

کنترل پیش‌بینانه کیفیت با استفاده از شبکه‌های عصبی مصنوعی (ANNs) و روش ترکیبی تحلیل رگرسیون و ANNs

نجمه نشاط^۱، هاشم محلوچی^۲

۱. دانشجوی کارشناسی ارشد، دانشکده مهندسی صنایع، دانشگاه صنعتی شریف، ایران

۲. استاد، دانشکده صنایع، دانشگاه صنعتی شریف، ایران

(تاریخ دریافت: ۱۳۸۷/۱۱/۲۶، تاریخ تصویب: ۱۳۸۸/۱۰/۲۰)

چکیده

در این مقاله با ارایه نمونه عملی فرآیند اسپری درآینگ، متدولوژی مدل‌سازی فرآیندها با استفاده از سلسله مراتبی از تحلیل رگرسیونی و الگوریتم شبکه عصبی مصنوعی، با هدف کنترل پیش‌بینانه کیفیت، برای نخستین بار تشریح و پیاده‌سازی شده است. استفاده از ANNs در این مقاله، به منظور معماری مدل عصبی فرآیند اسپری درآینگ با اتخاذ یک رویکرد عمومی و انتخاب الگوریتم پس انتشار خطا به کمک داده‌های مستقیم است. فرض تاثیر مثبت اعمال تحلیل رگرسیونی بر ارتقا پایایی مدل عصبی، با محاسبه و تحلیل شاخص‌های ارزیابی پایایی مدل که عبارتند از: ضریب تعیین (R^2)، میانگین خطای نسبی (MRE) و جذر میانگین مربعات خطا (RMSE)، برای مدل عصبی و مدل عصبی-آماري (مدل عصبی با اعمال تحلیل رگرسیونی) تایید شد. در انتها با توجه به نتایج ارزیابی پایایی، سناریوهای مختلفی برای تنظیم ورودی‌های فرآیند توسط مدل عصبی-آماري فرآیند طراحی شد که با استفاده از آن می‌توان کنترل پیش‌بینانه را جایگزین روش‌های مبتنی بر سعی و خطا برای کنترل فرآیند کرد.

واژه‌های کلیدی: کنترل پیش‌بینانه، شبکه عصبی مصنوعی، مدل‌سازی، اسپری درآینگ

۱. مقدمه


لازمه پیش‌بینی کیفیت محصول در هر فرآیند، مدل‌سازی و کشف رابطه بین عواملی است که می‌توانند بر کیفیت خروجی فرآیند تاثیرگذار باشند. در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANNs) به عنوان یک الگوریتم فرا ابتکاری در زمینه مدل‌سازی و پیش‌بینی، مورد توجه بسیار قرار گرفته است که این محبوبیت را می‌توان به توانایی و قابلیت‌های برجسته ANNs در زمینه مدل‌سازی و پیش‌بینی علی‌الخصوص در مورد فرآیندهای پیچیده مربوط دانست. قابلیت اطمینان بالا در حذف و تشخیص نوسانات غیر تصادفی در داده‌ها [۱۸]، توانایی در کشف اثرات متقابل بین متغیرها [۹]، صرفه‌جویی اقتصادی قابل توجه در به کارگیری، فراغت از مفروضات و قیود دست و پاگیر مدل‌های کلاسیک [۲۴] و توانایی کاهش تاثیر متغیرهای غیر موثر بر مدل از طریق تنظیم پارامترهای داخلی [۴]، از جمله ویژگی‌هایی است که موجب شده است تا این الگوریتم فرا ابتکاری را بر دیگر روش‌های کلاسیک مدل‌سازی و پیش‌بینی از جمله رگرسیون برتری دهد. از نخستین مطالعات انجام شده در زمینه مدل‌سازی فرآیندهای تولیدی، می‌توان به مقاله‌ای که در سال ۱۹۸۶ میلادی توسط مهر و ترا [۱۱] نوشته شد، اشاره کرد. در این مقاله، مدل‌سازی فرآیند تولید کاشی سرامیکی از طریق تشریح کمی روابط بین متغیرها در قالب معادلات ریاضی صورت گرفت. آندرسن و همکاران [۲] نیز سعی کردند تا با مدل‌سازی فرآیند و به کارگیری شبکه پس انتشار خطا، نسبت به پیش‌بینی کیفیت فرآیند جوشکاری، در یک تجربه آزمایشگاهی اقدام کنند. از دیگر مطالعات انجام شده در زمینه مدل‌سازی فرآیند می‌توان به مقاله‌ای که توسط اسمیت و داگلی [۲۰] با موضوع پیش‌بینی کیفیت فرآیند شکل‌دهی لوله PVC با استفاده از ANNs و تحلیل رگرسیونی انتشار یافت، اشاره کرد. در این مطالعه، انتخاب اولیه متغیرهای پیشنهادی مدل عصبی بر اساس نتایج تحلیل ضرایب انفرادی مدل رگرسیونی، صورت پذیرفت. مطالعه بعدی منسوب به مارتینز و همکاران [۱۳] است؛ در این مطالعه مدل عصبی با هدف کاهش ضایعات در فرآیند شکل‌دهی ارابه شد. در اصل در این مطالعه، از شبکه عصبی به عنوان ابزاری برای شناسایی و طبقه‌بندی الگو استفاده شد. اندکی بعد، بن برهیم و همکاران [۳] نیز برای صنایع سرامیکی (چینی بهداشتی) با به کارگیری الگوریتم پس انتشار خطا اقدام به مدل‌سازی و پیش‌بینی فرآیند شکل‌دهی چند متغیره کردند. سو و هسیه [۲۲] مدل‌سازی و بهبود عملکرد کیفی را

