



پیش‌بینی برخی خصوصیات فیزیکی (چروکیدگی و رنگ) و مکانیکی میوه بنه پس از خشک کردن با خشک‌کن بسترسیال به کمک شبکه‌های عصبی مصنوعی

محمد کاوه^۱، رضا امیری چایجان^۲

۱- دانشجوی کارشناسی ارشد مکانیک ماشین‌های کشاورزی، دانشگاه بوعلی سینا، همدان (skawe@yahoo.com)

۲- دانشیار گروه مهندسی بیوسیستم، دانشگاه بوعلی سینا، همدان

چکیده

هدف از این پژوهش، پیش‌بینی برخی خصوصیات فیزیکی (چروکیدگی و رنگ) و مکانیکی (نیروی شکست) میوه بنه در طی فرآیند خشک کردن با خشک‌کن بسترسیال به کمک شبکه‌های عصبی مصنوعی است. آزمایش‌ها در سه سطح دما (۴۰ و ۶۰ و ۸۰ درجه سلسیوس) و ۳ سطح سرعت (۰/۸ و ۲/۵ و ۴/۵ متر بر ثانیه) انجام شد. دو عامل موثر برای خصوصیات فیزیکی (چروکیدگی و رنگ) و مکانیکی (نیروی شکست)، دما هوای ورودی و سرعت هوای ورودی در عملکرد خشک‌کن بسترسیال به عنوان متغیرهای مستقل برای شبکه عصبی مصنوعی در نظر گرفته شد. داده‌های لازم برای ایجاد الگوهای آموزش، ارزیابی و آزمون با انجام آزمایش‌های خشک کردن برای دماها و سرعت‌ها مختلف با استفاده از یک خشک‌کن آزمایشگاهی بسترسیال، جمع‌آوری شد. از شبکه‌های پس انتشار پیش‌رو (CFBP) و پس انتشار پیش‌خور (FFBP) با الگوریتم‌های یادگیری لونیگ-مارکواریت و تنظیم بیزی برای آموزش الگوهای موجود استفاده شد. نتایج نشان داد که بهترین شبکه برای پیش‌بینی چروکیدگی، شبکه‌ای با توپولوژی ۱-۴-۲ با چرخه آموزش ۱۱ و با تابع آستانه TANSIG در شبکه CFBP دارای کمترین خطای آموزشی ۰/۰۰۰۰۱ و ضریب تعیین ۰/۹۹۱۷ می‌باشد. بیشترین ضریب تعیین برای نیروی شکست ۰/۹۸۴۱ به دست آمد.

واژه‌های کلیدی: بنه، خشک‌کن بسترسیال، نیروی شکست، چروکیدگی و شبکه‌های عصبی مصنوعی

مقدمه

بنه (*Pistacia Atlantica*) یکی از درختان قدیمی است که عمر طولانی دارد و ارتفاع آن حدود ۵-۶ متر می‌باشد. از درخت بنه شیره سقز تولید می‌شود که از این شیره در تهیه آدامس، عطر، خوشبوکننده‌ها، حشره کش‌ها و در صنعت دارو سازی در تهیه نرم‌کننده‌ها و ضد عفونی‌کننده‌ها استفاده می‌شود. همچنین در صنعت پلاستیک سازی، تهیه واکس کفش، چرم و صنعت چاپ مورد استفاده قرار می‌گیرد. میوه درخت بنه ریز و کروی و به رنگ سبز تیره است. مغز میوه بنه شبیه پسته، ولی کوچکتر از آن است. زمان برداشت میوه بنه اردیبهشت و خرداد است (Amiri Chayjan and Kaveh, 2013). میوه بنه دارای کاربردهای پزشکی از جمله: کاهش چربی‌های خون، نشاط‌آور و تقویت‌کننده کبد و طحال می‌باشد. روغن و عصاره این میوه برای سلامتی و بیماری‌های قلبی و عروقی مفید است (قنبری نیایی و همکاران، ۱۳۹۰).



