

## تخمین ضریب تبدیل شلتوک با استفاده از شبکه‌های عصبی مصنوعی در خشک کردن بستر سیال

رضا امیری چایجان<sup>۱\*</sup>، محمدهادی خوش تقاضا<sup>۲</sup>، غلامعلی منتظر<sup>۳</sup>، سعید مینایی<sup>۲</sup> و محمدرضا علیزاده<sup>۴</sup>

(تاریخ دریافت: ۱۳۸۶/۱۱/۱۳؛ تاریخ پذیرش: ۱۳۸۸/۳/۲)

### چکیده

هدف از این پژوهش، برآورد ضریب تبدیل شلتوک به برنج سفید در خشک کردن بستر سیال به کمک شبکه‌های عصبی مصنوعی است. هفت عامل مؤثر در عملکرد خشک‌کن‌های بستر سیال به عنوان متغیرهای مستقل برای شبکه عصبی مصنوعی در نظر گرفته شد. 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 شلتوک. تعداد آزمایش برای ایجاد الگوهای آموزش و ارزیابی به وسیله یک خشک‌کن آزمایشگاهی انجام گردید. سپس نمونه‌هایی از محفظه خشک‌کن جدا و عملیات پوست‌کنی و سفید کردن با دستگاه‌های آزمایشگاهی انجام گرفت. ضریب تبدیل میانگین، به عنوان ضریب تبدیل آزمایش منظور شد. از شبکه‌ها و الگوریتم‌های یادگیری متعدد برای آموزش الگوهای موجود استفاده شد. نتایج بررسی‌ها نشان داد که شبکه پس‌انتشار پیشرو با توپولوژی ۱-۷-۱۳-۷ و الگوریتم آموزش لونیگ-مارکوارت و تابع آستانه تانزانیت سیگموئید قادر است راندمان تبدیل شلتوک را به برنج سفید با ضریب تعیین ۹۵/۴۸ درصد و خطای متوسط مطلق ۰/۰۱۹ در شرایط مختلف خشک کردن شلتوک در گستره بستر سیال پیش‌بینی نماید هم‌چنین نتایج نشان داد که دمای هوای ورودی و میزان رطوبت نهایی شلتوک، بیشترین تأثیر را بر ضریب تبدیل شلتوک به برنج سفید در خشک کردن بستر سیال دارند.

واژه‌های کلیدی: الگوریتم لونیگ-مارکوارت، شبکه پس‌انتشار پیشرو، شلتوک، ضریب تبدیل

### مقدمه

کاهش ضایعات تولید در فرایند فراوری آن را ایجاب می‌کند. از دیدگاه تجاری، اولویت مهم، افزایش ضریب تبدیل شلتوک به برنج سفید سالم است، از این رو بیشینه کردن مقدار آن به عنوان اولین اصل در صنایع تبدیلی برنج است. حصول این مهم،

برنج رتبه دوم غذای اصلی مردم ایران را بعد از گندم به خود اختصاص داده است. رشد جمعیت کشور و افزایش میزان مصرف برنج، ضرورت یافتن راه‌حلی برای افزایش تولید و

۱. استادیار ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان

۲. دانشیاران ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

۳. استادیار مهندسی فن آوری اطلاعات، دانشکده فنی مهندسی، دانشگاه تربیت مدرس، تهران

۴. استادیار پژوهشی مؤسسه تحقیقات برنج کشور، رشت

\*: مسئول مکاتبات، پست الکترونیکی: amirireza@basu.ac.ir

بستگی به وارپته و مدیریت محصول در مزرعه و عملیات پس از برداشت، به خصوص شرایط خشک کردن دارد (۲۹). شلتوک، پس از مرحله برداشت و خرمکوبی حاصل می شود. عملیات پس از برداشت شلتوک برای دستیابی به برنج سفید شامل خشک کردن، پوست کنی، سفید کردن و درجه بندی است که در هر یک از مراحل مذکور، ضایعات برنج قابل ملاحظه است و عدم کارایی مناسب و تنظیم صحیح دستگاه های مربوطه در هر یک از مراحل فوق امکان ایجاد ضایعات بیش از حد استاندارد را به وجود می آورد. خشک کردن شلتوک در بین مراحل پس از برداشت، نقش قابل توجهی در ایجاد و افزایش ضایعات دارد، زیرا عملکرد سایر مراحل متأثر از خشک کردن شلتوک خواهد بود. از این رو این بخش توجه محققان بسیاری را در دنیا به خود معطوف کرده است (۱۰).

محققان توصیه می کنند که برای ذخیره سازی شلتوک، رطوبت آن می بایست حدود ۱۳ درصد (پایه تر) باشد و برای انجام عملیات تبدیل نیز بهتر است رطوبت شلتوک (بسته به نوع رقم شلتوک) بین ۱۰ تا ۱۳ درصد (پایه تر) باشد (۳۳). راندمان برنج سفید سالم (نسبت برنج سفید سالم به شلتوک مصرفی) در استان های گیلان و مازندران به طور متوسط به ترتیب ۵۲/۳۳٪ و ۵۰٪ می باشد (۸).

خشک کن های رایج در دنیا که به صورت تجاری برای خشک کردن شلتوک استفاده می شود عبارت اند از خشک کن های بستر ثابت و خشک کن های بستر سیال (۸ و ۳۰). خشک کن های بستر ثابت در مقیاس گسترده ای در ایران برای خشک کردن شلتوک استفاده می شود. از معایب خشک کن های مذکور این است که پس از خشک کردن شلتوک، رطوبت لایه های مختلف آن متفاوت است و این عدم یکنواختی سبب بروز ضایعات در مرحله تبدیل شلتوک به برنج سفید می شود. استفاده از دماهای بالا نیز در این خشک کن ها به دلیل این که ایجاد اختلاف رطوبتی زیاد لایه ها و بیش خشک شدن لایه های زیرین عملاً امکان پذیر نیست. به دلیل این که امکان جابه جایی لایه های شلتوک در حین خشک کردن بستر ثابت وجود ندارد،

پذیرش ضایعات کیفی و کمی در استفاده از این خشک کن ها گریزناپذیر است هم چنین استفاده از عمق های زیاد نیز باعث تشدید ضایعات می شود (۸).

فناوری سیال سازی یکی از روش هایی است که به طور گسترده در خشک کردن مواد غذایی و کشاورزی استفاده می شود. روش بستر سیال به عنوان یک روش آرام و یکنواخت خشک شدن شناخته شده است که قابلیت کاهش رطوبت مواد را با بازده بالا دارد (۲۸). مشخصه این فرایند، به کارگیری موادی با میزان رطوبت بالا و کنترل حرارتی مناسب به علت اختلاط مواد است (۲۰). مزایای خشک کردن به روش بستر سیال عبارت است از الف) یکنواختی میزان رطوبت محصول، از اینرو با دمای زیاد می توان محصول را خشک نمود، بدون این که محصول بیش از اندازه خشک شود. ب) ظرفیت بالای خشک کردن به علت انتقال مناسب تر جرم و حرارت ج) به کارگیری مخزن خشک کن کوچک تر و در نتیجه صرف هزینه کمتر د) افزایش معنی دار ضریب تبدیل شلتوک به برنج سفید و قابلیت تولید برنج مطلوب (۹).