با به کارگیری الگوریتم پس‌انتشار خطا (بر اساس قانون گرادیان نزولی) و اتخاذ رویکرد تاگوچی برای فرآیند تولید نیمه‌هادی‌ها، مورد مطالعه قرار دادند. در سال ۲۰۰۰ میلادی یک سیستم پیوندی متشکل از تکنیک‌های بهبود الگوریتمی، شبکه عصبی و منطق فازی در صنعت کاشی‌سرامیکی توسط لام و همکاران [۱۰] طراحی شد که در این سیستم، با به کارگیری ماژول پیش‌بینانه شبکه عصبی، تنظیمات قابل کنترل فرآیند پیش‌بینی شده و سپس الگوریتم بهبود سیستم با توجه به نتایج پیش‌بینی شده، تابع هدف را بهینه‌سازی می‌کرد. اما در مدل عصبی طراحی شده توسط کوک و همکاران [۵] برای پیشگویی استحکام تخته‌های نئوپان، پیش‌بینی کیفیت با استفاده از الگوریتم پس‌انتشار خطا و بهینه‌سازی کیفیت، با استفاده از الگوریتم ژنتیک انجام شد. بهینه‌سازی در مورد فرآیندهای شیمیایی نیز توسط ناسیمتو و همکاران [۱۴] با به کارگیری ANNs انجام شد که در این مطالعه پس از پیش‌بینی کیفیت خروجی توسط شبکه عصبی، بهینه‌سازی پارامترهای شیمیایی با استفاده از روش برنامه‌ریزی غیرخطی صورت گرفت. سپس مطالعه‌ای توسط سوکدومیا و تانوک [۲۳] در سال ۲۰۰۵ به منظور مدل‌سازی فرآیند تولید تیغه مورد استفاده در پره هواپیما انجام گرفت که در این مطالعه، عوامل موثر ورودی به مدل عصبی به روش سعی و خطا و با توجه به ضریب تعیین شبکه‌ها، انتخاب شد. در مدل‌سازی فرآیند لعاب زنی که با هدف بهینه‌سازی کیفیت خروجی رنگ لعاب، توسط ارگینل و آی [۶] انجام شد، تکنیک طراحی آزمایش‌ها به کار رفت. در ادامه این فعالیت، مقاله‌ای توسط سنتورک و ارگینل [۱۹] ارائه شد که در این مطالعه تئوریک استفاده از سیستم استنتاج تطبیقی فازی عصبی و آموزش آن با الگوریتم پس‌انتشار خطا برای شناسایی سطوح عوامل با به کارگیری روش طراحی آزمایش‌ها، پیشنهاد شد. فعالیت‌های علمی افزولپورکار و همکاران [۱] از دیگر مطالعات قابل توجه در این زمینه است که با استفاده از یک ماژول نرم‌افزاری هوشمند، پیش‌بینی کیفیت فرآیند تولید کاشی انجام شده است. نزدیک‌ترین مطالعه به مقاله حاضر، مربوط به مطالعه‌ای است که توسط هوسوز و همکاران [۹] به منظور پیش‌بینی عملکرد برج‌ی‌خنک‌کننده با استفاده از ANNs انجام گرفته است. در این مطالعه شاخص عملکرد فرآیند به عنوان مجموعه‌ای از مشخصه‌های کیفی فرآیند از جمله دمای آب تبخیر شده در برج‌خنک‌کننده، تعریف شده است. پراتس - مونتالبان و فرر [۱۵] طی یک مطالعه علمی، فاکتورهای مهم و موثر بر درجه‌بندی

وصفی کاشی‌های سرامیکی با استفاده از رگرسیون لجستیک و طراحی آزمایش‌ها مورد شناسایی قرار دادند. نکته قابل توجه در مورد تمامی این مطالعات مربوط به ویژگی در بسته بودن (بلک باکس بودن) شبکه‌های عصبی است به طوری که در هر دو مرحله معماری مدل عصبی و تفسیر و بکارگیری خروجی‌های مدل عصبی به عنوان یکی از نقاط ضعف شبکه‌های عصبی به شمار می‌رود. با این توصیف، هدف اساسی این تحقیق اتخاذ رویکردهایی است که با استفاده از آنها بتوان این نقطه ضعف از شبکه‌های عصبی را مرتفع کرده و با ارتقا پایایی مدل عصبی فرآیند بتوان نسبت به کنترل پیش‌بینانه کیفیت اقدام کرد. سوالات اساسی این تحقیق را می‌توان در قالب دو عبارت مطرح نمود: (۱) آیا استفاده از تحلیل رگرسیونی در معماری شبکه عصبی می‌تواند موجب افزایش پایایی مدل عصبی به منظور پیش‌بینی کیفیت فرآیند شود؟ (۲) چگونه می‌توان با استفاده از خروجی‌های پیش‌بینی شده توسط ANNs عملاً نسبت به کنترل پیش‌بینانه فرآیند اقدام نمود؟

