

پیش‌بینی عملکرد فرایندهای تولیدی با استفاده از رگرسیون لجستیک و شبکه عصبی مصنوعی (مورد کاوی: فرایند افشانه‌ی خشک‌کننده کاشی سرامیکی)

نجمه نشاط (دانشجوی کارشناسی ارشد)

هاشم محلوچی (استاد)

دانشکده‌ی مهندسی صنایع، دانشگاه صنعتی شریف

در این نوشتار با ارائه‌ی نمونه‌ی عملی فرایند «افشانه‌ی خشک‌کننده»^۱، مدل‌سازی فرایندها با استفاده از مدل‌های رگرسیون لجستیک و الگوریتم شبکه‌ی عصبی مصنوعی با هدف پیش‌بینی (برون‌یابی و درون‌یابی) عملکرد فرایند به کار گرفته می‌شود. به منظور مقایسه‌ی قدرت هرکدام از این دو مدل در پیش‌بینی عملکرد فرایند، شاخص‌های ارزیابی پایایی مدل، شامل ضرایب تعیین مدل و درصد صحت پیش‌بینی، محاسبه و تحلیل می‌شوند. استفاده از شبکه‌ی عصبی مصنوعی در این نوشتار، به منظور معماری مدل شبکه‌ی عصبی فرایند «افشانه‌ی خشک‌کننده» با اتخاذ یک رویکرد عمومی و انتخاب الگوریتم پس‌انتشار خطا به کمک داده‌های مستقیم صورت می‌گیرد. پس از حصول اطمینان از برتری مدل شبکه‌ی عصبی فرایند نسبت به مدل لجستیک آن و با توجه به نتایج ارزیابی پایایی، سناریوهای مختلفی برای تنظیم ورودی‌های با توجه به عملکرد پیش‌بینی شده توسط مدل شبکه‌ی عصبی فرایند طراحی می‌شود که با استفاده از آن می‌توان کنترل پیش‌بینانه‌ی عملکرد فرایند را جایگزین روش‌های مبتنی بر سعی و خطا برای کنترل عملکرد فرایند کرد.

واژگان کلیدی: پیش‌بینی عملکرد، شبکه‌ی عصبی مصنوعی، مدل‌سازی، رگرسیون لجستیک، افشانه‌ی خشک‌کننده (اسپری درآینگ).

najmeh_neshaat@yahoo.com
mahlooji@sharif.edu

مقدمه

بر سیستم، با توجه به مقدار رگرسور ارائه‌شده نسبت به پیش‌بینی مقادیر پاسخ اقدام می‌کنند.

در مقام مقایسه، هر کدام از این روش‌ها در مدل‌سازی فرایندهای تولیدی از ویژگی‌های منحصر به فردی برخوردارند به طوری که روش‌های کلاسیک (از جمله رگرسیون) قادر به معرفی متغیرهای مؤثر بر فرایند (با تکیه بر تحلیل‌های آماری) است و با توجه به پارامترهای حاصل از این مدل‌ها، کاربران می‌توانند به تفسیر و استنتاج ابعاد مسئله بپردازند.^[۱] روش‌های فراابتکاری همچون شبکه‌ی عصبی مصنوعی (ANNs) نیز برای دست‌یابی به جواب بهینه، خصوصیات برجسته‌ی در مدل‌سازی فرایندهای تولیدی دارند: قابلیت اطمینان بالا در حذف و تشخیص نوسانات غیر تصادفی در داده‌ها،^[۲] توانایی کشف اثرات متقابل بین متغیرها،^[۳] صرفه‌جویی قابل توجه در هزینه‌ها، فراغت از مفروضات و قیود دست و پاگیر مدل‌های کلاسیک^[۴] و توانایی کاهش تأثیر متغیرهای غیرمؤثر بر مدل از طریق تنظیم پارامترهای داخلی.^[۵] یکی از نخستین مطالعات انجام‌شده در زمینه‌ی مدل‌سازی فرایندهای تولیدی، نوشتاری است که در سال ۱۹۸۶ میلادی توسط مهرتو^[۶] نوشته شد. در این نوشتار، فرایند تولید کاشی سرامیکی از طریق تشریح روابط بین متغیرها در قالب معادلات ریاضی مدل‌سازی شد. نکته‌ی قابل توجه در مورد این مدل ریاضی، عدم

لازمه‌ی پیش‌بینی عملکرد در هر فرایند، کشف رابطه بین عواملی است که بر عملکرد فرایند تأثیر می‌گذارند. شیوه‌های کشف این رابطه یا مدل‌سازی از فرایند را می‌توان در قالب دو گروه کلی بیان کرد: ۱. روش‌های کلاسیک که سعی در ارائه‌ی یک معادله‌ی ریاضی از رابطه‌ی بین متغیرهای پیش‌گو و متغیر پاسخ داشته و غالباً محدود به خطی فرض کردن رابطه بین این دو دسته متغیرند؛ از آن جمله می‌توان به تکنیک رگرسیون خطی چندگانه (MLR)، متدولوژی سطح پاسخ (RMS)، رگرسیون اجزای اصلی (PCR) و روش حداقل مربعات جزئی (PLS) اشاره کرد. یادآور می‌شود که هرکدام از این روش‌ها به اقتضای ماهیت متغیرها و هدف مسئله از مدل‌سازی و پیش‌بینی، گزینش و توسعه داده می‌شوند، مثلاً در مدل‌سازی مسائلی با متغیر پاسخ برنولی حالتی خاص از رگرسیون خطی چندگانه با عنوان رگرسیون لجستیک چندگانه توسعه داده می‌شود؛ ۲. روش‌های فراابتکاری مدل‌سازی و پیش‌بینی با الگوریتم‌های شبکه‌ی عصبی مصنوعی (ANNs)^[۷] که به صورت یک جعبه‌ی سیاه رابطه‌ی بین ورودی‌های و خروجی‌ها را بدون داشتن اجزاء و پارامترهای اصلی سیستم تویحاً مدل‌سازی می‌کنند و پس از یادگیری قوانین حاکم

تاریخ: دریافت ۱۳۸۷/۱۱/۲۹، اصلاحیه ۱۳۸۸/۹/۸، پذیرش ۱۳۸۸/۱۲/۴.


به دو روش کلاسیک رگرسیون لجستیک و روش فرایندکاری شبکه عصبی، مقایسه‌ی قدرت این دو مدل در پیش‌بینی (درون‌یابی و برون‌یابی) عملکرد فرایند به‌عنوان یک متغیر تصادفی برای نخستین بار است.

