

مقایسه مدل ریاضی و شبکه عصبی مصنوعی در تخمین رطوبت برش‌های پرتقال طی فرایند خشک‌شدن

مریم نیکزاد^{۱*}، مریم خاورپور^۲، کامیار موقر نژاد

۱. استادیار، گروه فرایندهای جداسازی، دانشکده مهندسی شیمی، دانشگاه صنعتی نوشیروانی بابل، بابل ایران
۲. استادیار، گروه مهندسی شیمی، دانشکده فنی و مهندسی، واحد آیت‌الله آملی، دانشگاه آزاد اسلامی، آمل، ایران
۳. استاد، گروه ترموسینتیک و کاتالیست، دانشکده مهندسی شیمی، دانشگاه صنعتی نوشیروانی بابل، بابل ایران

(تاریخ دریافت: ۹۷/۱/۲۶، تاریخ آخرین بازنگری: ۹۷/۳/۳۱، تاریخ پذیرش: ۹۷/۴/۴)

چکیده

در تحقیق حاضر، خشک‌کردن لایه نازک برش‌های پرتقال در خشک‌کن هوای داغ آزمایشگاهی مدل‌سازی گردید. فرایند خشک‌کردن تحت شرایط متفاوت، سه دمای ۵۰، ۶۰ و ۷۰ °C و سرعت جابه‌جایی هوای ۱ و ۲ m/s انجام شد. آنالیز آماری داده‌ها نشان داد که تغییرات دما و سرعت جابه‌جایی هوا بر روی نسبت رطوبت اثرات معنی‌داری $p < 0.05$ داشته، اما اثر متقابل دما و سرعت جابه‌جایی هوا، اثر معنی‌دار نداشته است. بنابر نتایج حاصل، کم‌ترین نسبت رطوبت در برش‌های پرتقال خشک شده تحت دمای ۷۰ °C و سرعت جابه‌جایی هوای ۲ m/s به میزان ۵/۳٪ به دست آمد. پس از انجام آزمایش‌ها، داده‌های حاصل از آزمایش‌های خشک‌کردن با ۷ مدل شناخته‌شده ریاضی برازش داده شد. بر اساس نتایج برازش، مدل پیچ با بالاترین مقدار ضریب تعیین $R^2 = 0.9992$ و $RMSE = 2.71 \times 10^{-3}$ در مقایسه با سایر مدل‌ها عملکرد بهتری در برآورد نسبت رطوبت، نشان داد. همچنین، از مدل شبکه عصبی مصنوعی پس‌انتشار پیش‌خور برای تخمین نسبت رطوبت برش‌های پرتقال بر اساس سه متغیر ورودی مدت زمان خشک‌کردن، دما و سرعت جابه‌جایی هوا استفاده شد. در طراحی این شبکه از دو تابع آستانه تانژانت هیپربولیک و خطی در لایه پنهان و خروجی استفاده گردید. شبکه عصبی طراحی شده با توپولوژی ۱-۲۰-۳ و الگوریتم آموزشی لونیگ-مارکوات بهترین نتایج را با بالاترین مقدار ضریب تعیین $R^2 = 0.9994$ و کم‌ترین مقدار ریشه مجذور خطا $RMSE = 1.09 \times 10^{-3}$ ارائه داد. نتایج نشان داد که شبکه عصبی پرسپترون چند لایه، دارای دقت بالاتری در تخمین نسبت رطوبت برش‌های پرتقال طی فرایند خشک‌شدن است.

واژه‌های کلیدی: پرتقال، خشک‌کردن، نسبت رطوبت، شبکه عصبی مصنوعی، مدل ریاضی.

۱. مقدمه

مرکبات در میان محصولات کشاورزی در سراسر جهان جایگاه ویژه‌ای را در اختیار دارند. یکی از این میوه‌های مهم از لحاظ اقتصادی و صنعتی میوه پرتقال *Citrus sinensis* است که به علت دارا بودن مقادیر قابل توجه ویتامین C، بتاکاروتن و هم‌چنین فیبر و املاح معدنی نظیر پتاسیم، کلسیم و فسفر ارزش غذایی و دارویی فوق‌العاده‌ای دارد. مطابق گزارش فائو در سال ۲۰۱۰ کشور ایران، با سطح زیر کشت حدود ۲۴۰ هزار هکتار و تولید ۴/۰۲ میلیون تن مرکبات در سال، از نظر میزان تولید رتبه هفتم در سطح جهان را دارا است [۱]. این محصول به صورت تازه، آب‌میوه و خشک‌شده مورد مصرف قرار می‌گیرد. بر اساس مطالعات انجام شده میزان ضایعات پرتقال در مراحل مختلف بازاریابی حدود ۲۰٪ بوده که بخش زیادی از آن به دوره انبارداری مربوط می‌باشد [۲]. بنابراین ضروری است تا با استفاده از روش‌های نگهداری متفاوت این میزان ضایعات را تقلیل و ماندگاری محصول را افزایش داد.

خشک‌کردن یکی از قدیمی‌ترین روش‌ها برای حفظ و نگهداری مواد غذایی است که ماندگاری محصولات را افزایش می‌دهد. این فرایند علاوه بر کاهش سرعت فساد مواد غذایی توسط میکروارگانیسم‌ها، هم‌چنین سبب کاهش هزینه‌های انبارداری، بسته‌بندی و حمل و نقل می‌گردد [۳]. در بسیاری از کاربردهای صنعتی از روش خشک‌کردن با هوای داغ استفاده می‌شود. این فرایند شامل توزیع یکنواخت هوای گرم بر روی بستری از ماده خشک‌شونده است که سبب کاهش رطوبت ماده غذایی می‌گردد. شرایط عملیاتی فرایند خشک‌کردن اثر بسزایی بر روی نسبت رطوبت نهایی محصول و شاخص‌های کیفی آن دارد. از جمله عوامل تأثیرگذار می‌توان به دمای هوا، سرعت جابه‌جایی هوا و مدت زمان انجام فرایند اشاره نمود [۴]. بنابراین کنترل فرایند خشک‌کردن و کیفیت محصول خروجی آن نیازمند پیش‌بینی تغییرات نسبت رطوبت ماده موردنظر است.

یک روش مؤثر جهت طراحی، شبیه‌سازی و بهینه‌سازی فرایند خشک‌کردن، مدل‌سازی فرایند با یک مدل مناسب است. اغلب مدل‌های ریاضی ارائه شده در زمینه خشک‌کردن مواد غذایی به مطالعه متغیرهای فرایند، پیش‌بینی سینتیک خشک‌شدن و بهینه‌سازی پارامترهای عملیاتی پرداخته‌اند [۵-۷]. بسیاری از محققین از مدل‌های ریاضی خشک‌کردن لایه نازک برای

مدل‌سازی فرایند خشک‌شدن محصولات کشاورزی استفاده نمودند. این مدل‌ها سینتیک فرایند را اغلب با استفاده از توابع نمایی، رگرسیون غیرخطی و چندجمله‌ای‌های با درجه بالا تقریب می‌زنند. از مطالعات انجام شده در این زمینه می‌توان به مدل‌سازی سینتیک خشک‌کردن موز، سیب، کدو تنبل، گوشت شتر مرغ و هویج اشاره نمود [۸-۱۲]. لوتوسکا و همکارانش، خشک‌شدن برش‌های گلابی را به صورت لایه نازک مدل‌سازی کردند [۱۳]. آزمایش‌ها در پنج سطح دمایی ۳۰ الی ۷۰°C و سه سطح سرعت هوای خشک‌کردن ۱، ۱/۵ و ۲ m/s انجام شد. از بین پنج مدل ریاضی به کار رفته، مدل میدیلی بهترین برازش را با داده‌های آزمایشگاهی نشان داد. نوآکوبا و همکارانش، خشک‌کردن برش‌های پیاز را مورد مطالعه قرار دادند [۵]. آزمایش‌های خشک‌کردن در دماهای ۵۰، ۶۰ و ۷۰°C و سرعت هوای ۱/۵، ۱ و ۱/۵ m/s صورت گرفت. از میان مدل‌های در نظر گرفته شده، مدل پیچ با بالاترین ضریب رگرسیون و کم‌ترین میزان خطا به عنوان مناسب‌ترین مدل جهت توصیف فرایند خشک‌کردن برش‌های پیاز انتخاب گردید.

