

پایش فرآیند مالت‌سازی با استفاده از شبکه عصبی مصنوعی

علیرضا قدس‌ولی^{۱*} - محسن مختاریان^۲ - حمید بخش‌آبادی^۳ - فاطمه عرب‌عامریان^۴

تاریخ دریافت: ۱۳۹۰/۹/۲۸

تاریخ پذیرش: ۱۳۹۲/۳/۲۰

چکیده

مالت‌سازی یک فرآیند زیست فناوری پیچیده است که شامل مراحل خیس‌اندن، جوانه‌زنی و خشک کردن مالت جوانه‌زده در شرایط کنترل شده دما و رطوبت می‌باشد. در این پژوهش پارامترهای فرآیند مالت‌سازی از طریق توابع فعال‌سازی مختلف شبکه عصبی نظیر لگاریتم سیگموئید-لگاریتم سیگموئید، تانژانت هیپربولیک-تانژانت هیپربولیک، لگاریتم سیگموئید-تانژانت هیپربولیک، لگاریتم سیگموئید-همانی و تانژانت هیپربولیک-همانی پیش‌بینی گردید. مقادیر زمان خیس‌اندن (x_1) و زمان جوانه‌زنی (x_2) به عنوان ورودی‌ها و راندمان عصاره‌گیری گرم (y_1)، راندمان مالت‌سازی (y_2) و فعالیت آنزیمی (β -گلوکاناز) (y_3) به عنوان خروجی انتخاب گردید. نتایج نشان داد که استفاده از شبکه عصبی پرسپترون با تابع فعال‌سازی تانژانت هیپربولیک-همانی با ۱۷ نرون بهترین نتیجه را در بین کلیه توابع بکار رفته در پیش‌بینی پارامترهای مؤثر در فرآیند مالت‌سازی داشت. هم‌چنین این شبکه قادر بود مقادیر راندمان عصاره‌گیری گرم، راندمان مالت‌سازی و فعالیت آنزیمی (β -گلوکاناز) را با ضرایب تبیین ۱، ۰/۹۸۴ و ۰/۹۹۵ پیش‌بینی نماید. این شیوه نوین می‌تواند به طور موفقیت‌آمیزی برای پایش کمی تغییرات مالت در طی فرآیند مالت‌سازی مورد استفاده قرار گیرد.

واژه‌های کلیدی: شبکه عصبی مصنوعی، مالت، پیش‌بینی

مقدمه

مالت‌سازی از قدیمی‌ترین عملیات زیست فناوری و منظور از آن فرآیند جوانه‌زنی محدود و کنترل شده غلات است که پس از خشک کردن، محصول دارای خواص تغذیه‌ای تولید می‌گردد (Moris and Bryce, 2000). در صنعت مالت‌سازی از غلات مختلفی استفاده می‌گردد اما به دلیل وجود ترکیب شیمیایی خاص، تغییرات مطلوب طی جوانه‌زنی و وجود پوسته که نقش حفاظت از جوانه را طی حمل و نقل بر عهده دارد، جو از امتیاز بالاتری نسبت به سایر غلات برخوردار است (Celuse et al., 2006). هم‌چنین، مالت جو منبعی از آنزیم‌های هضم‌کننده نشاسته به خصوص آلفا و بتا آمیلازها است (Osman et al., 2002). در دهه اخیر با توجه به گسترش صنایع نوشابه‌سازی و کاربرد انواع مالت به عنوان منبع آنزیمی، شیرین‌کننده و غیره در صنایع پخت، قنادی و غذای کودک، نیاز به اصلاح ارقام پر محصول جو مناسب مالت‌سازی که مازاد آن بتواند برای مصارف دیگر (تغذیه انسانی و خوراک دام) کاربرد داشته باشد مدنظر قرار گرفته است.

عملیات عصاره‌گیری^۵ با آب گرم و سرد به منظور ارزیابی

جو بعد از گندم، برنج و ذرت چهارمین غله مهم است که کشت آن به حدود ده هزار سال پیش باز می‌گردد (Dendy and Dobraszczyk, 2001). در جهان جو با سطح زیر کشت ۵۶ میلیون هکتار و تولید سالیانه ۱۵۴ میلیون تن از جمله محصولات زراعی مهم به شمار می‌رود. سطح زیر کشت آن در ایران ۱/۳ میلیون هکتار با عملکرد ۱/۵۴ تن در هکتار و تولید سالیانه ۲ میلیون تن می‌باشد (USDA, 2010). از جو به طور عمده در خوراک دام و صنعت مالت‌سازی استفاده می‌شود، که مورد اخیر مهم‌ترین کاربرد غذایی آن است (Celuse et al., 2006).

۱- استادیار پژوهش بخش تحقیقات فنی و مهندسی، مرکز تحقیقات کشاورزی و منابع طبیعی گلستان
(*) نویسنده مسئول: (Email: Qodsevali@yahoo.com)

۲ و ۴- دانش‌آموختگان کارشناسی ارشد دانشگاه آزاد اسلامی واحد سبزوار، گروه علوم و صنایع غذایی، سبزوار، ایران

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

زمینه‌ی استفاده از شبکه عصبی مصنوعی در پیش‌بینی پارامترهای فرآیندهای مختلف نظیر آبیگری اسمزی کدوی حلوایی (مختاریان و همکاران، ۱۳۹۰)، مدل سازی خیساندن گندم (Kashaninejad et al., 2009)، تخمیر (Latrille et al., 1993) و غیره صورت گرفته ولی هیچ گونه پژوهشی در زمینه‌ی بکارگیری ابزار هوشمند شبکه‌ی عصبی مصنوعی در فرآیند مالت‌سازی صورت نگرفته است. کورولو سانتینا و همکاران (۲۰۱۰) بهینه‌سازی خشک کردن مالت ذرت را با استفاده از ژنتیک الگوریتم مورد بررسی قرار دادند. کُک و همکاران (۲۰۰۷) از شبکه عصبی و ژنتیک الگوریتم برای پیش‌بینی محتوی چربی آزاد، کریستالیزاسیون لاکتوز و میانگین اندازه ذرات در طی فرآیند تولید شیر خشک کامل با کمک خشک کن افشانه ای استفاده نمودند. گونی و همکاران (۲۰۰۸) از ابزار هوشمند شبکه عصبی مصنوعی برای پیش‌بینی زمان‌های انجماد و رفع انجماد مواد غذایی استفاده نمودند. مؤمن زاده و همکاران (۲۰۱۱) زمان خشک کردن شلتوک ذرت را طی خشک کردن با خشک کن همزمان مایکروویو-بستر سیال به وسیله شبکه عصبی پیش‌بینی نمودند. منلیک و همکاران (۲۰۱۰) با کمک شبکه عصبی محتوی رطوبت، نسبت رطوبت و آهنگ خشک کردن برش‌های سیب را طی خشک کردن با انجماد مورد بررسی قرار دادند. مددلو و همکاران (۲۰۰۹) اندازه میسل کازئین را توسط روش ترکیبی شبکه عصبی مصنوعی- روش شناسی سطح پاسخ^۴ پیش‌بینی نمودند. مته‌او و همکاران (۲۰۱۱) از شبکه عصبی برای پیش‌بینی میزان انباشته شدن داکوسی نیوالنول^۵ در دانه‌های جو آلوده به قارچ فوزاریوم کولموروم استفاده نمودند. فرناندز و همکاران (۲۰۱۱) غلظت آنتوسیانین را در پوست انگور کامل با کمک شبکه عصبی و پردازش تصویر تعیین نمودند.

