

مقایسه مدل‌سازی ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی در پیش‌بینی سینتیک خشک‌کردن سیر و موسیر در خشک‌کن بسترسپال

محمد کاوه^{۱*} - یوسف عباسپور گیلانده^۲ - رضا امیری چایجان^۳ - رضا محمدی گل^۴

تاریخ دریافت: ۱۳۹۶/۰۴/۲۹

تاریخ پذیرش: ۱۳۹۶/۱۰/۱۲

چکیده

هدف از این پژوهش، مقایسه برآورد نسبت رطوبت سیر و موسیر در طی فرآیند خشک‌کردن توسط خشک‌کن بسترسپال با استفاده از روش‌های مدل‌سازی ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی می‌باشد. فرآیند خشک‌کردن در سه سطح دمایی (۷۰°C و ۵۵، ۴۰) و سه سطح سرعت هوای ورودی (۰/۵ و ۱/۵ و ۲/۵ ms⁻¹) صورت گرفت. از ۵ مدل ریاضی خشک‌کردن جهت پیش‌بینی نسبت رطوبت سیر و موسیر استفاده شد. سرعت هوای ورودی، دمای هوای ورودی و زمان خشک‌کردن به‌عنوان پارامترهای ورودی در پیش‌بینی نسبت رطوبت، برای شبکه‌های عصبی مصنوعی و منطق فازی مورد استفاده قرار گرفت. برای ایجاد الگوهای آموزشی و ارزیابی فرآیند، از شبکه عصبی پس‌انتشار پیش‌خور و پیش‌رو با توابع آموزش لونیگ-مارکوارت (LM) و تنظیم بیزی (BR) و همچنین از سیستم استنتاجی فازی مددانی و به‌کارگیری تابع عضویت مثلثی برای مدل‌سازی استفاده شد. با توجه به نتایج به‌دست آمده، بهترین مدل برای پیش‌بینی خشک‌کردن سیر مدل (Page) و برای موسیر مدل Midilli و همکاران انتخاب شد. نتایج بررسی‌های شبکه عصبی مصنوعی نشان داد که به‌ترتیب ضرایب تبیین ۰/۹۹۹۴ و ۰/۹۹۹۶، ریشه خطای میانگین مربعات ۰/۰۰۳۶ و ۰/۰۰۱۴ و میانگین خطای مطلق ۰/۰۴۴ و ۰/۰۳۸ در شرایط مختلف خشک‌کردن سیر و موسیر را پیش‌بینی نماید. همچنین سیستم استنتاجی فازی این مقادیر را برای سیر و موسیر به‌ترتیب (ضرایب تبیین ۰/۹۹۹۷ و ۰/۹۹۹۸، ریشه خطای میانگین مربعات ۰/۰۰۲۷ و ۰/۰۰۱۱ و میانگین خطای مطلق ۰/۰۳۲ و ۰/۰۲۹) به‌دست آورد. مقایسه نتایج به‌دست آمده از مدل‌های ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی نشان داد که ریشه خطای میانگین مربعات در منطق فازی کمتر از شبکه‌های عصبی مصنوعی و مدل‌های ریاضی است.

واژه‌های کلیدی: خشک‌کن بستر سپال، سیر و موسیر، شبکه‌های عصبی مصنوعی، منطق فازی و نسبت رطوبت

مقدمه

فراورده‌های غذایی است که از نظر تجاری دارای اهمیت زیادی است و به شکل‌های ورقه‌ای یا پودر تهیه و به‌عنوان افزودنی در مواد غذایی استفاده و یا به مصارف دارویی می‌رسد (Sharma et al., 2009). موسیر (*Allium hirtifolium* Boiss. L.) گیاهی چند ساله از خانواده Alliaceae است. این گیاه بومی ایران بوده و به‌صورت وحشی در مراتع و کوهستان‌های ایران می‌روید. موسیر در اکثر مناطق کشور به‌صورت خشک مورد مصرف قرار می‌گیرد. به‌علاوه این گیاه در تهیه مقادیر قابل‌توجهی پتاسیم، فسفر، کلسیم، منیزیم، سدیم، ترشی و به‌عنوان افزودنی به ماست و ترشی کاربرد دارد. موسیر از نظر طبی جزو گیاهان دارویی مهم بوده و برای کاهش فشار خون مورد استفاده قرار می‌گیرد. همچنین برگ‌ها و پیازهای توپر آن قسمت‌های خوراکی موسیر می‌باشد. پودر آن به‌عنوان یک افزودنی خوشمزه یا ادویه مواد غذایی در ایران استفاده می‌شود (Kouchakzadeh, 2014). خشک‌کردن یکی از قدیمی‌ترین روش‌های نگهداری مواد غذایی و محصولات کشاورزی است که تا حد زیادی بر کیفیت محصول از نظر رنگ، بافت، اندازه و طعم تاثیرگذار می‌باشد. در

سیر (*Allium sativum* L.) یکی از مهم‌ترین محصولات کشاورزی است که به‌طور وسیع در جهان تولید می‌شود و به‌عنوان چاشنی و بدون هیچ عمل آماده‌سازی مورد استفاده قرار می‌گیرد. که علاوه بر استفاده از آن در محصولات غذایی به‌عنوان ماده ضدسرطان نیز کاربرد زیادی دارد. سیر علاوه بر مصرف تازه آن به شکل‌های دیگری نیز مورد استفاده قرار می‌گیرد. سیر خشک شده یکی از

۱ و ۲- به‌ترتیب دانشجوی دکترا و استاد، گروه مکانیک بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران
۳- دانشیار، گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران
۴- استادیار، گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه اراک، اراک، ایران
(Email: sirwankaweh@uma.ac.ir)
* - نویسنده مسئول:

منطق فازی نخستین بار توسط Zadeh (۱۹۶۵) مطرح شد. هدف اولیه وی توسعه مدلی کارآمدتر برای توصیف فرآیند پردازش زبان‌های طبیعی بود. اساس نظریه فازی را می‌توان به نظریه مجموعه‌های فازی و در نتیجه انتخاب تابع عضویت مناسب برای این مجموعه‌ها دانست در مطالعات مختلف و بسته به ماهیت مسأله، از توابع گوناگون استفاده می‌شود (Mohamed, 2011). به‌طور کلی، روش منطق فازی به‌عنوان یک انقلاب برای برخی از فرآیندهای پیچیده که فاقد تکنیکی موثر برای مدل‌سازی‌های جامع و موثر می‌باشد. واحدهای اساسی و لازم برای استفاده از هر رویکرد مدل فازی وجود دارد عبارتند از: پایگاه قواعد فازی، موتور استنتاج فازی، فازی ساز و غیرفازی‌ساز (Jafari et al., 2016) برخی از محققین از منطق فازی برای مواد غذایی استفاده کردند از جمله: برای پیش‌بینی برخی خواص خشک کردن پیاز (Jafari et al., 2016) برای پیش‌بینی کیفیت آب (Gharibi et al., 2012) و برای پیش‌بینی نسبت رطوبت خشک کردن کدو (Tavakolipour et al., 2015).

با این حال با توجه به مطالعات صورت گرفته، پژوهشی در مورد فرآیند خشک کردن سیر و موسیر با خشک‌کن بسترسیال و همچنین پیش‌بینی نسبت رطوبت خشک کردن این دو محصول با مدل‌های ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی صورت نگرفته است. بنابراین با توجه به ضرورت‌های بیان شده هدف از این پژوهش، ارزیابی تاثیر دمای هوا و سرعت هوای ورودی در روند خشک کردن سیر و موسیر در خشک‌کن بستر سیال و همچنین پیش‌بینی نسبت رطوبت سیر و موسیر به کمک مدل‌های ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی می‌باشد.


