

شناسایی ترکیب غیرمسلط عوامل کنترلی در مسئله‌ی چندپاسخه با استفاده از شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک

مهدی بشیری* (دانشیار)

امیر فرشباف گرانمایه (کارشناسی ارشد)
گروه مهندسی صنایع، دانشگاه شاهد

یافتن بهترین ترکیب عوامل کنترلی برای بهینه‌سازی توأمان چندین متغیر پاسخ که اکثراً با یکدیگر در تضادند، یکی از مهم‌ترین نیازهای مسائل صنعتی است. روش معمول برای حل این‌گونه مسائل استفاده از رگرسیون چندجمله‌یی برای شناسایی روابط بین عوامل کنترلی و متغیرهای پاسخ است، در حالی که شبکه‌ی عصبی مصنوعی در حالاتی که این روابط پیچیده باشد قابلیت مناسب‌تری از خود نشان می‌دهند. در این نوشتار، برخلاف حالت‌های به کار برده شده، متغیرهای پاسخ به‌عنوان ورودی و عوامل کنترلی به‌عنوان خروجی شبکه‌ی عصبی مصنوعی در نظر گرفته شده‌اند تا با ترکیب شبکه‌ی عصبی مصنوعی، تکنیک محدودیت جزئی (و الگوریتم ژنتیک بتوان ترکیبات غیرمسلط کارایی در مسئله‌ی چندپاسخه ارائه داد. قابلیت روش ارائه‌شده در قالب مثال عددی بیان شده است که نشان‌دهنده‌ی کارایی روش پیشنهادی نسبت به سایر رویکردهای موجود است.

واژگان کلیدی: مسئله‌ی چندپاسخه، جواب غیرمسلط، شبکه‌ی عصبی مصنوعی، محدودیت جزئی، الگوریتم ژنتیک.

۱. مقدمه

انتخاب مناسب متغیرهای ورودی قابل کنترل به یک فرایند صنعتی برای دستیابی به متغیرهای پاسخ مناسب یکی از مسائل معمول در کنترل کیفیت است. در بیشتر مسائل صنعتی با بیش از یک متغیر پاسخ سر و کار داریم و بهبود همزمان آنها از اهمیت ویژه‌ی برخوردار است. مشکل معمول در بهینه‌سازی همزمان متغیرهای پاسخ، متفاوت و گاهی متضاد بودن جهت بهینگی آنهاست. در نتیجه بهینه‌سازی فرایند تولید نسبت به یک متغیر پاسخ منجر به مقادیر غیربهینه‌ی سایر پاسخ‌ها می‌شود. از این رو طراحی روشی که به بهینه‌سازی همزمان متغیرهای پاسخ بپردازد از اهمیت خاصی برخوردار است. نکته‌ی قابل توجه دیگر در فرایند بهینه‌سازی پاسخ‌ها، تخمین رابطه‌ی بین متغیرهای قابل کنترل و متغیرهای پاسخ است. در مواردی که رابطه‌ی بین متغیرهای پاسخ و عوامل کنترلی پیچیده‌تر باشد، روابط رگرسیونی توانایی تخمین مناسب این روابط را ندارند. در برخی از پژوهش‌ها، توانایی شبکه‌ی عصبی مصنوعی در تخمین مناسب این رابطه با سایر ابزارها -- نظیر رگرسیون و سطح پاسخ -- مقایسه شده که نتایج حاصل از آنها نشان‌گر قابلیت بالای شبکه‌ی عصبی مصنوعی در تخمین این رابطه بوده است. در جدول ۱ این پژوهش‌ها به صورت خلاصه ذکر شده است.

* نویسنده مسئول

تاریخ: دریافت ۱۳۹۰/۱۲/۲۲، اصلاحیه ۱۳۹۱/۱۲/۲۶، پذیرش ۱۳۹۲/۲/۲۵.

bashiri@shahed.ac.ir
farshbaf@shahed.ac.ir

پژوهش‌گران زیادی با استفاده از شبکه‌ی عصبی مصنوعی به حل مسائل چندپاسخه پرداخته‌اند. اغلب این پژوهش‌ها از سه مرحله تشکیل شده‌است: ۱. ایجاد شبکه‌ی روابط بین عوامل کنترلی و متغیرهای پاسخ؛ ۲. تبدیل چند متغیر پاسخ به یک متغیر پاسخ؛ ۳. بهینه‌سازی متغیر تک‌پاسخه. آنها ابتدا از شبکه‌ی عصبی مصنوعی برای شناسایی روابط بین عوامل کنترلی و متغیرهای پاسخ استفاده کرده‌اند. رویکرد «توابع مطلوبیت» پرکاربردترین روش برای تجمیع متغیرهای پاسخ است؛ بعد از تجمیع، بهینه‌سازی متغیر پاسخ تجمیع شده با استفاده از یکی از روش‌های بهینه‌سازی انجام شده است. برخی از محققین این رویکرد را برای متغیرهای کیفی و همچنین محیط‌های دینامیک توسعه داده‌اند. تعدادی از این رویکردها به تفکیک روش‌های استفاده شده در هر سه مرحله‌ی مذکور در جدول ۲ ذکر شده است.

در مسائل بهینه‌سازی چندپاسخه، انتخاب جواب‌های غیرمسلط در مقایسه با یافتن جواب بهینه‌ی حاصل از تجمیع پاسخ‌ها از ارزش بالاتری برخوردار است؛ چرا که نقطه‌ی بهینه‌ی انتخاب شده خود یکی از جواب‌های غیرمسلط در مسئله‌ی مورد نظر است.

با توجه به جدول ۲ می‌توان مشاهده کرد که فقط یکی از مطالعات انجام‌شده^[۱] نهایتاً چندین جواب غیرمسلط را برای انتخاب به تصمیم‌گیرنده ارائه می‌دهد. در این مطالعه جواب‌های غیرمسلط از میان ترکیبات ممکن عوامل کنترلی (با توجه به سطوح انتخاب شده برای طراحی آزمایشات تاگوچی) است. به عبارت دیگر، می‌توان

جدول ۱. مطالعات صورت گرفته برای مقایسه‌ی قابلیت شبکه‌ی عصبی مصنوعی و سایر روش‌های موجود در تخمین متغیرهای پاسخ.

