

پیش‌بینی محتوای رطوبتی پیاز خوراکی در طی فرآیند خشک کردن با استفاده از شبکه عصبی مصنوعی

* حدیث نعمت پور ملک آباد^۱ - محمد جواد شیخ داوودی^۲ - اسماعیل خراسانی فردوانی^۳ و حسن ذکری دیزجی^۴

- ۱- دانش آموخته کارشناسی ارشد مکانیک ماشین های کشاورزی و مکانیزاسیون دانشگاه شهید چمران اهواز
- ۲- دانشیار گروه مکانیک ماشین های کشاورزی و مکانیزاسیون دانشگاه شهید چمران اهواز
- ۳- استادیار گروه مکانیک ماشین های کشاورزی و مکانیزاسیون دانشگاه شهید چمران اهواز
- ۴- استادیار گروه مکانیک ماشین های کشاورزی و مکانیزاسیون دانشگاه شهید چمران اهواز

چکیده	تاریخچه مقاله
<p>پیاز خوراکی به عنوان منبع غذایی و همچنین مصارف دارویی، امروزه بسیار مورد توجه قرار گرفته است. با افزایش بیش از پیش تولید پیاز، نیاز به انبارداری، افزایش ماندگاری، کاهش ضایعات و استفاده از پودر پیاز بیشتر احساس می شود. به همین جهت خشک کردن این محصول به عنوان یکی از راهکارهای عملی همواره مطرح می باشد. امروزه با توجه به مزایای فناوری هوش مصنوعی، استفاده از شبکه های عصبی مصنوعی در سطح وسیعی برای شیوه سازی و پیش بینی پارامترهای مورد نیاز در فرایندهای خشک کردن در حال رشد و توسعه است. هدف از انجام این تحقیق پیش بینی محتوای رطوبتی پیاز به کمک شبکه عصبی مصنوعی می باشد. در این تحقیق پیاز با استفاده از خشک کن جریان عمودی هوای داغ در زمان های مختلف در سه سطح دمای ۶۰، ۷۰ و ۸۰ درجه سلسیوس، سه سطح ضخامت لایه ۱۵، ۳۰ و ۴۵ میلی متر، سه سطح ضخامت خالل ۲، ۴ و ۶ میلی متر و سه تکرار، در سرعت هوای ثابت ۱/۵ متر بر ثانیه خشک شده تا محتوای رطوبتی آن ثابت و به ۶٪ (بر پایه تر) برسد. بهترین الگوریتم یادگیری لونبرگ-مارکوارت با کمترین مقدار خطای MSE انتخاب شد. توپولوژی بهینه ۱-۴ با تابع آستانه تازه انت سیگموئید و مقادیر خطای ۰/۰۱۳۳ و ۰/۰۰۹۹۸ به دست آمدند. مقایسه ضریب تبیین R^2 و MSE نشان داد که شبکه عصبی با ساختار ۱-۴ با تابع آستانه تازه انت سیگموئید و مقادیر خطای ۰/۰۲۲ به دست آمد. مقایسه ضریب تبیین R^2 و MSE آن ۰/۰۱۳۳ و ۰/۰۰۹۹۸ می کند؛ بهترین مقدار ضریب تبیین آن ۰/۰۱۳۳ و MSE آن ۰/۰۰۹۹۸ به دست آمد.</p>	دریافت: ۱۳۹۲/۰۷/۰۱ پذیرش نهایی: ۱۳۹۳/۰۳/۱۱
<p>کلمات کلیدی:</p> <p>پیاز، خشک کردن، محتوای رطوبتی، شبکه عصبی مصنوعی</p>	<p>عهده دار مکاتبات* E-mail: hadisnematpour@yahoo.com</p>

خشک کردن هویج شبکه عصبی مصنوعی استفاده کردند. پارامترهای سرعت و دمای هوای خشک کن و زمان خشک کردن به عنوان پارامترهای ورودی به شبکه در نظر گرفته شده بود. آن‌ها در بررسی خود از شبکه‌هایی با دوزیر لایه، یکی با نزون‌های سیگموئیدی و دیگری با نزون‌های خطی استفاده کردند. منحنی‌های خشک کردن حاصل از این شبیه‌سازی که با این شبکه بدست آمدند با دقّت مناسبی به داده‌های آزمایشی برازش داده شدند. از این مدل برای خشک کردن هویج در یک خشک کن مکانیکی استفاده شده بود. نتایج نشان دهنده آن بوده است که شبکه مدولار برای استفاده در تخمین تقریبی به‌منظور طراحی و انتخاب شرایط کاری بهینه و مقایسه کردن خشک کن مناسب است (۳). اسلام^۴ و همکاران (۹) پژوهشی در زمینه‌ی پیش‌گویی سرعت خشک شدن توسط شبکه‌ی عصبی انجام دادند. این تحقیق بر روی ورقه‌های گوجه‌فرنگی صورت گرفت. تیمارها شامل سرعت هوا در محدوده‌ی ۰/۵ تا ۲ متر بر ثانیه، دمای هوای خشک کن در محدوده‌ی ۴۰ تا ۵۵ درجه سلسیوس، رطوبت نسبی هوا در محدوده‌ی ۵ تا ۵۰ درصد و ضخامت ورقه‌های نمونه در محدوده‌ی ۳ تا ۱۰ میلی‌متر بود. در این تحقیق از مدل خشک شدن پیچ استفاده شده بدین نحو که همین مدل در شبکه عصبی آنالیز گردیده است (۹). ارترک^۵ و همکاران (۵) تحقیقی در زمینه‌ی مقایسه تخمین خشک کردن دینامیکی گیاه اکناسه‌آنگوستیفولیا (یک گیاه با کاربرد پزشکی فراوان) به وسیله تحلیل رگرسیونی و شبکه‌ی عصبی انجام دادند. در این تحقیق خشک کردن دینامیکی لایه نازک این گیاه و مقایسه‌ی آن در تحلیل رگرسیونی و شبکه‌ی عصبی بررسی شده است. آزمایش‌ها در سه سطح دمایی ۱۵، ۳۰ و ۴۵ درجه سلسیوس و در سه سطح سرعت هوا

مقدمه

خشک کردن یکی از فرآیندهای متداول در صنایع غذایی به حساب می‌آید و به احتمال زیاد اصلی‌ترین و پرهزینه‌ترین بخش در عملیات پس از برداشت می‌باشد (۲). از جمله مزایای خشک کردن محصولات کشاورزی، افزایش زمان ماندگاری محصول بدون افزودن مواد شیمیایی، کاهش اندازه بسته‌بندی و کاهش هزینه حمل و نقل می‌باشد. کنترل بدون وقفه فرآیند خشک کردن و افزایش کیفیت محصول خروجی نیازمند پیش‌بینی بدون وقفه تغییرات محتوای رطوبتی می‌باشد. مدل‌های به دست آمده اغلب به‌منظور مطالعه رفتار متغیرهای عملیاتی، پیش‌بینی سیستمیک خشک شدن و بهینه‌سازی فرآیند خشک کردن مورد استفاده قرار می‌گیرند (۱۰). فارکاس^۱ و همکاران (۷) جنبه‌های مدل‌سازی جبویات خشک شده توسط شبکه‌ی عصبی را مورد مطالعه قرار داده‌اند. در این تحقیق کاربرد شبکه‌ی عصبی در یک خشک کن بستر ثابت به کار گرفته شده است. هدف از این تحقیق تخمین زدن رابطه‌ی بین توزیع رطوبت مواد خشک شده و پارامترهای فیزیکی شامل دمای خشک شدن، رطوبت و سرعت هوای دمیده شده بود. در این پژوهش ورودی‌های شبکه شامل سرعت جریان هوا در سه سطح ۰/۱۷۸، ۰/۰۸۹ و ۰/۲۶۷ متر بر ثانیه، دمای هوای ورودی در سه سطح ۴۶/۵، ۴۴/۴ و ۴۲/۲ درجه سلسیوس و رطوبت ویژه‌ی هوای خشک کن در سه سطح ۱۴/۵ و ۱۴/۸ گرم بر متر مکعب و همه‌ی تیمارها در سه تکرار انجام شد. نتیجه بدست آمده در این تحقیق بدین شرح بود که می‌توان در یک خشک کن بستر ثابت توزیع رطوبت در اعماق توده محصول در حال خشک شدن را توسط شبکه عصبی مدل کرد به‌نحوی که خروجی شبکه (تخمین رطوبت) به تغییرات ورودی شبکه بیشتر حساس باشد (۷). کوییلس^۲ و ریز^۳ (۳) برای

3- Reyes

4- Islam

5- Erenturk

1- Farkas

2- Cubillos

توجه به مزایای فناوری هوش مصنوعی استفاده از شبکه‌های عصبی مصنوعی در سطح وسیعی برای شبیه‌سازی و پیش‌بینی پارامترهای مورد نیاز در فرایندهای خشک کردن در حال رشد و توسعه است. هدف از انجام این تحقیق پیش‌بینی محتوای رطوبتی پیاز به کمک شبکه عصبی مصنوعی می‌باشد.