۲. آشنایی با فرآیند اسپری درآینگ

فرآیند اسپری درآینگ، یکی از مراحل تولید کاشی‌های سرامیکی می‌باشد که در آن، دوغاب کاشی از طریق تجهیزات اسپری درایر به گرانول تبدیل می‌شود. به منظور تبدیل دوغاب به دانه‌های گرانول لازم است تا دوغاب موجود در حوضچه‌ها با "دمای دوغاب" (T_s)، تحت "فشار پمپ" (P_p) به داخل محفظه اسپری درایر پاشیده شود. همزمان با ورود دوغاب به داخل محفظه اسپری درایر، هوای داغ از طریق سیستم توزیع هوای داغ با "دمای ورودی" (\dot{T}_{in}) به بالای محفظه تزریق شده و موجب جذب رطوبت دوغاب و تبدیل آن به دانه‌های گرانول می‌شود. در نهایت با ایجاد جریانات گردابی در داخل محفظه از طریق اعمال "فشار مکش" (P_s)، ذرات گرانول از طریق شیر تخلیه از محفظه اسپری درایر خارج می‌شود. "فشار مکش" (P_s) ایجاد شده با تاثیر به روی سرعت جریانات گردابی، مهلت دانه‌های گرانول را برای به هم پیوستن و حجیم شدن، دستخوش تغییر می‌سازد. گرد و غبار موجود در داخل محفظه که دارای "دمای خروجی" (\dot{T}_0) است، توسط سیستم جمع آوری سیکلون‌ها از محفظه خارج می‌شود [۱۷]. با توجه به نحوه تشکیل ذرات گرانول و با علم به ساختار کاری اسپری درایر، P-Diagram فرآیند اسپری درآینگ مطابق با نمودار شماره (۱) رسم شده است [۱۷]:



نمودار ۱. P-Diagram فرایند اسپری درآینگ

مطابق با نگاره شماره (۱) متغیر خروجی دانه بندی (S_3)، که بیانگر وزن ذرات گرانول با قطر بیشتر از ۳۰۰ میکرون در یک نمونه ۱۰۰ گرمی از گرانول خروجی از اسپری درآینگ می باشد، معیاری برای بیان وضعیت دانه بندی گرانول ها به عنوان یک مشخصه کیفی فرآیند تعریف می شود.

۳. تحلیل رگرسیونی متغیرهای فرآیند

انجام تحلیل های رگرسیونی متغیرها قبل از مرحله معماری مدل عصبی با هدف جبران ناتوانایی مدل های عصبی در شناسایی نحوه تاثیر گذاری متغیرهای ورودی بر متغیر پاسخ انجام می گیرد. داده های جمع آوری شده از فرآیند اسپری درآینگ به منظور مدل سازی عصبی فرآیند، شامل ۱۰۰ نمونه کاملاً تصادفی می باشد که هر نمونه، حاوی اطلاعات مربوط به ۷ متغیر رگرسور و یک متغیر پاسخ متناظر با آن است. نتایج تحلیل همبستگی، بین متغیرهای رگرسور و متغیر پاسخ فرآیند اسپری درآینگ، طبق نگاره شماره (۱) قابل مشاهده است.

نگاره ۱. جدول تحلیل همبستگی بین متغیرهای رگرسور و متغیر پاسخ فرایند اسپری درآینگ

S_3	T_s	S_3	P_s	S_3	\dot{T}_{in}	S_3	P_p	S_3	\dot{T}_o	S_3	v	S_3	ρ	
-0.007		-0.05		0.111		0.002		0.249		0.316		0.567		ضریب همبستگی
0.95		0.601		0.297		0.983		0.017		0.002		0.000		Sig
-		-		-		-		+		+		+		وضعیت نهایی
*علامت "+" بیانگر وجود همبستگی و "-" به منزله عدم وجود همبستگی بین دو متغیر با توجه به نتایج تحلیل همبستگی و هم چنین نمودار پراکنش این دو متغیر می باشد.														

نتایج نگاره شماره (۱)، نشان می‌دهد که از بین هفت متغیر پیشنهادی، تنها سه متغیر v ، ρ و \dot{T}_O دارای همبستگی با متغیر پاسخ S_3 است و نتایج تحلیل همبستگی متغیرهای P_P ، P_S و \dot{T}_{in} با متغیر پاسخ S_3 ($0.1 < Sig$) و هم‌چنین عدم وجود رابطه غیرخطی این سه متغیر با S_3 (با توجه به نمودار پراکنش) بیانگر این مطلب است که ظاهراً تغییرات این سه متغیر نمی‌تواند تاثیر قابل توجهی بروی تغییرات S_3 داشته باشد. به منظور شناخت رابطه بین متغیرهای ورودی به مدل، لازم است تا وضعیت همبستگی بین این دسته از متغیرها به صورت دو به دو، طبق نگاره شماره (۲) مشخص گردد (در صورت وجود همبستگی ذکر شده است).

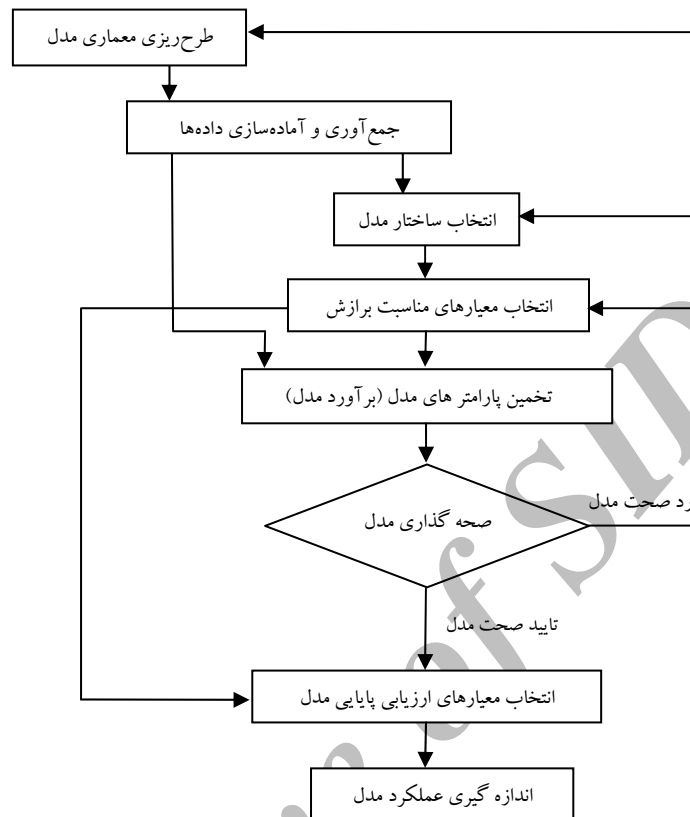
نگاره ۲. جدول تحلیل همبستگی بین متغیرهای رگرسور در فرایند اسپری درآینک

