

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در خشک‌کردن به روش

بستر ثابت به کمک شبکه‌های عصبی مصنوعی

محمدهادی خوش تقاضا، رضا امیری چایجان، غلامعلی منتظر و سعید مینایی*

* به ترتیب دانشیار گروه مکانیک ماشینهای کشاورزی دانشکده کشاورزی دانشگاه تربیت مدرس، نشانی: تهران، دانشگاه تربیت مدرس،

ص. پ. ۱۳۹-۱۴۱۱۵، تلفن: ۴-۴۴۱۹۴۹۱۱ (۰۲۱)، پیام‌نگار: khoshtag@modares.ac.ir؛ استادیار گروه ماشینهای کشاورزی

دانشکده کشاورزی دانشگاه بوعلی سینا؛ استادیار مهندسی فناوری اطلاعات دانشگاه تربیت مدرس؛ و دانشیار گروه مکانیک ماشینهای

کشاورزی دانشکده کشاورزی دانشگاه تربیت مدرس

تاریخ دریافت مقاله: ۸۵/۱/۲۸؛ تاریخ پذیرش: ۸۵/۱۲/۵

چکیده

هدف از این تحقیق پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در خشک‌کردن به روش بستر ثابت به کمک شبکه‌های عصبی مصنوعی است. چند پارامتر در عملکرد خشک‌کن‌های بستر ثابت مؤثرند که به عنوان متغیرهای مستقل برای شبکه عصبی مصنوعی در نظر گرفته شده‌اند. این متغیرها عبارت‌اند از رطوبت نسبی هوای محیط، دمای هوای محیط، سرعت هوای ورودی، عمق بستر شلتوک، دمای هوای ورودی، رطوبت اولیه و رطوبت نهایی. برای ایجاد الگوهای آموزش و ارزیابی به وسیله یک خشک‌کن آزمایشگاهی، ۳۵۷ آزمایش خشک کردن اجرا شد. سپس نمونه‌هایی از عمق‌های مختلف خشک‌کن جدا و عملیات پوست‌کنی و سفید کردن با دستگاه‌های آزمایشگاهی انجام شد. ضریب تبدیل برای تمام عمق‌ها اندازه‌گیری و میانگین آنها به عنوان ضریب تبدیل آزمایش منظور شد. از شبکه‌های پس انتشار پیشرو و پس انتشار پیشخور با الگوریتم‌های یادگیری لونیبرگ-مارکوارت و تنظیم بیزی برای آموزش الگوهای موجود استفاده شد. نتایج نشان داد که شبکه پس انتشار پیشخور با توپولوژی ۱-۷-۷-۷ و الگوریتم آموزش لونیبرگ-مارکوارت و راهبرد توابع یکسان برای تمام لایه‌ها (تانزاننت سیگموئید) قادر است راندمان تبدیل شلتوک را به برنج سفید با ضریب تعیین ۹۶/۵۵ درصد و خطای متوسط مطلق ۰/۰۱۹ در شرایط مختلف خشک‌کردن شلتوک در گستره بستر ثابت پیش‌بینی کند. نتایج نشان داد که دمای هوای ورودی و پس از آن میزان رطوبت نهایی، بیشترین تأثیر را بر ضریب تبدیل شلتوک دارند.

واژه‌های کلیدی

الگوریتم تنظیم بیزی، الگوریتم لونیبرگ-مارکوارت، شبکه پس انتشار پیشرو، شلتوک، ضریب تبدیل

مقدمه

محافظ و پوششی آن در مرحله پوست‌کنی و سبوس در مرحله سفید کردن جدا می‌شود. طی مراحل مذکور اگر رطوبت اولیه شلتوک در حد مناسبی نباشد، امکان آسیب دیدن آندوسپرم نشاسته‌ای برنج وجود دارد (Brooker et al., 1992). برای انبار کردن شلتوک، رطوبت آن باید حداکثر ۱۳ درصد بر پایه تر باشد، در

شلتوک در محدوده رطوبتی ۱۶ تا ۲۸ درصد (بر پایه تر) برداشت می‌شود. میزان رطوبت شلتوک برداشت شده بستگی دارد به روش و زمان برداشت، رقم، و موقعیت مکانی آن. عموماً شلتوک را بعد از برداشت ابتدا خشک می‌کنند و پس از آن در عملیات تبدیل پوست

حالی که برای عملیات تبدیل بهتر است، بسته به رقم، بین ۱۰ تا ۱۳ درصد پایه تر باشد (Teter, 1987). خشک کردن شلتوک، در عملیات پس از برداشت نقش مهمی در میزان ضایعات دارد زیرا عملکرد مراحل دیگر به مقدار زیاد متاثر از چگونگی خشک کردن شلتوک خواهد بود. از این رو، مطالعه ضایعات بخش خشک کردن شلتوک توجه محققان بسیاری را به خود معطوف کرده است (Bandyopadhyay & Roy, 1992).

هنگامی که از برنج برای تغذیه استفاده می شود خصوصیت کیفی آن به صورت دانه کامل از اهمیت زیادی برخوردار است. خصوصیات کیفی شلتوک تحت تأثیر عوامل متعدد مانند طول دوره رشد، زمان و چگونگی برداشت، نحوه نگهداری، حمل و نقل، و خشک کردن قرار می گیرد. از مهم ترین خصوصیات کیفی برنج می توان به میزان رطوبت، قابلیت جوانه زنی، چگالی، رنگ، و کیفیت تبدیل اشاره کرد. راندمان برنج سفید سالم، با کیفیت تبدیل ارتباط مستقیم دارد. در تولید برنج سفید، شرایطی که در مرحله خشک کردن و تبدیل تلفات کمتر ایجاد کند مناسب تر است. ضریب تبدیل شلتوک یکی از مهمترین معیارهای پیش بینی کیفیت تبدیل شلتوک به برنج سفید است. این شاخص برای ارزیابی عملکرد دستگاه های فراوری و تبدیل برنج، از جمله در مرحله خشک کردن، اهمیت ویژه ای دارد. کیفیت تبدیل شلتوک به برنج سفید هنگامی مناسب است که مقدار این شاخص بیشینه شود. پیش بینی ضریب تبدیل شلتوک به برنج سفید می تواند در یافتن شرایط بهینه خشک کردن شلتوک در شرایط بستر ثابت و در طراحی خشک کن و تنظیم مناسب آن به کار رود (Peyman et al., 2000; Juliano, 1993).

کاهش در رطوبت نسبی هوای خشک کردن در دمای ثابت، نسبت دانه های شکسته را بعد از عملیات تبدیل

افزایش می دهد (Aguerre et al., 1986). نتایج تحقیق پیوتی و همکاران (Peuty et al., 1994) برای یافتن شرایط مناسب خشک کردن برنج به روش بستر ثابت نشان داد که افزایش دمای ورودی به خشک کن در شرایطی که رطوبت نسبی هوای محیط زیاد است، تأثیر قابل توجهی روی بازده برنج سفید سالم ندارد و با کاهش رطوبت نسبی، افزایش دمای ورودی تأثیر زیادی بر بازده برنج سفید سالم خواهد داشت. به عبارت دیگر، با ثابت نگه داشتن دما و افزایش ظرفیت تبخیر هوا، بازده برنج سفید سالم کاهش خواهد یافت به طوری که شدت این کاهش در دماهای بالاتر بیشتر مشهود است. با کوتاه شدن زمان خشک شدن نیز بازده برنج سفید سالم کاهش یافت.

چن و همکاران (Chen et al., 1997) تحقیقی روی چهار متغیر خشک کردن شلتوک یعنی وضعیت خشک کردن (دما و رطوبت نسبی هوا)، رقم شلتوک، میزان رطوبت اولیه، و وضعیت و زمان نگهداری شلتوک قبل از خشک کردن انجام داده اند. نتایج نشان داد که وضعیت خشک کردن و رقم تأثیر معنی داری روی ثابت خشک کردن k در معادله پیچ^۱ در سطح ۵ درصد دارد، اما وضعیت زمان نگهداری شلتوک قبل از خشک کردن هیچ تأثیر معنی داری بر ثابت خشک کردن ندارد.

برای کاهش رطوبت شلتوک از روش های مختلف خشک کردن استفاده می شود. روش خشک کردن بستر ثابت بیشترین کاربرد را در کاهش رطوبت شلتوک در ایران دارد. هنگامی که هوا از میان دانه های بستر شلتوک به بالا هدایت می شود، در دبی پایین یک بستر ثابت خواهیم داشت به طوری که با افزایش دبی جریان، بستر منبسط و نقطه حد اقل سیال سازی حاصل می شود. به محدوده شروع جریان هوا از بستر مواد تا نقطه حد اقل سیال سازی اصطلاحاً بستر ثابت گفته می شود

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

پیش‌بینی رطوبت لایه‌های محصول در خشک‌کن بستر ثابت از محققانی هستند که از این تکنیک استفاده کرده‌اند.

زانگ و همکاران (Zhang *et al.*, 2002) برای پیش‌بینی شاخص‌های انرژی مصرفی، ترک دانه، رطوبت نهایی محصول، آهنگ دفع رطوبت^۱، شدت خشک‌شدن و آهنگ دفع جرم آب^۲ برای فرایند خشک‌کردن شلتوک به کمک چهار پارامتر ورودی: ضخامت لایه^۳ برنج، دبی هوای گرم، دمای هوا، و زمان خشک‌شدن، از روش شبکه‌های عصبی مصنوعی استفاده کردند. پس از پیش‌بینی توسط الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی، با استفاده از یک برنامه‌نویسی چندهدفه برای بهینه‌سازی پارامترهای خشک‌کردن در محدوده انجام آزمایش‌ها، مقدار بهینه ضخامت لایه^۳ برنج ۶۶ سانتی‌متر، سرعت هوای ورودی ۰/۳ متر بر ثانیه، دمای هوای ورودی ۹۳ درجه سانتی‌گراد و زمان خشک‌کردن ۲۳ دقیقه به دست آمد.

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید می‌تواند در یافتن شرایط بهینه خشک‌کردن شلتوک در شرایط بستر ثابت و در طراحی خشک‌کن و تنظیم مناسب آن به کار رود. هدف این تحقیق عبارت است از پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در خشک‌کردن به روش بستر ثابت به کمک پارامترهای دما و رطوبت نسبی هوای محیط، سرعت هوای ورودی، عمق بستر شلتوک، دمای هوای ورودی، رطوبت اولیه و رطوبت نهایی شلتوک.