منبع	روش‌های مقایسه‌شده در مطالعه	نتایج مقایسه
[۲]	مدل سطح پاسخ و شبکه‌ی عصبی مصنوعی	بیشینه خطای آزمایش برای مدل شبکه‌ی عصبی ۱/۴۸٪ و برای سطح پاسخ ۵/۲٪ است.
[۳]	روش سطح پاسخ و شبکه‌ی عصبی مصنوعی تابع شعاع مدار	نتایج نشان‌دهنده‌ی این است که شبکه‌ی تابع شعاع مدار برای ارزیابی نیروی محوری در عملیات مته‌کاری مناسب است.
[۴]	روش سطح پاسخ و رویکرد شبکه‌ی عصبی - الگوریتم ژنتیک	خطای پیش‌بینی به‌وسیله‌ی شبکه‌ی عصبی ۲ درصد و برای روش سطح پاسخ ۸ درصد است.
[۵]	شبکه‌ی عصبی مصنوعی، رگرسیون بردار پشتیبان (SVR*)، رگرسیون و روش سطح پاسخ	شبکه‌ی عصبی مصنوعی و رگرسیون بردار پشتیبان (SVR*) در تخمین متغیرهای پاسخ بهتر از رگرسیون و روش سطح پاسخ عمل می‌کنند.
[۶]	شبکه‌ی عصبی مصنوعی و روش سطح پاسخ	نتایج نشان‌دهنده‌ی مقادیر مناسب ضریب همبستگی برای روش سطح پاسخ است ولی شاخص‌های AAD و RMSE برای این روش زیاد مناسب نیستند. در حالی که نتایج حاصل از پیش‌بینی با استفاده از شبکه‌ی عصبی مصنوعی، نشان‌دهنده‌ی این است که هر چهار شاخص فوق مطلوب‌اند.

* support vector regression


جدول ۲. مطالعات صورت گرفته برای حل مسائل چندپاسخه که از شبکه‌ی عصبی مصنوعی برای تخمین روابط استفاده کرده‌اند.

ردیف	ویژگی اصلی	منبع	نوع شبکه‌ی عصبی مصنوعی مورد استفاده	روش مورد استفاده برای تجمیع پاسخ‌ها	روش مورد استفاده برای بهینه‌سازی	یافتن چندین حل غیرمسلط (NDS*)
۱		[۷]	پس‌انتشار پیش‌خور	تابع مطابقت	الگوریتم ژنتیک	
۲		[۸]	پس‌انتشار پیش‌خور	تابع مطابقت		
۳		[۹]	پس‌انتشار پیش‌خور			بلی
۴	حل مسئله‌ی چندپاسخه با استفاده از	[۹]	پس‌انتشار پیش‌خور		کارترین ترکیب از بین ترکیبات کارا	
۵	شبکه‌ی عصبی مصنوعی	[۱۰]	پس‌انتشار پیش‌خور	تابع مطابقت نمایی	الگوریتم جست‌وجوی ممنوعه	
۶		[۱۱]	پس‌انتشار پیش‌خور	تابع مطابقت		
۷		[۱۲]	پس‌انتشار پیش‌خور	تابع مطابقت	الگوریتم ژنتیک	
۸		[۱۳]	پس‌انتشار پیش‌خور	تابع مطابقت نمایی	الگوریتم تبرید تدریجی	
۹		[۱۴]	پس‌انتشار پیش‌خور	تابع مطابقت نمایی	الگوریتم ژنتیک	
۱۰	در نظر گرفتن متغیرهای کیفی	[۱۵]	دو شبکه‌ی پس‌انتشار پیش‌خور			
۱۱		[۱۶]	تابع شعاع مدار و پس‌انتشار پیش‌خور	تابع مطابقت	الگوریتم ژنتیک	
۱۲	یافتن مؤثرترین عنصر	[۱۷]	دو شبکه‌ی پس‌انتشار پیش‌خور	تابع مطابقت		
۱۳	در نظر گرفتن وزن برای متغیرهای پاسخ	[۱۸]	دو شبکه‌ی پس‌انتشار پیش‌خور	تابع مطابقت		
۱۴	در نظر گرفتن همبستگی متغیرهای پاسخ	[۱۹]	شبکه‌ی پس‌انتشار پیش‌خور			
۱۵		[۲۰]	شبکه‌ی پس‌انتشار پیش‌خور	تحلیل مؤلفه‌ی اصلی (PCA**) تحلیل رابطه‌ی خاکستری (GRA***)	الگوریتم ژنتیک	
۱۶		[۲۱]	شبکه‌ی پس‌انتشار پیش‌خور	تحلیل مؤلفه‌ی اصلی (PCA) تحلیل رابطه‌ی خاکستری (GRA)	الگوریتم تبرید تدریجی	

* non-dominated solution (NDS)

** principal component analysis (PCA)

*** grey relational analysis (GRA)



شکل ۱. توپولوژی شبکه‌ی عصبی مصنوعی در رویکرد پیشنهادی.

می‌شوند؛ اگر شبکه شروع به انطباق بیش از حد داده‌ها کند، خطای اعتبارسنجی افزایش می‌یابد. وقتی که خطای اعتبارسنجی به تعداد تکرار مشخصی افزایش یابد، فرایند آموزش متوقف می‌شود و وزن‌ها و بایاس‌های مربوط به تکراری که در آن خطای اعتبارسنجی کم‌ترین مقدار را دارد به عنوان وزن و بایاس نهایی بازگردانده می‌شوند.