با توسعه و پیشرفت سریع فناوری‌های رایانه‌ای و به‌وجود آمدن نرم‌افزارهای مرتبط، از فناوری هوش مصنوعی برای حل بسیاری از مسائل مدل‌سازی سیستم‌ها و پیش‌بینی فرایندها بهره برده می‌شود. در میان مباحث مختلف هوش مصنوعی، شبکه‌های عصبی مصنوعی از ابزارهایی مهم و پرکاربرد به حساب می‌آیند. امروزه استفاده از این شبکه‌ها برای شبیه‌سازی و مدل‌سازی فرایندهای مختلف در علوم و صنایع غذایی در حال توسعه و پیشرفت می‌باشد. شبکه عصبی مصنوعی، یکی از روش‌های محاسباتی است که از طریق فرایند یادگیری و با شناخت روابط ذاتی بین داده‌ها، نگاشتی بین داده‌های ورودی و خروجی ارائه می‌دهد [۱۴]. مدل‌های شبکه عصبی برخلاف مدل‌های ریاضی، بدون استخراج رابطه بین پارامترها، قادر به تشخیص رابطه بین آن‌ها می‌باشد و این موضوع سبب شده است مدل‌های شبکه عصبی ابزار قدرتمندی در مدل‌سازی محسوب گردند [۱۵]. انواع مختلفی از شبکه‌های عصبی مصنوعی در زمینه کاربردهای متفاوت معرفی شده‌اند که متداول‌ترین آن‌ها، پرسپترون چند لایه MLP می‌باشد. محققان متعددی در پژوهش‌های خود در بررسی فرایند خشک‌شدن محصولات کشاورزی از شبکه عصبی مصنوعی استفاده نمودند [۱۶-۱۸، ۳]. موقرنژاد و نیکزاد در

از بازار محلی قائمشهر خریداری و قبل از انجام آزمایش‌ها در یخچال در دمای 5°C نگهداری شد. پرتقال‌ها یک ساعت پیش از انجام آزمایش‌ها از یخچال خارج و در دمای محیط قرار گرفتند. بعد از شست‌وشو، توسط یک کاتر استیل به برش‌های نازک با ضخامت $1/5 \pm 0.1$ mm برش داده شدند. میزان رطوبت اولیه برش‌های پرتقال به روش وزن‌سنجی مطابق با روش استاندارد AOAC 2000 اندازه‌گیری شد [۲۱]. طبق این روش، نمونه‌ها در آون با دمای 105°C به مدت ۲۴ h تا رسیدن به وزن ثابت خشک‌شدند. این کار در سه تکرار انجام شد و میانگین رطوبت اولیه نمونه‌ها $1 \pm 0.83/22$ ٪ بر پایه مرطوب محاسبه گردید.

۲.۲. خشک کردن توسط هوای داغ

برای انجام آزمایش‌ها از خشک‌کن سینی‌دار مدل Uop8-A شرکت Armfield ساخت کشور انگلستان، موجود در آزمایشگاه عملیات واحد دانشگاه صنعتی نوشیروانی بابل استفاده شد که طرح‌واره این خشک‌کن در شکل (۱) نشان داده شده است. این خشک‌کن دارای سیستم‌های کنترل دما، سرعت هوا و ترازوی ثبت‌کننده وزن با دقت 0.01 ± 0.1 g می‌باشد که ترازو به رایانه متصل بوده و وزن نمونه‌ها طی فرایند خشک‌شدن با فاصله زمانی ۵ min ثبت گردید. جهت پایدار شدن شرایط عملیاتی سیستم، خشک‌کن به مدت زمان ۳۰ min پیش از شروع فرایند روشن گردید و پس از گذشت این زمان سینی توری حاوی نمونه‌های پرتقال در محفظه خشک‌کن قرار گرفت. وزن سینی و نمونه‌ها قبل از قرار دادن بر روی سینی توسط ترازوی دیجیتال با دقت 0.01 ± 0.1 g اندازه‌گیری شد. سپس نمونه‌های برش داده شده روی سینی دستگاه با فواصل مساوی چیده شدند، به طوری که یک لایه از نمونه‌ها بر روی سینی قرار گرفتند. دماهای مورد بررسی در سه سطح ۵۰، ۶۰ و 70°C و سرعت هوای ورودی در دو سطح ۱ و ۲ m/s در نظر گرفته شد. سرعت جابه‌جایی هوا در طول آزمایش‌ها، توسط دستگاه بادسنج دیجیتال مدل Anemometer, Lutron-YK, 80AM ساخت کشور تایوان، در خروجی جریان هوا از خشک‌کن اندازه‌گیری گردید. دما و رطوبت نسبی هوای محیط اطراف خشک‌کن از پارامترهای تأثیرگذار در خشک‌کردن مواد غذایی می‌باشند. از این رو پیش از انجام هر آزمایش دما و رطوبت نسبی هوای اطراف خشک‌کن به ترتیب با استفاده از دماسنج دیجیتالی مدل ATBIN


مدل‌سازی خشک‌کردن گوجه فرنگی [۴]، گنجه و همکارانش در خشک‌کردن پیاز [۱۹]، کریمی و همکارانش جهت مدل‌سازی خشک‌کردن موز [۲۰] و مجیدزاده و همکارانش جهت پیش‌بینی نسبت رطوبت کیوی [۱۶] از شبکه‌های عصبی مصنوعی استفاده نمودند. قادری و همکارانش در تحقیقی به مقایسه عملکرد مدل‌های ریاضی و شبکه عصبی مصنوعی در تخمین سینتیک خشک‌کردن قارچ در خشک‌کن مایکروویو-خلاء پرداختند [۳]. آن‌ها از شش مدل ریاضی برای برازش داده‌های آزمایشگاهی استفاده نمودند. هم‌چنین شبکه عصبی مصنوعی را با سه ورودی توان مایکروویو، فشار مطلق، زمان خشک‌شدن جهت تخمین نسبت رطوبت و نرخ خشک‌کردن آموزش دادند. نتایج بررسی حاکی از آن بود که در میان مدل‌های ریاضی مدل میدیلی بهترین برازش را با داده‌ها داشته است. اما مدل طراحی شده توسط شبکه عصبی مصنوعی توانایی بالاتری را در تخمین نسبت رطوبت و نرخ خشک‌کردن در مقایسه با مدل ریاضی نشان داد. هم‌چنین کاربرد شبکه عصبی مصنوعی در مدل‌سازی فرایند خشک‌کردن جوی سبز، توسط آقاجانی و همکارانش مورد بررسی قرار گرفت [۱۵]. آن‌ها از فرایند یادگیری پس انتشار خطا در آموزش شبکه با پارامترهای ورودی دما و زمان خشک‌کردن استفاده نمودند و نسبت رطوبت به‌عنوان خروجی شبکه در نظر گرفته شد. نتایج تخمین مدل شبکه عصبی نسبت به نتایج تخمین زده شده توسط مدل پیچ دقت بیش‌تری داشت.