مواد و روش‌ها

سیر و موسیر تازه با درجه رسیدگی و رنگ یکنواخت از بازار محلی در شهر همدان خریداری و تهیه گردید. برای جلوگیری از کاهش رطوبت اولیه محصولات، نمونه‌های مورد آزمایش، تا زمان انجام شروع آزمایش‌ها داخل دو پلاستیک مهر و موم شده به صورت جداگانه، در داخل یخچال با دمای $4 \pm 1^\circ\text{C}$ در آزمایشگاه پس از برداشت دانشگاه بوعلی سینا همدان نگهداری شد. برای انجام آزمایش‌ها، به‌منظور رسیدن به دمای اتاق، نمونه‌ها دو ساعت قبل از برش زدن از یخچال خارج می‌شدند. نمونه‌ها با استفاده از دستگاه برش کاتر (شکل ۱) از مقطع عرضی با ضخامت 3 ± 0.1 برش داده می‌شد. برای تعیین رطوبت اولیه محصولات از نمونه‌های ورقه‌ای ۲۵ گرمی استفاده شد که به مدت ۲۴ ساعت در دمای 70°C با استفاده از روش آون داغ مقدار رطوبت اولیه این محصولات به‌دست آمد. رطوبت اولیه برای سیر و موسیر با روش آون داغ به‌ترتیب 0.60 و 0.99 بر پایه خشک محاسبه شدند.

خشک کردن علاوه بر جلوگیری از فساد ماده غذایی ناشی از حمله میکروارگانیسم‌ها یا واکنش‌های شیمیایی، وزن ماده غذایی به دلیل از دست رفتن رطوبت محصول کاهش می‌یابد و در هزینه‌های حمل و نقل و بسته‌بندی و نگهداری صرفه‌جویی می‌شود (Kaleta et al., 2013; Adak et al., 2017).

سیال‌سازی یکی از روش‌هایی است که به‌طور گسترده در خشک کردن محصولات کشاورزی و مواد غذایی استفاده می‌شود. روش بسترسیال به‌عنوان یک فرآیند آرام و یکنواخت خشک‌شدن شناخته شده که قابلیت کاهش رطوبت مواد را با بازده بالا دارد. مشخصه این فرآیند، استفاده از موادی با میزان رطوبت بالا و کنترل حرارتی مناسب به علت اختلاط مواد است (Aghbashlo et al., 2014). مطالعات متعددی در مورد خشک کردن محصولات کشاورزی با خشک‌کن بسترسیال مانند سب (Kaleta et al., 2013)، پیاز (Bebartta et al., 2014)، بنه (Amiri Chayjan and Kaveh, 2014) و برنج (Foroughi-dahr et al., 2015) انجام شده است. هنگامی که بین پارامترهای وابسته و مستقل روابط پیچیده‌ای وجود دارد، روش‌های بهینه‌سازی می‌توانند بهترین گزینه برای حل این پیچیدگی‌ها باشند. یکی از این روش‌ها، شبکه‌های عصبی مصنوعی (ANNs) است که یک روش غیرالگوریتمی بر اساس آموزش و یادگیری با استفاده از داده‌های موجود می‌باشد. همچنین شبکه‌های عصبی مصنوعی (ANNs) قادر به پیش‌بینی متغیرهای وابسته بر اساس متغیرهای مستقل در محدوده یادگیری است (Samadi et al., 2013). شبکه‌های عصبی مصنوعی شامل یک الگوی پردازش اطلاعات و ابزار قدرتمند به‌منظور شبیه‌سازی، الهام گرفته از نرون‌های بیولوژیک است. با این رویکرد، شبکه‌های عصبی مصنوعی همانند ساختار بیولوژیکی مغز انسان با ترکیب ویژگی‌هایی همچون قدرت یادگیری، تصمیم‌دهی، پردازش موازی و تصمیم‌گیری، قابلیت حل کامل مسائلی پیچیده با ماهیتی خطی یا غیرخطی را خواهند داشت (Silva et al., 2015). محققین زیادی برای پیش‌بینی خواص محصولات کشاورزی از شبکه‌های عصبی مصنوعی استفاده نمودند از جمله: پیش‌بینی نسبت رطوبت و نرخ خشک کردن بادمجان با استفاده از خشک‌کن پیوسته (Kaveh et al., 2017)، پیش‌بینی نسبت رطوبت خشک کردن آویشن با استفاده از خشک‌کن مایکروبیو (Sarimeseli et al., 2014)، پیش‌بینی زمان خشک کردن ذرت با استفاده از خشک‌کن مایکروبیو-بستر سیال (Momenzadeh et al., 2011) و پیش‌بینی نرخ خشک کردن و نسبت رطوبت خشک کردن هویج با استفاده از خشک‌کن بستر سیال (Nazghelichi et al., 2011).

به تازگی، ابزار پیش‌بینی جدیدتر و دقیق‌تر مانند سیستم منطق فازی جهت پیش‌بینی و بهینه‌سازی پارامترهای فرآیند خشک کردن در روش‌های مختلف استفاده می‌شود. تئوری مجموعه‌های فازی و




شکل ۱- دستگاه برش: (۱) شاسی، (۲) تیغه، (۳) فک ثابت و (۴) فک متحرک

Fig. 1. Cutting machine (1) Chassis, (2) Blade, (3) Fixed jaw and Movable jaw

خشک کن آزمایشگاهی و تجهیزات مورد استفاده
 برای انجام آزمایشها از یک خشک کن بسترسیمال موجود در گروه مهندسی بیوسیستم دانشگاه بوعلی سینا همدان استفاده گردید (شکل ۲). اجزای اصلی خشک کن عبارتند از: المنت های گرم کننده هوا (۵ المنت ۳۰۰ واتی)، محفظه خشک کن (محل قرارگیری نمونه ها)، سیستم کنترل (سرعت دمنده و دمای هوای ورودی به محفظه خشک کن)، دمنده گریز از مرکز برای تأمین جریان هوا و لوله های رابط برای جریان و انتقال هوا، محفظه استوانه ای خشک کن. دمنده گریز از مرکز دارای قابلیت تغییر میزان هوای ورودی به محفظه خشک کن است. تنظیم سرعت هوای ورودی با تغییر سرعت دمنده و به صورت دستی توسط یک اینورتر (Vincker VSD2, ABB Co., ساخت تایوان با درجه تفکیک ۰/۱ هرتز که به الکتروموتور متصل است انجام می شود. پیچاندن پیچ تنظیم اینورتر موجب تغییر فرکانس برق در خروجی و تغییر دور دمنده شد. افزایش یا کاهش دور دمنده، افزایش یا کاهش سرعت جریان هوا را به همراه داشت. موتور مورد استفاده از نوع سه فاز می باشد که دارای تعداد دور

۲۸۰۰ rpm و قدرت ۲۵۰ W می باشد. دمای هوای خشک کن در محل قرارگیری نمونه ها به طور مستقیم با ترموکوپل اندازه گیری می شود که در زیر محفظه قرار گرفته است. همچنین برای جلوگیری از تلفات حرارتی، دور کانال منتهی به محفظه با پشم شیشه عایق بندی شد.
 برای توزین نمونه ها در حین مراحل خشک کردن از یک ترازوی دیجیتال (AND GF- 600، ژاپن) با درجه تفکیک ۰/۰۰۱ گرم استفاده شد. از ترموستات (آتین مگا، ایران) با درجه تفکیک ۰/۱ درجه سلسیوس که با ترموکوپل نوع K کار می کرد، برای تنظیم دمای هوای ورودی استفاده گردید. برای اندازه گیری دبی هوای ورودی محفظه خشک کن، از یک سرعت سنج هوای توربینی لوترون (YK, 80AM، تایوان) با درجه تفکیک $1 \text{ m s}^{-1} \pm$ مورد استفاده قرار گرفت. برای اندازه گیری دمای محیط و محفظه خشک کن و همچنین رطوبت نسبی هوا، از دستگاه رطوبت سنج- دماسنج لوترون (Lutron, YK-2005RH, Taiwan) استفاده شد.



