

کاربرد شبکه عصبی مصنوعی در پیش بینی محتوای رطوبتی در طی فرآیند خشک کردن انگور (۵۴۸)

ناصر بهروزی خزاعی^۱، تیمور توکلی^۲، رضا امیری چایجان^۳، محمد هادی خوش تقاضا^۴

چکیده

هدف از این تحقیق پیش‌بینی محتوای رطوبتی انگور در طی خشک کردن با جریان هوای گرم به عنوان تابعی از دما و سرعت هوا به کمک شبکه های عصبی مصنوعی است. در این تحقیق اثر عوامل تاثیرگذار دمای هوا در سه سطح (۵۰، ۶۰ و ۷۰ درجه سلسیوس) و سرعت هوا در چهار سطح (۰/۲۵، ۰/۵، ۰/۷۵ و ۱ متر بر ثانیه) بر تغییرات محتوای رطوبتی استفاده شد. برای ایجاد الگوهای آموزش و ارزیابی و تست به کمک یک خشک‌کن آزمایشگاهی، آزمایش‌های خشک کردن انجام گرفت. با به دست آمدن تغییرات محتوای رطوبتی با زمان از شبکه‌های TDNN و MLP با الگوریتم‌های یادگیری لونیبرگ-مارکوارت برای آموزش الگوها استفاده شد. شبکه عصبی TDNN نتایج بهتری نسبت به شبکه عصبی MLP نشان داد. شبکه TDNN با ساختار ۱-۸-۳ با تابع آستانه سیگموئید لگاریتمی در مقایسه با توپولوژی‌های دیگر نتایج بهتری را ارائه کرد. این توپولوژی تغییرات محتوای رطوبتی را با ضرایب تعیین ۰/۹۹۷۹ پیش بینی کرد.

کلیدواژه: خشک کردن انگور، محتوای رطوبتی، شبکه عصبی مصنوعی

۱- دانشجوی کارشناسی ارشد گروه مکانیک ماشین های کشاورزی، دانشگاه تربیت مدرس، پست الکترونیک: nasserbehroozi@yahoo.com

۲ و ۳- عضو هیئت علمی گروه مکانیک ماشین های کشاورزی، دانشگاه تربیت مدرس، تهران

۴- عضو هیئت علمی گروه مکانیک ماشین های کشاورزی، دانشگاه ابوعلی سینا، همدان

مقدمه:

خشک کردن یکی قدیمی ترین راههای نگهداری مواد غذایی است که برای جلوگیری از خرابی مواد غذایی با کاهش دادن محتوای رطوبتی منجر به کاهش یا توقف فعالیت های آنزیمی یا میکروبی می شود و از طرف دیگر محصولات با وزن و حجم کم تولید می شود که جابجایی و فرآوری آنها آسانتر می شود.

بیشتر کشمش تولیدی در ایران به این صورت بدست می آید که انگور بعد از چیده شدن و شسته شدن در محلول تیزابی، در محلی که اصطلاحاً بارگاه گفته می شود، به صورت یکنواخت پهن می شود. در این روش خشک کردن به خاطر معایبی همچون طولانی شدن زمان خشک شدن، اضافه شدن گرد و خاک، حمله آفات و شرایط نامعلوم هوا کیفیت کشمش تولیدی کاهش می یابد. به همین دلیل از نظر ارزش هر تن کشمش صادراتی، ایران در رده دهم جهان قرار دارد. علاوه بر آن در این روش خشک کردن تهیه کشمش محدود و نیاز به نیروی کاری زیاد دارد [۱، ۲]. در اکثر کشورها برای جلوگیری از آلودگی ها و سرعت بخشیدن به عمل خشک شدن، خشک کردن با خشک کن های صنعتی (خشک کن های با جریان هوای گرم و خورشیدی) جایگزین روش های سنتی گردیده است و از این طریق توانسته اند محصولات با کیفیت بالاتر و بدون ضایعات را در زمانی کوتاهتری بدست آورند. از معایب عمده خشک کن های خورشیدی محدود بودن زمان تابش خورشید و فصل کوتاه برداشت برای اکثر محصولات کشاورزی است. خشک کن های جریان هوای گرم بخصوص برای محصولات مثل انگور که زمان زیادی برای خشک شدن نیاز دارند، فرایند خشک شدن تسریع و با ایجاد شرایط بهداشتی و یکنواختی محصول نهایی برای خشک کردن محصولات کشاورزی اجتناب ناپذیر است [۵].