سیال سازی، پدیده ای است که به وسیله آن ذرات جامد در یک سیال معلق شده و شبیه سیال عمل می کند. هنگامی که یک سیال از میان ذرات یک بستر مواد به سمت بالا هدایت شود، در دبی پایین، یک بستر ثابت خواهیم داشت. با افزایش دبی جریان، به ترتیب بستر منبسط شده، بستر با شرایط حداقل سیال سازی، بستر سیال حبابی و انتقال هوایی مواد جامد را خواهیم داشت (۱۱ و ۲۴).

در شرایطی که روابط بین پارامترهای مستقل و وابسته پیچیده باشد، بهترین انتخاب، استفاده از روش های بهینه سازی هوشمند است. یکی از این روش ها، شبکه های عصبی مصنوعی (Artificial Neural Networks) است که یک روش غیرالگوریتمی بوده و اساس آن بر مبنای آموزش و یادگیری به کمک داده های موجود است (۱).

علی رغم مزایای زیاد روش های مدل سازی ریاضی، محدودیت هایی از قبیل انتخاب پارامترها، اعمال پیش فرض ها

زانگ و همکاران (۳۸) از شبکه‌های عصبی مصنوعی برای پیش بینی شاخصه های خشک کردن شلتوک از پارامترهای مؤثر در خشک کردن به روش بستر ثابت استفاده کردند و کوبیلوس و ریز (۱۴) برای پیش‌بینی میزان رطوبت خروجی در فرایند خشک کردن هویج از این روش بهره بردند. زیو و زیونگ (۳۵) نیز برای تسهیل و تسریع در پیش‌بینی خواص مکانیکی نخود پس از پختن آن، از شبکه‌های عصبی مصنوعی استفاده کردند.

بنابراین با توجه به ضرورت‌های بیان شده، اهداف این تحقیق عبارت است از: ایجاد ارتباط بین متغیرهای مستقل مؤثر در فرایند خشک کردن شلتوک به روش بستر سیال با ضریب تبدیل در شرایط آزمایشگاهی و یافتن شبکه عصبی با توپولوژی مناسب به منظور پیش‌بینی ضریب تبدیل شلتوک برنج سفید در خشک کردن به روش بستر سیال و سرانجام بررسی ترتیب اهمیت هر یک از متغیرهای ورودی بر ضریب تبدیل.

## مواد و روش‌ها

### انتخاب پارامترهای ورودی و خروجی

ضریب تبدیل شلتوک به برنج سفید (Head Rice Yield) به عنوان شاخص کیفی فرایند تولید برنج سفید به صورت زیر تعریف می‌شود (۱۳):

$$HRY = \frac{HR}{RW} \times 100 \quad [1]$$

HRY ضریب تبدیل شلتوک (درصد)، HR وزن برنج سفید سالم (g) و RW وزن شلتوک اولیه (g) است.

بررسی مطالعات گذشته نشان می‌دهد که عوامل متعددی در عملکرد خشک شدن شلتوک و ضریب تبدیل شلتوک به برنج سفید نقش تعیین‌کننده‌ای دارند. مهم‌ترین این عوامل عبارت است از: عمق بستر شلتوک (db)، دمای هوای محیط (Ta)، رطوبت نسبی هوای محیط (RHa)، دمای هوای ورودی به محفظه خشک‌کن (Tin)، میزان رطوبت اولیه شلتوک (MCin)، میزان رطوبت نهایی شلتوک (MCf)، سرعت هوای ورودی (Vin) (۶، ۹، ۱۳، ۲۵، ۳۱ و ۳۳). بنابراین:

برای حل معادلات دیفرانسیل و پیچیدگی حل معادلات سبب می‌شود استفاده از روش‌های ناپارامتری مانند شبکه‌های عصبی مصنوعی در حل مسائل خشک کردن توسعه پیدا کند، زیرا روش حل در شبکه‌های عصبی مصنوعی مبتنی بر ضرب ضرایب وزنی در قالب پردازش موازی است. از این رو سرعت دستیابی به جواب در این روش نسبت به روش‌های مدل‌سازی ریاضی بیشتر است. لذا برای اعمال سیستم کنترل، مناسب‌تر است. از سوی دیگر به علت توزیع اطلاعات در شبکه‌های عصبی مصنوعی، خطای ایجاد شده در اطلاعات ورودی تأثیر نامطلوب بر پردازش داده‌ها نخواهد داشت. همچنین با توجه به در نظر گرفتن پارامترهای کیفی و عدم امکان محاسبه آن با روش‌های مدل‌سازی ریاضی، روش شبکه‌های عصبی مصنوعی برای پیش‌بینی هم‌زمان پارامترهای خروجی مناسب است.

شبکه‌های عصبی مصنوعی به دلیل وفقی بودن، قابلیت اعتماد بیشتری نسبت به مدل‌های آماری دارند و قابلیت تعمیم و تقریب آنها بیشتر است. از سوی دیگر مدل‌های آماری قابلیت پذیرش تعداد زیاد متغیرهای ورودی را ندارند و با توجه به تعدد پارامترهای مؤثر در پارامترهای خشک کردن شلتوک، شبکه‌های عصبی مصنوعی برای پیش‌بینی پارامترها مناسب‌تر است.

فارکاس و همکاران (۱۸ و ۱۹) برای آزمون امکان پذیری پیش‌بینی توزیع رطوبت در یک خشک‌کن جو توسط شبکه‌های عصبی مصنوعی اقدام کردند و سپس برای یافتن بهترین شبکه عصبی مصنوعی برای پیش‌بینی آن تحقیق دیگری انجام دادند.

زیبسنسکی و همکاران (۳۷) برای مدل سازی فرایند تبخیر رطوبت در یک خشک‌کن بستر سیال از شبکه‌های عصبی مصنوعی استفاده کردند و زیبسنسکی و سیسیلسکی (۳۶) برای پیش‌بینی ضریب انتقال حرارت مواد مختلف و اسلام و همکاران (۲۳) برای پیش‌بینی نرخ خشک کردن قطعات سیب زمینی از روش شبکه‌های عصبی کمک گرفتند.

در این رابطه، M.C. درصد رطوبت نمونه‌ها بر پایه تر (%w.b.)،  $m_1$  جرم اولیه نمونه (kg)، و  $m_2$  جرم نهایی نمونه (kg) است. برای توزین نمونه‌ها از یک ترازوی دیجیتالی AND GF-600 ساخت کشور ژاپن با دقت  $0.01$  g و قدرت تشخیص  $0.01$  g استفاده شد. از اجاق آزمایشگاهی Memmert D06836 ساخت کشور آلمان استفاده شد، که دقت آن  $\pm 1^\circ\text{C}$  است.

از یک دستگاه پوست کن شلتوک برای انجام آزمایش‌ها استفاده شد. دستگاه مذکور دارای دو غلتک لاستیکی دوار است. این دستگاه بر اساس نمونه مشابه ساخت شرکت یانمار ژاپن مدل ST50 توسط پیمان و همکاران (۴) ساخته شده است. برای سفیدکردن نمونه‌های آزمایشی به منظور محاسبه ضریب تبدیل، از یک سفیدکن آزمایشگاهی ساخت شرکت KETT ژاپن مدل PEARLEST استفاده شد.