هدف اصلی از فرآوری محصولات به حداقل رساندن افت کمی و کیفی محصولات پس از برداشت می‌باشد. شناخت خواص فیزیکی و مکانیکی محصولات کشاورزی و مواد غذایی همواره مورد توجه و علاقه متخصصین کشاورزی و صنایع غذایی بوده است. تاکنون روشهای زیادی برای شناخت خواص بافت مواد بیولوژیک استفاده شده است. روشهای مکانیکی به علت سادگی و شباهتی که از لحاظ ماهیت با مراحل برداشت و فرآوری پس از برداشت محصول دارند، از عمومیت بیشتری برخوردارند. خواص مکانیکی ویژگی‌های هستند که بر رفتار محصول کشاورزی که تحت نیرویی قرار گرفته‌اند تاثیر می‌گذارد. خواص مکانیکی بر عملیات مختلف فرآوری محصولات کشاورزی تاثیر بسزایی دارند. اطلاعات مربوط به خواص مکانیکی برای استفاده در طراحی تجهیزات آسیاب کردن، جابجایی کردن، انبار کردن، حمل و نقل و فرآوری مفید هستند (Kashaninejad et al., 2005).

شبکه‌های عصبی از عناصر عملیاتی ساده‌ای ساخته شده‌اند که به صورت موازی در کنار هم عمل می‌کنند. این عناصر از سیستم‌های عصبی زیستی الهام گرفته شده‌اند. در طبیعت، عملکرد شبکه‌های عصبی از طریق نحوه اتصال بین اجزا تعیین می‌شود. بنابراین ما می‌توانیم یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی بسازیم و با تنظیم مقادیر هر اتصال، تحت عنوان وزن اتصال، نحوه ارتباط بین اجزای آن را تعیین نماییم. شبکه‌های عصبی نوعی مدل‌سازی ساده انگارانه از سیستم‌های عصبی واقعی هستند که کاربردهای فراوانی در حل مسائل مختلف در علوم دارند. حوزه کاربرد این شبکه‌ها آن‌چنان گسترده است که از کاربردهای طبقه‌بندی گرفته تا کاربردهای نظیر درون‌یابی، تخمین، آشکارسازی و ... را شامل می‌شوند. شاید مهمترین مزیت این شبکه‌ها، توانایی وافر آن‌ها در کنار سهولت استفاده از آن‌ها باشد (کیا، ۱۳۸۹).

شبکه‌های عصبی مصنوعی شامل یک الگوی پردازش اطلاعات و ابزاری قدرتمند به منظور شبیه سازی، الهام گرفته از نرون‌های بیولوژیک است. با این رویکرد، شبکه‌های عصبی مصنوعی همانند ساختار بیولوژیکی مغز انسان با ترکیب ویژگی‌هایی همچون قدرت یادگیری، تعمیم‌دهی، پردازش موازی و تصمیم‌گیری، قابلیت حل کامل مسائلی پیچیده با ماهیتی خطی یا غیر خطی را خواهند داشت (Menlik et al., 2010).

محققین بسیاری از شبکه‌های عصبی مصنوعی برای پیش‌بینی خواص فیزیکی مورد نظر در خشک‌کن‌ها استفاده کرده‌اند. (Niamnuy et al., 2012) برای پیش‌بینی چروکیدگی میگو، (Shafafi Zenoozian and Devahastin, 2009) برای پیش‌بینی تغییرات رنگ و چروکیدگی کدو، از شبکه‌های عصبی استفاده کردند. هدف از این پژوهش پیش‌بینی نیروی شکست، تغییرات رنگ و چروکیدگی بانه بعد از خشک کردن با خشک‌کن بستر سیال با استفاده از شبکه عصبی مصنوعی می‌باشد.



مواد و روشها

بنه تازه از جنگل‌های سردشت، استان آذربایجان غربی تهیه شد و برای انجام آزمایش‌ها در یخچال در دمای $3 \pm 1^\circ\text{C}$ نگهداری شد. مقدار رطوبت اولیه بنه با استفاده از آون به دست آمد. نمونه‌های ۱۵ گرمی در آون در دمای $70 \pm 1^\circ\text{C}$ به مدت ۲۴ ساعت قرار داده شد. مقدار رطوبت اولیه بنه (d.b.) $2/6$ به دست آمد (Amiri Chayjan and Kaveh, 2013).