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرایند "یادگیری"^۴ و با استفاده از پردازشگرهایی ساده به نام نرون^۴ تلاش می‌کند با شناخت روابط موجود میان داده‌ها، نگاشتی میان فضای ورودی

(Kunni & Lvenspiel, 1991). در شرایط بستر عمیق، به دلیل ایجاد اختلاف رطوبتی بین لایه‌های محصول در انتهای فرایند خشک‌شدن، تلفات ناشی از بیش یا کم خشک‌شدن افزایش می‌یابد. توصیه شده است، در صورتی که دمای مورد استفاده برای خشک‌کردن غلات در شرایط بستر ثابت بیش از ۴۳/۳ درجه سانتی‌گراد باشد بهتر است عمق بستر از ۰/۴۵ متر کمتر باشد (Brooker *et al.*, 1992).

راندمان برنج سفید سالم (نسبت برنج سفید سالم به شلتوک مصرفی) در استان‌های گیلان و مازندران به طور متوسط به ترتیب ۵۲/۳۳ و ۵۰ درصد است. در شرایط ایده‌ال، راندمان تبدیل باید حدود ۶۵ درصد باشد. از این‌رو کاهش ۱۳ تا ۱۵ درصدی در کاهش راندمان تبدیل باعث بروز زیان شدید در بخش اقتصاد کشور می‌شود (Shariatmadar, 1997). همچنین، در ایران به دلیل رعایت نکردن تنظیم‌های لازم برای اعمال دبی هوای ورودی مناسب به توده شلتوک به ازای هر تن و کنترل‌نشدن دمای هوای ورودی به خشک‌کن و عمق زیاد شلتوک، افزایش تلفات ناشی از خشک‌شدن برنج تشدید می‌شود (Hashemi Soleymani, 1997).

چند تن از محققان برای پیش‌بینی پارامترهای مورد نظر در خشک‌کن‌ها از شبکه‌های عصبی مصنوعی استفاده کرده‌اند. زیبسینسکی و سیلسسکی (Zbicinski & Ciesielski, 2000) برای پیش‌بینی ضریب انتقال حرارت مواد مختلف، اسلام و همکاران (Islam *et al.*, 2003) برای پیش‌بینی آهنگ (روند) خشک‌کردن، زیبسینسکی و همکاران (Zbicinski *et al.*, 1996) برای مدل‌سازی فرایند تبخیر رطوبت در یک خشک‌کن بستر سیال، و فارکاس و همکاران (Farkas *et al.*, 2000b; Farkas *et al.*, 2000a) برای

1- Moisture Removal Rate

2- Water Mass Removal Rate

3- Learning

4- Neuron

در مرحله آموزش، ابتدا محاسبات از ورودی شبکه به سوی خروجی آن 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. شبکه پس‌انتشار پیشرو (CFBP) نیز مانند شبکه پس‌انتشار پیشخور از الگوریتم BP برای بهنگام‌سازی وزن‌ها استفاده می‌کند ولی خصوصیت اصلی شبکه مذکور این است که نرون‌های هر لایه به همه نرون‌های لایه‌های قبل متصل‌اند (Khanna, 1990).

الگوریتم‌های آموزش

الگوریتم‌های آموزش به کار رفته برای بهنگام‌سازی وزن‌های شبکه‌های مورد استفاده عبارت‌اند از:

الگوریتم لونبرگ-مارکوارت^۱ (LM): این الگوریتم‌ها به دلیل چندان موثر نیستند که گرادینان در روند حل مسئله از بین می‌رود. الگوریتم‌های مبتنی بر ماتریس هسین^۲، به شبکه اجازه می‌دهند تا با دقت بیشتری الگوها را فرا بگیرند (Hagan & Menhaj, 1994). الگوریتم LM برای آموزش شبکه عصبی مصنوعی از طریق توزیع محاسبات و فضای مورد نیاز، موازی عمل می‌کند و از این رو سریع‌ترین روش برای آموزش شبکه‌های عصبی پس‌انتشار با ابعاد متوسط (حداکثر چندصد اتصال وزنی و بایاس) است. الگوریتم LM اساساً بر مبنای ماتریس هسین است که برای بهینه‌سازی غیرخطی بر مبنای حداقل مربعات استفاده می‌شود.

الگوریتم تنظیم بی‌زی^۳ (BR): فرایند آموزش شبکه پس‌انتشار با الگوریتم تنظیم بی‌زی، با توزیع تصادفی وزن‌های اولیه آغاز می‌شود. توزیع تصادفی این پارامترها جهت‌گیری اولیه را قبل از ارائه داده‌ها به شبکه تعیین می‌کند. بعد از ارائه داده‌ها به

(لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت‌شده از لایه ورودی را پردازش می‌کند و در اختیار لایه خروجی قرار می‌دهد. هر شبکه با دریافت نمونه‌هایی "آموزش" می‌بیند. آموزش، فرایندی است که در نهایت به یادگیری شبکه منجر می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف مقادیر مطلوب و محاسبه شده (خروجی شبکه) در حد قابل قبولی باشد. با دست یافتن به این شرایط، فرایند یادگیری محقق شده است. این وزن‌ها حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش‌دیده می‌تواند برای پیش‌بینی و درونیابی خروجی‌هایی متناسب با مجموعه جدید داده به کار رود (Dayhoff, 1990). در این تحقیق از شبکه‌های پس‌انتشار پیشرو^۴ و پس‌انتشار پیشخور^۵ استفاده شده است.

شبکه پس‌انتشار پیشخور (FFBP) شامل یک لایه ورودی، یک یا چند لایه مخفی، و یک لایه خروجی است. برای آموزش این شبکه از الگوریتم یادگیری پس‌انتشار خطا^۶ (BP) استفاده می‌شود. در حالت پس‌انتشار، ابتدا وزن‌های لایه خروجی تعدیل می‌شود، زیرا برای هر یک از نرون‌های لایه خروجی، مقدار مطلوب وجود دارد و می‌توان به کمک آنها و قاعده‌های به‌نگام‌سازی، وزن‌ها را تعدیل کرد (Khanna, 1990). پس از محاسبه خطای آموزش توسط شبکه، مقدار آن با مقدار مطلوب مقایسه و خطای آموزش محاسبه می‌شود و الگوریتم یادگیری اقدام به بهینه‌سازی مقدار خطای مربوط می‌کند. اگر خطای آموزش از خطای تعیین‌شده از قبل کمتر باشد، فرایند یادگیری پایان می‌یابد.

1- Training

2- Cascade-Forward Back Propagation

3- Feed-Forward Back Propagation

4- Error Back Propagation

5- Levenberg-Marquardt

6- Hessian Matrix

7- Bayesian Regularization

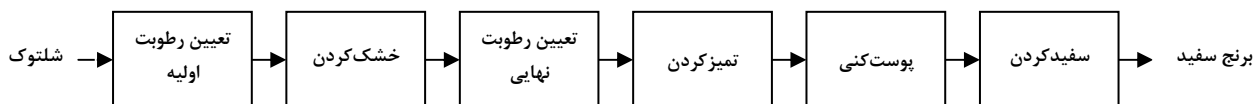
پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

SSE و یک تابع جریمه است به طور خودکار تنظیم می‌شود (Giroso *et al.*, 1995).

مواد و روش‌ها

برای تعیین ضریب تبدیل شلتوک در تمام آزمایش‌های بستر ثابت از دستگاه‌ها و روش‌های مختلفی استفاده شده است که روند آن در شکل ۱ نشان داده شده است و به اختصار بیان می‌شود.

شبکه، بهنگام‌سازی وزن‌های اولیه آغاز می‌شود تا توزیع ثانویه با استفاده از تنظیم بیزی حاصل شود. از آنجایی که داده‌های به کار رفته ممکن است با خطاهای زیادی همراه باشند، روش‌های مؤثری برای بهبود عملکرد تعمیم ضروری خواهد بود. از این‌رو، روش تنظیم بیزی که شامل تنظیم پیچیدگی شبکه و اصلاح تابع عملکرد است مناسب است. در این الگوریتم به جای مجموع مربعات خطا (*SSE*) از مجموعه آموزشی، یک تابع هدف که شامل



شکل ۱- روند تعیین ضریب تبدیل شلتوک در آزمایش‌های خشک کردن به روش بستر ثابت

اجاق در دمای ۱۳۰ درجه سانتی‌گراد استفاده شد (Anon, 2004). میزان رطوبت اولیه شلتوک بین ۱۴/۹ و ۲۱/۸۳ درصد بر پایه تر متغیر بود. از آنجا شلتوک با کمترین برداشت شده بود تغییرات رطوبت در توده شلتوک به دلیل وجود انواع شلتوک رسیده و نارس بوده است که روشی برای کاهش سطح رطوبت اولیه شلتوک اعمال نشده بود.

