

کاربرد روش ترکیبی سطح پاسخ و شبکه‌ی عصبی مصنوعی در پیش بینی سینتیک خشک کردن یک ماده‌ی غذایی تحت شرایط مختلف خشک کردن

محسن مختاریان^۱، مسعود شفافی زنونیان^۲، محمد آرمین^۳، فاطمه کوشکی^۴

^۱ عضو باشگاه پژوهشگران جوان، دانشگاه آزاد اسلامی، واحد سبزوار، سبزوار، ایران

^۲ استادیار گروه علوم و صنایع غذایی، دانشگاه آزاد اسلامی واحد سبزوار، سبزوار، ایران

^۳ استادیار گروه کشاورزی، دانشگاه آزاد اسلامی واحد سبزوار، سبزوار، ایران

^۴ دانش آموخته‌ی کارشناسی علوم و صنایع غذایی، دانشگاه آزاد اسلامی، واحد سبزوار، سبزوار، ایران

تاریخ پذیرش: ۹۰/۷/۳

تاریخ دریافت: ۹۰/۵/۲

چکیده

خشک کردن مواد غذایی به عنوان روشی جهت بهبود ماندگاری، ارائه شده است. به منظور پیش این فرایند از مدل‌های مختلف شبکه‌ی عصبی نظیر شبکه‌ی عصبی پرسپترون، تابع پایه‌ی شعاعی و مدل ترکیبی شبکه‌ی عصبی و روش شناسی سطح پاسخ به همراه توابع فعال سازی مختلف به عنوان یک ابزار پیش بینی کننده‌ی پارامترهای خشک کردن کدوی سبز استفاده گردید. پارامترهای زمان خشک کردن، دمای هوای خشک کردن و ضخامت نمونه به عنوان ورودی شبکه و از طرف دیگر، عدد فوریه، انرژی اکتیواسیون، ضریب انتشار رطوبت و چروکیدگی به عنوان خروجی شبکه در نظر گرفته شد. نتایج مدلسازی نشان داد که مدل شبکه‌ی عصبی پرسپترون همراه با تابع محرک لوگ سیگموئید- لوگ سیگموئید به عنوان بهترین تابع محرک مدل، توانست مقادیر انرژی اکتیواسیون، عدد فوریه، چروکیدگی و ضریب انتشار رطوبت را به ترتیب با ضرایب رگرسیون ۰/۹۹۹، ۰/۹۹۲، ۰/۹۹۹ و ۰/۹۹۱ پیش بینی نماید.

واژه‌های کلیدی: خشک کردن، پیش بینی، شبکه‌ی عصبی پرسپترون.

۱- مقدمه

کدو، گیاهی است یک ساله و خزنده که برگ‌های آن به شکل قلب و پهن و پوشیده از کرک ریز می‌باشد و دارای گل‌های زرد رنگ است و گل نر و گل ماده‌ی آن روی یک پایه قرار دارد (۶). ریشه‌ی آن باریک و بلند است. خشک کردن مواد غذایی و مشخصاً میوه‌ها و سبزیجات از زمان‌های بسیار دور به عنوان راهی جهت افزایش عمر ماندگاری آن‌ها معمول بوده و امروزه نیز به عنوان یکی از فرآیندهای مهم در صنایع غذایی مطرح می‌باشد. برخلاف سبزیجات تازه که فقط برای مدت کوتاهی و در شرایط خاصی نگه داری می‌شوند، فرآورده‌های خشک شده را می‌توان در مدت‌های طولانی، بدون کاهش ارزش غذایی نگه داری نمود. همچنین سبزیجات خشک شده به دلیل وزن توده‌ی کم به آسانی و راحتی حمل و نقل می‌شوند. در برخی مواد، خشک کردن سبب کاهش قابل توجهی در حجم شده و این سبب کاهش فضای مورد نیاز جهت نگه داری می‌گردد (۱۸). حفظ ارزش تغذیه‌ای و قابلیت و سرعت جذب آب مجدد محصول خشک شده دو پارامتری است که به عنوان شاخص کیفیت محصول مد نظر قرار می‌گیرند و هدف و هنر متخصصین صنایع غذایی ارائه و اجرای روش‌هایی است که به تولید محصول با کم‌ترین تغییرات ناخواسته و با بهترین کیفیت از نظر ارگانولپتیکی و تغذیه‌ای بینجامد. فرایند خشک شدن باید به آرامی و به صورت کاملاً یکنواخت انجام شود. لذا استفاده از خشک‌کن‌هایی که شرایط فرایند خشک شدن در آن‌ها قابل مهار باشد امری ضروری به نظر می‌رسد. به طور کلی برای مدل کردن پدیده‌های فیزیکی نظیر نسبت رطوبت محصولات کشاورزی دو رهیافت وجود دارد. یک روش استتاجی است، یعنی با استفاده از نظریه‌ها و فرمول‌های ریاضی نظیر قانون دوم فیک یا نوع ساده شده‌ی آن موسوم به قانون سرد شدن نیوتن رطوبت محصول مدل می‌شود. به عبارتی به صورت غیرمستقیم با استفاده از روابط و ضرایب ثابت مدلسازی انجام می‌شود (۸). به عنوان مثال، استفاده از مدل‌های خشک کردن محصولات کشاورزی مانند مدل نیوتن، پیچ، دو جمله‌ای، تقریب پخش و غیره که هر کدام دارای ثابت‌ها و ضرایب خاص خود می‌باشند. این رهیافت نسبتاً ساده است اما همواره با تقریب همراه بوده و از دقت پایینی برخوردار است. رهیافت دوم در مدل کردن پدیده‌های فیزیکی استفاده از روش‌های استتراجی است. در این روش، مدلسازی به صورت مستقیم انجام می‌شود بدون این


که از رابطه یا فرمولی در مدلسازی استفاده شود. مدلسازی رطوبت توسط شبکه‌های عصبی مصنوعی جزء روش‌های استتراجی (مستقیم) می‌باشد چون بدون استفاده از رابطه یا فرمولی فرآیند را مدلسازی می‌کنیم. از مزایای این روش، کشف روابط نهفته و اغلب غیر خطی بین متغیرهای وابسته و مستقل فرآیند تحت بررسی و قابلیت تعمیم آن است. تاکنون محققین زیادی از شبکه‌های عصبی مصنوعی برای پیش بینی پارامترهای مورد نظر در خشک‌کن‌ها استفاده کرده‌اند که در زیر به برخی از آن‌ها اشاره می‌کنیم. گوئین و همکاران (۲۰۱۰) خشک کردن به روش جا به جایی برای کدوی حلوائی مطالعه کردند. نتایج، نشان داد که افزایش دمای فرآیند خشک کردن را شتاب می‌بخشد به طوری که زمان فرآیند در دمای ۳۰ درجه‌ی سانتی گراد ۸ ساعت به طول می‌انجامد و در دمای ۷۰ درجه‌ی سانتی گراد فرایند در زمان ساعت به اتمام می‌رسد. نتایج داده‌های آزمایشگاهی در این پژوهش توسط مدل‌های دینامیکی برازش داده شده و مدل پیچ به عنوان مدل مناسب برای این فرآیند انتخاب گردید (۱۳). دویمز و همکاران (۲۰۰۷) سینتیک خشک کردن جا به جایی اجباری هوای برش‌های کدوی حلوائی را مورد مطالعه قرار دادند. نتایج، نشان داد که مدل لگاریتمی و ورما به عنوان بهترین مدل توصیف کننده رفتار خشک کردن کدوی حلوائی انتخاب شدند (۱۱). پیندو و همکاران (۲۰۰۶) سینتیک خشک کردن تحت خلاء کدوی حلوائی را با چروکیدگی مدل سازی کردند. نتایج، نشان داد که انجماد تاثیر بیش تری نسبت به آنزیم بری داشت. همچنین نتایج، حاکی از آن بود که انتشار مؤثر رطوبت نمونه پیش تیمار شده با انجماد و فشار در طی خشک کردن با خلاء افزایش می‌یابد و برعکس با دما کاهش می‌یابد (۲۰). علیاس (۲۰۰۷) خشک کردن ترکیبی هوا-مایکروویو برش‌های کدوی حلوائی را مورد مطالعه قرار دادند. نتایج، نشان داد که بهینه ترین دوره‌ی خشک کردن، رنگ و مصرف انرژی زمانی به دست آمد هوا داغ و مایکروویو به طور همزمان استفاده گردید و بهترین حالت زمانی بود که توان ۳۵۰ وات و ۵۰ درجه‌ی سانتی گراد بود (۵). گوئین^۱ و همکاران (۲۰۱۱) تاثیر خشک کردن را بر روی بافت و رنگ کدو حلوائی و فلفل سبز مورد بررسی قرار دادند. نتایج، نشان داد که دمای ۳۰ نسبت به ۷۰ درجه‌ی سانتی گراد سبب تغییرات رنگ کم تری در

نشده، لذا تحقیق حاضر، جهت بررسی فرآیند سینتیک خشک کردن این محصول مورد پژوهش قرار گرفت.