آشنایی با فرایند افشانه‌ی خشک‌کننده

فرایند «افشانه‌ی خشک‌کننده» یکی از مراحل تولید کاشی‌های سرامیکی است که در آن، دوغاب کاشی از طریق تجهیزات افشانه‌ی خشک‌کن به ریزدانه (گرانول) تبدیل می‌شود. به‌منظور تبدیل دوغاب به دانه‌های ریز لازم است دوغاب موجود در حوضچه‌ها با «چگالی» (ρ)، «گران‌روی» (ν) و دمای (T_s) مشخص، تحت «فشار پمپ» (P_p) به داخل محفظه‌ی افشانه‌ی خشک‌کن پاشیده شود. هم‌زمان با ورود دوغاب به داخل محفظه‌ی افشانه‌ی خشک‌کن، هوای داغ با دمای ورودی (T_{in}) به بالای محفظه تزریق می‌شود تا باعث جذب رطوبت دوغاب و تبدیل آن به دانه‌های ریز شود. در نهایت با ایجاد جریان‌ات گردابی در داخل محفظه از طریق اعمال «فشار مکش» (P_s)، ریزدانه‌ها از محفظه‌ی افشانه‌ی خشک‌کن خارج می‌شود. هوا و گرد و غبار موجود در داخل محفظه که دارای «دمای خروجی» (T_o) است، توسط سیستم جمع‌آوری چرخانه‌ها (سیکلون‌ها) از محفظه خارج می‌شود.^[۱۰] با توجه به نظر خبرگان فرایند، نمودار گسترده‌ی فرایند افشانه‌ی خشک‌کننده مطابق شکل ۱ رسم شده است. در جدول ۱ سعی شده است تا اطلاعات دقیقی‌تری از مشخصات متغیرهای قابل کنترل فرایند افشانه‌ی خشک‌کننده ارائه شود. تأثیر دمای محیطی (T) بر فرایند به‌عنوان متغیری غیرقابل کنترل، قابل چشم‌پوشی است. مطابق شکل ۱ متغیر خروجی دانه‌بندی (S_1) بیان‌گر وزن دانه‌های درشت (با قطر بیش از ۶۰۰ میکرون) در یک نمونه‌ی ۱۰۰ گرمی از دانه‌هاست. چنانچه مقدار متغیر خروجی دانه‌بندی کم‌تر از مقدار حدی «۶ گرم» باشد، بیان‌گر این مطلب است که قطر دانه‌ها در محدوده‌ی قابل قبول قرار دارند و عملکرد فرایند افشانه‌ی خشک‌کننده مورد تأیید است. بنابراین چنین رخدادی، یک آزمون برنولی است که کسب موفقیت ($6 \text{ gr} < \text{دانه‌بندی}$) در آن، به‌منزله‌ی مقدار «۱» یا به‌عبارتی تأیید عملکرد فرایند، و عدم موفقیت در آن به‌منزله‌ی «صفر» و به‌معنای عملکرد ناموفق فرایند افشانه‌ی خشک‌کننده است.

مراحل ایجاد مدل‌های لجستیک و شبکه‌ی عصبی فرایند

به‌منظور بررسی میزان پایایی^{۱۳} مدل‌های رگرسیونی و مدل شبکه‌ی عصبی در پیش‌بینی عملکرد فرایندهای تولیدی، ابتدا لازم است از طریق موردکاوی (فرایند افشانه‌ی خشک‌کننده) نسبت به تشریح و پیاده‌سازی مراحل مدل‌سازی فرایند اقدام شود. ساختار انتخابی برای مدل رگرسیونی فرایند افشانه‌ی خشک‌کننده با توجه به ماهیت اسمی متغیر پاسخ دانه‌بندی، مدل رگرسیونی لجستیک است که یکی از



شکل ۱. نمودار گسترده‌ی فرایند افشانه‌ی خشک‌کننده.

پویایی مدل به دلیل ثابت فرض کردن شرایط خاص تولید بود. برخی دیگر از محققین نیز سعی کردند تا با مدل‌سازی فرایند و به‌کارگیری شبکه‌ی پس‌انتشار خطا، نسبت به پیش‌بینی کیفیت فرایند جوشکاری در یک تجربه‌ی آزمایشگاهی اقدام کنند.^[۷] از دیگر مطالعات انجام‌شده در زمینه‌ی مدل‌سازی فرایند می‌توان به نوشتاری اشاره کرد که در سال ۱۹۹۱ با موضوع پیش‌بینی کیفیت فرایند شکل‌دهی لوله‌های PVC با استفاده از شبکه‌ی عصبی مصنوعی (ANNs) و تحلیل رگرسیونی انتشار یافت.^[۸] در این مطالعه، انتخاب اولیه‌ی متغیرهای پیشنهادی مدل شبکه‌ی عصبی مبتنی بر نتایج تحلیل ضرایب انفرادی مدل رگرسیونی بود. در مطالعه‌ی بعدی،^[۹] مدلی با هدف کاهش ضایعات در فرایند شکل‌دهی ارائه شد. در واقع، در این مطالعه از شبکه‌ی عصبی به‌عنوان ابزاری برای شناسایی و طبقه‌بندی الگو استفاده شد. اندکی بعد، محققین دیگری نیز با به‌کارگیری الگوریتم پس‌انتشار خطا نسبت به مدل‌سازی و پیش‌بینی فرایند شکل‌دهی چندمتغیره برای صنایع سرامیکی (چینی بهداشتی) اقدام کردند.^[۱۰] پس از آن مدل‌سازی و بهبود عملکرد کیفی با به‌کارگیری الگوریتم پس‌انتشار خطا (براساس قانون گردادیان نزولی) و اتخاذ رویکرد تاگوشی برای فرایند تولید نیمه‌هادی‌ها، مورد مطالعه قرار گرفت.^[۱۱] در سال ۲۰۰۰ میلادی یک سیستم پیوندی متشکل از شیوه‌های بهینه‌سازی الگوریتمی^۴، شبکه‌ی عصبی و منطق فازی^۵ در صنعت کاشی سرامیکی طراحی شد^[۱۲] که در آن، با به‌کارگیری پیش‌بینی عمده‌ی شبکه‌ی عصبی، تنظیمات قابل کنترل فرایند پیش‌بینی شده و سپس الگوریتم بهبود سیستم با توجه به نتایج پیش‌بینی شده، تابع هدف را بهینه‌سازی می‌کرد. اما در مدل شبکه‌ی عصبی که توسط کوک^۶ و همکارانش به‌منظور پیش‌گویی استحکام تخته‌های نئوپان طراحی شده بود،^[۱۳] پیش‌بینی کیفیت با استفاده از الگوریتم پس‌انتشار و بهینه‌سازی کیفیت با استفاده از الگوریتم ژنتیک انجام شد. در سال ۲۰۰۰ نیز فرایندهای شیمیایی با به‌کارگیری ANNs بهینه‌سازی شد^[۱۴] که در این مطالعه پس از پیش‌بینی کیفیت خروجی توسط شبکه‌ی عصبی، بهینه‌سازی پارامترهای شیمیایی با استفاده از روش برنامه‌ریزی غیر خطی^۷ صورت گرفت. سپس طی مطالعه‌ی توسط سوکدومیا^۸ و تانوک^۹ در سال ۲۰۰۵ به‌منظور مدل‌سازی فرایند تولید تیغه‌های مورد استفاده در پره هواپیما،^[۱۵] عوامل ورودی به مدل شبکه‌ی عصبی به‌روش سعی و خطا و با توجه به ضریب تعیین شبکه‌ها انتخاب شد. در مدل‌سازی فرایند لعاب‌زنی که با هدف بهینه‌سازی کیفیت خروجی رنگ لعاب انجام شد،^[۱۶] از شیوه‌ی طراحی آزمایش‌ها برای تحلیل ۳۲ مشاهده استفاده شد. در ادامه‌ی این فعالیت‌ها و در نوشتاری که براساس مطالعه‌ی تجربی توسط سنتورک^{۱۰} و ارگینل ارائه شد،^[۱۷] استفاده از سیستم استنتاج تطبیقی فازی عصبی (ANFIS)^{۱۱} ۶ لایه و آموزش آن با الگوریتم پس‌انتشار خطا، به‌منظور شناسایی سطوح عوامل از طریق به‌کارگیری روش طراحی آزمایش‌ها پیشنهاد شد. در یکی دیگر از مطالعات قابل توجه در این زمینه،^[۱۸] با استفاده از یک نرم‌افزاری عمده‌ی هوشمند نسبت به پیش‌گویی کیفیت فرایند تولید کاشی اقدام شده است. نزدیک‌ترین مطالعه به نوشتار حاضر، مطالعه‌ی است که در سال ۲۰۰۰ به‌منظور پیش‌بینی عملکرد برج‌های خنک‌کننده با استفاده از ANNs انجام شد.^[۳] در این مطالعه، شاخص عملکرد فرایند به‌عنوان مجموعه‌ی از مشخصه‌های کیفی فرایند -- از جمله دمای آب تبخیرشده در برج خنک‌کننده -- تعریف شده است. عوامل مهم و مؤثر بر درجه‌بندی کاشی‌های سرامیکی از نظر ظاهری، با استفاده از رگرسیون لجستیک^{۱۲} و طراحی آزمایش‌ها، طی یک مطالعه‌ی علمی در سال ۱۹۹۸ مورد شناسایی قرار گرفت.^[۱۹]