P_S ,	\dot{T}_O	P_P ,	\dot{T}_O	\dot{T}_{in} ,	\dot{T}_O	v ,	ρ	
0.31		-0.324		0.354		0.477		ضریب همبستگی
0.003		0.035		0.001		0.000		Sig

تحلیل همزمان نتایج نگاره شماره (۱) و نگاره شماره (۲) بیانگر آن است که متغیرهای P_S ، P_P و \dot{T}_{in} با تاثیرگذاری مستقیم بر S_3 به طور غیر مستقیم بر آن اثر می‌گذارند و این استنتاج را می‌توان برای P_P ، با توجه به لزوم برقراری بیلان "جرم" در داخل محفظه و برای P_S ، با توجه به لزوم برقراری بیلان "حجم" و برای \dot{T}_{in} ، با توجه به لزوم برقراری بیلان "انرژی" توجیه کرد. بنابراین مقادیر متغیر \dot{T}_O به عنوان یک متغیر وابسته به متغیرهای \dot{T}_{in} ، P_P و P_S بستگی دارد و برای ارایه مدل عصبی پیش‌بینی S_3 بر حسب متغیرهای v و \dot{T}_O لازم است تا مقادیر \dot{T}_O بر حسب متغیرهای مستقل آن یعنی \dot{T}_{in} ، P_P و P_S با استفاده از الگوریتم ANNs برآورد شود.

۴. متدولوژی مدل‌سازی عصبی فرآیند اسپری درآینک

انتخاب الگوریتم ANNs با هدف توسعه مدل فرآیند پیچیده اسپری درآینک با توجه به دستاوردهای مطالعات قبلی در مورد این فرآیند انجام می‌گیرد [۴، ۲۶]. بنابراین در این زیر بند، مراحل هشت‌گانه مدل‌سازی عصبی فرآیند اسپری درآینک با استفاده از نمودار شماره (۲) (فلوچارت عمومی مدل‌سازی) تشریح می‌گردد.



نمودار ۲. فلوجارت تشریح مراحل مدل سازی فرآیندهای تولیدی

قدم ۱) طرح ریزی معماری مدل: در این مرحله، چهارچوب کلی کار از قبیل هدف از مدل سازی، محدودیت ها و پیش فرض ها مشخص می شود.

قدم ۲) جمع آوری و آماده سازی داده ها: در مدل سازی عصبی با استفاده از ANNs، داده های فراهم شده برای برازش مدل، لازم است تا در یک عبارت کلی، نماینده جامعه ای باشند که از آن انتخاب شده اند (ارضای شرط یکپارچگی، کفایت و تصادفی بودن). با توجه به ارتباط تعداد داده های برازش به میزان پیچیدگی فرآیند، لازم است تا تعداد داده های مورد نیاز برای آموزش به صورت اقتضایی مشخص شود. سه رویکرد متفاوت برای تهیه داده های برازش مدل، عبارت اند از ۱) روش مستقیم (پرکاربردترین

روش برای مدل‌سازی فرایندهای تولیدی [۸]، (۲) روش شبیه‌سازی و (۳) روش طراحی آزمایش‌ها، که عیب عمده این روش، مدل‌سازی غیر واقعی از فرآیند، هزینه بر بودن آن و هم‌چنین پیش فرض قرار دادن رابطه خطی بین متغیرهای ورودی با متغیر خروجی فرآیند است. مضاف بر شروط یکپارچگی، کفایت و تصادفی بودن، لازم است تا به منظور افزایش کارایی فرایند برآزش قبل از ارایه داده‌ها به مدل، نسبت به پیش پردازش داده‌ها در دامنه‌ای مشخص اقدام شود.

قدم ۳) انتخاب ساختار مدل: انتخاب ساختار مدل عصبی، با توجه به مأموریت شبکه، می‌تواند از چهار مدل اصلی ART، مدل‌های MLP، مدل‌های RAN و یا مدل‌های SOM انتخاب شود. با توجه به کاربرد وسیع مدل‌های MLR در نگاشت روابط خطی و غیر خطی و کاربردهای مهندسی، غالباً در مدل‌سازی فرآیندهای تولیدی از مدل MLR استفاده می‌شود [۱۶]. پس از تعیین ساختار کلی مدل، لازم است تا نسبت به تعیین جزئیات ساختار مدل از جمله تعداد نرون لایه ورودی (بر اساس تعداد متغیر ورودی)، تعداد لایه‌های میانی (به روش سعی و خطا)، تعداد نرون لایه خروجی (بر اساس تعداد متغیر خروجی) و نوع تابع فعال‌سازی (به روش سعی و خطا)، اقدام شود [۷].