۲- مواد و روش‌ها

۲-۱- آماده‌سازی نمونه

در این تحقیق، نمونه‌های کدوی سبز تازه از بازار محلی تهیه گردید. سپس از لحاظ رنگ، قطر و وزن درجه بندی گردید. کلیه‌ی نمونه‌ها جهت کاهش میزان شدت تنفس و تغییرات فیزیولوژیکی و شیمیایی در یخچال با دمای ۵ تا ۶ درجه‌ی سانتی‌گراد نگه‌داری شد. در ابتدای هر آزمایش، نمونه‌های کدوی سبز شسته و سپس توسط یک چاقوی تیز و تخته‌ای از جنس پلی‌اتیلن در سه ضخامت ۳، ۵ و ۷ میلی‌متر ورقه‌ورقه و توسط یک کولیس (مدل ورتکس^۱، M502، با درجه بندی ۰/۰۱ میلی‌متر) ابعاد کنترل گردید (شکل ۱). کدوی سبز مورد استفاده دارای رطوبت اولیه ۱۳/۳۸ درصد (مبنای خشک) بود. رطوبت اولیه‌ی نمونه‌ها از طریق قرار دادن نمونه‌ها در آون اتمسفریک و در دمای ۱۰۵ درجه‌ی سانتی‌گراد به مدت ۴۸ ساعت تا دستیابی به وزن ثابت اندازه‌گیری شدند (۷).



شکل ۱ - ساختار شماتیک برش‌های کدوی سبز، Z ، ضخامت نمونه و D ، قطر نمونه.

۲-۲- تجهیزات خشک کردن

در این مطالعه از یک دستگاه خشک‌کن آزمایشگاهی استفاده گردید. خشک‌کن شامل یک فن‌گریز از مرکز، محفظه‌ی خشک‌کن به همراه سینی و مجرای عبوری هوا بود. ساختار خشک‌کن فوق در شکل ۲، نشان داده شده است. خشک‌کن ۳۰ دقیقه قبل از انجام فرآیند خشک کردن به منظور ایجاد شرایط پایا در طول فرآیند روشن و سپس بارگذاری گردید. جهت کنترل دمای خشک‌کن از صفحه‌ی نمایشگر کامپیوتری خشک‌کن استفاده

فلفل سبز شد. همچنین اندیس کروما^۱ کدو حلوایی کاهش معناداری را در خشک کردن انجمادی داشت (۱۴). جامبک و همکاران (۲۰۰۷) خشک کردن قارچ دکمه‌ای، کلم بروکسل و گل کلم را از طریق به کارگیری اولتراسوند تسریع بخشیدند. نتایج، نشان داد که پیش‌تیمار اولتراسوند سبب کاهش زمان خشک کردن در تمام نمونه‌ها گردید. همچنین ویژگی‌های آبیگری مجدد برای نمونه‌های تیمار شده با اولتراسوند بالاتر از نمونه‌های بدون تیمار بود (۱۵). پونوی و همکاران (۲۰۰۶) مدل سازی شبکه‌ی عصبی مصنوعی برای پیش‌بینی محتوی رطوبتی و دما را در برش‌های گوجه‌فرنگی با کمک خشک‌کن مایکروویو-خلا، مورد بررسی قرار دادند. نتایج، نشان داد که مدل شبکه‌ی عصبی با دو لایه‌ی پنهان و در هر لایه ۲۵ نرون به عنوان بهترین شبکه، تعیین گردید. مقادیر میانگین خطای نسبی و میانگین خطای مطلق برای دما به ترتیب ۱/۵۳ درصد و ۰/۷۷ بود (۲۱). منلیک و همکاران (۲۰۱۰) رفتار خشک کردن انجمادی سیب را از طریق شبکه‌ی عصبی مصنوعی مورد بررسی قرار دادند. در این پژوهش، محتوی رطوبتی، نسبت رطوبت و آهنگ خشک کردن سیب تخمین زده شد. نتایج، نشان داد که شبکه‌ی عصبی مصنوعی توانست محتوی رطوبتی، نسبت رطوبت و آهنگ خشک کردن را به ترتیب با ضرایب تبیین ۰/۹۹۹، ۰/۹۹۹ و ۰/۹۹۹ تخمین زد (۱۶). مؤمن زاده و همکاران (۲۰۱۰) خشک کردن مایکروویو-بستر سیال پوست ذرت را توسط شبکه‌ی عصبی مصنوعی مورد بررسی قرار دادند. نتایج، نشان داد که شبکه با تابع عملکرد تانژانت سیگموئید و پس‌انتشار بیش‌ترین دقت را در پیش‌بینی خشک کردن پوست ذرت داشت (۱۷).

هدف از این پژوهش، پیش‌بینی پارامترهای سینتیک خشک کردن لایه‌ای نازک کدوی سبز با کمک مدل‌ها و توابع فعال سازی مختلف شبکه‌ی عصبی مصنوعی بود. علاوه بر این، در این پژوهش از تکنیک بهینه‌سازی همزمان روش شناسی سطح پاسخ و شبکه‌ی عصبی مصنوعی برای تخمین پارامترهای عدد فوریه، انرژی اکتیواسیون، ضریب انتشار مؤثر و چروکیدگی استفاده گردید. استفاده از تکنیک ترکیبی شبکه‌ی عصبی مصنوعی و روش شناسی سطح پاسخ امروزه به عنوان یک ابزار جدید برای پیش‌بینی مورد استفاده قرار گرفته و با توجه به این که تاکنون هیچ گونه فعالیت تحقیقاتی راجع به خشک کردن کدوی سبز انجام

رطوبت به کار می‌رود (۱۰ و ۲۲).

$$\frac{\partial X}{\partial t} = D_{eff} \frac{\partial^2 X}{\partial x^2} \quad (2)$$

که در آن X مقدار رطوبت موضعی در مبنای خشک، t زمان و x مختصه‌ی فضایی^۲ می‌باشد. معادله‌ی انتشاری قانون دوم فیک بر انتشار جرم در طی دوره‌ی سرعت نزولی خشک کردن محصولات کشاورزی دلالت دارد (۲۲). برای به کار بردن قانون فیک فرض می‌گردد که فرآورده‌ی غذایی تک بعدی است، رطوبت اولیه‌ی یکنواختی دارد و دارای حرکت درونی رطوبت به مثابه‌ی مقاومت اصلی در برابر انتقال رطوبت است. متاسفانه در نظریه‌ی انتشار، چروکیدگی، سخت شدن سطحی یا ایزوترم‌های جذب در نظر گرفته نمی‌شود (۴).