مواد و روش‌ها

شبکه‌های عصبی مصنوعی

شبکه‌ی عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری^۳ و با استفاده از پردازشگرهایی بنام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرایندهی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دست‌یابی به این شرایط فرایندهای یادگیری محقق شده است. این وزن‌ها حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود^(۴). با توجه به ساختار شبکه عصبی مصنوعی، ویژگی‌های عمدۀ آن، سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم دانش پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اخلال قابل توجه در صورت اشکال در بخشی از اتصال‌ها بهدلیل توزیع وزن‌های شبکه است^(۱۱). در این تحقیق از شبکه پرسپترون استفاده شد که به اختصار توضیح داده می‌شود:

۰/۳ و ۱/۱ متر بر ثانیه و طول نمونه در سه اندازه کمتر از ۳ میلی‌متر، بین ۳ تا ۶ میلی‌متر و بیشتر از ۶ میلی‌متر انجام شد. ۱۵۰ گرم از نمونه‌ها پس از خروج از یخچال تحت تیمارهای فوق در خشک کن قرار گرفت. تحلیل رگرسیونی با چهار مدل نیوتون، هندرسون و پایس، پیج و پیج اصلاح شده صورت گرفت و همزمان تحلیل در شبکه‌ی عصبی نیز صورت گرفت و شبکه بهینه دو لایه با یک لایه مخفی و ۳۰ نرون حاصل شد. نتایج به دست آمده حاکی از آن بود که مدل شبکه‌ی عصبی با ۱۰ درصد دقت بهتر از مدل پیج اصلاح شده ظرفیت رطوبت را تخمین زد^(۵). امیری چایجان^(۱) چهار متغیر وابسته‌ی آهنگ خروج محصول، آهنگ تغییر، میزان مصرف انرژی و ضریب تبدیل شلتوك به برنج سفید در خشک کن بستر ثابت را به کمک شبکه‌ی عصبی مصنوعی برآورد کرد. نتایج بررسی‌های ایشان نشان داد که بهترین نتایج برای شبکه پس انتشار پیشرو با توپولوژی ۴-۹-۱۲-۷ و الگوریتم آموزش لونبرگ - مارکوارت^(۱) تابع آستانه‌ی لگاریتم سیگموئید حاصل می‌گردد^(۱). مِنلیک^۲ و همکاران^(۱۲) رفتار خشک کردن انجام‌داده سیب را از طریق شبکه‌ی عصبی مصنوعی مورد بررسی قرار دادند. در این پژوهش، محتوای رطوبتی، نسبت رطوبت و آهنگ خشک کردن سیب تخمین زده شد. نتایج، نشان داد که شبکه‌ی عصبی مصنوعی توانست محتوای رطوبتی، نسبت رطوبت و آهنگ خشک کردن را به ترتیب با خسایب تبیین ۰/۹۹۹، ۰/۹۹۹ و ۰/۹۹۹ تخمین بزند^(۱۲). پیاز خوراکی به عنوان منبع غذایی و همچنین مصارف دارویی، امروزه بسیار مورد توجه قرار گرفته است. با افزایش بیش از پیش تولید پیاز خوراکی، نیاز به انبارداری، افزایش ماندگاری، کاهش ضایعات و استفاده از پودر پیاز بیشتر احساس می‌شود. به همین جهت خشک کردن این محصول به عنوان یکی از راهکارهای عملی همواره مطرح می‌باشد. امروزه با

1- Levenberg- Marquardt Algorithm

2- Menlik

نعمت پور ملک آباد و همکاران: پیش‌بینی محتوای رطوبتی پیاز خوارکی...

(MSE) و سرانجام برگشت به قسمت پ یا پایان آموزش.

الگوریتم‌های آموزش

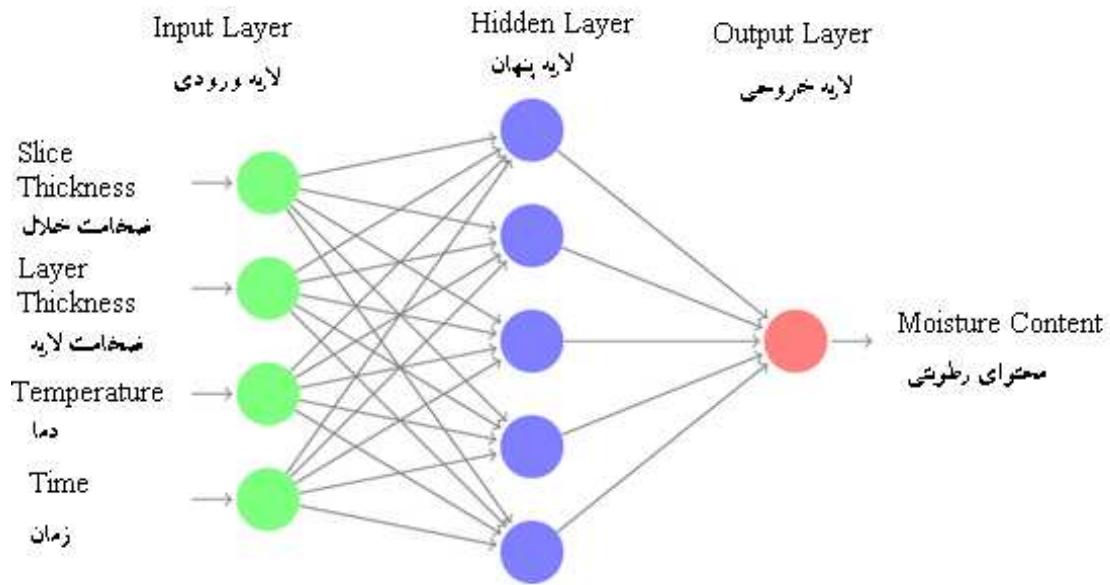
از الگوریتم‌های آموزش الگوریتم لونبرگ - مارکوارت برای بهنگام‌سازی وزن‌های شبکه عصبی مصنوعی استفاده شد که یکی از الگوریتم‌های پرکاربرد می‌باشد زیرا آموزش شبکه را بسیار سریع انجام می‌دهد و سطح خطای موجود را حداقل می‌سازد. در واقع این الگوریتم برای افزایش سرعت یادگیری شبکه طراحی شده که بر مبنای ماتریس هیسن می‌باشد.

خشک‌کن آزمایشگاهی و تجهیزات مورد استفاده

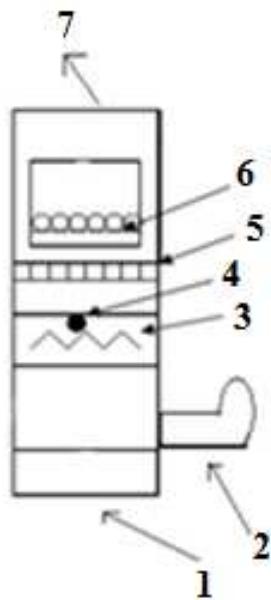
برای انجام این تحقیق ابتدا محصول از بازار خریداری و به آزمایشگاه انتقال داده شد. رطوبت اولیه محصول با استفاده از دستگاه آون اندازه گیری شد و بر پایه تر برابر $90/12$ به دست آمد. طی آزمایش خلال‌های $2, 4$ و 6 میلی-متری پیاز با استفاده از دستگاه خلال‌ساز در ضخامت‌های لایه $15, 30$ و 45 میلی-متر و با دماهای $60, 70$ و 80 درجه سلسیوس در سه تکرار، در سرعت هوای ثابت $1/5$ متر بر ثانیه از رطوبت $90/12$ در صد بر پایه تر تا 6 درصد بر پایه تر خشک شد. برای انجام آزمایش‌ها از یک خشک-کن آزمایشگاهی با جریان هوای اجباری و سینی ثابت مطابق شکل (۲) استفاده شد. این خشک-کن قابلیت کنترل دما و سرعت‌های مختلف را دارد و هوا به صورت عمودی به محصول برخورد می‌کند. در این خشک-کن از یک اینورتور برای کنترل دور فن و در نتیجه کنترل سرعت جریان هوا و از یک ترموموستات، برای کنترل دما استفاده گردید. هوا بعد از عبور از میان المنت‌های حرارتی وارد بخش خطی-کننده جریان شده تا هوا بیکه به نمونه‌های آزمایشی می‌رسد کانالیزه شود و به صورت یکسان در سطح مقطع خشک-کن پخش شود.