بررسی منابع بیانگر آن است که تاکنون پژوهش‌های اندکی در زمینه فرایند خشک‌شدن پرتقال و مدل‌سازی آن صورت گرفته است. از این رو برای انجام گامی مؤثر در بهبود، بهینه‌سازی و پیش‌بینی شرایط خشک‌کردن پرتقال، در این پژوهش به مطالعه اثر شرایط عملیاتی خشک‌کن بر روی نسبت رطوبت برش‌های پرتقال پرداخته شد. هم‌چنین مدل‌سازی نسبت رطوبت ماده در طول فرایند خشک‌شدن توسط مدل‌های ریاضی و شبکه عصبی مصنوعی، صورت گرفت و عملکرد این دو مدل در پیش‌بینی نسبت رطوبت ماده حین فرایند خشک‌کردن مورد مقایسه قرار گرفت.

۲. مواد و روش‌ها

۱.۲. ماده اولیه و آماده‌سازی نمونه‌ها

در این پژوهش پرتقال رقم تامسون ناول Thompson Navel



شکل (۱) طرح‌واره خشک‌کن سینی‌دار مورد استفاده در آزمایش‌های خشک‌کردن پرتقال

Fig. 1 A schematic diagram of tray dryer for orange drying

M_e ، محتوای رطوبت تعادلی kg water/kg solid و M_0 محتوای رطوبت اولیه kg water/kg solid نمونه‌های پرتقال می‌باشند. اما با توجه به این‌که مقدار M_e در قیاس با مقدار M_0 و M_t عدد کوچکی است، می‌توان مقدار آن را نادیده گرفت و رابطه (۲) را در نظر گرفت [۳]:

$$MR = \frac{M_t}{M_0} \quad (2)$$

در طول این تحقیق از رابطه (۲) برای محاسبه نسبت رطوبت استفاده شده است. سپس از داده‌های حاصل از خشک‌کردن تحت شرایط مختلف عملیاتی جهت مدل‌سازی ریاضی و شبکه عصبی استفاده شد.

۱.۳.۲. مدل‌سازی ریاضی

داده‌های محاسبه شده برای نسبت رطوبت تحت شرایط عملیاتی مختلف با ۷ مدل ریاضی که در جدول (۱) گزارش شده است، برازش شدند [۴]. برای مدل‌سازی ریاضی و به‌دست آوردن پارامترهای مدل از جعبه ابزار متلب MATLAB R2013a و از روش رگرسیون خطی و غیرخطی استفاده شد.

۹۱۵۰۵۵، ساخت کشور ایران و رطوبت‌سنج دیجیتال مدل TESTO 635 با دقت ۰/۱٪، ساخت کشور کره، اندازه‌گیری گردید که محدوده میانگین تغییرات دمای محیط $27 \pm 1^\circ \text{C}$ و رطوبت نسبی هوا $14 \pm 2\%$ بوده است. خشک‌شدن تا زمان ثابت شدن تقریبی وزن برش‌های پرتقال ادامه داشت. همه آزمایش‌های خشک‌کردن پس از مدت زمان ۹۰۰ min متوقف گردید.

۲.۲. مدل‌سازی سینتیک خشک‌شدن پرتقال

جهت مدل‌سازی خشک‌شدن پرتقال با مدل‌های ریاضی و شبکه ریاضی از نسبت رطوبت طی فرایند خشک‌شدن استفاده شد. نسبت رطوبت نمونه‌ها در طول فرایند خشک‌کردن از رابطه (۱) محاسبه می‌گردد [۱۸]:

$$MR = \frac{M_t - M_e}{M_0 - M_e} \quad (1)$$

که در رابطه فوق MR ، نسبت رطوبت بدون بعد، M_t ، محتوای رطوبت در هر لحظه از فرایند خشک‌کردن kg water/kg solid

جدول (۱) مدل‌های ریاضی جهت مدل‌سازی فرایند خشک‌کردن پرتقال [۴].

Table 1 Drying kinetic models considered for thin layer drying of orange.

رابطه مدل Model Equation	نام مدل Model Name	ردیف No
$MR = \exp(-kt)$	نیوتن Newton	1
$MR = \exp(-kt^n)$	پیچ Page	2
$MR = a \exp(-kt)$	هندرسون و پابیس Henderson & pabis	3
$MR = a \exp(-kt) + c$	لگاریتمی Logarithmic	4
$MR = a \exp(-k_0 t) + b \exp(-k_1 t)$	دو جمله‌ای Two-term	5
$MR = 1 + at + bt^2$	وانگ و سینگ Wang and singh	6
$MR = a \exp(-kt) + (1-a) \exp(-kbt)$	نفوذ Diffusion	7

تابع آستانه، بایاس و وزن می‌باشد [۲۰]. آموزش شبکه عصبی در واقع تعیین وزن‌ها و بایاس‌ها در اتصالات بین نرون‌ها می‌باشد به‌صورتی که شبکه عصبی بتواند مقدار پارامتر خروجی را با دقت بسیار بالایی تقریب بزند [۱۴]. هر شبکه عصبی مصنوعی از لایه نرون‌های ورودی، لایه یا لایه‌های نرون‌های پنهان و لایه نرون‌های خروجی تشکیل می‌شود. توابع آستانه متعددی در شبکه‌های عصبی مصنوعی مورد استفاده قرار می‌گیرند که عمدتاً از تابع سیگموئیدی در لایه میانی و از تابع آستانه خطی در لایه خروجی استفاده می‌شود. یکی از متداول‌ترین الگوریتم‌های آموزش شبکه عصبی، الگوریتم پس انتشار خطا BP می‌باشد. که طی آموزش شبکه عصبی با این الگوریتم، وزن‌ها و بایاس‌ها در ابتدا به‌وسیله اعداد کوچک تصادفی بارگذاری و سپس در طول آموزش طبق قانون کلی کم‌ترین کاهش گرادیان تصحیح می‌گردند [۳]. شاخص اجرایی برای این الگوریتم میانگین مربع خطا MSE می‌باشد که طبق رابطه (۶) محاسبه می‌گردد [۱۹]:

$$MSE = \frac{\sum_{i=1}^N (MR_{pred,i} - MR_{exp,i})^2}{N} \quad (6)$$

در تحقیق حاضر از شبکه عصبی چند لایه پرسپترون، که به‌علت سادگی و کاربردهای موفقیت‌آمیزش در حل مسائل فنی-مهندسی عمومیت یافته، جهت پیش‌بینی نسبت رطوبت برش‌های پرتقال طی فرایند خشک‌کردن، استفاده گردید. از

ضریب تعیین R^2 یکی از معیارهای اصلی جهت انتخاب مدل مناسب بود. علاوه بر ضریب تعیین، جهت ارزیابی عملکرد مدل‌های ریاضی از دیگر شاخص‌های آماری نظیر ریشه میانگین مربع خطا RMSE و مجموع مربعات خطا SSE نیز استفاده گردید که مقادیر این پارامترهای آماری به‌ترتیب توسط رابطه‌های ۵-۳ محاسبه گردیدند [۱۸]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (MR_{exp,i} - MR_{pre,i})^2}{\sum_{i=1}^n (MR_{exp,i} - MR_{ave})^2} \quad (3)$$

$$RMSE = \left[\frac{\sum_{i=1}^N (MR_{pred,i} - MR_{exp,i})^2}{N} \right]^{\frac{1}{2}} \quad (4)$$

$$SSE = \sum_{i=1}^N (MR_{pre,i} - MR_{exp,i})^2 \quad (5)$$

که N در روابط فوق تعداد داده‌های آزمایشگاهی می‌باشد. مدل مناسب جهت توصیف سینتیک خشک‌شدن با هوای داغ برش‌های پرتقال، بر اساس بالاترین میزان ضریب تعیین و حداقل مقادیر RMSE و SSE انتخاب گردید.