پس از خشک کردن شلتوک در محفظه خشک کن، اقدام به نمونه برداری از محل‌های مختلف محفظه خشک کن شد. مقدار نمونه برداشته شده از عمق‌های مختلف حدود  $70$  گرم است. مراحل کار برای انجام آزمایش‌های راندمان برنج سفید سالم عبارت است از:

الف) ابتدا از هر نمونه  $70$  گرمی یک نمونه  $10$  گرمی برای اندازه‌گیری رطوبت جدا گردید.

ب) نمونه‌های شلتوک توسط دستگاه بوجار تمیز شده و مواد زائد و دانه‌های پوک از آن جدا شد.

ج) سه نمونه  $15$  گرمی از نمونه‌های بوجاری شده جدا کرده و برای پوست‌کنی وارد دستگاه پوست‌کن شلتوک شد. بنابر توصیه شرکت سازنده، فاصله بین غلتک‌های دوار به میزان هفت دهم قطر متوسط شلتوک تنظیم شد.

د) مخلوط برنج قهوه‌ای و شلتوک جمع‌آوری شده از دستگاه پوست‌کن، توزین شده و وزن پوست جمع‌آوری شده نیز ثبت شد. دانه‌های شلتوک مخلوط با برنج قهوه‌ای، جدا شده و وزن برنج قهوه‌ای توزین شد.

ه) برنج قهوه‌ای حاصل از پوست‌کن را در مخزن دستگاه سفیدکن ریخته و عملیات سفیدکردن برنج انجام شد.

$$\text{HRY}(t) = f[d_b(t), T_a(t), \text{RH}_a(t), T_{in}(t), \text{MC}_{in}(t), \text{MC}_f(t), V_{in}(t)] \quad [2]$$

t, شماره‌الگوی آزمایشی است.

### خشک کن آزمایشگاهی

برای انجام آزمایش‌های بستر ثابت و سیال از خشک کن بستر سیال آزمایشگاهی که توسط صادقی و همکاران (۷) ساخته شده است، استفاده گردید (شکل ۱). این خشک کن مجهز به یک دمنده سانتریفیوژ با پره‌های عقبگرد و موتور متحرک سه‌فاز، قدرت  $2$  hp و دور  $2800$  rpm است. یک کوره حرارتی هوای گرم را تأمین می‌کند. محفظه خشک کن دارای سطح مقطع  $0.16 \times 0.16$  m<sup>2</sup> بوده و از جنس پلکسی گلاس شفاف است. این سیستم از چهار قسمت منبع تغذیه، مدار اصلی کنترل، مدار تقویت کننده حسگرها و مدار راه‌انداز رله تشکیل شده است. تغییر دور موتور سه‌فاز دمنده از طریق یک دستگاه تنظیم سرعت Topvert مدل 7300 L202 صورت می‌گیرد. حسگرهای دما و رطوبت نسبی، عملیات اندازه‌گیری دما و رطوبت نسبی هوای ورودی و خروجی و همچنین دمای بستر ذرات را انجام می‌دهند. سیستم کنترل به طور مستقیم به رایانه متصل است.

### آماده‌سازی نمونه‌ها

شلتوک پس از برداشت به وسیله کمباین برنج، در کیسه‌های پلاستیکی بزرگ قرار داده شد. برای جلوگیری از کاهش رطوبت شلتوک، در پلاستیک، محکم بسته شده و در دمای  $4^\circ\text{C}$  در سردخانه نگه‌داری شد. قبل از انجام آزمایش‌های خشک کردن، نمونه‌های شلتوک از یخچال خارج شد و به مدت حدود  $12$  ساعت در دمای اتاق (حدود  $20^\circ\text{C}$ ) به تعادل دمایی رسید. برای تعیین رطوبت شلتوک از نمونه‌های  $10$  گرمی استفاده شد که به مدت  $24$  ساعت در دمای  $130^\circ\text{C}$  در اجاق آزمایشگاهی قرار داده شد (۱۳). میزان رطوبت اولیه نمونه‌های شلتوک از رابطه زیر به دست می‌آید:

$$\text{M.C.} = \frac{m_1 - m_2}{m_1} \times 100 \quad [3]$$

پس از اندازه‌گیری میزان رطوبت اولیه نمونه‌های شلتوک، بیشترین مقدار آن حدود ۲۲ درصد پایه‌تر به دست آمد. در آزمایش‌های خشک‌کردن، کمترین میزان رطوبت نهایی حدود ۱۰ درصد پایه‌تر تعیین شده است و با توجه به این که محدوده رطوبتی مذکور برای انجام آزمایش‌های بستر سیال و بستر ثابت در نقطه حداقل سیال‌سازی ممکن است باعث ایجاد ناپایداری شود، بنابراین برای تعیین منحنی‌های مشخصه سیال‌سازی از مقدار متوسط محدوده مذکور (حدود ۱۶ درصد پایه‌تر) استفاده شد.

### طراحی روند آموزش (آزمایش‌ها) برای شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی به عنوان یکی از شاخه‌های هوش مصنوعی به دلیل دارا بودن ساختار پردازش موازی دارای سرعت پردازش بسیار بالایی هستند (۱۵). شبکه عصبی مصنوعی نوعی سیستم پردازش داده‌هاست که از تعداد زیادی پردازشگر ساده و مرتبط با هم به نام نرون تشکیل شده است و در ساختار آن از ساختمان مغز الهام گرفته شده است. شبکه‌های مذکور قادر به پردازش داده‌های پیوسته و گسسته زمانی از طریق تابع نگاشت غیرخطی هستند. در این تحقیق از داده‌های گسسته زمانی برای آموزش و آزمون شبکه‌های عصبی مصنوعی استفاده شده است. با فرض این که بردار پاسخ خروجی مطلوب  $d(x) = [d_1(x)d_2(x)...d_3(x)]$  باشد، قاعده یادگیری دلتای تعمیم یافته انجام به روش وفقی (Adaptive) وزن‌ها را تنظیم می‌کند. این قاعده فرایند بهینه‌سازی را برای هر یک از خطاهای خروجی انجام می‌دهد تا خطای بین خروجی مطلوب  $d(x)$  و خروجی شبکه عصبی  $y(k)$  را کمینه سازد. مقدار خطای بهنگام سازی وزن  $w$  در فرایند یادگیری عبارت است از:

$$E(w, x) = \sum_{i=1}^m e_i(d_i, x) = \sum_{i=1}^m D(d_i - y_i(x)) \quad [4]$$

که  $D(\cdot)$  بیانگر اندازه فاصله بین آمین خروجی مطلوب  $(d_i)$  و آمین خروجی شبکه عصبی مصنوعی  $(y_i(x))$  برای خروجی الگوی  $x$  است.  $E(w, x)$  خطای محاسبه وزن  $w$  برای الگوی

و- پس از خارج کردن نمونه‌های سفیدشده، برنج سفید سالم و شکسته به روش دستی جدا شده و وزن آن ثبت شد. دانه‌های شکسته برنج که معادل  $\frac{2}{3}$  برنج سالم بودند به عنوان برنج سالم منظور شد (۳۴).