بنابراین خشک کردن انگور تحت هوای گرم یکی از روش های موثر در کاهش ضایعات و افزایش کیفیت کشمش حاصله است که نیاز به طراحی و بهینه سازی خشک کن می باشد. یکی از پارامترهای موثر در آنالیز طراحی و بهینه سازی خشک کن ها، پیش بینی و مدل کردن فرآیند خشک کردن می باشد. یکی از مهمترین قسمت های فرآیند خشک کردن، پیش بینی تغییرات محتوای رطوبتی در طی زمان است. توسعه روش های متداول بر پایه اصول اولیه برای پیش بینی فرآیند زمان زیادی صرف می کند و دقت نتایج بدست آمده از آنها رضایت بخش نیست. شبکه های عصبی مصنوعی قدرت تامین دقت و سرعت لازم را برای پیش بینی فرآیند خشک کردن را دارند

رسیدن به محتوای رطوبتی مطلوب در خشک کردن انگور بخاطر این که تحت تاثیر چندین پارامتر متغیر که رابطه غیر خطی با آنها دارد، سخت و زمان بر است. همچنین خشک کردن بیش از حد، انرژی زیادی مصرف می کند و روی شاخص های کیفی محصول خشک شده تاثیر می گذارد و اگر رطوبت به حد مطلوب پایین آورده نشود، باعث کپک زدن محصول می شود، بنابراین رسیدن به یک محتوای رطوبتی مطلوب یکی از شاخص های کلیدی در فرآیند خشک کردن است. اندازه گیری محتوای رطوبتی در هنگام خشک کردن به خاطر محدودیت فنی حسگرهای موجود در این زمینه که از دقت کافی برخوردار نیستند و نمی توانند به صورت پیوسته محتوای رطوبتی را نشان دهند، رضایت بخش نیست [۷]. همچنین استفاده از سیستم های پیشرفته اندازه گیری که نیاز به تجهیزات زیاد دارد، باعث افزایش قیمت و کاهش محبوبیت استفاده از خشک کن ها می شود. مدل های فیزیکی ارائه شده در این زمینه برای برآورد محتوای رطوبتی بر اساس پارامترهای هوای خشک، نیاز به عملیات زیادی برای تعیین پارامترها و حل مدل دارد و با توجه به تقریبی بودن پارامترها، خطای پیش بینی آن زیاد است [۶].

کوبیلوس و ریز (۲۰۰۳) برای خشک کردن هویج از یک شبکه عصبی مدولار استفاده کردند. پارامترهای سرعت و دمای هوای خشک و زمان به عنوان پارامترهای ورودی به شبکه در نظر گرفته شد. در این بررسی از شبکه ای با دو زیر لایه یکی با نرون های سیگموئیدی و دیگری با نرون های خطی استفاده شد. منحنی های خشک کردن حاصل از این شبیه سازی که با این شبکه بدست آمدند با دقت مناسبی به داده های آزمایشی برازش داده شدند. از این مدل برای خشک کردن هویج در یک خشک کن مکانیکی استفاده شد. نتایج نشان دهنده آن بود که شبکه مدولار برای استفاده در تخمین تقریبی به منظور طراحی و انتخاب شرایط کاری بهینه و مقیاس کردن خشک کن مناسب است.

خوش تقاضا و همکاران (۱۳۸۶) برای پیش بینی ضریب تبدیل شلتوک به برنج سفید در خشک کردن به روش بستر ثابت از شبکه های عصبی مصنوعی استفاده کردند. متغیرهای مستقل در این تحقیق به عنوان ورودی به شبکه که عبارت اند از رطوبت نسبی هوای محیط، دمای هوای محیط، سرعت هوای ورودی، عمق بستر شلتوک، دمای هوای ورودی، رطوبت اولیه و نهایی و ضریب تبدیل شلتوک به عنوان خروجی شبکه در نظر گرفته شد. نتایج آنها نشان دهنده آن بود که شبکه پس انتشار

پیشخور با توپولوژی ۱-۷-۷ با الگوریتم یادگیری لونبرگ- مارکورات با تابع آستانه تانژانت سیگموئیدی قادر است راندمان تبدیل شلتوک را به برنج با ضریب تعیین ۹۶/۵۵ و خطای متوسط مطلق ۰/۰۱۹ در شرایط مختلف خشک کردن شلتوک پیش بینی کند [۲].