شبکه پرسپترون چند لایه (MLP)

این شبکه شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است (شکل ۱). برای آموزش این شبکه، معمولاً از الگوریتم پسانشار^۱ (BP) استفاده می‌شود. در طی آموزش شبکه پرسپترون به کمک الگوریتم یادگیری پسانشار، ابتدا محاسبات از ورودی شبکه به سوی خروجی شبکه انجام می‌شود و سپس مقادیر خطای محاسبه شده به لایه‌های قبل انتشار می‌یابد. در ابتدا، محاسبه خروجی به صورت لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود. در حالت پسانشار، ابتدا لایه‌های خروجی تعدیل می‌شود، زیرا برای هر یک از نمونه‌های لایه خروجی، مقدار مطلوبی وجود دارد و می‌توان به کمک آنها و قاعده‌های بهنگام‌سازی، وزن‌ها را تعديل نمود. با وجود اینکه الگوریتم پسانشار خطای نتایج بسیار خوبی در حل مسائل ارائه داده است، در حل برخی از مسائل ضعیف عمل می‌کند که این امر می‌تواند به دلیل طولانی بودن یا مشخص نبودن زمان یادگیری، انتخاب نامناسب ضریب یادگیری و یا توزیع تصادفی وزن‌های اولیه باشد. در برخی موارد نیز به دلیل وجود کمینه موضعی، فرایند یادگیری مختل می‌شود که به دلیل قرار گرفتن جواب در قسمت‌های هموار توابع آستانه دچار وقفه می‌شود. مراحل آموزش به کمک این الگوریتم عبارتند از (۴) و (۱۱): (الف)- اختصاص ماتریس وزن تصادفی به هر یک از اتصالات (ب)- انتخاب بردار ورودی و خروجی متناسب با آن (پ)- محاسبه خروجی نمون در هر لایه و در نتیجه محاسبه خروجی نمون‌ها در لایه خروجی (ت)- بهنگام‌سازی وزن‌ها به روش انتشار خطای شبکه به لایه‌های قبل که خطای یاد شده ناشی از اختلاف بین خروجی واقعی و خروجی محاسبه شده است. (ث)- ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص‌های تعریف شده مانند جذر میانگین مربعات خطأ



شکل (۱) معماری شبکه عصبی مصنوعی
Figure (1) Neural network architecture



شکل (۲) شماتیک خشک کن مورد استفاده: ۱- ترازوی دیجیتال، ۲- دمنده و کانال هوای ورودی به محفظه خشک کن، ۳- هیتر، ۴- ترمومتر، ۵- خطی کننده جریان هوا، ۶- سینی محصول، ۷- محل خروج هوا

Figure (2) Schematic dryer used: 1. digital scale, 2. channel blower and dryer air inlet chamber, 3. heater, 4. thermostat, 5. linear air flow, 6. product trays, 7. air exit

نعمت پور ملک آباد و همکاران: پیش‌بینی محتوای رطوبتی پیاز خوارکی...

یکی از مشکلاتی که هنگام آموزش شبکه عصبی ممکن است پیش بیاید، بیش آموزی شبکه است؛ بدین-صورت که در هنگام آموزش شبکه، خطاب به مقدار قابل قبول می‌رسد ولی هنگام ارزیابی، خطای شبکه به مراتب از خطای داده‌های آموزشی بیشتر است^(۸). برای جلوگیری از بیش آموزی دو راه وجود دارد: الف-توقف سریع آموزش^(۹)، ب- انتخاب کمترین تعداد نرون در لایه پنهان (۶). در این تحقیق از روش دوم استفاده شد. بدین صورت که برای آموزش شبکه، ابتدا داده‌ها به طور تصادفی به سه قسمت تقسیم شدند، طوری که ۶۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای ارزیابی و ۲۰ درصد داده‌ها برای تست شبکه در محدوده (۰-۱) نرمال و استفاده شدند. درین آموزش شبکه، زمانی که خطای بین داده‌های آموزش و ارزیابی شروع به افزایش کند، فرآیند آموزش قطع می‌شود. برای یافتن شبکه عصبی با تپولوژی مناسب به کمک الگوریتم آموزشی، از معیار خطای مجموع مربعات میانگین استفاده شد. هدف کمینه شدن خطای مذکور است که با رابطه زیر تعریف می‌شود.

(۴)

$$MSE = \frac{\sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2}{n_p * n_o}$$

که در آن MSE خطای مربعات میانگین در مرحله تست، Sip خروجی شبکه در نرون آم و الگوی Tip، N تعداد نرون- خروجی هدف در نرون آم و الگوی Tip، M تعداد الگوی های لایه خروجی و n_p تعداد الگوی های تست است. برای ارزیابی شبکه انتخاب شده در مرحله قبل از معیار ضریب تعیین (R^2) برای داده‌های پیش‌بینی شده در حین آموزش شبکه استفاده شد.

نتایج و بحث

شکل‌های (۳)، (۴) و (۵) تاثیر دما و ضخامت خلال را در ضخامت لایه‌های مختلف بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه نشان می‌دهد.

تعیین محتوای رطوبتی در طول آزمایش‌ها

با داشتن جرم ماده خشک محصول و جرم محصول در هر فاصله زمانی که اندازه گیری شده است؛ محتوای رطوبت لحظه‌ای از رابطه زیر قابل محاسبه است:

(۱)

$$X_i = \frac{(m_i - m_d)}{m_i} \times 100$$

در این معادله X_i نسبت رطوبت بر پایه‌ی تر در فاصله زمانی i ، m_i مقدار جرم محصول در فاصله زمانی i و m_d وزن خشک محصول بر حسب کیلوگرم می‌باشد. با داشتن رطوبت و جرم اولیه محصول و رطوبت نهایی، مقدار جرم نهایی محصول تعیین می‌شود. در هنگام خشک کردن محصول، زمانی که جرم محصول به جرم نهایی از پیش تعیین شده برسد، فرآیند خشک شدن قطع می‌شود.

