

تخمین رطوبت لایه‌های محیط متخلخل در خشک‌کردن بستر ثابت به کمک شبکه‌های عصبی (۵۹۱)

رضا امیری چایجان^۱ و محمد هادی خوش‌تقاضا^۲

چکیده

پیش‌بینی رطوبت لایه‌های محصولات متخلخل در انتهای مرحله خشک‌شدن به منظور کاهش خسارت ناشی از بیش یا کم خشک‌شدن محصولات مذکور حائز اهمیت است. در این تحقیق از محصول برنج به عنوان محصول متخلخل و از روش هوشمند شبکه عصبی مصنوعی برای پیش‌بینی رطوبت لایه‌های شلتوک در انتهای مرحله خشک‌شدن و در محدوده رطوبت متوسط نهایی ۸/۵ تا ۱۵٪ پایه تر استفاده شده است. آزمایش‌ها با نمونه‌های شلتوک و در محدوده عمق‌های ۵ تا ۴۰ سانتی‌متر با میزان رطوبت اولیه متوسط ۱۴/۹ تا ۲۱/۸۳٪ پایه تر در شرایط کنترل‌شده محیطی با دمای محیط ۲۰ تا ۳۰°C و رطوبت نسبی هوای ۴۰ تا ۹۰٪ انجام شد. در این آزمایش‌ها سرعت‌های مختلف هوا بین ۰/۱ m/s و سرعت حداقل سیال‌سازی اعمال شد و دمای هوای ورودی بین ۴۰ تا ۷۰°C بود. زمان خشک‌شدن نیز به عنوان پارامتر ورودی اعمال شد. رطوبت لایه‌های شلتوک به کمک هشت پارامتر فوق در هر آزمایش پیش‌بینی شد. کاربرد شبکه‌های عصبی پس‌انتشار پیشخور و پس‌انتشار پیشرو به همراه الگوریتم‌های یادگیری لوبنبرگ-مارکوارت و بیزی در حل این مسأله نشان داد که با استفاده از شبکه عصبی مصنوعی می‌توان رطوبت لایه‌های شلتوک را با ضریب همبستگی حدود ۹۶٪ و خطای حقیقی ۱۹/۰٪ در گستره بستر ثابت و در شرایط آزمایشگاهی پیش‌بینی کرد.

کلیدواژه: میزان رطوبت، الگوریتم لوبنبرگ-مارکوارت، شبکه پس‌انتشارپیشرو، شلتوک

۱- استادیار مهندسی مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، پست الکترونیک: amirireza@basu.ac.ir

۲- دانشیار مهندسی مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تربیت مدرس

مقدمه

چگونگی توزیع رطوبت محصولات متخلخل در پایان فرایند خشک‌شدن، یکی از عوامل تعیین‌کننده کیفیت خشک‌شدن می‌باشد. در فرایند خشک‌شدن محصولات مذکور در شرایط بستر عمیق ذرات در هر عمقی دارای آهنگهای مختلف خشک‌شدن هستند. توزیع ناهمگون رطوبت در لایه‌های مختلف در طی فرایند خشک‌شدن محصولات کشاورزی در شرایط بستر ثابت، عامل مهم ایجاد ضایعات در فرایند تبدیل آن در صنایع کشاورزی به شمار می‌رود. بنابراین پیش‌بینی رطوبت لایه‌های مختلف در فرایند خشک‌کردن این محصولات به منظور ارائه روشی برای کاهش اختلاف رطوبت لایه‌ها و یا انجام روش‌های پیشگیرانه در طی فرایند، بسیار سودمند خواهد بود [۳، ۴]. هنگامی که هوا با دبی کم از بین ذرات یک بستر مواد به سمت بالا هدایت می‌شود، یک بستر ثابت خواهیم داشت. با افزایش دبی جریان هوا، بستر مواد منبسط شده و حداقل سیال‌سازی حاصل می‌شود. در شرایط حداقل سیال‌سازی، مقاومت هوا با وزن توده مواد برابر می‌شود. محدوده شروع جریان سیال تا نقطه حداقل سیال‌سازی، بستر ثابت گفته می‌شود [۹، ۱۴].

در شرایط بستر عمیق به علت ایجاد اختلاف رطوبتی نسبتاً زیاد بین لایه‌های محصول در انتهای فرایند خشک‌شدن، تلفات ناشی از بیش یا کم خشک‌شدن افزایش می‌یابد. تغییر در دما و رطوبت هوای عبوری از میان بستر مواد به آهنگ رطوبت تبخیر شده از هر دانه بستگی دارد. روابط تجربی برای پیش‌بینی آهنگ خشک‌کردن محصولات مختلف در شرایط لایه نازک استفاده می‌شود [۳، ۱۶]. شلتوک یکی از محصولات دانه‌ای متخلخل است که فرایند خشک‌کردن آن در صنایع تبدیلی پس از برداشت بسیار مهم است و بر روی خواص فیزیکی و مکانیکی آن تأثیر بسزایی دارد و در این تحقیق از آن برای انجام آزمایش‌ها استفاده شده است. برای پیش‌بینی رطوبت لایه نازک محصولات دانه‌ای متخلخل، روابط تجربی به وسیله محققین ارائه شده است، که با استفاده از d ، t ، رطوبت نسبی هوا و زمان خشک‌شدن، محتوای رطوبتی لایه نازک را پیش‌بینی می‌کند.