برای اندازه‌گیری رطوبت نسبی هوای اتاق خشک‌کن از یک رطوبت‌سنج Lutron HT-3005 ساخت کشور تایوان استفاده شد. برای اندازه‌گیری دمای محیط از یک دماسنج دیجیتال Lutron TM-915 ساخت کشور تایوان با دقت  $(\pm 0.5\% + 1^\circ\text{C})$  و قدرت تشخیص  $0.1^\circ\text{C}$  استفاده شد.


به منظور اندازه‌گیری افت فشار ناشی از ستون بستر مواد در داخل محفظه خشک‌کن از یک فشارسنج دیجیتال Testo 505- P1 ساخت کشور آلمان استفاده شد. برای اندازه‌گیری دبی هوای خروجی از محفظه خشک‌کن، از یک سرعت‌سنج پره‌ای Lutron A-M-4202 ساخت کشور تایوان با دقت  $(\pm 0.2\% + 0.2 \text{ m/s})$  و قدرت تشخیص  $0.1^\circ\text{C}$  و محدوده عمل  $0.4-25 \text{ m/s}$  استفاده شد. برای اندازه‌گیری سرعت هوا، سنسور پره‌ای در خروجی محفظه ۷ در شکل ۱ نصب می‌شد.

### صفحه توزیع کننده


جریان هوا و چگونگی توزیع آن یک عامل مهم در خشک‌کردن به روش بستر سیال است. بدین منظور سرعت هوا باید یک‌نواخت باشد تا سیال‌سازی یک‌نواخت در هر نقطه بستر فراهم شود. طراحی مناسب صفحه توزیع‌کننده این نیاز را برآورده می‌سازد (۲۶). صفحه طراحی شده دارای سوراخ‌هایی به قطر ۳ mm و ضخامت ۱ mm است.

### روش انتخاب سرعت‌های هوای اعمال‌شده به بستر شلتوک

پس از انجام آزمایش‌های سیال‌سازی، منحنی‌های مشخصه سرعت هوا-افت فشار تحت شرایط مذکور سیال برای عمق‌های ۵، ۱۲/۵ و ۲۰ cm ترسیم شدند (شکل ۲). لازم به ذکر است آزمایش‌ها در شرایط بستر سیال و تا بیشترین دور دمنده (۲۸۰۰ rpm) انجام شد (جدول ۱).



شکل ۱. دستگاه خشک کن مورد استفاده: ۱- تابلو برق و اینورتر ۲- رایانه ۳- منبع تغذیه، مدار راه انداز رله ها و مدار تقویت کننده حسگرها ۴- دمنده ۵- مجرای عبور هوا ۶- کوره الکتریکی ۷- محفظه سیال سازی ۸- محفظه اختلاط ۹- ترازو



شکل ۲. منحنی مشخصه افت فشار- سرعت هوا برای شرایط بستر سیال در عمق های ۵ cm، ۱۲/۵ cm و ۲۰ cm (نقطه حد اقل سیال سازی = A)

جدول ۱. مقادیر سرعت انتخاب شده از منحنی های سرعت هوا- افت فشار برای انجام آزمایش های بستر سیال

پارامتر					عمق (m)
۷/۹	۷	۶/۶	۳/۱	۱/۵	۵
۲۸۰۰	۲۴۰۰	۲۰۰۰	۱۵۰۰	۱۱۰۰	سرعت هوا (m/s)
-	۷/۷	۷/۳	۵/۷	۲/۳	دور موتور (rpm)
-	۲۸۰۰	۲۴۰۰	۲۰۰۰	۱۶۰۰	سرعت هوا (m/s)
-	-	۶/۵	۴/۱	۱/۷	دور موتور (rpm)
-	-	۲۸۰۰	۲۴۰۰	۲۰۰۰	سرعت هوا (m/s)
-	-	-	-	-	دور موتور (rpm)

مانند تعداد لایه‌های پنهان، تعداد نرون‌ها، تعداد چرخه آموزش (Epoch)، در طی فرایند آموزش شبکه عصبی و به روش آزمون و خطا تعیین می‌شود.

به منظور پردازش داده‌های گوناگون برای کاربردهای مختلف از شبکه‌های متعدد استفاده شد که عبارت‌اند از:

الف) شبکه‌های پس انتشار پیشخور (Feed Forward Back Propagation) (FFBP): ساختار ایستایی (غیر وابسته به زمان) این شبکه در مسائل مهندسی و محاسبات علمی کاربرد دارد (۲۱). الگوریتم پس انتشار خطا روش اصلی برای بهنگام‌سازی وزن‌های شبکه FFBP برای انجام محاسبات است. ساختار عمومی شبکه پس انتشار پیشخور برای مسئله این تحقیق در شکل ۳ آمده است (۱۶).

$W(1), W(2), W(3), W(4)$  به ترتیب ماتریس‌های وزنی نرون‌های  $N(1, i), N(2, j), N(3, k), N(4, l)$  هستند.  $S_i^{(1)}, S_j^{(2)}, S_k^{(3)}, S_l^{(4)}$  به ترتیب جمع‌کننده‌های نرون‌های  $N(1, i), N(2, j), N(3, k), N(4, l)$  هستند. بنابراین معادلات نرون‌ها در لایه پنهان اول ( $N(2, j)$ ) شبکه به ترتیب زیر خواهد بود (۲۱):

$$\begin{cases} S_j^{(2)} = \sum_{q=0}^p w_{jq}^{(2)} \cdot x_q \\ Z_j = f(S_j^{(2)}) \\ j = 1, 2, \dots, p \end{cases} \quad [5]$$

شایان ذکر این که برای همه لایه‌های پنهان و لایه خروجی شبکه معادلات فوق حاکم است.  $f$  تابع آستانه غیرخطی است.  $Z_j$  خروجی نرون‌های لایه‌های پنهان و خروجی است.

ب) شبکه‌های پس انتشار پیشرو (Cascade Forward Back Propagation) (CFBP): این شبکه‌ها نیز مانند شبکه پس انتشار پیشخور از الگوریتم BP برای بهنگام‌سازی وزن‌ها استفاده می‌کند ولی خصوصیات اصلی شبکه مذکور این است که نرون‌های هر لایه به همه نرون‌های لایه‌های قبل متصل است (۱۶).


$x$  ام است. در شبکه‌های عصبی، حافظه شبکه در مقادیر پیوندهای موجود بین نرون‌ها و به شکل وزن‌های هر پیوند ذخیره می‌شود. در این فرایند، آموزش به معنای روند تغییر وزن‌ها تا حصول نتیجه مشخص (به دست آوردن خروجی مطلوب از شبکه) و یادگیری به معنای مرحله نهایی آموزش و تثبیت وزن‌های سیناپسی است (۱). در این روش آموزش، که با نظارت (Supervised) نام دارد، بخشی از الگوها برای آموزش به شبکه عرضه می‌شود، سپس خروجی شبکه، محاسبه شده و با داده‌های آزمایشگاهی مقایسه شده و در نهایت میزان خطای یادگیری محاسبه می‌شود. آموزش شبکه برای رسیدن به خروجی واقعی و کاهش خطای شبکه از طریق بهنگام‌سازی وزن‌های پیوندها انجام می‌شود.

