

مقاله پژوهشی

اندازه‌گیری و پیش‌بینی بازده مایکروبیو در حین خشک کردن برگه‌های سیب

ناهید عقیلی ناطق^{۱*} و محمد جعفر دالوند^۲

چکیده

خشک کردن یکی از مؤثرترین روش‌ها برای افزایش ماندگاری محصولات غذایی است. افزایش بازدهی و کاهش مصرف انرژی در خشک کردن ضروری است. صرفه‌جویی در زمان و انرژی بهترین مزایای روش خشک کردن مایکروبیو است. بنابراین هدف از این تحقیق بررسی تأثیر توان مایکروبیو (P)، جرم محصول (M) و زمان (T) بر انرژی جذب شده، اتلاف انرژی و همچنین پیش‌بینی بازده در حین خشک شدن برگه‌های سیب در مایکروبیو است. در این تحقیق توان‌های ۱۰۰، ۳۰۰ و ۶۰۰ وات مایکروبیو، جرم ۲۰، ۴۰، ۶۰، ۸۰ و ۱۰۰ گرم سیب و زمان ۶۰، ۹۰، ۱۲۰، ۱۵۰ و ۱۸۰ ثانیه در نظر گرفته شدند. در این مقاله، از سه روش مختلف هوش مصنوعی برای مدل‌سازی انرژی جذب شده و اتلاف انرژی سیب همراه با پیش‌بینی بازده مایکروبیو در طول فرآیند خشک کردن استفاده گردید. این روش‌ها عبارتند از: شبکه عصبی مصنوعی (ANN)، سامانه استنتاج فازی عصبی تطبیقی (ANFIS) و ماشین بردار پشتیبان (SVM) همراه با الگوریتم کرم شب تاب (FFA). نتایج نشان داد که مقدار انرژی جذب شده توسط سیب در طول خشک کردن در مایکروبیو به مقدار زیادی به مقدار جرم بستگی دارد. بیشترین و کمترین بازده مایکروبیو به ترتیب در توان ۶۰۰ وات و جرم ۱۰۰ گرم و کمترین بازده در زمان ۱۸۰ ثانیه و توان ۱۰۰ وات مشاهده گردید. همچنین، انرژی جذب شده در ۶۰۰ وات تقریباً چهار برابر بیشتر از آن در ۱۰۰ وات بود. سامانه عصبی-فازی و ماشین بردار پشتیبان نتایج خوبی نسبت به شبکه عصبی مصنوعی برای پیش‌بینی انرژی جذب شده، اتلاف انرژی و بازده مایکروبیو نشان دادند.

واژه‌های کلیدی: مایکروبیو، بهره‌وری، شبکه عصبی مصنوعی، سامانه استنتاج فازی عصبی تطبیقی، ماشین بردار پشتیبان، سیب، خشک کردن.

ارجاع: عقیلی ناطق ن. و دالوند م. ج. ۱۴۰۲. اندازه‌گیری و پیش‌بینی بازده مایکروبیو در حین خشک کردن برگه‌های سیب. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۲۸: ۲۱-۱۱. <https://dx.doi.org/10.22034/JRMAM.2023.14009.607>

۱- استادیار گروه ماشین‌های کشاورزی، دانشکده کشاورزی سنقر، دانشگاه رازی، کرمانشاه.

۲- دانش‌آموخته دکترا ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تهران، کرج.

*نویسنده مسئول: n.aghili@razi.ac.ir

تاریخ پذیرش: ۱۴۰۱/۱۱/۰۳

تاریخ دریافت: ۱۴۰۱/۰۷/۲۶

مقدمه

برخی از محققان در این حوزه با موفقیت از سامانه استنتاج عصبی فازی تطبیقی برای بهبود نتایج خود استفاده کرده‌اند (Kişi & Öztürk, 2007; Landeras *et al.*, 2013; Shiri *et al.*, 2012). با این حال، شبکه عصبی مصنوعی و سامانه استنتاج عصبی فازی تطبیقی عیوبی مانند برازش بیش از حد، همگرایی آهسته، عملکرد تعمیم ضعیف و رسیدن به کمینه محلی را دارند. در نتیجه، روش‌های دیگری برای پیش‌بینی دقیق‌تر مورد نیاز است. ماشین‌های بردار پشتیبان (SVM) با الگوریتم کرم شبتاب گروهی از روش‌های یادگیری تحت نظارت (همچنین به عنوان رگرسیون بردار پشتیبان یا SVR شناخته می‌شوند) است که به عنوان ابزارهای مهم برای کاربردهای محیطی ظاهر شده‌اند (Ornella and Tapia, 2010; Jain *et al.*, 2009). بنابراین، تحقیق حاضر با اهداف محاسبه انرژی جذب شده و تلف شده امواج مایکروویو در حین خشک کردن برگه‌های سیب در توان‌ها، جرم‌ها و زمان‌های مختلف تابش امواج مایکروویو و بررسی توانایی روش‌های تحلیل و ارزیابی با هوش مصنوعی (ماشین بردار پشتیبان با الگوریتم کرم شب تاب، شبکه عصبی مصنوعی و سامانه استنتاج عصبی فازی تطبیقی) در پیش‌بینی بازده مایکروویو انجام شد.