در تمامی مطالعات انجام‌شده‌ی پیشین، هدف از مدل‌سازی فرایند «پیش‌بینی مقدار خروجی فرایند» (برون‌یابی) یا «پیش‌بینی عملکرد فرایند» (درون‌یابی) است. اما در این نوشتار هدف از مدل‌سازی فرایند افشانه‌ی خشک‌کننده (افشانه‌ی خشک‌کننده)،

جدول ۱. مشخصات متغیرهای قابل کنترل فرایند افشانه‌ی خشک‌کننده.

نام متغیر	نوع متغیر	نماد اختصاری	محدوده‌ی نرمال تغییرات	دقت اندازه‌گیری
چگالی	ورودی	ρ	$1,64-1,68 \text{ gr cm}^{-3}$	$0,001 \text{ gr cm}^{-3}$
گرانروی	ورودی	ν	$43-102 \text{ S}$	1 S
دمای دوغاب	ورودی	T_s	$36-44^\circ \text{C}$	1°C
دمای ورودی	داخلی	\dot{T}_{in}	$54^\circ-55^\circ \text{C}$	1°C
فشار پمپ	داخلی	P_p	$14,5^\circ-17,5^\circ \text{ mbar}$	$0,1 \text{ mbar}$
فشار مکش	داخلی	P_s	$15-23 \text{ mbar}$	1 mbar
دمای خروجی	داخلی	\dot{T}_o	$93-103^\circ \text{C}$	1°C
دانه‌بندی	خروجی	S_1	$< 6 \text{ gr}$	1 gr

در مدل‌سازی با استفاده از ANNs لازم است داده‌های فراهم‌شده برای برازش مدل، نماینده‌ی جامعه‌ی باشد که از آن انتخاب شده‌اند (ارضای شرط یکپارچگی و کفایت). سه رویکرد متفاوت برای تهیه‌ی داده‌هایی برای برازش در مدل‌سازی شبکه‌ی عصبی عبارت‌اند از: روش مستقیم (پیکاربردترین روش برای مدل‌سازی فرایندهای تولیدی)، روش شبیه‌سازی، و روش طراحی آزمایش‌ها. یادآور می‌شود که به منظور افزایش کارایی مدل شبکه‌ی عصبی، پیش‌پردازش داده‌ها در دامنه‌ی مشخص پیش از ارائه‌ی آن‌ها به شبکه ضروری است.

گام ۳ انتخاب ساختار مدل: انتخاب ساختار در مدل‌سازی لجستیک از فرایند با توجه به ماهیت متغیر پاسخ (گم‌ی یا اسمی) مشخص می‌شود. ساختار عمومی رگرسیون برای مسائلی با متغیر پاسخ اسمی، رگرسیون لجستیک است. با این پیش فرض که Y متغیر پاسخ و $X_j (j = 1, 2, \dots, p)$ متغیرهای رگرسیون باشند، مدل عمومی رگرسیون لجستیک چنین تعریف می‌شود: [۲۲]

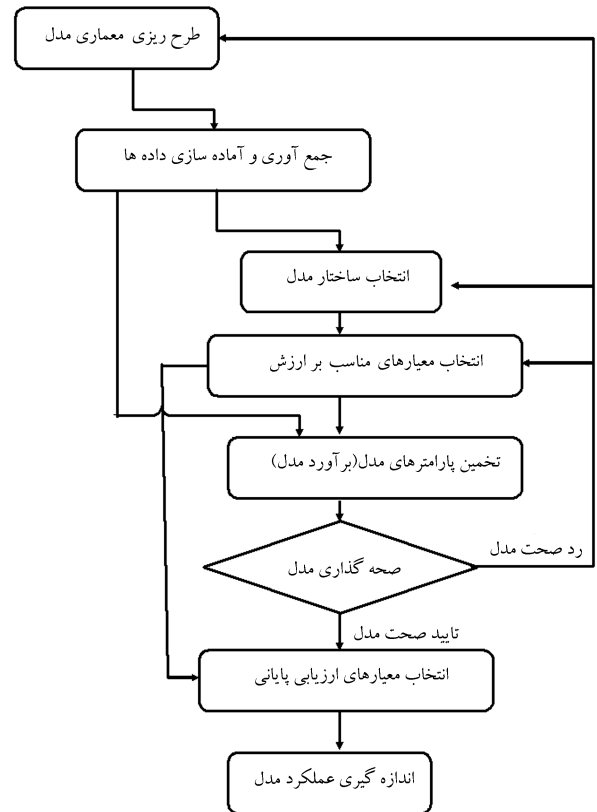
$$\begin{cases} P(Y = 1 | \vec{X}) = \frac{\text{Exp}(\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p)}{1 + \text{Exp}(\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p)} = \Pi(Y) \\ P(Y = 0 | \vec{X}) = 1 - \Pi(Y), \quad 0 \leq \Pi(Y) \leq 1 \end{cases} \quad (1)$$

به طوری که $\Pi(Y)$ تابع احتمال وقوع Y, \vec{X} بردار متغیرهای X_j ، β_j ضریب متغیر مستقل X_j ، و β_0 مقدار عرض از مبدأ در معادله‌ی عمومی رگرسیون لجستیک است. به منظور سهولت استفاده، رابطه‌ی غیرخطی ۱ با تبدیل لگاریتم تابع درست‌نمایی^{۱۵} متغیر پاسخ Y به تابع لوجیت (رابطه‌ی ۲) که یک تابع خطی بین متغیرهای مستقل X_j و متغیر پاسخ Y است تبدیل می‌شود.

$$\text{Logit}(\Pi(Y)) \log\left(\frac{\Pi(Y)}{1 - \Pi(Y)}\right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_p X_p \quad (2)$$

تابع «لوجیت» یک تابع خطی پیوسته با برد $(-\infty, \infty)$ و وابسته به دامنه‌ی X_j است که با استفاده از آزمون‌های آماری می‌توان معنی‌دار بودن تأثیر هر کدام از متغیرهای مستقل X_j را به روی احتمال وقوع متغیر پاسخ بررسی کرد. [۲۳]

ساختار مدل شبکه‌ی عصبی را می‌توان با توجه به مأموریت شبکه از بین چهار مدل اصلی «مدل نظری تشدید تطبیقی (ART)»^{۱۶}، «پرسپترون چندلایه» (MLP)^{۱۷}، شبکه‌های هم‌بند بازگشتی (RAN)^{۱۸}، یا نگاره‌های خودآرا (SOM)^{۱۹} انتخاب کرد. با توجه به کاربرد وسیع مدل‌های MLP در نگاشت روابط خطی و غیرخطی، غالباً در مدل‌سازی فرایندهای تولیدی از مدل MLP استفاده می‌شود. [۲۴] پس از تعیین ساختار کلی مدل، لازم است نسبت به تعیین جزئیات ساختار مدل،



شکل ۲. فلوچارت تشریح مراحل مدل‌سازی فرایند تولید.