موفقیت در مدل‌سازی شبکه عصبی مصنوعی به دو عامل بستگی دارد: تعداد داده‌ها و توزیع داده‌ها در محدوده انجام آزمایش‌ها (۱۶). طراحی آزمایش‌ها به منظور توزیع مناسب الگوها در محدوده مقادیر هفت متغیر مستقل انجام شد. طراحی آزمایش‌ها برای داده‌های آزمایشی در جدول ۲ برای شرایط بستر سیال نمایش داده شده است.

به منظور بررسی و ارزیابی شبکه‌های مختلف، پایگاه داده‌ای به دو قسمت تقسیم شد: آموزش (Training) و ارزیابی (Test). برای پیدا کردن بهترین پیش‌بینی، شبکه‌های مختلفی بر داده‌های مذکور اعمال شدند. شایان ذکر است که به منظور بررسی عملکرد تعمیم شبکه‌های به کار رفته، از الگوهای ارزیابی استفاده شد (۱۶). حدود ۲۵ درصد کل الگوها (۶۸ آزمایش) برای ارزیابی شبکه‌های آموزش دیده استفاده شد. از نرم‌افزار Neural Networks Toolbox MATLAB 7 (ver. 4.01) برای طراحی و ارزیابی شبکه‌های عصبی مصنوعی مختلف استفاده شد (۱۶). در طی فرایند آموزش، شبکه‌های عصبی مصنوعی به کمک داده‌های آموزشی، ارتباط بین نرون‌ها را در هر چرخه آموزش یاد می‌گیرند تا این که مقادیر پیش‌بینی شده به مقادیر خروجی مطلوب نزدیک شود و مقادیر خطای حاصل از مقادیر خطای مشخص شده کمتر گردد. پارامترهای ترکیبی

جدول ۲. محدوده در نظر گرفته شده برای متغیرهای مستقل در شرایط بستر سیال

سطوح	سرعت هوای ورودی (m/s)	رطوبت نهایی رطوبت (w.b.%)	رطوبت اولیه رطوبت (w.b.%)	دمای هوای ورودی (°C)	رطوبت نسبی هوای محیط (%)	دمای هوای محیط (°C)	عمق شلتوک (cm)
کمینه	۱/۴۷	۱۰	۱۴/۹	۴۰	۴۰	۲۰	۵
بیشینه	۷/۹	۱۴	۲۲	۷۰	۹۰	۳۰	۲۰
تعداد سطوح	۵	۳	-	۴	۶	۳	۳



شکل ۳. ساختار شبکه عصبی پسانتشار پیشخور مورد استفاده (b، بایاس است).

کمک الگوریتم‌های آموزشی، از معیار خطای مربعات میانگین (Mean Square Error) استفاده می‌شود که با رابطه ۶ تعریف می‌شود.  $E_{RMS}$  به عنوان معیار اولیه برای انتخاب معماری مناسب به شمار می‌رود (۲۱):

$$E_{RMS} = \sqrt{\frac{\sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2}{n_p \times n_o}} \quad [6]$$

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،  $n_p$  تعداد الگوها،  $n_o$  تعداد نرون‌های لایه خروجی،  $N$  تعداد نرون‌های خروجی و  $M$  تعداد

شبکه عصبی المان (Elman Network) (EN): این شبکه یکی از شبکه‌های بازگشتی است و جزء شبکه‌های پسانتشار سه‌لایه به شمار می‌رود که یک پیوند پس‌خوردی از خروجی لایه پنهان به ورودی آن دارد. این مسیر بازخوردی برای شبکه المان این امکان را فراهم می‌کند تا الگوهای موقتی را مانند الگوهای دائمی فرا گیرد (۱۷).

بررسی قابلیت تعمیم شبکه عصبی آموزش‌دیده، آخرین مرحله در توسعه مدل شبکه عصبی مصنوعی است. در این مرحله مدل‌های شبکه عصبی آموزش‌دیده به وسیله مجموعه داده‌های ارزیابی که مستقل از داده‌های آموزش است مورد آزمون قرار می‌گیرد. برای یافتن شبکه‌ای با معماری مناسب به



[۱۴] تابع تانژانت هایپربولیک سیگموئید

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

$X_j$ ، مجموع ورودی‌های وزن‌دار هر نرون لایه نام است و از رابطه زیر محاسبه می‌شود:

$$X_j = \sum_{i=1}^m W_{ij} \times Y_i + b_j \quad [15]$$

در این رابطه،  $m$  تعداد نرون‌های لایه خروجی،  $W_{ij}$  وزن بین لایه  $i$  و  $j$ ،  $Y_i$  خروجی نرون  $i$ ام و  $b_j$  مقدار بایاس نرون لایه نام است.

یک الگوریتم یادگیری، روشی برای تنظیم ضرایب وزنی (وزن‌ها و بایاس‌ها) شبکه است که تابع خطا را کمینه می‌سازد. الگوریتم‌های آموزش به کار رفته برای بهنگام‌سازی وزن‌های شبکه‌های مورد استفاده به اختصار بیان می‌شود (۵، ۱۵ و ۱۶):

الگوریتم لونبرگ-مارکوآرت (LM): الگوریتم‌های آموزشی که مبنای گرادیانی مانند الگوریتم پس‌انتشار خطا، در مقیاس گسترده‌ای توسط محققان استفاده می‌شود. این الگوریتم‌ها به دلیل این که گرادیان در روند حل مسأله از بین می‌روند، چندان مؤثر نیستند. الگوریتم‌هایی که بر مبنای ماتریس هسین (Hessian Matrix) هستند، به شبکه اجازه می‌دهند تا با دقت بیشتری الگوها را فرا بگیرند. در راستای دستیابی به جواب، فرایند آموزش به سرعت همگرا می‌شود، زیرا ماتریس هسین در طی حل مسأله از بین نمی‌رود. برای بهره‌گیری از نتایج مفید آموزش به روش ماتریس هسین، از الگوریتم لونبرگ-مارکوآرت (Levenberg-Marquardt) استفاده می‌شود.

الگوریتم تنظیم بی‌زی (BR): فرایند آموزش شبکه پس‌انتشار با الگوریتم تنظیم بی‌زی (Bayesian Regularization Backpropagation)، 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 شبکه، بهنگام‌سازی وزن‌های اولیه آغاز می‌شود تا توزیع ثانویه با استفاده از تنظیم بی‌زی حاصل

الگوهای آموزشی است. هدف آن است که میزان این خطا به کمترین مقدار ممکن برسد.