قدم ۴) انتخاب معیارهای مناسبت برآزش: مناسبت برآزش مدل در مدل‌سازی عصبی، از طریق توقف فرایند آموزش مدل عصبی مشخص می‌شود. سه معیار برای توقف آموزش در مدل MLR وجود دارد که به محض تحقق هر یک، مرحله آموزش به نشانه مناسبت برآزش و صحت مدل، متوقف می‌شود. این معیارها عبارت‌اند از: ۱) کمتر شدن مقدار میانگین مربعات خطا (MSE) در هر سیکل یا Epoch از مقدار تعیین شده قبلی، ۲) تغییرات نامحسوس در نرم‌گرادیان خطا در تکرارهای متوالی و یا کمتر شدن مقدار نرم‌گرادیان خطا از مقدار تعیین شده قبلی و ۳) افزایش تعداد تکرارها از مقدار تعیین شده قبلی [۱۲].

قدم ۵) تخمین پارامترهای مدل (برآورد مدل): تخمین پارامترهای مدل عصبی، در اصل همان ارایه داده‌ها به شبکه و آموزش آن است که با هدف تنظیم پارامترهای داخلی (وزن‌ها و بایاس‌ها) شبکه انجام می‌گیرد. چنانچه به شبکه اجازه داده شود تا از طریق تنظیم پارامترهای داخلی، متغیرهای موثر را از متغیرهای غیر مؤثر بر مدل تفکیک کند، رویکرد اتخاذ شده یک رویکرد عمومی است و در صورتی که متغیرهای مؤثر بر مدل، با تکیه به روش‌های دیگر از جمله بهره‌گیری از تحلیل‌های آماری همچون تحلیل واریانس

گزینش شوند، رویکرد اتخاذ شده یک رویکرد متمرکز است [۲۱]. در مرحله آموزش لازم است تا در مورد پارامترهای اجرای آموزش؛ از جمله نوع الگوریتم آموزش، نرخ یادگیری (α)، ضریب ممنتوم (μ)، نحوه ارایه داده‌ها (تصادفی یا دوره‌ای) و هم‌چنین معیارهای توقف آموزش، تصمیم‌گیری به عمل آید.

قدم ۶) صحنه‌گذاری مدل: صحنه‌گذاری در مدل‌سازی عصبی، در اصل همان بررسی معیارهای توقف برای دسته‌ای گزینش شده از داده‌های آموزش می‌باشد که داده‌های صحنه‌گذاری نامیده می‌شود. در حین فرایند آموزش معیارهای توقف آموزش برای این دسته از داده‌ها مورد بررسی لحظه به لحظه قرار می‌گیرد و چنانچه آموزش متوقف گردد و تابع خطای فرآیند آموزش (MSE) کمتر از مقدار تعیین شده توسط کاربر باشد فرآیند آموزش به معنای دستیابی به یک مدل قابل قبول متوقف می‌شود.

قدم ۷) انتخاب معیارهای ارزیابی پایایی مدل: معیارهای ارزیابی پایایی که به منظور بررسی قدرت پیش‌بینی مدل عصبی فرآیند انتخاب شده‌اند، عبارت‌اند از [۱۶]: الف) ضریب تعیین (R^2) بین مقادیر خروجی واقعی و مقادیر پیش‌بینی شده توسط شبکه که مطابق رابطه (۳) محاسبه می‌گردد.


$$R^2 = 1 - \left(\frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \right)$$

بهترین عملکرد موقعی است که R^2 مقداری نزدیک به ۱ داشته باشد و مقدار صفر برای R^2 نشان دهنده آن است که مقادیر خروجی برآورد شده توسط مدل به مقادیر واقعی خروجی نزدیک نمی‌باشد؛ ب) شاخص میانگین خطای نسبی (MRE) که نشان دهنده متوسط قدر مطلق نسبت خطا به مقادیر واقعی می‌باشد و ج) شاخص جذر میانگین مربعات خطا (RMSE) که میانگین مربعات خطاهای محاسبه شده از مقادیر واقعی و مقادیر پیش‌بینی شده را نشان می‌دهد. هر چه MRE و RMSE مقادیر کمتری داشته باشند نشان دهنده آن است که مدل با خطای کمتری نسبت به پیش‌بینی مقادیر خروجی اقدام می‌نماید.

قدم ۸) ارزیابی پایایی مدل: در این مرحله لازم است تا با توجه به معیارهای انتخاب شده در قدم (۷) و جمع‌آوری داده‌هایی مستقل از داده‌های برازش مدل، اما در محدوده‌ای گسترده تر (با هدف اندازه‌گیری پایایی در برون‌یابی و درون‌یابی مدل)، نسبت به محاسبه و تحلیل پایایی مدل اقدام شود.

۵. متدولوژی مدل سازی عصبی و عصبی - آماری فرآیند اسپری درایینگ


در این مرحله به منظور بررسی تاثیر اعمال تحلیل های رگرسیونی بر ارتقاء پایایی مدل عصبی فرآیند اسپری درایینگ، اقدام به معماری دو مدل عصبی با رویکرد عمومی و مدل عصبی - آماری با اتخاذ رویکرد متمرکز (توجه به نتایج تحلیل های رگرسیونی در مدل سازی عصبی) شده است. با توجه به مطالعات مشابه قبلی در زمینه مدل سازی فرآیند اسپری درایینگ [۲۶ و ۴]، با اتخاذ یک رویکرد عمومی، ساختار MLP و الگوریتم آموزشی پس انتشار خطا PB (مبتنی بر قانون لونبرگ مارکوارت) برای مدل عصبی فرایند اسپری درایینگ انتخاب گردیده است. به منظور دستیابی به بهترین پیکره بندی برای شبکه مدل عصبی فرآیند، شبکه های مختلفی شامل ۱ الی ۳ لایه مخفی با تعداد متغیر از نرون لایه مخفی و همچنین توابع محرک متفاوت در نظر گرفته شد. نتایج ارزیابی مناسب هر یک از این شبکه ها بر اساس تابع خطای شبکه بیانگر این مطلب بود که شبکه ای با دو لایه مخفی شامل ۱۲ و ۱۴ نرون با توابع محرک تانژانت سیگموئید، لگ سیگموئید و تابع محرک خطی به ترتیب برای لایه های آن می تواند بهترین پیکره بندی برای شبکه مدل عصبی باشد. جزییات بیشتر این شبکه، در قالب نمودار شماره (۳) قابل مشاهده می باشد.