برای انجام آزمایش‌ها از یک خشک‌کن بستر سیال آزمایشگاهی استفاده شد. آزمایشها در سه سطح دما (40°C و 60°C و 80°C درجه سلسیوس) و ۳ سطح سرعت ($0/8$ و $2/5$ و $4/5$ متر بر ثانیه) و در سه تکرار، در شرایط آزمایشگاهی که مقدار رطوبت نسبی محیط آزمایشگاه در طی آزمایشها $26/3 - 31/49\%$ و دمای محیط آزمایشگاه بین $19/81$ تا $27/12^\circ\text{C}$ اندازه گیری شده بود، انجام شد. سپس رطوبت نمونه‌ها به ۱۸ درصد بر پایه خشک رسیدند و محاسبات نیروی شکست، چروکیدگی و رنگ براساس این رطوبت انجام گرفت.

چروکیدگی

محصول در شرایط متفاوت دما و سرعت‌های ورودی مختلف خشک شد. درصد چروکیدگی به کمک معادله زیر محاسبه شد (Mayor and Sereno, 2004).

$$M = \frac{(V_0 - V)}{V_0} \times 100 \quad (1)$$

M درصد چروکیدگی V_0 و V به ترتیب حجم اولیه (قبل از خشک کردن) و حجم ثانویه (حجم بعد از خشک کردن) (m^3) است.

رنگ

برای به دست آوردن میزان تغییر رنگ میوه بنه (RGB) در طی فرآیند، رنگ نمونه‌ها قبل و بعد از خشک کردن توسط دستگاه آنالیز رنگ مدل (RGB-1002) ساخت تایوان استفاده شد. این دستگاه رنگ‌های قرمز (R)، سبز (G) و آبی (B) را اندازه‌گیری می‌کند. درصد تغییرات RGB از معادلات زیر به دست می‌آیند:

$$\Delta R = \frac{R_1 - R_2}{R_1} \times 100 \quad (2)$$

$$\Delta G = \frac{G_1 - G_2}{G_1} \times 100 \quad (3)$$



$$\Delta B = \frac{B_1 - B_2}{B_1} \times 100 \quad (۴)$$

که در آن ΔR درصد تغییرات رنگ قرمز، R_1 میزان رنگ قرمز قبل از خشک کردن، R_2 میزان رنگ قرمز بعد از خشک کردن، ΔG درصد تغییرات رنگ سبز، G_1 میزان رنگ سبز قبل از خشک کردن و G_2 میزان رنگ سبز بعد از خشک کردن، ΔB درصد تغییرات رنگ آبی، B_1 میزان رنگ آبی قبل از خشک کردن و B_2 میزان رنگ سبز بعد از خشک کردن است.

نیروی شکست

حد شکستگی دانه، نقطه‌ای در منحنی نیرو-تغییر شکل می‌باشد که در آن حتی با کاهش نیرو میزان تغییر شکل افزایش پیدا کرده و جسم شکسته می‌شود. این نقطه، نقطه گسیختگی ماده را بیان می‌کند. در مورد مواد نرم و سخت، بعد از گسیختگی تغییر شکل قابل توجهی دیده می‌شود. بنابراین در آزمایش‌های مختلف از روی نمودار نیرو-تغییر شکل، حداکثر نیروی شکست دانه ثبت شد. برای انجام آزمایشات از دستگاه آزمون مواد Zwick/Roell ساخت کشور آلمان استفاده شد.

شبکه عصبی

در این تحقیق از شبکه‌های پس انتشار پیشخور و پس انتشار پیشرو استفاده شده است.

شبکه پس انتشار پیشخور (FFBP): شامل یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی است. برای آموزش این شبکه از الگوریتم یادگیری پس انتشار خطا (BP) استفاده می‌شود. که ابتدا وزن‌های لایه خروجی با مقادیر مطلوب مقایسه شده در صورتی که خطا بیش از حد تعیین شده باشد وزن‌های لایه خروجی بر اساس قاعده‌های به هنگام سازی تعدیل می‌شود و هنگامی که خطای آموزش کمتر از خطای از پیش تعیین شده باشد فرآیند یادگیری پایان می‌یابد.

شبکه پس انتشار پیش‌رو (CFBP): مانند شبکه پس انتشار پیشخور از الگوریتم BP برای اصلاح وزن‌ها استفاده می‌کند ولی خصوصیت اصلی شبکه مذکور این است که نرون‌های هر لایه به همه نرون‌های لایه‌های قبل متصل است (Amiri-Chayjan and Esna-Ashari, 2010).