حل معادله‌ی فیک برای یک تیغه^۳ به صورت زیر می‌باشد (رابطه‌ی ۳):

$$MR = \frac{m_t - m_e}{m_0 - m_e} = \frac{8}{\pi^2} \sum_{n=0}^{\infty} \frac{1}{(2n+1)^2} \exp\left(-\frac{\pi^2 D_{eff} t}{4L^2} (2n+1)^2\right) \quad (3)$$

ضریب نفوذ مؤثر از طریق محاسبه‌ی شیب معادله‌ی ۴ به دست می‌آید:

$$MR = \frac{m_t - m_e}{m_0 - m_e} = \frac{8}{\pi^2} \exp(-\pi^2 F_0) \quad (4)$$


در این معادله، F_0 عدد فوریه (بدون دیمانسیون) می‌باشد. وقتی که نمودار مقدار $\ln MR$ نسبت به زمان رسم گردد شیب خط به دست آمده را در معادله‌ی (۵) قرار داده تا ضریب نفوذ مؤثر به دست آید.

$$k_0 = \frac{\pi^2 D_{eff}}{4L^2} \quad (5)$$

که در آن، m_t میزان رطوبت در زمان t ، m_0 رطوبت اولیه، m_e مقدار رطوبت تعادلی، L نیم ضخامت تیغه (بر حسب متر)، D_{eff} ضریب نفوذ مؤثر (بر حسب متر مربع بر ثانیه)، t زمان (بر حسب ثانیه)، MR نسبت رطوبت (بدون بُعد) و k_0 شیب خط می‌باشد. ضریب نفوذ معمولاً با رسم داده‌های تجربی خشک کردن بر حسب $\ln MR$ نسبت به زمان تعیین می‌گردد. ضریب نفوذ مؤثر، همان شیب زاویه‌ی بخش خطی است. مقادیر انرژی اکتیواسیون نمونه در طی فرآیند خشک کردن با هوای داغ بر حسب معادله‌ی آرنیوس بیان می‌شود (روابط ۶ و ۷) (۲۲).

$$D_{eff}^0 = D^0 \exp\left(-\frac{E_a}{RT}\right) \quad (6)$$

$$\ln D_{eff}^0 = \ln D^0 + \frac{E_a}{R} \left(\frac{1}{T}\right) \quad (7)$$



شکل ۲ - ساختار شماتیک خشک کن سینی دار: (۱) خروجی هوا، (۲) محفظه‌ی خشک کن، (۳) درب خشک کن، (۴) جعبه‌ی فرمان، (۵) نمایش دهنده و (۶) سینی‌های خشک کن

گردید. نمونه‌ها به صورت یکنواخت بر روی سینی به صورت یک لایه‌ی نازک پخش گردید. وزن نمونه‌های توسط ترازوی دستگاه (AND Co., EK 300i, Tokyo, Japan) هر ۱۰ دقیقه یک بار ثبت گردید. آزمایش‌ها در سه دمای ۶۰، ۷۰ و ۸۰ درجه‌ی سانتی‌گراد و در رطوبت نسبی ۳۰ و ۴۰ درصد اندازه‌گیری شد. فرآیند خشک کردن تا رسیدن رطوبت نمونه به ۰/۲۵ (کیلوگرم آب/کیلوگرم مواد جامد) ادامه یافت. کلیه‌ی آزمایش‌ها در سه تکرار به منظور افزایش دقت آزمایش، انجام گرفت و میانگین مقادیر گزارش گردید.

۲-۳- مدل سازی ریاضی منحنی‌های خشک کردن

در این تحقیق، نسبت رطوبت خشک کردن کدوی سبز توسط معادله‌ی زیر محاسبه گردید:

$$MR = \frac{(m_t - m_e)}{(m_0 - m_e)} \quad (1)$$

در این معادله m_t مقدار رطوبت در زمان t ، m_0 مقدار رطوبت اولیه و m_e مقدار رطوبت تعادلی می‌باشد. مقدار رطوبت m_e در مقایسه با رطوبت‌های m_t یا m_0 بسیار ناچیز بوده و این مساله، سبب تشخیص راحت این دو از یکدیگر می‌گردد. نمونه‌ها در سه دمای ۶۰، ۷۰ و ۸۰ درجه‌ی سانتی‌گراد و سه ضخامت ۳، ۵ و ۷ میلی‌متر در خشک کن جا به جایی هوای داغ خشک گردید. در این تحقیق، رفتار کاهش رطوبت با گذشت زمان، مورد مطالعه قرار گرفت (۱۲). قانون فیک^۱ اغلب برای توصیف پدیده‌ی نفوذ

می‌گیرد، می‌باشد. در این شبکه، تعداد نرون‌های لایه ورودی برابر با تعداد عناصر بردار ورودی و تعداد نرون‌های لایه‌ی خروجی برابر با تعداد عناصر بردار خروجی می‌باشد. آنالیز دقیق و واقعی برای پیدا کردن تعداد نرون‌های لایه‌ی میانی در کل بسیار پیچیده است. اما می‌توان گفت که تعداد نرون‌های لایه‌ی میانی تابعی از عناصر برداری ورودی و همچنین حداکثر تعداد نواحی از فضای ورودی که به طور خطی از هم جدا پذیرند می‌باشد. از این رو، تعداد نرون‌های لایه‌ی مخفی عموماً به طور تجربی به دست می‌آید. هر نرون توسط خروجی خود به نرون‌های لایه‌ی بعد متصل می‌گردد، ولی با نرون‌های لایه‌ی خودش ارتباط ندارد. خروجی هر نرون توسط رابطه‌ی (۱۰) زیر تعریف می‌گردد:

$$a = f(\sum_{i=1}^n p_i w_{ji} + b_j) \quad (10)$$

در این رابطه، w_{ji} مقدار وزن اتصال بین نرون i لایه‌ی مذکور با نرون j لایه‌ی قبل است که بیانگر اهمیت ارتباط بین دو نرون در دو لایه‌ی متوالی می‌باشد، b_j وزن مربوط به بایاس^۲ برای نرون j ، p_i مقدار خروجی از نرون i لایه‌ی قبل، a مقدار خروجی از نرون j و f ، تابع آستانه‌ی نرون j است.

توابع زیادی در انتقال اعداد از لایه‌ی قبل به لایه‌ی بعد ممکن است مورد استفاده قرار گیرند. از جمله می‌توان به توابع زیگموئید، گوس، تانژانت هیپربولیک، تابع همانی^۳ و سکانت هیپربولیک را نام برد. ولی تابع زیگموئیدی بیشترین استفاده را در مسائل مهندسی دارد. این تابع به صورت زیر می‌باشد:

$$f(z) = \frac{1}{1 + \exp(-z)} \quad (11)$$

چیدمان شبکه‌ی عصبی به کار رفته در این پژوهش، شامل سه ورودی و چهار خروجی بود (رابطه‌ی ۱۲). ورودی‌ها شامل زمان خشک کردن، دمای هوای خشک کردن و ضخامت نمونه و خروجی‌ها شامل عدد فوریه، انرژی اکتیواسیون، ضریب انتشار رطوبت و چروکیدگی می‌باشد. چیدمان شبکه مذکور در شکل ۳، نشان داده شده است.

$$\text{Output} = f(T, t, z) \quad (12)$$

که در آن D_0 ضریب پیش‌نمایی معادله‌ی آرنیوس (m^2/s) ، E_a انرژی فعال سازی برای نفوذ رطوبت $(kJ/kmol)$ ، R ثابت جهانی گازهای ایده آل $(kJ/kmol.k)$ ، T دمای مطلق بر حسب کلونین می‌باشد. انرژی فعال سازی را می‌توان با ترسیم $\ln D_{eff}$ بر حسب $1/T$ تعیین نمود.

۲-۴- چروکیدگی

برای اندازه‌گیری چروکیدگی نمونه‌های، در هر دمای مورد نظر نمونه‌ها ابتدا خشک شده و سپس از طریق معادله‌ی (۸) چروکیدگی تعیین گردید.

$$\% \text{SKG} = \frac{V_0 - V}{V_0} \quad (8)$$

در این معادله، V_0 حجم کدوی سبز تازه (سانتی متر مکعب) و V حجم کدوی سبز بعد از خشک شدن (سانتی متر مکعب) می‌باشد. حجم نمونه‌ها از طریق جابجایی آن-هپتان تعیین گردید. جرم نمونه جابجا شده در آن-هپتان از طریق ترازوی دیجیتال (Jewelry, AND, model FX-CT SERIES, FX-300 CT, Japan) اندازه‌گیری گردید. حجم نمونه از طریق معادله‌ی (۹) محاسبه گردید.


$$V = \frac{m}{\rho} \quad (9)$$

در این معادله، m جرم آن-هپتان جا به جا شده (گرم)، ρ دانسیته‌ی آن-هپتان (گرم/سانتی متر مکعب) و V حجم نمونه (سانتی متر مکعب) می‌باشد (۹).