هدف از این مطالعه پیش‌بینی و تعیین بهترین رقم جو برای فرآیند مالت‌سازی و بررسی امکان سنجی پیشگویی ویژگی‌های مالت حاصله نظیر راندمان عصاره‌گیری گرم، راندمان مالت‌سازی و فعالیت آنزیمی (β -گلوکاناز) با استفاده از مدل‌های شبکه عصبی مصنوعی می‌باشد.

مواد و روش‌ها

آماده‌سازی مالت

لاین‌های جو مورد استفاده در این تحقیق با نام‌های ۱۷-۸۸ EBYT- و ۲۰-۸۸ EBYT- از ایستگاه تحقیقات گنبدکاووس تهیه شده و جهت انجام آزمایشات به آزمایشگاه بخش تحقیقات فنی مهندسی در مرکز تحقیقات کشاورزی و منابع طبیعی استان گلستان

ویژگی‌های کیفی مالت نهایی و هم چنین تولید محصولات متنوع انجام می‌شود. فرآیندی که مالت آسیاب شده با آب مخلوط و با کنترل دما، مواد موجود در آن استخراج شود عصاره‌گیری آب گرم و به فرآورده حاصل ورت^۱ می‌گویند. هدف از عصاره‌گیری آب گرم گسترش فعالیت آنزیم‌های مالت و تبدیل نشاسته و مواد غیرمحلول به ترکیبات قابل حل در آب و دستیابی به حداکثر مقدار کربوهیدرات‌های ساده است (Briggs, 1998). پژوهش‌های متعددی در زمینه فرآیند مالت‌سازی صورت گرفته است. گروهی از پژوهشگران، بهینه‌سازی خشک کردن مالت ذرت را در دمای ۵۴، ۶۴ و ۷۶ درجه سانتی‌گراد بررسی و مشاهده نمودند که دمای ۵۴ درجه سانتی‌گراد برای خشک کردن مالت آنزیمی ذرت دمای مناسبی است (Biazus et al., 2005). گروهی از محققین ایرانی اثر دما و نوع خشک‌کن را بر خواص فیزیکوشیمیایی مالت حاصل از ارقام جو مورد بررسی و ارزیابی قرار دادند. نتایج حاکی از آن بود که بهترین دما برای تولید مالت آنزیمی و غیر آنزیمی به ترتیب در ۵۵ و ۸۵ درجه سانتی‌گراد بود. نتایج خشک کردن ترکیبی در دمای ۵۵ درجه سانتی‌گراد خشک‌کن هوای داغ نشان داد با افزایش توان از ۱۰۰ وات به ۳۰۰ وات در مایکروویو، ویژگی‌های کیفی روندی مشابه خشک‌کن هوای داغ داشتند (آقاجانی و همکاران، ۱۳۸۸). هم چنین گروه دیگری از محققین ایرانی بررسی اثر فرآیند مالت‌سازی بر ویژگی‌های فیزیکوشیمیایی دو رقم جو صحرا و دشت را بررسی نمودند (آقاجانی و همکاران، ۱۳۸۸). در پژوهش دیگر، اختلاط مالت منابع غلاتی جهت استفاده در صنایع پخت و تولید نوشابه‌های مالتی غیر الکلی مورد بررسی و ارزیابی قرار گرفت. نتایج نشان داد که افزودن مالت تربیتکاله (۱۰ درصد)، و افزودن مالت گندم و مالت تربیتکاله (هر یک ۱۰ درصد) به ترتیب منجر به تولید ماده اولیه مناسب صنایع نوشابه‌های مالتی و صنایع پخت می‌شود (قدس ولی، ۱۳۸۹).

امروزه شبکه عصبی مصنوعی^۲ به عنوان یک ابزار قدرتمند نقش مهمی در پیش‌بینی پارامترهای فرآیند ایفا می‌نماید. اولین مدل ریاضی نرون مصنوعی در ابتدا توسط مک کولاک و پیتس^۳ پیشنهاد گردید (Sablani et al., 2007). یک نرون مصنوعی از واحد پردازشی مقدماتی با چندین ورودی و یک خروجی تشکیل شده است. ورودی‌های نرون می‌توانند خروجی‌های سایر نرون‌های یا خروجی‌های ساده‌ی بیرونی باشد. خروجی از یک سلول عصبی می‌تواند ورودی به چندین سلول عصبی دیگر باشد. هم چنین، سیگنال‌های ورودی به نرون‌ها توسط وزن‌های ویژه اصلاح می‌گردد (Wu and McLarty, 2000). تاکنون تحقیقات متعددی در

1- Wort

2- Artificial neural network (ANN)

3- McCullock and Pitts

4- ANN-RSM

5- Deoxynivalenol

منتقل شدند.

تعیین میزان فعالیت آنزیم بتاگلوکاناز

اندازه‌گیری آنزیم با استفاده از کیت‌های تجاری مگازیم^۲ ساخت ایرلند و با استفاده از روش مک کلری و شامر و (۱۹۸۷) و با استفاده از معادله ۲ تعیین شد که مبین فعالیت آنزیمی به صورت واحد بر کیلوگرم مالت (U/kg) می‌باشد (McCleary and Shameer, 1987).

$$Y = (630 \times A) + 4 \quad (2)$$

در این معادله؛ A میزان جذب محلول آزمایش در ۵۹۰ نانومتر توسط دستگاه اسپکتوفتومتر (pharmacia LKB.Novaspect II انگلستان) می‌باشد.

تعیین راندمان عصاره‌گیری با آب گرم^۳

پس از تهیه عصاره به روش زمان‌بندی درجه حرارت، وزن مخصوص عصاره حاصله به کمک پیکنومتر تعیین گردید سپس با مراجعه به جدول پلاتو^۴، بریکس عصاره اندازه‌گیری شد و در نهایت از معادله ۳، درصد راندمان عصاره آب گرم تعیین شد (AOAC, 2006).

$$E = \frac{(300+M)P}{100-P} \quad (3)$$

که E، M و P به ترتیب درصد بازدهی استخراج عصاره آب گرم بر اساس ماده خشک، درصد رطوبت (مبنای تر) در مالت و مواد جامد محلول کل در ۱۰۰ گرم عصاره با استفاده از جدول پلاتو می‌باشد.