الگوریتم‌های آموزش

الگوریتم‌های آموزش به کار رفته برای بهنگام‌سازی وزن‌های شبکه‌های مورد استفاده عبارتند از:

الگوریتم لونیبرگ-مارکوارت (LM): الگوریتم LM برای آموزش شبکه عصبی مصنوعی از طریق توزیع محاسبات و فضای مورد نیاز، موازی عمل می‌کند و از این رو سریع‌ترین روش برای آموزش شبکه‌های عصبی پس انتشار با ابعاد متوسط (حداکثر چند



صد اتصال وزنی و بایاس) است. الگوریتم LM اساسا بر مبنای ماتریس هسین که برای بهینه‌سازی غیر خطی بر مبنای حداقل مربعات استفاده می‌شود.

الگوریتم تنظیم بیزی (BR): فرایند آموزش شبکه پس انتشار با تنظیم بیزی، با توزیع تصادفی وزن‌های اولیه آغاز می‌شود. توزیع تصادفی این پارامترها جهت‌گیری اولیه را قبل از ارائه داده‌ها به شبکه تعیین می‌کند. بعد از ارائه داده‌ها به شبکه، بهنگام-سازی وزن‌های اولیه آغاز می‌شود تا توزیع ثانویه با استفاده از تنظیم بیزی حاصل شود (Demuth et al., 2007).

طراحی شبکه

شبکه عصبی مصنوعی با دو نرون لایه ورودی (سرعت و دمای هوای ورودی) و یک نرون در لایه خروجی (چروکیدگی یا رنگ یا نیروی شکست) طراحی شد (شکل ۱). مقدار ورودی و مرزها در جدول ۱ ارائه شد. تجزیه و تحلیل اطلاعات به دست آمده با استفاده از Neural Network Toolbox (ver. 5) از نرم‌افزار Matlab استفاده شد. برای بهینه‌سازی ساختار شبکه از سه تابع زیر استفاده شد (Niamnuy et al., 2012):

$$Y_j = X_i \quad \text{(PURELIN)} \quad (۴)$$

$$Y_j = \frac{2}{(1 + \exp(-2X_j)) - 1} \quad \text{(TANSIG)} \quad (۵)$$

$$Y_j = \frac{1}{1 + \exp(-X_j)} \quad \text{(LOGSIG)} \quad (۶)$$

که X_i از رابطه زیر محاسبه می‌شود:

$$X_j = \sum_{i=1}^m W_{ij} \times Y_i + b_j \quad (۷)$$

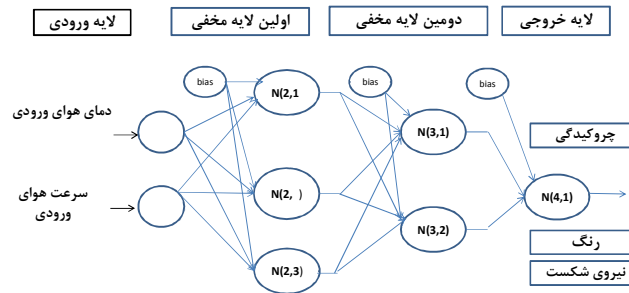
m تعداد نرون لایه خروجی، W_{ij} وزن بین لایه i و j ، Y_i خروجی نرون i ام، و b_j مقدار بایاس نرون لایه j ام است.

حدود ۷۵٪ داده‌ها برای آموزش و ۲۵٪ داده‌ها به طور تصادفی برای ارزیابی شبکه آموزش دیده مورد استفاده قرار گرفت. برای یافتن شبکه‌ای با توپولوژی مناسب به کمک الگوریتم‌های آموزشی، از معیار میانگین مربع خطا استفاده شده است.

$$MSE = \frac{\sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2}{NM} \quad (۸)$$



که MSE میانگین مربع خطا در مرحله آموزش، S_{ip} خروجی شبکه در نرون i ام و p ام و T_{ip} خروجی مطلوب در نرون i ام و p ام، N تعداد نرون‌های خروجی و M تعداد الگوهای آموزشی است.