کاربردی‌ترین مدل‌های خطی تعمیم‌یافته برای تحلیل رابطه‌ی یک یا چند متغیر بر متغیر پاسخ اسمی است. [۲۱] در این نوشتار مراحل مدل‌سازی برای هر دو مدل لجستیک و شبکه‌ی عصبی با توجه به شکل ۲ تشریح می‌شود.

گام ۱ طرح ریزی معماری مدل: در این مرحله از مدل‌سازی لجستیک و شبکه‌ی عصبی، محدودیت‌ها، پیش‌فرض‌ها و به طور کلی راهکارها و سیاست‌های مدل‌سازی مشخص می‌شود.

گام ۲ جمع‌آوری و آماده‌سازی داده‌ها: تصادفی‌بودن، یکپارچگی و کفایت داده‌ها از جمله شروط تعریف‌شده برای برازش داده‌های مدل لجستیک در این مرحله از مدل‌سازی است؛ این در حالی است که در مدل‌های رگرسیون لجستیک چندمتغیره، علاوه بر شروط بیان‌شده، عدم وجود هم‌خطی‌های متعدد^{۱۴} بین متغیرها نیز تعریف شده و در گام ۶ مورد بررسی قرار می‌گیرد.

از جمله تعداد نرون لایه‌ی ورودی (براساس تعداد متغیر ورودی)، تعداد لایه‌های میانی (به‌روش سعی و خطا)، تعداد نرون لایه‌ی خروجی (براساس تعداد متغیر خروجی) و نوع تابع فعال‌سازی (به‌روش سعی و خطا) اقدام شود.^[۲۵]

گام ۴ انتخاب معیارهای مناسب برازش: در مدل‌سازی براساس رگرسیون لجستیک، برآورد ضرایب مدل مبتنی بر روش بیشینه‌درست‌نمایی است. از آنجا که در مدل‌های رگرسیون لجستیک، متغیر تصادفی خطا $e_i \{i = 1, 2, \dots, m\}$ بیان‌گر تعداد داده‌ها است) از تابع توزیع دوجمله‌یی با میانگین صفر و انحراف معیار $\Pi(Y)(1 - \Pi(Y))$ پیروی می‌کند، احتمال وقوع داده‌های مشاهده‌شده -- به عبارتی مقدار تابع درست‌نمایی -- ملاک نیکویی برازش قرار می‌گیرد.^[۲۶] مناسب بودن برازش مدل در مدل‌سازی شبکه‌ی عصبی، از طریق توقف آموزش مدل شبکه‌ی عصبی مشخص می‌شود. برای توقف آموزش در مدل MLR سه معیار وجود دارد که به‌محض تحقق هر یک، مرحله‌ی آموزش به نشانه‌ی مناسب بودن برازش مدل متوقف می‌شود. این معیارها عبارت‌اند از: ۱. کم‌تر شدن مقدار میانگین مربعات خطا (MSE) در هر دوره، از مقدار تعیین‌شده‌ی قبلی؛ ۲. تغییرات نامحسوس در نرم‌گرادیان خطا در تکرارهای متوالی، یا کم‌تر شدن مقدار نرم‌گرادیان خطا از مقدار تعیین‌شده‌ی قبلی؛ ۳. افزایش تعداد تکرارها نسبت به تعداد تعیین‌شده‌ی قبلی.^[۲۷]

گام ۵ تخمین پارامترهای مدل (برآورد مدل) برآورد مدل رگرسیون لجستیک که همان تعیین ضرایب مربوط به هر متغیر است، به‌گونه‌ی انجام می‌شود که مقدار تابع درست‌نمایی برحسب m داده، طبق رابطه‌ی ۳ بیشینه شود، به‌طوری که y_i بیان‌گر مقدار Y متناظر با نمونه‌ی i ام $\{i = 1, 2, \dots, m\}$ و β_j نشان‌دهنده‌ی ضریب رگرسیون مربوط به متغیر تصادفی X_j است.^[۲۸]

$$L(\beta_j) = \prod_{i=1}^m \Pi(x_i)^{y_i} [1 - \Pi(x_i)]^{1-y_i} \quad (3)$$

تخمین پارامترهای مدل شبکه‌ی عصبی، در اصل همان ارائه‌ی داده‌ها و آموزش شبکه است که با هدف تنظیم پارامترهای داخلی (وزن‌ها و بایاس‌های) شبکه انجام می‌گیرد. چنانچه به شبکه اجازه دهیم از طریق تنظیم پارامترهای داخلی، متغیرهای مؤثر را از متغیرهای غیرمؤثر بر مدل تفکیک کند، رویکرد اتخاذشده رویکردی عمومی است. اما اگر متغیرهای مؤثر بر مدل، با تکیه بر روش‌های دیگر از جمله بهره‌گیری از تجربه‌ی خبرگان فرایند یا تحلیل‌های آماری همچون تحلیل واریانس (با فرض خطی بودن رابطه‌ی بین متغیرها) گزینش شوند، رویکرد اتخاذشده یک رویکرد متمرکز است. بررسی مطالعات پیشین، نشان‌دهنده‌ی برتری رویکرد متمرکز نسبت به رویکرد عمومی با توجه به معیار عملکرد شبکه است.^[۲۹] در مرحله‌ی آموزش لازم است درمورد پارامترهای اجرای آموزش، از جمله نوع الگوریتم آموزش، نرخ یادگیری، نحوه‌ی ارائه‌ی داده‌ها (تصادفی یا دوره‌یی) و همچنین معیارهای توقف آموزش، تصمیم‌گیری به‌عمل آید.^[۳۰]

گام ۶ صحت‌گذاری مدل: به‌منظور صحت‌گذاری مدل رگرسیون لجستیک، نتایج آزمون‌های Wald و Hosmer and Lemeshow مورد استفاده قرار می‌گیرد. آزمون Wald آزمونی است با فرض $\beta_j \{j = 1, 2, \dots, p\} = 0$ ، H_0 برای هر ضریب رگرسیونی β_j در یک مدل رگرسیون لجستیک که p رگرسور دارد. در صورتی که P_{value} مربوط به آماره‌ی این آزمون (W_0 در رابطه‌ی ۴) از مقدار ضریب اطمینان (α) کم‌تر باشد، مؤثر بودن متغیر X_j بر متغیر پاسخ مورد تأیید

خواهد بود.

$$W_0 = \frac{\hat{\beta}_j}{S(\hat{\beta}_j)} \quad (4)$$

در این رابطه مقدار $\hat{\beta}_j$ بیان‌گر مقدار برآوردشده‌ی ضریب رگرسیونی β_j و $S(\hat{\beta}_j)$ انحراف استاندارد برآورد β_j است.