معماری شبکه عصبی مصنوعی

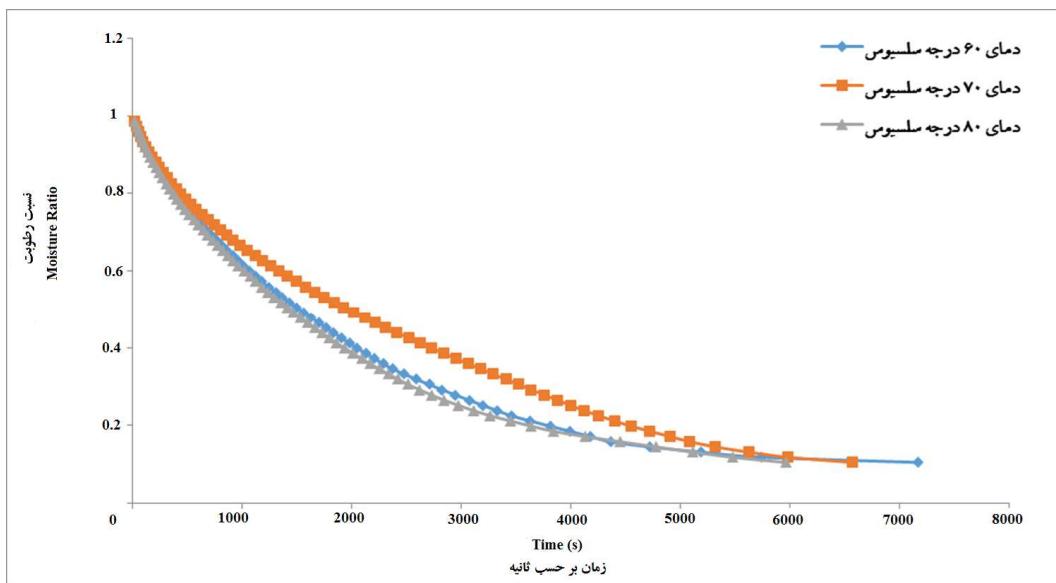
به طور کلی با آزمایش‌های انجام شده دو الگو ایجاد گردید، در الگوی اول ضخامت خلال، ضخامت لایه، دما و زمان به عنوان ورودی و محتوای رطوبتی به عنوان خروجی در نظر گرفته شد. در الگوی دوم ضخامت خلال، ضخامت لایه، دما و محتوای رطوبتی به عنوان ورودی و پیش‌بینی مدت زمان لازم برای خشک شدن به عنوان خروجی تعیین گردید. در پژوهش حاضر از الگوی اول استفاده شد. شبکه عصبی با چهار نرون لایه ورودی (ضخامت خلال، ضخامت لایه، دما و زمان) و یک نرون لایه خروجی (پیش‌بینی محتوای رطوبتی) طراحی شد (شکل ۴). در این تحقیق از نرم افزار Qnet2000 استفاده گردید. از شبکه پرسپترون یک لایه برای پیش‌بینی استفاده شد و همچنین توابع آستانه مختلفی برای یافتن حالت بهینه آن مورد ارزیابی قرار گرفت که عبارتند از:

(۲) تابع سیگموئیدی لگاریتمی

$$\text{Logsig} = \frac{1}{1 + \exp(X_i)}$$

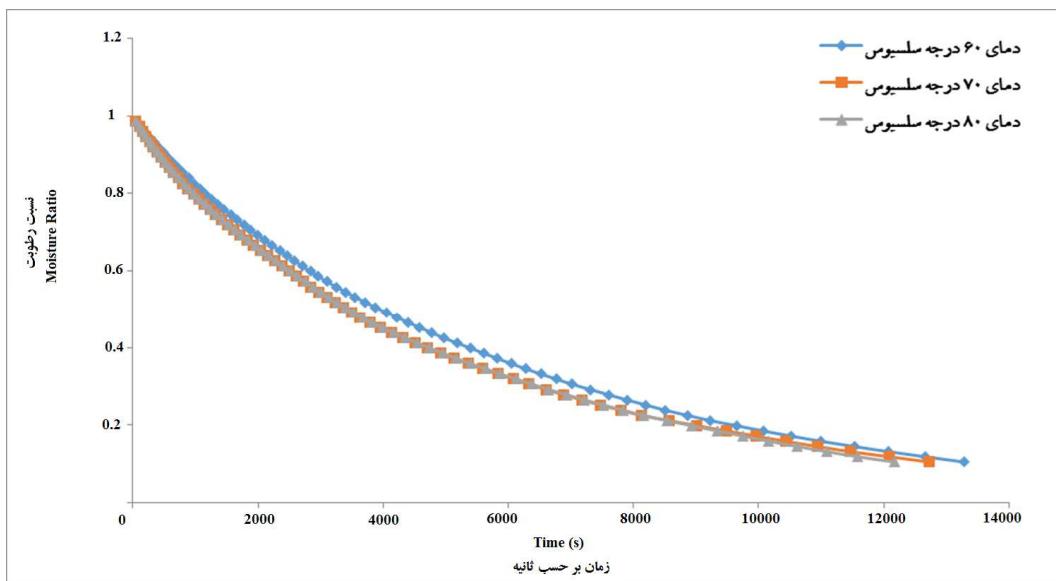
(۳) تابع تانژانت سیگموئیدی

$$\text{Tansig} = \frac{2}{(1 + \exp(-2X_i))} - 1$$



شکل (۳) a تأثیر دما و ضخامت خلال ۲ میلی‌متر در ضخامت لایه ۱۵ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

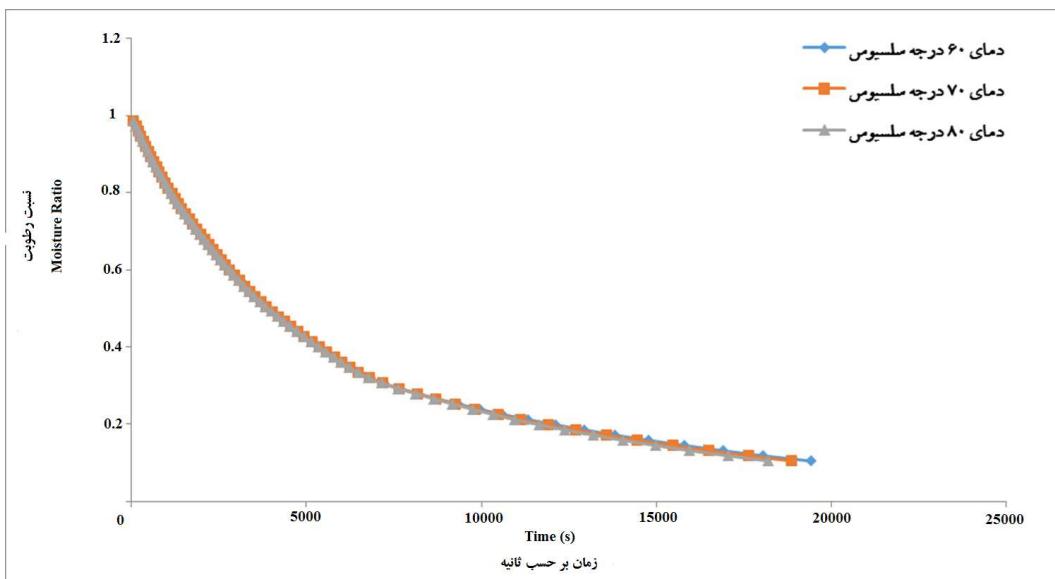
Figure (3) a The effect of temperature and 2 mm thickness on the 15 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second



شکل (۳) b تأثیر دما و ضخامت خلال ۴ میلی‌متر در ضخامت لایه ۱۵ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

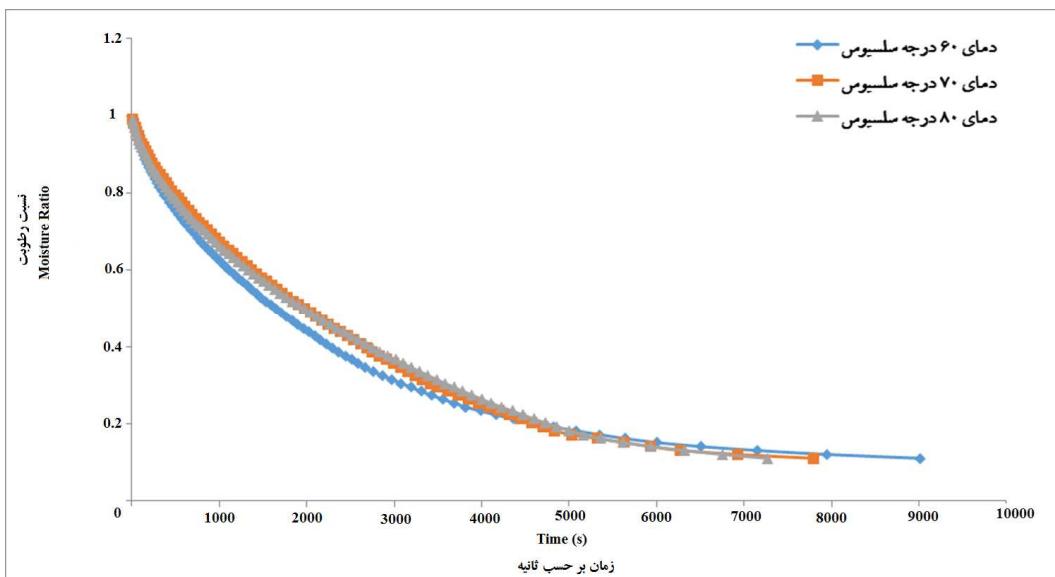
Figure (3) b The effect of temperature and 4 mm thickness on the 15 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second

نعمت پور ملک آباد و همکاران: پیش‌بینی محتوای رطوبتی پیاز خوراکی...