خشک‌کن آزمایشگاهی و تجهیزات مورد استفاده

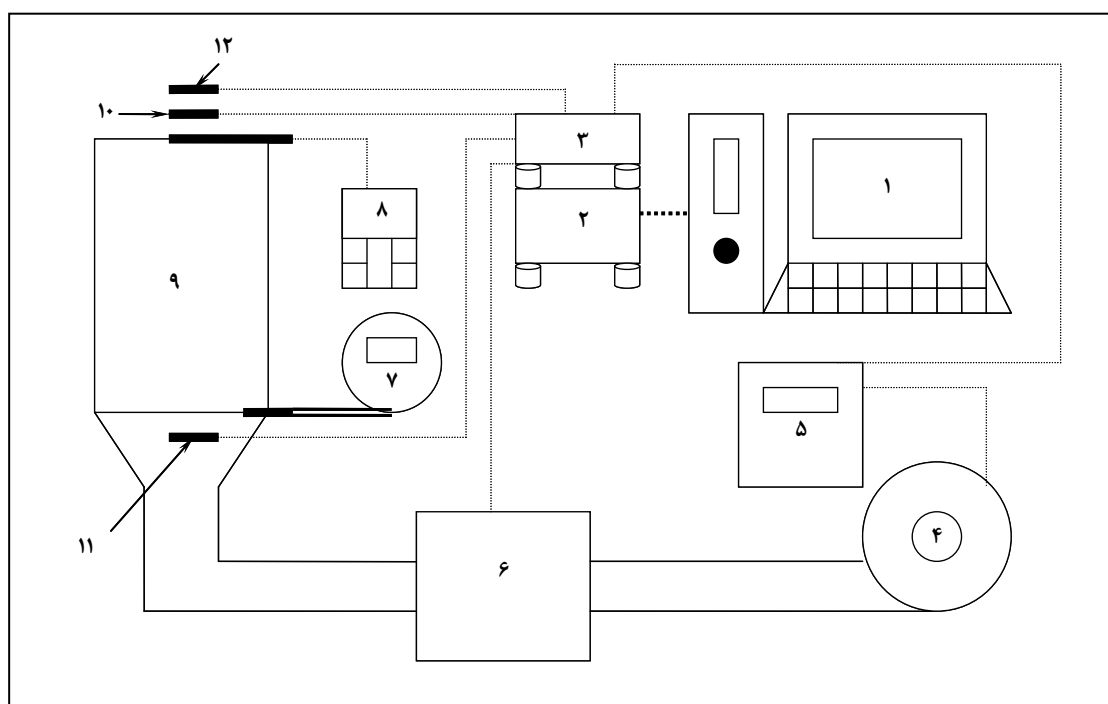
برای خشک کردن نمونه‌های شلتوک، از دستگاه خشک‌کن آزمایشگاهی استفاده شد، که صادقی و همکاران (Sadeghi *et al.*, 2004) آن را طراحی کرده و ساخته بودند (شکل ۲). در این دستگاه محفظه خشک‌کن با سطح مقطع ۰/۱۶ × ۰/۱۶ متر مربع از جنس پلکسی‌گلاس شفاف است و هوای مورد نیاز

آماده‌سازی نمونه‌ها

برای اجرای آزمایش‌ها، از شلتوک رقم هاشمی استفاده شد که اغلب در شمال کشور کشت می‌شود. این رقم در بین کشاورزان و مردم منطقه جزء ارقام مناسب و بازارپسند محسوب می‌شود. حدود ۱۰۰۰ کیلوگرم شلتوک از یک مزرعه مؤسسه تحقیقات برنج واقع در رشت انتخاب و در کیسه‌های نایلونی با ظرفیت ۵۰ کیلوگرم ریخته و در آنها کاملاً بسته شد تا از کاهش رطوبت شلتوک جلوگیری و در عین حال تعادل نسبی بین دانه‌ها ایجاد شود. برای جلوگیری از کاهش رطوبت شلتوک و ایجاد فساد در آن، کیسه‌های شلتوک در دمای ۴ درجه سانتی‌گراد و رطوبت نسبی حدود ۸۰ درصد در سردخانه نگهداری شد. برای تعیین رطوبت دانه‌ها از روش خشک‌کردن و کاهش وزن به مدت ۲۴ ساعت درون

همچنین دمای بستر ذرات حسگرهای دما و رطوبت نسبی اندازه‌گیری می‌کنند. برای نگارش برنامه کنترل خشک‌کن، از نرم‌افزار Visual Basic استفاده شده است. این برنامه قابلیت ثبت حسگرهای دما، رطوبت نسبی و دور موتور دمنده را با فواصل یک ثانیه دارد. سرعت هوای خروجی را یک سرعت‌سنج هوای پره‌ای از نوع LoutronA-M-4202 (بر حسب متر بر ثانیه) با دقت ± 1 درصد اندازه‌گیری می‌کند. برای تنظیم رطوبت و دمای اتاق خشک‌کن نیز از یک دستگاه رطوبت و گرماساز، ساخت شرکت "پیوند صنعت همگام" استفاده شد. به کمک دستگاه مذکور، رطوبت نسبی و دمای هوای اتاق روی مقادیر مورد نظر تنظیم و آزمایش‌ها در شرایط تنظیم شده اجرا شد.

برای فرایند خشک‌کردن را دمنده‌ای سانتریفیوژ با موتور سه‌فاز با قدرت ۲ اسب بخار و سرعت ۲۸۰۰ دور بر دقیقه تأمین می‌شود. هوای عبوری از یک کوره حرارتی با ۱۱ المنت به دمای مطلوب می‌رسد. به منظور کنترل دما و دبی هوای ورودی به محفظه خشک‌کن، یک سیستم کنترل خودکار رایانه‌ای استفاده شده است. این سیستم از چهار قسمت: منبع تغذیه، مدار اصلی کنترل، مدار تقویت‌کننده حسگرها، و مدار راه‌انداز رله تشکیل شده است. تغییر دور موتور سه‌فاز دمنده را یک دستگاه تنظیم سرعت Topvert مدل 7300 L202 بر عهده دارد که از تغییر فرکانس جریان ورودی به موتور دمنده دور موتور دمنده تغییر داده می‌شود. دما و رطوبت نسبی هوای ورودی و خروجی و



شکل ۲- خشک‌کن آزمایشگاهی (۱- رایانه؛ ۲ و ۳- منبع تغذیه، اتصال حسگرها و سیستم کنترل؛ ۴- دمنده؛ ۵- اینورتر؛ ۶- کوره حرارتی؛ ۷- فشارسنج؛ ۸- بادسنج؛ ۹- محفظه خشک‌کن؛ ۱۰ و ۱۱- حسگر دما؛ و ۱۲- حسگر رطوبت نسبی)

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

اجرای عملیات تبدیل، یک نمونه ۷۰ گرمی از عمق‌های مختلف به فواصل ۵ سانتی‌متر از ستون شلتوک جدا شد. برای عمق ۲۰ سانتی‌متر به ترتیب از هر یک از عمق‌های ۲۰، ۱۵، ۱۰، ۵، و صفر سانتی‌متر نمونه‌های ۷۰ گرمی جدا شدند. با دستگاه بوجار Tripette & Renaud مدل Colonne Inra Labo ساخت کشور فرانسه، مواد زاید و خارجی نمونه‌ها نیز جدا و نمونه‌ها برای عملیات تبدیل آماده شدند. سپس از هریک از نمونه‌ها، سه نمونه ۱۵ گرمی به شکلی جدا شد که عاری از دانه‌های سبز و نارس باشند. نمونه‌های شلتوک ابتدا به دستگاه پوست‌کن غلتک لاستیکی وارد و سپس برنج قهوه‌ای به داخل محفظه سفیدکن ریخته شد. دانه‌های شکسته که قطر بزرگ آنها کوچک‌تر از $\frac{1}{3}$ قطر بزرگ برنج سالم بود به روش دستی از دانه‌های سالم جدا و توزین شدند. راندمان برنج سفید سالم^۱ (HRY) از رابطه زیر محاسبه شد:

$$HRY = \frac{HR}{RW} \times 100 \quad (1)$$

در این رابطه، HR = وزن برنج سفید سالم (بر حسب گرم) و RW = وزن اولیه شلتوک (۱۵ گرم) است. میانگین ضرایب تبدیل تمام عمق‌ها به عنوان ضریب تبدیل هر آزمایش مستقل خشک‌کردن در نظر گرفته شد.

طراحی شبکه عصبی مصنوعی

با در نظر گرفتن هفت عامل ورودی اعمال شده در همه آزمایش‌های خشک‌کردن بستر ثابت، مقدار متوسط ضریب تبدیل توده شلتوک به دست آمد. شبکه عصبی مصنوعی با هفت نرون لایه ورودی (عمق بستر شلتوک، رطوبت نهایی، رطوبت اولیه، دمای هوای محیط، رطوبت نسبی

روش خشک‌کردن

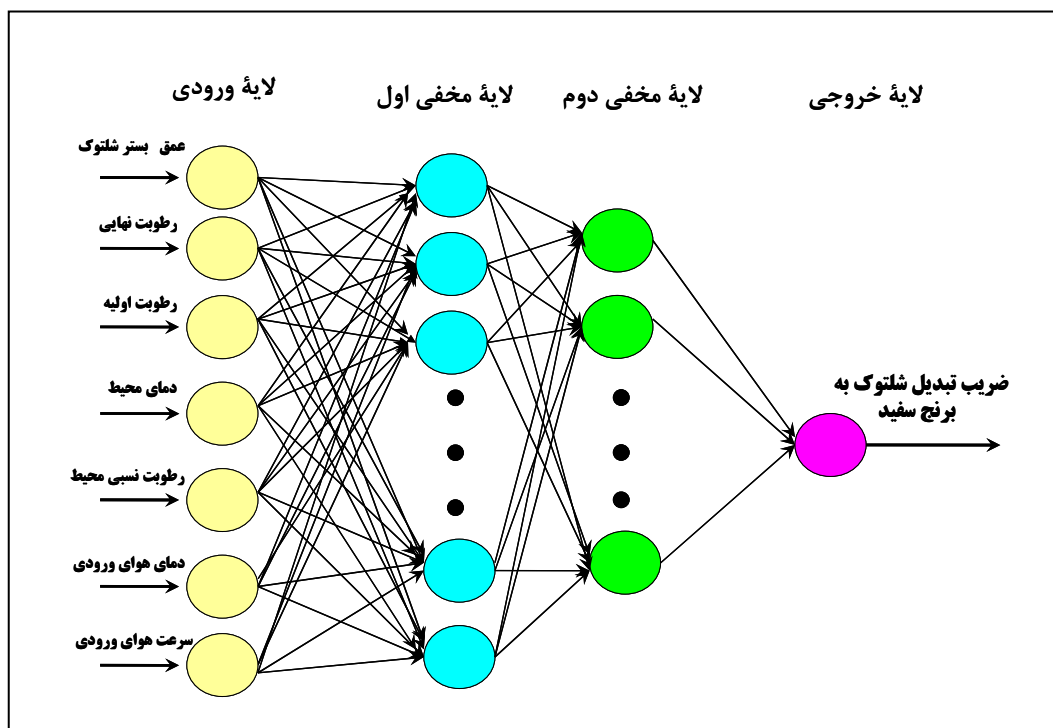
عوامل زیادی در فرایند خشک‌کردن شلتوک مؤثرند؛ برخی از این عوامل عبارت‌اند از: رطوبت اولیه شلتوک، رطوبت نهایی شلتوک، عمق لایه شلتوک، رطوبت نسبی محیط، و دمای هوای محیط، دمای ورودی، دبی هوای ورودی، و زمان خشک‌شدن. عوامل یاد شده در شرایط آزمایشگاهی اعمال و آزمایش‌ها در عمق ۵ تا ۲۰ سانتی‌متر اجرا شد؛ در هر مورد از عمق‌های یادشده، رطوبت متوسط نهایی نمونه‌ها با روش وزن‌کردن در زمان‌های متوالی به سطوح ۸/۷۶ تا ۱۴/۶ درصد پایه‌تر کاهش داده شد. از نمونه شلتوک با رطوبت اولیه بین ۱۴/۹ و ۲۱/۸۳ درصد بر پایه‌تر استفاده شد. قبل از هر آزمایش شرایط اتاق آزمایش در دما و رطوبت نسبی مورد نظر تنظیم می‌شد و به تعادل می‌رسید. دمای محیط بین ۲۰ تا ۳۰ درجه سانتی‌گراد و رطوبت نسبی آن بین ۴۰ تا ۹۰ درصد تنظیم شد. پس از متعادل‌شدن هوای اتاق، آزمایش‌ها شروع و دماهای بین ۴۰ تا ۷۰ درجه سانتی‌گراد برای خشک‌کردن نمونه‌ها اعمال شد. دور موتور نیز طوری تنظیم شد که سرعت‌های بین ۰/۱ متر بر ثانیه و سرعت حداقل سیال‌سازی برای هر عمق اعمال شود. مقادیر سرعت حداقل سیال‌سازی برای عمق‌های ۵، ۱۲/۵، و ۲۰ سانتی‌متر به ترتیب ۱، ۱/۳، و ۲/۲ متر بر ثانیه به دست آمد. با توجه به موارد فوق، ۳۵۸ آزمایش خشک‌کردن شلتوک در شرایط بستر ثابت و در شرایط محیطی کنترل شده اجرا شد.