در ابتدای مرحله آهنگ ثابت خشک کردن، هوای گرم درحین عبور از لایه‌های زیرین بستر عمیق، اشباع شده و تأثیر چندانی بر خشک‌کردن دانه‌های لایه‌های بالاتر نمی‌گذارد. بنابراین سه منطقه خشک‌شدن در طی فرایند خشک‌کردن بسترهای عمیق شلتوک، ایجاد می‌شود. مراحل خشک شدن شلتوک، در هر یک از مناطق مذکور در زمان‌های متفاوت از شروع فرایند رخ می‌دهد. اندازه نواحی یادشده بستگی به محتوای رطوبتی دانه‌ها و دمای آنها، رطوبت و سرعت هوا دارد. مناطقی که در فرایند خشک‌شدن بستر عمیق ایجاد می‌شود، عبارتند از: "منطقه خشک شده"، "منطقه در حال خشک‌شدن" و "منطقه خشک‌نشده". در منطقه خشک‌شده، فشار جزیی بخار دانه در تعادل با هوا است. در منطقه خشک‌نشده، دانه‌ها از ابتدای فرایند، تغییر چندانی نداشته‌اند. در لایه‌های کم عمق یا لایه نازک، فرایند خشک‌شدن در کل بستر مواد رخ می‌دهد [۳، ۱۶].

پیش‌بینی دقیق محتوای رطوبتی لایه‌های مختلف محصولات کشاورزی، عمدتاً به علت تغییرپذیری عوامل اصلی که در عمل پیش می‌آید، با مشکل مواجه می‌شود طی تحقیقی، فارکاس و همکاران از نوعی شبکه عصبی مصنوعی برای یک خشک‌کن بستر ثابت کشاورزی استفاده کردند. هدف آنان کاربرد مدل شبکه عصبی مصنوعی برای پیش‌بینی توزیع رطوبت محصول در طی فرایند خشک‌کردن بود. آنها دریافتند که شبکه عصبی مصنوعی می‌تواند برای مدلسازی فرایند خشک‌کردن دانه به کار رود. [۶، ۷]. شایان ذکر اینکه پژوهشهای مذکور فقط نظری بوده و هیچگونه آزمایشی انجام نشده بلکه آموزش و آزمون شبکه فقط با داده‌های مدل ریاضی انجام شده است.

در تحقیقی دیگر، یک مدل شبکه عصبی مصنوعی برای پیش‌بینی فرایند تبخیر رطوبت در یک خشک‌کن بستر سیال پیشنهاد شد. در این روش از مدل توأمان شبکه عصبی مصنوعی و مدل ریاضی برای تخمین دو پارامتر آهنگ تبخیر رطوبت و شار حرارتی و نیز برای محاسبه ضریب انتقال حرارت استفاده شد. نتایج این تحقیق نشان داد که مدل شبکه عصبی نسبت به مدل ریاضی نتایجی بهتر با خطایی کمتر تولید می‌کند [۱۷].

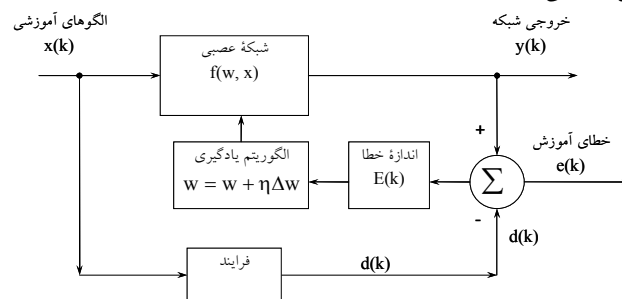
برای بیان دینامیک خشک‌شدن برخی محصولات به کمک شبکه عصبی مصنوعی، پژوهشی توسط کامینسکی و تومساک انجام شد. پارامترهای دبی هوا و دمای آن در ورودی خشک‌کن، رطوبت اولیه و دمای اولیه مواد به عنوان ورودی شبکه و پارامتر کیفیت و تغییر آن با زمان به عنوان خروجی شبکه لحاظ شد. نتایج این پژوهش بیانگر این مطلب است که شبکه‌های مذکور قادر به پیش‌بینی مناسب خروجی‌ها هستند [۱۱].

هدف این پژوهش ارائه یک شبکه عصبی مصنوعی با توپولوژی مناسب برای پیش بینی رطوبت هر لایه محصولات دانه ای متخلخل در خشک کردن به روش بستر ثابت است که در این تحقیق از شلتوک به عنوان محیط متخلخل برای انجام آزمایش ها استفاده می شود. به عبارت دیگر، این مقاله به دنبال یک نگاشت هشت بعدی (رطوبت نسبی هوای محیط، دمای هوای محیط، رطوبت نسبی اولیه، رطوبت نسبی نهایی، سرعت هوای ورودی، عمق لایه، دمای ورودی و زمان خشک شدن) به کمک شبکه عصبی مصنوعی است، تا بتوان از مقادیر برآورد شده رطوبت لایه های مختلف یک محصول متخلخل مانند شلتوک را در حل مسایل مربوط به خشک کردن شلتوک در شرایط واقعی استفاده کرد. از ویژگی های این تحقیق، استفاده از داده های آزمایشگاهی خشک کردن به روش بستر ثابت برای آموزش و ارزیابی شبکه ها است.