مدل‌سازی شبکه‌ی عصبی مصنوعی

برای مدل‌سازی با شبکه عصبی مصنوعی از نرم افزار SPSS نسخه ی ۱۹ (۲۰۱۱) استفاده گردید. نوع شبکه طراحی شده پرسپترون چند لایه^۵ بر اساس شبکه‌ی پس انتشار^۶ با مومنتم و با نرون بایاس بود که در آن لایه ورودی شامل دو نرون (زمان جوانه زنی (x_1) و زمان خیساندن (x_2)) و لایه خروجی شامل سه نرون (راندمان مالت‌سازی (y_1), راندمان عصاره‌گیری (y_2) و فعالیت آنزیمی (β -گلوکاناز (y_3)) بود. بنابراین مدل شبکه عصبی بر اساس ۲ ورودی و ۳ خروجی طراحی گردید. همان طور که مشاهده می‌گردد شکل ۱ شماتیک ساختار شبکه عصبی پرسپترون را نشان می‌دهد. بهینه‌سازی ساختار شبکه عصبی با بررسی چیدمان‌های مختلف شبکه و نیز ارزیابی همبستگی بین خروجی‌های شبکه عصبی و داده‌های

پس از تمیز نمودن و بوجاری دانه‌ها توسط الک (ساخت ایران، شرکت دماوند، مدل E:11) و به صورت دستی، آنها به دسته‌هایی به طور مساوی تقسیم شدند و به طور جداگانه برای زمان‌های ۲۴، ۳۶ و ۴۸ ساعت تا رسیدن به میزان رطوبت نهایی ۴۶-۴۲ درصد تحت فرآیند خیساندن قرار گرفتند (دمای آب حدود ۲۰ درجه سانتی‌گراد و سختی آب حدود ۲۵۰ پی.پی.ام). در مرحله بعدی دانه‌های خیسانده شده حاصل از سه زمان فوق به سه قسمت مساوی توزین و به داخل ژرمیناتور (مدل Tabai Espec Corp، ساخت ژاپن) جهت طی شدن مدت زمان لازم ۳، ۵ و ۷ روز برای جوانه‌زنی منتقل و دمای ژرمیناتور در حدود ۲۰-۱۷ درجه سانتی‌گراد و رطوبت نسبی حدود ۹۰ تا ۹۵ درصد تنظیم گردید (Agu and Palmer, 2003). در نهایت نمونه‌ها در دمای ۶۵-۵۵ درجه‌ی سانتی‌گراد برای مدت ۴۸-۲۴ ساعت خشک و سپس ریشه‌چه‌های آنها به روش سایشی و با الک کردن جدا گردید و برای عصاره‌گیری با آب گرم، مالت نرم آسیابی تحت عمل عصاره‌گیری به روش زمان‌بندی درجه حرارت^۱ قرار داده شد (AOAC, 2006). ابتدا ۵۰ گرم مالت آسیابی نرم توزین و به بشر حاوی ۲۰۰ میلی‌لیتر آب مقطر ۴۶ درجه سانتی‌گراد اضافه شد و پس از مخلوط کردن، به مدت ۳۰ دقیقه در بن ماری (ساخت ایران، شرکت اندیشه تجهیز، مدل W350) در دمای ۴۵ درجه سانتی‌گراد قرار داده شد. سپس دمای خیسانده شده مالت هر دقیقه، یک درجه سانتی‌گراد بالا برده شد تا به ۷۰ درجه سانتی‌گراد رسید. در این هنگام پس از افزودن ۱۰۰ میلی‌لیتر آب مقطر ۷۰ درجه سانتی‌گراد، مخلوط به مدت ۶۰ دقیقه در دمای ۷۰ درجه سانتی‌گراد نگهداری گردید. در نهایت مخلوط حاصل پس از سرد شدن با کاغذ صافی واتمن شماره ۱ و به کمک پمپ خلأ (مدل: SERIAL NO 900، ساخت امریکا) صاف و عصاره شیرین از باقی‌مانده مالت جدا گردید.

راندمان مالت‌سازی

راندمان مالت‌سازی نمونه‌های جو در طی فرآیند مالت‌سازی توسط معادله (۱) با کمک ترازوی دیجیتال (AVERY GEC، مدل T5/NO286 ساخت انگلستان با دقت ۰/۰۱) انجام گرفت.

$$MY = \frac{A}{B} \times 100 \quad (1)$$

در این معادله MY، راندمان مالت‌سازی (درصد)، A، وزن دانه‌های مالت حاصله (گرم) و B، وزن دانه‌های جو اولیه (گرم) می‌باشند.

2- Megazyme Ltd. Ireland

3- Hot Water Extract

4- Platto Table

5- Multi Layer Perceptron (MLP)

6- Back Propagation Network (BPN)

1- Temperature programing

رقم مناسب برای فرآیند تولید مالت می‌باشد (جدول ۱). هم چنین بین دو لاین جو در کلیه حالت‌ها اختلاف آماری معنی‌دار در سطح احتمال ۹۹ درصد مشاهده می‌گردد. نتایج نشان داد که در لاین ۲۰-۸۸ EBYT- کلیه پارامترهای راندمان مالت‌سازی، راندمان عصاره‌گیری گرم و فعالیت آنزیم β -گلوکاناز دارای امتیاز آماری بالاتری نسبت به لاین ۱۷-۸۸-EBYT می‌باشد.

با توجه به این گزارشات، کلیه پیش‌بینی‌های انجام گرفته توسط شبکه عصبی مصنوعی در مورد فرآیند مالت‌سازی روی مالت‌های به دست آمده از لاین ۲۰-۸۸-EBYT انجام گرفت. همان طور که گفته شد در این پژوهش از توابع فعال‌سازی مختلف برای پیش‌بینی ویژگی‌های فرآیند مالت‌سازی استفاده گردید. در ابتدا قبل از انجام فرآیند مدل‌سازی برای هر تابع فعال‌سازی بهترین حالت تقسیم‌بندی داده^۶ (تفکیک داده) به روش سعی و خطا تعیین گردید. جدول ۲ انواع تقسیم‌بندی‌های بکار رفته برای مدل‌سازی پارامترهای مالت‌سازی را نشان می‌دهد.

نتایج بررسی بهترین حالت تقسیم‌بندی مجموعه داده‌ها برای هر تابع فعال‌سازی بکار رفته در شکل ۲ نشان داده شده است. مبنای ارزیابی، بر اساس کمترین مقدار خطای میانگین کل در آزمون شبکه بود. برای بدست آوردن بهترین حالت از روش سعی و خطا استفاده گردید. نتایج نشان داد که به ترتیب برای توابع فعال‌سازی لوگ سیگموئید-لوگ سیگموئید، تانژانت هیپربولیک-تانژانت هیپربولیک، لوگ سیگموئید-تانژانت هیپربولیک، لوگ سیگموئید-همانی و تانژانت هیپربولیک-همانی بهترین تقسیم‌بندی، P_4 ، P_7 ، P_4 ، P_5 و P_6 بدست آمد. بنابراین در فرآیند بعدی مدل‌سازی داده‌ها از بهترین ترکیب تقسیم‌بندی برای هر تابع فعال‌سازی استفاده گردید.