مواد و روش‌ها

سامانه مایکروویو

از یک اجاق مایکروویو خانگی ۲۴۶۵ مگاهرتز (Samsung, OM75P؛ Samsung Electronics Inc, Japan) اصلاح شده و توسعه یافته با توان اسمی ۱۱۰۰ وات و ابعاد اتاقک ۳۰۰ (عرض) × ۳۸۰ (عمق) × ۲۶۰ (ارتفاع) میلی‌متر استفاده گردید. دستگاه مایکروویو مجهز به مگنترون ولتاژ بالا، ترانسفورماتور، یک‌سو کننده و همچنین خازن ولتاژ بالا بود. کنترل دوره‌ای (روشن/خاموش) منبع تغذیه توسط یک کنترل‌کننده زمان انجام می‌شد تا توان را در ۱۰۰٪ یا ۰٪ در طول چرخه‌های روشن و خاموش نگه دارد. مدت زمان چرخه‌های ON و OFF بر حسب ثانیه بود.

روش آزمایش

آزمایش‌ها در سه تکرار و با جرم‌های ۲۰، ۴۰، ۶۰، ۸۰ و ۱۰۰ گرم، توان ۱۰۰، ۳۰۰ و ۶۰۰ وات و زمان ۶۰، ۹۰،

خشک کردن یکی از مؤثرترین روش‌ها برای افزایش ماندگاری محصولات غذایی است. تحقیقات فراوانی در زمینه خشک کردن میوه‌ها و سبزیجات در مایکروویو انجام شده است (Maskan, 2000; Torringa *et al.*, 2001; Soysal, 2004). مایکروویو با تغییر میدان الکترومغناطیسی، در مواد حرارت حجمی سریعی ایجاد می‌کند (Datta, 2001). صرفه جویی در زمان و انرژی بهترین مزایای روش خشک کردن مایکروویو است (Balbay *et al.*, 2012; Darvishi *et al.*, 2013; Kahyaoglu *et al.*, 2012). مقدار انرژی مورد استفاده برای فرآیند خشک کردن و گرمایش برای فرآیندهای تولید در بخش‌های صنعتی و خانگی مهم است. انرژی از آنجایی که نقش اساسی در زندگی انسان ایفا می‌کند به عنوان یک عامل مهم در نظر گرفته می‌شود. افزایش جمعیت و استانداردهای زندگی باعث افزایش مصرف انرژی شده است. بازده انرژی در خشک کردن به عوامل زیادی از جمله فناوری‌های به کار رفته در سامانه‌های خشک کردن، سطح تولید و غیره بستگی دارد. افزایش بازدهی و کاهش مصرف انرژی در خشک کردن ضروری است. بسیاری از محققان میزان مصرف انرژی را در روش خشک کردن به شیوه مایکروویو را مطالعه کرده‌اند (Jindarat *et al.*, 2011; Sharma & Prasad, 2006).

از طرفی امروزه پیش‌بینی انرژی مصرفی به کمک ابزارهای هوش مصنوعی در حوزه صنایع غذایی انجام می‌گردد تا شاید بتوان با توسعه مدل‌هایی جهت پیش‌بینی انرژی مصرفی، نیاز به انجام آزمایشات متعدد که مستلزم صرف وقت و هزینه یاست، کاهش یابد (Momenzadeh, 2012). استفاده از شبکه عصبی مصنوعی (ANN) در حوزه مواد غذایی، راه مؤثری برای حل سه مشکل پیچیدگی، غیرخطی بودن و عدم قطعیت یاست. شبکه عصبی مصنوعی در مقایسه با سایر مدل‌های تجربی حساسیت کمتری به نویز دارد (Sander *et al.*, 2003). سامانه استنتاج عصبی فازی تطبیقی (ANFIS)، ترکیبی از شبکه عصبی مصنوعی و سامانه فازی است و مزایای هر دو سامانه را دارد (Naderloo *et al.*, 2012). سامانه استنتاج عصبی فازی تطبیقی می‌تواند برای روابط پیچیده و غیر خطی بین داده‌های ورودی و خروجی با روش یادگیری ترکیبی استفاده شود (Ho & Tsai, 2011).

که در آن L گرمای نهان آب در طول تبخیر (۲۴۳۷ کیلوژول بر کیلوگرم) است. بنابراین، مجموع توان جذب شده امواج میکروویو بر اساس مجموع گرمای محسوس ماده خشک و محتوای آب در نمونه‌های محصول محاسبه شد (Clary *et al.*, 2005).

$$P_{abs} = Q_p + Q_d + E_w \quad (۸)$$

برای محاسبه بازدهی میکروویو معادله (۴) را می‌توان به صورت $\eta = (Q_p + Q_d + E_w) P_{in}$ بازنویسی نمود.

با توجه به تحقیقات پیشین و شرایط آزمایش، C_d و C_w برای سیب و آب به ترتیب $۴/۰۲۷$ و $۴/۲$ کیلو ژول بر کیلوگرم درجه سلسیوس هستند (Oliveira *et al.*, 2012).

تحلیل داده‌ها

محاسبه و مدل‌سازی توان جذب شده، توان تلف شده و بازده میکروویو با استفاده از آزمایش عاملی بر پایه طرح کامل تصادفی در سه تکرار با در نظر گرفتن سه عامل جرم (۲۰، ۴۰، ۶۰، ۸۰ و ۱۰۰ گرم)، زمان (۶۰، ۹۰، ۱۲۰، ۱۵۰ و ۱۸۰ ثانیه) و توان (۱۰۰، ۳۰۰ و ۶۰۰ وات) انجام گردید. تمامی داده‌ها با استفاده از نرم‌افزار SAS 9.4 تجزیه و تحلیل گردیدند. اثرات عامل‌ها بر انرژی جذب شده، اتلاف انرژی و بازدهی توسط حداقل تفاوت معنی‌دار (LSD) در سطح احتمال ۵ درصد انجام شد.