۲.۳.۲. مدل‌سازی با شبکه عصبی مصنوعی چندلایه پرسپترون
شبکه عصبی مصنوعی از مجموعه‌ای از واحدهای سازنده به نام نرون یا گره شکل گرفته که هر نرون نیز شامل سه بخش اصلی

$$y_i = \text{tansig}(x_i) = \frac{\exp(x_i) - \exp(-x_i)}{\exp(x_i) + \exp(-x_i)} \quad (7)$$

$$y_i = \text{logsig}(x_i) = \frac{1}{1 + \exp(-x_i)} \quad (8)$$

۴.۲. آنالیز داده‌ها

آزمایش‌ها در سه تکرار انجام شدند. هم‌چنین میانگین و انحراف معیار داده‌ها تعیین گردیدند. آنالیز واریانس داده‌ها با استفاده از نرم‌افزار آنالیز آماری SPSS نسخه ۱۷ و مقایسه میانگین‌ها با آزمون دانکن انجام شد. اثر دماهای مختلف خشک‌کردن ۵۰، ۶۰ و ۷۰ °C و سرعت هوای ۱ و ۲ m/s بر نسبت رطوبت نیز مورد آنالیز قرار گرفت.

۴. نتایج و بحث


۴.۱. بررسی منحنی خشک‌شدن

برای بررسی سینتیک خشک شدن لایه نازک پرتقال، منحنی‌های نسبت رطوبت به‌ازای زمان خشک شدن در شرایط مختلف آزمایشگاهی مطابق شکل (۳) رسم گردید. هم‌چنین نتایج تجزیه واریانس تأثیر دما و سرعت جابه‌جایی هوا بر نسبت رطوبت نمونه‌های خشک شده در جدول (۲) گزارش شده است. این نتایج نشان می‌دهد که اثر اصلی دمای هوای خشک‌کن و سرعت جابه‌جایی هوا در سطح احتمال ۰/۰۵، $p < 0/05$ معنی‌دار بوده ولی اثر متقابل دوجانبه دمای خشک‌کن و سرعت جابه‌جایی هوا بر نسبت رطوبت معنی‌دار نمی‌باشد. همان‌طور که در شکل (۳) مشاهده می‌شود، نسبت رطوبت به‌صورت نمایی در زمان تقلیل یافت به‌عنوان مثال در سرعت جابه‌جایی هوای ۲ m/s و در دماهای ۵۰، ۶۰ و ۷۰ °C پس از گذشت ۲۰۰ min از زمان فرایند خشک‌شدن نسبت رطوبت نمونه‌ها به‌ترتیب حدود ۴۴، ۵۸ و ۶۵٪ کاهش یافت، در حالی‌که در زمان ۴۰۰ min در دماهای فوق، نسبت رطوبت نمونه‌ها به‌ترتیب حدود ۶۱، ۷۰ و ۸۵٪ تقلیل یافت که نتایج مشابه در دیگر تحقیق‌ها برای مواد خشک شده مختلف گزارش شده است (۳، ۹، ۱۹، ۲۰). نتایج آنالیز آماری نشان داد که در هر سرعت جابه‌جایی هوا، نسبت رطوبت در سه دمای متفاوت با هم اختلاف معنی‌دار آماری


قانون آموزش پس انتشار خطا برای آموزش شبکه مورد نظر استفاده شد. شبکه عصبی مورد نظر به‌صورت کدنویسی در محیط نرم افزار متلب MATLAB R2013a، ایجاد گردید. داده‌های حاصل از آزمایش‌های خشک‌کردن به‌صورت ماتریس‌های ورودی و خروجی در محیط متلب وارد شد. در واقع سه پارامتر شامل دما، سرعت جابه‌جایی هوا و زمان خشک‌کردن به‌عنوان ورودی و پارامتر نسبت رطوبت MR نمونه‌های پرتقال به‌عنوان خروجی، در نظر گرفته شد. یعنی یک شبکه عصبی با سه نرون در لایه ورودی و یک نرون در لایه خروجی طراحی گردید که طرح‌واره آن در شکل (۲) نشان داده شده است.

در مجموع ۳۵۴ داده از آزمایش‌های خشک‌کردن حاصل شد که جهت تشکیل ساختار شبکه عصبی از آن‌ها استفاده گردید. در ابتدا داده‌ها به‌صورت ماتریس‌های ورودی و خروجی دسته‌بندی و کدنویسی شدند. سپس به‌منظور پیش‌گیری از بیش‌برازش، داده‌ها به‌طور تصادفی به سه بخش، آموزش (۶۰٪ داده‌ها)، ارزیابی (۲۰٪ داده‌ها) و آزمون (۲۰٪ داده‌ها) تقسیم گردیدند. هم‌چنین به‌منظور افزایش سرعت هم‌گرایی و کارایی شبکه، داده‌ها نرمال‌سازی شدند، به‌طوری‌که داده‌ها در بازه [۰، ۱] قرار گرفتند.


به‌منظور تعیین مناسب‌ترین نوع الگوریتم، از الگوریتم‌های آموزش متفاوت لونبرگ-مارکوارت `trainlm`، پس انتشار ارتجاعی `trainrp`، آموزش با سرعت یادگیری متغیر `traingda` و آموزش دسته‌ای کاهش شیب `traingd` استفاده شد. به‌صورتی‌که هر شبکه عصبی با یک لایه پنهان دربردارنده ۲۵ نرون، با تعداد چرخه‌ی آموزشی ثابت ۴۰، تابع آستانه تانژانت هیپربولیک در لایه آستانه و تابع آستانه خطی در لایه خروجی، با یکی از الگوریتم‌ها آموزش داده شد و عملکرد شبکه جهت تعیین بهترین نوع الگوریتم بررسی گردید. هم‌چنین پس از تعیین الگوریتم مناسب، به‌منظور تعیین بهترین ساختار و توپولوژی، شبکه با ساختار یک لایه پنهان با تعداد نرون‌های مختلف بررسی شد. جهت انجام این بررسی‌ها، دو تابع آستانه تانژانت هیپربولیک و لگاریتم سیگموئید در لایه پنهان و تابع آستانه خطی در لایه‌ی خروجی مورد استفاده قرار گرفت. توابع تانژانت هیپربولیک و لگاریتم سیگموئید به‌ترتیب در روابط ۷ و ۸ تعریف شده‌اند [۱۷]:



شکل (۲) طرح‌واره شبکه عصبی چندلایه پرسپترون در کار حاضر
 Fig. 2 Schematic structure of Multi-layer perceptron neural network in this work



(a)



(b)

شکل (۳) تغییرات نسبت رطوبت به‌ازای زمان خشک‌شدن برش‌های پرتقال در دماهای مختلف و سرعت‌های (a) ۱/۰ متر بر ثانیه، (b) ۲/۰ متر بر ثانیه.

Fig. 3 Variation of moisture ratio against time at different temperature and air velocity a) 1.0 m/s and b) 2.0 m/s

جدول (۲) نتایج تجزیه واریانس نسبت رطوبت برش‌های پرتقال.

Table 2 The ANOVA results for moisture ratio of orange slices.