شکل ۲- شماتیک خشک کن آزمایشگاهی بستر سیال: (۱) اتاق خشک کن، (۲) سنسور سرعت هوا، (۳) فن و موتور الکتریکی، (۴) گرم کننده

الکتریکی، (۵) اینورتر و ترموستات، (۶) ترازو، (۷) کامپیوتر، (۸) دماسنج، (۹) رطوبت سنج و (۱۰) شاسی

Fig. 2. Schematic diagram of laboratory scale fluidized bed dryer: (1) Drying chamber (2) Air velocity sensor (3) Fan and electrical motor, (4) Electrical heater, (5) Inverter and thermostat, (6) Scale, (7) Computer, (8) Thermometer, (9) Hygrometer and (10) Chassis

برای زمان‌های طولانی خشک شدن در خشک‌کن بستر سیال، مقدار M_e در مقایسه با مقادیر M_o و M_b خیلی کوچک می‌باشد بنابراین رطوبت تعادلی صفر در نظر گرفته شد و رابطه به صورت

$$MR = \frac{M_o}{M_b} \text{ خلاصه شد.}$$

مدل‌های ریاضی

برای تطبیق مدل‌های تجربی با داده‌های به دست آمده از آزمایش از نرم‌افزار ۱/۴ Curve Expert استفاده شد. ۱۳ مدل خشک‌کردن (Page, Logarithmic, Demir *et al*, Two-term, Midilli *et al*, Newton, Henderson and Pabis, Wang and Singh, Weibull, Logistic, Aghbashlo *et al*, Modified Page, Verma *et al*.) به داده‌های به دست آمده از آزمایش برای یافتن مناسب‌ترین مدل جهت تشریح رفتار خشک‌شدن سیر و موسیر در خشک‌کن بستر سیال برآزش داده شدند.

طراحی روند آموزش شبکه‌های عصبی مصنوعی

ساختار عمومی شبکه عصبی پرسپترون چندلایه در شکل ۳ نشان داده شده است. از این شبکه برای پیش‌بینی نسبت رطوبت با سه نرون در لایه اول که برابر با تعداد ورودی‌ها از جمله دمای هوای ورودی، سرعت هوای ورودی و زمان خشک‌کردن بوده است استفاده شد.


قبل از شروع آزمایش‌ها، دستگاه خشک‌کن به مدت نیم ساعت برای رسیدن به شرایط تعادل پایدار زودتر روشن می‌شد. آزمایش‌ها با برش‌های سیر و موسیر با ضخامت سه میلی‌متر به صورت جداگانه در سه سطح دمایی (۴۰، ۵۵ و ۷۰°C) و سه سطح سرعت هوای ورودی (۰/۵ و ۱/۵ و ۲/۵ m s⁻¹) صورت گرفت و تغییرات وزنی آن‌ها در فواصل زمانی مشخص، با استفاده از ترازوی دیجیتالی ثبت گردید. در نهایت تمامی فرآیند آزمایش‌ها از رطوبت اولیه ۰/۶۰ برای سیر و ۱/۹۹ برای موسیر تا زمانی که رطوبت نهایی سیر و موسیر به ترتیب به ۰/۱ و ۰/۱ بر پایه خشک می‌رسید متوقف می‌شد. تمامی آزمایش‌ها در سه تکرار انجام گرفت.

برآزش منحنی‌های خشک‌کردن

نسبت رطوبت با توجه به رطوبت اولیه، رطوبت تعادلی و رطوبت نمونه‌ها در هر لحظه در طول خشک‌کردن سیر و موسیر به وسیله رابطه (۱) محاسبه گردید (Mahani and Aghkhani, 2016; Doymaz *et al.*, 2015):

$$MR = \frac{M_o - M_e}{M_b - M_e} \quad (1)$$

که در آن MR نسبت رطوبت (بدون بعد)، M_o نسبت رطوبت در زمان t ، M_b و M_e به ترتیب، رطوبت اولیه و رطوبت تعادلی بر پایه خشک (d.b.) می‌باشند.



شکل ۳- ساختار شبکه عصبی با دو لایه پنهان

Fig. 3. Selected ANN structure with two hidden layers

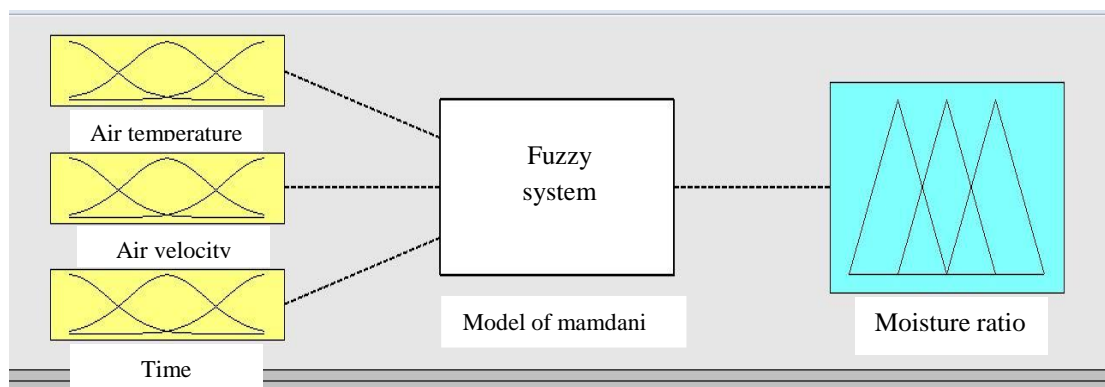
شبکه های عصبی مصنوعی از چندین لایه تشکیل می شوند. لایه های ابتدایی و انتهایی به ترتیب لایه ورودی و لایه خروجی نام دارند. همچنین بین این دو لایه ممکن است یک یا دو لایه پنهان وجود داشته باشند. طی فرآیند آموزش این وزن ها و مقادیر ثابتی که با آن ها جمع می شود اصطلاحاً بایاس نامیده می شوند، به طور پی در پی تغییر می کند تا خطا به کمترین مقدار خود برسد. پس از محاسبه هر خروجی، شبکه تحت یک تابع فعال سازی شروع به اصلاح آن می کند. برای بهینه سازی ساختار شبکه از سه تابع فعال سازی تابع سیگموئید لگاریتمی (LOG)، تابع خطی (PUR) و تانژانت هایپربولیک سیگموئید (TAN) استفاده شد (Kaveh et al., 2017).

طراحی روند منطق فازی

در این مطالعه از سامانه استنتاج فازی به عنوان فرآیندی سینماتیک برای تبدیل دانش به یک نگاشت غیرخطی استفاده شد. دلیل این امر، توانایی روش های مبتنی بر منطق فازی در شبیه سازی رفتار انسان در تصمیم گیری های غیرقطعی در بحث تشخیص و تعیین کیفیت محصولات غذایی بود. سیستم استنتاج فازی بر اساس قواعد اگر- آنگاه بنا شده است که با استفاده از این قواعد می توان ارتباط بین ورودی و یا خروجی را به دست آورد. متغیرهای ورودی سامانه فازی طراحی شده در این مطالعه، دمای هوای ورودی ($^{\circ}\text{C}$)، سرعت هوای ورودی (ms^{-1}) و زمان خشک کردن (min) بود. همچنین متغیر خروجی منطق فازی در این بخش نسبت رطوبت بود (شکل ۴).

به منظور بررسی و ارزیابی شبکه های مختلف، پایگاه داده ای به دو دسته آموزش و ارزیابی تقسیم شد. حدود ۲۵٪ کل داده ها (۳۶ داده برای سیر و ۴۹ داده برای موسیر) به طور تصادفی برای ارزیابی شبکه های آموزش دیده و ۷۵٪ داده ها (۱۰۷ داده برای سیر و ۱۴۵ داده برای موسیر) به منظور آموزش شبکه انتخاب شدند. یک شبکه پرسپترون دو و سه لایه با توابع فعال سازی مختلف برای تعیین ساختار مطلوب مورد آزمایش قرار گرفت. تعداد نرون های لایه میانی (یک لایه و دو لایه) از سه تا ۲۰ تغییر داده شدند. به منظور پردازش داده های مورد آزمایش از دو شبکه پس انتشار پیش خور (Feed Forward Back Propagation (FFBP) و پس انتشار پیشرو (Cascad Forward Back Propagation (CFBP) استفاده شد. همچنین از توابع آموزش لونبرگ- مارکواریت ((Levenberg-Marquardt (LM) و تنظیم بییزی (Bayesian Regulation (BR)) برای بهنگام سازی وزن های شبکه های مورد نظر به کار گرفته شد.

در طی فرآیند آموزش، شبکه های عصبی مصنوعی به کمک داده های آموزشی، ارتباط بین نرون ها را در هر چرخه آموزش فرا می گیرند تا این مقادیر پیش بینی شده به مقادیر خروجی مطلوب نزدیک شوند و مقادیر خطای حاصل از مقادیر خطای مشخص شده کمتر گردد. پارامترهای ترکیبی مانند تعداد لایه های پنهان، تعداد نرون ها، تعداد چرخه آموزش، در طی فرآیند آموزش شبکه و به روش آزمون و خطا تعیین می شوند.