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی، یکی از روش های نرم رایانش است که به کمک فرایند یادگیری و با استفاده از پردازشگرهایی ساده به نام نرون تلاش می کند با شناخت روابط ذاتی میان داده ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می دهند. هر شبکه با دریافت مثالهایی آموزش می بیند. آموزش فرایندی است که در نهایت به یادگیری منجر می شود. یادگیری شبکه، زمانی انجام می شود که وزن های ارتباطی بین لایه ها چنان تغییر کند که اختلاف مقادیر پیش بینی شده و محاسبه شده در حد قابل قبولی باشد. با دستیابی به این شرایط فرایند یادگیری محقق شده است. این وزن ها حافظه و دانش شبکه را بیان می کنند. شبکه عصبی آموزش دیده می تواند برای پیش بینی خروجی هایی متناسب با مجموعه جدید داده به کار رود. با توجه به ساختار شبکه عصبی مصنوعی، ویژگی های عمده آن، سرعت بالای پردازش، توانایی یادگیری به کمک روش ارائه الگو، توانایی تعمیم دانش پس از یادگیری، انعطاف پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال های شبکه به دلیل توزیع وزن های شبکه است [۵، ۱۲]. در این تحقیق از شبکه های پس انتشار پیشرو و پس انتشار پیشخور استفاده شده است.

شبکه پس انتشار پیشخور (CFBP) شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. برای آموزش این شبکه از الگوریتم یادگیری پس انتشار خطا استفاده می شود. در حالت پس انتشار، ابتدا وزن های لایه خروجی تعدیل می شود، زیرا برای هر یک از نرون های لایه خروجی، مقدار مطلوب وجود دارد و می توان به کمک آنها و قاعده های به هنگام سازی، وزنها را تعدیل نمود. گرچه الگوریتم پس انتشار خطا نتایج بسیار خوبی در حل مسائل داشته است ولی در حل برخی از مسائل نیز ضعیف عمل می کند که آن نیز ناشی از طولانی بودن و یا مشخص نبودن زمان یادگیری، انتخاب نامناسب ضریب یادگیری و یا توزیع تصادفی وزنها اولیه است. در برخی موارد نیز به دلیل وجود کمیته موضعی، فرایند یادگیری مختل می شود. شکل ۱ فرایند پس انتشار را برای به هنگام سازی وزنها و بهینه سازی فرایند یادگیری نشان می دهد. انتخاب اندازه مناسب خطا برای به دست آوردن جواب مناسب برای مسئله می تواند تعیین کننده باشد.




شکل ۱- فرایند به هنگام سازی توسط شبکه های پس انتشار خطا

شبکه پس انتشار پیشرو (FFBP) نیز مانند شبکه پس انتشار پیشخور از الگوریتم BP برای به هنگام سازی وزنها استفاده می کند ولی خصوصیت اصلی شبکه مذکور این است که نرون های هر لایه به همه نرون های لایه های قبل متصل است. الگوریتم های آموزش بکاررفته برای به هنگام سازی وزنها شبکه های مورد استفاده عبارتند از: الگوریتم لونیگ-مارکوارت و الگوریتم تنظیم بیزی.

مواد و روشها

خشک‌کن آزمایشگاهی و تجهیزات مورد استفاده

برای انجام آزمایشها، از یک دستگاه خشک‌کن آزمایشگاهی استفاده شد، که توسط صادقی و همکاران طراحی و ساخته شده بود (شکل ۲). محفظه خشک‌کن با سطح مقطع $0.16 \times 0.16 \text{ m}^2$ و از جنس پلکسی گلاس شفاف بوده و. هوای مورد نیاز برای فرایند خشک کردن توسط دمنده‌ای سانتریفیوژ با موتور سه فاز با قدرت ۲ hp و سرعت ۲۸۰۰ rpm تأمین می‌شد. هوای عبوری از یک کوره حرارتی با ۱۱ المنت به دمای مطلوب می‌رسید. به منظور کنترل دما و دبی هوای ورودی به محفظه خشک‌کن، از یک سیستم کنترل خودکار رایانه‌ای استفاده شده بود [۱]. سرعت هوای خروجی توسط یک سرعت‌سنج هوای پره‌ای از نوع LoutronA-M-4202 با دقت $\pm 1 \text{ m/s}$ اندازه‌گیری می‌شد. برای حفظ رطوبت و دمای اتاق خشک‌کن نیز از یک دستگاه رطوبت‌ساز، ساخت شرکت پیوند صنعت همگام استفاده شد. به کمک دستگاه مذکور، رطوبت نسبی و دمای هوای اتاق در مقادیر مورد نظر تنظیم و سپس همه آزمایشها در شرایط تنظیم شده انجام گردید.