میانگین مربعات MSE	درجه آزادی Degree of freedom	منبع Source
0.0073*	1	Air temperature
0.0217*	2	Air velocity
0.0575 ^{ns}	2	Air Temperature×Air velocity
0.0018	24	Test Error

*، ** و ^{ns} به ترتیب معنی‌دار در سطوح ۱ و ۵٪ و بدن اختلاف معنی‌دار می‌باشد.

خشک‌شونده نیاز به انرژی کمی دارد که در مدت زمان کوتاه قابل تأمین می‌باشد. لیکن پس از تبخیر رطوبت سطحی نمونه‌ها، رطوبت درونی باید به سطح منتقل و تبخیر گردد که این پدیده انتقال نیاز به انرژی دارد. هرچه فاصله انتقال بیش‌تر، انرژی بیش‌تری مورد نیاز خواهد بود. به همین جهت سرعت خشک‌کردن کاهش می‌یابد [۱۰، ۱۳]. میانگین نسبت رطوبت برش‌های پرتقال خشک شده بر اساس دو عامل دما و سرعت جابه‌جایی هوای خشک‌کن توسط آزمون مقایسه میانگین چند دامنه‌ای دانکن مقایسه گردید که نتایج آن در جدول ۳ گزارش شده است. نتایج این جدول نشان می‌دهد دمای خشک‌کن تأثیر بیش‌تری نسبت به سرعت جابه‌جایی هوا بر روی نسبت رطوبت نهایی ماده خشک شده داشته به طوری که در دمای ۷۰ °C و سرعت جابه‌جایی هوای ۲ m/s، نسبت رطوبت نهایی ۶۱/۵٪ از دمای ۶۰ °C و ۷۱/۰۳٪ از دمای ۵۰ °C در همان سرعت جابه‌جایی هوا کم‌تر بوده است. هم‌چنین نسبت رطوبت در سرعت جابه‌جایی هوای ۲ m/s در دمای ۷۰ °C نسبت به سرعت جابه‌جایی هوای ۱ m/s در همان دما ۳۴/۵٪ کم‌تر بوده است.

۲.۳ مدل‌سازی ریاضی سینتیک خشک‌شدن

در جدول (۴) ضرایب و شاخص‌های ارزیابی حاصل از برازش نسبت‌های رطوبت آزمایشگاهی و ۷ مدل ریاضی شناخته شده سینتیک خشک کردن لایه نازک در سه سطح دمایی ۵۰، ۶۰ و ۷۰ °C و دو سرعت هوای ۱ و ۲ m/s ارائه شده است. نتایج حاکی از آن است که تمام مدل‌ها به جزء مدل وانگ-سینگ و نیوتن، با $R^2 > 0.95$ توصیف خوبی از فرایند خشک‌کردن داشتند. اگرچه در این میان، مدل پیچ با بالاترین مقدار ضریب تعیین و کم‌ترین مقدار ریشه میانگین مربع خطا و مجموع مربع خطا به‌عنوان بهترین مدل برای توصیف سینتیک خشک‌شدن لایه نازک پرتقال

داشته‌اند ($p < 0.05$). همان‌طور که شکل (۳) نشان می‌دهد با افزایش دمای هوای خشک کردن از ۵۰ به ۷۰ °C، به دلیل کاهش زمان خشک‌شدن، شیب منحنی‌های تغییرات نسبت رطوبت به زمان افزایش یافت. به‌عنوان مثال در سرعت جابه‌جایی هوای ۱ m/s زمان رسیدن به نسبت رطوبت ۵۰٪ برای نمونه‌ها، با افزایش دما از ۵۰ به ۷۰ °C از ۳۶۰ به ۱۸۰ min رسید. در واقع سرعت فرایند با افزایش دمای هوای خشک‌کن افزایش پیدا کرد. افزایش سرعت جابه‌جایی هوای خشک‌کن در دمای ثابت سبب کاهش بیش‌تر نسبت رطوبت در زمان کوتاه‌تر گردید. به‌عنوان نمونه، زمان رسیدن به نسبت رطوبت ۲۰٪ برش‌های پرتقال در سرعت جابه‌جایی هوای ۲ m/s در دمای ۷۰ °C نسبت به سرعت جابه‌جایی هوای ۱ m/s در همان دما حدوداً ۶۰ دقیقه کوتاه‌تر گردید. نتایج آنالیز آماری نیز نشان داد اثر سرعت هوای خشک کردن از ۱/۰ به ۲/۰ m/s بر نسبت رطوبت نیز معنی‌دار بود ($p < 0.05$). اما اثر آن در مقایسه با اثر دما ناچیزتر است. با توجه به شکل مشخص است که سرعت خشک‌شدن در اوایل فرایند بیش‌تر از اواخر فرایند می‌باشد. به بیان دیگر، با افزایش زمان خشک‌شدن و کاهش محتوای رطوبتی نمونه‌ها، شیب منحنی‌ها کاهش می‌یابد که نشان‌دهنده کاهش سرعت خشک‌شدن می‌باشد. همان‌طور که در شکل (۳) مشاهده می‌شود، در مدت زمان ۱۰۰ min اول فرایند خشک‌شدن، نسبت رطوبت حدود ۵۰٪ کاهش یافته است. این در حالی است که نسبت رطوبت در ۱۰۰ min بعد تنها حدود ۲۰٪ کاهش یافته است. نتایج مشابه این، در تحقیقات و مطالعاتی که سایر محققین در زمینه خشک‌کردن مواد غذایی انجام دادند نیز مشاهده شده است [۵، ۱۸، ۲۰]. آن‌ها نیز گزارش کردند که با کاهش نسبت رطوبت، سرعت خشک‌شدن کاهش می‌یابد. زیرا در زمان‌های نخستین فرایند، تبخیر رطوبت موجود بر روی سطح برش‌های ماده

جدول (۳) مقایسه میانگین نسبت رطوبت برش‌های پرتقال خشک‌شده در سرعت‌های جابه‌جایی و دماهای مختلف هوای خشک‌کن.

Table 3 Comparison of average moisture ratio of dried orange slices at different air velocity and temperature.

نسبت رطوبت Moisture ratio (%)	سرعت جابه‌جایی هوا Air convection velocity (m/s)	دمای هوا Temperature (°C)
21.8 ^a	1.0	50
18.3 ^b	2.0	
16.1 ^c	1.0	60
13.8 ^d	2.0	
8.1 ^e	1.0	70
5.3 ^f	2.0	

برای شبکه با ساختار ۱-۲۰-۳ با تابع آستانه تانژانت هیپربولیک در لایه پنهان $MSE=1/0.2 \times 10^{-6}$ ، به دست آمد. از این رو در مدل‌سازی سینتیک خشک‌کردن برش‌های پرتقال از شبکه عصبی با این ساختار استفاده گردید. نتایج این تحقیق با گزارشات سایر پژوهشگران در پیش‌بینی نسبت رطوبت در طول فرایند خشک‌شدن هم‌خوانی دارد [۴، ۱۹، ۲۰، ۲۳]. یوسفی و همکارانش نیز شبکه عصبی پس‌انتشار پیش‌خور با الگوریتم آموزش لونیگ-مارکوات با ساختارهای دارای یک لایه پنهان را مناسب‌ترین مدل شبکه عصبی خشک‌کردن پاپایا معرفی کردند [۲۴]. اسلام و همکارانش در مطالعه‌ای که بر روی مدل‌سازی خشک‌کردن لایه نازک برش‌های پرتقال انجام دادند از شبکه عصبی پس‌انتشار پیش‌خور با الگوریتم آموزش لونیگ-مارکوات استفاده نمودند و شبکه عصبی با ساختار یک لایه پنهان را به‌عنوان بهترین مدل عصبی معرفی نمودند [۲۵]. جهت تعیین میزان دقت مدل شبکه عصبی، داده‌های آزمایشگاهی و پیش‌بینی شده توسط شبکه عصبی پرسپترون چندلایه طراحی شده، در سه مرحله آموزش، ارزیابی و آزمایش مورد ارزیابی قرار گرفت که نتایج آن در جدول (۷) گزارش شده است. همان‌طور که نتایج نشان می‌دهد، ضریب تعیین بالا $R^2 > 0.9993$ و میانگین مربع خطای پایین $MSE < 1/16 \times 10^{-6}$ حاکی از کارایی بالای شبکه در پیش‌بینی داده‌های تجربی است.