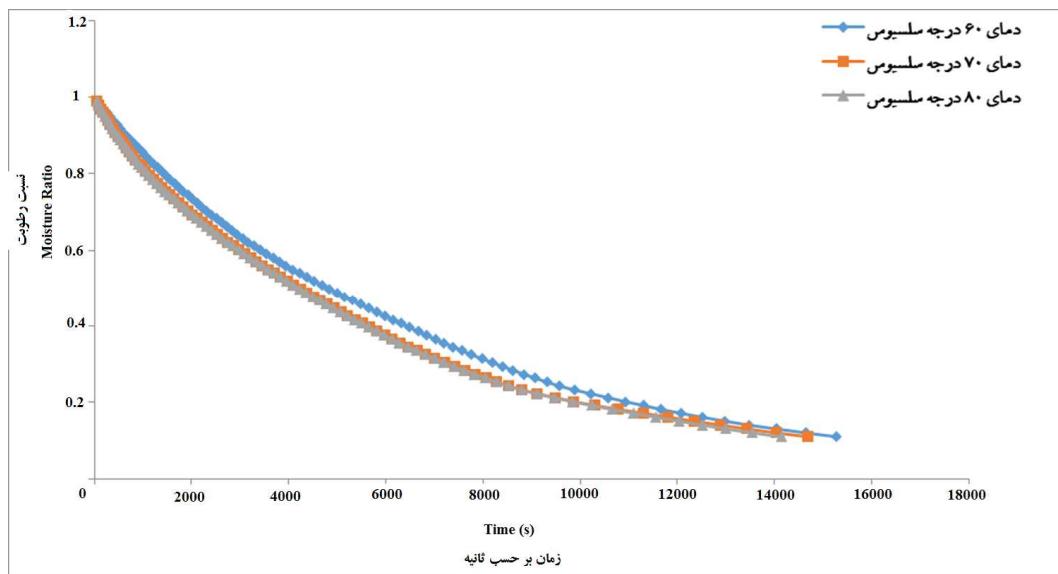
شکل (۳) پ تاثیر دما و ضخامت خلال ۶ میلی‌متر در ضخامت لایه ۱۵ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

Figure (3) c The effect of temperature and 6 mm thickness on the 15 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second



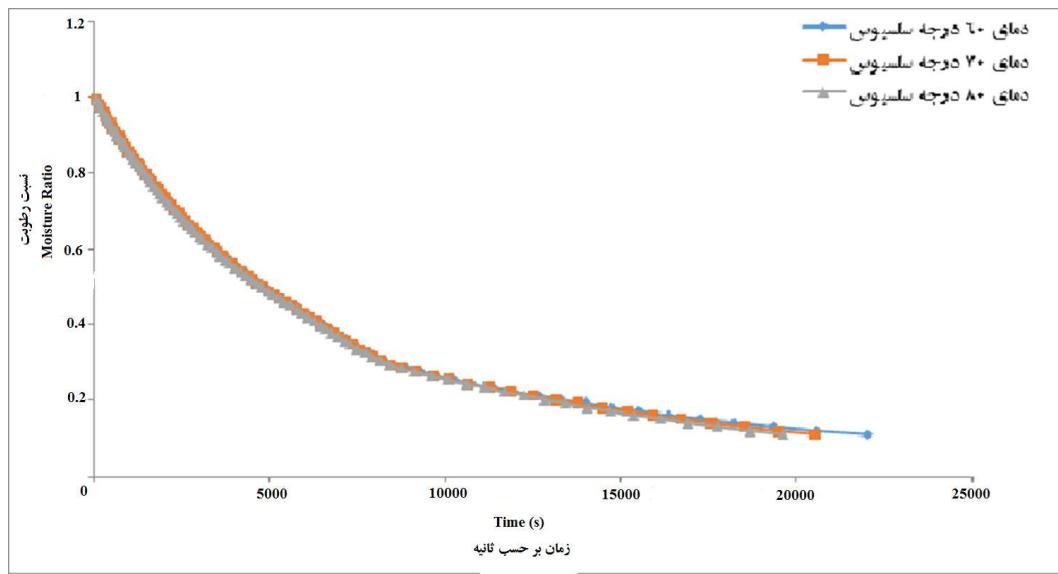
شکل (۴) الف تاثیر دما و ضخامت خلال ۲ میلی‌متر در ضخامت لایه ۳۰ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

Figure (4) a The effect of temperature and 2 mm thickness on the 30 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second



شکل (۴) ب تأثیر دما و ضخامت خالل ۴ میلی‌متر در ضخامت لایه ۳۰ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

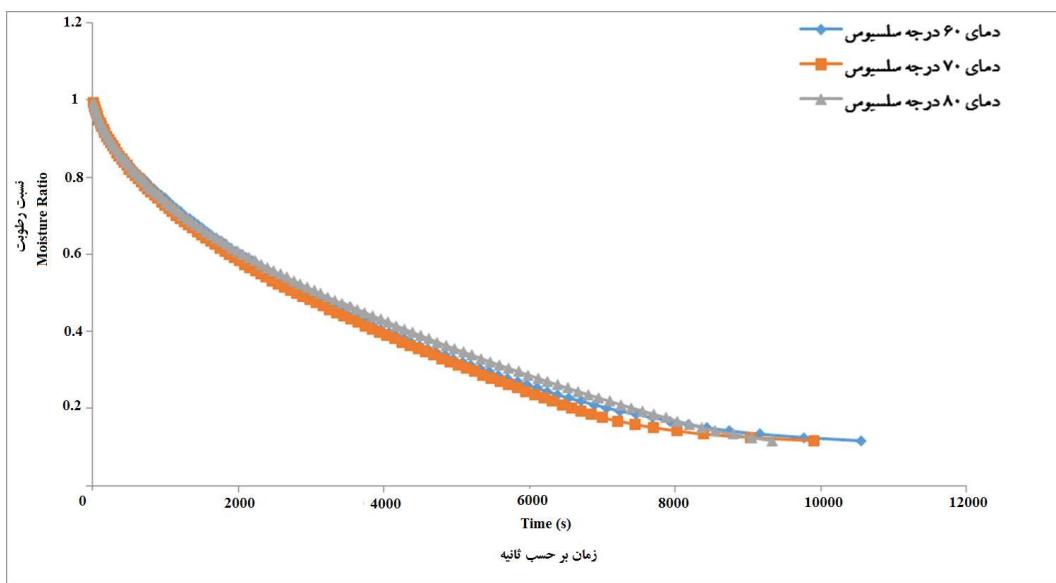
Figure (4) b The effect of temperature and 4 mm thickness on the 30 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second



شکل (۴) پ تأثیر دما و ضخامت خالل ۶ میلی‌متر در ضخامت لایه ۳۰ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

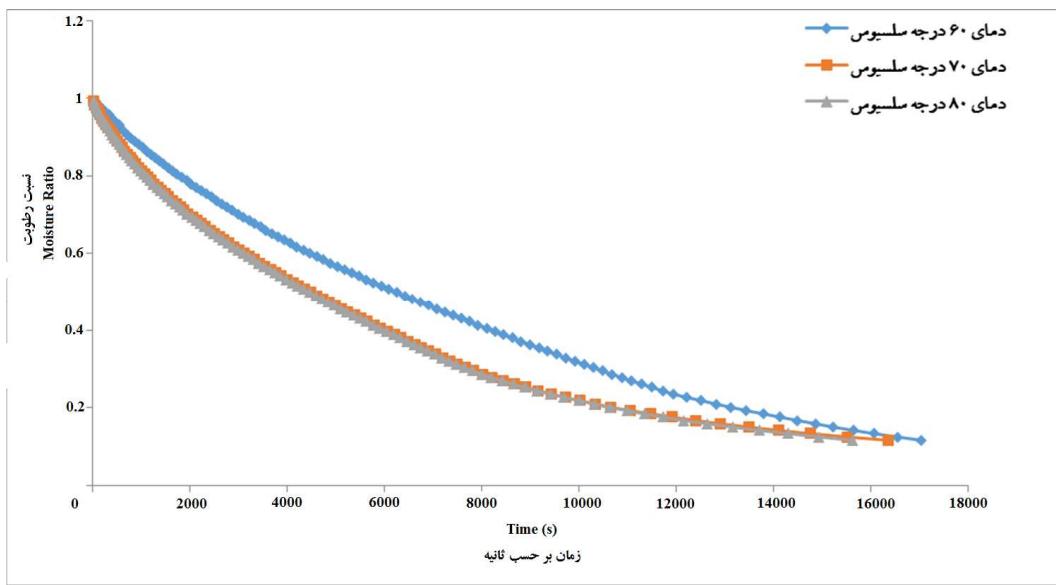
Figure (4) c The effect of temperature and 6 mm thickness on the 30 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second

نعمت پور ملک آباد و همکاران: پیش‌بینی محتوای رطوبتی پیاز خوراکی...