۲-۵- مدل سازی شبکه‌ی عصبی مصنوعی^۱

۲-۵-۱- شبکه‌ی عصبی پرسپترون

شبکه‌ی عصبی مصنوعی متشکل از مجموعه‌ای از نرون‌ها با ارتباطات داخلی بین یکدیگر می‌باشد که قادر است بر اساس اطلاعات و داده‌های ورودی، جواب‌های خروجی را تخمین بزند. شبکه‌های عصبی معمولاً به صورت لایه لایه و منظم ایجاد می‌گردند. اولین لایه که اطلاعات و داده‌های ورودی به آن وارد می‌گردد لایه ورودی نامیده می‌شود. لایه‌های میانی لایه‌های مخفی و آخرین لایه که جواب‌های خروجی از مدل را فراهم می‌نماید لایه‌ی خروجی نامیده می‌گردد (۲). ساده‌ترین و معمول‌ترین نوع شبکه‌ی عصبی که در بسیاری از علوم مهندسی از جمله تحقیق حاضر استفاده می‌گردد شبکه‌ی عصبی چند لایه پرسپترون همراه با ناظر که از روش پس انتشار خطا برای آموزش کمک



شکل ۳- ساختار شبکه‌ی عصبی، T ، دمای هوای خشک کردن، t ، زمان خشک کردن، z ضخامت نمونه، F_0 ، عدد فوریه، D_{eff} ضریب انتشار موثر رطوبت، E_a انرژی اکتیواسیون و SKG ، چروکیدگی.

۲-۵-۲- شبکه‌ی عصبی تابع پایه‌ی شعاعی

این شبکه با کاربردهای متنوع، یکی از محبوب‌ترین شبکه‌های عصبی و احتمالاً رقیب اصلی پرسپترون چند لایه است. شبکه‌های تابع پایه‌ی شعاعی، بیش‌تر از روش‌های طبقه‌بندی الگوی آماری سنتی الهام گرفته‌اند که این روش‌ها در واقع به شکلی در شبکه‌ی عصبی تجلی یافته‌اند. اما با منظور کردن شبکه‌ی تابع پایه‌ی شعاعی در طبقه‌بندی کلی شبکه‌های عصبی، این روش‌ها که برای عده‌ی معدودی شناخته شده بودند به صورت گسترده‌ای به کار گرفته شده‌اند. معماری اصلی یک شبکه‌ی تابع پایه‌ی شعاعی همان‌طور که در شکل ۴ نشان داده شده، یک شبکه‌ی سه لایه است. لایه‌ی ورودی صرفاً یک لایه با انشعاب خروجی^۱ است و هیچ‌گونه پردازشی انجام نمی‌دهد. لایه‌ی دوم یا لایه‌ی پنهان یک نگاشت غیر خطی از فضای ورودی به یک فضای با بعد بالاتر که در آن الگوها به صورت خطی تفکیک پذیر می‌شوند، انجام می‌دهد. بنابراین، لایه‌ی نهایی یک جمع وزنی ساده با یک خروجی خطی انجام می‌دهد. اگر از شبکه‌ی تابع پایه‌ی شعاعی برای تقریب تابع استفاده شود، آنگاه این خروجی

خوب است. ویژگی منحصر به فرد شبکه‌ی تابع پایه‌ی شعاعی، پردازشی است که در لایه‌ی پنهان انجام می‌شود. ایده این است که الگوها در فضای ورودی تشکیل خوشه‌هایی می‌دهند. اگر مراکز این خوشه‌ها معلوم باشند، آنگاه فاصله از مرکز خوشه را می‌توان اندازه گرفت. به علاوه، این فاصله غیر خطی در نظر گرفته می‌شود، به طوری که برای یک الگو در ناحیه‌ی نزدیک به مرکز خوشه، مقداری نزدیک به ۱ به دست می‌دهد. خارج این ناحیه، این مقدار به شدت کاهش می‌یابد. تصور این است که این ناحیه، حول مرکز خوشه به طور شعاعی متقارن است، به این دلیل تابع غیر خطی به عنوان تابع پایه‌ی شعاعی شناخته می‌شود. متداول‌ترین تابع پایه‌ی شعاعی به صورت رابطه‌ی ۱۳ است:

$$\varphi(r) = \exp\left(-\frac{r^2}{\tau^2}\right) \quad (13)$$

در یک شبکه‌ی تابع پایه‌ی شعاعی، τ فاصله از مرکز خوشه است. مزایای بسیاری برای شبکه‌های عصبی تابع پایه‌ی شعاعی نسبت به شبکه‌های پرسپترون چند لایه‌ی ادعا شده است. گفته شده است که یک تابع پایه‌ی شعاعی سریع‌تر از یک شبکه‌ی پرسپترون چند لایه آموزش می‌یابد و مرزهای تصمیم‌گیری تولید می‌کند. مزیت دیگری که ادعا شده است این است که تعبیر لایه‌ی

۲-۶- طراحی آزمایش‌ها و مدل سازی فرآیند بهینه سازی

در این پژوهش، تکنیک سطح پاسخ برای تعیین نقاط بهینه سازی شبکه‌ی عصبی مصنوعی مورد استفاده قرار گرفت. در فرآیند بهینه سازی ضریب مومنتوم^۱، تکرار یادگیری^۲ و تعداد نرون^۳ به عنوان متغیرهای مستقل فرآیند انتخاب گردید. میانگین خطای نسبی به عنوان متغیر پاسخ فرآیند در این پژوهش، مورد بررسی قرار گرفت. برای تجزیه تحلیل آماری، طرح مربع مرکزی نما مرکزی^۴ شامل ۲۰ آزمایش با ۶ تکرار در نقاط مرکزی به کار گرفته شد. مقادیر کد شده و واقعی متغیرهای مستقل مورد استفاده در فرآیند بهینه سازی شبکه‌ی عصبی در جدول ۱، نشان داده شده است.

جهت آنالیز آماری داده‌ها از نرم افزار آماری Design Expert نسخه ۶/۰۱ استفاده گردید. داده‌های تجربی با کمک یک مدل چند جمله ای درجه‌ی دو برازش داده شد. این مدل به صورت زیر می‌باشد:

$$Y_k = \beta_{k0} + \sum_{i=1}^2 \beta_{ki} X_i + \sum_{i=1}^2 \beta_{kii} X_i^2 + \sum_{i=1}^2 \sum_{j=1, j \neq i}^2 \beta_{kij} X_i X_j + \epsilon_k \quad (17)$$

در این معادله β_{ki} ضرایب ثابت مدل و X_i متغیرهای مستقل مورد استفاده در فرآیند بهینه سازی شبکه‌ی عصبی می‌باشد. ارزیابی بهترین مدل بهینه سازی شبکه به کمک تکنیک سطح پاسخ از طریق بررسی آزمون فقدان برازش مدل مذکور بود. به طوری که مدلی که آزمون فقدان برازش را غیر معنی دار نمود به عنوان بهترین مدل انتخاب گردید. متغیرهای مستقل و غیر مستقل بهینه سازی شبکه‌ی عصبی مصنوعی در جدول ۲، نشان داده شده است.

جدول ۱- مقادیر کد شده و واقعی فرآیند بهینه سازی شبکه

مقادیر کد شده و واقعی متغیرهای فرآیند		
متغیرها	بالا	پایین
تعداد نرون (X_1)	۵۰	۲
ضریب مومنتوم (X_2)	۰/۷	۰/۱
تکرار یادگیری (X_3)	۷۰۰۰	۵۰

پنهان در تابع پایه‌ی شعاعی ساده تر از تعبیر لایه‌ی پنهان در یک شبکه‌ی چند لایه ای پرسپترون است (۳).