میانگین قدرمطلق درصد خطا (MAPE)^۲ در مورد داده‌های آزمون و اعتبارسنجی و میانگین قدرمطلق درصد خطای داده‌های آموزش برای انتخاب ساختار مناسب شبکه‌ی عصبی مصنوعی به منظور آموزش روابط بین عوامل کنترلی و متغیرهای پاسخ کاربرد دارند. میانگین قدرمطلق درصد خطا یکی از معیارهای اندازه‌گیری استاندارد است که مطابق رابطه ۱ نشان داده می‌شود:^[۲۴]

$$MAPE = \frac{1}{M} \sum_{i=1}^M \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100 \quad (1)$$

و در آن، y_i مقدار هدف، \hat{y}_i خروجی شبکه‌ی عصبی مصنوعی، و M مجموع تعداد مجموعه داده‌های آزمون و اعتبارسنجی است.

ب) تولید جواب‌های غیرمسلط با استفاده از الگوریتم ژنتیک

پس از طراحی و ایجاد شبکه‌ی عصبی مصنوعی مورد نظر، به شناسایی جواب‌های غیرمسلط مورد نظر در این گام می‌پردازیم. چنانچه تمامی متغیرهای پاسخ را از نوع هرچه بیشتر بهتر (LTB)^۳ در نظر بگیریم، جواب \bar{x} غیر مسلط است اگر و فقط اگر $x \in \Omega$ وجود نداشته باشد که به ازای $i = 1, 2, \dots, I$ نامعادله $\hat{y}_i(x) \geq \hat{y}_i(\bar{x})$ و برای دست کم یکی از i ها نامعادله‌ی فوق به صورت اکید برقرار باشد. به مجموعه‌ی جواب‌های غیرمسلط، مجموعه‌ی بهینه‌ی پارتو اطلاق می‌شود.

برای تولید جواب‌های غیرمسلط براساس مطالعات پیشین روش‌های متفاوتی ارائه شده که از آن جمله می‌توان به روش وزن‌دهی^۴،^[۲۵] روش محدودیت جزئی،^[۲۶] و روش اندازه‌ی وزن‌دهی شده^۵،^[۲۷] اشاره کرد.

گفت که جواب‌های غیرمسلط از فضای گسسته انتخاب شده است. گفتنی است محققین دیگری نیز در گام آخر پژوهش خود جواب‌هایی با تابع مطلوبیت کلی بالا به تصمیم‌گیرنده ارائه می‌دهند،^[۸] اگرچه جواب‌های ارائه شده الزاماً غیرمسلط نیستند. در این نوشتار، با استفاده از شبکه‌ی عصبی مصنوعی، تکنیک محدودیت جزئی و الگوریتم ژنتیک روشی نوین برای تولید جواب‌های غیرمسلط کارا به تصمیم‌گیرنده ارائه شده است.

برخی از محققین نیز با استفاده از روش محدودیت جزئی به تولید جواب غیرمسلط در مسئله‌ی چندپاسخ پرداخته‌اند. آنان ابتدا با استفاده از داده‌های حاصل از طراحی آزمایشات به ساخت مدل رابطه بین عوامل کنترلی و متغیرهای پاسخ پرداخته‌اند.^[۲۴] سپس با استفاده از روش محدودیت جزئی جواب‌های غیرمسلط مسئله را تولید کرده و در نهایت با توجه به نظر DM رویکردی مبتنی بر نمایش گرافیکی متغیرهای پاسخ برای انتخاب بهترین جواب از بین جواب‌های غیرمسلط تولید شده ارائه کرده‌اند. چنانچه تعداد متغیرهای پاسخ افزایش یابد، این رویکرد با توجه به استفاده از نمایش گرافیکی متغیرهای پاسخ برای انتخاب بهترین جواب غیرمسلط، کارایی ندارد. در مطالعه‌ی دیگر و با رویکردی مشابه مطالعه‌ی مورد اشاره، نسبت به تولید جواب غیرمسلط و انتخاب بهترین آن‌ها اقدام شده، با این تفاوت که برخلاف رویکرد پیشین محدودیتی برای تعداد متغیرهای پاسخ ندارد.

نوشتار حاضر در ادامه به این صورت سازمان‌دهی شده است که در بخش دوم روش پیشنهادی مبتنی بر شبکه‌ی عصبی مصنوعی، تکنیک محدودیت جزئی و الگوریتم ژنتیک ارائه می‌شود. در بخش سوم، رویکرد ارائه شده روی مثال عددی توضیح داده شده و نتایج حاصل از آن تحلیل شده است. در بخش چهارم نیز به تحلیل رویکرد پیشنهادی و ارائه نتیجه‌گیری می‌پردازیم.

۲. رویکرد پیشنهادی

رویکرد پیشنهادی شامل سه مرحله است: الف) شناسایی روابط بین عوامل کنترلی و متغیرهای پاسخ توسط شبکه‌ی عصبی مصنوعی؛ ب) تولید جواب‌های غیرمسلط با استفاده از الگوریتم ژنتیک؛ ج) غربال‌گری جواب‌های غیرمسلط.

الف) شناسایی روابط بین عوامل کنترلی و متغیرهای پاسخ توسط شبکه‌ی عصبی مصنوعی

در مسائل چندپاسخ، برای استخراج و مدل کردن روابط موجود بین عوامل کنترلی و متغیرهای پاسخ از «شبکه‌ی عصبی مصنوعی» استفاده می‌شود. غالباً از عوامل کنترلی به عنوان «ورودی شبکه» و از متغیرهای پاسخ به عنوان «خروجی شبکه» عصبی مصنوعی یاد می‌شود. اما گاهی یافتن معکوس این رابطه مفیدتر واقع می‌شود. به عبارت دیگر گاهی نیاز داریم که متغیرهای پاسخ را به عنوان ورودی و عوامل کنترلی را به عنوان خروجی به شبکه ارائه کنیم. در شکل ۱ توپولوژی مورد استفاده‌ی شبکه‌ی عصبی مصنوعی در این پژوهش نشان داده شده است.