شکل ۱: توپولوژی شبکه مورد استفاده

جدول ۱- پارامترهای ورودی شبکه عصبی مصنوعی برای پیش‌بینی چروکیدگی، رنگ و نیروی شکست

پارامترها	کمینه	بیشینه	تعداد سطوح
دما هوا ($^{\circ}C$)	۴۰	۸۰	۳
سرعت هوا (m/s)	۰/۸	۴/۵	۳

نتایج و بحث

درصد تغییرات چروکیدگی، رنگ و نیروی شکست میوه بنه در خشک‌کن بستر سیال در دما و سرعت‌های مختلف به دست آمد. همانطور که در جدول‌های (۲، ۳ و ۴) نشان داده شده است بیشترین درصد تغییرات چروکیدگی، رنگ و نیروی شکست میوه بنه در دمای ۸۰ درجه سلسیوس و سرعت ۴/۵ متر بر ثانیه بود و کمترین مقدار تغییرات درصد تغییرات چروکیدگی، رنگ و نیروی شکست در دمای ۴۰ درجه سلسیوس و در سرعت ۰/۸ متر بر ثانیه به دست آمد. با افزایش دما و سرعت هوای ورودی درصد تغییرات چروکیدگی، رنگ و نیروی شکست افزایش یافت.



جدول ۲: درصد تغییرات چروکیدگی بنه در دما و سرعت‌های مختلف خشک‌کن

دمای هوای ورودی °C	۰/۸m/s	۲/۵m/s	۴/۵m/s
۴۰	۶۰/۹۱	۶۲/۸۱	۶۶/۹۲
۶۰	۶۶/۵	۶۷/۷۱	۷۰/۵۷
۸۰	۶۸/۸۸	۷۰/۹۸	۷۲/۲۰

جدول ۳- درصد تغییرات رنگ (ΔRGB) بنه در دما و سرعت‌های مختلف خشک‌کن

دمای هوای ورودی (°C)	۰/۸m/s			۲/۵m/s			۴/۵m/s		
	R	G	B	R	G	B	R	G	B
۴۰	۲۳/۱۶	۲۹/۶۴	۲۹/۷۴	۳۷/۷۶	۳۶/۴۴	۳۲/۹۹	۴۲/۳۶	۴۹/۰۸	۴۵/۲۸
۶۰	۳۳/۳۷	۴۳/۲۷	۳۹/۱۵	۴۷/۵۱	۵۳/۱۳	۴۵/۳۰	۵۳/۲۴	۵۵/۷۶	۵۰/۱۰
۸۰	۴۹/۲۱	۵۷/۶۴	۵۷/۲۱	۵۳/۳۰	۶۱/۱۹	۵۷/۳۱	۶۶/۱۵	۶۲/۷۷	۵۹/۸۵

جدول ۴- تغییرات نیروی شکست (نیوتن) بنه در دما و سرعت‌های مختلف خشک‌کن

دمای هوای ورودی (°C)	۰/۸m/s	۲/۵m/s	۴/۵m/s
۴۰	۴۴/۶۹	۵۷/۰۲	۶۷/۶۲
۶۰	۵۶/۱۳	۷۶/۵۲	۸۶/۱۳
۸۰	۷۳/۶۱	۹۳/۵۱	۱۳۵/۶۲

شبکه عصبی

چروکیدگی، تغییرات رنگ و نیروی شکست در شرایط بستر سیال به کمک شبکه‌های پس انتشار پیش‌خور (FFBP) و پس

انتشار پیش‌رو (CFBP) الگوریتم‌های یادگیری و توپولوژی‌های مختلف بررسی شد.



با توجه جدول (۵)، کاربرد الگوریتم LM و BR به همراه شبکه‌های CFBP و FFBP نشان داد که بهترین شبکه برای پیش‌بینی چروکیدگی، شبکه‌ای با توپولوژی ۱-۴-۲ با چرخه آموزش ۱۱ و با تابع آستانه TANSIG در شبکه CFBP دارای کمترین خطای آموزشی ۰/۰۰۰۰۱، خطای نسبی میانگین آن ۰/۱۳۶ و ضریب تعیین ۰/۹۹۱۷ می‌باشد.