روش تبدیل شلتوک به برنج سفید

برای بررسی راندمان برنج سفید سالم، از دستگاه‌های پوست‌کن یانمار مدل ST 50 و سفیدکن KETT مدل PEARLEST ساخت کشور ژاپن استفاده شد. قبل از

1- Head Rice Yield

هوای محیط، دمای هوای ورودی، و سرعت هوای ورودی) و یک نرون لایه خروجی (ضریب تبدیل شلتوک) طراحی شد. شکل ۳ توپولوژی شبکه عصبی مورد استفاده همراه با پارامترهای ورودی و خروجی آزمایشی را نشان می‌دهد. در این تحقیق از جعبه ابزار شبکه عصبی MATLAB، نسخه ۴/۱ استفاده شده است.



شکل ۳- توپولوژی شبکه عصبی مصنوعی مورد استفاده

$$Y_j = \frac{1}{1 + \exp(-X_j)} \quad (2) \text{ تابع سیگموئید}^1$$

$$Y_j = X_j \quad (3) \text{ تابع خطی}^2$$

$$(4) \text{ تابع تانژانت هایپربولیک}^3$$

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

که در آنها، X_j = مجموع ورودی‌های وزن دار هر یک از نرون‌های لایه زام است و از رابطه زیر محاسبه می‌شود:

برای دستیابی به پاسخ مناسب، دو شبکه مورد استفاده قرار گرفت، یکی شبکه پسانتشار پیشرو و دیگری شبکه پسانتشار پیشخور. فرایند آموزش توسط شبکه‌های فوق فرایندی تکراری است که شامل تغییر وزن‌های بین لایه‌های مختلف است و طی آموزش به تدریج به سمت ثبات این وزن‌ها پیش می‌رود، به طوری که خطای بین مقادیر مطلوب (مقدار واقعی) و پیش‌بینی شده به حداقل برسد. توابع فعال‌سازی مختلفی برای یافتن حالت بهینه آن ارزیابی شد (Khanna, 1990) که عبارت‌اند از:

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

خروجی نرون λ_m ؛ و b_j مقدار بایاس نرون لایه λ_m است.

حدود ۲۵ درصد داده‌ها به طور تصادفی برای ارزیابی

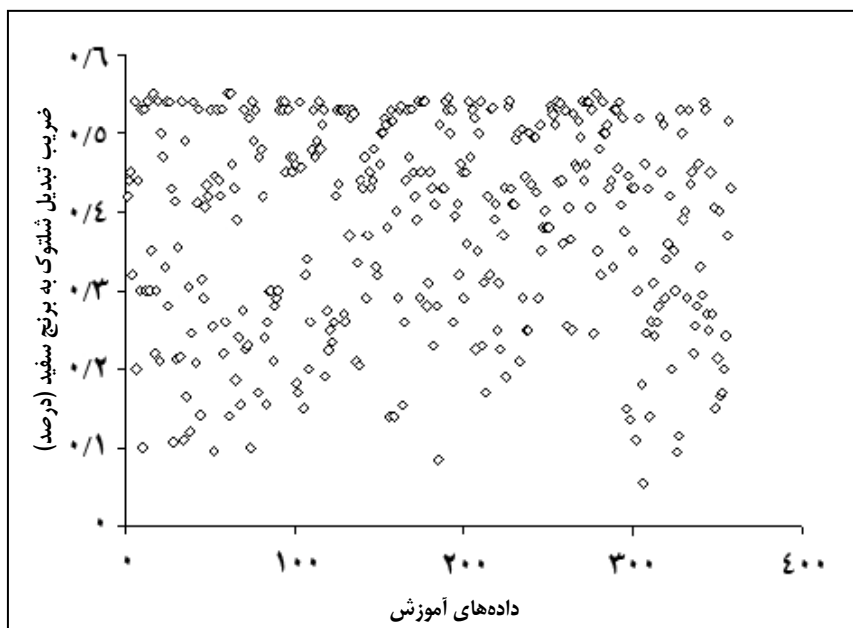
شبکه آموزش دیده مورد استفاده قرار گرفت. پراکندگی

داده‌های آموزشی در شکل ۴ نشان داده شده است.

$$X_j = \sum_{i=1}^m W_{ij} \times Y_i + b_j \quad (5)$$

برای شبکه‌های پس‌انتشار پیشرو و پیشخور، m = تعداد

نرون‌های لایه خروجی؛ W_{ij} = وزن بین لایه i و j ؛ Y_i =



شکل ۴- تعداد و پراکندگی داده‌های آموزش

T_{ip} = خروجی مطلوب در نرون λ_m و الگوی p ام؛ N = تعداد

نرون‌های خروجی؛ و M = تعداد الگوهای آموزشی است.

برای بهینه‌سازی شبکه‌های یافته شده در مرحله قبل نیز از

معیارهای ضریب تعیین، خطای میانگین مطلق، و انحراف

معیار خطای میانگین مطلق استفاده شد که روابط آنها

(Dayhoff, 1990; Khanna, 1990) به صورت زیر است:

$$R^2 = 1 - \frac{\sum_{k=1}^T [S_k - T_k]}{\sum_{k=1}^T [S_k - T_m]} \quad , \quad (T_m = \frac{\sum_{k=1}^T S_k}{T}) \quad (7)$$

برای یافتن شبکه‌ای با توپولوژی مناسب

به کمک الگوریتم‌های آموزشی، از معیار

خطای مربعات میانگین استفاده شد که هدف از آن

کمینه‌شدن خطای مذکور است و با رابطه ۶

(Dayhoff, 1990; Khanna, 1990) تعریف می‌شود:

$$E_{MS} = \sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2 \quad (6)$$

که در آن، E_{MS} = خطای مربعات میانگین در مرحله

آموزش؛ S_{ip} = خروجی شبکه در نرون λ_m و الگوی p ام؛

$$E_{MA} = \frac{I}{T} \sum_{k=1}^T |S_k - T_k| \quad (8)$$

$$SD_{E_{MA}} = \sqrt{\frac{\sum_{k=1}^T |S_k - T_k| - \left| \overline{S_k - T_k} \right|}{T - I}} \quad (9)$$

توابع فعال‌سازی مختلف برای لایه‌ها. در شرایط توابع یکسان برای تمام لایه‌ها در شبکه CFBP، هر دو الگوریتم LM و BR در اکثر موارد دچار ورآموزی^۲ می‌شدند یا قادر به یادگیری داده‌های آموزشی نبودند (جدول ۲). در الگوریتم LM، تابع فعال‌سازی تانژانت هایپربولیک (TANSIG) برای تمام لایه‌ها نسبت به توابع فعال‌سازی سیگموئید (LOGSIG) و خطی (PURELIN) نتایج بهتری داشت. تابع فعال‌سازی PURELIN با هر دو الگوریتم نتایج مناسبی ارائه نداد. همچنین تابع LOGSIG به همراه الگوریتم BR نتایج مناسبی حاصل نکرد و در الگوریتم LM از تابع TANSIG عملکرد ضعیف‌تری نشان داد. در شرایط کلی، توپولوژی چهار لایه نسبت به توپولوژی سه‌لایه نتایج بهتری به دست می‌دهد. توپولوژی‌های سه‌لایه در الگوریتم BR قادر به یادگیری داده‌های آموزشی نبودند. در جدول ۲ مشاهده می‌شود که الگوریتم BR با توپولوژی ۱-۱۰-۱۴-۷ و تابع فعال‌سازی TANSIG بهترین نتایج را برای شبکه CFBP در راهبرد اول ارائه می‌دهد، خطای آموزش آن ۰/۰۰۰۵۱ حاصل شد. در این شرایط، کمترین مقدار خطای واقعی ۰/۰۲۰ و بیشترین مقدار ضریب تعیین، ۰/۹۶۱۹ به دست آمد (شکل ۵-الف). تعداد چرخه^۳ آموزش آن ۶۷ بود.

در شرایط توابع فعال‌سازی غیریکسان برای شبکه CFBP، الگوریتم BR، نسبت به الگوریتم LM، به طور متوسط دارای عملکرد بهتر و خطای کمتری است (جدول ۳). توپولوژی‌های سه‌لایه در هر دو الگوریتم، نسبت به

که در آنها، $R^2 =$ ضریب تعیین؛ $E_{MA} =$ خطای میانگین مطلق؛ و $SD_{E_{MA}} =$ انحراف معیار خطای میانگین مطلق است. برای افزایش دقت و سرعت شبکه عصبی مصنوعی، ابتدا داده‌های ورودی به کمک رابطه^{۱۰} به شکل هنجار^۱ درآمدند:

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (10)$$

که در آن، $X_n =$ مقدار هنجار شده؛ $X_i =$ مقدار واقعی؛ $X_{min} =$ کمینه مقادیر واقعی؛ و $X_{max} =$ بیشینه مقادیر واقعی است.