برای آموزش شبکه‌ی عصبی مصنوعی، طبق توضیحات ارائه شده ابتدا متغیرهای پاسخ به عنوان ورودی و متغیرهای کنترلی به عنوان خروجی شبکه‌ی عصبی مصنوعی تعیین می‌شود. سپس داده‌های حاصل از انجام آزمایشات واقعی به سه زیرمجموعه‌ی «داده‌های آموزش»، «آزمون» و «اعتبارسنجی» تقسیم می‌شود. داده‌های آموزش برای محاسبه‌ی شیب و نیز برای به روزرسانی وزن‌ها و بایاس‌ها در شبکه‌ی عصبی مصنوعی به کار می‌رود. داده‌های اعتبارسنجی در حین فرایند آموزش بررسی

۳. مثال عددی

این مثال که توسط محققین^[۳۰] مورد بررسی قرار گرفته، مربوط به فرایند خم کردن در صنایع نیمه‌هادی است. عوامل کنترلی مورد نظر در مسئله‌ی مذکور عبارت‌اند از: نرخ جریان (X_1)، دمای جریان (X_2)، و دمای بلوک مولد گرما (X_3). همچنین متغیرهای پاسخ آزمون عبارت‌اند از:

Y_1 : دمای بیشینه در موقعیت ۱؛

Y_2 : دمای خم کردن اولیه در موقعیت ۱؛

Y_3 : دمای خم کردن نهایی در موقعیت ۱؛

Y_4 : دمای بیشینه در موقعیت ۲؛

Y_5 : دمای خم کردن اولیه در موقعیت ۲؛

Y_6 : دمای خم کردن نهایی در موقعیت ۲.

برای بررسی تأثیر عوامل کنترلی از طرح باکس - بنکن برای طراحی آزمایشات استفاده شده است. مشخصات عوامل کنترلی در کنار سطوح مورد استفاده در جدول ۳، و نتایج آزمایش‌ها در جدول ۴ نشان داده شده است.

در این مثال، تمامی متغیرهای پاسخ از نوع «هرچه به هدف نزدیک‌تر بهتر (NTB)»^۶ بوده و حدود بالا و پایین توسط مهندس فرایند مشخص شده و در جدول ۵ ارائه شده است.^[۳۰] حد بالا و پایین متغیر پاسخ نشان می‌دهد که متغیرهای

جدول ۳. مشخصات عوامل کنترلی در طراحی آزمایشات باکس - بنکن.

عامل کنترلی	نام عامل کنترلی	واحد	سطح پایین	سطح بالا
X_1	نرخ جریان	استاندارد فوت مکعب در دقیقه (*SCFM)	۴۰	۱۲۰
X_2	دمای جریان	درجه سانتی‌گراد	۲۰۰	۴۵۰
X_3	دمای بلوک	درجه سانتی‌گراد	۱۵۰	۳۵۰

* standard cubic feet per minute

جدول ۴. نتایج آزمایشات.

Y_6	Y_5	Y_4	Y_3	Y_2	Y_1	X_3	X_2	X_1
۱۲۶	۱۱۳	۱۱۰	۱۱۰	۱۰۳	۱۳۹	۲۵۰	۲۰۰	۴۰
۱۳۱	۱۱۴	۱۱۷	۱۲۶	۱۲۵	۱۴۰	۲۵۰	۲۰۰	۱۲۰
۱۴۷	۱۴۰	۱۴۷	۱۳۳	۱۵۱	۱۸۴	۲۵۰	۴۵۰	۴۰
۱۷۱	۱۶۹	۱۹۹	۱۶۹	۱۷۶	۲۱۰	۲۵۰	۴۵۰	۱۲۰
۱۱۵	۱۱۸	۱۳۴	۱۲۲	۱۳۰	۱۸۲	۱۵۰	۳۲۵	۴۰
۱۱۵	۱۱۸	۱۳۴	۱۲۲	۱۳۰	۱۷۰	۱۵۰	۳۲۵	۱۲۰
۱۶۴	۱۴۶	۱۴۳	۱۵۳	۱۵۱	۱۷۵	۳۵۰	۳۲۵	۴۰
۱۷۱	۱۵۰	۱۵۲	۱۵۴	۱۵۲	۱۸۰	۳۵۰	۳۲۵	۱۲۰
۱۰۱	۱۰۱	۱۱۱	۱۰۳	۱۰۸	۱۳۲	۱۵۰	۲۰۰	۸۰
۱۳۵	۱۴۱	۱۷۶	۱۳۸	۱۴۳	۲۰۶	۱۵۰	۴۵۰	۸۰
۱۶۰	۱۳۹	۱۳۱	۱۵۷	۱۴۱	۱۸۳	۳۵۰	۲۰۰	۸۰
۱۹۰	۱۷۵	۱۹۲	۱۸۴	۱۸۰	۱۸۱	۳۵۰	۴۵۰	۸۰
۱۴۵	۱۳۸	۱۵۵	۱۳۳	۱۳۵	۱۷۲	۲۵۰	۳۲۵	۸۰
۱۴۹	۱۴۱	۱۶۱	۱۴۵	۱۴۹	۱۹۰	۲۵۰	۳۲۵	۸۰
۱۴۸	۱۴۰	۱۵۸	۱۳۹	۱۴۱	۱۸۰	۲۵۰	۳۲۵	۸۰

جدول ۵. حدود بالا و پایین و هدف متغیرهای پاسخ.

متغیر پاسخ	حد پایین	هدف	حد بالا
Y_1	۱۸۵	۱۹۰	۱۹۵
Y_2	۱۷۰	۱۸۵	۱۹۵
Y_3	۱۷۰	۱۸۵	۱۹۵
Y_4	۱۸۵	۱۹۰	۱۹۵
Y_5	۱۷۰	۱۸۵	۱۹۵
Y_6	۱۷۰	۱۸۵	۱۹۵

پاسخ بیشتر از حد بالا یا کم‌تر از حد پایین مطلوبیتی برای تصمیم‌گیرنده ندارد. افزون بر این، در مواردی که حدود بالا و پایین متغیرهای پاسخ معین نباشد، یک مرحله برای تخمین آن‌ها در الگوریتم اضافه می‌شود.

