکتو باسیلوس دلبروکی در روز ۱ (Log CFU/mL)	۷/۴۱	۷/۰۳	۷/۷۵
شمارش لاکتو باسیلوس دلبروکی در روز ۷ (Log CFU/mL)	۶/۷۸	۶/۱۲	۷/۴۹
شمارش لاکتو باسیلوس دلبروکی در روز ۱۴ (Log CFU/mL)	۶/۴۵	۵/۰۶	۷/۸۸
شمارش لاکتو باسیلوس اسیدوفیلوس در روز ۱ (Log CFU/mL)	۷/۳۳	۷/۱۵	۷/۴۶
شمارش لاکتو باسیلوس اسیدوفیلوس در روز ۷ (Log CFU/mL)	۷/۲۵	۶/۸۹	۷/۶۸
شمارش لاکتو باسیلوس اسیدوفیلوس در روز ۱۴ (Log CFU/mL)	۷/۰۶	۶/۲۱	۷/۲۴

به‌عنوان پیش پردازش چندین اجرا توسط نرم‌افزار انجام شد و با مشاهده عملکرد آموزش شبکه‌ها، داده‌های نامطلوب و پرت برداشته شدند، اگرچه این اجراها مدت زیادی طول کشید اما منجر به شناسایی داده‌های پرت و برچیدن آنها برای بهبود آموزش عملکرد پیشگویی شبکه‌ها شد. در این اجراها مشاهده شد اگر چه با گذشت اپیک‌های زیاد تابع خطای شبکه به سمت صفر میل می‌کرد (شکل ۲) ولی تابع خطای اعتبارسنجی افزایش می‌یافت و در نتیجه شبکه‌های آموزش داده شده نتوانستند پیشگویی صحیحی از مجموعه داده‌های تست داشته باشند و این به خاطر وجود داده‌های پرت در میان مجموعه داده‌های آموزش بود زیرا این داده‌ها تفاوت زیادی با بقیه داده‌ها داشتند در صورتی‌که با گذشت اپیک‌های زیاد در راستای کاهش خطای شبکه، تابع خطای اعتبارسنجی نیز کاهش یابد در آن صورت شبکه با کمترین خطا قابل تعمیم خواهد بود (مهناج، ۱۳۸۷؛ قدیر، ۲۰۰۳؛ رزمی‌راد و همکاران، ۲۰۰۸). براساس بینش مهندسی و با توجه به محدوده تغییرات پارامترهای ورودی پایگاه داده تعدادی داده غیرواقعی به‌منظور افزایش مجموعه داده‌های آموزش و افزایش محدوده پیشگویی زنده‌مانی در زمان‌های مختلف به مجموعه داده‌های آموزش افزوده شدند. نتایج روند تغییرات MSE به‌دست آمده از پیش پردازش داده‌های سه مرحله آموزش، اعتبارسنجی و آزمایش جهت پیش‌بینی تغییرات شمارش لاکتوباسیلوس اسیدوفیلوس (زنده‌مانی) در لایه خروجی مدل تعریف شده برای شبکه عصبی FF در شکل ۲ آورده شده است که در آن ۸ دور آموزش با الگوریتم آموزشی لونبرگ-مارکوات کمترین میزان میانگین مربعات خطا مشاهده می‌شود که به‌عنوان مدل بهینه انتخاب شده است.



شکل ۲ - روند تغییرات MSE در سه مرحله آموزش، اعتبارسنجی و آزمایش در لایه خروجی.