امروزه با توسعه سریع فناوری پردازش رایانه‌ای و ایجاد نرم افزارهای مربوطه، از مزایای فناوری هوش مصنوعی برای حل مسائل مربوط به مدل سازی سیستم‌ها و پیش‌بینی فرآیندها استفاده می‌شود. یکی از روش‌های هوش مصنوعی که در سطح وسیعی در خشک کردن از یک دهه گذشته آغاز شده و برای شبیه‌سازی و پیش‌بینی پارامترهای مورد نیاز در فرآیندهای خشک‌کردن در حال بسط و توسعه است، شبکه‌های عصبی مصنوعی می‌باشد که در این تحقیق از آن برای مدل سازی فرآیند استفاده می‌شود [۶].

مواد و روش ها

۱- مدل سازی شبکه های عصبی مصنوعی

شبکه‌ای عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری^۱ 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 فرآیندی 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 فرآیند 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 بکار رود [۹]. با توجه به ساختار شبکه عصبی مصنوعی، ویژگی‌های عمده آن، سرعت بالای پردازش، توانایی یادگیری الگو به روش اراده الگو، توانایی تعمیم دانش پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال‌های به دلیل توزیع وزن‌های شبکه است [۱۰]. در این تحقیق از شبکه MLP و TDNN استفاده شد که به اختصار توضیح داده می‌شود:

۱-۱ شبکه پرسپترون چند لایه (MLP)

این شبکه شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. برای آموزش این شبکه، معمولاً از الگوریتم پس انتشار^۲ (BP) استفاده می‌شود. در طی آموزش شبکه MLP به کمک الگوریتم یادگیری BP، 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 پس انتشار، ابتدا لایه‌های خروجی تعدیل می‌شود، زیرا برای هر یک از نرون‌های لایه خروجی، مقدار مطلوبی وجود دارد و می‌توان به کمک آنها و قاعده‌های بهنگام سازی، وزن‌ها را تعدیل نمود. با وجود اینکه الگوریتم پس انتشار خطا نتایج بسیار خوبی در حل مسائل ارائه داده است، در حل برخی از مسائل ضعیف عمل می‌کند که 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، فرآیند 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 [۹، ۱۰]: (الف) اختصاص ماتریس وزن تصادفی به هریک از اتصالات (ب) انتخاب بردار ورودی و خروجی متناسب با آن (پ) محاسبه خروجی نرون در هر لایه و در نتیجه محاسبه خروجی نرون‌ها 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

¹ Learning
² Back propagation

شده است. (ث)- ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص های تعریف شده مانند جذر میانگین مربعات خطا (MSE) و سرانجام برگشت به قسمت پ یا پایان آموزش.

۱-۲ شبکه عصبی با تاخیر زمانی

شبکه داراری ساختاری شبیه ساختار شبکه MLP با این تفاوت که یک اتصال تاخیری در ورودی آن است. این شبکه عموماً یک شبکه دینامیکی نامیده می شود.

۱-۳ الگوریتم های آموزش

از الگوریتم های آموزش الگوریتم لونیگ-مارکواریت^۱ (LM) برای بهنگام سازی وزن های شبکه عصبی مصنوعی استفاده شد که یکی از الگوریتم های پرکاربرد می باشد چون آموزش شبکه را بسیار سریع انجام داده و سطح خطای موجود را حداقل می سازد. در واقع این الگوریتم برای افزایش سرعت یادگیری شبکه طراحی شده که بر مبنای ماتریس هیس می باشد.