۱.۳. شناسایی روابط بین عوامل کنترلی و متغیرهای پاسخ توسط

شبکه‌ی عصبی مصنوعی

در این مرحله با در نظر گرفتن ورودی و خروجی شبکه، که به ترتیب متغیرهای پاسخ و عوامل کنترلی‌اند، در ساختارهای مختلف (تعداد لایه‌های پنهان و تعداد نورون‌های متفاوت در آن‌ها)، شبکه‌ی عصبی مصنوعی آموزش دیده و معیار سنجش عملکرد شبکه، که در این نوشتار میانگین قدرمطلق درصد خطای داده‌های آزمون و اعتبارسنجی و میانگین قدرمطلق درصد خطای داده‌های آموزش تعیین شده است، برای هر ساختار محاسبه و ثبت می‌شود. ساختار دارای کم‌ترین مقدار این معیار به عنوان ساختار مناسب شبکه‌ی عصبی مصنوعی انتخاب می‌شود. در این مثال، شبکه‌ی عصبی مصنوعی با دو لایه‌ی پنهان و به ترتیب با ۶ و ۴ نورون در لایه‌های پنهان اول و دوم به عنوان ساختار مناسب شبکه‌ی عصبی مصنوعی انتخاب می‌شود. پس از این انتخاب، شبکه با ساختار انتخاب شده دوباره آموزش داده می‌شود تا به معیار اندازه‌گیری عملکرد بهتر از مرحله‌ی انتخاب ساختار مناسب برسد. در مثال ذکر شده، با ساختار تعیین شده، میانگین قدرمطلق درصد خطای داده‌های آزمون و اعتبارسنجی ۰.۸۷۵۴% و میانگین قدرمطلق درصد خطای داده‌های آموزش ۰.۸۷۰۳% هستند.

۲.۳. تولید جواب‌های غیر مسلط با استفاده از الگوریتم ژنتیک

برای تولید جواب‌های غیرمسلط، ابتدا باید سطوح ε_i ها با توجه به حدود بالا و پایین تعیین شده در جدول ۵ مشخص شوند. در این مثال عددی، سه سطح برای مقادیر ε_i در نظر گرفته شده که همراه با حدود تعیین شده برای متغیرهای پاسخ نسبت به سطح ε_i در جدول ۶ آورده شده است. یادآور می‌شود که تعداد سطوح آن می‌تواند مقادیر دیگری را که توسط تحلیل‌گر مشخص می‌شود، انتخاب کند. با توجه به جدول ۶، برای مثال برای متغیر پاسخ اول در صورتی که ε_1 در سطح ۱ قرار گیرد، در روش محدودیت جزئی این محدودیت وجود دارد که مقدار این متغیر پاسخ تقریباً برابر مقدار هدف (فاصله‌ی ۰.۷۰۲ از هدف) باشد و زمانی که ε_1 در سطح دوم قرار گیرد، مقدار متغیر پاسخ اول می‌تواند فاصله بیشتری از مقدار هدف داشته باشد تا جایی که در سطح سوم از ε_1 متغیر پاسخ کافی است که فقط در محدوده‌ی تعیین شده‌ی خود در جدول ۵ قرار گیرد. به عبارت دیگر با تغییر سطوح ε_i ها در هر بار حل مدل، هر یک از متغیرهای پاسخ می‌توانند فواصل متفاوتی نسبت به هدف‌شان داشته باشند و در نتیجه‌ی هر بار حل مدل، یک جواب غیرمسلط به دست می‌آید. به دلیل عدم تقارن

جدول ۶. سطوح تعریف شده برای ε_i و حدود متغیرهای پاسخ نسبت به آن.

سطوح ε_i	حدود متغیر پاسخ نام نسبت به سطح ε_i					
	متغیر پاسخ ۱	متغیر پاسخ ۲	متغیر پاسخ ۳	متغیر پاسخ ۴	متغیر پاسخ ۵	متغیر پاسخ ۶
۱	[۱۸۹,۹۸ ۱۹۰,۰۲]	[۱۸۴,۹۸ ۱۸۵,۰۲]	[۱۸۴,۹۸ ۱۸۵,۰۲]	[۱۸۹,۹۸ ۱۹۰,۰۲]	[۱۸۴,۹۸ ۱۸۵,۰۲]	[۱۸۴,۹۸ ۱۸۵,۰۲]
۲	[۱۸۷,۵ ۱۹۲,۵]	[۱۷۷,۵ ۱۹۰]	[۱۷۷,۵ ۱۹۰]	[-۱۸۷,۵ ۱۹۲,۵]	[۱۷۷,۵ ۱۹۰]	[۱۷۷,۵ ۱۹۰]
۳	[۱۸۵ ۱۹۵]	[۱۷۰ ۱۹۵]	[۱۷۰ ۱۹۵]	[۱۸۵ ۱۹۵]	[۱۷۰ ۱۹۵]	[۱۷۰ ۱۹۵]

جدول ۷. جواب‌های تولید شده غیرزاید، زمانی که متغیر پاسخ اول در تابع هدف قرار داده شده است.

ردیف	مقدار متغیرهای کنترلی						مقدار متغیر پاسخ		
	X_1	X_2	X_3	Y_1	Y_2	Y_3	Y_4	Y_5	Y_6
۱	۸۹,۳	۴۴۹,۱۶	۳۲۴,۸۲	۱۹۰	۱۸۵	۱۸۵	۱۹۰	۱۷۰,۷۵	۱۹۳,۹۲
۲	۹۳,۱۹	۴۴۹,۳۸	۳۱۴,۴۱	۱۹۰	۱۸۵	۱۸۵	۱۹۴,۸۱	۱۷۰,۸۲	۱۸۹,۹۶
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
۲۱	۸۶,۲۶	۴۴۹,۹۶	۳۴۷,۶۱	۱۹۰	۱۷۰	۱۷۹,۳۶	۱۹۴,۰۷	۱۸۵	۱۸۵
۲۲	۸۵,۷۱	۴۴۹,۹۷	۳۴۳,۵۶	۱۹۰	۱۷۰	۱۷۳,۳۸	۱۹۲,۵	۱۸۵	۱۸۵