آزمون Hosmer and Lemeshow: در این آزمون نیکویی برازش مدل، براساس بزرگی مقدار P_{value} مربوط به آماره‌ی مربع k این آزمون سنجیده می‌شود. به‌منظور صحت‌گذاری داده‌های مورد استفاده در برازش مدل لازم است در این مرحله، شرط پیش‌فرض عدم وجود هم‌خطی‌های متعدد بین متغیرهای رگرسور مورد بررسی قرار گیرد. هم‌خطی متعدد به حالتی اطلاق می‌شود که وجود هم‌بستگی شدید بین متغیرهای مستقل با افزایش کواریانس ضرایب β_j ، موجب نامعتبر شدن نتایج تخمین ضرایب رگرسیونی β_j شود.^[۳۱] از طریق محاسبه‌ی آماره‌ی VIF (طبق رابطه‌ی ۵) و بررسی شرط $VIF < 4$ می‌توان وجود هم‌خطی متعدد بین متغیرهای رگرسور را رد کرد. R_j^2 (بیان‌گر ضریب تعیین مدل رگرسیونی با ثابت فرض کردن تمامی متغیرهای مدل، به‌استثنا X_j است).

$$VIF(\beta_j) = \frac{1}{(1 - R_j^2)} \quad (5)$$

صحت‌گذاری مدل شبکه‌ی عصبی به‌منزله‌ی بررسی مسئله‌ی حفظ داده‌ها یا آموزش بیش از حد شبکه^{۲۰} در حین فرایند است. این مسئله که ریشه درانتخاب نامناسب تعداد نرون‌های لایه‌های مخفی دارد، زمانی رخ می‌دهد که شبکه یک کمیته‌ی محلی گرفتار شود. این پدیده منجر به کاهش قدرت تعمیم^{۲۱} شبکه علی‌رغم کاهش خطای آموزش خواهد شد. راه حل‌های متصور برای گریز از این مشکل در دو دسته‌ی عام قرار دارد: ۱. تنظیم تابع عملکرد؛ ۲. تعیین داده‌هایی به‌عنوان داده‌های صحت‌گذاری^{۲۲} که به‌عنوان ملاکی برای نشان دادن کاهش قدرت تعمیم‌دهی شبکه مورد استفاده قرار می‌گیرند.

گام ۷ انتخاب معیارهای ارزیابی پایایی مدل: معیارهای ارزیابی پایایی که به‌منظور بررسی قدرت درونی پایایی و برونی پایایی مدل لجستیک و مدل شبکه‌ی عصبی فرایند انتخاب شده‌اند، عبارت‌است از: ضرایب تعیین «Nagelkerke» و «Cox & Snell» (که در مدل لجستیک به‌روش بیشترین درست‌نمایی محاسبه می‌شود) و شاخص «درصد صحت پیش‌بینی» که بیان‌گر درصد کلی مواردی است که مدل وقوع یا عدم وقوع متغیر پاسخ را به‌درستی تشخیص داده است.

گام ۸ ارزیابی پایایی مدل: در این مرحله لازم است با توجه به معیارهای انتخاب‌شده در گام ۷ و جمع‌آوری داده‌هایی مستقل از داده‌های برازش مدل -- اما در محدوده‌ی گسترده‌تر (با هدف اندازه‌گیری پایایی در برونی پایایی و درونی پایایی مدل) -- نسبت به محاسبه و تحلیل پایایی مدل لجستیک و مدل شبکه‌ی عصبی اقدام شود.

ایجاد مدل لجستیک فرایند افشانه‌ی خشک‌کننده و

بررسی مناسب بودن آن

در مدل‌سازی لجستیک از فرایند افشانه‌ی خشک‌کننده، متغیرهای پیشنهادی برای معماری مدل مطابق شکل ۱ انتخاب شده و با فرض خطی بودن ارتباط متغیرهای ورودی و متغیر پاسخ دانه‌بندی، نسبت به تهیه داده‌های برازش مدل به‌روش مستقیم اقدام می‌شود. داده‌های جمع‌آوری‌شده از فرایند افشانه‌ی خشک‌کننده به‌منظور برازش

جدول ۲. نتایج صحنه‌گذاری مدل لجستیک پیش‌بینی عملکرد فرایند.

آزمون عدم هم‌خطی متعدد	آزمون Wald				چگالی (ρ)
	VIF	β_j	Pvalue	Exp(β_j)	
۱,۰۵	-۱۶۰,۱۷۸	۰,۰۰۲	۰,۰۰۰	۱۰,۰۰۱	
۱,۳۲	۰,۵۵۲	۰,۰۰۲	۱,۷۳۷	۹,۴۱۳	دمای ورودی ($\dot{T}in$)
۱,۷۵	-۰,۹۸۱	۰,۰۴۲	۰,۰۴۲	۴,۱۲۷	فشار پمپ (Ps)

مدل، شامل ۱۰۰ نمونه‌ی کاملاً تصادفی از دامنه‌ی تغییرات نرمال متغیرها است که هر نمونه حاوی اطلاعات مربوط به ۷ متغیر رگرسور و یک متغیر پاسخ متناظر با آن است. تابع لجستیک پیش‌بینی وضعیت دانه‌بندی یا به عبارتی پیش‌بینی عملکرد فرایند برحسب رگرسورهای مؤثر چگالی، دمای ورودی و فشار پمپ، مطابق رابطه‌ی ۶ و با استفاده از نرم‌افزار SPSS ارائه شده است.

مدل ریاضی مدل‌سازی شبکه‌ی عصبی به منظور پیش‌بینی شاخص عملکرد فرایند در قالب شکل ۳ قابل مشاهده است. به منظور برازش (آموزش) مدل شبکه‌ی عصبی فرایند، داده‌های برازش مدل به روش تصادفی و با استفاده از نرم‌افزار MATLAB^[۲۲] به مدل ارائه شده است. لازم به ذکر است پیش‌پردازش داده‌های برازش مدل، از طریق نرمال‌سازی داده‌ها و تحدید آنها در محدوده‌ی $[-1, 1]$ طبق رابطه‌ی ۷ با استفاده از نرم‌افزار صورت گرفته است.^[۲۳]

$$\text{Logit}(\Pi(S_{11})) = -160,178 \times \rho + 0,552 \times \dot{T}in - 0,981 \times Ps \quad (6)$$

صحت مدل رگرسیون لجستیک عملکرد فرایند با توجه به نتایج آزمون Wald ($P_{value} < \alpha = 0,05$) و خروجی آزمون Hosmer and Lemeshow ($VIF < 4$)، مطابق جدول ۲ مورد تأیید است.