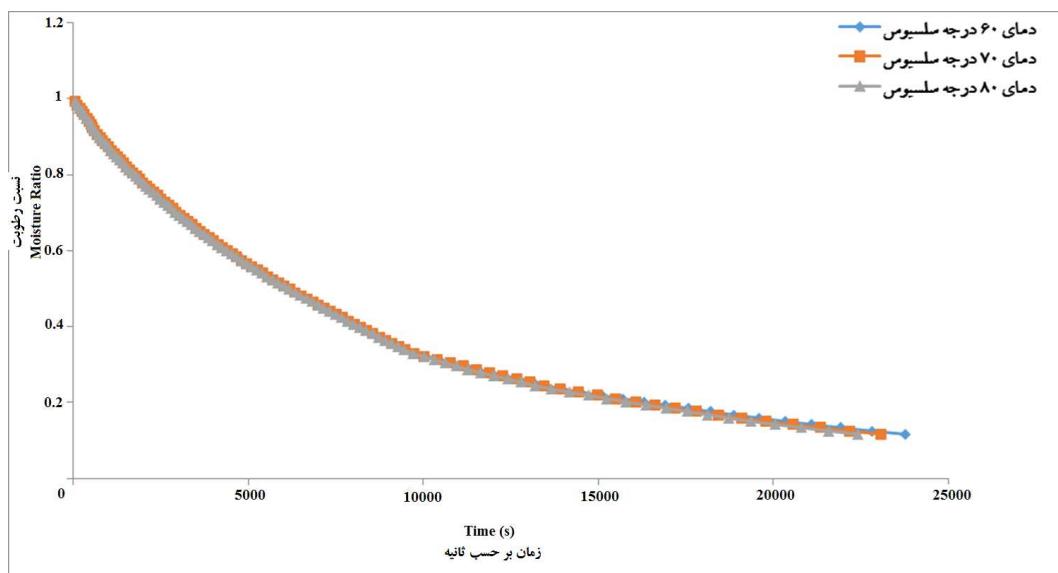
شکل (۵) a) تأثیر دما و ضخامت خالل ۲ میلی‌متر در ضخامت لایه ۴۵ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

Figure (5) a The effect of temperature and 2 mm thickness on the 45 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second



شکل (۵) b) تأثیر دما و ضخامت خالل ۴ میلی‌متر در ضخامت لایه ۴۵ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۵ متر بر ثانیه

Figure (5) b The effect of temperature and 4 mm thickness on the 45 mm layer thickness on moisture ratio changes at a speed of 1.5 meters per second



شکل (۵) پ تاثیر دما و ضخامت خلال ۶ میلی‌متر در ضخامت لایه ۴۵ میلی‌متر بر تغییرات نسبت رطوبت با زمان در سرعت ۱/۰ متر بر ثانیه

Figure (5) c The effect of temperature and 6 mm thickness on the layer 45 mm thickness on moisture ratio changes at a speed of 1.5 meters per second

جدول (۱) نتایج حاصل از بکارگیری الگوریتم یادگیری (LM) تابع آستانه (Tansig) با یک لایه پنهان در شبکه با استفاده از نرم‌افزار (Qnet2000) در ۱۰۰۰۰ (Iteration)

Table (1) Results of LM learning algorithm threshold function Tansig with a hidden layer of software on a network using Qnet2000 in Iteration 10000

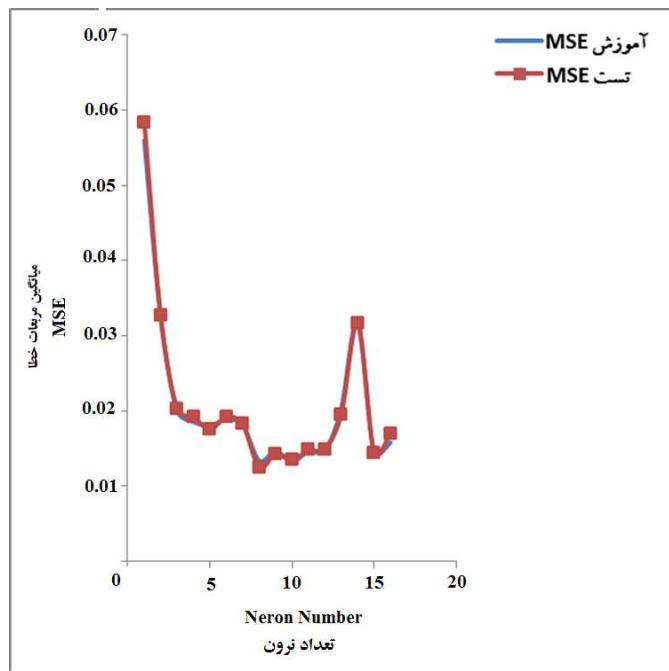
تپولوژی (Topology)	(Training MSE)	میانگین مربعات خطای آموزش (Training MSE)	ضریب تبیین آموزش (Training R ²)	ضریب تبیین تست (Test R ²)
4-1-1	0.056	0.058	0.962	0.959
4-2-1	0.032	0.033	0.987	0.987
4-3-1	0.020	0.020	0.995	0.995
4-4-1	0.019	0.019	0.996	0.995
4-5-1	0.018	0.018	0.997	0.997
4-6-1	0.019	0.019	0.996	0.996
4-7-1	0.018	0.018	0.996	0.996
4-8-1	0.013	0.013	0.998	0.998
4-9-1	0.015	0.014	0.997	0.997
4-10-1	0.013	0.013	0.998	0.998
4-11-1	0.015	0.015	0.997	0.997
4-12-1	0.015	0.015	0.997	0.997
4-13-1	0.020	0.020	0.995	0.995
4-14-1	0.032	0.032	0.996	0.996
4-15-1	0.015	0.014	0.998	0.998
4-16-1	0.016	0.017	0.997	0.997

نعمت پور ملک آباد و همکاران: پیش‌بینی محتوای رطوبتی پیاز خوراکی...

جدول (۲) نتایج حاصل از بکارگیری الگوریتم یادگیری (LM) تابع آستانه (Logsig) با یک لایه پنهان در شبکه با استفاده از نرم‌افزار (Qnet2000) در مرحله ۱۰۰۰۰ (Iteration)

Table (2) Results of LM learning algorithm threshold function Logsig with a hidden layer of software on a network using Qnet2000 in Iteration 10000

توپولوژی	میانگین مربعات خطای آموزش	میانگین مربعات خطای تست	ضریب تبیین آموزش	ضریب تبیین تست	(Test R ²)	(Training R ²)	(Test MSE)	(Training MSE)	(Topology)
4-1-1	0.093	0.092	0.093	0.093	0.908	0.904	0.093	0.092	4-1-1
4-2-1	0.035	0.032	0.035	0.032	0.985	0.987	0.035	0.032	4-2-1
4-3-1	0.032	0.033	0.032	0.033	0.986	0.987	0.032	0.033	4-3-1
4-4-1	0.036	0.032	0.036	0.032	0.985	0.987	0.036	0.032	4-4-1
4-5-1	0.033	0.033	0.033	0.033	0.987	0.987	0.033	0.033	4-5-1
4-6-1	0.023	0.022	0.023	0.023	0.994	0.994	0.023	0.022	4-6-1



شکل (۶) مقایسه (MSE) آموزش و تست شبکه با تابع آستانه (Tansig) در نرون‌های مختلف لایه پنهان

Figure (6) Comparison of the MSE training and testing the network with hidden layer threshold function Tansig in different Nerons