که متغیر پاسخ چهارم در تابع هدف قرار گرفته است در یکی از تکرارها سطح ۱، ۳، ۲، ۳، ۱ و به ترتیب برای ε_i به‌ازای متغیرهای پاسخ ۱ تا ۶ به دست آمده است. این سطوح کوچک‌تر مساوی جواب موجود در تکرار پنجم است، زمانی که متغیر پاسخ اول در تابع هدف قرار گرفته است. بنابراین جواب حاصل از قرار دادن متغیر پاسخ اول در تابع هدف حذف می‌شود. در مرحله دوم، جواب‌های با سطوح ε_i یکسان با یکدیگر مقایسه می‌شوند و جوابی که مجموع اختلاف آن از مقدار ایده‌آل کم‌تر باشد انتخاب می‌شود. مجموع اختلاف از مقدار ایده‌آل^۷ در رابطه‌ی ۳ تحت عنوان SDT نشان داده شده است.

$$SDT = \sum_{i=1}^I |Y_i - T_i| \quad (3)$$

که در آن Y_i مقدار پاسخ نام و T_i مقدار هدف نامین متغیر پاسخ است. پس از غربال‌گری ۵۳۸ جواب به دست آمده حاصل از قرار دادن هر یک از متغیرهای پاسخ در تابع هدف، تنها ۱۷ جواب غیرمسلط باقی می‌ماند که این نتایج در جدول ۸ آورده شده‌اند.

به‌منظور بررسی کارایی روش پیشنهادی، نتایج حاصل از مثال مورد اشاره با روش‌های ارائه شده توسط سایر محققین مقایسه شده است. در جدول ۹ نتایج حاصل از سایر مطالعات در بهینه‌سازی این مسئله‌ی چندپاسخه نشان داده شده است. لازم به ذکر است که روش‌های پیشین موجود صرفاً یک جواب به‌عنوان جواب مرجع (بهینه) ارائه می‌کند، در صورتی که روش حاضر اقدام به شناسایی جواب‌های غیرمسلط می‌کند که در مسائل بهینه‌سازی چندهدفه از استقبال بیشتر نزد محققین برخوردار است. ستون چهارم جدول ۹ شامل مجموع قدرمطلق اختلاف‌های متغیرهای پاسخ بهینه به دست آمده از مقدار هدف متناظرشان است. گفتنی است مقدار مذکور به تفکیک هر یک از جواب‌های غیرمسلط (حاصل از روش پیشنهادی) در ستون ۱۱ جدول ۸ نشان داده شده است. مقایسه‌ی نتایج حاصل از روش پیشنهادی و سایر مطالعات نشان می‌دهد که در تمامی جواب‌های غیرمسلط تولید شده با استفاده از روش پیشنهادی، مجموع قدرمطلق اختلاف متغیرهای پاسخ از مقدار هدف مقدار کم‌تری نسبت به رویکرد برخی از محققین^{[۳۱]، [۳۲]} دارد، در حالی که ۵ جواب بهینه‌ی حاصل از رویکرد محققین دیگر^[۱۶] فقط نسبت به ۳

حدود بالا و پایین متغیرهای پاسخ ۲، ۳، ۵ و ۶ (جدول ۵)، حدود تعیین شده‌ی این متغیرها نسبت به سطوح ε_i نیز به همان نسبت تعیین شده‌اند (جدول ۶).

چنان که پیش‌تر اشاره شد، ρ عدد ثابت مثبت به‌اندازه‌ی کافی کوچک است که تولید جواب‌های غیرمسلط قوی را تضمین می‌کند. در این مثال مقدار ρ ، $10^3 \times 1/5$ در نظر گرفته شده است. این مقدار با استفاده از نتایج تحلیل حساسیت صورت‌گرفته در مطالعات پیشین^[۲۳] و با در نظر گرفتن مقیاس متغیرهای پاسخ در مثال مورد نظر انتخاب شده است.

در این مثال ۶ متغیر پاسخ، و به‌ازای هر یک از آن‌ها ۳ سطح برای ε متناظر آن متغیر پاسخ وجود دارد. بنابراین در کل 6×3^5 بار مسئله‌ی بهینه‌سازی باید حل شود، اما بسیاری از دفعات حل اضافی‌اند. برای مثال، اگر متغیر پاسخ اول در تابع هدف و سایر متغیرهای پاسخ بنا به سطوح ε_i در محدودیت قرار گیرند، چنانچه به‌ازای سطوح پایین‌تر ε_i ها متغیر پاسخ اول برابر مقدار ایده‌آل (۱۹۰) باشد، بررسی سطوحی از ε_i که تمامی آن‌ها بزرگ‌تر یا مساوی سطوح بررسی شده‌اند، ضرورتی ندارد. به این ترتیب از انجام بسیاری از حالت‌های تکراری و اضافی جلوگیری می‌شود تا زمان حل کل مسئله کاهش یابد.

با توجه به توضیحات داده شده، زمانی که متغیرهای پاسخ ۱، ۲، ۳، ۴، ۵ و ۶ در تابع هدف مسئله‌ی روش محدودیت جزئی قرار داده شده و توسط الگوریتم ژنتیک حل شدند به ترتیب ۲۲، ۱۹۱، ۴۲، ۳۶، ۱۷۶ و ۷۱ جواب غیر زاید تولید شده است. برخی از جواب‌های تولید شده زمانی که متغیر پاسخ اول در تابع هدف قرار گرفته است، در جدول ۷ آمده است.