۲- خشک کن آزمایشگاهی و تجهیزات مورد استفاده

در این تحقیق برای انجام آزمایش ها از یک خشک کن آزمایشگاهی با جریان هوای اجباری واقع در مرکز تحقیقات کشاورزی و منابع طبیعی استان آذربایجان غربی استفاده شد. این خشک کن قابلیت کنترل دما و سرعت های مختلف را دارد. محفظه خشک کن در ابعاد ۱×۱×۱ متر و سینی خشک کن در ابعاد ۰/۹×۰/۹ متر با شبکه سیمی ۸×۸ میلی متر اخته شده ست. جریان هوا به صورت عمودی به محصول برخورد می کند. این خشک کن مجهز به یک سیستم توزین با دقت ۰/۰۰۱ گرم برای وزن کردن پیوسته محصول در حال خشک شدن (با فاصله زمانی ۳۰ دقیقه) می باشد که توسط یک پورت به کامپیوتر متصل شده و عمل داده برداری توسط برنامه در کامپیوتر انجام می شود (شکل ۱).

در این خشک کن از یک اینوتور برای کنترل دور فن و در نتیجه کنترل سرعت جریان هوا و از یک کنترلر دما، برای کنترل دما استفاده شد. هیتر خشک کن از ۲۰ المنت ۵۰۰ واتی ساخته شده که هوا بعد از عبور از لابلای المنت های حرارتی رد بخش خطی-کننده جریان شده تا هوایی که به نمونه های آزمایشی می رسد کانالیزه شود و به صورت یکسان در سطح مقطع خشک کن پخش شود.

۳- تعیین محتوای رطوبتی در طول آزمایش ها

با داشتن جرم ماده خشک محصول و جرم محصول در هر فاصله زمانی که اندازه گیری شده است، محتوای رطوبت محصول در هر فاصله زمانی از رابطه (۱) قابل محاسبه است [۱۱]:

$$X_i = \frac{M_i - M_d}{M_d} \quad (1)$$

در این معادله X_i میزان رطوبتی بر پایه ای خشک در فاصله زمانی i ، مقدار جرم محصول در فاصله زمانی i و M_d وزن خشک محصول که بر حسب کیلو گرم می باشند.

دمای محیط در طی آزمایش 23 ± 2 درجه سلسیوس است. مناسب ترین رطوبت مطلوب تجاری کشمش ۱۷-۱۸٪ بر پایه خشک است [۱۲]. با داشتن رطوبت و جرم اولیه محصول و رطوبت نهایی، مقدار جرم نهایی محصول تعیین می شود. در هنگام خشک کردن محصول، زمانی که جرم محصول به جرم نهایی از پیش تعیین شده رسید، فرآیند خشک شدن قطع می شود.

¹ Levenberg- Marquardt Algorithm

۴- سطوح آزمایشی

دما و سرعت هوای ورودی به خشک کن و آماده سازی اولیه محصول از عوامل موثر در فرآیند خشک کردن انگور است. در این تحقیق دما هوا در سه سطح (۵۰، ۶۰ و ۷۰ درجه سلسیوس)، سرعت هوا در چهار سطح (۰/۲۵، ۰/۵، ۰/۷۵ و ۱ متر بر ثانیه) و تیمار آماده سازی ۲/۵٪ کربنات پتاسیم +۱٪ روغن زیتون استفاده شد. رطوبت نسبی هوا طبق بررسی محققان در حدود ۷-۵٪ بر سرعت خشک شدن انگور تاثیر می گذارد [۱۲]. از طرف دیگر حذف متغیرهای با تاثیر کم در ورودی های عصبی مصنوعی باعث ایجاد شبکه با پایداری مناسب می شود. در این تحقیق رطوبت نسبی هوا در محدوده بین ۱۰-۱۵٪ قرار داشت. این سطوح دما و سرعت هوای گرم تقریباً تمام شرایط هوا را تا حد امکان پوشش می دهد. لایه مومی شکلی بر روی انگور نفوذ آب از محصول به عامل خشک کننده (هوای گرم) را محدود می سازد و زمان خشک شدن را افزایش می دهد. آماده سازی باعث از بین رفتن و یا تغییر ترکیبات لایه مومی شکل در سطح انگور شده و نفوذپذیری پوست را نسبت به انتقال رطوبت تحت تاثیر قرار می دهد و همچنین روی کیفیت محصول نهایی تاثیر بسزایی دارد [۳، ۱۳]. در این تحقیق نمونه های انگور به مدت یک دقیقه در محلول های آماده سازی غوطه ور می شود و هر آزمایشی سه بار تکرار می شود.