بعد از مرحله پیش پردازش تلاش‌های زیادی در راستای کاهش تابع خطای آموزش شبکه‌ها با افزایش تعداد لایه‌های مخفی و تعداد نرون‌های آنها انجام شد نتایج نشان دادند که افزایش تعداد لایه‌های مخفی (بیش از یک لایه مخفی) تابع خطای شبکه‌ها را به صورت قابل توجهی کاهش نداد ولی افزایش تعداد نرون‌های لایه مخفی هر دو نوع شبکه ارائه شده تا تعداد معینی توانست تابع خطای آنها را بیشتر کاهش دهد که مقادیر پارامترهای مختلف مدل در پیش‌بینی زنده‌مانی باکتری پروبیوتیک در زمان‌های مختلف در ماست در طی روزهای ۱، ۷ و ۱۴ در جدول ۴ نشان داده شده است. بررسی نتایج، گویای این مطلب است که با افزایش تعداد لایه‌های پنهان از ۱ تا ۱۰ به مرور میزان خطای مربعات کاهش و میزان ضریب تبیین افزایش می‌یابد این در حالی است که با افزایش لایه پنهان از ۱۰ به ۲۰ میزان خطای مربعات افزایش و میزان ضریب تبیین کاهش می‌یابد بنابراین مقدار بهینه عملکرد شبکه با ۱۰ لایه می‌باشد. همچنین تحقیقات نشان داده است نوع تابع تحریک نیز در کارایی مدل شبکه عصبی موثر است بنابراین دو نوع تابع تحریک تانژانت سیگموئید و خطی در مرحله پیش پردازش برای بهینه سازی مدل به کار گرفته و با هم مقایسه شدند براساس نتایج به دست آمده، تابع تحریک تانژانت سیگموئید با ۱۰ نرون در لایه مخفی در روزهای ۱، ۷ و ۱۴ به ترتیب دارای بیشترین ضریب ۰/۹۹۷، ۰/۹۹۴ و ۰/۹۹۳ و میانگین مربعات خطا (MSE) ۰/۰۰۰۵۶، ۰/۰۰۰۷۵ و ۰/۰۰۰۸۴ بود. البته به طور کلی اغلب مدل‌ها از دقت تخمین مناسبی جهت پیش‌بینی قابلیت زنده‌مانی باکتری پروبیوتیک در طی نگهداری برخوردار بودند (شکل ۳).

نشریه فرآوری و نگهداری مواد غذایی جلد (۴)، شماره ۱، ۱۳۹۱

جدول ۴- مقایسه اثر تعداد لایه‌های پنهان و تعداد نرون‌ها در هر لایه پنهان بر دقت پیش‌بینی زنده‌مانی باکتری پروبیوتیک در روز ۱ در ماست

داده	Feed-forward							
	خطی				تانزانته سیگموئید			
	نرون در لایه پنهان	اعتبار سنجی R ²	آزمایش R ²	mse	نرون در لایه پنهان	اعتبارسنجی R ²	آزمایش R ²	mse
شمارش لاکتوباسیلوس اسیدوفیلوس روز ۱ (logCFU/MI)	۱	۰/۹۳۸	۰/۹۴۴	۰/۰۵۷	۱	۰/۹۲۱	۰/۹۶۴	۰/۰۰۵۷
	۵	۰/۹۸۸	۰/۹۵۶	۰/۰۱۵	۵	۰/۹۴۱	۰/۹۷۶	۰/۰۰۶۱
	۱۰	۰/۹۷۵	۰/۹۶۷	۰/۰۰۶۲	۱۰	۰/۹۶۷	۰/۹۹۷	۰/۰۰۰۵۶
	۱۵	۰/۹۶	۰/۹۵	۰/۰۱۵	۱۵	۰/۹۴۳	۰/۹۷۸	۰/۰۰۸۴۵
	۲۰	۰/۹۶۶	۰/۹۵۱	۰/۰۰۳۷	۲۰	۰/۹۴۹	۰/۹۶۱	۰/۰۰۵۸۷

جدول ۵- مقایسه اثر تعداد لایه‌های پنهان و تعداد نرون‌ها در هر لایه پنهان بر دقت پیش‌بینی زنده‌مانی باکتری پروبیوتیک در روز ۷ در ماست.