نتایج حاصل از مدل‌سازی شبکه عصبی پرسپترون همراه با توابع فعال‌سازی لگاریتم سیگموئید- لگاریتم سیگموئید، تانژانت هیپربولیک-تانژانت هیپربولیک، لگاریتم سیگموئید-تانژانت هیپربولیک، لگاریتم سیگموئید-همانی و تانژانت هیپربولیک-همانی به همراه چیدمان‌های بدست آمده در حالت‌های مختلف در جدول ۳ نشان داده شده است. بررسی نتایج بدست آمده در خصوص شبکه عصبی پرسپترون همراه با توابع فعال‌سازی لگاریتم سیگموئید- لگاریتم سیگموئید با یک لایه پنهان نشان داد که (جدول ۳) چیدمان ۳-۱۲-۲، یعنی شبکه‌ای با ۲ ورودی، ۱۲ گره (نرون) در لایه پنهان و ۳ خروجی، بهترین نتیجه را در پیش‌بینی راندمان عصاره‌گیری گرم، راندمان مالت‌سازی و فعالیت آنزیمی (β -گلوکاناز) دارد. این شبکه قادر بود راندمان عصاره‌گیری گرم، راندمان مالت‌سازی و فعالیت آنزیمی (β -گلوکاناز) را به ترتیب با مقادیر ضرایب تبیین ۰/۹۸۴ و ۰/۹۹۳ پیش‌بینی نماید. بررسی آنالیز شبکه عصبی سایر

آزمایشی انجام گرفت. برای بهینه‌سازی شبکه عصبی پارامترهای مختلف شبکه نظیر تعداد نرون در هر لایه پنهان، نوع تابع فعال‌سازی در لایه پنهان و خروجی، نرخ یادگیری و ضریب مومنتوم باید ارزیابی گردد. به منظور یافتن بهترین پیکربندی، تعداد یک لایه پنهان با ۲-۳۲ عدد نرون در هر لایه پنهان، نرخ یادگیری ۰/۴، ضریب مومنتوم ۰/۹ و توابع فعال‌سازی لگاریتم سیگموئید^۱ (رابطه‌ی ۴) و تانژانت هیپربولیک^۲ (رابطه‌ی ۵) و همانی^۳ (رابطه‌ی ۶) در لایه پنهان و خروجی استفاده گردید.

$$f(z) = \frac{1}{1 + \exp(-z)} \quad (4)$$

$$f(Z) = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (5)$$

$$\text{Id}(z) = z \quad (6)$$

به منظور مقایسه کارایی شبکه عصبی، از شاخص‌های ضریب تبیین^۴ و خطای نسبی میانگین^۵ استفاده گردید (روابط ۷ و ۸).

$$\text{MRE} = \left(\frac{1}{N} \sum_{i=1}^N \frac{|P_{ANNi} - P_{Exp,i}|}{P_{Exp,i}} \right) \times 100 \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (P_{ANNi} - P_{Exp,i})^2}{\sum_{i=1}^N (P_{ANNi} - \bar{P}_{ANN})^2} \quad (8)$$

در این معادلات، مقدار P_{ANN} مقدار پیش‌بینی شده برای پارامترهای خروجی از شبکه، P_E مقادیر داده‌های تجربی بدست آمده از آزمایش و N تعداد مشاهدات می‌باشد (مختاریان و همکاران، ۱۳۹۰).


نتایج و بحث

در این پژوهش ترکیبی از لایه‌ها و نرون‌های مختلف همراه با تابع فعال‌سازی مختلف (در لایه‌های پنهان و خروجی) برای بهینه‌سازی شبکه پرسپترون مورد استفاده قرار گرفت. شبکه‌های عصبی با یک لایه پنهان، تعداد ۲ تا ۳۲ نرون به طور تصادفی انتخاب و قدرت شبکه در پیش‌بینی پارامترهای مالت‌سازی نظیر فعالیت آنزیم بتاگلوکاناز، راندمان مالت‌سازی و راندمان عصاره‌گیری گرم مورد ارزیابی قرار گرفت. جهت فرآیند مالت‌سازی از دو لاین جو با نام‌های ۱۷-۸۸-EBYT و ۲۰-۸۸-EBYT استفاده گردید. بررسی نتایج آزمایشات (راندمان مالت‌سازی، راندمان عصاره‌گیری گرم و فعالیت آنزیم β -گلوکاناز) حاکی از آن بود که رقم ۲۰-۸۸-EBYT به عنوان

- 1- Logarithm sigmoid activation function (logsig)
- 2- Hyperbolic tangent activation function (tagh)
- 3- Identity activation function
- 4- Coefficient of determination (R^2)
- 5- Mean Relative Error (MRE)

کاشانی‌نژاد و همکاران (۲۰۰۹) از دو نوع شبکه عصبی مصنوعی (شبکه پرسپترون و تابع پایه شعاعی) برای پیش‌بینی محتوی رطوبت دانه گندم در طی خیساندن استفاده نمودند.

توابع فعال‌سازی بکار رفته در پیش‌بینی پارامترهای مالت‌سازی دانه جو نشان داد که این توابع با تعداد ۱۷ نرون در لایه پنهان، به عنوان بهترین تعداد نرون انتخاب گردید. مقادیر ضریب تبیین و خطای نسبی آزمون داده‌ها برای این توابع در جدول ۳ نشان داده شده است.