جدول ۵- نتایج آرایش‌های مختلف شبکه عصبی مصنوعی (ANN) در برآورد تغییرات چروکیدگی برای خشک‌کن بستر سیال

چرخه آموزش	MAE	R ²	MSE	آرایش شبکه	تابع محرک	توابع آموزش	شبکه
۱۰	۰/۲۴۲	۰/۹۷۷۴	۰/۰۰۱۱۸	۲-۳-۱	TANSIG-LOGSIG-TANSIG	LM	FFBP
۱۹	۰/۳۹۱	۰/۹۷۰۵	۰/۰۰۲۱۶	۲-۵-۱	TANSIG	BR	
۱۱	۰/۱۳۶	۰/۹۹۱۷	۰/۰۰۰۰۱	۲-۴-۱	TANSIG	LM	CFBP
۹	۰/۳۷۸	۰/۹۸۰۶	۰/۰۰۱۲۲	۲-۴-۳-۱	TANSIG-TANSIG-PURELIN	BR	

نتایج به دست آمده از شبکه عصبی مصنوعی برای تغییرات رنگ بنه در خشک‌کن بسترسیال در آرایش‌های مختلف نشان داد که برای تغییر رنگ قرمزی (ΔR) بهترین شبکه FFBP با تابع آموزش لونیبرگ-مارکوارت (LM) و با آرایش ۱-۵-۲ با $R^2=0/9755$ و همچنین برای تغییرات رنگ سبزی (ΔG) بهترین شبکه با ساختار CFBP با تابع آموزش لونیبرگ-مارکوارت (LM)، آرایش ۱-۵-۲، $R^2=0/9811$ و $MSE=0/00184$ و $MAE=1/21$ با چرخه آموزش و تابع محرک TANSIG-LOGSIG-TANSIG، به عنوان بهترین شبکه انتخاب شد. برای تغییرات رنگ آبی (ΔB)، بهترین شبکه با ساختار FFBP با تابع آموزش لونیبرگ-مارکوارت (LM)، با آرایش ۱-۴-۲، $MSE=0/00252$ و $R^2=0/9781$ و $MAE=1/35$ با چرخه آموزش و تابع محرک TANSIG-PURELIN-TANSIG، به عنوان بهترین آرایش مطلوب انتخاب شد.

با توجه به جدول (۶) بهترین شبکه برای پیش‌بینی نیروی شکست در خشک‌کن بستر سیال در ساختار FFBP، تابع آموزش تنظیم بیزی (BR) و با آرایش ۱-۳-۲ دارای بیشترین ضریب تعیین ($R^2=0/9841$)، کمترین میانگین مربعات خطا ($MSE=0/00061$) و حداقل خطای مطلق ($MAE=1/48$) با چرخه آموزش به دست آمد.



جدول ۶- نتایج آرایش‌های مختلف شبکه عصبی مصنوعی (ANN) در برآورد نیروی شکست برای خشک‌کن بستر سیال

چرخه آموزش	MAE	R ²	MSE	آرایش شبکه	توابع محرک	توابع آموزش	شبکه
۴۲	۱/۵۳	۰/۹۸۳۸	۰/۰۰۰۹۱	۲-۳-۱	TANSIG	LM	FFBP
۱۲۴	۱/۴۸	۰/۹۸۴۱	۰/۰۰۰۶۱	۲-۵-۳-۱	TANSIG-PURELIN-TANSIG	BR	
۱۰	۲/۱۹	۰/۹۶۶۲	۰/۰۰۱۴۲	۲-۶-۴-۱	TANSIG-TANSIG-TANSIG	LM	CFBP
۱۱	۳/۴۲	۰/۹۴۶۷	۰/۰۰۲۹۳	۲-۳-۱	TANSIG	BR	

نتیجه‌گیری

شبکه عصبی روشی مناسب برای نگاشت غیر خطی است و چروکیدگی، تغییرات رنگ (RGB) و نیروی شکست را به کمک دو پارامتر ورودی دمای خشک‌کن و سرعت جریان هوا پیش‌بینی می‌کند. بهترین شبکه عصبی برای آموزش داده‌های چروکیدگی و پیش‌بینی چروکیدگی، شبکه‌ای با توپولوژی ۲-۴-۱ با چرخه آموزش ۱۱ و با تابع آستانه TANSIG در شبکه CFBP دارای کمترین خطای آموزشی (۰/۰۰۰۰۱) و خطای نسبی میانگین آن (۰/۱۳۶) و بیشترین ضریب تعیین (۰/۹۹۱۷) می‌باشد. همچنین بهترین شبکه برای پیش‌بینی نیروی شکست در خشک‌کن بستر سیال در ساختار FFBP، تابع آموزش تنظیم بیزی (BR) و با آرایش ۲-۵-۳-۱ دارای بیشترین ضریب تعیین ($R^2=0.9841$)، کمترین میانگین مربعات خطا ($MSE=0.00061$) و حداقل خطای مطلق ($MAE=0.148$) با چرخه آموزش به دست آمد.