شکل ۴- شکل کلی از مدل منطق فازی مورد استفاده در این مطالعه

Fig. 4. Overall form of fuzzy logic classifying model

جدول ۱، مختصری از پارامترهای ورودی و خروجی (مرز و سطوح) برای شبکه های عصبی مصنوعی و منطق فازی را نشان می دهد. قوانین فازی نیز بر اساس نظر کارشناسان خبره تعریف شدند. این قوانین برای برقراری ارتباط بین ورودی و خروجی متغیرها به کار گرفته شدند. در تدوین سامانه استنتاج فازی از روش ممدانی و تابع

عضویت مثلثی (trimf) برای تغییرات ورودی و خروجی استفاده شد. در جدول ۲، محدوده متغیرهای وابسته استفاده شده، به همراه توابع عضویت تعریف شده برای متغیرهای ورودی و خروجی گزارش شده است. به طور کلی، ۸۱ قوانین اگر- سپس با عملگر "AND" برای خشک کردن لایه نازک هر یک از محصولات سیر و موسیر به دست

جدول ۱- خلاصه‌ای از پارامترهای ورودی و خروجی برای ANN و Fuzzy logic

Table 1- Summary of input and output parameters for ANN and fuzzy logic

Parameter	Symbol	Unit	Category	Min	Max
Air temperature	T	°C	Input	40	70
Air velocity	V	m s ⁻¹	Input	0.5	2.5
Drying time (garlic)	DT	min	Input	0	310
Drying time (shallot)	DT	min	Input	0	180
Moisture ratio	MR	-	Output	0.0617	1

متغیرهای لفظی، خیلی خیلی کم (VVL)، خیلی کم (VL)، کم (L)، متوسط منفی (NM)، متوسط (M)، متوسط مثبت (PM)، زیاد (H)، خیلی زیاد (VH)، خیلی خیلی زیاد (VVH)، استفاده شد.

برای فازی کردن پارامترهای ورودی دما و سرعت هوای ورودی از متغیرهای لفظی، کم (L)، متوسط (M) و زیاد (H) برای متغیر ورودی زمان خشک‌کردن و متغیر خروجی نسبت رطوبت از

جدول ۲- متغیرهای ورودی به همراه تابع عضویت برای فازی سازی فرآیند خشک‌کردن سیر و موسیر

Table 2- Input variables accompanied by membership functions to fuzzification of drying process of Garlic and shallot

Variable	Membership function	Range Triangular	
		Garlic	Shallot
Drying temperature	Low	40,45,50	40,45,50
	Medium	45,50,55	45,50,55
	High	55,65,70	55,65,70
Air velocity	Low	0.5, 0.75, 1	0.5, 0.75, 1
	Medium	0.75, 1.5, 2	0.75, 1.5, 2
	High	1.5, 2, 2.5	1.5, 2, 2.5
Drying time	Too much low	0,0,20	0,0,30
	Very low	0,20,30	0,30,60
	Low	20,40,60	30,60,90
	Negative medium	40,60,80	60,90,120
	Medium	60, 80, 100	90,150,180
	Positive medium	80,100,120	150, 180, 220
	High	100,120,140	180, 220, 260
	Very high	120,140,160	220,260,290
Moisture ratio	Very very high	160,180,180	260, 290,310
	Too much low	(0,0,0.006)	(0,0,0.006)
	Very low	(0.005,0.01,0.03)	(0.005,0.01,0.03)
	Low	0.01, 0.04, 0.08	0.01, 0.04, 0.08
	Negative medium	0.06, 0.1, 0.3	0.06, 0.1, 0.3
	Medium	0.1, 0.3, 0.45	0.1, 0.3, 0.45
	Positive medium	(0.3, 0.5, 0.6)	(0.3, 0.5, 0.6)
	High	0.5, 0.65, 0.7	0.5, 0.65, 0.7
	Very high	0.6, 0.74, 0.8	0.6, 0.74, 0.8
	Very very high	0.7, 0.9, 1	0.7, 0.9, 1

سطح دمایی (۴۰، ۵۵ و ۷۰°C) و سه سطح سرعت هوای ورودی (۰/۵ و ۱/۵ و ۲/۵ ms⁻¹) استفاده شد. معیارهایی از جمله ضریب تبیین (همبستگی) (R²)، شاخص ریشه میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) برای تعیین کیفیت عملکرد مدل‌های ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی در این پژوهش مورد استفاده قرار گرفته شده‌اند. با توجه به نتایج حاصله، هرچه قدر این میانگین مربعات خطا به صفر و ضریب تبیین به یک نزدیک‌تر باشد، بیانگر اختلاف کمتری بین داده‌های واقعی و داده‌های پیش‌بینی شده خواهد بود (Murthy and Manohar,)

از نرم‌افزار Neural Network Toolbox MATLAB (ver4.01) نیز برای انجام تحلیل‌ها برای طراحی و ارزیابی شبکه‌های عصبی مصنوعی و منطق فازی در پیش‌بینی پارامترهای خشک‌کردن استفاده شد.

آنالیز مدل‌های پیش‌بینی

برای مقایسه مدل‌های ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی در پیش‌بینی نسبت رطوبت سیر و موسیر از آزمایش سه

می باشد. با توجه به شکل، با افزایش دما و سرعت هوای ورودی، سرعت خروج رطوبت از سیر و موسیر سریع تر شده و زمان خشک شدن کاهش یافت. این روند در دماهای بالاتر با شدت بیشتری رخ داد. بر این اساس کمترین زمان خشک شدن برای هر دو محصول سیر و موسیر در دمای 70°C محصول اتفاق افتاد و بیشترین زمان خشک شدن در دمای 40°C به دست آمد. یکی از دلایلی که منجر به این اتفاق شد این بود که با افزایش دمای هوای ورودی، دمای درون محفظه افزایش یافته و باعث کاهش بیشتر میزان رطوبت نمونه ها می شود. به عبارت دیگر دمای بالاتر، باعث انتقال بیشتر جرم و حرارت و کاهش رطوبت شدیدتر می شود. با این حال میزان کاهش رطوبت، به علت بیشتر شدن انرژی جنبشی مولکول ها و افزایش انتقال جرم، افزایش یافت. نتایج مشابهی در خشک کردن به وسیله خشک کن بستر سیال برای محصولات پیاز (Bebartta *et al.*, 2014)، بنه (Amiri Chayjan and Kaveh, 2014)، خرما (Puspasari *et al.*, 2012)، برنج (Khanali *et al.*, 2016) و پوست هندوانه (Oberoi and Sogi, 2015) گزارش شده است.

(2014; Kaveh and Amiri Chayjan, 2017)

$$R^2 = 1 - \frac{\sum_{i=1}^N (S_i - T_i)^2}{\sum_{i=1}^N (S_i - T_m)^2} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i - T_i)^2} \quad (3)$$