شکل ۱- شماتیک ساختار شبکه‌ی عصبی پرسپترون

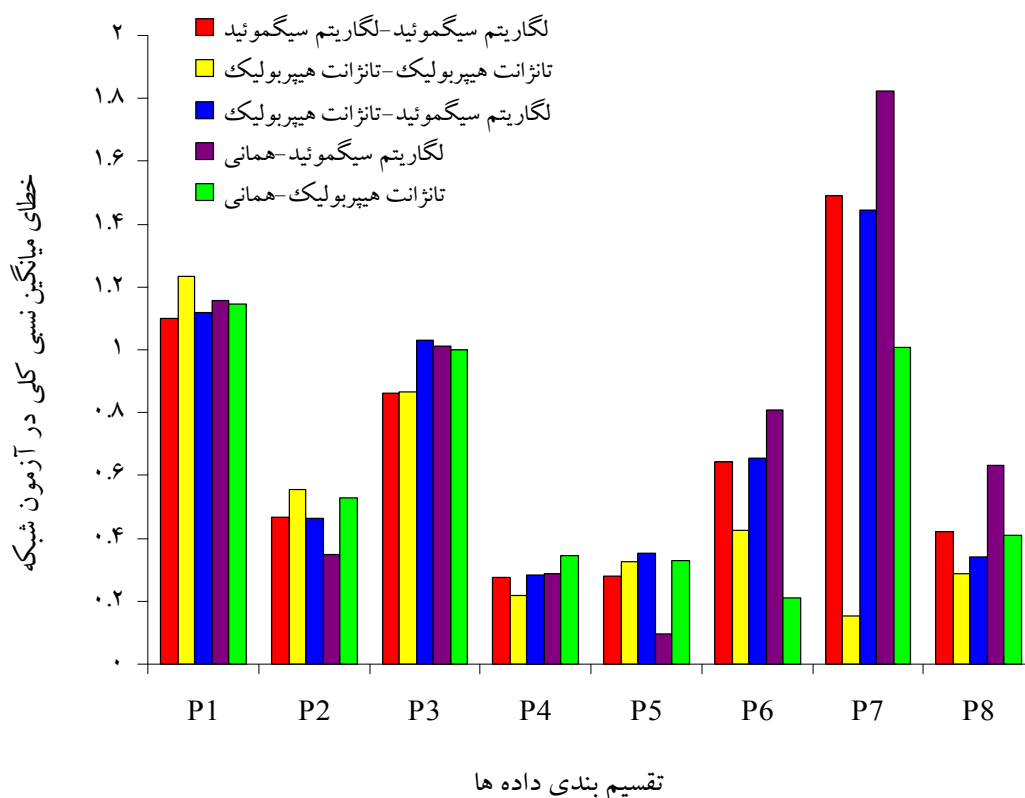
جدول ۱- مقایسه میانگین پارامترهای مؤثر در فرآیند مالت‌سازی

لاین جو	راندمان عصاره‌گیری گرم (%)	راندمان مالت‌سازی (%)	فعالیت آنزیم β -گلوکاناز (U/Kg)
EBYT-۸۸-۲۰	۵۲/۴۷ ^a	۸۷/۷۵ ^a	۱۵۹/۱۳ ^a
EBYT-۸۸-۱۷	۴۹/۴۱ ^b	۸۵/۲۴ ^b	۱۲۵/۹۶ ^b

* - در هر ستون میانگین‌های دارای حروف مشابه از لحاظ آماری اختلاف معنی‌داری ندارند ($\alpha=0/01$)

جدول ۲- حالت‌های مختلف تقسیم‌بندی داده‌ها برای پیش‌بینی پارامترهای مالت‌سازی

حالت تقسیم‌بندی	درصد داده‌های یادگیری (%)	درصد داده‌های آزمون (%)	نشانه
۱	۲۵	۷۵	P ₁
۲	۴۰	۶۰	P ₂
۳	۵۰	۵۰	P ₃
۴	۶۶/۶۷	۳۳/۳۳	P ₄
۵	۷۵	۲۵	P ₅
۶	۸۰	۲۰	P ₆
۷	۸۵	۱۵	P ₇
۸	۸۸	۱۲	P ₈



شکل ۲- حالت‌های مختلف تقسیم بندی مجموعه داده‌های به کار رفته در مدل سازی شبکه‌ی عصبی

مالت‌سازی و فعالیت آنزیمی (β -گلوکاناز) داشت. مقادیر خطای نسبی آزمون داده‌ها برای این سه فاکتور به ترتیب ۰/۰۰۰۰۶۵، ۰/۰۱۲ و ۰/۰۰۵ محاسبه گردید. چایجان و همکاران (۱۳۸۸) ضریب تبدیل شلتوک را با استفاده از شبکه‌های عصبی مصنوعی در خشک کردن بستر سیال، پیش‌بینی نمودند. در این پژوهش از توابع فعال سازی سیگموئیدی، تانزانت هیپربولیک و خطی استفاده گردید. نتایج نشان داد که شبکه عصبی پس انتشار پیشرو^۳ با چیدمان ۷-۱۳-۷ و تابع فعال سازی تانزانت سیگموئید توانست راندمان تبدیل شلتوک را به برنج سفید با ضریب تعیین ۹۵/۴۸ درصد و خطای میانگین مطلق ۰/۰۱۹ پیش‌بینی نماید.

نمودار آنالیز حساسیت مقادیر پیش‌بینی شده توسط شبکه عصبی پرسپترون در برابر مقادیر تجربی برای بهترین چیدمان مدل‌های شبکه عصبی پرسپترون نشان داد که داده‌ها به طور تصادفی در اطراف خط رگرسیونی با ضریب تبیین بالاتر از ۰/۹۸۴ قرار گرفته‌اند که این خود دلیلی بر ارزیابی دقیق شبکه عصبی در پیش‌بینی ویژگی‌های مالت‌سازی می‌باشد (شکل ۳).

نتایج نشان داد که مدل شبکه عصبی پرسپترون از توانایی بالاتری نسبت به شبکه عصبی تابع پایه شعاعی^۱ برخوردار می‌باشد (Kashaninejad *et al.* 2009). خزائی و همکاران (۱۳۸۶) از سه نوع شبکه عصبی مصنوعی برای پیش‌بینی خواص کیفی انگور استفاده نمودند. نتایج نشان داد که شبکه عصبی المان^۲ با تابع فعال سازی لگاریتم سیگموئید نتایج بهتری نسبت به تابع فعال‌سازی تانزانت هیپربولیک-لگاریتم سیگموئیدی داشت.

مقایسه نتایج مدل‌های مختلف شبکه عصبی برای تعیین بهترین مدل شبکه عصبی در پیش‌بینی ویژگی‌های مالت در جدول ۴ نشان داده شده است. همان طور که مشاهده می‌گردد، کلیه مدل‌های شبکه عصبی توانایی بالایی در پیش‌بینی ویژگی‌های مالت‌سازی داشته و ضریب تبیین مدل‌های شبکه عصبی بالاتر از ۰/۹۴۲ بدست آمد. با این وجود مقایسه نتایج نشان داد که شبکه عصبی پرسپترون با تابع فعال‌سازی تانزانت هیپربولیک-همانی بهترین نتیجه را با ۱۷ نرون در لایه پنهان، در پیش‌بینی راندمان عصاره‌گیری گرم، راندمان

3- Cascade Forward Back Propagation (CFBP)

1- Radial Basis Function (RBF)

2- Elman Network

جدول ۳- نتایج شبکه عصبی پرسپترون همراه با توابع فعال سازی مختلف در پیش بینی ویژگی های مالت