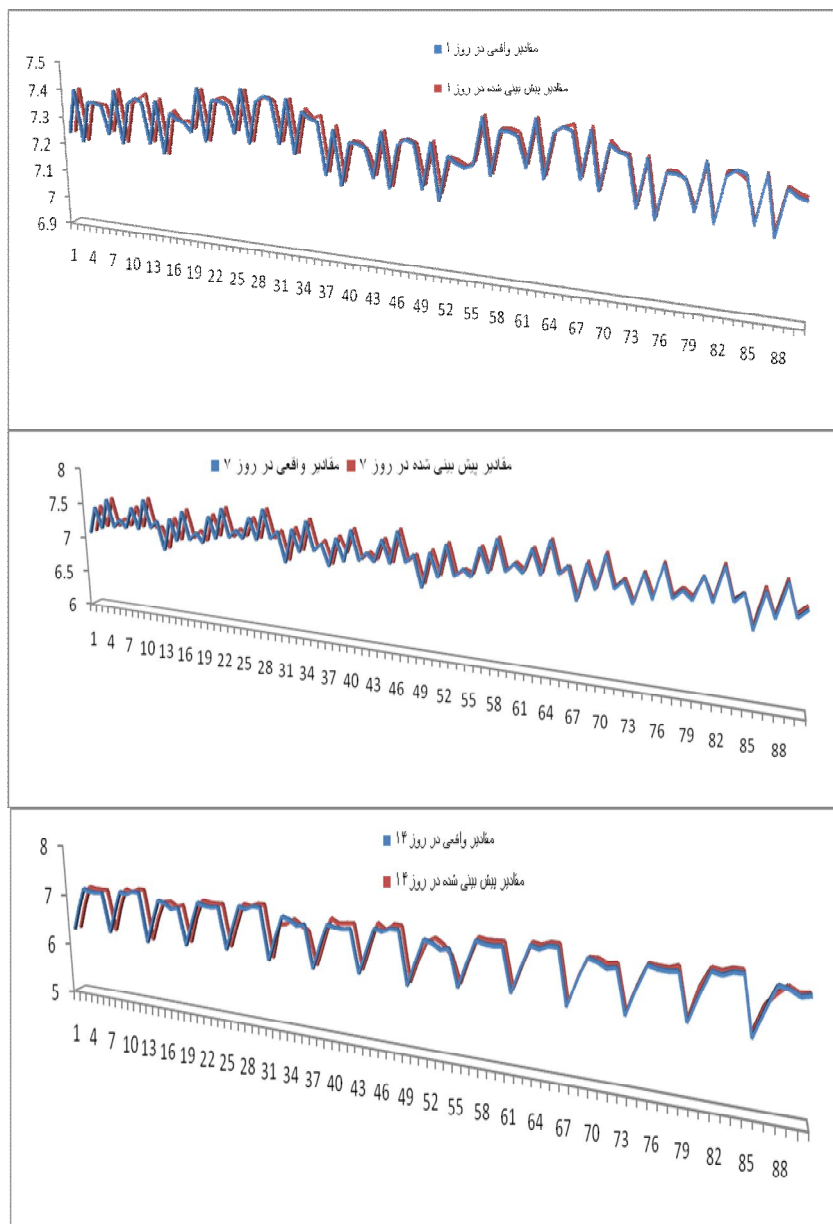
داده	Feed-forward							
	خطی				تانزانته سیگموئید			
	نرون در لایه پنهان	اعتبار سنجی R ²	آزمایش R ²	mse	نرون در لایه پنهان	اعتبارسنجی R ²	آزمایش R ²	mse
شمارش لاکتوباسیلوس اسیدوفیلوس روز ۷ (logCFU/MI)	۱	۰/۹۴	۰/۹۴	۰/۰۵۵	۱	۰/۹۲۱	۰/۹۶	۰/۰۰۵۷
	۵	۰/۹۶	۰/۹۶	۰/۰۱۶	۵	۰/۹۴۱	۰/۹۷	۰/۰۰۶۱
	۱۰	۰/۹۷	۰/۹۹۷	۰/۰۰۶۲	۱۰	۰/۹۷۸	۰/۹۹۴	۰/۰۰۰۷۵
	۱۵	۰/۹۹۲	۰/۹۶۲	۰/۰۰۳۳	۱۵	۰/۹۴۳	۰/۹۷۶	۰/۰۰۸۴۵
	۲۰	۰/۹۸۸	۰/۹۶۸	۰/۰۰۳۶	۲۰	۰/۹۴۹	۰/۹۶۱	۰/۰۰۵۸۷

غلامعلی شریفی عرب و همکاران

جدول ۶- مقایسه اثر تعداد لایه‌های پنهان و تعداد نرون‌ها در هر لایه پنهان بر دقت پیش‌بینی زنده‌مانی باکتری پروبیوتیک در روز ۱۴ در ماست.