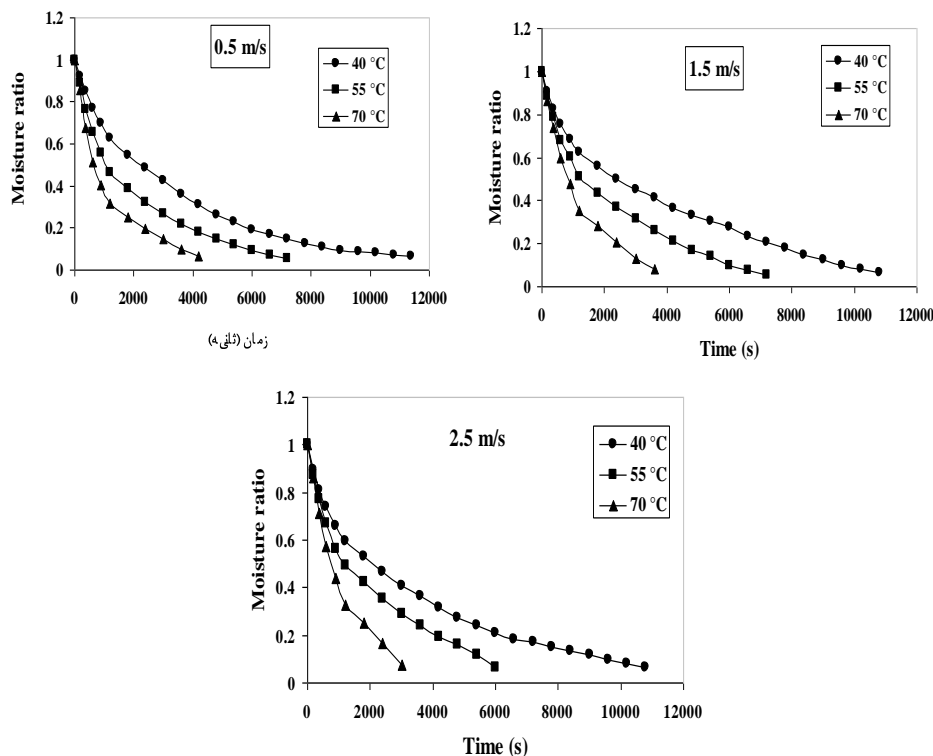
$$MAE = \frac{1}{N} \sum_{p=1}^N |S_i - T_i| \quad (4)$$

در این روابط S_i مقدار پیش بینی شده، برای الگوی i ام، T_i مقدار آزمایشی برای الگوی i ام، T_m میانگین مقادیر پیش بینی شده و N تعداد کل داده ها است.

نتایج و بحث

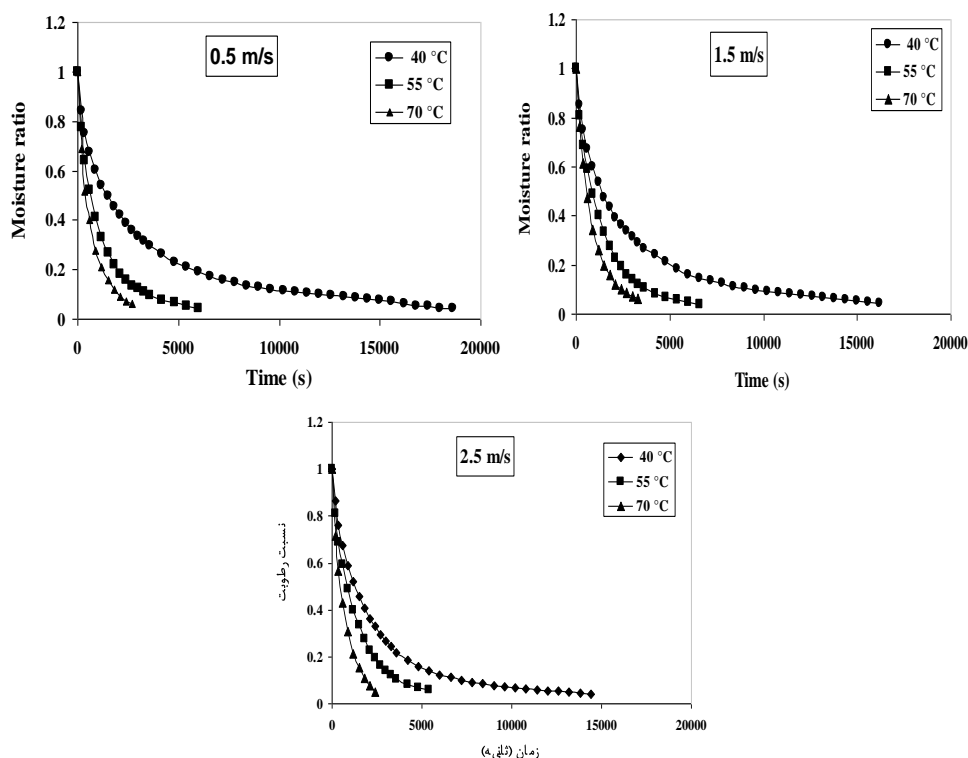
سینتیک خشک شدن

شکل ۵ و ۶ نمودار مربوط به نسبت رطوبت و زمان خشک کردن



شکل ۵- تغییرات نسبت رطوبت سیر در شرایط سرعت هوا و دمای هوای ورودی

Fig. 5. Moisture ratio variation of garlic in different air velocities and air temperatures



شکل ۶- تغییرات نسبت رطوبت موسیر در شرایط سرعت هوا و دمای هوای ورودی

Fig. 6. Moisture ratio variation of shallot under different air velocities and air temperatures

به‌دست آمده از جدول ۳ مقدار ضریب تبیین (R^2) برای هر پنج مدل برای هر دو محصول بالای ۰/۹۹۷۰ بود. با توجه به جدول ۳ مدل Page برای پیش‌بینی خشک کردن سیر و مدل Midilli *et al.* برای پیش‌بینی خشک کردن موسیر نسبت به مدل‌های دیگر برآزش بهتری داشتند.

برآزش مدل‌های ریاضی سینتیک خشک‌کردن

پنج مدل ریاضی خشک کردن (جدول ۳) بر اساس بیشترین مقدار ضریب تبیین (R^2) و مقدار میانگین مطلق خطا (MAE) و ریشه خطای مربعات میانگین (RMSE) جهت پیش‌بینی روند خشک‌شدن برای هر دو محصول سیر و موسیر انتخاب شدند. با توجه به نتایج

جدول ۳- مدل‌های ریاضی مورد استفاده برای نسبت رطوبت

Table 3- Mathematical models applied to fit the drying curves

Model	Equation	References	Garlic			Shallot		
			RMSE	R^2	MAE	RMSE	R^2	MAE
Page	$MR = \exp(-kt^n)$	Kantrong <i>et al.</i> , 2014	0.0051	0.9992	0.053	0.0092	0.9981	0.126
Demir <i>et al.</i>	$MR = a \exp(-kt)^n + b$	Kaveh and Amiri Chayjan 2017	0.0094	0.9983	0.106	0.0104	0.9977	0.142
Logarithmic	$MR = a \exp(-kt) + b$	Amiri Chayjan <i>et al.</i> , 2017	0.0138	0.9974	0.149	0.0074	0.9986	0.109
Two-term	$MR = a \exp(kt) + b \exp(k_1t)$	Akpınar and Toraman, 2016	0.0123	0.9979	0.132	0.0064	0.9988	0.092
Midilli <i>et al.</i>	$MR = a \exp(-kt^n) + bt$	Khoshtaghaza <i>et al.</i> , 2015	0.0064	0.9990	0.072	0.0020	0.9993	0.046

ضریب تبیین ($R^2=0/9994$)، کمترین ریشه خطای مربعات میانگین

مدل Page برای پیش‌بینی خشک‌کردن سیر بیشترین مقدار

داده شدند. تعداد نرون های پنهان با اضافه شدن در لایه های پنهان به جای x و y با استفاده از معماری $3-y-x-1$ و $3-y-1$ به ترتیب برای شبکه با یک و دو لایه پنهان تغییر داده شدند. برای دستیابی به ساختار بهینه شبکه های عصبی مصنوعی (ANNs) برای پیش بینی نسبت رطوبت برای محصولات سیر و موسیر، شبکه هایی با آرایش های مختلف و تعداد نرون های متفاوت در لایه (های) میانی مورد ارزیابی قرار گرفتند. چندین آرایش از RMSE کمتر و R^2 بالاتری برخوردار بودند که در قالب دو ساختار پیش رو (CFBP) و پیش خور (FFBP) در جدول ۴ برای خشک کن بستر سیال ارائه شده است. در پیش بینی نسبت رطوبت سیر برای داده های آموزش، استفاده از الگوریتم آموزش LM به همراه شبکه FFBP با توپولوژی $3-7-7-1$ ، با تابع فعال سازی TAN-TAN-PUR و چرخه آموزش ۱۷۷ دارای کمترین مقدار ریشه میانگین مربعات خطا ($0/0036$) و بیشترین مقدار ضریب تبیین ($0/9994$) است.