تابع فعال سازی	فعالیت آنزیمی (بتا - گلوکاناز)				راندمان مالت سازی				راندمان عصاره گیری گرم				تعداد نرون	تابع فعال سازی
	میانگین خطای نسبی		ضریب تبیین		میانگین خطای نسبی		ضریب تبیین		میانگین خطای نسبی		ضریب تبیین			
	ازمون	یادگیری	ازمون	یادگیری	ازمون	یادگیری	ازمون	یادگیری	ازمون	یادگیری	ازمون	یادگیری		
	0/812	1/205	0/102	0/971	0/016	0/052	0/412	0/556	۲					
	0/779	0/433	0/151	0/933	0/726	0/015	0/563	0/150	۵					
	0/292	3/259	0/887	0/660	0/735	0/320	1/095	0/748	۸					
	0/993	0/014	0/005	0/984	0/015	0/018	0/0024	0/0026	۱۲					لگاریتم سیگموئید-لگاریتم سیگموئید
	0/947	0/089	0/068	0/984	0/028	0/014	0/999	0/0032	۱۷					
	0/926	0/097	0/102	0/966	0/037	0/033	0/849	0/177	۲۴					
	0/724	0/084	0/410	0/948	0/088	0/068	0/361	1/831	۳۲					
	0/195	0/868	0/838	0/927	0/069	0/087	0/578	0/453	۲					
	0/946	0/035	0/078	0/978	0/334	0/012	۱	0/004	۵					
	0/938	6/364	0/081	0/945	0/045	0/064	0/988	0/003	۸					
	0/977	0/206	0/021	0/975	0/017	0/028	0/98	0/035	۱۲					تانزانت هیپربولیک-تانزانت هیپربولیک
	0/995	0/003	0/007	0/983	0/0005	0/020	۱	0/002	۱۷					
	0/943	0/016	0/160	0/971	0/101	0/031	0/995	0/017	۲۴					
	0/781	20/99	0/328	0/966	0/138	0/038	0/986	0/059	۳۲					
	0/318	1/786	0/605	0/895	0/029	0/194	0/680	0/288	۲					
	0/474	0/702	0/513	0/913	0/372	0/099	0/260	1/187	۵					
	0/294	4/773	0/874	0/491	1/018	0/443	0/21	1/001	۸					
	0/821	0/287	0/178	0/973	0/031	0/040	0/974	0/032	۱۲					تانزانت هیپربولیک-لگاریتم سیگموئید
	0/942	0/056	0/071	0/973	0/027	0/028	0/996	0/009	۱۷					
	0/775	0/185	0/397	0/967	0/069	0/066	0/857	0/171	۲۴					
	0/745	0/091	0/461	0/931	0/181	0/077	0/293	2/046	۳۲					

ادامه جدول ۳- نتایج شبکه عصبی پرسپترون همراه با توابع فعال‌سازی مختلف در پیش‌بینی ویژگی‌های مالت

تابع فعال سازی	راندمان عصاره‌گیری گرم				راندمان مالت‌سازی				فعالیت آنزیمی (بنا- گلوکاناز)			
	ضرب تیبین	ضرب نسبی	میانگین خطای نسبی	یادگیری	ضرب تیبین	ضرب نسبی	میانگین خطای نسبی	یادگیری	ضرب تیبین	ضرب نسبی	میانگین خطای نسبی	یادگیری
۲	0/4	0/577	0/618	0/618	0/811	0/155	0/207	0/317	0/200	0/317	0/200	0/698
۵	0/209	1/335	0/835	0/835	0/651	0/245	0/482	0/850	1/232	0/850	1/232	0/281
۸	0/231	1/037	0/765	0/765	0/846	0/084	0/222	0/627	4/846	0/627	4/846	0/330
۱۲	1	0/0003	0/0004	0/0004	0/983	0/040	0/017	0/003	0/012	0/003	0/012	0/995
۱۷	1	0/00003	0/00009	0/00009	0/983	0/018	0/012	0/0052	0/0051	0/0052	0/0051	0/995
۲۴	0/666	0/478	0/300	0/300	0/902	0/175	0/192	0/194	0/093	0/194	0/093	0/875
۳۲	0/130	5/925	1/128	1/128	0/25	1/173	1/405	1/144	3/006	1/144	3/006	0/152
۲	0/360	2/221	0/618	0/618	0/741	0/416	0/246	0/681	0/806	0/681	0/806	0/397
۵	0/212	1/853	0/776	0/776	0/639	0/187	0/412	0/772	0/644	0/772	0/644	0/315
۸	0/999	0/001	0/0007	0/0007	0/982	0/037	0/020	0/0035	0/1996	0/0035	0/1996	0/994
۱۲	1	0/00014	0/00008	0/00008	0/983	0/022	0/016	0/004	0/008	0/004	0/008	0/995
۱۷	1	0/000065	0/00019	0/00019	0/984	0/012	0/013	0/005	0/005	0/005	0/005	0/995
۲۴	1	0/00021	0/00008	0/00008	0/983	0/042	0/0107	0/005	0/007	0/005	0/007	0/995
۳۲	0/998	0/096	0/002	0/002	0/981	0/054	0/019	0/005	3/156	0/005	3/156	0/994

لگاریتم سیگموئید-همانی

تانژانت هیپربولیک-همانی

ستون بین اولین لایه پنهان و لایه خروجی) و مقادیر بایاس (B_{input} ماتریس بایاس ورودی برای اولین لایه پنهان دارای ۱۷ سطر و ۱ ستون (17×1)، B_{output} ماتریس بایاس خروجی دارای ۳ سطر و ۱ ستون (3×1) به صورت زیر به دست آمد:

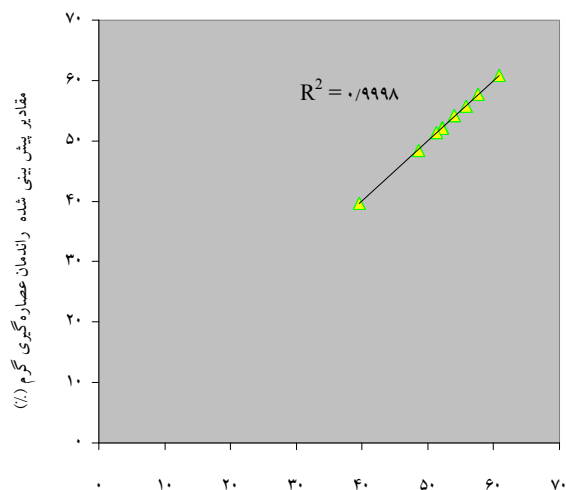
در شبکه بهینه شده (یعنی شبکه عصبی با تابع فعال‌سازی تانژانت هیپربولیک-همانی با ۱۷ نرون در لایه پنهان) ماتریس وزن‌ها ($Q_{17 \times 6}$)، یعنی ماتریس با ۱۷ سطر و ۶ ستون بین مقادیر ورودی به شبکه و اولین لایه پنهان و $G_{3 \times 17}$ ، یعنی ماتریس با ۳ سطر و ۱۷