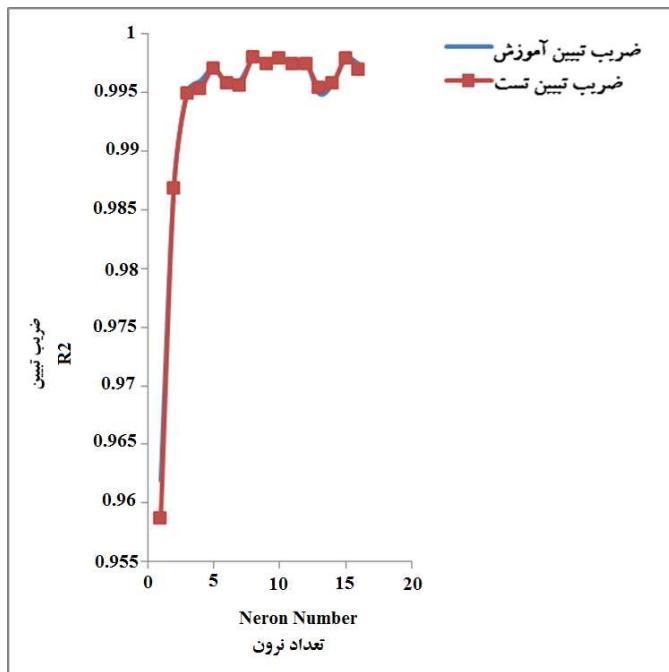
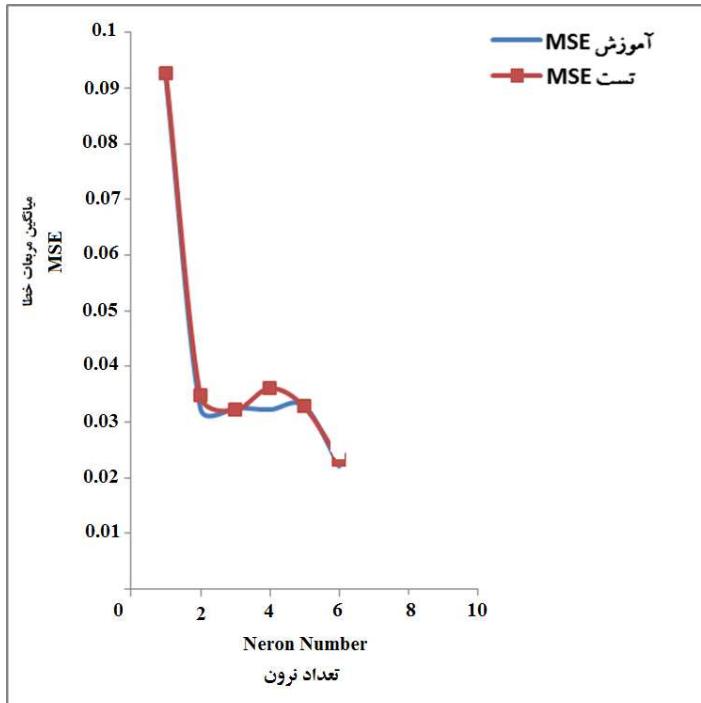
شکل (۷) مقایسه (R^2) آموزش و تست شبکه با تابع آستانه (Tansig) در نرون‌های مختلف لایه پنهان

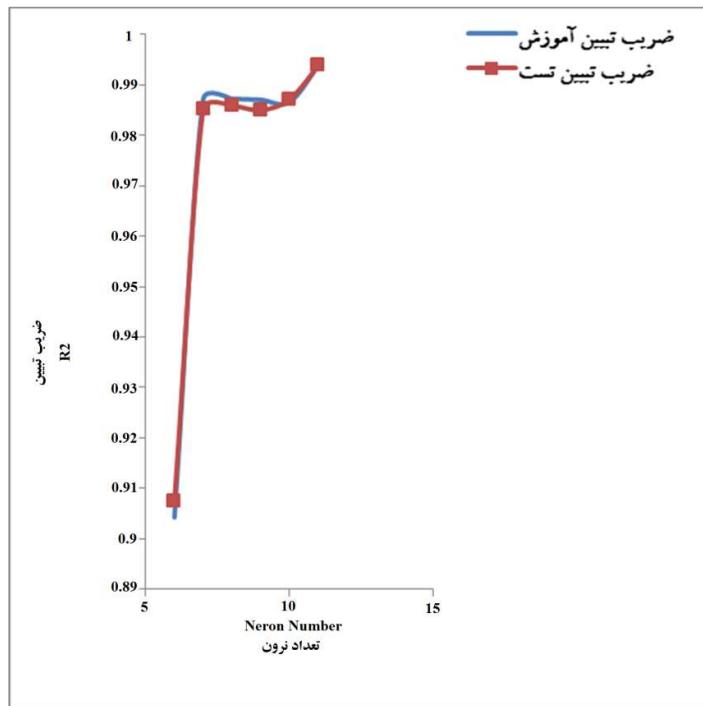
Figure (7) Comparison of the R^2 training and testing the network with hidden layer threshold function Tansig in different Neurons



شکل (۸) مقایسه (MSE) آموزش و تست شبکه با تابع آستانه (Logsig) در نuron‌های مختلف (Logsig)

Figure (8) Comparison of the MSE training and testing the network with hidden layer threshold function Logsig in different Neurons

نعمت پور ملک آباد و همکاران: پیش‌بینی محتوای رطوبتی پیاز خوراکی...



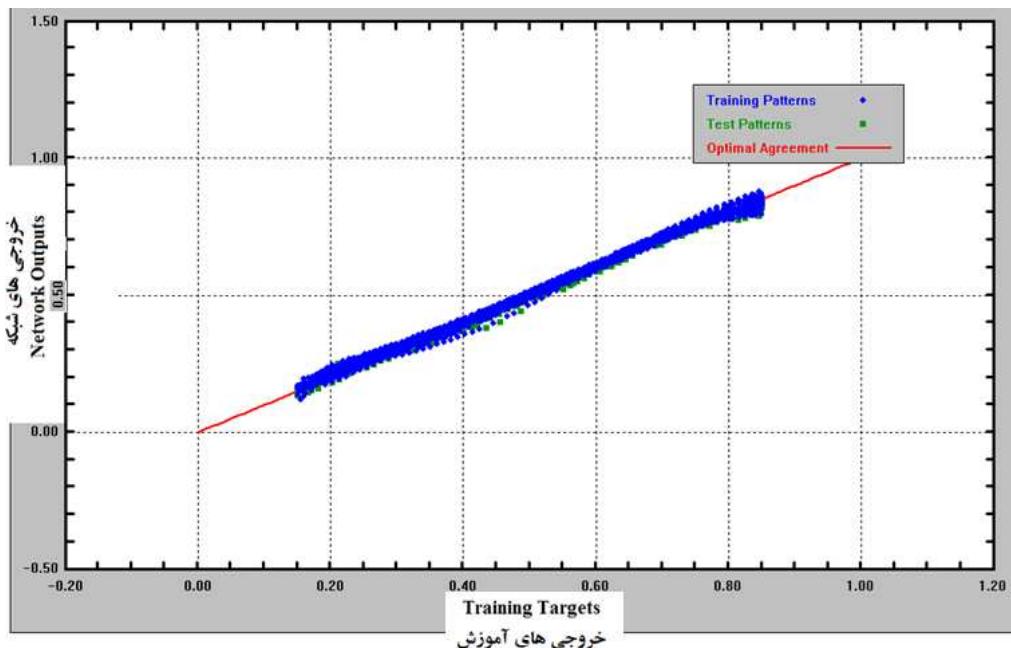
شکل (۹) مقایسه (R^2) آموزش و تست شبکه با تابع آستانه (Logsig) در نرون‌های مختلف لایه پنهان
Figure (9) Comparison of the R^2 training and testing the network with hidden layer threshold function Logsig in different Neurons