برای ارزیابی یادگیری شبکه‌های عصبی و حصول بهترین نتایج، از چندین معیار استفاده شد. مقادیر آماری برای ارزیابی قابلیت تعمیم عبارت‌اند از ضریب تعیین (Coefficient of Determination) ( $R^2$ )، خطای مطلق میانگین (Mean Absolute Error) ( $E_{ma}$ )، انحراف معیار خطای مطلق میانگین (Standard Deviation of Mean Absolute Error) ( $SD_{ma}$ )، خطای نسبی میانگین (Mean Relative Error) ( $E_{mr}$ ) و انحراف معیار خطای نسبی میانگین ( $SD_{mr}$ ) که به ترتیب از روابط زیر محاسبه می‌شوند:

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

$$E_{ma} = \frac{1}{n} \sum_{k=1}^n |S_k - T_k| \quad [8]$$

$$SD_{ma} = \sqrt{\frac{\sum_{k=1}^n (|S_k - T_k| - \overline{|S_k - T_k|})^2}{n-1}} \quad [9]$$

$$E_{mr} = \frac{1}{n} \sum_{k=1}^n \left| \frac{S_k - T_k}{T_k} \right| \quad [10]$$

$$SD_{mr} = \sqrt{\frac{\sum_{k=1}^n \left( \left| \frac{S_k - T_k}{T_k} \right| - \overline{\left| \frac{S_k - T_k}{T_k} \right|} \right)^2}{n-1}} \quad [11]$$

در این رابطه‌ها،  $S_k$  مقدار پیش‌بینی شده به وسیله شبکه عصبی مصنوعی برای الگوی  $k$ ام،  $T_k$  مقدار هدف (آزمایشی) برای الگوی  $k$ ام،  $T_m$  میانگین مقادیر پیش‌بینی شده و  $n$  تعداد الگوهای آموزشی است.

توابع آستانه (Threshold function) مختلفی برای یافتن حالت بهینه شبکه‌ها مورد ارزیابی قرار گرفت که عبارت‌اند از (۱۵ و ۱۶):

$$Y_j = \frac{1}{1 + \exp(-X_j)} \quad [12] \quad \text{تابع سیگموئید لگاریتمی}$$

$$Y_j = X_j \quad [13] \quad \text{تابع خطی}$$

## نتایج و بحث

ضریب تبدیل شلتوک در شرایط بستر سیال به کمک شبکه‌های پس انتشار پیشخور (FFBP)، پس انتشار پیشرو (CFBP) و آلمان (EN) الگوریتم‌های یادگیری و توپولوژی‌های مختلف بررسی شد.

کاربرد الگوریتم LM به همراه شبکه‌های CFBP و FFBP نشان داد که توپولوژی ۷-۱۳-۷-۱ در شبکه FFBP دارای کمترین خطای آموزشی (۰/۰۰۰۱۸) است (شکل ۴ و جدول ۳). خطای مطلق میانگین شبکه مذکور ۰/۰۲۳ و خطای نسبی میانگین آن ۵/۳۲ درصد است.

کاربرد الگوریتم یادگیری BR و شبکه‌های CFBP و FFBP نشان می‌دهد که بکارگیری این ترکیب‌ها نتایج ضعیف‌تری نسبت به الگوریتم LM دارد زیرا خطاهای مطلق میانگین و نسبی میانگین بیشتری دارد. بهترین نتیجه مربوط به الگوریتم یادگیری BR و شبکه یادگیری FFBP و توپولوژی ۷-۷-۷-۱ است که با تابع آستانه LOGSIG حاصل می‌شود که خطای مطلق میانگین ۰/۰۲۵ و خطای نسبی میانگین ۸/۹۵ درصد ارائه می‌دهد (جدول ۴).

شبکه EN نیز برای پیش‌بینی مقدار HRY استفاده شد، مقادیر خطای آموزش شبکه EN با الگوریتم یادگیری LM نشان داد که بهترین نتیجه، مربوط به توپولوژی ۷-۱۱-۷-۱ با خطای آموزش ۰/۰۰۰۲۴ است. این شبکه خطای مطلق میانگین ۰/۰۲۹ و خطای نسبی میانگین ۸/۳۵ درصد تولید کرد (جدول ۵). به کارگیری الگوریتم BR با شبکه EN نتیجه‌ای ضعیف‌تر از الگوریتم LM با شبکه مذکور در بر دارد، زیرا مقدار خطاهای آموزش و مطلق میانگین آن بیشتر از مقادیر مشابه برای الگوریتم LM است (جدول ۶).

با توجه به آزمایش شبکه‌های مختلف و بررسی نتایج آن می‌توان دریافت که به کارگیری الگوریتم یادگیری LM، تابع آستانه LOGSIG در شبکه FFBP با توپولوژی ۷-۱۳-۷-۱ واجد بهترین نتیجه از نظر معیارهای در نظر گرفته شده است. چگونگی یادگیری این شبکه در شکل ۵ نشان داده شده است.

شود. از آنجایی که داده‌های بکاررفته ممکن است با مقدار زیادی خطا همراه باشند، روش‌های مؤثری برای بهبود عملکرد تعمیم ضروری خواهد بود. از این رو روش تنظیم بیزی که شامل تنظیم پیچیدگی شبکه و اصلاح تابع عملکرد است، مناسب می‌باشد. در این الگوریتم به جای مجموع مربعات خطا (SSE) از مجموعه آموزشی، یک تابع هدف که شامل SSE و یک تابع جریمه است به طور خودکار تنظیم می‌شود.

به منظور تعیین پارامترهای شبکه از روش تغییر پویای تعداد نرون‌ها برای انتخاب ساختار مناسب شبکه‌های عصبی مصنوعی در طی فرایند یادگیری استفاده شده است (۲۲). در این روش، ابتدا از تعداد کم و منطقی واحدهای پنهان برای یادگیری استفاده می‌شود. هنگامی که یک منحنی یادگیری در کمینه محلی گرفتار شد، واحدهای جدید اضافه می‌شود. در این صورت فرایند یادگیری به علت تغییر در شکل فضای وزن پیشرفت می‌کند. مزیت‌های روش افزایش پویای نرون‌های جدید عبارت است از: الف) پیچیده‌شدن تدریجی محاسبات به دلیل افزایش تدریجی واحدهای پردازش، ب) به دست آوردن اندازه مناسب شبکه با تنظیم تدریجی واحدهای پردازش و ج) پایش و ارزیابی کمینه محلی در طی یادگیری.


برای هنجارسازی (Normalization) الگوها از رابطه زیر استفاده شده است (۲۱):

$$X_n = \frac{X(B_U - B_L) + X_{\max} B_L - X_{\min} B_U}{X_{\max} - X_{\min}} \quad [16]$$

در این رابطه،  $X_{\min}$  و  $X_{\max}$  به ترتیب مقادیر کمینه و بیشینه داده‌ها،  $X$  داده‌های آزمایشی،  $X_n$  مقدار نرمال‌شده،  $B_L$  و  $B_U$  به ترتیب محدوده‌های پایینی و بالایی داده‌ها است. محدوده‌های هنجارسازی [۰، ۱] و [-۱، ۱] اعمال شد. تعداد ۲۷۴ آزمایش برای خشک کردن بستر سیال انجام شد. حدود ۷۵ درصد الگوها برای آموزش و بقیه برای آزمون شبکه‌های آموزش دیده به کار رفت.