۲-۵-۳- فرآیند یادگیری و انتخاب بهترین تابع عملکرد شبکه

برای توسعه‌ی مدل‌ها (در هر دو شبکه به کار رفته) ابتدا داده‌ها به دو زیر مجموعه، تقسیم شدند: ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد باقیمانده هم برای آزمایش شبکه در نظر گرفته شدند. داده‌ها با استفاده از نرم افزار SPSS نسخه ۱۷ مدل‌سازی شد. برای تعیین بهترین چیدمان شبکه از دو معیار ضریب تبیین (R^2) و خطای مربعات میانگین (MRE) استفاده می‌شود که هدف به ترتیب بیشینه و کمینه نمودن پارامترهای فوق می‌باشد. این معیارها توسط معادلات ۱۴ و ۱۵ محاسبه می‌شوند.

$$MRE = \left(\frac{1}{N} \sum_{i=1}^N \frac{|P_{ANN,i} - P_{exp,i}|}{P_{exp,i}} \right) \times 100 \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (P_{ANN,i} - P_{exp,i})^2}{\sum_{i=1}^N (P_{ANN,i} - MRE_{ANN,i})^2} \quad (15)$$

در این معادلات، P_{ANN} مقدار پیش بینی شده برای پارامترهای خروجی از شبکه، P_E مقادیر داده‌های تجربی به دست آمده از آزمایش و N تعداد مشاهدات می‌باشد (۲۱). وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود از این رو داده‌های ورودی به شبکه باید نرمال شود. در صورتی که این مرحله انجام نشود شبکه در طول فاز آموزش، همگرا نخواهد شد و نتایج مطلوب تولید نخواهد شد. در این بررسی، برای نرمالیزه کردن داده‌ها از رابطه‌ی ۱۶ استفاده شده است که ورودی‌ها را بین ۰/۱ و ۰/۹ استاندارد می‌نماید. در نهایت، می‌توان خروجی‌های شبکه را با معکوس نمودن الگوریتم استاندارد سازی به حالت اولیه برگرداند (۲۱ و ۲).

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \times (r_{max} - r_{min}) + r_{min} \quad (16)$$

در این معادله، x داده خام اولیه، x_n داده نرمالیزه شده، x_{max} و x_{min} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و r_{max} و r_{min} به ترتیب حد بالایی و پایینی دامنه‌ی تغییرات داده‌های تبدیل شده است.

- 1 - Momentum coefficient (M)
- 2 - Training epoch (Te)
- 3 - Number of neuron (NN)
- 4 - Face-Centred Central Composite Design (CCF)

جدول ۲- متغیرهای مستقل و غیر مستقل بهینه سازی شبکه‌ی عصبی مصنوعی

پاسخ‌ها	متغیرهای مورد بررسی			شماره آزمون
	تکرار یادگیری (X_3)	ضریب مومنتوم (X_2)	تعداد نرون (X_1)	
۰/۰۰۱۲۷۶	۳۵۲۵	۰/۴	۵۰	۱
۰/۱۶۸۹۵۳	۷۰۰۰	۰/۱	۲	۲
۰/۰۰۱۲۷۶	۷۰۰۰	۰/۷	۵۰	۳
۰/۰۰۱۴۳۰	۷۰۰۰	۰/۴	۲۶	۴
۰/۱۶۸۹۵۳	۵۰	۰/۱	۲	۵
۰/۱۶۸۹۵۳	۳۵۲۵	۰/۴	۲	۶
۰/۰۰۱۴۳۰	۳۵۲۵	۰/۴	۲۶	۷
۰/۰۰۱۵۳۱	۳۵۲۵	۰/۴	۲۶	۸
۰/۰۰۱۶۴۰	۳۵۲۵	۰/۴	۲۶	۹
۰/۰۰۱۲۷۷	۷۰۰۰	۰/۱	۵۰	۱۰
۰/۰۰۱۴۷۰	۳۵۲۵	۰/۴	۲۶	۱۱
۰/۰۰۱۵۳۰	۳۵۲۵	۰/۴	۲۶	۱۲
۰/۱۶۸۹۵۳	۵۰	۰/۷	۲	۱۳
۰/۰۰۱۴۳۰	۳۵۲۵	۰/۱	۲۶	۱۴
۰/۰۰۱۴۳۰	۵۰	۰/۴	۲۶	۱۵
۰/۰۷۰۸۵۴	۳۵۲۵	۰/۷	۲۶	۱۶
۰/۱۱۴۱۴۸	۷۰۰۰	۰/۷	۲	۱۷
۰/۰۲۸۲۶۷	۵۰	۰/۱	۵۰	۱۸
۰/۰۰۱۳۹۰	۳۵۲۵	۰/۴	۲۶	۱۹
۰/۰۲۸۲۶۷	۵۰	۰/۷	۵۰	۲۰

۳- نتایج و بحث

سبز استفاده گردید. اولین مدل، مدل ترکیبی سطح پاسخ و شبکه‌ی عصبی مصنوعی بود که برای تعیین شرایط بهینه پارامترهای شبکه‌ی عصبی مصنوعی با هدف کمینه نمودن مقدار خطای نسبی و بیشینه نمودن ضریب تبیین مورد استفاده قرار گرفت. متغیرهای بهینه سازی شبکه‌ی عصبی مصنوعی شامل تعداد نرون، تکرار یادگیری و ضریب مومنتوم بود. نتایج آنالیز آماری بهینه سازی چیدمان شبکه‌ی عصبی مصنوعی نشان داد که مدل درجه‌ی چهارم^۱ به دلیل غیر معنی دار نمودن آزمون فقدان برازش به عنوان بهترین مدل در فرآیند بهینه سازی فاکتورهای مؤثر در بهینه سازی شبکه‌ی عصبی مصنوعی انتخاب گردید. علاوه بر این، نتایج، نشان داد که مقدار ضریب تبیین و ضریب تبیین تعدیل شده^۲ به ترتیب برای مدل فوق ۰/۹۹۴۲ و ۰/۹۸۱۶ به دست آمد.

در این پژوهش، ترکیبی از لایه‌ها و نرون‌های مختلف همراه با تابع فعال سازی مختلف (در لایه‌های پنهان و خروجی) برای بهینه سازی شبکه‌ی پرسپترون مورد استفاده قرار گرفت. شبکه‌های عصبی با یک لایه‌ی پنهان، تعداد ۵ تا ۵۰ نرون به طور تصادفی انتخاب و قدرت شبکه در پیش بینی پارامترهای خشک کردن لایه ای نازک کدوی سبز ارزیابی گردید. برای آموزش شبکه‌ی پرسپترون با الگوریتم یادگیری پس انتشار خطا همراه با مومنتوم استفاده گردید که در آن ضریب مومنتوم در رنج ۰/۱ - ۰/۷ و نرخ یادگیری ۰/۴ در نظر گرفته شد. جدول ۳، دامنه‌ی تغییرات متغیرهای ورودی و خروجی شبکه‌های عصبی مصنوعی را نشان می‌دهد. در این مقاله از مدل‌های مختلف همراه با تابع‌های محرک متفاوت برای تخمین پارامترهای سینتیک خشک کردن کدوی

1 - Cubic

2 - Adjust R-squared

این شرایط مقدار خطای نسبی حداقل و از لحاظ مقداری صفر می‌باشد. مطلوبیت به دست آمده در شرایط بهینه برای متغیرها و پاسخ‌ها مورد بررسی ۱، گزارش گردید.