منابع

- ۱- قنبری نیایی، ع.، فتحی، ر.، شاهنده، ف.، یزدانی، م.، و حاجی‌زاده، ا. ۱۳۹۰. تاثیر تمرین استقامتی و عصاره پسته وحشی (بنه) بر سطح استراحتی ویسفاتین و لیپیدهای پلاسما. ماهنامه علمی- پژوهشی دانشور پزشکی، دانشگاه شاهد، سال هیجدهم، شماره ۹۴، ۱-۱۱.
- ۲- کیا، م. ۱۳۸۹. محاسبات نرم در MATLAB. چاپ اول. انتشارات کیان رایان سبز. ص ۱۴۱-۱۴۰.
- 3- Amiri Chayjan, R., and M. Kaveh. 2013. Physical parameters and kinetic modeling of fix and fluid bed drying of terebinth seeds. J. Food Proces Preservation, doi:10.1111/jfpp.12092. (in Pre)
- 4- Amiri Chayjan, R., and M. Esna-Ashari. 2010. Comparison between artificial neural networks and mathematical models for estimating equilibrium moisture content in raisin. Agric Eng Int: CIGR Journal 12(1): 158–166.
- 5- Demuth, H., M. Beale, and M. Hagan. 2007. Neural network toolbox 5. The MathWorks, Natick, MA, USA.



- 6- Kashaninejad, M., A. Mortazavi, A. Safekordi, and L.G. Tabil. 2005. Some physical properties of Pistachio (*Pistachio vera* L.) nut and its kernel. *Journal of Food Engineering*. 72 (1): 30–38.
- 7- Mayor, L., and A. M. Sereno. 2004. Modelling shrinkage during convective drying of food materials: a review. *Journal of Food Engineering*. 61: 373–386.
- 8- Menlik, T., M.B. Özdemir, and V. Kirmaci. 2010. Determination of freeze-drying behaviors of apples by artificial neural network. *Expert Systems with Applications*. 37: 7669–7677.
- 9- Niamnuy, C., Kerdpiboon, S., and M. Devahastin. 2012. Artificial neural network modeling of physicochemical changes of shrimp during boiling. *LW T - Food Science and Technology* 45: 110-116.
- 10- Shafafi Zenoozian, M. and S. Devahastin. 2009. Application of wavelet transform coupled with artificial neural network for predicting physicochemical properties of osmotically dehydrated pumpkin. *Journal of Food Engineering*. 90: 219–227.





Prediction some physical properties (shrinkage and color) and mechanical properties of terebinth fruit under fluidized bed dryer using artificial neural networks.

Mohammad Kaveh^{1*} and Reza Amiri Chayjan²

1. MSc Student, Department of Biosystems Engineering, Bu-Ali Sina University, Hamedan
2. Associate Professor, Department of Biosystems Engineering, Bu-Ali Sina University, Hamedan

The purpose of this study was prediction of physical (shrinkage and color) and mechanical properties (rupture force) of terebinth fruit during fluidized bed dryer drying assist with artificial neural networks (ANNs). Two effective factors on physical (shrinkage and color) and mechanical properties (rupture force), were air temperature and air velocity as independent variables for artificial neural network modeling. Data necessary for training, evaluating and testing of ANN were conducted using a laboratory fluidized bed dryer were collected. Feed and cascade forward back propagation networks with learnin algorithms of Levenberg-Marquardt and the Bayesian regulation the patterns were used to train. The results showed that the best network for prediction of shrinkage was cascade forward back propagation with threshold function of TANSIG and 2-4-1 topology. This structure was trained at 11 epochs. This optimized network had presented the lowest training mean square error (0.00001) and the highest coefficient of determination (0.9917) was obtained. The highest coefficient of determination for the rupture force was 0.9841.