۵- محصول

در صنایع غذایی برای تولید هر محصول غذایی با کیفیت مطلوب، مهمترین اصل داشتن ماده اولیه مناسب می باشد [۱]. نوع واریته انگور در تهیه کشمش با کیفیت مرغوب بسیار موثر است. در این تحقیق نمونه های مورد نیاز از انگور سفید بی دانه از شهرستان ارومیه تهیه گردید. نمونه ها بعد از انتقال به آزمایشگاه در دمای ۴°C نگهداری شدند. برای هر آزمایش از ۳ کیلو گرم انگور استفاده شد.

محتوای قند انگور (شاخص بریکس) به کمک رفراکتومتر دستی، قطر حبه های انگور بوسیله کولیس با دقت ۰/۰۱ میلی متر و محتوای رطوبت اولیه انگور به روش آن تحت خلا به مدت ۸ ساعت و دمای ۷۰ سلسیوس تعیین می شود [۱۴]. شاخص بریکس برای حبه های انگور برابر ۱ ± ۲۳ و درصد رطوبت اولیه انگور و محصول نهایی بر پایه تر به ترتیب برابر ۷۵ ± ۲ و ۱۸ ± ۱/۷۵، و قطر حبه های انگور برابر ۱/۱ ± ۰/۱ سانتی متر است.

طراحی شبکه عصبی مصنوعی

با در نظر گرفتن سه عامل دمی و سرعت هوای ورودی و زمان، تغییرات محتوای رطوبتی در طی خشک کردن بدست می آید. شبکه عصبی با سه نرون لایه ورودی (دما هوا، سرعت هوا، و زمان) و یک نرون لایه خروجی (نسبت تغییرات محتوای رطوبتی) طراحی شد. شکل ۱، توپولوژی شبکه عصبی مورد نظر و پارامترهای ورودی و خروجی برای شبکه مذکور را نشان می دهد. توپولوژی شبکه مذکور از نوع پیشخور است. در این تحقیق از نرم افزار 7. Matlab استفاده شد. از شبکه MLP و TDNN برای پیش بینی استفاده شد و همچنین توابع آستانه مختلفی برای یافتن حالت بهینه آن مورد ارزیابی قرار گرفت که عبارتند از:

(۲) تابع سیگموئیدی لگاریتمی

$$Y_i = \frac{1}{1 + \exp(-X_j)}$$

(۳) تابع تانژانت سیگموئیدی

$$Y_i = \frac{2}{(1 + \exp(-2X_j)) - 1}$$

یکی از مشکلاتی که هنگام آموزش شبکه عصبی ممکن است پیش بیاید، بیش اموزی شبکه است. بدین صورت که در هنگام آموزش شبکه، خطا به مقدار قابل قبول می رسد ولی هنگام ارزیابی، خطای شبکه به مراتب از خطای داده های آموزشی

بیشتر باشد [۱۵]. برای جلوگیری از بیش‌آموزی دو راه وجود دارد: الف- توقف سریع آموزش ۱، ب- انتخاب کمترین تعداد نرون در لایه پنهان [۱۶]. در این تحقیق از روش دوم استفاده شد. بدین صورت که برای آموزش شبکه، ابتدا داده به طور تصادفی به سه قسمت تقسیم شدند، طوری که ۶۰ درصد داده برای آموزش و ۲۰ درصد داده ها برای ارزیابی و ۲۰ درصد داده برای تست شبکه استفاده شد. در حین آموزش شبکه، زمانی که خطای بین داده های آموزش و ارزیابی می‌خواهد زیاد شود، فرآیند آموزش قطع می‌شود. برای یافتن شبکه عصبی با توپولوژی مناسب به کمک الگوریتم آموزشی، از معیار خطای مربعات میانگین استفاده می‌شود که هدف کمینه شدن خطای مذکور است که با رابطه زیر تعریف می‌شود.