علاوه بر محاسبه شاخص‌های ارزیابی، نمودار رگرسیون مربوط به داده‌های آزمایشگاهی و پیش‌بینی شده برای داده‌های آزمایش در شکل (۴) نیز نشان داده شده است. مطابق شکل، داده‌های پیش‌بینی شده انطباق بسیار خوبی با داده‌های آزمایشگاهی داشته و همه نقاط حول خط ۴۵ درجه با ضریب همبستگی $R^2 = 0.9994$ قرار گرفتند که این تأییدی بر عملکرد بالای شبکه می‌باشد.

معرفی می‌گردد. مقدار R^2 برای مدل پیچ تحت شرایط مختلف بیش از ۰/۹۹۸۸ محاسبه گردید. دامنه تغییرات R^2 بین ۰/۹۹۸۸ و ۰/۹۹۹۲، RMSE بین $10^{-3} \times 2/71$ و ۰/۰۰۷۳ و SSE بین $10^{-6} \times 4/16$ و ۰/۰۰۳۰ حاصل شد که سبب انتخاب آن به‌عنوان مناسب‌ترین مدل گردید. کوچک‌زاده و همکارش در مطالعه‌ای که بر روی سینتیک خشک‌شدن پسته انجام دادند، مدل پیچ را به‌عنوان بهترین مدل توصیف‌کننده نسبت رطوبت معرفی نمودند [۲۲]. هم‌چنین آکوی در مطالعه‌ای که بر روی سینتیک خشک‌کردن برش‌های انبه انجام داد، مدل‌های مختلف نیوتن، پیچ و هندرسون-پابیس را جهت برازش داده‌های آزمایشگاهی به‌کار برد که در میان آن‌ها مدل سینتیکی پیچ با تقریب خوبی توانست این فرایند را توصیف نماید [۶].

۳.۳. مدل‌سازی شبکه عصبی مصنوعی پرسپترون چندلایه سینتیک خشک‌شدن

جهت انتخاب الگوریتم آموزشی، شاخص ارزیابی MSE به‌عنوان معیار عملکرد شبکه در نظر گرفته شد که مقادیر آن برای شبکه‌های آموزش دیده با الگوریتم‌های مختلف در جدول (۵) گزارش گردیده است. همان‌طور که از نتایج برمی‌آید الگوریتم آموزش لونیگ-مارکوات trainlm عملکرد بهتری نسبت به سایر الگوریتم‌ها داشته و ضعیف‌ترین عملکرد مربوط به الگوریتم با سرعت یادگیری متغیر traingda بود.

به منظور تعیین مناسب‌ترین ساختار برای شبکه، تعداد نرون‌های مختلف در هر لایه بررسی شد. هم‌چنین از دو تابع آستانه در لایه پنهان استفاده گردید. شبکه با الگوریتم لونیگ-مارکوات آموزش داده شد و اثر پارامترهای فوق بر روی عملکرد شبکه بررسی گردید. نتایج به دست آمده در جدول (۶) درج گردیده است.

بر اساس معیار ارزیابی میانگین مربع خطا MSE، بهترین نتیجه

جدول (۴) ثوابت مدل‌های ریاضی به همراه نتایج آماری برازش مدل‌ها در شرایط متفاوت خشک‌کردن برش‌های پرتقال.

Table 4 Model constants along with statistical regression results at different drying condition of orange slices.

Air velocity (m/s)						Parameter پارامتر	Model Name نام مدل
سرعت هوا (m/s)							
70(°C)	2.0	60(°C)	50(°C)	70(°C)	1.0	50(°C)	
0.0063	0.0051	0.0031	0.0042	0.0034	0.0022	k	Newton نیوتن
0.9423	0.8478	0.8974	0.9663	0.9170	0.9478	R ²	
0.0627	0.0918	0.0760	0.0499	0.0709	0.0528	RMSE	
0.2284	0.4898	0.3356	0.1449	0.2918	0.1622	SSE	
0.0303	0.042	0.021	0.015	0.02	0.0099	k	Page پیج
0.6848	0.59	0.66	0.76	0.68	0.74	n	
0.9988	0.9992	0.9990	0.9991	0.9991	0.9992	R ²	
0.0073	2.81×10 ⁻³	2.81×10 ⁻³	2.81×10 ⁻³	3.03×10 ⁻³	2.71×10 ⁻³	RMSE	
0.0030	4.39×10 ⁻⁶	4.16×10 ⁻⁶	4.50×10 ⁻⁶	5.25×10 ⁻⁶	4.17×10 ⁻⁶	SSE	Henderson & pabis هندرسون و پابیس
0.8465	0.7961	0.8580	0.8997	0.8644	0.9122	a	
0.0048	0.0033	0.0023	0.0034	0.0026	0.0018	k	
0.9833	0.9557	0.9728	0.9887	0.9766	0.9860	R ²	
0.0340	0.0500	0.0394	0.0291	0.0379	0.0275	RMSE	Logarithmic لگاریتمی
0.0661	0.1427	0.0888	0.0484	0.0822	0.0433	SSE	
0.8152	0.7303	0.7655	0.8498	0.7712	0.7638	a	
0.0060	0.0056	0.0040	0.0045	0.0042	0.0029	k	
0.0624	0.1324	0.1659	0.0821	0.1427	0.1849	c	Two-term دو جمله‌ای
0.9920	0.9851	0.9927	0.9962	0.9934	0.9969	R ²	
0.0237	0.0292	0.0206	0.0170	0.0203	0.0131	RMSE	
0.0315	0.0478	0.0239	0.0163	0.0232	0.0097	SSE	
0.6434	0.5894	0.6815	0.7096	0.6810	0.7730	a	Wang and singh وانگ-سینگ
0.0034	0.0021	0.0017	0.0026	0.0019	0.0014	k ₀	
0.2997	0.3551	0.2826	0.2670	0.2852	0.2072	b	
0.0216	0.0204	0.0144	0.0147	0.0146	0.0109	k ₁	
0.9972	0.9976	0.9980	0.9987	0.9987	0.9987	R ²	Diffusion نفوذ
0.0122	0.0118	0.0035	0.0051	0.0071	0.0042	RMSE	
0.0082	0.0077	0.0031	0.0014	0.0028	0.0010	SSE	
-0.0033	-0.0030	-0.0027	-0.0030	-0.0028	-0.0021	a	
2.88×10 ⁻⁶	2.88×10 ⁻⁶	2.15×10 ⁻⁶	2.48×10 ⁻⁶	2.52×10 ⁻⁶	1.52×10 ⁻⁶	b	Diffusion نفوذ
0.7267	0.6789	0.8720	0.8991	0.8756	0.9541	R ²	
0.1378	0.1347	0.0857	0.0871	0.0875	0.0499	RMSE	
1.083	1.033	0.4188	0.4333	0.4373	0.1424	SSE	
0.2773	0.3676	0.2817	0.2537	0.2815	0.1995	a	Diffusion نفوذ
0.0423	0.0298	0.0203	0.0194	0.0203	0.0147	k	
0.0912	0.0785	0.0090	0.1421	0.1001	0.1027	b	
0.9969	0.9959	0.9981	0.9989	0.9984	0.9988	R ²	
0.0148	0.0154	0.0105	0.0070	0.0099	0.0062	RMSE	Diffusion نفوذ
0.0123	0.0133	0.0062	0.0027	0.0055	0.0022	SSE	

جدول (۵) مقایسه عملکرد الگوریتم‌های مختلف آموزش شبکه عصبی.