مقدار خطای متوسط آموزش برای شبکه‌های پس‌انتشار پیشرو و پس‌انتشار پیشخور به همراه الگوریتم‌های یادگیری و توپولوژی‌های مختلف بررسی شد.

نتایج و بحث

دو راهبرد برای بررسی تأثیر توابع فعال‌سازی مختلف برای بهینه‌سازی شبکه‌های مورد استفاده به کار گرفته شد: یکی توابع فعال‌سازی یکسان برای لایه‌ها و دیگری

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

توپولوژی‌های چهارلایه، نتایج ضعیف‌تری ارائه داد. در این راهبرد از ترکیب‌های مختلف LOGSIG، TANSIG و PURELIN در توپولوژی‌های سه‌لایه و چهارلایه استفاده شد. بهترین نتایج در جدول ۳ نشان داده شده است. در الگوریتم BR توپولوژی ۱-۹-۱۱-۷ با ترتیب توابع فعال‌سازی LOGSIG-LOGSIG-TANSIG با وجود ارائه خطای آموزش بیشتر، نسبت به چند توپولوژی دیگر، دارای ضریب تعیین بیشتر (۰/۹۶۳۰)، خطای مطلق (۰/۰۲۰) و میانگین خطای مطلق (۰/۰۱۶) کمتری نسبت به آنهاست (جدول ۳ و شکل ۵-ب).

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

پارامتر	کمینه	بیشینه
عمق کل شلتوک (سانتی‌متر)	۵	۲۰
رطوبت نهایی بر پایه تر (درصد)	۸/۷۶	۱۴/۶
رطوبت اولیه بر پایه تر (درصد)	۱۴/۹	۲۱/۸۳
دمای هوای محیط (درجه سانتی‌گراد)	۲۰	۳۰
رطوبت نسبی محیط (درصد)	۴۰	۹۰
دمای هوای ورودی (درجه سانتی‌گراد)	۴۰	۷۰
سرعت هوای ورودی (متر بر ثانیه)	۰/۱	سرعت حداقل سیال‌سازی

جدول ۲- مقادیر خطای آموزش برای شبکه CFBP برای مقادیر مختلف تعداد لایه‌ها و نرون‌ها و توابع فعال‌سازی یکسان برای لایه‌ها

الگوریتم یادگیری	تابع فعال‌سازی	تعداد لایه‌ها و نرون‌ها	E_{MS}	R^2	E_{MA}	SD_{EMA}	چرخه آموزش
	TANSIG	۷-۱۳-۱	۰/۰۰۰۳۰	۰/۹۴۲۹	۰/۰۲۲	۰/۰۱۹	۳۰
LM	LOGSIG	۷-۱۳-۱	۰/۰۰۰۳۴	۰/۹۳۴۶	۰/۰۲۵	۰/۰۲۱	۳۲
	TANSIG	۷-۹-۷-۱	۰/۰۰۰۵۶	۰/۹۶۰۹	۰/۰۲۱	۰/۰۱۶	۳۰
	LOGSIG	۷-۹-۷-۱	۰/۰۰۰۷۵	۰/۹۵۴۲	۰/۰۲۲	۰/۰۱۸	۲۹
	TANSIG	۷-۱۱-۹-۱	۰/۰۰۰۵۶	۰/۹۶۰۶	۰/۰۲۰	۰/۰۱۶	۵۷
BR	TANSIG	۷-۱۳-۹-۱	۰/۰۰۰۵۱	۰/۹۶۱۴	۰/۰۲۰	۰/۰۱۵	۶۴
	TANSIG	۷-۱۴-۱۰-۱	۰/۰۰۰۵۱	۰/۹۶۱۹	۰/۰۲۰	۰/۰۱۵	۶۷
	TANSIG	۷-۱۵-۷-۱	۰/۰۰۰۶۱	۰/۹۶۱۲	۰/۰۲۰	۰/۰۱۶	۵۲

جدول ۳- مقادیر خطای آموزش برای شبکه CFBP برای مقادیر مختلف تعداد لایه ها و نرون ها و توابع فعال سازی غیریکسان برای لایه ها

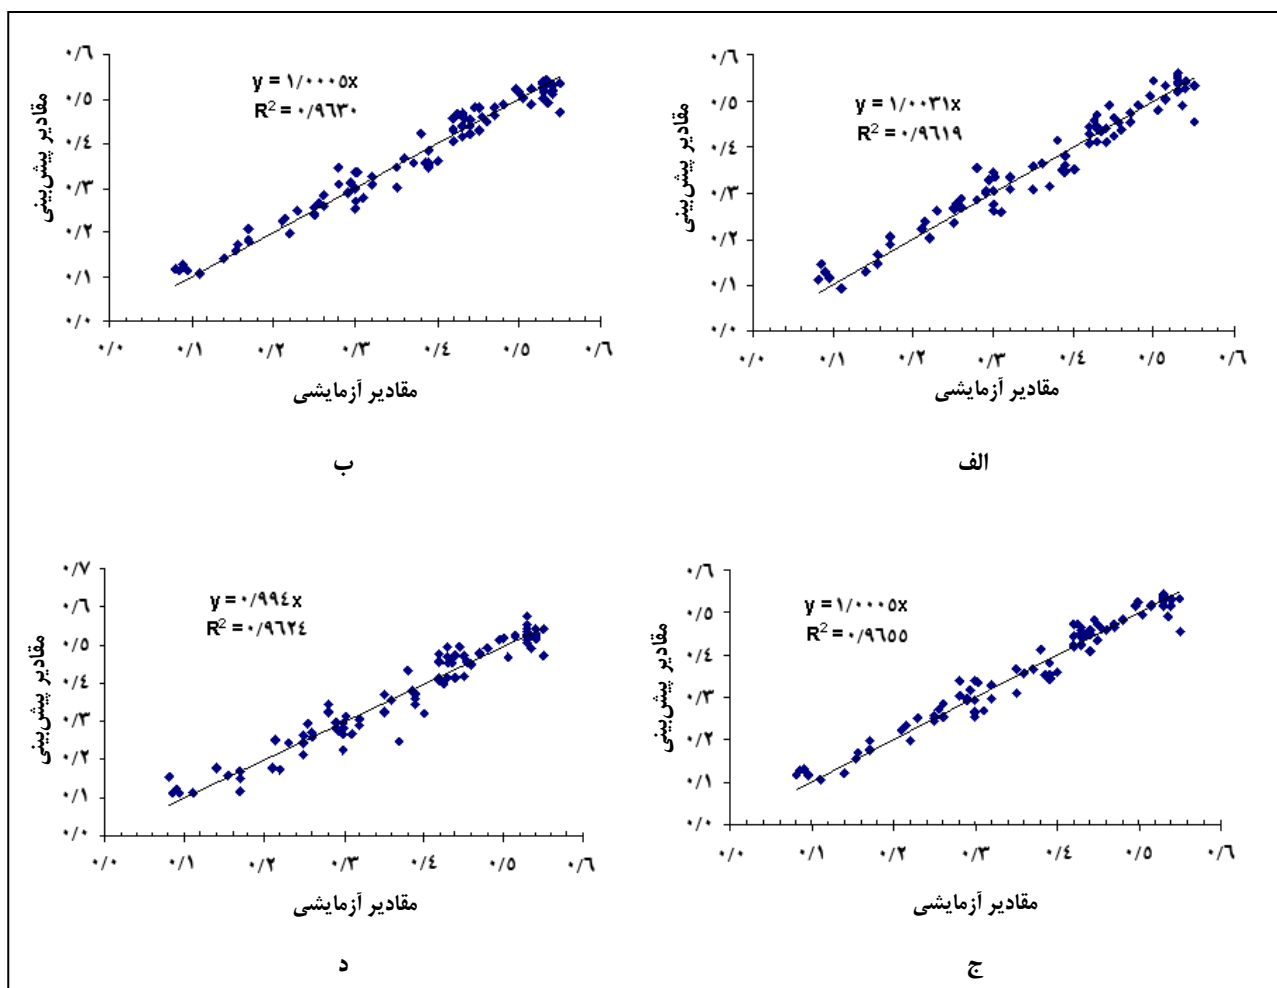
الگوریتم یادگیری	توابع فعال سازی	تعداد لایه ها و نرون ها	E_{MS}	R^2	E_{MA}	SD_{EMA}	چرخه آموزش
	LOGSIG-TANSIG	۷-۱۳-۱	۰/۰۰۰۴۸	۰/۹۴۶۴	۰/۰۲۳	۰/۰۱۸	۳۰
LM	TANSIG- LOGSIG	۷-۱۳-۱	۰/۰۰۰۴۷	۰/۹۳۶۸	۰/۰۲۵	۰/۰۲۰	۳۴
	TANSIG- TANSIG- LOGSIG	۷-۹-۷-۱	۰/۰۰۰۲۷	۰/۹۴۸۴	۰/۰۲۴	۰/۰۱۹	۳۴
	LOGSIG- LOGSIG- TANSIG	۷-۹-۷-۱	۰/۰۰۰۱۲	۰/۹۳۹۷	۰/۰۲۳	۰/۰۲۲	۳۳
	LOGSIG- LOGSIG- TANSIG	۷-۱۱-۹-۱	۰/۰۰۰۵۷	۰/۹۶۳۰	۰/۰۲۰	۰/۰۱۶	۶۱
BR	LOGSIG- LOGSIG- TANSIG	۷-۱۳-۹-۱	۰/۰۰۰۵۸	۰/۹۶۰۰	۰/۰۲۱	۰/۰۱۶	۵۱
	LOGSIG- LOGSIG- TANSIG	۷-۱۴-۱۰-۱	۰/۰۰۰۵۹	۰/۹۶۰۸	۰/۰۲۰	۰/۰۱۶	۴۵
	LOGSIG- TANSIG- LOGSIG	۷-۱۴-۱۰-۱	۰/۰۰۰۵۹	۰/۹۶۰۴	۰/۰۲۰	۰/۰۱۶	۶۲
	TANSIG- LOGSIG- TANSIG	۷-۱۵-۷-۱	۰/۰۰۰۵۵	۰/۹۶۰۹	۰/۰۲۰	۰/۰۱۶	۵۱

یکسان (جدول ۵) بهترین نتایج الگوریتم LM در شرایط توابع فعال سازی LOGSIG-LOGSIG-TANSIG برای توپولوژی ۱-۱۲-۱۲-۸ به دست آمد. در حالی که برای الگوریتم BR بهترین نتایج مربوط به توابع فعال سازی LOGSIG-LOGSIG-TANSIG با توپولوژی ۱-۷-۱۱-۷ است که با توجه به این که توپولوژی اخیر نسبت به بهترین توپولوژی LM خطای آموزش بیشتری دارد و از این رو توپولوژی LM انتخاب می شود. بهترین توپولوژی جدول ۵ مربوط به توابع فعال سازی LOGSIG-LOGSIG-TANSIG با توپولوژی ۱-۱۲-۱۲-۷ است که خطای آموزش ۰/۰۰۰۵۲، ضریب تعیین ۰/۹۶۲۴ (جدول ۴-د)، خطای میانگین مطلق ۰/۰۱۹، و انحراف معیار خطای میانگین مطلق ۰/۰۱۶ تولید می کند و دارای تعداد چرخه آموزش ۴۹ است.