شکل ۲- دستگاه خشک‌کن مورد استفاده (۱- تابلو برق، ۲- رایانه، منبع تغذیه، مدار راه‌انداز رله‌ها و مدار تقویت کننده حسگرها ۳- اینورتر تر ۴- دمنده ۵- موتور دمنده ۶- کوره الکتریکی ۷- موتور محرک مکانیزم ارتعاش ۸- پولی‌های چند شیاره ۹- لنگ و لغزنده ۱۰- بازوهای مرتعش ۱۱- زانویی ۱۲- محفظه سیال ازی ۱۳- پایه‌های مستهلک کننده نوسانات) [۱]

روش انجام آزمایش‌های خشک کردن

برای انجام آزمایشها، از شلتوک رقم هاشمی استفاده شده است. ابتدا حدود ۲۵۰۰ کیلوگرم شلتوک از یک مزرعه انتخاب و سپس داخل کیسه‌های نایلونی ۵۰ کیلوگرمی قرار داده و در آنها کاملاً بسته شد تا از کاهش رطوبت شلتوک جلوگیری و در عین حال، تعادل نسبی نیز بین دانه‌ها ایجاد شود. برای جلوگیری از کاهش رطوبت شلتوک و فساد آن، کیسه‌های شلتوک در دمای 4°C و رطوبت نسبی حدود ۸۰٪ در سردخانه نگهداری شد. برای تعیین رطوبت دانه‌ها به روش خشک کردن و کاهش وزن به مدت ۲۴ ساعت درون اجاق به دمای 130°C استفاده شد [۲]. میزان رطوبت اولیه شلتوک بین ۱۴/۹٪ و ۲۱/۸۳٪ پایه تر متغیر بود. از آنجایی که برداشت به وسیله کمباین انجام شده بود تغییرات رطوبت در توده شلتوک به دلیل وجود انواع شلتوک رسیده و نارس بوده که روشی برای کاهش سطح رطوبت اولیه شلتوک اعمال نشده بود.

عوامل متعددی در فرایند خشک کردن بستر ثابت مؤثرند. برخی از این عوامل عبارتند از: رطوبت اولیه، رطوبت نهایی، عمق لایه، رطوبت نسبی هوای محیط، دمای هوای محیط، دمای و دبی هوای ورودی و زمان خشک شدن. عوامل یاد شده در شرایط آزمایشگاهی اعمال شد. آزمایشها در عمق ۵ تا ۴۰ cm انجام و در هر مورد از عمق‌های یادشده، رطوبت متوسط نهایی نمونه‌ها با روش وزن کردن در زمان‌های متوالی به سطوح ۸/۵ تا ۱۵/۵٪ پایه تر کاهش داده شد.

برای انجام آزمایشها از شلتوک با رطوبت اولیه بین ۱۴/۹٪ و ۲۱/۸۳٪ پایه تر استفاده شد. قبل از انجام هر آزمایش شرایط اتاق آزمایش در دما و رطوبت نسبی مورد نظر تنظیم شده و به تعادل می‌رسید. دمای محیط بین ۲۰ تا 30°C و رطوبت نسبی محیط بین ۴۰ تا ۹۰٪ تنظیم شد. پس از متعادل شدن هوای اتاق، آزمایشها شروع شده و دماهای بین ۴۰ تا 70°C اعمال شد. دور موتور نیز طوری تنظیم شد که سرعت‌های بین ۱/۸ m/s و سرعت حداقل سیال‌سازی برای هر عمق اعمال شود. با توجه به

موارد فوق ۳۵۷ آزمایش خشک کردن شلتوک در شرایط بستر ثابت و در شرایط محیطی کنترل شده انجام شد. پس از اینکه رطوبت متوسط بستر مواد به مقدار مورد نظر رسید، سه نمونه برای تعیین رطوبت از هر یک از لایه های بالا، وسط و پایین جدا و با استفاده از اجاق اندازه گیری شد. بدین ترتیب ۹۱۹ الگوی آموزشی برای استفاده در روش شبکه عصبی مصنوعی به دست می آید.


طراحی شبکه عصبی مصنوعی

با در نظر گرفتن هشت ورودی اعمال شده (جدول ۱) در تمام آزمایش های بستر ثابت مقادیر رطوبت عمق های بالا، وسط و پایین برای توده شلتوک به دست آمد. تحت شرایط بیان شده در بخش قبل، شبکه عصبی مصنوعی با هشت نرون لایه ورودی (رطوبت متوسط نهایی، رطوبت اولیه، عمق لایه، رطوبت نسبی هوای محیط، دمای هوای محیط، دمای هوای ورودی به خشک کن، زمان خشک شدن و عمق شلتوک) و یک نرون لایه خروجی (رطوبت لایه مورد نظر) طراحی شد. شکل ۳ توپولوژی شبکه عصبی مورد استفاده همراه با پارامترهای ورودی و خروجی را نشان می دهد. در این تحقیق از نرم افزار Neural Network Toolbox MATLAB (Ver. 4.1) استفاده شده است.