مدل‌سازی شبکه عصبی مصنوعی

در ساختار مدل شبکه عصبی مصنوعی سه گروه نورون وجود دارد. ورودی، مخفی و خروجی که در لایه‌های ورودی، مخفی و خروجی قرار می‌گیرند. لایه‌ها با یک تابع انتقال متصل می‌شوند. در روش انتشار برگشتی، ورودی‌ها و خروجی‌ها با تنظیم وزن‌ها و بایاس‌ها به یکدیگر مرتبط می‌شوند، به گونه‌ای که خطای پیش‌بینی به حداقل می‌رسد. طراحی سامانه مستلزم انتخاب توابع انتقال لایه پنهان و خروجی، الگوریتم آموزشی، تعداد نرون‌ها در لایه پنهان و انتخاب معیارهای عملکرد است (Zhang *et al.*, 1998). در این تحقیق از شبکه عصبی پس انتشار خطا سه لایه استفاده شد (شکل ۱). شبکه عصبی مصنوعی دارای سه ورودی با داده‌های نرمال شده یعنی جرم، زمان و توان ورودی و لایه خروجی دارای سه نورون برای پیش‌بینی بازده، انرژی جذب شده و اتلاف انرژی بود. توابع انتقال تانژانت هذلولی (tansig) و خطی (purelin)

۱۲۰، ۱۵۰ و ۱۸۰ ثانیه انجام شد. پس از تهیه نمونه‌ها، دمای اولیه آن‌ها توسط دماسنج مادون قرمز اندازه‌گیری شد. وزن برش‌های سیب با ترازوی دیجیتال با دقت $۰/۰۱$ گرم اندازه‌گیری شد و نمونه‌ها به خشک‌کن منتقل شدند. توان دستگاه با توجه به تیمار آزمایشی تنظیم شد و سپس تشعشعات میکروویو برای دوره‌های تعیین شده (زمان‌ها) به نمونه‌ها اعمال گردید. پس از اتمام دوره آزمایش، نمونه‌ها بلافاصله از میکروویو خارج شده و دما و وزن آن‌ها اندازه‌گیری شد.

محاسبه انرژی جذب شده توسط سیب

امواج میکروویو که به محصول برخورد می‌کند می‌تواند از طریق محصول منتقل شود و همچنین توسط محصول منعکس یا جذب شود. توان موج ورودی میکروویو را می‌توان به صورت زیر بیان کرد:

$$P_{in} = P_{abs} + P_{tran} + P_{ref} \quad (۱)$$

جایی که P_{in} توان امواج میکروویو، P_{ref} توان منعکس شده P_{tran} توان گذر کرده و P_{abs} توان جذب شده امواج میکروویو است. برای محاسبه توان جذب شده و تلفات توان، معادله (۱) را می‌توان به صورت زیر مرتب کرد:

$$P_{abs} = P_{in} - P_{tran} - P_{ref} \quad (۲)$$

$$P_{loss} = P_{tran} + P_{ref} \quad (۳)$$

بازدهی جذب انرژی در طول خشک کردن با میکروویو معیار صحیحی را از عملکرد سامانه خشک کردن ارائه می‌دهد که می‌تواند به صورت زیر بیان شود (Jindarat *et al.*, 2011).

$$\eta_{abs} = \text{Absorbed Wave/Incident Wave} = P_{abs}/P_{in} \quad (۴)$$

برای تعیین روشی برای پیش‌بینی انرژی جذب شده توسط تکه‌های سیب بر اساس خواص میوه، گرمای محسوس آب (Q_p , kJ) و ماده خشک (Q_d , kJ) نمونه‌ها به صورت زیر محاسبه می‌شود:

$$Q_p = M_w C_w \Delta T \quad (۵)$$

$$Q_d = M_d C_d \Delta T \quad (۶)$$

که در آن C_w و C_d به ترتیب گرمای ویژه محصول و آب هستند، M_d ($\text{kJ/kg } ^\circ\text{C}$) و M_w به ترتیب ماده خشک (kg) و محتوای آب در محصول (kg) هستند. گرمای نهان آب (kJ , E_w) حذف شده از یک محصول (kg , W_r) را می‌توان به صورت زیر تعیین کرد:

$$E_w = W_r L \quad (۷)$$

با تابع هسته شعاعی (RBF) استفاده شد. تابع هسته برای تبدیل داده‌ها به فضای ابعاد بالاتر به کار می‌رود. همچنین دقت پیش‌بینی‌های با استفاده از تابع هسته شعاعی به انتخاب صحیح سه عامل (ϵ, σ, C) بستگی دارد. در این تحقیق از الگوریتم بهینه‌سازی کرم شبتاب برای تخمین این پارامترها استفاده شده است. تحقیقات نشان داده است که الگوریتم کرم شبتاب در یافتن بهینه محلی و عمومی در مقایسه با سایر الگوریتم‌های بهینه‌سازی الهام گرفته شده از بیولوژیک کارآمدتر است (Fister et al., 2013; Pal et al., 2012; Yang, 2013).

ارزیابی عملکرد مدل‌ها

برای ارزیابی موفقیت مدل‌های ANN، ANFIS و SVM-FFA، دو شاخص آماری زیر مورد استفاده قرار گرفتند:

(۱) ریشه میانگین مربع خطا (RMSE) (معادله (۱۰))

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}}, \quad (10)$$

که در آن O_i و P_i به ترتیب به عنوان مقادیر آزمایشی و پیش‌بینی شناخته می‌شوند و n تعداد کل داده‌های آزمون است و R^2 ضریب تعیین (معادله (۱۱))

$$R^2 = 1 - \frac{\sum_{i=1}^n [P_i - O_i]^2}{\sum_{i=1}^n P_i^2} \quad (11)$$

نتایج و بحث

تجزیه و تحلیل میزان حساسیت

سه عامل مؤثر بر بازدهی مایکروبیو شامل توان، زمان و جرم به متغیرهای فرعی و اصلی تقسیم شدند. داده‌های خام با استفاده از شبیه‌سازی ANN با حساسیت مورد تجزیه و تحلیل قرار گرفتند. همانطور که در شکل ۱ نشان داده شده است، جرم، به دنبال آن توان بالاترین حساسیت را روی بازده دارند.