اولیه پروسه خشک کردن از دست می‌دهد و زمان زیادی برای از دست دادن رطوبت باقیمانده لازم است. با توجه به جداول (۱)، (۲) و شکل‌های (۶)، (۷)، (۸) و (۹) در توابع تبدیل Tansig و Logsig به ترتیب با تعداد ده و شش نرون در لایه مخفی و با $R^2 = 0.998$ و $MSE = 0.013$ با مقادیر 0.022 و 0.013 مناسب‌ترین آرایش برای شبکه بدست آمدند. با توجه به مقادیر به دست آمده برای R^2 و MSE توپولوژی‌های دارای یک لایه پنهان (۱۰-۱ و ۴-۶-۱) به عنوان توپولوژی‌های بهینه انتخاب شدند. جدول (۱) و شکل‌های (۶) و (۷) به ترتیب مقایسه MSE و R^2 ، مقادیر آموزش و تست شبکه با افزایش تعداد نرون‌ها در تابع آستانه Tansig می‌باشند که مقادیر آموزش و تست شبکه به هم بسیار نزدیک بوده که نشان از کارایی مناسب شبکه دارد. در جدول (۲) و شکل‌های (۸) و (۹) نیز به ترتیب

با توجه به شکل‌های به دست آمده آمده نتیجه‌گیری شد که تغییر پارامترهای ضخامت خلال، ضخامت لایه و دما اثرات بسیار معنی‌داری بر زمان لازم برای فرآیند خشک شدن دارند. کاهش ضخامت خلال، کاهش ضخامت لایه و افزایش دما موجب کاهش زمان لازم برای فرآیند خشک شدن می‌شوند. نتایج نشان می‌دهد که کاهش ضخامت خلال در مقایسه با کاهش ضخامت لایه و افزایش دما تأثیر بیشتری بر کاهش زمان لازم برای فرآیند خشک شدن نشان می‌دهد. در شروع پروسه خشک کردن، رطوبت اولیه محصول زیاد بوده و نرخ از دست دادن رطوبت زیاد است، بتدریج با پیشرفت زمان محتوی رطوبت محصول به طور طبیعی کاهش پیدا کرده و نرخ کاهش رطوبت به طور طبیعی کاهش می‌یابد. محصول عمدۀ رطوبت خود را در لحظات

کردن پرنتال معرفی کردند (۱۳). اسلام و همکاران (۹) نیز بیان کردند توپولوژی‌های دارای یک لایه پنهان بهترین برآذش را در خشک کردن ورقه‌های گوجه-فرنگی نشان می‌دهند. امیری چایجان و همکاران (۱) شبکه پس انتشار پیشخور و الگوریتم آموزش لونبرگ-مارکوارت را بهترین شبکه عصبی خشک کردن بستر سیال شلتوك برنج در نظر گرفتند. بنابراین می‌توان با استناد به نتایج سایر محققان و همچنین نتایج به دست آمده در این پژوهش نتیجه گرفت که شبکه‌های عصبی پرسپترون یک لایه پرسپترون با الگوریتم آموزش لونبرگ-مارکوارت و اکثرا توپولوژی‌های دارای یک لایه پنهان بهترین مدل شبکه عصبی برای پیش‌بینی سیستیک خشک کردن انواع مختلف میوه‌ها و سبزی‌ها می‌باشد

مقایسه R^2 و MSE، مقادیر آموزش و تست شبکه با افزایش تعداد نرون‌ها درتابع آستانه Logsig می‌باشد که در هر دو آن‌ها مقادیر آموزش و تست شبکه نیز به هم بسیار نزدیک بوده و در نهایت می‌توان گفت که از میان دوتابع آستانه مذکور، تابع آستانه Tansig با توپولوژی بهینه (۱۰-۱۱-۴) کارایی مناسب‌تری داشته که در شکل (۱۰) رگرسیون خروجی‌های شبکه برای این توپولوژی ارائه شده است. در شکل (۱۰) مقادیر آموزش، تست و خط بهینه برای شبکه در این توپولوژی بسیار به هم نزدیک بوده و تقریباً می‌توان گفت که بر هم منطبق است، که R^2 و MSE آن به ترتیب ۰/۹۹۸ و ۰/۰۱۳۳ می‌باشد و نشان از کاربرد مناسب شبکه دارد. برای تائید نتایج به دست آمده می‌توان گفت که شریفی و همکاران از بین مدل‌های موجود، شبکه عصبی پس انتشار پیشخور با الگوریتم آموزش لونبرگ-مارکوارت با توپولوژی‌های دارای یک لایه پنهان (۱۱-۵-۱)، (۱-۶-۳) و (۳-۷-۱) را بهترین مدل عصبی خشک



شکل (۱۰) رگرسیون خروجی‌های شبکه عصبی مصنوعی با تعداد ۱۰ نرون در لایه مخفی و با تابع آستانه Tansig (مناسب-توین توپولوژی برای شبکه) با استفاده از نرم‌افزار Qnet2000 در ۱۰۰۰۰ Iteration

Figure (10) Outputs regression neural network with ten neurons in the hidden layer and the threshold function Tansig (the most suitable criteria for network topology) using software Qnet2000 in Iteration 10000

نعمت پور ملک آباد و همکاران: پیش‌بینی محتوای رطوبتی پیاز خوارکی...

برای لایه‌ها با تپولوژی (۱-۱۰-۴)، ضربی Tansig
تبیین $0/998007$ و $0/013283$ MSE برای ضخامت-
های ۲، ۴ و ۶ میلی‌متری ورقه‌های پیاز در شرایط
مختلف خشک کردن لایه نازک پیاز می‌باشد.
نتایج بدست آمده نشان از قابلیت شبکه‌های عصبی
به عنوان ابزاری برای پیش‌بینی تغییرات محتوای رطوبتی
با زمان است که می‌تواند در سیستم‌های کنترل خشک-
کن به کار رود.

نتیجه‌گیری

نتایج حاصل از این تحقیق نشان می‌دهد که:
شبکه عصبی مصنوعی، محتوی رطوبتی ورقه‌های
نازک پیاز را به کمک چهار پارامتر ورودی ضخامت
خلال، ضخامت لایه، دما و مدت زمان لازم برای خشک
کردن پیش‌بینی می‌کند. بهترین شبکه عصبی برای
آموزش داده‌ها، شبکه پرسپترون یک لایه با الگوریتم
آموزش لونبرگ - مارکوارت و تابع فعال‌سازی

منابع

- Amiri Chayjan, R., 2006. Intelligent Prediction of drying process of Rice. P.h.d thesis. Department of Mechanic of Agricultural Machinery. Agricultural faculty. Tarbiat Modares University. (In Persian with English abstract)
- Cohen, J.S., and Yang, T.C.S. 1995. Progress in food dehydration. Trends in Food Science and Technology, 6: 20-25.
- Cubillos, F., and Reyes, A. 2003. Design of a model based on a modular neural network approach. Drying Technology, 21, 7: 1185-1195.
- Dayhoff, J. E. 1990. Neural Network Principles. Prentice-Hall International. U.S.A.
- Erenturk, K., Erenturk, S., and Lope, G. 2004. A comparative study for the estimation of dynamical drying behavior of *Echinacea angustifolia*: regression analysis and neural network. Computers and Electronics in Agriculture, 45, 3: 71-90.
- Erenturk, S., and Erenturk, K. 2007. Comparison of genetic algorithm and neural network approaches for the drying process of carrot. Journal of Food Engineering, 78: 905–912.
- Farkas, I., Reményi, P., and BirÓ, B. 2000b. Modeling aspects of grain drying with a neural network. Computers and Electronics in Agriculture, 29: 99-113.
- Hernandez-Perez, J. A., Garcia-Alvarado, M. A., Trystram, G., and Heyd, B. 2004. Neural networks for the heat and mass transfer prediction during drying of cassava and mango. Innovative Food Science and Emerging Technologies, 5: 57–64.
- Islam, M. R., sablani, S. S., and Mujumdar. A. S. 2003. An artificial neural network model for prediction of drying rates. Drying Technology, 21, 9: 1867-1884.
- Karathanos, V.T. and Belessiotis, V.G. 1999. Application of a thin layer equation to drying data fresh and semi-dried fruits. Journal of Agricultural Engineering Research, 74: 355-361.

11. Khanna, T. 1990. Foundation of neural networks. Addison-Wesley Publishing Company. U.S.A.
12. Menlik, T., Ozdemir, M.B., and Kirmaci, V. 2010. Determination of freeze-drying behaviors of apples by artificial neural network. Journal of Expert Systems with Applications, 37: 7669-7677.
13. Sharifi, M., Rafiee, Sh., Keyhani, A., and Omid, M. 2010. Orange thin layer drying kinetics simulation model (var. Thomson) using artificial neural networks. Journal of Food Science and Technology, 45, 11: 1-11. (In Persian with English abstract)