به منظور ارزیابی پایایی مدل لجستیک فرایند با جمع‌آوری یک نمونه‌ی ۲۸ تایی از فرایند در شرایطی مشابه با شرایط جمع‌آوری داده‌های برازش، اما در محدوده‌ی گسترده‌تر (با هدف اندازه‌گیری پایایی در برون‌یابی و درون‌یابی) نسبت به محاسبه‌ی شاخص‌های ارزیابی پایایی مدل لجستیک فرایند، اقدام شده است. نتایج این محاسبات، نشان‌دهنده‌ی مقدار ضریب تعیین Nagelkerke برابر با ۰,۸۰۵ و مقدار ضریب تعیین Cox & Snell برابر با ۰,۶۰۴ و درصد صحت پیش‌بینی برابر با ۹۰ است.

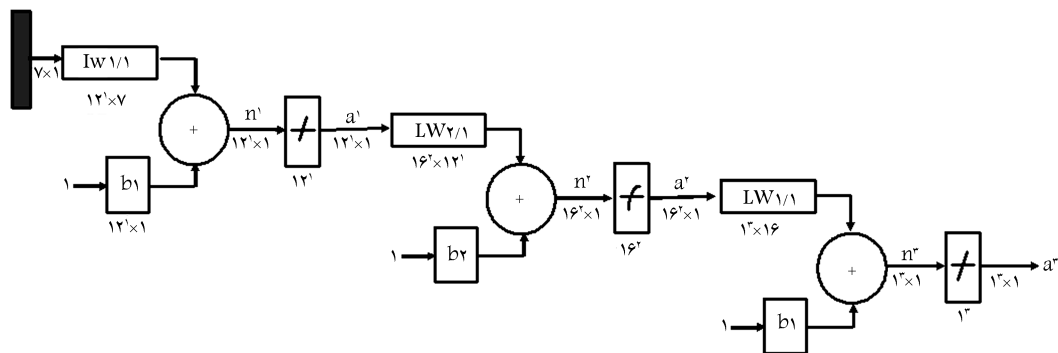
ایجاد مدل شبکه‌ی عصبی فرایند افشانه‌ی خشک‌کننده و ارزیابی آن

مدل شبکه‌ی عصبی فرایند، با توجه به متغیرهای پیشنهادی در شکل ۱ و داده‌های ۱۰۰ تایی برازش مدل (مورد استفاده در برازش مدل لجستیک فرایند) معماری شده است. در مدل شبکه‌ی عصبی فرایند، تمامی متغیرهای گران‌روی، دمای ورودی، فشار مکش، چگالی، دمای خروجی و فشار پمپ با توجه به امکان وجود اثرات متقابل فرایندها به‌عنوان متغیرهای ورودی به مدل و متغیر خروجی از مدل، متغیر

اسمی دانه‌بندی تعریف شده است. توسعه‌ی مدل شبکه‌ی عصبی پیش‌بینی دانه‌بندی یا پیش‌بینی شاخص عملکرد فرایند، با انتخاب ساختار MLP براساس الگوریتم آموزشی پس‌انتشار خطا و اتخاذ رویکردی عمومی در مدل‌سازی انجام گرفته است. الگوریتم پس‌انتشار خطا از متداول‌ترین و پرکاربردترین الگوریتم‌های آموزشی با ناظر است که دست کم در ۷۵٪ از کاربردهای ANNs استفاده می‌شود.^[۲۲] در این الگوریتم مقدار پاسخ ارائه‌شده به شبکه با مقدار خروجی شبکه مقایسه شده و پس از محاسبه‌ی خطای موجود، از آن برای تنظیم وزن‌ها و بایاس‌های شبکه استفاده می‌شود به طوری که با ارائه‌ی مجدد همان مقدار به شبکه، خروجی متناظر با آن به پاسخ هدف نزدیک‌تر می‌شود. قانون یادگیری مورد استفاده در این الگوریتم برای تنظیم پارامترهای مدل شبکه‌ی عصبی، قانون لوبزگ - مارکوارت است که مناسب آموزش شبکه‌های کوچک و متوسط است و مشخصه‌ی بارز آن سرعت ۱۰ تا ۱۰۰ برابر بیشتر نسبت به دیگر قوانین است. این قانون شش پارامتر تنظیم دارد که از جمله می‌توان به تعداد تکرار، نرخ یادگیری، کم‌ترین گرادینان خطا و پارامتر بیشترین شکست اشاره کرد. یادآور می‌شود که پارامتر بیشترین شکست، پارامتری برای جلوگیری از یادگیری بیش از حد شبکه است که بیان‌گر تعداد تکرار مجازی است که فرایند آموزش پس از بروز مشکل حفظ داده‌ها ادامه می‌یابد.

$$x_{ni} = 2 * \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} - 1 \quad (7)$$

به طوری که x_i بیان‌گر مقدار ورودی به مدل و x_{ni} مقدار نرمال‌شده‌ی متناظر با x_i است. صحنه‌گذاری مدل شبکه‌ی عصبی پیش‌بینی عملکرد، مطابق شکل ۴ از طریق تعیین بخشی از داده‌های ارائه‌شده به شبکه به‌عنوان داده‌های صحنه‌گذاری انجام گرفت




شکل ۳. مدل ریاضی مدل‌سازی شبکه‌ی عصبی به منظور پیش‌بینی شاخص عملکرد فرایند افشانه‌ی خشک‌کننده.

جدول ۳. معیارهای توقف و نتایج آموزش در لحظه توقف برای مدل شبکه عصبی پیش‌بینی عملکرد فرایند.


نتایج در لحظه توقف				معیارهای توقف		
گرادینان	تکرار	میانگین مربعات آموزش	میانگین مربعات خطای صحنه‌گذاری	تکرار	گرادینان (تغییرات خطا)	میانگین مربعات خطا
۰٫۰۰۱۹۷۶۴	۷۲	$7,49748e-006$	$9,23989e-005$	۱۰۰	$1e-010$	$1e-005$

با مدل لجستیک عملکرد فرایند را پیش‌بینی می‌کند. برتری مدل شبکه‌ی عصبی در پیش‌بینی عملکرد فرایند افشانه‌ی خشک‌کننده را می‌توان به دلایل مختلفی ربط داد. برخی از این دلایل عبارت‌اند از: وجود اثرات متقابل شدید بین متغیرها، وجود رابطه‌ی غیرخطی بین متغیرهای رگرسور و متغیر پاسخ، یا قدرت نسبی مدل‌های شبکه‌ی عصبی در برون‌یابی. با حصول اطمینان از کارایی و برتری نسبی مدل شبکه‌ی عصبی در پیش‌بینی عملکرد فرایند افشانه‌ی خشک‌کننده، این مدل به عنوان گزینه‌ی برتر مورد استفاده قرار می‌گیرد تا نسبت به ارائه‌ی سناریوهای مختلف برای تنظیم ورودی‌های فرایند (در دامنه‌ی گسترده‌تر از دامنه‌ی نرمال تغییرات رگرسورها)، طبق شکل ۵ اقدام شود.