اثر تغییرات جرم، زمان و توان بر بازده

انرژی جذب شده و اتلاف انرژی به طور قابل توجهی تحت تأثیر جرم، توان و زمان محصول قرار گرفتند ($P < 0.01$) (جدول ۱). بیشترین و کمترین بازده مایکروبیو به ترتیب در توان ۶۰۰ وات و جرم ۱۰۰ گرم و کمترین بازده در زمان ۱۸۰ ثانیه و توان ۱۰۰ وات مشاهده گردید (جدول ۲). با افزایش توان، زمان و جرم، انرژی جذب شده افزایش یافت. این ممکن است به دلیل افزایش مولکول‌های آب دوقطبی در توان‌های مایکروبیو بالاتر


به ترتیب در نوروهای لایه پنهان و خروجی استفاده شد. برای آموزش شبکه از الگوریتم آموزشی Levenberg-Marquardt استفاده شد. میانگین مربعات خطا (MSE) به عنوان تابع عملکرد برای یافتن معماری بهینه برای شبکه عصبی استفاده شد. برای آموزش شبکه، تعداد نوروهای مختلف در لایه پنهان و MSE مورد آزمایش قرار گرفت. در این تحقیق از 10^{-8} MSE، حداقل گرادینان 10^{-10} و حداکثر تکرار ۱۰۰۰ استفاده گردید. وزن‌ها و بایاس‌های اولیه شبکه با استفاده از تابع netint توسط برنامه ایجاد شد. مقادیر نرخ یادگیری و ضریب حرکت به ترتیب ۰/۰۲ و ۰/۹ بود. بهترین تعداد نوروها برای لایه پنهان با سعی و خطا انتخاب شدند. داده‌ها به دو زیر مجموعه تقسیم شدند: ۷۵ درصد برای آموزش و ۲۵ درصد باقیمانده برای آزمون استفاده شد.

مدل‌سازی سامانه استنتاج عصبی - فازی

سامانه استنتاج عصبی - فازی یک شبکه پنج لایه است که برای نگاشت فضای ورودی به فضای خروجی با استفاده از ترکیبی از الگوریتم‌های یادگیری شبکه عصبی و قوانین فازی استفاده می‌شود (Turkmen, 2011). برای یافتن بهترین شبکه سامانه استنتاج عصبی - فازی تصمیمات لازم مانند تعداد توابع عضویت، انواع توابع عضویت، روش‌های بهینه‌سازی و همچنین تعداد تکرارها مورد نیاز است. در این مطالعه الگوریتم یادگیری ترکیبی برای تعریف رابطه بین متغیرهای ورودی و خروجی انتخاب شد. انواع مختلفی از توابع عضویت مانند مثلثی، دوزنقه‌ای، زنگی شکل، گوسی و سیگموئید برای تولید بهترین شبکه سامانه استنتاج عصبی - فازی مورد بررسی قرار گرفت. توابع عضویت خطی برای خروجی توابع عضویت استفاده گردید.

ماشین بردار پشتیبان

ماشین بردار پشتیبان بر روی استاندارد روش یادگیری ماشینی قابل اندازه‌گیری و به حداقل رساندن خطر ساختاری متمرکز است، که کران بالایی خطای تعمیم را به جای خطای آماده‌سازی همسایگی، که رویکرد معمولی در دیگر روش‌های یادگیری ماشینی مرسوم است، به حداقل می‌رساند (Vapnik, 1998). ماشین بردار پشتیبان



شکل ۱- تجزیه و تحلیل حساسیت عوامل تأثیرگذار بر بازده تخمینی میکروبیو

مرتبط باشد که منجر به جذب انرژی بیشتر از امواج میکروویو می‌گردد. این پدیده به نوبه خود منجر به افزایش دمای نمونه‌ها می‌شود (Motevali *et al.*, 2011b). افزایش جرم و توان منجر به بازدهی بالا شد، در حالی که با افزایش زمان بازدهی کاهش یافت.

اثرات متقابل توان×جرم و زمان×توان بر بازده، معنی‌دار بود، در حالی که اثر زمان×جرم بی‌معنا بود. مقدار انرژی جذب شده در ۶۰۰ وات تقریباً چهار برابر بیشتر از ۱۰۰ وات بود. نتایج مشابهی توسط چندین محقق برای سایر محصولات گزارش شده است (Motevali *et al.*, 2011a; Sami *et al.*, 2011).