داده	Feed-forward							
	خطی				تانژانت سیگموئید			
	نرون در لایه پنهان	اعتبار سنجی R^2	آزمایش R^2	mse	نرون در لایه پنهان	اعتبارسنجی R^2	آزمایش R^2	mse
شمارش لاکتوباسیلوس اسیدوفیلوس روز ۱۴ (logCFU/MI)	۱	۰/۹۴۹	۰/۹۴۱	۰/۰۵۶	۱	۰/۹۴۹	۰/۹۶۶	۰/۰۰۵۸
	۵	۰/۹۶۶	۰/۹۶۱	۰/۰۱۶۱	۵	۰/۹۶۶	۰/۹۷۱	۰/۰۰۶۵
	۱۰	۰/۹۶۷	۰/۹۹	۰/۰۰۶۳	۱۰	۰/۹۶۷	۰/۹۹۳	۰/۰۰۰۸۴
	۱۵	۰/۹۹۳	۰/۹۶۸	۰/۰۰۳۳	۱۵	۰/۹۹۳	۰/۹۷۵۶	۰/۰۰۸۳
	۲۰	۰/۹۸۹	۰/۹۶۷	۰/۰۰۳۸	۲۰	۰/۹۸۹	۰/۹۶۲	۰/۰۰۵۸

اما از میان آنها مدل ۳-۱۰-۳۴ با ضریب تبیین به ترتیب در روز ۱، ۷ و ۱۴، $R^2=0/997$ ، $R^2=0/994$ ، $R^2=0/993$ نسبت به سایر مدل‌ها از دقت بالاتری برخوردار بود. که نتایج این مطالعه با نتایج مدل شبکه عصبی آقای سوفوو همکارانش در پیش‌بینی زمان ماندگاری ماست با ضریب تبیین حدود $R^2=0/99$ مطابقت دارد.



شکل ۳- مقایسه داده‌های آزمایشگاهی و مقادیر پیش‌بینی شده بهترین شبکه آموزش دیده با توپولوژی ۳-۱۰-۳۴ در سه روز ۱، ۷، ۱۴.

نتایج این بررسی نشان داد که مدل ارائه شده می‌تواند جانشین بسیار قدرتمندی برای سایر مدل‌های آماری قدیمی باشد. در واقع یافته‌های تحقیق نشان داد که دقت کامل مدل مذکور مبتنی بر داده‌های ورودی می‌تواند برآورد بسیار مناسبی از زنده‌مانی باکتری‌های پروبیوتیک داشته باشد. تا به حال مدل مناسبی برای پیش‌بینی زنده‌مانی محصولات پروبیوتیک با استفاده از شبکه عصبی ارائه نشده است اما در برخی از تحقیقات به بررسی عوامل موثر بر رشد برخی از سویه‌های پروبیوتیک پرداخته شده است در مقام مقایسه، نتایج به دست آمده با نتایج کیوی‌ها رجو و همکاران (۲۰۰۵) نزدیک بود آنها برای پیش‌بینی ضرایب رشد بیفیدوباکتریوم لانگوم پارامترهای ورودی شامل دما و زمان، pH را به عنوان داده‌های ورودی انتخاب کرده که مدل سطح پاسخ و شبکه عصبی ضریب رشد را به ترتیب با ضریب تبیین حدود $R^2=0/80$ و $R^2=0/93$ پیش‌بینی نمود. همچنین در تحقیقی جانگامینا و همکاران (۲۰۱۱) با استفاده از مدل شبکه عصبی و مدل سطح پاسخ (RSM) به رشد بیفیدوباکتریوفیديوم پرداخته و میزان دقت نتایج حاصل از مدل RSM و ANN را به ترتیب دارای ضریب تبیین $R^2=0/84$ و $R^2=0/93$ بیان نمودند.

نتیجه‌گیری

در این مقاله مدل شبکه عصبی پیشرفته‌ای جهت ارائه پیش‌بینی ماندگاری باکتری‌های پروبیوتیک در ماست پروبیوتیک ارائه شده است. مقایسه نتایج حاصل از مدل‌های شبکه عصبی با مقادیر واقعی، نشان می‌دهد که مدل‌ها می‌توانند رشد لاکتوباسیلوس اسیدوفیلوس را با دقت بسیار بالایی پیش‌بینی نمایند. مدل پیشنهاد شده می‌تواند اثر سایر پارامترهای موثر بر رشد لاکتوباسیلوس اسیدوفیلوس را در نظر گیرد. اگرچه مدل‌ها با دقت بالا رشد لاکتوباسیلوس اسیدوفیلوس را ارائه نموده‌اند لیکن با افزایش آزمایش‌ها تجربی استفاده شده به منظور ورودی‌های شبکه می‌توان به سادگی دقت مدل‌ها را افزایش داد و علاوه بر آن می‌توان به کارگیری مدل‌های پیشرفته به سادگی اثر سایر پارامترها را بر کیفیت ماست نیز بررسی نمود.