برای دستیابی به پاسخ مناسب، دو شبکه مورد استفاده قرار گرفت. این شبکه ها عبارتند از: شبکه پس انتشار پیشرو و شبکه پس انتشار پیشخور. فرایند آموزش توسط شبکه های فوق فرایندی تکراری است که شامل تغییر وزن های بین لایه های مختلف است و در طی آموزش بتدریج به سمت ثبات این وزن ها پیش می رود. به طوری که خطای بین مقادیر مطلوب (مقدار واقعی) و پیش بینی شده به حداقل برسد. برای ارزیابی توپولوژی های مختلف از روش افزایشی برای انتخاب تعداد نرون ها و لایه ها به منظور یادگیری شبکه استفاده شد. بدین طریق که هنگامی که در یک مرحله، شبکه در کمینه های محلی گرفتار می شد، بتدریج نرون های جدید به شبکه اضافه شد. این روش دارای پتانسیل عملی بیشتری برای یافتن اندازه مناسب شبکه است. مزایای این روش عبارت است از: الف) پیچیدگی شبکه ها با افزایش نرون ها بتدریج افزایش می یابد. ب) اندازه بهینه شبکه اغلب با تنظیمات بدست می آید. ج) پایش و ارزیابی کمینه محلی در طی یادگیری انجام می شود. توابع آستانه مختلفی برای یافتن حالت بهینه آن مورد ارزیابی قرار گرفت که عبارتند از: تابع سیگموئید لگاریتمی، تابع خطی، تابع تانژانت هایپربولیک سیگموئید

جدول ۱- پارامترهای ورودی شبکه عصبی مصنوعی و محدوده های کمینه و بیشینه آنها

پارامتر	کمینه	بیشینه
عمق کل شلتوک (cm)	۵	۵۰
عمق لایه شلتوک (cm)	۰	۴۰
مدت زمان خشک شدن (min)	-	زمان انتهای آزمایش
رطوبت اولیه (%w.b.)	۱۴/۹	۲۱/۸۳
دمای محیط (°C)	۲۰	۳۰
رطوبت نسبی محیط (%)	۴۰	۹۰
دمای هوای ورودی (°C)	۴۰	۷۰
سرعت هوای ورودی (m/s)	۰/۱	سرعت حداقل سیال سازی برای هر عمق



شکل ۳- توپولوژی شبکه عصبی مصنوعی مورد استفاده

برای آموزش، ابتدا حدود ۲۴٪ داده‌ها را به طور تصادفی برای فرایند ارزیابی جدا شد، به طوری که ۷۳۹ داده برای آموزش و ۲۱۸ داده برای آزمون شبکه انتخاب شدند. پراکندگی داده‌های آموزشی در شکل ۴ نشان داده شده است. برای یافتن شبکه‌ای با توپولوژی مناسب به کمک الگوریتم‌های آموزشی، از معیار خطای مربعات میانگین استفاده می‌شود که هدف کمینه شدن خطای مذکور است که با رابطه (۱۰) تعریف می‌شود:


$$E_{RMS} = \sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2 \quad (1)$$

که در آن E_{RMS} خطای مربعات میانگین در مرحله آموزش، 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 نرونهای خروجی و M تعداد الگوهای آموزشی است. برای بهینه کردن شبکه‌های یافته شده در مرحله قبل نیز از معیارهای خطای میانگین مطلق و انحراف معیار خطای میانگین مطلق استفاده شد که روابط آنها به صورت زیر است:

$$E_{MA} = \frac{1}{T} \sum_{k=1}^T |S_k - T_k| \quad (2)$$

$$SD_{EMA} = \sqrt{\frac{\sum_{k=1}^T |S_k - T_k| - |S_k - T_k|}{T - 1}} \quad (3)$$

که در آن S_k خروجی شبکه در مرحله ارزیابی داده‌ها، T_k مقادیر خروجی مطلوب الگوها، E_{MA} خطای میانگین مطلق و SD_{EMA} انحراف معیار خطای میانگین مطلق است. مقدار خطای متوسط آموزش برای شبکه‌های پس‌انتشار پیشرو و پس‌انتشار پیشخور به همراه الگوریتم‌های یادگیری و توپولوژیهای مختلف بررسی شد.



شکل ۴- پراکندگی داده‌های آموزش

نتایج و بحث

دو راهبرد برای بررسی تاثیر توابع آستانه مختلف برای بهینه سازی شبکه های مورد استفاده بکار گرفته شد که عبارتند از توابع آستانه یکسان برای تمام لایه ها (جدول ۲) و توابع آستانه مختلف برای لایه ها (جدول ۳). در شرایط توابع آستانه یکسان برای تمام لایه ها، نتایج حاکی از آن بود که تابع آستانه TANSIG عملکرد بهتری نسبت به توابع آستانه دیگر دارد. همچنین الگوریتم های BR و LM در بین الگوریتم های بکاررفته دارای ضریب همبستگی بالاتر و خطای مطلق میانگین و انحراف معیار کمتری برای هر دو شبکه پس انتشار هستند. از این رو الگوریتم های مذکور انتخاب و نسبت به بهینه سازی آنها اقدام شد. با توجه به جدول ۲ مشاهده می شود توپولوژیهای سه لایه دارای عملکرد ضعیف تری نسبت به توپولوژی های چهار لایه هستند به طوری که خطای بیشتری نسبت به توپولوژیهای چهار لایه ایجاد کرده اند. در شرایط توابع آستانه یکسان برای تمام لایه ها، شبکه CFBP با الگوریتم LM و تعداد نرونهای و لایه های ۱-۱۱-۱۶-۸ بهترین عملکرد را ارائه داد. توپولوژی مذکور به دلیل بیشترین مقدار ضریب تعیین (۰/۹۵۶۰) و کمترین مقدار خطای مطلق میانگین (۰/۱۸۷۲) و انحراف معیار میانگین خطای مطلق (۰/۱۹۲۴) مناسب تر از توپولوژیهای دیگر است. این توپولوژی با تعداد چرخه ۸۹، کمترین مقدار خطای مجذور مربعات (۰/۰۰۰۲۲) را در بین توپولوژیهای مورد ارزیابی داشت.