جدول ۱- نتایج خلاصه ANOVA اصلی

عامل	درجه آزادی	میانگین مربعات	
		انرژی تلف شده	انرژی جذب شده
جرم	۴	۲۴۸۰۶۳۳۹۸***	۲۴۸۰۶۳۳۹۸***
توان	۲	۳۳۹۷۸۶۵۰۵۲***	۳۵۹۲۳۱۱۸۲۹***
زمان	۴	۱۰۱۴۶۸۸۸۵۳***	۴۰۴۷۷۴۹۲۳***
توان×جرم	۸	۸۱۸۵۰۸۵۷***	۸۱۸۵۰۸۵۷***
زمان×جرم	۱۶	۲۵۳۹۵۰۰ ^{ns}	۲۵۳۹۵۰۰ ^{ns}
زمان×توان	۸	۹۲۷۰۸۶۳۲***	۱۷۰۸۴۳۵۳۹***
زمان×توان×جرم	۳۲	۳۲۴۴۰۹۵ ^{ns}	۳۲۴۴۰۹۵ ^{ns}
خطا	۱۵۰	۱۹۰۲۵۳۷۵۷	۳۵۲۳۲۱۸



جدول ۲- اثرات متقابل توان - زمان و توان - جرم بر بازده میکروبیو

میانگین بازده میکروبیو	عامل		میانگین بازده میکروبیو	عامل	
	توان	زمان		توان	جرم
۰/۱۱ ^g	۱۰۰	۶۰	۰/۰۶ ⁱ	۱۰۰	۲۰
۰/۴۳ ^e	۳۰۰		۰/۳۳ ^f	۳۰۰	
۰/۴۶ ^a	۶۰۰		۰/۳۳ ^f	۶۰۰	
۰/۰۶ ^h	۱۰۰	۹۰	۰/۰۷ ^h	۱۰۰	۴۰
۰/۴۳ ^e	۳۰۰		۰/۴۳ ^d	۳۰۰	
۰/۴۴ ^e	۶۰۰		۰/۴۳ ^d	۶۰۰	
۰/۰۴ ⁱ	۱۰۰	۱۲۰	۰/۰۸ ^g	۱۰۰	۶۰
۰/۴ ^f	۳۰۰		۰/۵۵ ^b	۳۰۰	
۰/۴۴ ^e	۶۰۰		۰/۵۶ ^b	۶۰۰	
۰/۰۳ ^j	۱۰۰	۱۵۰	۰/۰۹ ^j	۱۰۰	۸۰
۰/۴ ^f	۳۰۰		۰/۶۴ ^k	۳۰۰	
۰/۴۴ ^e	۶۰۰		۰/۶۸ ^l	۶۰۰	
۰/۰۱ ^k	۱۰۰	۱۸۰	۰/۱ ^m	۱۰۰	۱۰۰
۰/۳۶ ^l	۳۰۰		۰/۷۶ ⁿ	۳۰۰	
۰/۳۹ ^m	۶۰۰		۰/۷۹ ^o	۶۰۰	


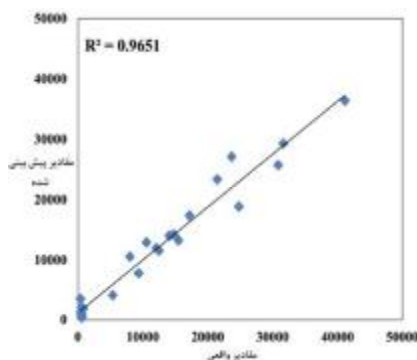
شبکه عصبی مصنوعی پیش‌بینی نگریدید، در حالی‌که انرژی جذب شده و اتلاف انرژی با دقت بالا پیش‌بینی شدند.

جدول ۳- عملکرد شبکه عصبی مصنوعی برای اتلاف انرژی، انرژی جذب شده و بازده مایکروبیو بر اساس شاخص‌های آماری مختلف

مختلف	RMSE	R ²	آموزش	انرژی تلف شده
	۱۷۳۵/۸۸	۰/۹۶۱	آموزش	
	۱۳۳۷/۴۶	۰/۹۷۲	آزمون	
	۲۰۰۷/۳	۰/۹۴۳	آموزش	انرژی جذب شده
	۱۷۴۳/۴۳	۰/۹۷۶	آزمون	
	۰/۰۵	۰/۷۶۲	آموزش	بازده مایکروبیو
	۰/۰۹۲	۰/۸۲۳	آزمون	



شکل ۲- نمودارهای مقادیر پیش‌بینی شده اتلاف انرژی با استفاده از مدل شبکه عصبی مصنوعی برای (الف) داده‌های آموزش و (ب) داده‌های آزمون



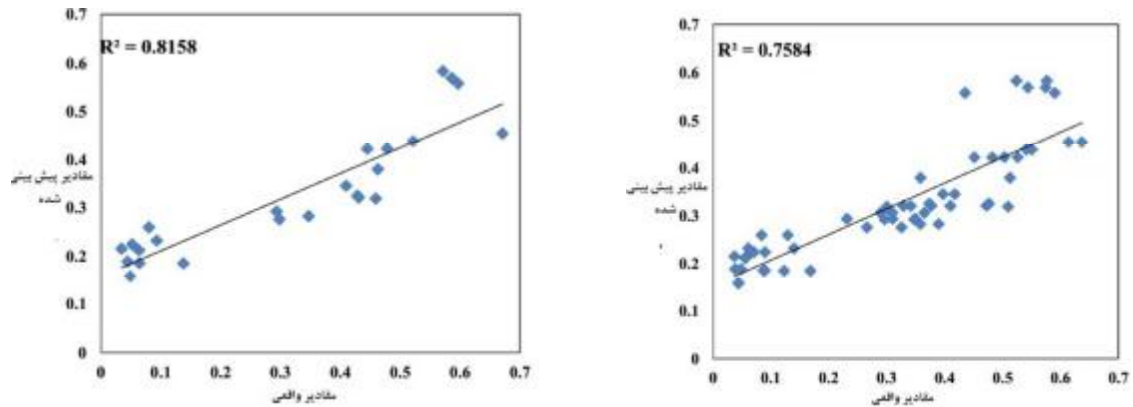
شکل ۳- نمودارهای مقادیر پیش‌بینی شده انرژی جذب شده با استفاده از مدل شبکه عصبی مصنوعی برای (الف) داده‌های آموزش و (ب) داده‌های آزمون

اتلاف انرژی، انرژی جذب شده و بازدهی مایکروبیو توسط سامانه عصبی-فازی در شکل‌های ۵، ۶ و ۷ نشان داده شده است. همان‌طور که در این شکل‌ها مشاهده می‌گردد، نتایج پیش‌بینی اتلاف انرژی و انرژی جذب شده بهتر از بازدهی مایکروبیو است.