دومین مدل مورد استفاده مدل شبکه‌ی عصبی پرسپترون می‌باشد. بررسی نتایج به دست آمده در خصوص شبکه‌ی عصبی پرسپترون چند لایه^۱ همراه با تابع محرک لوگ سیگموئید- لوگ سیگموئید^۲، با یک لایه‌ی مخفی نشان داد که چیدمان ۳-۵۰-۳، یعنی شبکه‌ی ۳ با ۳ ورودی، ۵۰ گره (نرون) در لایه‌ی پنهان و ۴ خروجی، بهترین نتیجه را برای پیش بینی سینتیک خشک کردن کدوی سبز داشت. به طوری که این مدل قادر به پیش بینی انرژی اکتیواسیون، عدد فوریه، چروکیدگی و ضریب انتشار رطوبت را به ترتیب با ضرایب تبیین ۰/۹۹۹، ۰/۹۹۹، ۰/۹۹۹ و ۰/۹۹۱ می‌باشد. همچنین از سایر تابع‌های محرک برای مدلسازی با شبکه‌ی عصبی پرسپترون در خصوص پیش بینی پارامترهای سینتیک خشک کردن کدوی سبز، مورد مطالعه قرار گرفت. نتایج گزارش‌های این حالت در جدول ۴، نشان داده شده است. نتایج جدول، نشان می‌دهد که مدل شبکه‌ی عصبی پرسپترون همراه با تابع محرک لوگ سیگموئید-تانژانت هیپربولیک^۳ نیز از توانایی بالایی در تخمین پارامترهای خشک کردن کدوی سبز داشته و توانست انرژی اکتیواسیون، عدد فوریه، چروکیدگی و ضریب انتشار رطوبت را به ترتیب با ضرایب رگرسیون ۰/۹۹۹، ۰/۹۸۸، ۰/۹۹۴ و ۰/۹۹۲ پیش بینی نماید. تابع محرک همانی-لوگ سیگموئید^۴ به همراه شبکه‌ی عصبی پرسپترون نیز نتایج موفقیت آمیزی را در پیش بینی پارامترهای خشک کردن لایه‌ی ای نازک کدوی سبز ارائه نمود به طوری که این شبکه با ۱۵ نرون در لایه‌ی مخفی بهترین حالت را در تخمین پارامترهای انرژی اکتیواسیون، عدد فوریه، چروکیدگی و ضریب انتشار رطوبت داشت.

معادله‌ی پاسخ برای تاثیر پارامترهای بهینه سازی شبکه‌ی عصبی مصنوعی روی مقدار میانگین خطای نسبی برای داده‌های کُد شده در زیر به دست آمد:

$$MRE = 6.543E-003 - 0.084 X_1 + 0.035 X_2 - 4E-012 X_3 + 0.071 X_1^2 + 0.022 X_2^2 - 0.013 X_3^2 + 6.85E-003 X_1X_2 + 1.03E-004 X_1X_3 - 6.851E-003 X_2X_3 - 0.042 X_1^2X_2 - 0.014 X_1^2X_3 + 0.014 X_1X_2^2 + 6.85E-003 X_1X_2X_3, (R^2 = 0.9942)$$

شکل ۴، نمودار سه بعدی سطح پاسخ، میانگین خطای نسبی را در مقابل تعداد نرون و ضریب مونتوم نشان می‌دهد. همان طور که مشاهده می‌گردد با افزایش تعداد نرون از ۵ تا ۵۰ مقدار میانگین خطای نسبی کاهش یافته و منحنی سه بعدی سطح پاسخ یک منحنی پاسخ مینیموم را نشان می‌دهد. از طرف دیگر، افزایش مقدار ضریب مونتوم نیز روندی مشابه قبل را نشان داده و با افزایش ضریب مونتوم از ۰/۱ تا ۰/۷ مقدار میانگین خطای نسبی روند نزولی را طی می‌نماید. نتایج مشابه توسط نازقلیچی و همکاران (۲۰۱۱) مشاهده گردید (۱۹).

شکل ۵ نمودار سطح پاسخ و کانتور تکرار یادگیری و تعداد نرون را برای بهینه سازی شبکه‌ی عصبی مصنوعی نشان می‌دهد. نتایج، نشان داد که افزایش تعداد نرون روندی مشابه قبل را داشته و با افزایش تعداد نرون‌ها مقدار میانگین خطای نسبی کاهش یافته، به طوری که مقدار میانگین خطای نسبی در تعداد نرون ۵، ۰/۱۱ و در ۵۰، ۰/۰۱- می‌باشد. از طرف دیگر، افزایش تکرار یادگیری از ۵۰ تا ۷۰۰۰ تاثیر ناچیزی در مقدار میانگین خطای نسبی نشان داد.


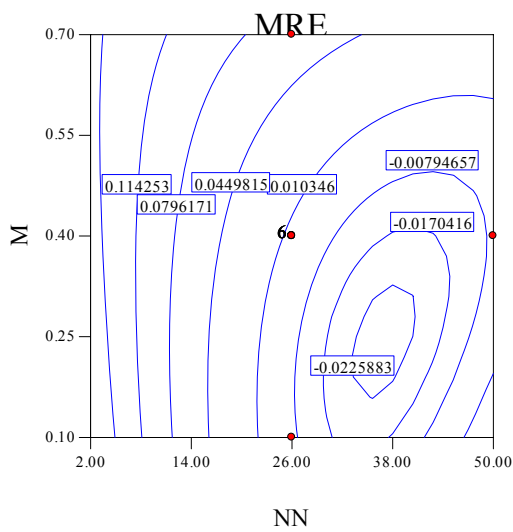
شکل ۶ نمودار سطح پاسخ تکرار یادگیری و ضریب مونتوم را برای بهینه سازی شبکه‌ی عصبی مصنوعی نشان می‌دهد. نتایج، نشان داد که افزایش ضریب مونتوم از ۰/۱ تا ۰/۴ سبب کاهش مقدار میانگین خطای نسبی گردید و افزایش مقدار ضریب مونتوم از ۰/۴ تا ۰/۷ مقدار میانگین خطای نسبی افزایش می‌یابد. همان طور که از منحنی پیداست مقدار میانگین خطای نسبی در ۰/۴، صفر و در ۰/۷، ۰/۰۴ می‌باشد. به طور مشابه همان طور که مشاهده می‌گردد افزایش تکرار یادگیری از ۵۰ تا ۷۰۰۰ مقدار میانگین خطای نسبی را افزایش می‌یابد. به طوری که مقدار میانگین خطای نسبی در تکرار یادگیری ۵۰، ۰/۰۲- و در ۳۵۲۵، ۰/۰۱- می‌باشد.

نتایج، نشان داد که در شرایط بهینه متغیرهای بهینه سازی شبکه‌ی عصبی مصنوعی یعنی تعداد نرون، تکرار یادگیری و ضریب مونتوم به ترتیب ۲۷، ۶۵۳۵ و ۰/۴۳ می‌باشد. همچنین در



1 - Multilayer perceptron (MLP)
2 - Logarithm sigmoid- Logarithm sigmoid (logsig-
logsig)
3 - Logarithm sigmoid-tangent hyperbolic (logsig-tanh)
4 - Identity- Logarithm sigmoid (Identity- logsig)