$$MES = \sum_P^M \sum_{i=1}^N (S_{ip} - T_{ip})^2 \quad (4)$$

که در آن MSE خطای مربعات میانگین در مرحله تست، S_{ip} خروجی شبکه در نرون i ام و الگوی p ام، T_{ip} خروجی هدف در نرون i ام و الگوی p ام، N تعداد نرون های لایه خروجی و M تعداد الگوی های تست است. برای ارزیابی شبکه انتخاب شده در مرحله قبل از معیار ضریب تعیین (R^2) برای داده های پیش بینی شده در حین آموزش شبکه استفاده شد. برای افزایش دقت و سرعت شبکه عصبی مصنوعی، داده ها ورودی و خروجی به کمک رابطه زیر به شکل هنجار شده در محدوده $[0, 1]$ می‌آید:


$$t_n = \frac{t_i}{50} \quad (7) \quad X_n = \frac{X_i}{X_o} \quad (6) \quad T_n = \frac{T_i - T_{\min}}{T_{\max} - T_{\min}} \quad (5)$$

که T_n ، X_n و t_n مقدار هنجار شده، X_i مقدار واقعی محتوای رطوبتی، X_o محتوای رطوبت اولیه و T_{\max} بیشینه مقادیر واقعی دما، T_{\min} مقدار کمینه دما و T_i مقدار واقعی دماست. t_i مقدار واقعی زمان است. بعد از آموزش شبکه، شبکه‌ای که کمترین خطای تست را داشته باشد به عنوان بهترین شبکه انتخاب می‌شود.


بحث و نتایج

تأثیر دما و سرعت هوای گرم ورودی بر تغییرات محتوای رطوبتی در شکل های ۲ و ۳ نشان داده شده است. برای بررسی عملکرد شبکه پرسپترون چند لایه از توپولوژیهای مختلف با تعداد نرون های مختلف مورد استفاده قرار گرفت. در گام اول بعد از این شبکه آموزش دید، خطای MSE تست شبکه محاسبه و بر اساس آن مناسبترین توپولوژی انتخاب شد (جدول ۱). مقار MSE حاصل با این توپولوژی مناسب نبود. نتایج چند توپولوژی در جدول ۱ آورده شده است. در ضمن کاربرد تابع آستانه Logsig عملکرد بهتری از خود نشان می‌دهد. شبکه با ساختار ۱-۸-۳ با تعداد چرخه آموزش ۲۲، تابع آستانه سیگموئید لگاریتمی با الگوریتم یادگیری LM در مقایسه با توپولوژیهای دیگر کمترین خطای آموزشی (۰/۰۰۲۱) را تولید کرده است. این توپولوژی تغییرات محتوای رطوبتی را با ضرایب تعیین ۰/۹۷۳۱ پیش بینی کرد (شکل ۴). کاربرد شبکه عصبی با تأخیر زمان (TDNN) نتایج بهتری نسبت به شبکه عصبی پرسپترون چند لایه دارد (جدول ۲). شبکه با ساختار ۱-۸-۳ با تعداد چرخه آموزش ۱۷، تابع آستانه سیگموئید لگاریتمی با الگوریتم یادگیری LM در مقایسه با توپولوژیهای دیگر کمترین خطای آموزشی (۰/۰۰۰۱۲) را تولید کرده است. این توپولوژی تغییرات محتوای رطوبتی را با ضرایب تعیین ۰/۹۹۷۹ پیش بینی کرد (شکل ۴). نتایج به دست آمده نشان از قابلیت شبکه عصبی به عنوان ابزاری برای پیش بینی تغییرات محتوای رطوبتی با زمان است که می‌توان در سیستم های کنترل خشک‌کن بکار رود


² Early Stopping



شکل ۱- نمای کلی خشک کن مورد استفاده: ۱- دریچه هوای ورودی، ۲- دمنده، ۳- دریچه کنترل سرعت هوا، ۴- ترموستات، ۵- هیتر، ۶- خطی کننده جریان هوا، ۷- سینی محصول، ۸- ترازو، ۹- دریچه خروجی هوا، ۱۰- رایانه.



شکل ۳- تاثیر سرعت بر تغییرات محتوای رطوبتی با زمان در دمای ۶۰ سلسیوس.




شکل ۲- تاثیر دما بر تغییرات محتوای رطوبتی با زمان در سرعت ۱ متر بر ثانیه.