پیش‌بینی بازده با استفاده از شبکه عصبی مصنوعی، سامانه استنتاج عصبی-فازی تطبیقی و ماشین بردار پشتیبان

به منظور به حداقل رساندن زمان آموزش شبکه عصبی مصنوعی، تنها یک لایه پنهان در نظر گرفته شد. با این پیکربندی، بهترین شبکه با توپولوژی ۳-۷-۱ پیدا شد، یعنی شبکه‌ای که ۷ نورون در لایه پنهان دارد. مقادیر R² و RMSE برای بهترین مدل شبکه عصبی مصنوعی در جدول ۳ نشان داده شده است. شکل‌های ۲، ۳ و ۴ عملکرد بهترین ساختار شبکه عصبی مصنوعی را برای پیش‌بینی تلفات انرژی، انرژی جذب شده و بازدهی مایکروبیو نشان می‌دهند. بازده مایکروبیو به درستی توسط


ویژگی‌های بهترین ساختار سامانه عصبی-فازی در جدول ۴ خلاصه شده است. همان‌طور که در این شکل مشاهده می‌شود، تابع عضویت Gbell بهترین نتایج را به همراه داشت. تعداد توابع عضویت ورودی بر اساس تعداد ورودی به هر سامانه عصبی-فازی تعیین شد. نتایج پیش‌بینی



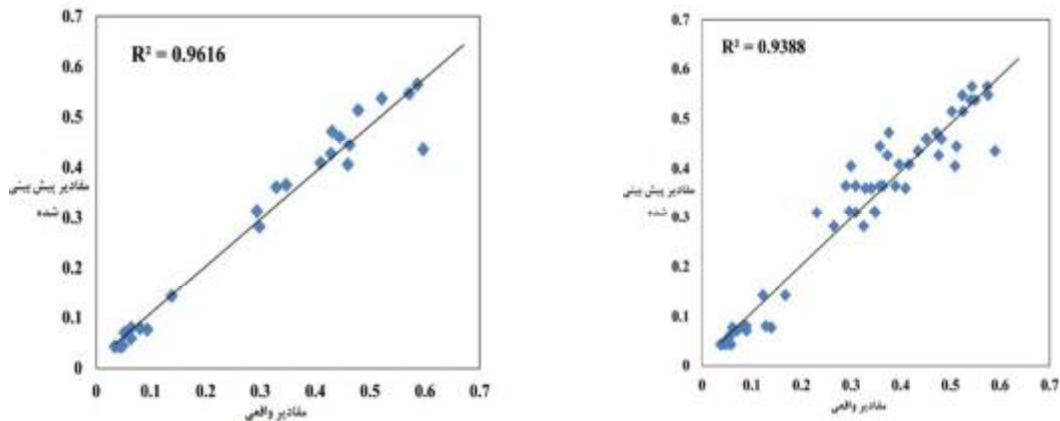
شکل ۴- نمودارهای مقادیر پیش‌بینی شده بازده مایکروبیو با استفاده از مدل شبکه عصبی مصنوعی برای (الف) داده‌های آموزش و (ب) داده‌های آزمون

جدول ۴- ویژگی‌های بهترین ساختار سامانه عصبی-فازی


RMSE	R ²	روش آموزش	تعداد تابع عضویت		نوع تابع عضویت		
			تعداد تکرار	ورودی	خروجی	ورودی	
۱۶۱۶/۱	۰/۹۸۲	هیبریدی	۴۰	۳،۳،۳	خطی	گوسی	انرژی تلف شده
۱۵۷۶/۳	۰/۹۷۶	هیبریدی	۴۰	۳،۳،۳	خطی	گوسی	انرژی جذب شده
۰/۰۳۷	۰/۹۵۲	هیبریدی	۴۰	۳،۳،۳	خطی	گوسی	بازده مایکروبیو



شکل ۵- نمودارهای مقادیر پیش‌بینی شده اتلاف انرژی با استفاده از مدل عصبی-فازی برای (الف) داده‌های آموزش و (ب) داده‌های آزمون




شکل ۶- نمودارهای مقادیر پیش‌بینی شده بازده مایکروبیو با استفاده از مدل عصبی-فازی برای (الف) داده‌های آموزش و (ب) داده‌های آزمون




شکل ۷- نمودارهای مقادیر پیش‌بینی شده انرژی جذب شده با استفاده از مدل عصبی- فازی برای الف) داده‌های آموزش و ب) داده‌های آزمون

نتیجه، واضح است که اتلاف انرژی پیش‌بینی شده و انرژی جذب شده با مقادیر اندازه‌گیری شده مطابقت خوبی دارند، در حالی که بازدهی مایکروبیو پیش‌بینی شده به خوبی آن‌ها نیست.