جدول ۴- مقایسه مدل‌های شبکه عصبی در پیش‌بینی ویژگی‌های مالت


تابع فعال سازی	پارامترهای آماری	راندمان عصاره‌گیری گرم	راندمان مالت‌سازی	فعالیت آنزیمی (β-گلوکاناز)
لگاریتم سیگموئید-لگاریتم سیگموئید	خطای نسبی آزمون شبکه	۰/۰۰۲۴	۰/۰۱۵	۰/۰۱۴
	ضریب تبیین	۰/۹۹۹	۰/۹۸۴	۰/۹۹۳
	چیدمان	۲-۱۲-۳	۲-۱۲-۳	۲-۱۲-۳
تانزانته هیپربولیک-تانزانته هیپربولیک	خطای نسبی آزمون شبکه	۰/۰۰۲	۰/۰۰۰۵	۰/۰۰۳
	ضریب تبیین	۱	۰/۹۸۳	۰/۹۹۵
	چیدمان	۲-۱۷-۳	۲-۱۷-۳	۲-۱۷-۳
تانزانته هیپربولیک-لگاریتم سیگموئید	خطای نسبی آزمون شبکه	۰/۰۰۹	۰/۰۲۷	۰/۰۵۶
	ضریب تبیین	۰/۹۹۶	۰/۹۷۳	۰/۹۴۲
	چیدمان	۲-۱۷-۳	۲-۱۷-۳	۲-۱۷-۳
لگاریتم سیگموئید-همانی	خطای نسبی آزمون شبکه	۰/۰۰۰۰۳	۰/۰۱۸	۰/۰۰۵۱
	ضریب تبیین	۱	۰/۹۸۳	۰/۹۹۵
	چیدمان	۲-۱۷-۳	۲-۱۷-۳	۲-۱۷-۳
تانزانته هیپربولیک-همانی	خطای نسبی آزمون شبکه	۰/۰۰۰۰۶۵	۰/۰۱۲	۰/۰۰۵
	ضریب تبیین	۱	۰/۹۸۴	۰/۹۹۵
	چیدمان	۲-۱۷-۳	۲-۱۷-۳	۲-۱۷-۳

Q_{17×6}


-0.276	-0.307	0.261	-0.165	0.49	0.417
0.144	-0.345	0.204	0.49	0.162	-0.522
0.272	-0.006	-0.43	0.394	-0.458	-0.361
0.379	-0.311	-0.587	0.043	-0.713	-0.666
0.692	-0.148	0.25	-0.301	0.082	-0.622
0.085	0.147	-0.004	-0.589	-0.213	-0.483
-0.057	-0.088	0.453	-0.453	-0.354	0.523
0.027	-0.258	-0.239	0.357	0.177	-0.281
0.716	-1.613	0.993	-1.113	1.732	0.34
-1.373	0.583	1.27	-0.55	0.779	0.526
-0.226	-0.836	1.839	-0.689	-0.561	1.746
0.299	-0.401	0.008	0.092	0.299	-0.223
1.376	-0.337	-0.489	-0.864	0.537	0.439
-0.345	0.174	-0.193	-0.365	0.882	-0.281
-0.196	-0.195	0.895	0.556	-0.478	0.176
-0.129	0.392	-0.619	0.099	-0.616	0.231
-0.171	0.297	-0.136	0.326	-0.274	-0.399



مقادیر تجربی راندمان عصاره گیری گرم (g)



مقادیر تجربی راندمان مالت سازی (%)



مقادیر تجربی فعالیت آنزیمی (β-گلوکاناز) (U/kg)

شکل ۳- مقادیر پیش بینی شده و تجربی پیش بینی پارامترهای مالت توسط بهترین شبکه آموزش داده شده

$$G_{3 \times 17} \begin{bmatrix} 0.37 & -0.57 & -1.47 & -0.7 & -0.15 & 0.02 & 0.21 & -0.25 & -1.22 & -1.36 & 0.67 & 0.21 & -1.35 & 0.9 & -0.35 & 0.34 & -0.24 \\ -0.54 & 0.15 & 0.26 & 0.45 & 0.29 & -0.96 & -0.28 & 0.14 & -0.27 & 0.05 & -0.77 & 0.38 & 0.78 & -0.17 & 0.64 & 0.18 & 0.29 \\ -0.22 & -0.45 & 0.23 & -0.22 & -0.57 & -0.21 & -0.22 & -0.27 & 1.55 & 1.03 & -1.59 & -0.49 & 0.34 & -0.73 & -0.46 & -0.36 & 0.32 \end{bmatrix}$$

$$B_{input} \begin{bmatrix} 0.415 \\ -0.359 \\ -0.372 \\ -0.202 \\ 0.101 \\ 0.04 \\ 0.008 \\ -0.088 \\ 1.626 \\ -0.099 \\ 0.927 \\ 0.359 \\ 0.729 \\ 0.398 \\ 0.424 \\ -0.776 \\ -0.283 \end{bmatrix}$$

$$B_{output} \begin{bmatrix} -0.026 \\ 0.681 \\ -0.333 \end{bmatrix}$$

نتیجه گیری

خطای نسبی آزمون شبکه نسبت به سایر توابع از توان عملیاتی بالاتری در پیش‌بینی راندمان عصاره‌گیری گرم، راندمان مالت‌سازی و فعالیت آنزیمی (β -گلوکاناز) برخوردار می‌باشد. نتایج حاکی از آن بود که این شبکه با ۱۷ نرون در لایه پنهان، توانست پارامترهای راندمان عصاره‌گیری گرم، راندمان مالت‌سازی و فعالیت آنزیمی (β -گلوکاناز) را با مقادیر ضریب تبیین ۱، ۰/۹۸۴ و ۰/۹۹۵ پیش‌بینی نماید. بنابراین پژوهش حاضر نشان داد که شبکه عصبی به عنوان یک سیستم غیر خطی می‌تواند نقش مهمی در پیش‌بینی پارامترهای کیفی فرآیندهای مواد غذایی (مثلاً فرآیند مالت‌سازی) داشته که به عنوان یک روش غیر تخریبی و سریع می‌تواند کمک شایانی در محاسبه پارامترهای فرآوری ایفا نماید.