۳.۳. غربال‌گری جواب‌های غیرمسلط

پس از حل مسئله با ε_i های مختلف و قرار دادن متغیرهای پاسخ مختلف در تابع هدف، فهرستی از جواب‌های غیرمسلط فراهم می‌آید؛ اما این جواب‌ها مستلزم انجام غربال‌گری و تصفیه‌اند. چنان که پیش‌تر اشاره شد، در رویکرد پیشنهادی غربال‌گری شامل دو مرحله است. در مرحله اول، هرگاه جواب حاصل از روش محدودیت جزئی به‌ازای سطوح پایین‌تر ε_i ها بهینه باشد، جواب‌های به دست آمده به‌ازای مقادیر سطوح بزرگ‌تر ε_i ها حذف خواهد شد. برای مثال، در حل این مثال عددی زمانی

جدول ۸. جواب‌های غیرمسلط تولید شده با استفاده از رویکرد پیشنهادی.

ردیف	مقدار متغیر پاسخ									
	SDT	Y_6	Y_5	Y_4	Y_3	Y_2	Y_1	X_3	X_2	X_1
۱	۲۳,۱۷	۱۹۳,۹۲	۱۷۰,۷۵	۱۹۰	۱۸۵	۱۸۵	۱۹۰	۳۲۴,۸۲	۴۴۹,۱۹	۸۹,۳
۲	۲۷,۲۲	۱۹۰	۱۷۰	۱۹۱,۵۴	۱۷۹,۳۲	۱۸۵	۱۹۰	۳۰۷,۴۹	۴۴۹,۷۷	۹۲,۸۳
۳	۳۶,۹	۱۸۵	۱۷۰	۱۹۵	۱۷۰	۱۸۵	۱۸۸,۱	۲۸۹,۱۶	۴۵۰	۹۶,۲
۴	۲۳,۸۴	۱۸۷,۹۳	۱۸۵	۱۹۲,۴۸	۱۸۵	۱۷۰,۰۴	۱۹۳,۴۷	۳۴۹,۹۹	۴۴۸,۹۳	۸۷,۰۷
۵	۲۹,۱۲	۱۸۵	۱۸۵	۱۹۲,۵	۱۷۳,۳۸	۱۷۰	۱۹۰	۳۴۳,۵۶	۴۴۹,۹۹	۸۵,۷
۶	۲۳,۴۵	۱۸۹,۱۷	۱۷۰,۱۱	۱۹۴,۳۹	۱۸۵	۱۸۵	۱۹۰	۳۱۱,۴۶	۴۵۰	۹۳,۸۱
۷	۳۰,۶۳	۱۹۰	۱۷۰,۰۴	۱۹۰	۱۷۴,۳۳	۱۸۵	۱۹۰	۳۰۲,۶۳	۴۵۰	۹۲,۲
۸	۲۲,۳۱	۱۸۶,۷۵	۱۸۴,۹۸	۱۹۴,۹۹	۱۸۵,۰۱	۱۷۰,۸۳	۱۹۱,۳۷	۳۴۹,۹۸	۴۴۹,۸۷	۸۶,۸۸
۹	۲۱,۵۸	۱۸۹,۹۶	۱۷۷,۵	۱۹۱,۶۱	۱۸۵	۱۷۷,۵	۱۹۰,۰۱	۳۴۱,۵	۴۴۹,۶۷	۸۶,۶۵
۱۰	۲۲	۱۹۲,۹۹	۱۷۸,۴۹	۱۹۰	۱۸۵	۱۷۷,۵	۱۹۰	۳۴۵,۸۲	۴۴۸,۸۶	۸۶,۲۷
۱۱	۲۵,۳۲	۱۹۰	۱۷۷,۵	۱۹۰	۱۷۹,۶۹	۱۷۷,۵	۱۹۰	۳۳۶,۹۲	۴۴۹,۸۲	۸۶,۲۹
۱۲	۱۹,۳۳	۱۸۵,۰۱	۱۷۳,۱۹	۱۹۰	۱۸۵	۱۷۷,۵۱	۱۹۰,۰۱	۳۲۹,۵۵	۴۴۹,۸۹	۸۸,۴۶
۱۳	۳۵,۸۲	۱۹۵	۱۸۵	۱۹۴,۷۸	۱۷۱,۴۷	۱۷۷,۵	۱۹۰	۳۴۱,۵۷	۴۴۹,۸۹	۸۶,۰۹
۱۴	۲۵,۳۵	۱۸۸,۴۱	۱۸۵	۱۹۰,۰۲	۱۷۷,۹۱	۱۷۰,۱۷	۱۹۰,۰۱	۳۴۹,۴۸	۴۵۰	۸۵,۷۳
۱۵	۲۷,۷	۱۸۵,۰۲	۱۷۷,۴۹	۱۹۴,۹۵	۱۷۷,۲۷	۱۷۷,۵	۱۹۰	۳۲۴,۳۶	۴۴۹,۹۹	۸۹,۴۳
۱۶	۱۸,۳۱	۱۸۵	۱۸۱,۶۴	۱۹۰,۰۲	۱۸۵,۰۱	۱۷۰,۱	۱۸۹,۹۹	۳۴۹,۲۴	۴۴۹,۸۹	۸۶,۱۶
۱۷	۲۲,۲۷	۱۸۵	۱۸۴,۹۸	۱۹۵	۱۸۲,۷۵	۱۷۰	۱۹۰	۳۴۹,۵	۴۴۹,۴۱	۸۶,۷۶

جدول ۹. نتایج بهینه حاصل از سایر مطالعات برای مثال عددی.