جدول ۳ - دامنه‌ی تغییر پارامترهای ورودی و خروجی شبکه

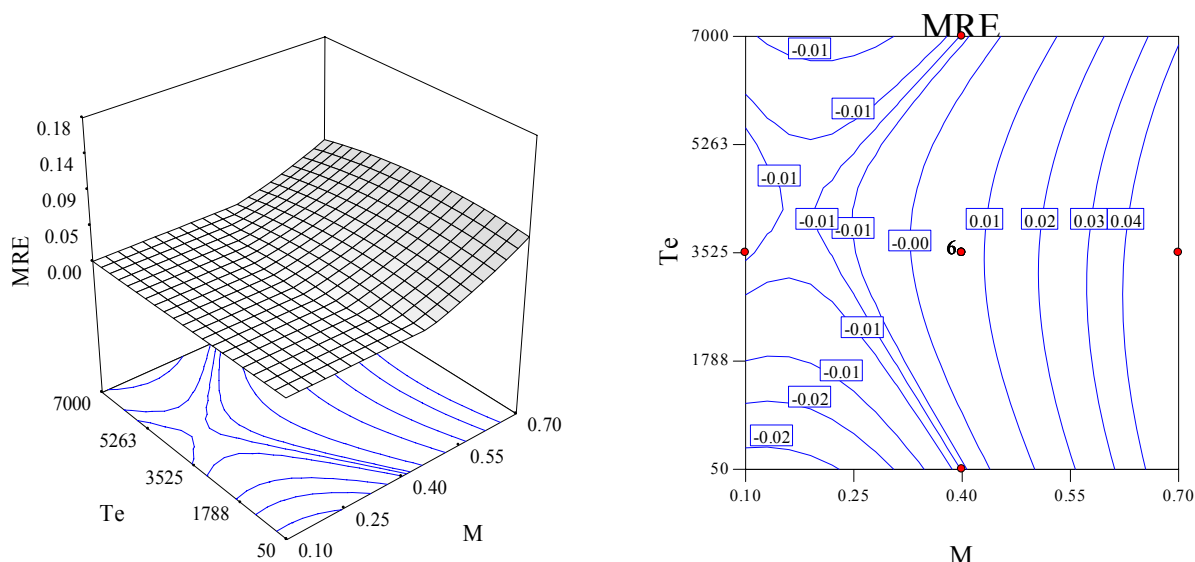
دامنه تغییر	پارامتر
۸۰-۶۰	دمای هوای خشک کردن (oC)
۵۴۰-۰	زمان خشک کردن (دقیقه)
۷-۳	ضخامت (میلی متر)
$۲/۱۳ \times ۱۰^{-۵}$ - $۵/۸۱ \times ۱۰^{-۶}$	ضریب انتشار موثر رطوبت (m^2/s)
۳۰/۰۲۲ - ۴۶/۳۲	انرژی اکتیواسیون (kj/kmol)
۳۳۰/۶۸-۰	عدد فوریه (بدون بُعد)
۳/۸۵-۳/۴۸	چروکیدگی (%)



شکل ۴ - منحنی سه بعدی تاثیر تعداد نرون (NN) و ضریب مومنتوم (M) روی میانگین خطای نسبی (MRE).



شکل ۵ - منحنی سه بعدی تاثیر تعداد نرون (NN) و تکرار یادگیری (Te) روی میانگین خطای نسبی (MRE).



شکل ۶- منحنی سه بعدی تاثیر ضریب مومنتوم (M) و تکرار یادگیری (Te) روی میانگین خطای نسبی (MRE).

نمودار آنالیز حساسیت مقادیر پیش‌بینی شده توسط شبکه‌ی عصبی پرسپترون همراه با تابع محرک لوگ سیگموئید-لوگ سیگموئید در برابر مقادیر تجربی برای بهترین چیدمان (ساختار ۴-۵۰ یعنی شبکه‌ی عصبی با ۳ ورودی و ۵۰ نرون در لایه‌ی پنهان و ۴ خروجی) شبکه‌ی عصبی نشان داد که داده‌ها به طور تصادفی در اطراف خط رگرسیونی با ضریب تبیین بالاتر از ۰/۹۹۱ قرار گرفته‌اند که این خود دلیلی بر ارزیابی دقیق شبکه‌ی عصبی در پیش‌بینی پارامترهای خشک کردن لایه‌ی ای نازک کدوی سبز می‌باشد (شکل ۷). همان‌طور که مشاهده گردید، این روش توانست پارامترهای خشک کردن لایه‌ی ای نازک کدوی سبز یعنی انرژی اکتیواسیون، عدد فوریه، چروکیدگی و ضریب انتشار رطوبت را به ترتیب با ضرایب رگرسیون ۰/۹۹۹، ۰/۹۹۲، ۰/۹۹۹ و ۰/۹۹۱ پیش‌بینی نماید.

۴- نتیجه‌گیری


در این تحقیق، پارامترهای مؤثر در خشک کردن هوای داغ کدوی سبز توسط مدل‌های مختلف شبکه‌ی عصبی همراه با توابع محرک مختلف پیش‌بینی گردید. نتایج نشان داد که مدل شبکه‌ی عصبی پرسپترون از دقت بالایی در پیش‌بینی پارامترهای خشک کردن کدوی سبز برخوردار می‌باشد. با وجود این، مدل شبکه‌ی عصبی پرسپترون همراه با تابع محرک لوگ سیگموئید-لوگ سیگموئید به عنوان بهترین تابع محرک مدل، توانست مقادیر

علاوه بر دو مدل فوق، در این پژوهش از مدل شبکه‌ی تابع پایه‌ی شعاعی به همراه دو تابع محرک پایه‌ی شعاعی نرمالیزه شده^۱ و تابع پایه‌ی شعاعی عادی^۲ در پیش‌بینی سینتیک خشک کردن کدوی سبز نیز استفاده گردید. نتایج نشان داد که این مدل همراه با تابع محرک پایه‌ی شعاعی نرمالیزه شده نتایج بهتری را در تخمین پارامترهای خشک کردن کدوی سبز نشان دادند. به طوری که این مدل توانست با ۵۰ نرون در لایه‌ی پنهان پارامترهای انرژی اکتیواسیون، عدد فوریه، چروکیدگی و ضریب انتشار رطوبت را به ترتیب با ضرایب تبیین ۱، ۰/۶۷۱، ۱ و ۰/۹۹۹ پیش‌بینی نماید. مقایسه‌ی نتایج مدل‌های شبکه‌ی عصبی همراه با توابع فعال‌سازی مختلف برای تعیین بهترین چیدمان شبکه‌ی عصبی مصنوعی در جدول ۴، نشان داده شده است. به طور کلی، نتایج نشان داد که در بین مدل‌های مختلف همراه با تابع محرک مختلف، شبکه‌ی پرسپترون چند لایه همراه با تابع محرک لوگ سیگموئید-لوگ سیگموئید نتایج بهتری را در پیش‌بینی پارامترهای خشک کردن هوای داغ کدوی سبز نشان می‌دهد. در گام بعد، بهترین مدل پیش‌بینی کننده سینتیک خشک کردن کدوی سبز شبکه پرسپترون چند لایه همراه با تابع محرک لوگ سیگموئید-تانزانانت هیپربولیک می‌باشد. نتایج سایر شبکه‌ها در جدول ۴، نشان داده شده است.


1 - Normalized radial basis function (NRBF)
2 - Ordinary radial basis function (ORBF)

جدول ۴- مقایسه‌ی دو مدل شبکه‌ی عصبی در پیش بینی پارامترهای خشک کردن کدوی سبز


انرژی اکتیواسیون	ضریب انتشار موثر	چروکیدگی	عدد فوریه	پارامترهای آماری	تابع محرک	مدل شبکه
۰/۹۹۴	۰/۹۸۳	۰/۹۹۳	۰/۶۴۱	R ²		
۰/۰۰۵۷۰	۰/۰۱۶۳	۰/۰۰۵۰	۰/۴۶۸۵	MRE	logsig-logsig	MLP-RSM
۳-۲۷-۴	۳-۲۷-۴	۳-۲۷-۴	۳-۲۷-۴	چیدمان		
۰/۹۹۹	۰/۹۹۱	۰/۹۹۹	۰/۹۹۲	R ²		
۰/۰۰۰۰۸۹	۰/۰۰۴۲۱	۰/۰۰۰۱۱	۰/۰۰۳۱۴	MRE	logsig-logsig	MLP
۳-۵۰-۴	۳-۵۰-۴	۳-۵۰-۴	۳-۵۰-۴	چیدمان		
۰/۹۸۹	۰/۹۷۵	۰/۹۸۹	۰/۷۵۴	R ²		
۰/۰۰۶۴	۰/۰۱۲۴	۰/۰۰۷۸	۰/۱۳۳۳	MRE	tanh-tanh	MLP
۳-۳۵-۴	۳-۳۵-۴	۳-۳۵-۴	۳-۳۵-۴	چیدمان		
۰/۹۹۹	۰/۹۹۲	۰/۹۹۴	۰/۹۸۸	R ²		
۰/۰۰۰۲۵۹	۰/۰۰۱۹۲	۰/۰۰۰۲۴۸	۰/۰۰۴۱	MRE	logsig-tanh	MLP
۳-۲۵-۴	۳-۲۵-۴	۳-۲۵-۴	۳-۲۵-۴	چیدمان		
۰/۹۹۷	۰/۹۹۱	۰/۹۹۸	۰/۹۵۱	R ²		
۰/۰۰۰۸۰۳	۰/۰۰۱۳۸	۰/۰۰۰۹۷۴	۰/۰۰۰۷۰۴	MRE	identity-tanh	MLP
۳-۳۰-۴	۳-۳۰-۴	۳-۳۰-۴	۳-۳۰-۴	چیدمان		
۰/۹۹۹	۰/۹۹۸	۰/۹۹۷	۰/۹۷۳	R ²		
۰/۰۰۰۷۳۹	۰/۰۰۰۶۶۱	۰/۰۰۰۸۴۹	۰/۰۰۱۷۵	MRE	identity-logsig	MLP
۳-۱۵-۴	۳-۱۵-۴	۳-۱۵-۴	۳-۱۵-۴	چیدمان		
۱	۰/۹۹۹	۱	۰/۶۷۱	R ²		
$۴/۷۴ \times ۱۰^{-۱۲}$	$۲/۸۶ \times ۱۰^{-۱۲}$	$۱/۹۶ \times ۱۰^{-۱۲}$	۰/۰۰۴۳	MRE	NRBF	RBF
۳-۵۰-۴	۳-۵۰-۴	۳-۵۰-۴	۳-۵۰-۴	چیدمان		
۰/۵۲۳	۰/۶۶۳	۰/۵۳۳	۰/۷۶۵	R ²		
$۷/۱۷ \times ۱۰^{-۱۵}$	$۱/۵۲ \times ۱۰^{-۱۵}$	$۴/۰۲ \times ۱۰^{-۱۵}$	۰/۰۰۴۳	MRE	ORBF	RBF
۳-۵۰-۴	۳-۵۰-۴	۳-۵۰-۴	۳-۵۰-۴	چیدمان		