الف) شبکه FFBP



ب) شبکه CFBP

شکل ۴. مقادیر MSE برای الگوریتم یادگیری LM و برخی از توپولوژی‌های شبکه‌های FFBP و CFBP

جدول ۳. نتیجه حاصل از به کارگیری الگوریتم یادگیری LM، تابع آستانه LOGSIG در شبکه CFBP با توپولوژی ۷-۱۳-۷-۱

چرخه آموزش	$SD_{mr}$	$E_{mr}$	$SD_{ma}$	$E_{ma}$	$R^2$	MSE
۱۹	۷/۳۱	۵/۳۲	۰/۰۲۳	۰/۰۱۹	۰/۹۵۴۸	۰/۰۰۰۱۸

جدول ۴. نتیجه حاصل از به کارگیری الگوریتم یادگیری BR، تابع آستانه LOGSIG در شبکه FFBP با توپولوژی ۷-۷-۷-۱


چرخه آموزش	$SD_{mr}$	$E_{mr}$	$SD_{ma}$	$E_{ma}$	$R^2$	SSE
۲۵	۱۰/۲۱	۸/۹۵	۰/۰۳۲	۰/۰۲۵	۰/۹۳۳۱	۰/۰۹۵

جدول ۵. نتیجه حاصل از به کارگیری الگوریتم یادگیری LM، تابع آستانه LOGSIG در شبکه EN با توپولوژی ۷-۱۱-۷-۱


چرخه آموزش	$SD_{mr}$	$E_{mr}$	$SD_{ma}$	$E_{ma}$	$R^2$	MSE
۲۳	۱۱/۲۲	۸/۳۵	۰/۰۲۹	۰/۰۲۶	۰/۹۲۲۵	۰/۰۰۰۲۴

جدول ۶. نتیجه حاصل از به کارگیری الگوریتم یادگیری BR، تابع آستانه TANSIG در شبکه EN با توپولوژی ۷-۱۰-۷-۱

چرخه آموزش	$SD_{mr}$	$E_{mr}$	$SD_{ma}$	$E_{ma}$	$R^2$	SSE
۲۳	۱۲/۲۸	۱۱/۲۵	۰/۰۳۱	۰/۰۲۹	۰/۸۹۲۳	۰/۲۶۷۰



شکل ۵. چگونگی یادگیری شبکه CFBP، الگوریتم یادگیری LM، تابع آستانه LOGSIG با توپولوژی ۱-۷-۱۳-۷



شکل ۶. خطای واقعی یادگیری شبکه CFBP، الگوریتم یادگیری LM، تابع آستانه LOGSIG با توپولوژی ۱-۷-۱۳-۷

جدول ۷. نتیجه حاصل از اعمال نویز در به کارگیری الگوریتم یادگیری LM، تابع آستانه LOGSIG در

شبکه CFBP با توپولوژی ۱-۷-۱۳-۷

چرخه آموزش	$SD_{mr}$	$E_{mr}$	$SD_{ma}$	$E_{ma}$	$R^2$	MSE
۱۹	۱۰/۰۲	۸/۳۶	۰/۰۲۹	۰/۰۲۵	۰/۹۲۳۹	۰/۰۰۰۲۳

به منظور بررسی اهمیت متغیرهای ورودی خشک‌کن بر مقدار HRY، به طور متوالی اقدام به حذف متغیرها شد، نتایج در جدول ۸ نشان داده شده است. از نتایج می‌توان دریافت که دمای ورودی و میزان رطوبت نهایی به خشک‌کن بیشترین تأثیر را بر مقدار HRY در شرایط بستر سیال دارد. متغیرهای رطوبت نسبی هوای محیط و دمای هوای محیط کمترین تأثیر را بر HRY در شرایط بستر سیال دارند. میزان رطوبت اولیه، سرعت هوای ورودی و عمق شلتوک نیز تأثیر قابل توجهی

چگونگی روند یادگیری الگوهای آموزشی و ارزیابی، بیانگر یادگیری مناسب شبکه است. عدم نوسان ناگهانی، دلیل بر عدم وراموزی و فقدان الگوهای نامناسب در میان الگوهاست (شکل ۶). افزودن نویز به الگوهای آموزشی به منظور پایداری شبکه و بررسی میزان تأثیر متغیرهای ورودی بر HRY انجام شد. بدین منظور نویزی تصادفی با دامنه‌ای برابر با  $\pm 10\%$  درصد دامنه الگوی ورودی به آنها افزوده شد که نتیجه آن در جدول ۷ نشان داده شده است.

جدول ۸. نتیجه حاصل از حذف پارامترهای ورودی در به کارگیری الگوریتم یادگیری LM، تابع آستانه LOGSIG در شبکه CFBP با توپولوژی ۱-۷-۱۳-۷

پارامتر حذف شده	MSE	R <sup>2</sup>	E <sub>ma</sub>	SD <sub>ma</sub>	E <sub>mr</sub>	SD <sub>mr</sub>	چرخه آموزش
RH <sub>a</sub>	۰/۰۰۰۰۲۶	۰/۹۳۱۱	۰/۰۲۲	۰/۰۲۳	۷/۷۲	۹/۴۲	۱۲
T <sub>a</sub>	۰/۰۰۰۰۲۵	۰/۹۲۹۳	۰/۰۲۱	۰/۰۲۵	۸/۵۵	۱۰/۱۷	۱۵
MC <sub>in</sub>	۰/۰۰۰۰۵۸	۰/۴۵۳۹	۰/۰۴۱	۰/۰۳۵	۱۴/۹۳	۱۶/۹۸	۱۳
MC <sub>f</sub>	۰/۰۰۰۰۹۸	۰/۳۱۲۰	۰/۰۵۵	۰/۰۵۹	۲۰/۰۵	۲۶/۳۳	۱۹
V <sub>in</sub>	۰/۰۰۰۰۴۹	۰/۵۱۰۹	۰/۰۴۴	۰/۰۴۰	۱۵/۰۱	۱۸/۳۷	۱۶
d <sub>b</sub>	۰/۰۰۰۰۳۳	۰/۸۵۸۴	۰/۰۲۹	۰/۰۲۵	۱۰/۹۷	۱۳/۳۴	۱۱
T <sub>in</sub>	۰/۰۰۰۰۷۵	۰/۱۷۳۰	۰/۰۵۸	۰/۰۵۷	۲۴/۴۷	۲۶/۰۹	۱۸

نهایی شلتوک استفاده شده است لذا نتایج آن با نتایج محققان دیگر متفاوت است. میزان رطوبت نهایی مناسب برای خشک کردن بستر سیال توسط محققان حدود (۱۸ %w.b.) ذکر شده است که در خشک‌کن دو مرحله‌ای استفاده می‌شد (۲۷، ۳۰ و ۳۲). دمای اعمال شده نیز توسط محققان فوق ۹۰ تا ۱۲۰ °C توصیه شده است. در این شرایط HRY کاهش نمی‌یابد.