Table 5 Performance comparison of neural network training algorithms.

میانگین مربعات خطا MSE	نوع الگوریتم آموزش Training algorithm
2.12×10^{-6}	trainlm
3.11×10^{-5}	trainrp
5.22×10^{-4}	traingda
8.92×10^{-4}	traingd

جدول (۶) بررسی عملکرد ساختارهای مختلف شبکه عصبی.

Table 6 Performance evaluation of different types of artificial neural network structure.

میانگین مربع خطا MSE	تعداد نرون در لایه پنهان Number of hidden neurons	تابع آستانه لایه پنهان Activation function of hidden layer
1.18×10^{-4}	5	logsig
9.11×10^{-5}	7	logsig
7.52×10^{-5}	10	logsig
3.94×10^{-5}	12	logsig
2.17×10^{-5}	15	logsig
1.65×10^{-5}	20	logsig
2.68×10^{-5}	25	logsig
4.22×10^{-5}	30	logsig
9.92×10^{-6}	5	tansig
7.42×10^{-6}	7	tansig
4.12×10^{-6}	10	tansig
2.92×10^{-6}	12	tansig
1.85×10^{-6}	15	tansig
1.02×10^{-6}	20	tansig
2.12×10^{-6}	25	tansig
3.38×10^{-6}	30	tansig

جدول (۷) ارزیابی عملکرد شبکه عصبی طراحی شده برای داده‌های آموزش، ارزیابی و آزمایش.


Table 7 Performance evaluation of the developed ANN model for training, validation, testing data.

Data			Evaluation index
Testing	Validation	Training	
آزمایش	ارزیابی	آموزش	
0.9994	0.9993	0.9997	R^2
1.16×10^{-6}	3.62×10^{-6}	2.16×10^{-6}	MSE

ریاضی سینتیکی ریاضی در کار حاضر و مدل شبکه عصبی مصنوعی، از یک شاخص ارزیابی یکسان می‌بایست استفاده می‌شد. از این رو میزان ریشه میانگین مجذور خطای RMSE برای شبکه عصبی طراحی شده تحت شرایط بهینه محاسبه گردید که مقدار آن برابر 1.0×10^{-3} به دست آمد. نتایج به دست آمده نشان داد مدل شبکه عصبی چند لایه پرسپترون با ضریب تعیین

۴.۳. مقایسه عملکرد مدل سینتیکی و شبکه عصبی مصنوعی

بر اساس نتایج به دست آمده، مدل‌های ریاضی و شبکه عصبی مصنوعی، دارای توانایی تخمین و پیش‌بینی مقدار نسبت رطوبت برش‌های پرتقال در طول فرایند خشک‌شدن با دقت بالا، می‌باشند. جهت مقایسه عملکرد مدل پیچ به عنوان بهترین مدل



شکل (۴) مقایسه بین داده‌های آزمایشگاهی نسبت رطوبت و داده‌های پیش‌بینی شده توسط شبکه عصبی
 Fig. 4 Comparison between experimental data of moisture ratio and the predicted ones by ANN

هم‌چنین اثر سرعت جابه‌جایی و دمای هوای خشک‌کن در محدوده مورد مطالعه بر نسبت رطوبت در سطح ۰.۵٪ معنی‌دار ارزیابی شد ولی اثر متقابل دما و سرعت جابه‌جایی هوا معنی‌دار نشده است. نتایج حاصل از آزمایش‌ها جهت مدل‌سازی ریاضی، با ۷ مدل سینتیکی متداول برازش داده شد که از میان آن‌ها، مدل پیچ بر اساس بالاترین میزان ضریب تعیین بیش از ۰/۹۹۸۸ و کم‌ترین ریشه میانگین مربع خطا کم‌تر از ۰/۰۰۷۳ به‌عنوان مناسب‌ترین مدل توصیف‌کننده سینتیک خشک‌کردن برش‌های پرتقال انتخاب گردید. هم‌چنین چند شبکه عصبی سه لایه پرسپترون با الگوریتم آموزشی و توابع آستانه مختلف طراحی و عملکرد آن‌ها جهت تعیین مناسب‌ترین شبکه عصبی، ارزیابی شد. نتایج ارزیابی منجر به انتخاب شبکه عصبی چند لایه با یک لایه پنهان، ساختاری با سه ورودی، ۲۰ نرون در لایه پنهان و ۱ خروجی، با تابع آستانه تانژانت هیپربولیک و با الگوریتم آموزشی لونبرگ-مارکوات گشت. نتایج مقایسه عملکرد مدل پیچ و مدل شبکه عصبی در پیش‌بینی نسبت رطوبت برش‌های پرتقال در حین فرایند خشک‌شدن حاکی از آن است که می‌توان با اطمینان بیش‌تری به پیش‌بینی مدل شبکه عصبی اعتماد کرده و از آن برای بهینه‌سازی و کنترل فرایند استفاده نمود.

بالاتر $R^2=0/9994$ و ریشه میانگین مجذور خطای کم‌تر $1/009 \times 10^{-3}$ توانایی بالاتری نسبت به مدل ریاضی پیچ در پیش‌بینی نسبت رطوبت برش‌های پرتقال حین فرایند خشک‌شدن دارد. نتایج مشابه در تحقیقات پیشین در زمینه مقایسه عملکرد شبکه عصبی و مدل‌های ریاضی برای تخمین نسبت رطوبت در طول فرایند خشک‌شدن محصولاتی نظیر سیب، قارچ و لیمو ترش، گزارش شده است [۳، ۲۳، ۲۶]. علاوه بر این، مدل ریاضی تنها تغییرات نسبت رطوبت را به صورت تابعی از زمان ارائه می‌دهد و هرگز نمی‌تواند رابطه پیچیده غیرخطی میان متغیرهای ورودی و خروجی فرایند را مشخص کند. این در حالی است که مدل شبکه عصبی مصنوعی قادر است علاوه بر رابطه پیچیده غیرخطی بین متغیرهای ورودی و خروجی، تمامی برهمکنش‌های میان متغیرها را نیز درک نماید.

۴. نتیجه‌گیری

در این پژوهش، جهت مدل‌سازی فرایند خشک‌کردن پرتقال، نسبت رطوبت برش‌های پرتقال به ازای زمان در طول فرایند خشک‌کردن در یک خشک‌کن هوای داغ تحت شرایط مختلف دما و سرعت هوا، به‌طور آزمایشگاهی بررسی گردید. افزایش دما و سرعت جابه‌جایی هوا باعث افزایش سرعت خشک‌کردن گشت.