($RMSE=0/0051$) و میانگین مطلق خطا ($MAE=0/053$) به دست آمد. مدل Midilli و همکاران برای خشک کردن موسیر بیشترین مقدار ضریب تبیین ($R^2=0/9993$)، کمترین ریشه خطای مربعات میانگین ($RMSE=0/002$) و میانگین مطلق خطا ($MAE=0/046$) به دست آمد. (Amiri Chayjan and Kaveh, 2014) مدل Logistic را برای پیش بینی نسبت رطوبت بنه در یک خشک کن بستر سیال پیشنهاد دادند. Khoshtaghaza و همکاران (۲۰۱۵) برای پیش بینی نسبت رطوبت سویا در یک خشک کن بستر سیال - مایکروویو مدل Page را به عنوان بهترین مدل انتخاب کردند.

شبکه های عصبی مصنوعی برای پیش بینی نسبت رطوبت
شبکه های عصبی پس انتشار پیش رو و پیش خور برای پیش بینی نسبت رطوبت استفاده شدند. الگوریتم ها با استفاده از نگاشت غیر خطی بین پارامترهای ورودی (سرعت هوای ورودی، دمای هوای ورودی و زمان خشک کردن) و پارامترهای خروجی (نسبت رطوبت) آموزش

جدول ۴- نتایج روش های مختلف ANN در برآورد نسبت رطوبت سیر و موسیر

Table 4- The results of the different arrangements of ANN in estimating moisture ratio of garlic and shallot

Product	Network	Training algorithm	Threshold function	Number of layers and neurons	Test			Train			Epoch
					RMSE	R^2	MAE	RMSE	R^2	MAE	
Garlic	FFBP	LM	TAN-TAN-PUR	3-7-7-1	0.0036	0.9994	0.044	0.0042	0.9993	0.056	177
Shallot	CFBP	LM	TAN-TAN-LOG	3-20-20-1	0.0014	0.9996	0.038	0.0038	0.9994	0.049	135

ورودی، سرعت هوای ورودی و زمان خشک کردن) و یک خروجی (نسبت رطوبت) انجام شد. به این ترتیب، قوانین فازی برای ورودی و خروجی های متغیر تعریف شد به طور کلی، ۸۱ قوانین اگر- سپس با اپراتور برای خشک کردن لایه نازک سیر و موسیر در خشک کن بستر سیال تحت دما هوای ورودی، سرعت هوای ورودی و زمان خشک کردن استفاده شد. توابع عضویت مثلثی برای تنظیم برخی از تغییرات در چهار متغیر (دما هوای ورودی، سرعت هوای ورودی، زمان خشک کردن و نسبت رطوبت) استفاده شد.

پس از مدل سازی تکمیل شده توسط منطق فازی، عملکرد مدل فازی با استفاده از معیارهای مختلف آماری ($RMSE$ ، R^2 و MAE) مورد بررسی قرار گرفت. با توجه به جدول ۵ نتایج نشان داد که، در پیش بینی نسبت رطوبت با مدل منطق فازی، به ترتیب $R^2=0/9997$ و $R^2=0/9998$ برای سیر و موسیر به دست آمد. همچنین مقدار $RMSE=0/0027$ برای سیر و $RMSE=0/0011$ برای موسیر محاسبه شد.

همچنین برای پیش بینی داده های آموزش نسبت رطوبت موسیر بهترین نتیجه در الگوریتم آموزش LM به همراه شبکه CFBP، توپولوژی $3-20-20-1$ ، با تابع فعال سازی TAN-TAN-LOG و چرخه آموزش ۱۳۵ دارای کمترین ریشه میانگین مربعات خطا ($0/0014$) و بیشترین مقدار ضریب تبیین ($0/9996$) به دست آمد. برای پیش بینی نسبت رطوبت آویشن با استفاده از شبکه های عصبی مصنوعی مقدار ضریب تبیین ($0/9999$) و ریشه میانگین مربعات خطا ($0/0035$) به دست آمد (Sarimeseli et al., 2014). همچنین برای پیش بینی نسبت رطوبت شلغم با استفاده از شبکه های عصبی مصنوعی مقدار ضریب تبیین ($0/9990$) و میانگین مربعات خطا ($0/0007$) محاسبه شد (Kaveh and Amiri Chayjan, 2017).

نتایج به دست آمده از مدل سازی با استفاده از منطق فازی
شیبه سازی نسبت رطوبت با استفاده از رویکرد سیستم استنتاج مددانی در MATLAB تحت اگر- سپس با سه ورودی (دما هوای

پایین‌تر باشند مدل عملکرد بهتری خواهد داشت. برای مثال، اگر $R^2 = 1.00$ و $RMSE = 0$ باشد آن‌گاه آن مدل بسیار عالی خواهد بود (Hasanipanah *et al.*, 2016). از مقایسه شاخص‌های آماری در جدول ۶ شاخص RMSE برای پیش‌بینی نسبت رطوبت در سیر (۰/۰۰۵۱) برای مدل ریاضی Page، (۰/۰۰۳۶) برای شبکه‌های عصبی مصنوعی و (۰/۰۰۲۷) برای منطق فازی) و برای موسیر (۰/۰۰۲۰) برای مدل ریاضی Midilli *et al.* (۰/۰۰۱۴) برای شبکه‌های عصبی مصنوعی و (۰/۰۰۱۱) برای منطق فازی) محاسبه شد. همچنین، مقدار R^2 برای پیش‌بینی نسبت رطوبت در سیر (۰/۹۹۹۲) برای مدل Page، (۰/۹۹۹۴) برای شبکه‌های عصبی مصنوعی و (۰/۹۹۹۷) برای منطق فازی) و برای موسیر (۰/۹۹۹۳) برای مدل Midilli *et al.*، (۰/۹۹۹۶) برای شبکه‌های عصبی مصنوعی و (۰/۹۹۹۸) برای منطق فازی) به‌دست آمد.

جدول ۵- نتایج منطق فازی در برآورد نسبت رطوبت سیر و موسیر

Table 5- The results of the different arrangements of fuzzy logic in estimating moisture ratio of garlic and shallot

Product	RMSE	R ²	MAE
Garlic	0.0027	0.9997	0.032
Shallot	0.0011	0.9998	0.029

توکلی‌پور و همکاران (۲۰۱۴) برای پیش‌بینی نسبت رطوبت کدو با استفاده از سیستم منطق فازی مقدار $R^2 = 0.919$ و $RMSE = 0.0662$ را به‌دست آوردند. جعفری و همکاران (۲۰۱۶) مقدار $R^2 = 0.9971$ با استفاده از سیستم منطق فازی برای پیش‌بینی نسبت رطوبت پیاز را محاسبه کردند.

مقایسه بین مدل‌های ریاضی، شبکه‌های عصبی مصنوعی و منطق فازی

در صورتی که شاخص‌های عملکرد دارای R^2 بالاتر و RMSE

جدول ۶- مقایسه روش‌های مختلف (مدل‌های ریاضی، ANN و Fuzzy) برای پیش‌بینی نسبت رطوبت

Table 6- Comparing the different method (mathematical model, ANN, and Fuzzy) used to predict the moisture ratio

Performance index	Garlic		Shallot			
	Page model	ANN	Fuzzy	Midilli <i>et al</i> model	ANN	Fuzzy
RMSE	0.0051	0.0036	0.0027	0.0020	0.0014	0.0011
R ²	0.9992	0.9994	0.9997	0.9993	0.9996	0.9998
MAE	0.053	0.044	0.032	0.046	0.038	0.029

ورودی، دمای هوای ورودی و زمان خشک کردن) استفاده شد (Muzzammil and Ayyub, 2010). اما در روش مدل‌های ریاضی که فقط زمان خشک کردن به‌عنوان ورودی وجود دارد به هر یک از زمان‌های خشک کردن میزان ۱۰٪ اضافه و کم شد. نتایج تجزیه و تحلیل حساسیت برای پارامترهای ورودی بر اساس داده‌های گروه‌بندی شده در جدول ۷ و ۸ به‌ترتیب برای سیر و موسیر نشان داده شده است. همچنین نتایج تجزیه و تحلیل حساسیت برای مدل‌های ریاضی در جدول ۹ نشان داده شده است. با توجه به جدول ۷ و ۸، زمان خشک کردن و سرعت هوای ورودی به‌ترتیب بیشترین کمترین تاثیر را بر نسبت رطوبت در هر دو محصول سیر و موسیر در شبکه‌های عصبی مصنوعی و منطق فازی داشتند. با توجه به جدول ۹، افزایش ۱۰ درصدی زمان خشک کردن برای هر دو محصول تاثیر بیشتری بر حساسیت نشان داد.