در شرایط توابع فعال سازی یکسان برای شبکه FFBP، الگوریتم BR دارای توپولوژی های بیشتری برای ارائه نتایج مناسب تر بود (جدول ۴). برای هر دو الگوریتم LM و BR، استفاده از تابع فعال سازی LOGSIG نتایج ضعیف تری نسبت به تابع TANSIG ارائه می دهد. توپولوژی های سه لایه در الگوریتم LM نتایج ضعیفی ارائه داد. در الگوریتم BR توپولوژی های چهار لایه دارای عملکرد بهتری در یادگیری داده های آموزشی بودند. بهترین نتایج توپولوژی های این راهبرد مربوط به الگوریتم LM با توپولوژی ۱-۷-۷-۷ است که خطای آموزش ۰/۰۰۰۴۷، ضریب تعیین ۰/۹۶۵۵ (شکل ۵-ج)، خطای میانگین مطلق ۰/۰۱۹، و انحراف معیار خطای میانگین مطلق ۰/۰۱۵ را نشان می دهد. تعداد چرخه آموزش برای حصول این نتیجه ۳۳ است.

برای شبکه FFBP در راهبرد توابع فعال سازی غیر

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...



شکل ۵- ضریب تبدیل پیش‌بینی شده با روش شبکه عصبی مصنوعی در مقابل مقادیر واقعی آن برای چهار توپولوژی بهینه
 الف- شبکه CFBP، الگوریتم BR، توپولوژی ۱-۱۰-۱۴-۷، تابع فعال‌سازی TANSIG-TANSIG-TANSIG
 ب- شبکه CFBP، الگوریتم BR، توپولوژی ۱-۹-۱۱-۷، تابع فعال‌سازی LOGSIG-LOGSIG-TANSIG
 ج- شبکه FFBP، الگوریتم LM، توپولوژی ۱-۷-۷-۷، تابع فعال‌سازی TANSIG-TANSIG-TANSIG
 د- شبکه FFBP، الگوریتم LM، توپولوژی ۱-۱۲-۱۲-۷، تابع فعال‌سازی LOGSIG-LOGSIG-TANSIG

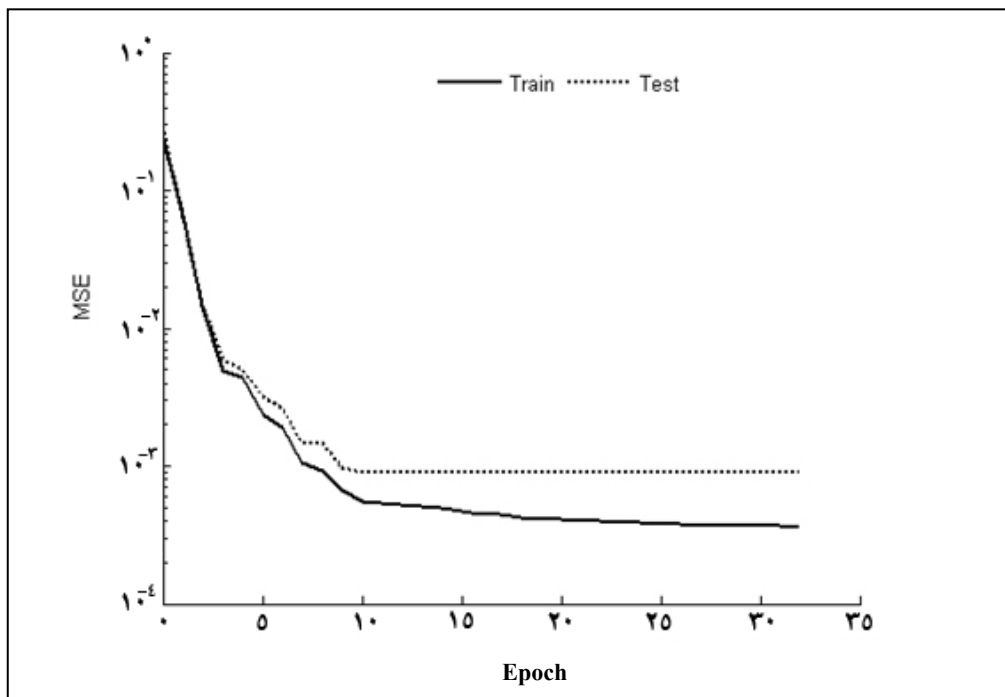
جدول ۴- مقادیر خطای آموزش برای شبکه FFBP در شرایط مقادیر مختلف تعداد لایه‌ها و نرون‌ها و توابع فعال‌سازی یکسان برای لایه‌ها

چرخه آموزش	SD_{EMA}	E_{MA}	R^2	E_{MS}	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی	الگوریتم یادگیری
۳۳	۰/۰۱۵	۰/۰۱۹	۰/۹۶۵۵	۰/۰۰۰۴۷	۷-۷-۷-۱	TANSIG	
۲۹	۰/۰۲۰	۰/۰۲۴	۰/۹۴۲۴	۰/۰۰۰۲۸	۷-۷-۷-۱	LOGSIG	
۶۸	۰/۰۱۶	۰/۰۱۹	۰/۹۶۲۸	۰/۰۰۰۵۵	۷-۸-۸-۱	TANSIG	
۳۸	۰/۰۲۰	۰/۰۲۴	۰/۹۴۱۷	۰/۰۰۰۲۸	۷-۸-۸-۱	LOGSIG	
۴۶	۰/۰۱۷	۰/۰۱۹	۰/۹۶۲۱	۰/۰۰۰۵۵	۷-۹-۷-۱	TANSIG	
۲۷	۰/۰۲۵	۰/۰۲۹	۰/۹۱۷۶	۰/۰۰۰۲۶	۷-۹-۷-۱	LOGSIG	
۷۷	۰/۰۱۶	۰/۰۲۰	۰/۹۶۱۳	۰/۰۰۰۵۰	۷-۱۰-۷-۱	TANSIG	LM
۲۷	۰/۰۱۹	۰/۰۲۱	۰/۹۵۰۱	۰/۰۰۰۱۶	۷-۱۰-۷-۱	LOGSIG	
۶۱	۰/۰۱۶	۰/۰۲۰	۰/۹۶۴۰	۰/۰۰۰۴۷	۷-۱۳-۸-۱	TANSIG	
۳۰	۰/۰۲۳	۰/۰۲۵	۰/۹۳۰۳	۰/۰۰۰۰۶۱	۷-۱۳-۸-۱	LOGSIG	
۶۲	۰/۰۱۶	۰/۰۲۰	۰/۹۶۲۸	۰/۰۰۰۵۵	۷-۸-۷-۱	TANSIG	
۳۶	۰/۰۱۶	۰/۰۲۰	۰/۹۶۰۴	۰/۰۰۰۴۸	۷-۸-۷-۱	LOGSIG	
۶۴	۰/۰۱۶	۰/۰۱۹	۰/۹۶۲۵	۰/۰۰۰۵۴	۷-۸-۸-۱	TANSIG	
۴۷	۰/۰۱۶	۰/۰۲۰	۰/۹۶۱۱	۰/۰۰۰۴۸	۷-۸-۸-۱	LOGSIG	
۶۹	۰/۰۱۵	۰/۰۱۹	۰/۹۶۳۹	۰/۰۰۰۵۲	۷-۹-۸-۱	TANSIG	BR
۴۰	۰/۰۱۷	۰/۰۲۰	۰/۹۵۹۹	۰/۰۰۰۵۳	۷-۹-۸-۱	LOGSIG	
۶۶	۰/۰۱۶	۰/۰۱۹	۰/۹۶۳۱	۰/۰۰۰۵۴	۷-۹-۹-۱	TANSIG	
۴۳	۰/۰۱۶	۰/۰۲۱	۰/۹۵۸۱	۰/۰۰۰۵۲	۷-۹-۹-۱	LOGSIG	
۵۸	۰/۰۱۶	۰/۰۱۹	۰/۹۶۲۴	۰/۰۰۰۵۵	۷-۱۱-۷-۱	TANSIG	
۴۵	۰/۰۱۶	۰/۰۲۰	۰/۹۶۰۵	۰/۰۰۰۴۶	۷-۱۱-۷-۱	LOGSIG	
۵۸	۰/۰۱۶	۰/۰۱۹	۰/۹۶۲۴	۰/۰۰۰۵۵	۷-۱۲-۱۰-۱	TANSIG	
۳۷	۰/۰۱۶	۰/۰۲۰	۰/۹۶۰۵	۰/۰۰۰۵۰	۷-۱۲-۱۰-۱	LOGSIG	
۷۲	۰/۰۱۶۰	۰/۰۱۹	۰/۹۶۳۶	۰/۰۰۰۵۵	۷-۱۵-۹-۱	TANSIG	
۳۶	۰/۰۱۷	۰/۰۲۰	۰/۹۵۸۸	۰/۰۰۰۵۰	۷-۱۵-۹-۱	LOGSIG	