چنان که در شکل ۵ مشاهده می‌شود، وضعیت عملکرد فرایند در حالی که دمای ورودی در دامنه‌ی ۵۳۵ تا ۵۵۵ درجه‌ی سانتی‌گراد و فشار مکش در دامنه‌ی ۱۰ تا ۲۶ میلی‌بار تغییر می‌کند، با فرض دو مقدار ۱٫۶۷ و ۱٫۶۸ ثانیه برای چگالی توسط مدل شبکه‌ی عصبی پیش‌بینی شده است. در این سناریو، وضعیت عملکرد فرایند به کمک (x_i, x_j) ‌ها مشخص شده است به طوری که $x_i, x_j = \{0, 1\}$ و مقدار $x_i = 1$ نشان‌دهنده‌ی وضعیت مطلوب عملکرد فرایند در حالتی است که $\rho = 1,67$ ؛ همچنین مقدار $x_i = 0$ نشان‌دهنده‌ی عدم موفقیت در عملکرد فرایند با فرض $\rho = 1,67$ است. به همین ترتیب مقدار $x_j = 1$ نشان‌دهنده‌ی وضعیت مطلوب عملکرد فرایند در حالتی است که $\rho = 1,68$ ، و مقدار $x_j = 0$ نشان‌دهنده‌ی عدم موفقیت در عملکرد فرایند با فرض $\rho = 1,68$ است. لازم به ذکر است دلیل انتخاب دمای ورودی و فشار مکش به عنوان متغیر تصادفی و چگالی به عنوان یک پارامتر ثابت دوسطحی، با توجه به مقدار $\text{Exp}(\beta z)$ (مندرج در جدول ۲) یا به عبارتی میزان تأثیر هر متغیر در افزایش احتمال موفقیت فرایند، انتخاب شده است. روابط حاکم بین سناریوهای مختلف بیان‌گر این نکته است که در صورت افزایش چگالی دوغاب لازم است نسبت به افزایش دمای ورودی و کاهش فشار مکش به منظور دست‌یابی به عملکرد موفقیت‌آمیز فرایند افشانه‌ی خشک‌کننده اقدام شود. این دستاورد از نظر علمی نیز قابل توجیه است به طوری که



شکل ۵. سناریوهای مختلف برای تنظیم فرایند افشانه‌ی خشک‌کننده.



شکل ۴. نمودار فرایند آموزش و صحنه‌گذاری مدل شبکه عصبی عملکرد فرایند.

به طوری که فرایند آموزش پس از ۷۲ بار تکرار با توجه به افزایش خطای مربوط به داده‌های صحنه‌گذاری و بروز مشکل حفظ داده‌ها متوقف شد. طبق جدول ۳، و با توجه به تحقق هدف تعیین‌شده برای میانگین مربعات خطا ($1e-005 < 7,49748e-006$)، مناسب بودن مدل برای تعمیم دهی تأیید می‌شود.

در این مرحله به منظور ارزیابی پایایی مدل شبکه‌ی عصبی فرایند، لازم است داده‌های ۲۸ تایی ارزیابی پایایی به مدل ارائه شود و نتایج پیش‌بینی شده توسط مدل شبکه‌ی عصبی فرایند برای این داده‌ها ملاک محاسبه‌ی شاخص‌های ارزیابی قرار گیرد. نتایج محاسبه‌ی این شاخص‌ها برای مدل شبکه‌ی عصبی نشان‌دهنده‌ی مقدار ضریب تعیین Nagelkerke برابر با ۰٫۹۳۲ و مقدار ضریب تعیین Cox & Snell برابر با ۰٫۷۱۷ و صحت پیش‌بینی برابر با ۹۶٫۴ درصد است.

بحث و بررسی نتایج

نتایج ارزیابی پایایی مدل لجستیک و مدل شبکه‌ی عصبی فرایند، از طریق محاسبه‌ی شاخص‌های ضرایب تعیین "Nagelkerke" و "Cox & Snell" و شاخص «درصد صحت پیش‌بینی» مطابق با جدول ۴ قابل مشاهده است.

مقایسه‌ی نتایج شاخص‌های ارزیابی پایایی در پیش‌بینی (برون‌یابی و درون‌یابی) عملکرد فرایند افشانه‌ی خشک‌کننده برای مدل‌های لجستیک و شبکه‌ی عصبی بیان‌گر این مطلب است که مدل شبکه‌ی عصبی فرایند، با قدرت بیشتری در مقایسه جدول ۴. نتایج محاسبه شاخص‌های ارزیابی پایایی مدل پیش‌بینی عملکرد فرایند.

درصد صحت پیش‌بینی	انحراف معیار کوکس و اسنل	انحراف معیار ناگل کرک	مدل لجستیک
۹۰٪	۰٫۶۰۴	۰٫۸۰۵	مدل لجستیک
۹۶٫۴٪	۰٫۷۱۷	۰٫۹۳۲	مدل شبکه‌ی عصبی

و مدل شبکه‌ی عصبی پیش‌بینی عملکرد فرایند، با استفاده از شبکه‌ی MLP براساس پس‌انتشار خطا با اتخاذ رویکرد عمومی در مدل‌سازی تشریح و پیاده‌سازی شود. پس از برآزش مدل‌ها با استفاده از داده‌های واقعی، نسبت به ارزیابی پایایی مدل‌ها اقدام شد. این ارزیابی با استفاده از داده‌هایی مستقل و در دامنه‌ی گسترده‌تر از داده‌های برآزش انجام گرفت تا نشان‌گر قدرت درون‌یابی و برون‌یابی مدل‌ها باشد. نتیجه‌ی مقایسه‌ی ارزیابی پایایی مدل‌های لجستیک و شبکه‌ی عصبی فرایند بیان‌گر قدرت نسبی مدل‌های شبکه‌ی عصبی در پیش‌بینی عملکرد فرایند افشانه‌ی خشک‌کننده است هرچند که این قدرت نسبی در پیش‌بینی را می‌توان با ارائه‌ی داده‌های آموزش بیشتر بهبود بخشید. پس از حصول اطمینان از کارایی و سهولت استفاده‌ی مدل‌های شبکه‌ی عصبی در پیش‌بینی عملکرد فرایند افشانه‌ی خشک‌کننده، با ارائه‌ی سناریوهای مختلف برای تنظیم ورودی‌های و تفسیر و استنتاج روابط بین متغیرها، تا حد زیادی مسئله‌ی در بسته بودن^{۲۳} مدل‌های شبکه‌ی عصبی رفع، واز این طریق کنترل پیش‌بینانه‌ی عملکرد فرایند جایگزین روش‌های مبتنی بر سعی و خطا برای کنترل عملکرد فرایند می‌شود.

در نتیجه‌ی افزایش چگالی دوغاب، فشار پمپ افزایش یافته و تشدید سرعت پاشش دوغاب در داخل محفظه افشانه‌ی خشک‌کن، افزایش دمای ورودی و کاهش فشار مکش را برای کاهش فرصت به هم چسبیدن ذرات و در نتیجه تولید ریزدانه‌هایی با دانه‌بندی مناسب (عملکرد موفقیت‌آمیز فرایند) اجتناب‌ناپذیر می‌کند. البته طبق شکل ۵، وجود استثنائاتی در این قاعده‌ی کلی مشاهده می‌شود که می‌توان آنها را به اثرات متقابل متغیرها مربوط دانست. مثلاً در دمای ۵۵۵ درجه سانتی‌گراد و فشار مکش ۱۰ میلی‌بار با چگالی ۱/۶۷ ثانیه عملکرد فرایند موفقیت‌آمیز است ولی با چگالی ۱/۶۸ ثانیه عملکرد فرایند ناموفق است.