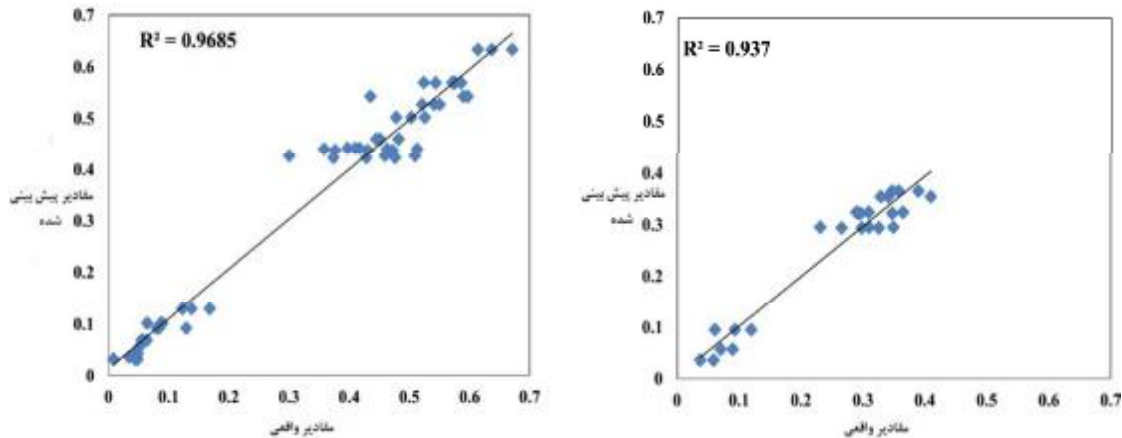
نتایج پیش‌بینی اتلاف انرژی، انرژی جذب شده و بازدهی مایکروبیو در شکل‌های ۸، ۹ و ۱۰ نشان داده شده است. مطابق این شکل‌ها مشاهده می‌شود که بیشتر نقاط در امتداد خط مورب قرار می‌گیرند. در



شکل ۸- نمودارهای مقادیر پیش‌بینی شده انرژی جذب شده با استفاده از مدل ماشین بردار پشتیبان برای الف) داده‌های آموزش و ب) داده‌های آزمون



شکل ۹- نمودارهای مقادیر پیش‌بینی شده اتلاف انرژی با استفاده از مدل ماشین بردار پشتیبان برای الف) داده‌های آموزش و ب) داده‌های آزمون



شکل ۱۰- نمودارهای پراکندگی و مقادیر پیش‌بینی شده بازده مایکروویو با استفاده از مدل ماشین بردار پشتیبان برای الف) داده‌های آموزش و ب) داده‌های آزمون

عصبی مصنوعی، ۰/۳ و ۹۶ برای مدل عصبی-فازی و ۰/۵ و ۹۶ برای مدل ماشین بردار پشتیبان بودند. واضح است که تطابق بهتری بین مقادیر اندازه‌گیری شده و برآورد شده توسط مدل عصبی-فازی و ماشین بردار پشتیبان پیشنهادی در مقایسه با مدل شبکه عصبی مصنوعی وجود دارد. علاوه بر این، مدل عصبی-فازی در مقایسه با مدل ماشین بردار پشتیبان در داده‌های آموزش و آزمون برای پیش‌بینی بازده مایکروویو مناسب‌تر بود، در حالی که مدل ماشین بردار پشتیبان برای پیش‌بینی انرژی جذب‌شده و اتلاف انرژی بهتر از مدل عصبی-فازی بود. از این رو، روش عصبی-فازی و ماشین بردار پشتیبان را می‌توان به عنوان روش‌های محاسباتی نرم قدرتمند برای پیش‌بینی اتلاف انرژی، انرژی جذب شده و بازدهی مایکروویو فرض نمود.

منابع

- Balbay, A., Kaya, Y., & Sahin, O. (2012). Drying of black cumin (*Nigella sativa*) in a microwave assisted drying system and modeling using extreme learning machine. *Energy*, 44(1): 352-357.
- Clary, C. D., Wang, S., & Petrucci, V. E. (2005). Fixed and incremental levels of microwave power application on drying grapes under vacuum. *Journal of Food Science-Chicago*, 70(5): E344.
- Darvishi, H., Azadbakht, M., Rezaeiasl, A., & Farhang, A. (2013). Drying characteristics of sardine fish dried with microwave heating. *Journal of the Saudi Society of Agricultural Sciences*, 12(2): 121-127.
- Datta, A. K. (2001). Mathematical modeling of microwave processing of foods: An

جدول ۵- آمار عملکرد مدل ماشین بردار پشتیبان برای برآورد اتلاف انرژی، انرژی جذب شده و بازده مایکروویو بر

اساس شاخص‌های آماری مختلف

	RMSE	R ²		
انرژی تلف شده	۱۲۹۴/۷۶	۰/۹۸۹	آموزش	
	۱۲۹۶/۳۱	۰/۹۸۸	آزمون	
انرژی جذب شده	۱۰۹/۴۳۹	۰/۹۸	آموزش	
	۱۰۸/۴۶۰	۰/۹۸۶	آزمون	
بازده مایکروویو	۰/۰۵۶	۰/۹۴۳	آموزش	
	۰/۰۵۶	۰/۹۵۷	آزمون	

نتیجه‌گیری

در این پژوهش، تأثیر توان مایکروویو (P)، جرم محصول (M) و زمان (T) بر انرژی جذب شده و اتلاف انرژی سیب در طول خشک شدن در مایکروویو بررسی گردید. همچنین پیش‌بینی بازده مایکروویو حین خشک کردن سیب بررسی گردید. با توجه به نتایج ما، جرم و به دنبال آن توان بالاترین حساسیت را بر بازدهی مایکروویو داشتند. قابلیت سامانه عصبی-فازی، شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی بازدهی امواج مایکروویو، انرژی جذب شده و اتلاف انرژی ارزیابی گردید. نتایج نشان داد که RMSE و R² بازده مایکروویو برای داده‌های آموزشی به ترتیب ۰/۵ و ۷۶، برای مدل شبکه عصبی مصنوعی، ۰/۴ و ۹۵ برای مدل سامانه عصبی-فازی و ۰/۵ و ۹۴ برای مدل ماشین بردار پشتیبان بود. در مورد داده‌های آزمایش، RMSE و R² برای پیش‌بینی بازده مایکروویو به ترتیب ۰/۰۹ و ۸۲ برای مدل شبکه