جدول ۵- مقادیر خطای آموزش برای شبکه FFBP برای مقادیر مختلف تعداد لایه‌ها و نرون‌ها و توابع فعال‌سازی مختلف برای لایه‌ها

چرخه آموزش	SD_{EMA}	E_{MA}	R^2	E_{MS}	تعداد لایه‌ها و نرون‌ها	توابع فعال‌سازی	الگوریتم یادگیری
۴۹	۰/۰۱۶	۰/۰۲۰	۰/۹۶۰۳	۰/۰۰۰۵۲	۷-۷-۷-۱	TANSIG- LOGSIG -TANSIG	
۸۲	۰/۰۱۶	۰/۰۲۰	۰/۹۶۱۰	۰/۰۰۰۵۵	۷-۷-۷-۱	LOGSIG- TANSIG- TANSIG	
۵۲	۰/۰۱۶	۰/۰۲۰	۰/۹۵۹۲	۰/۰۰۰۵۵	۷-۸-۸-۱	TANSIG- LOGSIG -TANSIG	
۴۹	۰/۰۱۶	۰/۰۱۹	۰/۹۶۲۴	۰/۰۰۰۵۲	۸-۱۲-۱۲-۱	LOGSIG- LOGSIG- TANSIG	LM
۶۲	۰/۰۱۶	۰/۰۲۰	۰/۹۶۰۳	۰/۰۰۰۴۴	۸-۱۵-۹-۱	TANSIG- TANSIG- LOGSIG	
۴۵	۰/۰۱۹	۰/۰۲۲	۰/۹۶۰۸	۰/۰۰۰۵۰	۸-۱۵-۹-۱	TANSIG- LOGSIG -TANSIG	
۴۷	۰/۰۱۵	۰/۰۲۰	۰/۹۶۱۰	۰/۰۰۰۴۶	۸-۱۲-۹-۱	TANSIG- LOGSIG -TANSIG	
۶۳	۰/۰۱۷	۰/۰۲۰	۰/۹۶۰۱	۰/۰۰۰۵۵	۸-۱۲-۹-۱	LOGSIG- LOGSIG- TANSIG	
۴۷	۰/۰۱۸	۰/۰۲۲	۰/۹۵۱۹	۰/۰۰۰۵۴	۷-۱۱-۱	TANSIG- LOGSIG	
۹۶	۰/۰۱۷	۰/۰۲۰	۰/۹۵۷۲	۰/۰۰۰۵۳	۷-۱۱-۱	LOGSIG-TANSIG	
۵۵	۰/۰۱۷	۰/۰۲۲	۰/۹۵۲۵	۰/۰۰۰۵۱	۷-۱۴-۱	TANSIG- LOGSIG	
۴۸	۰/۰۱۷	۰/۰۲۱	۰/۹۵۶۱	۰/۰۰۰۵۳	۷-۱۴-۱	LOGSIG-TANSIG	BR
۴۸	۰/۰۱۶	۰/۰۲۰	۰/۹۶۱۸	۰/۰۰۰۵۰	۷-۸-۷-۱	TANSIG- TANSIG- LOGSIG	
۴۲	۰/۰۱۶	۰/۰۱۹	۰/۹۶۲۸	۰/۰۰۰۵۳	۷-۱۱-۷-۱	LOGSIG- LOGSIG- TANSIG	
۵۱	۰/۰۱۶	۰/۰۲۰	۰/۹۶۱۵	۰/۰۰۰۵۲	۷-۱۱-۷-۱	LOGSIG- TANSIG- LOGSIG	
۳۹	۰/۰۱۶	۰/۰۲۰	۰/۹۶۱۳	۰/۰۰۰۵۱	۷-۱۵-۹-۱	TANSIG-LOGSIG - TANSIG	

در میان چهار توپولوژی برتر انتخاب شده از جدول‌های ۲ تا ۵، بهترین نتایج، مربوط به راهبرد توابع فعال‌سازی یکسان (TANSIG)، شبکه FFBP و الگوریتم LM است که توپولوژی ۷-۷-۷-۱ را دارد، زیرا خطای آموزش کمتر (۰/۰۰۰۴۷)، ضریب همبستگی بیشتر (۰/۹۶۵۵) و خطای مطلق مناسب (۰/۰۱۹)، و انحراف معیار خطای ۰/۰۱۵ را تولید می‌کند. تعداد چرخه آموزش آن ۳۳ است (شکل ۶).



شکل ۶- چگونگی فرایند یادگیری شبکه بهینه

ماتریس‌های بین لایه‌ها و بایاس‌ها برای توپولوژی بهینه عبارت است از:

$$iw_{\{2,1\}} = \begin{bmatrix} -0.18043 & 0.2443 & -0.4702 & -0.5486 & -0.36558 & 0.2063 & -0.2689 \\ -0.1200 & 0.4807 & -0.10767 & 0.2989 & -0.2044 & 0.1925 & -0.4733 \\ 0.1483 & -0.2789 & 0.4738 & -0.5046 & -0.10786 & -0.10867 & 0.7994 \\ -0.1565 & -0.2756 & -0.6771 & 0.2740 & 0.1688 & 0.5258 & -0.8160 \\ -0.6410 & -0.432 & 0.1845 & -0.10867 & -0.5788 & 0.3031 & -0.1398 \\ -0.1730 & 0.2847 & 0.1117 & 0.3129 & -0.10735 & 0.357 & 0.5784 \\ -0.7443 & 0.627 & 0.7078 & -0.7218 & 0.3602 & -0.1142 & -0.2469 \end{bmatrix}$$

$$iw_{\{3,2\}} = \begin{bmatrix} -0.1710 & 0.1923 & 0.7670 & 0.1201 & -0.4244 & 0.3018 & 0.0612 \\ -0.6262 & 0.4669 & 0.2058 & 0.5892 & -0.2627 & 0.5635 & -0.4067 \\ -0.5705 & 0.1827 & 0.1484 & -0.1117 & -0.3106 & 0.2466 & 0.2973 \\ -0.2855 & -0.3462 & -0.5574 & -0.5248 & -0.3472 & -0.2301 & -0.6342 \\ -0.0549 & 0.1947 & -0.10630 & -0.1016 & 0.3396 & 0.4008 & 0.1428 \\ -0.1339 & -0.1822 & 0.1816 & -0.5325 & 0.3094 & -0.10452 & 0.5318 \\ 0.2585 & -0.1045 & 0.3321 & -0.6069 & -0.5523 & -0.2862 & 0.1409 \end{bmatrix}$$


$$iw_{\{4,3\}} = \begin{bmatrix} -0.7379 & -0.8922 & 0.5624 & 0.6194 & 0.5166 & -0.4459 & -0.7528 \end{bmatrix}$$

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

$$b\{1\} = \begin{bmatrix} -0.2528 \\ -0.0299 \\ 0.1609 \\ -0.1875 \\ 0.1016 \\ -0.5235 \\ -0.3763 \end{bmatrix} \quad b\{2\} = \begin{bmatrix} -0.3660 \\ -0.3897 \\ 0.1953 \\ 0.1046 \\ -0.2489 \\ 0.3149 \\ -0.1806 \end{bmatrix} \quad b\{3\} = [0.033]$$

مقادیر انحراف کمتر از ۰/۰۳ بودند که مقدار مناسبی است. به منظور بررسی میزان تأثیر پارامترهای ورودی بر مقدار HRV اقدام به حذف هر یک از پارامترهای ورودی در شبکه‌های مورد نظر شد، به طوری که در هر نوبت شش پارامتر ورودی به شبکه اعمال شد. نتایج در جدول ۶ نشان داده شده است.

برای بررسی قابلیت تعمیم شبکه آموزش‌دیده بهینه، از ۹۰ داده مستقل استفاده شد. نتایج نشان داد که شبکه مذکور با توپولوژی به کار رفته، می‌تواند برای پیش‌بینی مقادیر ضریب تبدیل با خطای واقعی ۰/۰۱۹ به کار رود. به طوری که مقادیر پیش‌بینی‌شده ۷ تا از داده‌های ارزیابی دارای انحراف ۰/۰۳ بودند (شکل ۷) و ۹۲/۲ درصد داده‌ها دارای



شکل ۷- پراکندگی خطای واقعی حاصل از پیش‌بینی مقادیر ضریب تبدیل شلتوک به برنج سفید به وسیله شبکه بهینه طراحی شده

جدول ۶- نتیجه حاصل از حذف پارامترهای ورودی در به کارگیری الگوریتم یادگیری LM، تابع آستانه TANSIG در شبکه FFBP با

توپولوژی ۱-۷-۷-۷

پارامتر حذف شده	E_{MS}	R^2	E_{ma}	SD_{ma}	چرخه آموزش
رطوبت نسبی هوای محیط	۰/۰۰۰۵۸	۰/۹۴۹۵	۰/۰۲۱۵	۰/۰۱۹	۳۰
دمای هوای محیط	۰/۰۰۰۵۵	۰/۹۳۷۳	۰/۰۲۳۵	۰/۰۲	۲۸
رطوبت اولیه	۰/۰۰۰۸۴	۰/۸۶۵۸	۰/۰۳۴۵	۰/۰۲۸۵	۲۶
رطوبت نهایی	۰/۰۰۱۰	۰/۷۷۳۰	۰/۰۴۳	۰/۰۳۷۵	۲۸
سرعت هوای ورودی	۰/۰۰۰۷۷	۰/۹۳۱۹	۰/۰۲۵	۰/۰۲۱۵	۳۵
عمق بستر شلتوک	۰/۰۰۰۷۲	۰/۹۴۴۱	۰/۰۲۳۵	۰/۰۱۸۵	۲۷
دمای هوای ورودی	۰/۰۱۰	-	۰/۱	۰/۰۷۰۵	۲۷