همانطور که از این نتایج دیده می‌شود، دقت پیش‌بینی منطق فازی از شبکه‌های عصبی مصنوعی و مدل‌های ریاضی خشک کردن در پیش‌بینی نسبت رطوبت سیر و موسیر با توجه به شاخص‌های آماری بهتر است. از این رو، پیش‌بینی نسبت رطوبت سیر و موسیر با استفاده از منطق فازی بهتر از ANN و مدل‌های ریاضی است.

تجزیه و تحلیل میزان حساسیت

آزمایش‌های حساسیت معمولاً برای تعیین اهمیت نسبی هر یک از پارامترهای مستقل بر روی پارامترهای وابسته برای اطمینان انجام می‌شود. تمام پارامترها مستقل به نوبه خود در تجزیه و تحلیل حساسیت مورد توجه قرار می‌گیرند.

برای به‌دست آوردن میزان حساسیت هر یک از پارامترهای ورودی روی میزان نسبت رطوبت در شبکه‌های عصبی مصنوعی و منطق فازی از روش حذف هر یک از ورودی‌ها (سرعت هوای

جدول ۷- تجزیه و تحلیل پارامترهای غیرمستقیم مستقل برای پیش‌بینی نسبت رطوبت سیر

Table 7- Sensitivity analyses of the non-dimensional independent parameters for predication of moisture ratio of garlic

Inputs	ANN			Fuzzy		
	RMSE	R ²	MAE	RMSE	R ²	MAE
All	0.0036	0.9994	0.044	0.0027	0.9997	0.032
Without air velocity	0.0052	0.9991	0.062	0.0045	0.9994	0.041
Without air temperature	0.0074	0.9988	0.088	0.0069	0.9990	0.078
Without drying time	0.0088	0.9986	0.094	0.0081	0.9988	0.088

جدول ۸- تجزیه و تحلیل پارامترهای غیرمستقیم مستقل برای پیش بینی نسبت رطوبت موسیر

Table 8- Sensitivity analyses of the non-dimensional independent parameters for predication of moisture ratio of shallot

Inputs	ANN			Fuzzy		
	RMSE	R ²	MAE	RMSE	R ²	MAE
All	0.0011	0.9998	0.029	0.0014	0.9996	0.038
Without air velocity	0.0019	0.9996	0.041	0.0025	0.9993	0.052
Without air temperature	0.0044	0.9992	0.060	0.0052	0.9991	0.066
Without drying time	0.0062	0.9989	0.082	0.0074	0.9990	0.087

جدول ۹- تجزیه و تحلیل پارامتر زمان برای پیش بینی نسبت رطوبت سیر و موسیر در مدل های ریاضی

Table 9- Analysis the drying time parameter to predict the moisture content of garlic and shallot in mathematical models

Inputs	Garlic			Shallot		
	RMSE	R ²	MAE	RMSE	R ²	MAE
All	0.0051	0.9992	0.053	0.0020	0.9993	0.046
Increased by 10%	0.0061	0.9989	0.075	0.0035	0.9990	0.063
Decreased by 10%	0.0057	0.9990	0.069	0.0028	0.9992	0.057

نتیجه گیری

از دو شبکه (Demir *et al.*, Two-term and Midilli *et al.*), از دو شبکه FFBP و CFBP با الگوریتم های LM و BR و همچنین از سیستم استنتاجی فازی ممدانی و به کارگیری تابع عضویت مثلثی برای پیش بینی نسبت رطوبت سیر و موسیر در خشک کن بستریال استفاده شد. نتایج نشان داد که مدل Fuzzy logic برای هر دو محصول دارای پایین ترین مقدار (RMSE) و بالاترین مقدار (R²) بود. بنابراین مدل Fuzzy logic برای پیش بینی نسبت رطوبت سیر و موسیر نسبت به مدل های ریاضی و شبکه های عصبی مصنوعی عملکرد بهتری داشت.

رفتار خشک شدن سیر و موسیر به صورت لایه نازک در خشک کن بستر سیال سه دمای هوای ورودی (۴۰، ۵۵ و ۷۰°C) سه سرعت هوای ورودی (۰/۵، ۱/۵ و ۲/۵ m s⁻¹) بررسی شد. نتایج نشان داد با افزایش دمای هوای ورودی، زمان خشک شدن سیر و موسیر کاهش می یابد. کمترین زمان خشک شدن مربوط به دمای ۷۰°C و سرعت هوای ورودی ۲/۵ ms⁻¹ بود. برای پیش بینی نسبت رطوبت، از مدل های ریاضی، شبکه های عصبی مصنوعی و منطق فازی استفاده شد. از ۵ مدل ریاضی (, Logarithmic, Page

References

- Adak, N., N. Heybeli, and C. Ertekin. 2017. Infrared drying of strawberry. *Food Chemistry* 219: 109-116.
- Aghbashlo, M., R. Sotudeh-Gharebagh, R. Zarghami, A. S. Mujumdar, and N. Mostoufi. 2014. Measurement techniques to monitor and control fluidization quality in fluidized bed dryers: A review. *Drying Technology* 32: 1005-1051.
- Akpınar, E. K., and S. Toraman. 2016. Determination of drying kinetics and convective heat transfer coefficients of ginger slices. *Heat and Mass Transfer* 52 (10): 2271-2281.
- Amiri Chayjan, R., and M. Kaveh. 2014. Physical parameters and kinetic modeling of fix and fluid bed drying of terebinth seeds. *Journal of Food Processing and Preservation* 38: 1307-20.
- Amiri Chayjan, R., M. Kaveh, and S. Khayati. 2017. Modeling some thermal and physical characteristics of terebinth fruit under semi industrial continuous drying. *Journal of Food Measurement and Characterization* 11: 12-23.
- Bebartta, J. P., N. R. Sahoo, S. K. Dash, M. K. Panda, and U. S. Pal. 2014. Kinetics modeling and moisture diffusivity of onion slices in fluidized bed drying. *Journal of Food Processing and Preservation* 38 (1): 193-199.
- Doymaz, I., H. Demir, and A. Yildirim. 2015. Drying of quince slices: effect of pretreatments on drying and Rehydration Characteristics. *Chemical Engineering Communication* 202 (10): 1271-1279.
- Foroughi-dahr, M., M. Golmohammadi, R. Pourjamshidiyan, M. Rajabi-hamaneh, and S. J. Hashemi. 2015. On the Characteristics of thin layer drying models for intermittent drying of rough rice. *Chemical Engineering Communication* 202 (8): 1024-1035.
- Gharibi, H., A. Hossein Mahvi, R. Nabizadeh, H. Arabilibeik, M. Yunesian, and M. H. Sowlat. 2012. A novel approach in water quality assessment based on fuzzy logic *Journal of Environmental Management* 112: 87-95.