منابع

- Alborzi, M. 2004. Introduction to Neural Networks, 2nd ed. Sharif University Press.
 AOAC. 2002. Official methods of analysis of the AOAC, 15thed. (Ed.S. Williams),
 Arlington, USA: Association of Official Analytical Chemists.
 Bari, M., Ashrafi, R., Alizadeh, M., and Rofehgarineghad, L. 2009. Effects of
 different of yogurt starter or probiotic bacteria, storage time & different

- concentration of cysteine on the microflora characteristics of Bio-Yogurt. *Research Journal of Biological Sciences*, 4, (2), 137-142.
- Dave, R., and Shah, N. 1997. Viability of yoghurt and probiotic bacteria in yoghurts made from commercial starter cultures. *International Dairy Journal*, 7: 31-41.
- Donkor, O.N., Nilmini, S.L.I., Stolic, P., Vasilgevic, T. and Shah, N.P. 2007. Survival & activity of selected probiotic organism in set-type yoghurt during cold storage. *International Dairy Journal*, 17, 92-151.
- Eerikainen, T., Linko, P., Siimes, T., and Zhu, Y.M. 1993. Fuzzy Logic and Neural Network Applications in Food Science and Technology, *Trends Food Science Technology*, 4:237-242.
- Ganga S., Meena, Suneel Gupta, Gautam C., Majumdar and Rintu Banerjee, 2011. Growth Characteristics Modeling of Bifidobacterium bifidum Using RSM and ANNGanga S. Meena, Suneel Gupta, Gautam C. Majumdar and Rintu Banerjee, Vol. 54, No. 6: pp. 1357-1366.
- García-Gimeno, R.M., Hervás-Martínez, C., and de Silóniz, M.I. 2002. Improving artificial neural networks with a pruning methodology and genetic algorithms for their application in microbial growth prediction in food. *International Journal of Food Microbiology*, 72, 19-30.
- Goodacre, R., and D.B. Kell. 1992. Rapid Assessment of the Adulteration of Virgin Olive Oils by Other Seed Oils Using Pyrolysis Mass Spectrometry and Artificial Neural Networks. *Journal of Science Food Agricultural*, 63:297-307.
- Huang, Y., Kangas, L.J., and Rasco, B.A. 2007. Applications of artificial neural networks (ANNs) in food science. *Critical Reviews in Food Science and Nutrition*, 47(2), pp. 113-26
- Khadir, M.T. 2003. Ringwood, linear and nonlinear model predictive control design for a milk pasteurization plant control and intelligent systems, Vol. 31, 1.
- Kiviharju, K., Leisola, M. and Eerikainen, T. 2005. Optimization of a Bifidobacterium longum production process. *Journal of Biotechnology*, 117: 299-308.
- Lou, W. and Nakai, S. 2001. Application of artificial neural networks for predicting the thermal inactivation of bacteria: A combined effect of temperature, pH and water activity. *Food Research International*, 34, pp. 573-579.
- Mhnaj, Mohammad Bagher, 2009. Computational Intelligence, Foundations of Neural Networks, Vol. 1, 4th ed. Amir Kabir University Press.
- Rasdhari, M., Parekh, T., Dave, N., Patel, V. and Subhash, R. 2008. Evaluation of various physic-chemical Properties of Hibiscus safdariffa & L. casei incorporated probiotic yogurt. *Pakistan Journal of Biological Sciences*, 11, (17): 2101-2108.