و همکاران (Bonazzi *et al.*, 1994)، تأثیر دمای ورودی بر نسبی میانگین بیشتری منجر شود بیانگر تأثیر بیشتر آن پارامتر ورودی بر مقدار HRY خواهد بود. لذا با توجه به نتایج به دست آمده می توان دریافت که به ترتیب دمای ورودی و میزان رطوبت نهایی بیشترین تأثیر و رطوبت نسبی هوا و عمق شلتوک کمترین تأثیر را بر HRY در محدوده انجام آزمایشها دارند، زیرا دمای هوا و پس از آن میزان رطوبت نهایی باعث ایجاد بیشترین خطا در HRY می شوند. با توجه به اینکه خشک کردن شلتوک با خشک کن بستر ثابت در محدوده آهنگ ثابت و نزولی انجام می شود، برابند اهمیت متغیرها در دو مرحله ارائه شده است، زیرا رطوبت نهایی عامل محدودکننده در مرحله نزولی خشک کردن است و به دلیل تأثیر اندک دمای ورودی بر آهنگ خروج رطوبت در این مرحله، ایجاد ترک در دانه تشدید می شود. چروکیدگی شدید دانه و در نتیجه، ایجاد تنشهایی در داخل دانه برنج و اختلاف در شدت خشک شدن در قسمت های مختلف دانه برنج، ترک خوردن دانه را در پی دارد. طبق نتایج تحقیق بونازی

و همکاران (Bonazzi *et al.*, 1994)، تأثیر دمای ورودی بر HRY از پارامترهای دیگر بیشتر است. نتایج پژوهش های آنچتا و آندالس (Ancheta & Andales, 1990) نیز بیانگر اهمیت رطوبت نهایی بر HRY است. هاشمی سلیمانی (Hashemi Soleymani, 1997) در پژوهشی اهمیت دمای ورودی بر HRY را نشان داد و بیان کرد که دمای مناسب خشک کردن شلتوک باید کمتر از ۵۰ درجه سانتی گراد باشد. طی پژوهشی، تتر (Teter, 1987) نیز بر اهمیت تنظیم دما به منظور حصول HRY مناسب تأکید کرده است. او دمای ۴۵ درجه سانتی گراد را برای خشک کردن بستر ثابت متوالی برنج توصیه کرده است. در مطالعات خوش تقاضا و سلیمانی (Khoshtaghaza & Soleymani, 1999) نیز مشخص شده است که مهم ترین عامل تأثیرگذار بر شکنندگی دانه برنج (رقم بینام)، دمای هوای ورودی است و میزان رطوبت نهایی در درجه دوم اهمیت قرار دارد. نتایج بررسی ها نشان داد که به ترتیب دمای هوای ورودی و میزان رطوبت نهایی بیشترین تأثیر را بر HRY دارند.

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

دریافت که دمای ورودی و پس از آن میزان رطوبت نهایی بیشترین تأثیر و رطوبت نسبی هوا و عمق شلتوک کمترین تأثیر را بر HRY در محدوده انجام آزمایش‌ها دارند. همچنین از نتایج این تحقیق چنین برمی‌آید که با توجه به تغییرات نسبتاً بالای پارامترهای ورودی و خطاهای اندازه‌گیری، می‌توان ضریب تبدیل شلتوک را با دقت مناسب در محدوده بستر ثابت پیش‌بینی و اقدام به بهینه‌سازی فرایند کرد یا گام‌هایی را جهت کاهش ضایعات، طی فرایند خشک‌کردن، برداشت. بررسی‌ها نشان داد که دمای هوای ورودی و پس از آن میزان رطوبت نهایی، بیشترین تأثیر را بر HRY دارند.

نتیجه‌گیری

شبکه عصبی مصنوعی روشی مناسب برای نگاشت غیرخطی است و ضریب تبدیل شلتوک را به کمک هفت پارامتر ورودی: رطوبت متوسط نهایی، رطوبت اولیه، سرعت هوای ورودی، رطوبت نسبی هوای محیط، دمای هوای محیط، دمای هوای ورودی به خشک‌کن، و عمق شلتوک پیش‌بینی می‌کند. بهترین شبکه عصبی، برای آموزش داده‌ها، شبکه پس انتشار پیش‌خورد با الگوریتم آموزش لونیگ-مارکوارت و تابع فعال‌سازی TANSIG برای لایه‌ها، ۷ نرون در لایه مخفی اول و ۷ نرون در لایه مخفی دوم است. با توجه به نتایج به دست آمده می‌توان

مراجع

- Aguerre, R., Suarez, C. and Viollaz, P. E. 1986. Effect of drying on the quality of milled rice. *J. Food Tech.* 21, 75-80.
- Ancheta, C. J. and Andales, S. C. 1990. Total milled and head rice recoveries of paddy as influenced by its physico-varietal characteristics. *AMA.* 21, 34-39.
- Anon. 2004. Moisture Measurement-Unground Grain and Seeds. ASAE Standard S352.2 47th Ed. ST. Joseph. MI: USA.
- Bandyopadhyay, S. and Roy, N. C. 1992. Rice Process Technology. Oxford and IBH Pub. Co. New Delhi. India.
- Bonazzi, C., Du Peuty, M. A. and Themelin, A. 1997. Influence of drying conditions on the processing quality of rough rice. *Drying Tech.* 15 (3,4): 1141-1157.
- Brooker, D. B., Bakker-Arkema F. W. and Hall C. W. 1992. Drying and Storage of Grain and Oilseeds. Van Nostrand Reinhold. N. Y.
- Chen, H., Siebenmorgen, T. J. and Marks, B. P. 1997. Relating drying rate constant to reduction of long-grain head-rice yield. *Trans. ASAE.* 40(4): 1132-1139.
- Dayhoff, J. E. 1990. Neural Networks Principles. Prentice-Hall International. USA.
- Farkas, I., Remenyi, P. and Biro, A. 2000a. A neural network topology for modeling grain drying. *Computers Electronics Agric.* 26, 147-158.

- Farkas, I., Remenyi, P. and Biro, A. 2000b. Modeling aspects of grain drying with a neural network. *Computers Electronics Agric.* 29, 99-113.
- Girosi, F., Jones, M. and Poggio, T. 1995. Regularization theory and neural network architectures. *Neural Computing.* 7, 219-269.
- Hagan, M. T. and Menhaj, M. B. 1994. Training feed forward networks with the marquardt algorithm. *IEEE Trans. Neural Networks.* 5(6): 989-993.
- Hashemi Soleymani, S. J. 1997. Necessity of preparation and implementation of universal program in rice processing industrial. Research Report. 6th Symposium of Rice. Isfahan. Iran. (in Farsi)
- Islam, M. R., Sablani, S. S. and Mujumdar, A. S. 2003. An artificial neural network model for prediction of drying rates. *Drying Tech.* 21(9): 1867-1884.
- Juliano, B. O. 1993. Rice in Human Nutrition. Rome: Food and Nutrition Series. FAO. No. 26. International Rice Research Institute.
- Khanna, T. 1990. Foundations of Neural Networks. Addison-Wesley Pub. Co. USA.
- Khoshtaghaza, M. H. and Soleymani, M. 1999. Effect of drying parameters on rice fissuring. *Agric. Sci. J.* 5(20): 49-62. (in Farsi)
- Kunni, D. and Levenspiel, O. 1991. Fluidization Engineering. Stoneham-Butterworth Heineman. USA.
- Peyman, M. H., Tavakoli Hashjin, T. and Minaei, S. 2000. Determination of proper distance between plastic rollers of paddy huller for dehulling of three popular rice varieties in Gilan province. *Agric. Sci. J.* 5(20): 37-48. (in Farsi)
- Peuty, M. A., Themelin, A., Cruz, J. F., Arnand, G. and Fohr, J. P. 1994. Improvement of Paddy Quality by Optimization of Drying Conditions. In: Roudolph, V. and Keey, P. B. (Eds.). Drying.
- Sadeghi, M., Khoshtaghaza, M. H. and Khayyat, A. A. 2004. Principles of design and fabrication of laboratory vibration fluidized bed dryer for fluidization study of humid materials. *Amir-Kabir J. (Mechanical Engineering and Dependent Branches).* 15(58-b): 385-397. (in Farsi)
- Shariatmadar, H. 1997. Research Report of the 6th Symposium of Rice. Isfahan, Iran. (in Farsi)
- Teter, N. 1987. Paddy Drying Manual. Rome: Food and Nutrition Series. FAO. Italy.
- Zbicinski, I. and Ciesielski, K. 2000. Extension of the neural networks operating range by the application of dimensionless numbers in prediction of heat transfer coefficients. *Drying Tech.* 18(3): 649-660.

پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در ...

Zbicinski, I., Strumillo, P. and Kaminski, W. 1996. Hybrid neural model of thermal drying in a fluidized bed. Computers Chemical Eng. 20, 695-700.

Zhang, Q., Yang, S. X., Mittal, G. S. and Yi, S. 2002. Prediction of performance indices and optimal parameters of rough rice drying using neural network. Biosystems Eng. 83(3): 281-290.

Prediction of Head Rice Yield in Fixed Bed Drying Using Artificial Neural Networks

M. H. Khoshtaghaza*, R. Amiri Chayjan, Gh. Montazer and S. Minaei

* Corresponding Author: Associate Professor, Farm Machinery Department, Tarbiat Modares University, P. O. Box: 14115-139, Tehran, Iran. E-mail: khoshtag@modares.ac.ir

The objective of this research was the prediction of head rice yield (HRY) in fixed bed dryer by using artificial neural network approach. Several parameters affect on operation of fixed bed dryers that were considered as input variables for artificial neural network. These variables were: air relative humidity, air temperature, inlet air velocity, bed depth, initial moisture content, final moisture content and inlet air temperature. In total, 375 drying experiments were accomplished for creating of training and testing patterns by a laboratory dryer. Samples were separated from various depths of dryer and then dehulling and polishing operations were done by laboratory apparatuses. HRY was measured for all the depths and average of them was considered as HRY for each experiment. Feed forward neural network and cascade forward neural network with Levenberg-Marquardt and Bayesians regulation back propagation algorithm were used for training of presented patterns. Results showed that the feed forward back propagation algorithm with topology of 7-7-7-1 and Levenberg-Marquardt training algorithm and similar activation functions for all of the layers (Sigmoid Tangent) predicted the HRY with coefficient of determination 0.9655 and mean absolute error 0.019 at different conditions of fixed bed paddy drying method. Results showed that the input air temperature and final moisture content had the strongest effect on HRY.

Key words: Bayesian Regularization, Feed- Forward Back Propagation Network, Head Rice Yield, Levenberg-Marquardt, Rough Rice