نمودار ۳. پیکره بندی شبکه مدل عصبی فرآیند اسپری درایینگ

در مدل سازی عصبی، تمامی ۷ متغیر شناسایی شده و ۱۰۰ داده تهیه شده برای برازش مدل مورد استفاده قرار می گیرد. در مدل سازی عصبی - آماری فرایند در ابتدا با توجه به نتایج تحلیل رگرسیون، مقدار متغیر \dot{T}_O با استفاده از الگوریتم ANNs برآورد شده و سپس مقادیر برآورد شده \dot{T}_O و مقادیر اندازه گیری شده ρ و همچنین مقادیر \dot{T}_{in} ، P_p و P_s به مدل ارائه می شود. ارایه مقادیر \dot{T}_{in} ، P_p و P_s به مدل عصبی - آماری فرآیند به دلیل وجود همبستگی بین این متغیرها با متغیر \dot{T}_O صورت می گیرد زیرا این همبستگی می تواند نشانه ای بر وجود اثرات متقابل بین متغیرها و تاثیر گذاری بر S_3 باشد. نتایج رگرسیونی لحاظ شده

در معماری مدل عصبی- آماری عبارت‌اند از: (۱) وجود ۹ نمونه پرت در نمونه ۱۰۰ تایی داده‌های برازش مدل، (۲) عدم تاثیر گذاری متغیر T_s بر متغیر پاسخ S_3 و (۳) احتمال وجود اثرات متقابل بین متغیرهای T_{in} ، P_p و P_s و لزوم حضور این متغیرها در مدل. پیکره بندی شبکه مدل عصبی- آماری فرآیند اسپری درآینگ طبق روالی مشابه با پیکره بندی شبکه مدل عصبی انجام گرفت و جزئیات آن در قالب نمودار شماره (۴) قابل مشاهده می‌باشد. نتایج ارزیابی مناسبیت شبکه‌های پیشنهادی بر اساس تابع خطای شبکه بیانگر این مطلب بود که شبکه‌ای با دولایه مخفی شامل ۱۲ و ۱۸ نرون با توابع محرک تانژانت سیگموئید، لگ سیگموئید و تابع محرک خطی به ترتیب برای لایه‌های آن می‌تواند بهترین پیکره بندی برای شبکه مدل عصبی- آماری باشد.



نمودار ۴. پیکره بندی شبکه مدل عصبی- آماری فرآیند اسپری درآینگ

به منظور دستیابی به پیکره بهینه شبکه و یا به عبارتی برازش مدل، داده‌های برازش مدل عصبی و عصبی- آماری فرایند با استفاده از نرم افزار MATLAB، به مدل‌ها ارایه و آموزش انجام گرفت. معیارهای مناسبیت برازش مدل‌های عصبی و عصبی- آماری فرآیند اسپری درآینگ و نتایج کسب شده در لحظه توقف آموزش مطابق با نگاره شماره (۳) ارایه شده است.

نگاره ۳. جدول معیارهای و نتایج توقف آموزش مدل عصبی و عصبی- آماری فرآیند اسپری

نتایج در لحظه توقف			معیارهای توقف			
GRAD	Epoch	MSE	GRAD	Epoch	MSE	
0.0015223	19	0.023765	1e-010	100	1e-005	مدل عصبی
0.0010241	19	0.058235	1e-010	100	1e-005	مدل عصبی- آماری

مدل‌های عصبی و عصبی- آماری پس از برازش با استفاده از شاخص‌های ارزیابی پایایی، و یک مجموعه داده ۲۸ تایی به‌عنوان داده‌های ارزیابی پایایی مدل که مستقل از داده‌های آموزش بوده و در محدوده‌ای گسترده‌تر جمع‌آوری شده‌اند، تحت اندازه‌گیری پایایی قرار گرفتند و نتایج $R^2=73.49$ ، $MRE=1.92$ و $RMSE=1.44$ گرم برای مدل عصبی فرایند و نتایج $R^2=79.12$ ، $MRE=1.682$ و $RMSE=1.343$ گرم برای مدل عصبی- آماری فرایند اخذ شد.

۶. بحث و بررسی نتایج


نتایج ارزیابی پایایی مدل‌های عصبی و عصبی- آماری با به کارگیری سه شاخص ارزیابی پایایی در قالب نگاره شماره (۴) قابل مشاهده می‌باشد.

نگاره ۴. جدول نتایج ارزیابی پایایی برای مدل عصبی و عصبی- آماری فرایند اسپری درآینگ

RMSE	MRE	R^2	
1.44	1.92%	73.49%	مدل عصبی
1.343	1.682%	79.12%	مدل عصبی- آماری


با مقایسه نتایج ارزیابی پایایی این دو مدل می‌توان بهبود ۵.۶۳ در ضریب تعیین، کاهش ۰.۲۴ در میانگین خطای نسبی و کاهش ۰.۰۹۷ گرم در جذر میانگین مربعات خطا را در مدل عصبی- آماری در مقایسه با مدل عصبی مشاهده کرد و از این طریق تاثیر اعمال تحلیل‌های رگرسیونی را در بهبود قدرت پیش‌بینی مدل عصبی فرایند اسپری درآینگ، مثبت ارزیابی کرد. ذکر این نکته ضروری به نظر می‌رسد در صورتی که برای پیش‌بینی فرایند الزام به برآورد \bar{T}_0 و تحمل خطای ناشی از این برآورد وجود نداشته باشد مدل عصبی- آماری عملکرد بهتری را نشان می‌داد.