جدول ۲- مقادیر خطای آموزش برای مقادیر مختلف تعداد لایه ها و نرون ها برای چند شبکه مورد تفاده در شرایط توابع آستانه یکسان برای تمام لایه ها

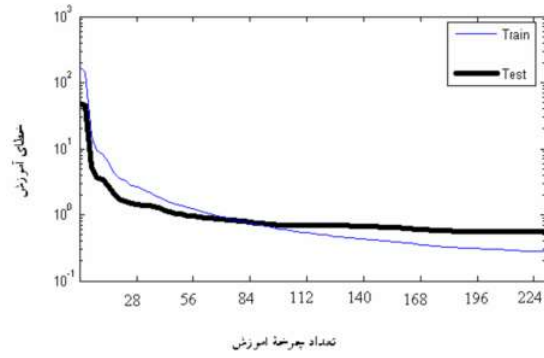
نوع شبکه	الگوریتم یادگیری	تابع آستانه	تعداد لایه ها و نرونها	RMS E	R^2	E_{MA}	SD_{EMA}	چرخه آموزش
		TANSIG	۸-۱۶-۱	۰/۰۰۱۷	۰/۹۰۸۳	۰/۲۹۴۷	۰/۲۵۶۲	۷۶
		LOGSIG	۸-۱۶-۱	۰/۰۰۳۱	۰/۸۵۵۲	۰/۳۵۵۰	۰/۳۱۱۷	۱۱۷
	LM	LOGSIG	۸-۱۵-۱۱-۱	۰/۰۰۲۵	۰/۹۲۵۹	۰/۲۵۶۷	۰/۲۴۲۷	۴۹
			.					
	CFBP	TANSIG	۸-۱۶-۱۱-۱	۰/۰۰۲۲	۰/۹۵۶۰	۰/۱۸۷۲	۰/۱۹۲۴	۸۹
			.					
		TANSIG	۸-۱۲-۱۲-۱	۰/۰۰۷۱	۰/۹۵۰۶	۰/۲۰۷۹	۰/۱۹۷۵	۱۳۵
			.					
	BR	LOGSIG	۸-۱۲-۱۲-۱	۰/۰۰۶۷	۰/۹۵۵۸	۰/۱۹۹۷	۰/۱۷۷۹	۱۵۵
			.					
		TANSIG	۸-۱۷-۱	۰/۰۰۲۱	۰/۹۰۸۹	۰/۲۹۹۲	۰/۲۴۶۴	۴۸
		LOGSIG	۸-۱۹-۱	۰/۰۰۱۸	۰/۸۹۷۰	۰/۳۱۶۹	۰/۲۵۹۵	۵۷
	LM	TANSIG	۸-۱۷-۹-۱	۰/۰۰۴۹	۰/۹۴۶۸	۰/۲۱۰۹	۰/۲۰۵۹	۷۶
			.					
		LOGSIG	۸-۱۷-۹-۱	۰/۰۰۶۶	۰/۹۲۳۶	۰/۲۶۹۷	۰/۲۲۹۳	۸۷
			.					
	FFBP	TANSIG	۸-۱۰-۱	۰/۰۰۲۳	۰/۸۴۲۸	۰/۳۶۵۷	۰/۳۲۵۲	۹۱
		LOGSIG	۸-۱۰-۱	۰/۰۰۲۱	۰/۸۶۸۵	۰/۳۴۶۱	۰/۲۹۲۱	۸۸
	BR	TANSIG	۸-۱۵-۱۴-۱	۰/۰۰۸۳	۰/۹۴۴۰	۰/۲۱۶۳	۰/۲۱۳۱	۱۶۷
			.					
		LOGSIG	۸-۱۵-۱۴-۱	۰/۰۰۰۷	۰/۹۵۲۳	۰/۲۰۴۶	۰/۱۹۳۹	۱۶۲