بر مقدار HRY دارند، به طوری که حذف آنها بر یادگیری شبکه تأثیر نامطلوب گذاشته است. با توجه به نتایج حاصل از بستر سیال می‌توان دریافت که اثر دمای هوای ورودی از اثر میزان رطوبت نهایی محصول در شرایط بستر سیال بیشتر است. سوپرنوناریت (۳۰) بر اهمیت دمای ورودی و میزان رطوبت نهایی در خشک‌کردن بستر سیال تأکید کرده است. در تحقیق حاضر از روش بستر سیال به عنوان روش خشک‌کردن

### منابع مورد استفاده

۱. البرزی، م. ۱۳۸۰. آشنایی با شبکه‌های عصبی (تالیف بیل و جکسون). چاپ اول، انتشارات دانشگاه صنعتی شریف، تهران.
۲. امیری چایجان، ر.، م. ه. خوش تقاضا و م. ح. کیانمهر. ۱۳۸۳. اصول طراحی خشک‌کن بستر سیال آزمایشگاهی برای برخی محصولات دانه‌ای زراعی. مجله تحقیقات مهندسی کشاورزی ۲۰(۵): ۳۵-۵۲.
۳. پهلوان زاده، ح. ۱۳۷۷. خشک کردن - اصول، کاربرد و طراحی (تالیف استرامیلو و کودرا). چاپ اول، انتشارات دانشگاه تربیت مدرس، تهران.
۴. پیمان، م. ح.، ت. توکلی هاشجین و س. مینایی. ۱۳۷۹. تعیین فاصله مناسب بین غلطک‌ها در پوست‌کن غلطک لاستیکی برای تبدیل سه رقم برنج متداول در استان گیلان. مجله علمی پژوهشی علوم کشاورزی ۲۰(۵): ۳۷-۴۸.
۵. غضنفری، م. و ز. کاظمی. ۱۳۸۲. اصول و مبانی سیستم‌های خبره - با فصولی درباره شبکه‌های عصبی مصنوعی و تئوری مجموعه‌های فازی. چاپ اول، دانشگاه علم و صنعت ایران، تهران.
۶. کیانمهر، م. ۱۳۸۰. بررسی عوامل مؤثر فیزیکی در ترک‌خوردگی شلتوک در خشک‌کن با جریان معکوس‌شونده هوا. رساله دکتری مهندسی مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران.
۷. صادقی، م. ۱۳۸۳. بررسی تأثیر ارتعاش بر عملکرد خشک‌کن‌های بستر سیال برای خشک‌کردن چای. رساله دکتری مهندسی

مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران.

۸. هاشمی سلیمانی، س. ۱۳۷۶. ضرورت تهیه و اجرای برنامه جامع در صنایع تبدیلی برنج. گزارش کار ششمین گردهمایی برنج کشور در اصفهان، انتشارات اداره کل آمار وزارت کشاورزی، ۱۳۵-۱۲۵.
9. Ancheta, C. J. and S. C. Andales. 1990. Total milled and head rice recoveries of paddy as influenced by its physico-variety characteristics. *Agric. Mechaniz. in Asia, Afr. and Latin Amer. (AMA)* 21: 34-39.
10. Bandyopadhyay, S. and N. C. Roy. 1992. *Rice Process Technology*. Oxford and IBH Pub. Co. New Delhi, India.
11. Brooker, D. B., F. W. Bakker-Arkema and C. W. Hall. 1992. *Drying and Storage of Grain and Oilseeds*. Van Nostrand Reinhold. N. Y.
12. Chakraverty, A. 1988. *Post Harvest Technology of Cereal, Pulses and Oilseeds*. Oxford and IBH Pub. Co, New Delhi.
13. Chen, H., T. J. Siebenmorgen and B. P. Marks. 1997. Relating drying rate constant to reduction of long-grain head-rice yield. *Trans. ASAE* 40(4): 1132-1139.
14. Cubillos, F. and A. Reyes. 2003. Drying of Carrots in a fluidized bed. II. Design of a model based on a modular neural network approach. *Drying Technol.* 21(7): 1185-1196.
15. Dayhoff, J. E. 1990. *Neural Networks Principles*. Prentice-Hall International, USA.
16. Demuth, H. and M. Beale. 2003. *Neural Network Toolbox for Matlab- Users Guide Version 4.1*. The Mathworks Inc., USA.
17. Elman, J. L. 1990. Finding structure in time. *Cognitive Sci.* 14:179-211.
18. Farkas, I., P. Remenyi and A. Biro. 2000. A neural network topology for modeling grain drying. *Comput. Electronics Agric.* 26: 147-158.
19. Farkas, I., P. Remenyi and A. Biro. 2000. Modeling aspects of grain drying with a neural network. *Comput. Electronics Agric.* 29: 99-113.
20. Giner, S. A. and A. Calvelo. 1987. Modeling wheat drying in fluidized bed. *J. Food Sci.* 52(5): 1358-1363.
21. Heristev, R. M. 1998. The ANN Book. GNU Public License. Available on (<ftp://ftp.funet.fi/pub/sci/neural/books/>).
22. Hirose, Y., K. Yamashita and S. Hijiya. 1991. Back-propagation algorithm which varies number of hidden units. *Neural Networks* 4: 61-66.
23. Islam, M. R., S. S. Sablani and A. S. Mujumdar. 2003. An artificial neural network model for prediction of drying rates. *Drying Technol.* 21(9): 1867-1884.
24. Kunni, D. and O. Levenspiel. 1991. *Fluidization Engineering*. Stoneham-Butterworth Heineman, USA.
25. Mossman, A. P. 1986. A review of basic concept in rice drying research. *Food Sci. and Nutr.* 25(1): 49-70.
26. Parikh, D. M. 1991. Air flow in batch fluid-bed processing. *Pharmaceutical Technol.* 31:100-110.
27. Poomsa-ad, N., S. Soponronnarit, S. Prachayawarakorn and A. Terdyothin. 2002. Effect of tempering on subsequent drying of paddy using fluidization technique. *Drying Technol.* 20(1): 195-210.
28. Shilton, N. C. and K. Neranjan. 1993. Fluidization and its applications to food processing. *Food Structure* 12: 199-215.
29. Siebenmorgen, T. J. 1992. Relating moisture transfer rate in rice to kernel quality. *Drying* 92A:58-71.
30. Soponronnarit, S. 1999. Fluidized bed paddy drying. *Sci. Asia* 25:51-56.
31. Sun, Z. H. and T. Siebenmorgen. 1993. Milling characteristics of various rough rice kernel thickness fractions. *Cereal Chem.* 70(6): 727-733.
32. Sutherland, J. W. and T. F. Gholy. 1990. Rapid fluid bed drying of paddy rice in the humid tropics. *Proc. of ASEAN Seminar on Post harvest Technology, Brunei Darussalam*, Pages. 19-30.
33. Teter, N. 1987. *Paddy Drying Manual*. Rome: Food and Nutrition Series (FAO), Italy.
34. USDA. 1979. *Inspection Handbook for the Sampling, Inspection, Grading and Certification of Rice*. HB 918-11. Washington DC. Agricultural Marketing Service.
35. Xie, G. and R. Xiong. 1999. Use of hyperbolic and neural network models in modeling quality changes of dry peas in long time cooking. *J. Food Eng.* 41: 151-162.
36. Zbicinski, I. and K. Ciesielski. 2000. Extension of the neural networks operating range by the application of dimensionless numbers in prediction of heat transfer coefficients. *Drying Technol.* 18(3): 649-660.
37. Zbicinski, I., P. Strumillo and W. Kaminski. 1996. Hybrid neural model of thermal drying in a fluidized bed. *Computers Chem. Eng.* 20: 695-700.
38. Zhang, Q., S. X. Yang, G. S. Mittal and S. Yi. 2002. Prediction of performance indices and optimal parameters of rough rice drying using neural network. *Biosys. Eng.* 83(3): 281-290.