- Naderloo, L., Alimardani, R., Omid, M., Sarmadian, F., Javadikia, P., Torabi, M. Y., & Alimardani, F. (2012). Application of ANFIS to predict crop yield based on different energy inputs. *Measurement*, 45(6): 1406-1413.
- Oliveira, J., Lessio, B., Morgante, C., Santos, & M., Augusto, P. (2012). Specific heat (Cp) of tropical fruits: cajá, cashew apple, cocoa, kiwi, pitanga, soursop fruit and yellow melon. *International Food Research Journal*, 19(3): 811-814.
- Ornella, L., & Tapia, E. (2010). Supervised machine learning and heterotic classification of maize (*Zea mays* L.) using molecular marker data. *Computers and Electronics in Agriculture*, 74(2): 250-257.
- Pal, S. K., Rai, C., & Singh, A. P. (2012). Comparative study of firefly algorithm and particle swarm optimization for noisy non-linear optimization problems. *International Journal of Intelligent Systems and Applications (IJISA)*, 4(10): 50.
- Sami, S., Etesami, N., & Rahimi, A. (2011). Energy and exergy analysis of an indirect solar cabinet dryer based on mathematical modeling results. *Energy*, 36(5): 2847-2855.
- Sander, A., Bolf, N., & Kardum, J. P. (2003). Research on dynamics and drying time in microwave paper drying. *Chemical and biochemical engineering quarterly*, 17(2): 159-164.
- Sharma, G., & Prasad, S. (2006). Optimization of process parameters for microwave drying of garlic cloves. *Journal of food engineering*, 75(4): 441-446.
- Shiri, J., Nazemi, A. H., Sadraddini, A. A., Landeras, G., Kisi, O., Fard, A. F., & Marti, P. (2013). Global cross-station assessment of neuro-fuzzy models for estimating daily reference evapotranspiration. *Journal of hydrology*, 480: 46-57.
- Soysal, Y. (2004). Microwave drying characteristics of parsley. *Biosystems engineering*, 89(2): 167-173.
- Torrina, E., Esveld, E., Scheewe, I., van den Berg, R., & Bartels, P. (2001). Osmotic dehydration as a pre-treatment before combined microwave-hot-air drying of mushrooms. *Journal of food engineering*, 49(2): 185-191.
- Turkmen, I. (2011). Efficient impulse noise detection method with ANFIS for accurate image restoration. *AEU-International Journal of Electronics and Communications*, 65(2): 132-139.
- Vapnik, V. N., Vapnik, V. (1998). Statistical learning theory. *Wiley New York*.
- Yang, X. S. (2013). Multiobjective firefly algorithm for continuous optimization. overview. *Food Science and Technology-New York- Marcel Dekker*, 1: 147-188.
- Fister, I., Fister Jr, I., Yang, X.-S., & Brest, J. (2013). A comprehensive review of firefly algorithms. *Swarm and Evolutionary Computation*, 13: 34-46.
- Ho, Y.-C., & Tsai, C.-T. (2011). Comparing ANFIS and SEM in linear and nonlinear forecasting of new product development performance. *Expert Systems with Applications*, 38(6): 6498-6507.
- Jain, P., Garibaldi, J. M., & Hirst, J. D. (2009). Supervised machine learning algorithms for protein structure classification. *Computational biology and chemistry*, 33(3): 216-223.
- Jindarat, W., Rattanadecho, P., & Vongpradubchai, S. (2011). Analysis of energy consumption in microwave and convective drying process of multi-layered porous material inside a rectangular wave guide. *Experimental Thermal and Fluid Science*, 35(4): 728-737.
- Kahyaoglu, L. N., Sahin, S., & Sumnu, G. (2012). Spouted bed and microwave-assisted spouted bed drying of parboiled wheat. *Food and Bioprocess Technology*, 90(2): 301-308.
- Kiş, Ö., & Öztürk, Ö. (2007). Adaptive neurofuzzy computing technique for evapotranspiration estimation. *Journal of Irrigation and Drainage Engineering*, 133(4): 368-379.
- Landeras, G., López, J. J., Kisi, O., & Shiri, J. (2012). Comparison of Gene Expression Programming with neuro-fuzzy and neural network computing techniques in estimating daily incoming solar radiation in the Basque Country (Northern Spain). *Energy Conversion and Management* 62: 1-13.
- Maskan, M. (2000). Microwave/air and microwave finish drying of banana. *Journal of food engineering*, 44(2): 71-78.
- Momenzadeh, L., Zomorodian, A., & Mowla, D. (2012). Applying Artificial Neural Network for Drying Time Prediction of Green Pea in a Microwave Assisted Fluidized Bed Dryer. *Journal Agricultural Science Technology*, 4, 513-522.513
- Motevali, A., Minaei, S., & Khoshtagaza, M. H. (2011a). Evaluation of energy consumption in different drying methods. *Energy Conversion and Management*, 52(2): 1192-1199.
- Motevali, A., Minaei, S., Khoshtagaza, M. H., & Amirnejat, H. (2011b). Comparison of energy consumption and specific energy requirements of different methods for drying mushroom slices. *Energy*, 36(11): 6433-6441.

Engineering with Computers, 29(2): 175-184.

Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1): 35-62.