به منظور دستیابی به نتایج مناسب تر، راهبرد توابع آستانه مختلف برای شبکه های مختلف بررسی شد (جدول ۳). نتایج نشان داد که شبکه FFBP عملکرد بهتری نسبت به شبکه CFBP دارد. به طوری که بهترین توپولوژی، متعلق به شبکه FFBP با الگوریتم آموزش BR است. ترتیب تابع آستانه LOGSIG- TANSIG- LOGSIG برای لایه ها و توپولوژی ۱-۱۱-۱۶-۸ دارای عملکرد بهتری نسبت به راهبرد تابع آستانه یکسان برای تمام لایه ها است. این توپولوژی با آن که دارای خطای مجذور مربعات بیشتری نسبت به توپولوژی بهینه در شرایط تابع آستانه یکسان برای لایه ها است، ولی دارای ضریب تعیین بیشتر (۰/۹۵۹۳)، خطای مطلق کمتر (۰/۱۸۵۵) و انحراف معیار خطای مطلق کمتر (۰/۱۷۶۳) است. بنابراین توپولوژی مذکور به عنوان شرایط بهینه برای پیش بینی رطوبت لایه های شلتوک به کمک هشت پارامتر مستقل رطوبت متوسط نهایی، رطوبت اولیه، عمق لایه، رطوبت نسبی هوای محیط، دمای هوای محیط، دمای هوای ورودی به خشک کن، زمان خشک شدن و عمق شلتوک مناسب است.


چگونگی یادگیری شبکه بهینه طراحی شده در شکل ۵ نمایش داده شده است. خطای RMSE این شبکه در بهترین شرایط ۰/۰۰۰۷۲ بدست آمد که کمترین مقدار خطا در بین توپولوژی های ارزیابی شده است. ضریب همبستگی برای شبکه بهینه انتخاب شده برابر ۰/۹۵۹۳ به دست آمد که می تواند مقدار مناسبی در مقایسه با مدل های ریاضی باشد (شکل ۶). زیرا این توپولوژی قادر است رطوبت لایه ها را با خطای مطلق متوسط ۰/۱۸۵۵ پایه تر پیش بینی کند که با توجه به تغییرات اولیه رطوبت شلتوک بسیار مناسب است (شکل ۷). از طرفی خطای واقعی ناچیز بیانگر عملکرد مناسب و عدم وراآموزی شبکه بهینه است. ۰/۹۹/۰۸٪ از داده های ارزیابی خطای واقعی کمتر از ۱٪ (۰/w.b) داشتند و خطای واقعی ۰/۳۷/۹۰٪ از داده های ارزیابی در محدوده (۰/w.b) $\pm 0/5$ قرار داشت (شکل ۸).

جدول ۳- مقادیر خطای آموزش برای مقادیر مختلف تعداد لایه ها و نرون ها برای چند شبکه مورد استفاده در شرایط توابع آستانه مختلف برای لایه ها


نوع شبکه	الگوریتم یادگیری	توابع آستانه	تعداد لایه ها و نرونها	RMSE	R^2	E_{MA}	SD_{EMA}	چرخه آموزش
		TANSIG- LOGSIG	۸-۱۵-۱۱-۱	۰/۰۰۰۱۶	۰/۹۵۰۱	۰/۲۱۰۲	۰/۱۹۵۹	۷۴
		TANSIG						
	LM	- LOGSIG- TANSIG	۸-۱۶-۱۱-۱	۰/۰۰۰۲۳	۰/۹۴۴۶	۰/۲۲۰۶	۰/۲۱۰۶	۷۵
		LOGSIG						
CFB P		- TANSIG- LOGSIG	۸-۱۲-۱۲-۱	۰/۰۰۰۷۷	۰/۹۳۶۶	۰/۲۴۱۲	۰/۲۱۶۵	۱۱۲
		TANSIG						
		- LOGSIG- TANSIG	۸-۱۵-۹-۱	۰/۰۰۰۷۹	۰/۹۳۳۶	۰/۲۴۲۷	۰/۲۲۴۷	۲۲۶
		LOGSIG						
	BR	- TANSIG- LOGSIG	۸-۱۵-۹-۱	۰/۰۰۰۷۷	۰/۹۴۷۳	۰/۲۱۳۸	۰/۲۰۰۳	۱۳۸
		TANSIG						
		- LOGSIG- TANSIG	۸-۱۲-۹-۱	۰/۰۰۰۸۸	۰/۹۴۲۰	۰/۲۲۸۷	۰/۲۰۴۲	۳۰۹
		LOGSIG						
		- LOGSIG- TANSIG	۸-۱۷-۹-۱	۰/۰۰۰۴۷	۰/۹۴۶۵	۰/۲۲۰۹	۰/۱۹۳۴	۷۹
		LOGSIG						
	LM	- TANSIG- TANSIG	۸-۱۷-۹-۱	۰/۰۰۰۴۰	۰/۹۴۴۲	۰/۲۱۵۳	۰/۲۰۸۲	۷۶
		LOGSIG						
		- LOGSIG- LOGSIG	۸-۱۷-۹-۱	۰/۰۰۰۳۸	۰/۹۴۰۹	۰/۲۲۱۹	۰/۲۱۲۶	۱۰۰
		TANSIG						
		- TANSIG- TANSIG	۸-۱۸-۱۱-۱	۰/۰۰۰۳۲	۰/۹۴۷۲	۰/۲۱۳۲	۰/۲۰۲۲	۸۷
		LOGSIG						
FFB P		- TANSIG- LOGSIG	۸-۱۵-۱۴-۱	۰/۰۰۰۶۲	۰/۹۵۷۱	۰/۱۹۸۲	۰/۱۷۰۶	۱۱۸
		TANSIG						
		- TANSIG- LOGSIG	۸-۱۵-۱۴-۱	۰/۰۰۰۶۷	۰/۹۵۱۴	۰/۲۱۱۰	۰/۱۸۷۲	۲۰۷
		LOGSIG						
	BR	- TANSIG- LOGSIG	۸-۱۶-۱۱-۱	۰/۰۰۰۷۲	۰/۹۵۹۳	۰/۱۸۵۵	۰/۱۷۶۳	۲۲۹
		LOGSIG						
		- TANSIG- LOGSIG	۸-۱۶-۱۶-۱	۰/۰۰۰۵۴	۰/۹۵۷	۰/۱۹۶۴	۰/۱۷۴۹	۱۳۴
		TANSIG						
		- TANSIG- LOGSIG	۸-۱۷-۱۰-۱	۰/۰۰۰۷۱	۰/۹۵۱۱	۰/۲۰۸۲	۰/۱۸۷۰	۱۳۴
		TANSIG						
		- TANSIG- LOGSIG	۸-۱۸-۱۲-۱	۰/۰۰۰۰۶	۰/۹۵۱۳	۰/۲۰۱۷	۰/۱۹۰۱	۱۱۵
		TANSIG						