به منظور تحلیل بین داده‌ای مقادیر پیش‌بینی شده برای S_3 توسط مدل‌های عصبی و عصبی- آماری فرایند اسپری درآینگ، نمودار روند شماره (۵) برای داده‌های ۲۸ تایی ارزیابی پایایی، رسم گردیده است.



نمودار ۵. نمودار روند مقادیر پیش‌بینی شده با مدل عصبی و عصبی - آماری در مقایسه با مقادیر واقعی برای داده‌های ۲۸ تایی ارزیابی پایایی

در این نمودار که به منظور سهولت مقایسه و نمایش پایایی مدل عصبی - آماری در مقابل مدل عصبی ارایه شده است، مقادیر واقعی خروجی فرآیند (S_3) با علامت دایره و به همین ترتیب علامت مثلث و ضربدر نشان دهنده مقادیر پیش‌بینی شده توسط مدل عصبی و مدل عصبی - آماری فرآیند است. با مشاهده مغایرت بین مقادیر واقعی و مقادیر پیش‌بینی شده توسط مدل‌های عصبی و عصبی - آماری، به خصوص در محدوده‌ای خارج از محدوده طبیعی تغییر خروجی فرآیند (نمونه‌های شماره ۱۳، ۱۲، ۱۵، ۱۴، ۱۶) می‌توان به پایایی مدل عصبی - آماری در درون‌یابی و برون‌یابی مقادیر S_3 در مقایسه با مدل عصبی پی برد. به منظور کنترل پیش‌بینانه کیفیت با استفاده از خروجی‌های مدل عصبی - آماری فرآیند اسپری درآینگ سناریوهای مختلفی برای تنظیم ورودی‌های فرآیند، در دامنه‌ای گسترده از دامنه نرمال تغییرات متغیرها، در قالب نمودار شماره (۶) ارایه شده است، همان گونه که در این نمودار مشاهده می‌شود، مقادیر S_3 در حالی که ρ در دامنه ۱.۶۶ الی ۱.۶۹ گرم بر سانتیمتر مکعب و \dot{T}_0 در دامنه ۹۲ الی ۱۰۵ درجه سانتیگراد تغییر می‌نماید، توسط مدل "عصبی - آماری" برآورد شده است.



نمودار ۶. سناریوهای مختلف تنظیم ورودی‌ها بر اساس دانسیته و دمای خروجی با استفاده از مدل "عصبی-آماري"

مطابق با نمودار شماره (۶) وجود یک رابطه مستقیم بین ρ و S_3 و همچنین بین \dot{T}_O و S_3 قابل تایید می‌باشد، البته در مواردی نیز ممکن است این قاعده نقض گردد که می‌توان به وجود اثرات متقابل بین متغیرهای ورودی بر متغیر خروجی S_3 مرتبط دانست. بنابراین با بهره‌گیری از مدلی مطمئن و پایا برای پیش‌بینی خروجی فرایند (مدل عصبی-آماري) و طراحی سناریوهای مختلف برای ورودی‌ها، می‌توان کیفیت خروجی فرآیند را با توجه به مقادیر پیش‌بینی شده برای S_3 توسط مدل عصبی-آماري پیش‌بینی کرد.

۷. نتیجه‌گیری

در این مقاله سعی شد تا از طریق مورد کاوی (فرآیند اسپری درآینگ)، مراحل معماری مدل عصبی فرآیند با استفاده از شبکه MLP بر اساس BP با اتخاذ رویکرد عمومی در مدل‌سازی و همچنین مدل عصبی-آماري فرآیند با اتخاذ رویکرد متمرکز در مدل عصبی با توجه به نتایج تحلیل رگرسیونی، تشریح گردد و پس از برآزش مدل با استفاده از داده‌های ۲۸ تایی ارزیابی، نسبت به ارزیابی پایایی مدل‌ها اقدام شود. این ارزیابی پایایی با استفاده از داده‌هایی مستقل و در دامنه‌ای گسترده‌تر از داده‌های برآزش انجام گرفت به طوری که بتواند قدرت درونیابی و برون‌یابی مدل‌ها در پیش‌بینی کیفیت خروجی فرآیند را نشان دهد. نتیجه مقایسه ارزیابی پایایی مدل‌های عصبی و عصبی-آماري، به صورت بین

نمونه‌ای، بیانگر قدرت نسبی مدل‌های عصبی-آماری در برون‌یابی و درون‌یابی فرآیند اسپری درآینگ بود و با مقایسه نتایج ارزیابی پایایی مدل عصبی و عصبی-آماری با استفاده از شاخص‌های ارزیابی پایایی می‌توان به نقش موثر تحلیل‌های رگرسیونی در بهبود پایایی مدل عصبی فرآیند اسپری درآینگ پی برد؛ هر چند که این بهبود را با ارایه داده‌های آموزش بیشتر می‌توان ارتقاء بخشید. پس از حصول اطمینان از برتری مدل عصبی-آماری با طراحی سناریوهای مختلف برای تنظیم ورودی‌ها و تفسیر و استنتاج روابط بین متغیرها، تا حد زیادی مساله در بسته بودن مدل‌های عصبی رفع و از این طریق کنترل پیش‌بینانه کیفیت جایگزین روش‌های پر هزینه مبتنی بر سعی و خطا می‌شود.