10. Hasanipanah, M., D. J. Armaghani, H. Khamesi, S. B. Amnieh, and S. Ghoraba. 2016. Several non-linear models in estimating air-overpressure resulting from mine blasting. *Engineering with Computer* 32 (3): 441-455.
11. Jafari, S. M., M. Ganje, D. Dehnad, and V. Ghanbari. 2016. Mathematical, fuzzy logic and artificial neural network modeling techniques to predict drying kinetics of onion. *Journal of Food Processing and Preservation* 40 (2): 329-339.
12. Kaleta, A., K. Górnicki, R. Winiczenko, and A. Chojnacka. 2013. Evaluation of drying models of apple (var. Ligol) dried in a fluidized bed dryer. *Energy Conversion and Management* 67: 179-185.
13. Kantrong, H., A. Tansakul, and G. S. Mittal, 2014. Drying characteristics and quality of shiitake mushroom undergoing microwave-vacuum drying and microwave-vacuum combined with infrared drying. *Journal of Food Science and Technology* 51 (12): 3594-3608.
14. Kaveh, M., and R. Amiri Chayjan. 2017. Modeling thin-layer drying of turnip slices under semi-industrial continuous band dryer. *Journal of Food Processing and Preservation* 41 (2): e12778.
15. Kaveh, M., R. Amiri Chayjan, and A. M. Nikbakht. 2017. Mass transfer characteristics of eggplant slices during length of continuous band dryer. *Heat and Mass Transfer* 53: 2045-2059.
16. Khanali, M., A. Banisharif, and Sh. Rafiee. 2016. Modeling of moisture diffusivity, activation energy and energy consumption in fluidized bed drying of rough rice. *Heat and Mass Transfer* 52 (11): 2541-2549.
17. Khoshtaghaza M. H., H. Darvishi, and S. Minaei. 2015. Effects of microwave- fluidized bed drying on quality, energy consumption and drying kinetics of soybean kernels. *Journal of Food Science and Technology* 52 (8): 4749-4760.
18. Kouchakzadeh, A. 2014. Drying kinetic and shrinkage circumstance of Persian shallot bulb. *Agriculture Engineering International. CIGR Journal* 16 (2): 176-180.
19. Mahani, M. N. Z., and M. H. Aghkhani. 2016. The effect of slicing type on drying kinetics and quality of dried carrot. *Journal of Agricultural Machinery* 6 (1): 224-235. (In Farsi).
20. Mohamed, M. T. 2011. Performance of fuzzy logic and artificial neural network in prediction of ground and air vibrations. *International Journal of Rock Mechanics and Mining Sciences* 48: 845-851.
21. Momenzadeh, L., A. Zomorodian, and D. Mowla. 2011. Experimental and theoretical investigation of shelled corn drying in a microwave-assisted fluidized bed dryer using artificial neural network. *Food and Bioproducts Processing* 89: 15-21.
22. Murthy, T. P. K., and B. Manohar. 2014. Hot air drying characteristics of mango ginger: Prediction of drying kinetics by mathematical modeling and artificial neural network. *Journal of Food Science and Technology* 51 (12): 3712-3721.
23. Muzzammil, M., and M. Ayyub, 2010. ANFIS-based approach for scour depth prediction at piers in non-uniform sediments. *Journal of Hydroinformatics* 12 (3): 303-317.
24. Nazghelichi, T., M. H. Kianmehr, and M. Aghbashlo. 2011. Prediction of carrot cubes drying kinetics during fluidized bed drying by artificial neural network. *Journal of Food Science and Technology* 48 (5): 542-550.
25. Oberoi, D. P. S., and D. S. Sogi. 2015. Drying kinetics, moisture diffusivity and lycopene retention of watermelon pomace in different dryers. *Journal of Food Science and Technology* 52 (11): 7377-7384.
26. Puspasari, I., M. Z. M. Talib, W. R. W. Daud, and S. M. Tasirin. 2012. Drying kinetics of oil palm frond particles in an agitated fluidized bed dryer. *Drying Technology* 30: 619-630.
27. Samadi, S. H., B. Ghobadian, G. Najafi, A. Motevali, and S. Faal. 2013. Drying of apple slices in combined heat and power (CHP) dryer: Comparison of mathematical models and neural networks. *Chemical Product and Process Modeling* 8 (1): 41-52.
28. Sarimeseli, A., M. A. Coskun, and M. Yuceer. 2014. Modeling microwave drying kinetics of thyme (*Thymus Vulgaris* L.) leaves using ANN methodology and dried product quality. *Journal of Food Processing and Preservation* 38 (1): 558-564.
29. Sharma, G. P., S. Prasad, and V. K. Chahar. 2009. Moisture transport in garlic cloves undergoing microwave-convective drying. *Food and Bioproducts Processing* 87: 11-16.
30. Silva, B. G. D., A. M. F. Fileti, and O. P. Taranto. 2015. Drying of Brazilian pepper-tree fruits (*Schinus terebinthifolius* Raddi): development of classical models and artificial neural network approach. *Chemical Engineering Communication* 202: 1089-1097.
31. Tavakolipour, H., M. Mokhtarian, and A. Kalbasi-Ashtari. 2014. Intelligent monitoring of zucchini drying process based on fuzzy expert engine and ANN. *Journal of Food Process Engineering* 37 (5): 474-481.
32. Zadeh, L. 1965. Fuzzy sets, *Inform. Control* 8: 338-353.

Comparison of Mathematical Modeling, Artificial Neural Networks and Fuzzy Logic for Predicting the Moisture Ratio of Garlic and Shallot in a Fluidized Bed Dryer

M. Kaveh^{1*}- Y. Abbaspour-Gilandeh¹- R. Amiri Chayjan²- R. Mohammadigol³

Received: 10-07-2017

Accepted: 02-01-2018

Introduction

Garlic (*Allium sativum* L.) is an important Allium crop in the world. Due to its therapeutic properties, it was cultivated in many countries. Furthermore, garlic is usually used as a flavoring agent; it may be used in the shape of powder or granule as a valuable condiment for foods. In addition to its use in food products, it was also widely used as an anticancer agent. Shallot (*Allium hiertifolium* Boiss. L) is a perennial and bulbous plant. It is from Alliaceae family and is an important medicinal plant. The shallot is native of Iran, and grows in the high pastures. Shallot is consumed in dry areas in most parts of the country. Also shallots have been well known in Iranian folk medicine and its bulbs have been widely used for treating rheumatic and inflammatory disorders. In addition, this plant is used in the preparation of significant amounts of potassium, phosphorus, calcium, magnesium, sodium, pickles and as an additive to yogurt and pickles. ANN as a modern approach has successfully been used to solve an extensive variety of problems in the science and engineering, exclusively for some space where the conventional modeling procedure fail. A well-trained ANN can be used as a predictive model for a special use, which is a data processing system inspired by biological neural system. When mathematical equations are difficult to extrapolate, and fuzzy logic is better when decisions must be made with the estimated values below the incomplete information. The fuzzy logic theory effectively addresses the uncertainty problems that solve the ambiguity.

Materials and Methods

The aim of this study was to predict moisture ratio of garlic and shallot during the drying process with fluidized bed dryer using mathematical model, artificial neural networks and fuzzy logic methods. Tests were carried out on three levels of inlet air temperature (40, 55 and 70 °C) and three inlet air velocities (0.5, 1.5 and 2.5 m/s). To estimate the drying kinetic of garlic and shallot, five mathematical models were used to fit the experimental data of thin layer drying. Three factors (air temperature, air velocity and drying time) to forecast moisture ratio in fluidized bed dryer as independent variables for artificial neural networks and fuzzy logic was considered. Cascade forward back propagation (CFBP) and feed forward back propagation (FFBP) with Levenberg-Marquardt (LM), Bayesian learning (BR) algorithms for ANN and the Mamdani Fuzzy Inference System using triangular membership function were used for training patterns.

Results and Discussion

Consequently, the Page and Midilli *et al.* model was selected as the best mathematical model to describe the drying kinetics of the garlic and shallot slices, respectively. The results of artificial neural networks model for predicting MR showed that the R^2 of 0.9994 and 0.9996; and and RMSE of 0.0036 and 0.0014 were obtained for garlic and shallot, respectively. Also, The fuzzy inference system presented the R^2 of 0.9997 and 0.9998; and and RMSE of 0.0027 and 0.0011 for garlic and shallot, respectively. Comparing the results obtained from mathematical models, artificial neural networks and fuzzy logic, showed that the RMSE in the fuzzy logic was lower than artificial neural network and mathematical models.

Conclusions

Three factors (air temperature, air velocity and drying time) were considered for forecasting moisture ratio in fluidized bed dryer as independent variables using mathematical model, artificial neural networks and fuzzy logic. Cascade forward back propagation (CFBP) and feed forward back propagation (FFBP) with Levenberg-

1- Department of Biosystems Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran

2- Department of Biosystems Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

3- Department of Biosystems Engineering, Faculty of Agriculture and Natural Resources, Arak University, Arak, Iran

(*- Corresponding Author Email: sirwankaweh@uma.ac.ir)

Marquardt (LM), Bayesian learning (BR) algorithms and the Mamdani Fuzzy Inference System using triangular membership function were used for training the patterns. Comparing the results obtained from mathematical models, artificial neural networks and fuzzy logic, showed that the root mean square error in fuzzy logic was lower than others.

Keywords: Artificial neural network, Fluidized bed dryer, Fuzzy logic, Garlic and Shallot, Moisture ratio