جدول ۱- نتایج مربوط به شبکه MLP با توابع آستانه مختلف

توپولوژی	تابع آستانه	خطای ارزیابی	تعداد تکرار
۳-۸-۱	Tansig	۰/۰۶۶۷	۲۵
۳-۱۱-۱	Tansig	۰/۰۰۲۹	۲۰
۳-۱۴-۱	Tansig	۰/۱۳۱۵	۱۶
۳-۵-۱	Logsig	۰/۰۰۲۵	۱۷
۳-۸-۱	Logsig	۰/۰۰۲۱	۲۲
۳-۱۱-۱	Logsig	۰/۰۶۴۵	۱۴

جدول ۲- نتایج مربوط به شبکه TDNN با توابع آستانه مختلف

توپولوژی	تابع آستانه	خطای ارزیابی	تعداد تکرار
۳-۵-۱	Tansig	۰/۰۰۴۸	۱۶
۳-۸-۱	Tansig	۰/۰۰۰۳	۳۰
۳-۱۱-۱	Tansig	۰/۰۰۳۸	۲۲
۳-۵-۱	Logsig	۰/۰۰۰۱۶	۱۵
۳-۸-۱	Logsig	۰/۰۰۰۱۲	۱۷



شکل ۴- محتوای بتی پیش بینی شده با روش شبکه صبی نوعی در ابل مقادیر واقعی آن رای داده ای وزش
(الف) شبکه TDNN (ب) شبکه MLP

منابع:

- ۱- زمردی، ش. و دولتی بانه، ح. ۱۳۸۲. توصیه های لازم برای افزایش کیفیت کشمش. چکیده مقالات اولین همایش ملی خشکبار ایران. تبریز.
- ۲- خوش تقاضا، م. ه. امیری چایجان، ر. منتظر، غ. و مینایی، س. ۱۳۸۶. پیش بینی ضریب تبدیل شلتوک به برنج سفید در خشک کردن به روش بستر ثابت به کمک شبکه های عصبی مصنوعی. مجله تحقیقات مهندسی کشاورزی، ۸ (۲): ۱۳۵-۱۵۶.
- ۳- ضرابی، م. ۱۳۷۷. تعیین پارامترهای طراحی در خشک کردن انگور. پایان نامه کارشناسی ارشد شیمی، دانشکده فنی مهندسی، دانشگاه تربیت مدرس.
- 4- **Togrul, I. T. and Pehlivan, D. 2004.** Modeling of thin layer drying kinetics of some fruits under open-air sun drying process. Journal of Food Engineering. 65: 413-425.
- 5- **Karathanos, V. T. and Belessiotis V. G. 1997.** Sun and artificial air drying kinetics of some agricultural products. Journal of Food Engineering. 31: 35-46.



- 6- **Farkas, I., Remenyi, P. and Biro, B. 2000a.** A neural network topology for modeling grain drying. *Computers and Electronics in Agriculture*. 26: 147-158.
- 7- **Farkas, I., Remenyi, P. and Biro, B. 2000b.** Modeling aspects of grain drying with a neural Network. *Computers and Electronics in Agriculture*. 29: 99-113.
- 8- **Cubillos, F., and Reyes, A. 2003.** Design of a model based on a modular neural network approach. *Drying Thechnology*, 21(7):1185-1195.
- 9- **Dayhoff, J. E. 1990.** *Neural Network Principles*. Prentice-Hall International, U.S.A
- 10- **Khanna, T. 1990.** *Foundation of neural networks*. Addison-Wesley Publishing Company, U.S.A.
- 11- **Hamdy, H. E. G. 2006.** Experimental investigation and empirical correlations of thin layer drying characteristics of seedless grapes. *Energy Conversion and Management*. 47: 1610-1620.
- 12- **Pangavhane, D. R. Sawhney, R. L. and Sarsavadia, M. 2000.** Drying kinetics studies on single layer Thompson seedless grape under controlled heated air conditions. *Journal of Food Processing and Preservation*. 24: 335-352.
- 13- **Tulasidas, T. N. Raghavan G. S. V. and Norris, E. R. 1996.** Effects of dipping and washing pre-treatment on microwave drying of grape. *Journal of Food Process Engineering*. 19: 15-24.
- 14- **AOAC. 1990.** Association of Official Analytical Chemists (Report No. 934.06). Arlington, VA
- 15- **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.
- 16- **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.