منابع

- [1] خوش تقاضا، م. ه.؛ تقی‌نژاد، ا. (۱۳۹۵). بررسی تأثیر پوشش نانو ذرات بر خواص انبارمانی پرتقال تامسون. *فصلنامه علوم و صنایع غذایی*، جلد ۱۳، شماره ۶۱، ص ۱۰۹-۱۲۱.
- [2] برزونی، ع.؛ آق‌خانی، م. ح.؛ مسکوک، ع.؛ عباسپور فرد، م. ح. (۱۳۹۲). اثر پیش تیمار حرارت و اسانس‌های گیاهی بر خواص پس از برداشت پرتقال خونی. *نشریه علوم باغبانی (علوم و صنایع کشاورزی)*، جلد ۲۷، شماره ۴، ص ۴۲۳-۴۱۸.
- [3] Ghaderi, A., Abbasi, S., Motevali, A., Minaei, S. (2012). Comparison of mathematical models and artificial neural networks for prediction of drying kinetics of mushroom in microwave-vacuum. *Chem. Ind. Chem. Eng. Q.*, 18, 283-293.
- [4] Movagharnejad, K., Nikzad, M. (2007). Modeling of tomato drying using artificial neural network. *Comput. Electron. Agric.*, 59, 78-85.
- [5] Nwakuba, N. R., Chukwuezie, O. C., Osuchukwu, L. C. (2017). Modeling of drying process and energy consumption of onion (*Ex-gidankwano Spp.*) slices in a hybrid crop dryer. *American J Eng Res.*, 6, 44-55.
- [6] Akoy, E. O. M. (2014). Experimental characterization and modeling of thin-layer drying of mango slices. *Int. Food. Res. J.*, 21, 1911-1917.
- [7] Aregbesola, O. A., Ogunsinaa, B. S., Sofolahana, A. E., Chimeb, N. N. (2015). Mathematical modeling of thin layer drying characteristics of dika (*Irvingiagabonensis*) nuts and kernels. *Nigerian. Food. J.*, 33, 83-89.
- [8] da Silva, W. P., e Silva, C. M.D.P.S., Gama, F. J.A., Gomes, J. P. (2014). Mathematical models to describe thin-layer drying and to determine drying rate of whole bananas. *J. Saudi. Soc. Agric. Sci.*, 13, 67-74.
- [9] Rayaguru, K., Routray, W. (2012). Mathematical modeling of thin layer drying kinetics of stone apple slices. *Int. Food. Res. J.*, 19, 1503-1510.
- [10] Onwude, D. I., Hashim, N., Janius, R. B., Nawi, N., Abdan, K. (2016). Evaluation of a suitable thin layer model for drying of pumpkin under forced air convection. *Int. Food. Res. J.*, 23, 1173-1181.
- [11] نایبندی آتشی، س.؛ مرتضوی، ع.؛ طباطبایی یزدی، ف.؛ محبی، م.؛ وریدی، م. ح. (۱۳۹۶). بهینه‌سازی فرایند آبیگری اسمزی و مدل‌سازی سینتیک انتقال جرم طی خشک‌کردن با هوای داغ گوشت شترمرغ. *فصلنامه فناوری‌های نوین غذایی*، جلد ۴، شماره ۱۵، ص ۶۵-۷۶.
- [12] Sonmete, M. H., Menteş, H. O., Ertekin, C., Özcan, M. M. (2017). Mathematical modeling of thin layer drying of carrot slices by forced convection. *J. Food. Meas. Charact.*, 11, 629-638.
- [13] Lutovska, M., Mitrevski, V., Pavkov, I., Mijakovski, V., Radojčin, M. (2016). Mathematical modeling of thin layer drying of pear. *Chem. Ind. Chem. Eng. Q.*, 22, 191-199.
- [14] آل‌حسینی، ع.؛ سرابی جماب، م.؛ قرآنی، ب.؛ کدخدایی، ر.؛ وان گساسولاک، س. (۱۳۹۶). بررسی کارایی شبکه‌های عصبی مصنوعی در پیش‌بینی تأثیر غلظت پلیمر و ولتاژ فرایند الکتروپاشش بر ویژگی‌های فیزیکی ذرات. *فصلنامه فناوری‌های نوین غذایی*، جلد ۴، شماره ۱۶، ص ۳۱-۴۳.
- [15] Aghajani, N., Kashaninejad, M., Deghani, A. A., Daraei Garmakhany, A. (2012). Comparison between artificial neural networks and mathematical models for moisture ratio estimation in two varieties of green malt. *Qual. Assur. Saf. Crop. Foods.*, 4, 93-101.
- [16] مجیدزاده، ح.؛ عمادی، ب.؛ فرزاد، ع. (۱۳۹۴). پیش‌بینی محتوی رطوبت میوه کیوی در خشک‌کن خلاء با استفاده از روش شبکه عصبی مصنوعی. *نشریه پژوهش‌های علوم و صنایع غذایی ایران*، جلد ۱۱، شماره ۱، ص ۱۰۷-۱۱۷.
- [17] Beigi, M., Torki Harchegani, M., Mahmoodi Eshkaftaki, M. (2017). Prediction of paddy drying kinetics: A comparative study between mathematical and artificial neural network modeling. *Chem. Ind. Chem. Eng. Q.*, 23, 251-258.
- [18] Abbaszadeh, A., Motevali, A., Khoshtaghaza, M. H., Kazemi, M. (2011). Evaluation of thin-layer drying models and neural network for describing drying kinetics of *Lasagnas angustifolia* L. *Int. Food. Res. J.*, 18, 1321-1328.
- [19] گنجه، م.؛ جعفری، م.؛ قنبری، و.؛ دزیانی، م.؛ عزتی، ر.؛ سلیمانی، م. (۱۳۹۱). مدل‌سازی سینتیک خشک‌کردن پیاز در یک خشک‌کن بستر سیال مجهز به کنترل‌کننده رطوبت با استفاده از روش‌های رگرسیونی، منطق فازی و شبکه‌های عصبی مصنوعی. *مجله علوم تغذیه و صنایع غذایی ایران*، جلد ۷، شماره ۵، ص ۳۹۹-۴۰۷.
- [20] کریمی، ف.؛ دهقان‌نیا، ج.؛ قنبرزاده، ب.؛ رفیعی، ش. (۱۳۹۱). مدل‌سازی خشک‌کردن لایه نازک موز و بهینه‌سازی فرایند توسط شبکه عصبی مصنوعی. *نشریه پژوهش‌های صنایع غذایی*، جلد ۲۲، شماره ۳، ص ۳۴۷-۳۴۸.
- [21] AOAC, (2000). Official Methods of Analysis Association of Official Analytical Chemists, 17th edn. In: Cunniff, P. (Ed.), Arlington, VA, USA, PP. 1-37.
- [22] Kouchakzadeh, A., Haghighi, K. (2011). Modeling



of vacuum-infrared drying of pistachios. *Agric. Eng. Int: CIGR. J.*, 13, 1-6.

[23] Karlovic, S., Bosiljkov, T., Brncic, M., Jezek, D., Tripalo, B., Dujmic, F., Dzineva, I., Skupnjak, A. (2013). Comparison of artificial neural network and mathematical models for drying of apple slices pretreated with high intensity ultrasound. *Bulg. J. Agric. Sci.*, 19, 1372-1377.

[24] Yousefi, A., Asadi, V., Nassiri, M., Niakousari, M., Khodabakhsh Aghdam, Sh. (2012). Comparison of Mathematical and Neural Network Models in the Estimation of Papaya Fruit Moisture Content. *Philipp Agric Sci.*, 95, 246-251.

[25] Islam, M. D. R., Sablani, S. S., Mujumdar, A. S., (2003). Artificial neural network model for prediction of drying rates. *J Dry Technol.*, 21, 1867-1884.

[۲۶] یوسفی، ع.؛ قاسمیان، ن.؛ سالاری، ا. (۱۳۹۶) مدل‌سازی سینتیک خشک‌کردن برش‌های لیموترش به روش تابش مادون قرمز با استفاده از شبکه‌های عصبی GMDH هیبریدی. *فصلنامه فناوری‌های نوین غذایی*، جلد ۵، شماره ۱، ص ۹۱-۱۰۵.