در این پژوهش از مدل‌های مختلف شبکه عصبی برای تعیین بهترین شبکه در پیشگویی ویژگی‌های مالت مورد استفاده قرار گرفت. برای این منظور، ابتدا در هر تابع فعال‌سازی بهترین تفکیک داده‌ها تعیین گردید. نتایج نشان داد که مناسب‌ترین آرایش داده‌ها برای توابع فعال‌سازی لگاریتم سیگموئید-لگاریتم سیگموئید، تانژانت هیپربولیک-تانژانت هیپربولیک، لگاریتم سیگموئید-تانژانت هیپربولیک، لگاریتم سیگموئید-همانی و تانژانت هیپربولیک-همانی به ترتیب P_4, P_7, P_4, P_5, P_6 بود. بنابراین در فرآیند بعدی مدل‌سازی داده‌ها از بهترین ترکیب تقسیم‌بندی برای هر تابع فعال‌سازی استفاده گردید. نتایج مدل‌سازی شبکه عصبی نشان داد که تابع فعال‌سازی تانژانت هیپربولیک-همانی به دلیل داشتن کمترین

منابع

- آقاجانی، ن.، کدیور، م.، کاشانی نژاد، م.، و حسینی، ح.، ۱۳۸۸، بررسی اثر فرآیند مالت‌سازی بر ویژگی‌های فیزیکوشیمیایی دو رقم جو (صحرا و دشت)، مجله علوم و فنون کشاورزی و منابع طبیعی، شماره ۴۸، ۲۱۹-۲۲۹.
- آقاجانی، ن.، کاشانی نژاد، م.، کدیور، م.، حسینی، ح.، ۱۳۸۸، اثر دما و نوع خشک‌کن بر خواص فیزیکوشیمیایی مالت حاصل از ارقام جو، مجله علوم کشاورزی و منابع طبیعی، شماره ۳.
- چایجان، ر. آ.، خوش‌تقاضا، م. ه.، منتظر، غ. ع.، مینایی، س.، علیزاده، م. ز. ر.، ۱۳۸۸، تخمین ضریب تبدیل شلتوک با استفاده از شبکه‌های عصبی مصنوعی در خشک کردن بستر سیال، علوم و فنون کشاورزی و منابع طبیعی، شماره ۴۸، ۲۸۵-۲۹۸.
- خزائی، ن. ب.، چایجان، ر. آ.، توکلی‌هشتچین، ت.، خوش‌تقاضا، م. ه.، ۱۳۸۶، بررسی شاخص‌های مهم خشک کردن انگور در روش خشک

کردن با جریان هوای گرم به کمک شبکه‌های عصبی مصنوعی، مجله پژوهش کشاورزی: آب و خاک و گیاه در کشاورزی، شماره ۳، ۱۴۱-۱۵۴.
 قدس ولی، ع. ر.، ۱۳۸۹، بررسی اختلاط مالت منابع غلاتی جهت استفاده در صنایع پخت و تولید نوشابه‌های مالتی غیر الکلی، مجله تحقیقات مهندسی کشاورزی، شماره ۳، ۵۵-۷۰.

مختاریان، م.، توکلی‌پور، ح.، و کوشکی، ف.، ۱۳۹۰، پیش بینی خواص فیزیکی پسته با استفاده از شبکه‌های عصبی مصنوعی در طی فرآوری، مجله علوم و فناوری غذایی، شماره ۳ (پیاپی ۹)، ۲۵-۳۸.

Agu, R. C. and Palmer, G. H., 2003, Pattern of nitrogen distribution in barley grains grown in the field. *Journal of the Institute of Brewing*, 109, 110-113.

Association of Analytical Chemists. 2006, Official Method of Analysis of the Association of Analytical Chemists, 18th edition. AOAC Washington, DC.

Biazus, J. P. M., Souza, A. G., Santana, J. C. C., Sauza, R. R., and Tambougi, E. B. 2005. Optimization of drying process zea mays malt to use as alternative source of amylolytics enzymes Brazilian Archives of Biology and Technology, 48: 185-190.

Briggs, D. E., 1998, Malt and Malting. Blackie Academic and Profession. London. 79 p.

Celuse, I. Brijis, K. and Delcour, A., 2006, The effect of malting and mashing on barley protein extractability. *Journal of Cereal Science*, 44(2), 203-211.

Curvelo Santana, J. C., Araújo, S. A., Librantz, A. F. H. and Tambourgi, E. B. 2010. Optimization of Corn Malt Drying by Use of a Genetic Algorithm, *Journal of Drying Technology*, 28: 1236-1244.

Dendy, D. A. V. and Dobraszczyk, B. J., 2001, Cereal and products: chemistry and technology. Aspen Publishers, Inc, 423 p.

Fernandes, A. M., Oliveira P., Moura J. P., Oliveira A. A., Falco V., Correia M. J. and Melo-Pinto P. 2011. Determination of Anthocyanin Concentration in Whole Grape Skins Using Hyperspectral Imaging and Adaptive Boosting Neural Networks. *Journal of Food Engineering*, In press.

Goni, S. M., Oddone S., Segura J. A., Mascheroni R. H. and Salvadori V. O. 2008. Prediction of foods freezing and thawing times: Artificial neural networks and genetic algorithm approach. *Journal of Food Engineering*, 84: 164-178.

Kashaninejad, M., Dehghani, A. A. and Kashiri, M., 2009, Modeling of wheat soaking using two artificial neural networks (MLP and RBF). *Journal of Food Engineering*, 91, 602-607.

Koc, A. B., Heinemann P. H. and Ziegler G. R. 2007. Optimization of whole milk powder processing variables with neural networks and genetic algorithms. *Journal of Food and Bioproducts Processing*, 85: 336-343.

Madadlou, A., Emam-Djomeh Z., Ebrahimzadeh Mousavi M., Ehsani M. R., Javanmard M. and Sheehan D. 2009. Response surface optimization of an artificial neural network for predicting the size of re-assembled casein micelles. *Journal of Computers and Electronics in Agriculture*, 68: 216-221.

Mateo, F., Gadea R., Mateo E. M. and Jiménez M. 2011. Multilayer perceptron neural networks and radial-basis function networks as tools to forecast accumulation of deoxynivalenol in barley seeds contaminated with *Fusarium culmorum*. *Journal of Food Control*, 22: 88-95.

Menlik, T., Özdemir M. B., and Kirmaci V. 2010. Determination of freeze-drying behaviors of apples by artificial neural network. *Journal of Expert Systems with Applications*, 37: 7669-7677.

McCleary, B. V. and Shameer, I., 1987, Assay of β -glucanases using Azo Barley Glucan: an improved precipitant. *Journal of the Institute of Brewing*, 93, 87-90.

Momenzadeh, L., Zomorodian A. and Mowla D. 2011. Experimental and theoretical investigation of shelled corn drying in a microwave-assisted fluidized bed dryer using artificial neural network. *Journal of food and bioproducts processing*, 89: 15-21.

Moris, P. C., and Bryce, J. H. 2000. *Cereal Biotechnology*, Woodhead Publishing Limited. Washington. 237p.

Osman, A. M., Coverdate, S. M., Cole, N., Hamilton, S. E., Jersey, J. D., and Inkerman, P. A. 2002. Characterisation and assessment of role of barley malt endoproteases during malting and mashing. *Journal of Institute of Brewing*, 108: 1. 62-67.

Sablani, S. S., Shafiur Rahman, M., Datta, A. K., and Mujumdar, A. S. 2007. *Handbook of food and bioprocess modeling technology*. CRC press. P 378-380.

USDA. 2011, United States Department of Agriculture. Foreign Agricultural Service. Office of Global Analysis. International Production Assessment Division. Washington, DC, USA

Wu, C. H. and McLarty, J. W., 2000 *Neural Networks and Genome Informatics*. Elsevier Publishing Co. USA.