نتیجه‌گیری

در این نوشتار سعی شد تا از طریق موردکاوی (فرایند افشانه‌ی خشک‌کننده)، مراحل معماری مدل لجستیک پیش‌بینی عملکرد فرایند با استفاده از رگرسیون لجستیک

پانویس

1. spray drying
2. artificial neural networks
3. mehrotra
4. algorithmic optimization
5. fuzzy logic
6. Cook
7. non-linear programming
8. Sukthomya
9. Tannock
10. Senturk
11. adaptive neuro fuzzy system
12. Logistic Regression
13. reliability
14. multicollinearity
15. likelihood function
16. adaptive resonance theory models
17. multilayer perceptrons
18. recurrent associative networks
19. self-organizing maps
20. overfitting
21. generalization
22. validation
23. black-box

منابع

3. Hosoz, M.; Ertunc, H.M. and Bulgurcu, H. "Performance prediction of a cooling tower using artificial neural network", *Journal of Energy Conversion and Management*, **48**, pp. 1349-1359 (2007).
4. Twomey, J. and Smith, A. "Bias and variance of validation models for function approximation", *Neural Networks under Condition of Sparse Data, IEEE Transaction on System and Cybernetics*, **28**(3), pp. 231-239 (1998).
5. Coit, D.W.; Jackson, B.T. and Smith, A. "Static neural network process models: Considerations and case studies", *Journal of Production Research*, **13**, pp. 145-175 (1997).
6. Mehrotra, S.P. "Role of mathematical modeling in metallurgy", *Bull. Master. Sci.*, **12**(384), pp. 354-363 (1986).
7. Andersen, K.; Cook, G.E. and Ramaswamy, K. "Artificial neural networks applied to arc welding process modeling and control", *IEEE Transaction on Industrial Application*, **26**, pp. 824-830 (1990).
8. Smith, A.E. and Dagli, C.H. "Controlling industrial process through supervised feedforward neural networks", *Computers & Industrial Engineering*, **21**, pp. 247-251 (1991).
9. Martinez, S.E.; Smith, A.E. and Bopaya B. "Reducing waste in casting with a predictive neural model", *Journal of Intelligent Manufacturing Systems*, **4**, pp. 23-31 (1993).
10. Ben Brahim, S.; Smith, A.E. and Bopaya B., "Relating product specifications and performance data with a neural networks model for design improvement", *Journal of Intelligent Manufacturing Systems*, **4**, pp. 231-243 (1993).
11. Su, C. and Hsieh, K.L. "Applying neural network approach to achieve robust design for dynamic quality char-
1. Walsh, D.E. and Zaccari, N. "Predictive statistical process controls-A neural network approach to maximizing tablet yield", *Pharmaceutical Technology Europe*, (11), pp. 46-53 (2001).
2. Saxen, H. and Petterson, F. "Methods for the selection of inputs and structure of feedforward neural networks", *Computers and Chemical Engineering*, **30**, pp. 1038-1045 (2006).

- acteristics" *International Journal of Quality and Reliability Management*, **15**(5), pp. 509-519 (1998).
12. Lam, S.S.; Petri, K.L. and Smith, A.E. "Prediction and optimization of a ceramic casting process using a hierarchical hybrid system of neural networks and fuzzy logic" *IEEE Transactions on design and manufacturing*, **16**, pp. 68-76 (2000).
 13. Cook, D.F.; Ragsdale, C.T. and Major, R.L. "Combining a neural with a genetic algorithm for process parameter optimization", *Engineering Application of Artificial Intelligence*, **13**, pp. 391-396 (2000).
 14. Nascimento, C.A.O.; Giudici, R. and Guardani, R. "Neural net based approach for optimization of industrial chemical process", *Computers and Chemical Engineering*, **24**, pp. 2303-2374 (2000).
 15. Sukthomya, W. and Tannock, J. "The training of neural networks to model manufacturing process", *Journal of Intelligent Manufacturing*, **16**, pp. 39-51 (2005).
 16. Erginel, N. and Ay, N. "How process factors affect ceramic tile color", *Am. Ceram. Soc. Bull.*, **84**(7), pp. 9201-9203 (2005).
 17. Senturk, S. and Erginel, N. "ANFIS applied to the color problem of ceramic tile", *American Ceramic Society Bulletin*, **87**(8), pp. 123-140 (2005).
 18. Afzulpurkar, N.V.; Saeed, I.A.K. and Vyawahare, V.S. "Ceramic tile process modeling for quality improvement using ANNs", *ICIT IEEE International Conference on Industrial Technology*, (2006).
 19. Prats-Montalban, J.M. and Ferrer, A. "Integration of color and textural information in multivariate image analysis: Defect detection and classification issues", *Journal of Chemometrics*, **21**(2), pp. 10-23 (2008).
 20. SACMI Corporation "From technology through machinery to kilns for SACMI Tile", Italy, SACMI Press, pp. 66-98 (1989).
 21. Hauck, W.W. and Donner, A. "Wald's test as applied to hypotheses in logit analysis", *Journal of The American Statistical Associations*, **72**, pp. 851-853 (1997).
 22. Cox, R.B. "Regression models and life tables", *Journal of Royal Statistical Society*, **34**, pp. 182-220 (1972).
 23. Wright, R.E. "Logistic regression: Reading and understanding multivariate statistics" (Eds L.G. Grimm and P.R. Yarnold), Washington DC, American Psychological Association, pp. 217-244 (1995).
 24. Hornik, K.; Stinchcombe, M. and White, H. "Multi-layer feed forward networks are universal approximators." *Neural Networks*, **2**, pp. 359-366, (1989).
 25. Ramesh, M.C.; Rajamanickam, R. and Jayaraman, S. "The prediction of yarn tensile properties by using artificial neural networks", *The Journal of the Textile Institute*, **86**(3), pp. 456-469 (1995).
 26. Velleman, P.F. and Welsch, R.E. "Efficient computing of regression diagnostics", *American Statistician*, **35**, pp. 234-242 (1998).
 27. Edwards, P.J.; Murray, A.F.; Papadopoulos, G.; Wallace, A.R.; Barnard, J. and Smith, G. "The application of neural networks to the paper making industry", *IEEE Transaction on Neural Networks*, **10**(6), pp. 1456-1464 (1999).
 28. Jennings, D.E. "Judging inference adequacy in logistic regression", *Journal of The American Statistical Association*, **81**, pp. 471-476 (1986).
 29. Magali, R.G. and Meireles, P.E. "A comprehensive review for industrial application of artificial neural networks.", *IEEE Journal*, **50**, p. 3 (2003).
 30. Smith, A.E. and Dagli, C.H. "Relating binary and continuous problem entropy to back propagation network architecture" , *In Application of Artificial Neural Networks*, Bellingham, WA:SPIE, pp. 551-562 (1991).
 31. Hines, W.W. and Montgomery, D.C., *Probability and Statistics in Engineering and Management Science*, 3rd ed, New York, John Wiley & Sons , pp. 315-336 (1990).
 32. Hecht-Nielsen, R. "Theory of the back propagation neural network", *Proceedings of the International Joint Conference on neural networks*, pp. 593-603 (1989).
 33. Hagan, M.T.; Demuth, H.B. and Beale, M., *Neural Network Design*, Boston, PWS Publishing Company, pp. 35-73 (1996).