مقادیر تجربی ضریب انتشار مؤثر



مقدار تجربی انرژی اکتیواسیون



مقادیر تجربی عدد فوریه



مقادیر تجربی چروکیدگی

شکل ۷ - مقادیر پیش‌بینی شده و تجربی پارامترهای خشک کردن لایه ای نازک کدوی سبز توسط شبکه‌ی عصبی پرسپترون همراه با تابع محرک لوگ سیگموئید - لوگ سیگموئید

- 10- Doymaz, I. 2007a. Air-drying characteristics of tomatoes. *Journal of Food Engineering*, 78: 1291-1297.
- 11- Doymaz, I. 2007b. The kinetics of forced convective air-drying of pumpkin slices. *Journal of Food Engineering*, 79: 243-248.
- 12- Doymaz, I. and Ismail, O. 2011. Drying characteristics of sweet cherry. *Journal of Food and Bioproducts Processing*, 89: 31-38.
- 13- Guiné, R. P. F. Pinho, S. and Barroca, M. J. 2010. Study of the convective drying of pumpkin (*Cucurbita maxima*). *Journal of Food and Bioproducts Processing*, In Press.
- 14- Guiné, P. F. R., and Barroca, J. M. 2011. Effect of drying treatments on texture and color of vegetables (pumpkin and green pepper). *Journal of Food and Bioproducts Processing*, In Press.
- 15- Jambrak, A. R. Mason, T. J. Paniwnyk, L. and Lelas, V. 2007. Accelerated drying of button mushrooms, Brussels sprouts and cauliflower by applying power ultrasound and its rehydration properties. *Journal of Food Engineering*, 81: 88-97.
- 16- Menlik, T. Özdemir, M. B. and Kirmaci, V. 2010. Determination of freeze-drying behaviors of apples by artificial neural network. *Journal of Expert Systems with Applications*, In Press.
- 17- Momenzadeh, L. Zomorodian, A. and Mowla, D. 2010. Experimental and theoretical investigation of shelled corn drying in a microwave-assisted fluidized bed dryer using Artificial Neural Network. *Journal of Food and Bioproducts Processing*, In Press.
- 18- Mwithiga, G. and Olwal, J. O. 2005. The drying kinetics of kale (*Brassica oleracea*) in a convective hot air dryer. *Journal of Food Engineering*, 71: 373-378.
- 19- Nazghelichi, T. Aghbashlo, M. and Hossein Kianmehr, M. 2011. Optimization of an artificial neural network topology using coupled response surface methodology and genetic algorithm for fluidized bed drying. *Journal of Computers Electronics in Agriculture*, 75: 84-91.
- 20- Pinedo, A. A. and Murr, F. E. X. 2006. Kinetics of vacuum drying of pumpkin (*Cucurbita maxima*): Modeling with shrinkage. *Journal of Food Engineering*, 76: 562-567.
- 21- Poonnoy, P. Tansakul, A. and Chinnan, M. 2006. Artificial Neural Network Modeling for Temperature and Moisture Content Prediction in Tomato Slices Undergoing Microwave-Vacuum Drying. *Journal of Food Engineering & Physical Properties*, 49: 185-191.
- 22- Sacilik, K. R. Keskin, and A. K. Elicin. 2006. Mathematical modeling of solar tunnel drying of thin layer organic tomato. *Journal of Food Engineering*, 73: 231-238.
- انرژی اکتیواسیون، عدد فوریه، چروکیدگی و ضریب انتشار رطوبت را به ترتیب با ضرایب رگرسیون ۰/۹۹۹، ۰/۹۹۲، ۰/۹۹۹ و ۰/۹۹۱ پیش بینی نماید که این ضرایب نشان دهنده دقت بالای مدل در تخمین پارامترهای خشک کردن کدوی سبز می باشد به طور کلی، پیشنهاد می گردد که در پژوهش های بعدی از سایر ابزارهای تخمین زن نظیر سیستم های فازی-عصبی و همچنین سایر مدل های شبکه های عصبی مصنوعی و توابع فعال سازی مختلف جهت مقایسه با مدل های تجربی استفاده و قدرت این ابزارها در تخمین پارامترهای خشک کردن کدوی سبز مورد ارزیابی قرار گیرد.
- ### ۵-منابع
- ۱- رنجبر، آ. ۱۳۸۸. پیش بینی هزینه های تعمیر و نگه داری تراکتور جاندیر با استفاده از دو ساختار متفاوت شبکه ی عصبی MLP. *مجله ی اقتصاد و توسعه ی کشاورزی (علوم و صنایع کشاورزی)*، جلد ۲۲، شماره ی ۲، ۸۷-۹۶.
- ۲- اسفندیاری درآباد، ف. ۱۳۸۹. پیش بینی میانگین دمای ماهانه ی ایستگاه سینوپتیک سندرچ با استفاده از مدل شبکه ی عصبی مصنوعی پرسپترون چند لایه (MLP). *مجله ی جغرافیا (فصلنامه ی علمی-پژوهشی انجمن جغرافیای ایران)*، سال ۸، شماره ی ۲۷، ۶۴-۴۵.
- ۳- میر صالحی، م. ۱۳۸۷، شبکه های عصبی مصنوعی، انتشارات دانشگاه فردوسی، ۱۵۱-۱۵۴.
- 4- Akgun, N. A. and Doymaz, I. 2005. Modeling of olive cake thin-layer drying process. *Journal of Food Engineering*, 68: 455-461.
- 5- Alibas, I. 2007. Microwave, air and combined microwave-air-drying parameters of pumpkin slices. *Journal of LWT*, 40: 1445-1451.
- 6- <http://anrcatalog.ucdavis.edu/pdf/7245.pdf>
- 7- AOAC, 1990. Official Method of Analysis. 15th ed. vol.2. Association of Official Analytical Chemists, Inc., Arlington.
- 8- Broyart, B. and Trystram, G. 2003. Modeling of heat and mass transfer phenomena and quality changes during continuous biscuit baking using both deductive and inductive (neural network) modeling principles. *Institution of Chemical Eng. Trans, IChemE*, Vol 81, Pt. C.
- 9- Devahastin, S. Suvarnakuta, P. Soponronnarit, S. and Mujumdar, A. S. 2004. A comparative study of low-pressure superheated steam and vacuum drying of a heat-sensitive material. *Journal of Drying Technology*, 22: 1845-1867.