- Razmi-Rad, E., Ghanbarzadeh, B., and Rashmekarim, J. 2008. An artificial neural network for prediction of zeleny sedimentation volume of wheat flour. *International Journal of Agricultural and Biological*, 10, pp: 422-426.
- Sablani Shyam, S. and Shafiur Rahman, M. 2003. Using neural networks to predict thermal conductivity of food as a function of moisture content, temperature and apparent porosity, *Food Research International*, 36, pp. 617–623.
- Sahadeva, R.P.K., Leong, S.F., Chua, K.H., Tan, C.H., Chan, H.Y., Tong, E.V., Wong, S.Y.W. and Chan, H.K. 2011. Survival of commercial probiotic strains to ph and bile, *International Food Research Journal*, 18(4): 1515-1522.
- Sofu, A., and Ekinci, F.V. 2007. Estimation of storage time of yogurt with artificial neural network modeling. *Journal of Dairy Science*, 2007. Jul. 90(7):3118-25.
- Sumit, G., and Goyal, G.K. 2011. Development of neuron based artificial intelligent scientific computer engineering models for estimating shelf life of instant coffee sterilized drink. *International Journal of Computational Intelligence and Information Security*, 2(7): 4-12.
- Sumit Goyal, and Goyal, G.K. 2012. Cascade and feed forward backpropagation artificial neural networks models for prediction of sensory quality of instant coffee flavoured sterilized drink, *Advances in Computer Science and its Applications*, 93, Vol. 1, No. 2
- Taillandier, P., Gilis, F., Ramon Portugal, F., Laforce, P., and Strehaiano. 1996. Influence of medium composition, pH and temperature on the growth and viability of *Lactobacillus acidophilus*. *Biotechnology Letters*, Vol. 18, No. 7: 775-780.
- Tharmaraj, N. and Shah, N.P. 2003. Selective enumeration of *Lactobacillus delbruecki* subsp. *bulgaricus*, *Streptococcus thermophilus*, *Lactobacillus acidophilus*, bifidobacteria, *Lactobacillus casei*, *Lactobacillus rhamnosus* and *Propionibacteria*. *Journal of Dairy Science*, 86: 2288-2296.
- Tulbek, M.C., Panigrahi, S., Borhan, S., and Boyacioglu, D. 2003. Boyacioglu and H. Clifford, Prediction of alkaline noodle, sensory attributes by multiple regression and ANN models, *Proceedings of the IFT Annual Meetings*, Chicago, USA.
- Yeganehzad, S., Mazaheri-Tehrani, M. and Shahidi, F. 2007. Studying microbial, physicochemical & sensory properties of directly concentration probiotic yogurt. *African Journal of Agricultural Research*, 2, (8): 366-369.

Quality of probiotic yoghurt Prediction Using Intelligent Computing Expert System Models

***Gh.A. Sharifi Arab¹, R. Rafiei Nazari², H. Jalali² and M. Arab Ameri³**

¹Islamic Azad University, Damghan branch, MSc. Student, food Science and technology,

²Associate Prof., Islamic Azad University, damghan branch, ³M.Sc Food Science and Technology, Department of Food and Drug, Shahroud University of Medical Sciences, Shahroud, Iran

Abstract

Over the last few years, the use of artificial neural networks (ANNs) has increased in many areas of food science and artificial neural network have been applied to many Quality Control problems. The aim of this study is to develop and optimize artificial neural network models for forecast of viability of probiotic bacteria in yogurt. In this study, A Levenberg-Marquardt algorithm trained feed-forward artificial neural was used as a model. Several parameters such as titratable acidity, pH, syneresis, color and bacterial counts (*Streptococcus thermophilus*, *L. delbrueckii* ssp. *bulgaricus* *Lactobacillus acidophilus* and the viability of probiotic bacteria are considered. The efficiency of the developed model was assessed through a calculate the Mean Square Error (MSE) and value of R^2 . The transfer function of the neural network model is effective in performance. The two tangent sigmoid and linear transfer function model is used to optimize pre-processing and were compared. According to the results, the tangent sigmoid stimulation with 10 neurons in the hidden layer Here, the highest coefficients of determination on days 1, 7 and 14 during storage were (0.997, 0.994, 0.993) and the mean square error (MSE) 0.00056, 0.00075 and 0.00084 respectively. The overall accuracy of most models suitable for predicting viability of probiotic bacteria on during storage. Therefore, the best structure of a neural network to predict survival was 34-10-3.

Keywords: Probiotic, Yoghurt, Neural networks, *Lactobacillus acidophilus*

*Corresponding author; sharifi268@gmail.com