Archive of SID

منابع

1. Afzulpurkar N.V., Saeed I.A.K. and Vyawahare V.S. (2006). "Ceramic tile Process Modeling for Quality Improvement Using ANNs", ICIT IEEE International Conference on Industrial Technology.
2. Andersen K., Cook G.E. and Ramaswamy K. (1990). "Artificial Neural Networks Applied to Arc Welding Process Modeling and Control", IEEE Transaction on Industrial Application, Vol 26, pp. 824-830.
3. Ben Brahim S., Smith A.E. and Bopaya B. (1993). "Relating Product Specifications and Performance Data with a Neural Networks Model for Design Improvement", Journal of Intelligent Manufacturing, Vol. 4, pp. 231-243.
4. Chegini G.R., Khazaei J., Ghobadian B. and Goudarzi A.M. (2008) "Prediction of process and product parameters in an orange juice spray dryer using artificial neural networks" Journal of Food Engineering, Vol. 84, pp. 534-543.
5. Coit D.W., Jackson B.T. and Smith A. (1997). "Static neural network process models: Considerations and case studies", Journal of Production Research, Vol. 13, pp. 145-175.
6. Cook D.F., Ragsdale C.T. and Major R.L. (2000). "Combining a Neural with a Genetic Algorithm for Process Parameter-Optimization" Engineering Application of Artificial Intelligent, Vol. 13, pp. 391-396.
7. Erginel N. and Ay N. (2005). "How Process Factor Affect Ceramic Tile Color", American Ceramic Society Bulletin, Vol. 84, No. 7, pp. 9201-9203.
8. Edwards P.J., Murray A.F., Papadopoulos G., Wallace A.R., Barnard J. and Smith G. (1999). "The application of Neural Networks to the Paper Making Industry", IEEE Transaction on Neural Networks, Vol. 10, No. 6, pp. 1456-1464.
9. Hornik K., Stinchcombe M. and White H. (1989). "Multilayer Feed Forward Networks Are Universal Approximators", Neural Networks, Vol. 2, pp. 359-366.
10. Hosoz M., Ertunc H.M. and Bulgurcu H. (2007). "Performance Prediction of a Cooling tower Using Artificial Neural Network", Journal of Energy Conversion and Management, Vol. 48, pp. 1349-1359.

11. Lam S.S., Petri K.L. and Smith A.E. (2000). "Prediction and Optimization of a Ceramic Casting Process Using a Hierarchical Hybrid System of Neural Networks and Fuzzy Logic" IEEE Transaction on design and manufacturing, Vol. 32, pp. 83-91.
12. Mehrotra S.P. (1986). "Role of Mathematical Modeling in Metallurgy" Bulletin Master Science, Vol. 12, pp. 354-363.
13. Magali R.G., Meireles P.E. (2003). "A Comprehensive Review for Industrial Application of Artificial Neural Networks", IEEE Journal, Vol. 50, pp. 3-12.
14. Martinez S.E., Smith A.E. and Bopaya B. (1993). "Reducing Waste in Casting With a Predictive Neural Model", Journal of Intelligent Manufacturing System, Vol. 4, pp. 23-31.
15. Nascimento C.A.O., Giudici R. and Guardani R. (2000). "Neural Net Based Approach for Optimization of Industrial Chemical Process", Computer and Chemical Engineering, Vol. 24, pp. 2303-2374.
16. Prats-Montalban J.M. and Ferrer A. (2008). "Integration of Color and Textural Information in Multivariate Image Analysis: Defect Detection and Classification Issues", Journal of Chemometrics, Vol. 21, No. 2, pp. 10-23.
17. Ramesh M.C., Rajamanickam R. and Jayaraman S. (1995). "The Prediction of Yarn Tensile Properties by Using Artificial Neural Networks" The Journal of the Textile Institute, Vol. 86, No. 3, pp. 456-469.
18. SACMI Corporation (1989). "From Technology Through Machinery to Kilns for SACMI Tile, Italy", SACMI Press.
19. Saxen H. and Petterson F. (2006). "Methods for the Selection of Nputs and Structure of Feedforward Neural Networks" Computers and Chemical Engineering, Vol. 30, pp. 1038-1045.
20. Senturk S. and Erginel N. (2005). "Anfis Applied to the Color Problem of Ceramic Tile", American Ceramic Society Bulletin, Vol. 87, No. 8, pp. 123-140.
21. Smith A.E. and Dagli C.H. (1991). "Controlling Industrial Process Through Supervised Feedforward Neural Networks", Computer & Industrial Engineering, Vol. 21, pp. 247-251.

22. Smith A.E. and Dagli C.H. (1991). "Relating Binary and Continuous Problem Entropy to Back Propagation Network Architecture" In Application of Artificial Neural Networks, Vol. 14, pp. 551-562.
23. Su C. and Hsieh K.L. (1998). "Applying Neural Network Approach to Achieve Robust Design for Dynamic Quality Characteristics", International Journal of Quality and Reliability Management, Vol. 15, No. 5, pp. 509-519.
24. Sukthomya W., Tannock J. (2005). "The Training of Neural Networks to Model Manufacturing Process", Journal of Intelligent Manufacturing, Vol. 16, pp. 39-51.
25. Twomey J. and Smith A. (1998). "Bias and Variance of Validation Models for Function Approximation", Neural Networks under Condition of Sparse Data, IEEE Transaction on System and Cybernetics, Vol. 28, No. 3, pp. 231-239.
26. Youssefi Sh., Emam-Djomeh Z. and Mousavi S.M. (2009), Comparison of Artificial Neural Network (ANN) and Response Surface Methodology (RSM) in the prediction of quality parameters of spray-dried pomegranate juice, Drying Technology, Vol. 27, No. 7, pp. 910-917.

Archive of SID