شکل ۵- چگونگی فرایند یادگیری شبکه بهینه



شکل ۶- محتوای رطوبتی پیش بینی شده با روش شبکه عصبی مصنوعی در مقابل مقادیر واقعی آن برای داده های آزمون



شکل ۷- پیش‌بینی مقادیر رطوبت لایه‌های شلتوک به وسیله شبکه بهینه طراحی شده



شکل ۸- خطای واقعی حاصل از پیش‌بینی مقادیر رطوبت لایه‌های شلتوک به وسیله شبکه بهینه طراحی شده

مراجع

۱. صادقی، م.، خوش‌تقاض، م.ه. و خیاط، الف.ع.، ۱۳۸۳. اصول طراحی و ساخت خشک‌کن بستر سیال ارتعاشی آزمایشگاهی جهت مطالعه شناسایی مواد مرطوب. نشریه علمی پژوهشی امیرکبیر (مهندسی مکانیک و گرایش‌های وابسته). سال ۱۵، شماره ب-۵۸، ص ۳۹۷-۳۸۵.
2. Brooker, D.B., Bakker-Arkema, F.W., and Hall, C.W. 1992. Drying and Storage of Grains and Oilseeds, 1rd ed., Van Nostrand Reinold, USA.
3. Calderwood, D.I. 1971. Rice Drying and storage studies. The Rice Journal, 74: 56-59.
4. Kaminski, W. and Tomczak, E. 1999. An integrated neural model for drying and degradation of selected products. Drying Technology, 17(7&8): 1291-1301.
5. Hall, C.W. 1980. Drying and Storage of Agricultural Crops. 1rd ed., the AVI Publishing Co, Westport, Connecticut.
6. Kunii, D. and Levenspiel, O. 1991. Fluidization Engineering, 2rd ed., Stoneham: Butterworth-Heinemann, USA.
7. Teter, N. 1987. Paddy Drying Manual. FAO. Rome.
8. Peuty, M.A., Themelin, A., Cruz, J.F., Arnand, G. and Fohr, J.P. 1994. Improvement of paddy quality by optimization of drying conditions. Proceedings of the 9th International Drying Symposium. Gold Coast, Australia, Vol. B: 929-935.
9. Farkas, I., Remenyi, P. and Biro, A. 2000a. Modeling aspects of grain drying with a neural network. Computers and Electronics in Agriculture, 29: 99-113.
10. Farkas, I., Remenyi, P. and Biro, A. 2000b. A neural network topology for modeling grain drying. Computers and Electronics in Agriculture, 26: 147-158.



11. Zbicinski, I., Strumillo, P. and Kaminski, W. 1996. Hybrid neural model of thermal drying in a fluidized bed. *Computers in Chemical Engineering*, 20: 695-700.
12. Dayhoff, J.E. 1990. *Neural Networks Principles*. 1rd ed. Prentice-Hall International, USA.
13. Khanna, T. 1990. *Foundations of Neural Networks*. 1rd ed. Addison-Wesley Publishing Company, USA.
14. Hagan, M.T. and Menhaj, M.B. 1994. Training feed forward networks with the marquardt algorithm. *IEEE Transaction on Neural Networks*. 5(6): 989-993.
15. Girosi, F., Jones, M. and Poggio, T. 1995. Regularization theory and neural network architectures. *Neural Computing*. 7: 219-269.
16. Kozma, R., Sakuma, M., Yokoyama, Y. and Kitamura, M. 1996. On the accuracy of mapping back propagation with forgetting. *Neurocomputing*. 13(2-4): 295-311.
17. ASAE. 2000. *ASAE Standard S352.2: Moisture Measurement-Unground Grain and Seeds*. ST. Joseph. MI: USA.
18. Heristev, R.M. 1998. *The ANN Book*. GNU Public License. Available on (<ftp://ftp.funet.fi/pub/sci/neural/books/>).