D	SDT	$(Y_1^*, Y_2^*, Y_3^*, Y_4^*, Y_5^*, Y_6^*)$	(X_1^*, X_2^*, X_3^*)	رویکرد
۰,۴۲	۲۹,۲	(۱۹۲,۱, ۱۸۴,۱, ۱۸۱, ۱۹۳,۷, ۱۸۰,۳, ۱۷۱,۲)	(۶۸,۹۷, ۳۷۰, ۲۸۶,۰۶)	[۱۶]
۰,۴۱	۳۷,۴	(۱۸۷, ۱۷۶,۷, ۱۷۳,۸, ۱۹۲,۹, ۱۷۴,۲, ۱۸۶,۲)	(۷۴,۵۵, ۴۷۲,۹, ۳۳۲,۷۵)	[۳۱]
۰,۳	۴۲,۱	(۱۸۶, ۱۷۴,۵, ۱۷۲, ۱۹۲,۶, ۱۷۳, ۱۸۵)	(۸۴,۱۶, ۴۵۰, ۳۲۹,۸۷)	[۳۰]
روش پیشنهادی				
۰,۴۱	۱۸,۳۱	(۱۸۹,۹۹, ۱۷۰,۱, ۱۸۵,۰۱, ۱۹۰,۰۲, ۱۸۱,۶۴, ۱۸۵)	(۸۶,۷۶, ۴۴۹,۴۱, ۳۴۹,۵)	(بهترین جواب موجود در جواب‌های غیرمسلط از نظر مقدار SDT)
روش پیشنهادی				
۰,۶۹	۱۹,۳۳	(۱۹۰,۰۱, ۱۷۷,۵۱, ۱۸۵, ۱۹۰, ۱۷۳,۱۹, ۱۸۵,۰۱)	(۸۸,۴۶, ۴۴۹,۸۹, ۳۲۹,۵۵)	(بهترین جواب موجود در جواب‌های غیرمسلط از نظر مقدار تابع مطلوبیت)

جواب غیرمسلط تولید شده بهتر و نسبت به ۱۴ جواب غیرمسلط تولید شده بدتر است: [۳۲]

$$d_i(\hat{y}_i(x)) = \begin{cases} 0 & \hat{y}_i(x) < Y_i^{\min} \text{ یا } \hat{y}_i(x) > Y_i^{\max} \\ \left[\frac{\hat{y}_i - Y_i^{\min}}{T_i - Y_i^{\min}} \right]^{s_i} & Y_i^{\min} \leq \hat{y}_i(x) \leq T_i \\ \left[\frac{Y_i^{\max} - \hat{y}_i}{Y_i^{\max} - T_i} \right]^{t_i} & T_i \leq \hat{y}_i(x) \leq Y_i^{\max} \\ 1 & \hat{y}_i(x) = T_i \end{cases}$$

نوع «هرچه به هدف نزدیک‌تر بهتر» (NTB) و به صورت رابطه ۴ تعریف شده (۴)

۴. نتیجه‌گیری

در مسائل چندپاسخه مهم‌ترین موضوع بهینه‌سازی همزمان تمام متغیرهای پاسخی است که معمولاً با یکدیگر در تضادند. به عبارت دیگر حرکت در جهت بهینه‌ی یکی از متغیرهای پاسخ ممکن است در خلاف جهت بهینگی متغیر پاسخ دیگر باشد. از این رو ارائه جواب‌های غیرمسلط به تصمیم‌گیرنده می‌تواند مناسب‌تر باشد. در اغلب مطالعات موجود در ادبیات از معادلات رگرسیونی برای این منظور استفاده شده است، در حالی که مطالعاتی نشان‌دهنده‌ی خطای کم‌تر شبکه‌های عصبی مصنوعی برای تخمین رابطه‌ی بین عوامل کنترلی و متغیرهای پاسخ است. در این نوشتار، با استفاده از شبکه‌ی عصبی مصنوعی (که ورودی‌های آن متغیرهای پاسخ، و خروجی‌های آن عوامل کنترلی بودند) روش محدودیت جزئی و الگوریتم ژنتیک به تولید جواب‌های غیرمسلط پرداختیم. روش پیشنهادی روی یک مثال عددی انجام شده و نتایج حاصل از آن با نتایج حاصل از حل مثال مورد نظر توسط سایر محققین مقایسه شد؛ نتایج حاصله نشان‌دهنده‌ی کارایی روش پیشنهادی است. انتخاب سیستماتیک سطوح و مقادیر ε_i به صورتی که نتایج حاصل از تولید جواب‌های غیرمسلط را بهبود بخشد، می‌تواند به عنوان زمینه تحقیقات آتی مطرح شود.

که در آن $d_i(\hat{y}_i(x))$ تابع مطلوبیت، Y_i^{\max} و Y_i^{\min} به ترتیب حدود پایین و بالا، و T_i سطح مطلوب متغیر پاسخ i ام است.

در روابط فوق، s و t به نوعی نشان‌دهنده‌ی میزان خطی بودن انحراف از هدف هستند. اگر هر دو متغیر s و t برابر ۱ باشند، انحراف از مقدار مطلوب با تابعی خطی برآورد می‌شود و افزایش و کاهش این مقادیر نسبت به ۱ به ترتیب باعث مقعر و محدب شدن تابع برآورد می‌شود. هرینگتون^[۳۳] میانگین هندسی را برای تجمیع توابع مطلوبیت جداگانه پیشنهاد داد.

با استفاده از رابطه‌ی ۴ و برابر ۱ قرار دادن مقادیر s و t ، مقدار تابع مطلوبیت تجمیع‌شده‌ی آن‌ها (D) توسط میانگین هندسی به دست آمده و در جدول ۹ نشان داده شده‌اند. جوابی از بین جواب‌های غیرمسلط به دست آمده که بهترین مقدار از نظر مقدار تابع مطلوبیت تجمیع شده را دارد نیز نشان داده شده است. چنان که مشاهده می‌شود این جواب نسبت به جواب بهینه‌ی سایر رویکردها نیز تابع مطلوبیت کلی بهتری دارد. از این مقایسه می‌توان چنین استنباط کرد که با در نظر گرفتن معیارهای متفاوت برای ارزیابی جواب‌ها، دست کم یکی از جواب‌های غیرمسلط به دست آمده مقداری مساوی، یا بهتر از جواب صرفاً مرجح ارائه شده توسط سایر رویکردها خواهد داشت.

پانویس‌ها

1. ε -constraint
2. mean absolute percentage error
3. larger the better
4. weighting method
5. weighted metrics method
6. nominal the best
7. sum of deviation from target

منابع (References)

1. Liao, H. "A data envelopment analysis method for optimizing multi-response problem with censored data in the Taguchi method", *Computers and Industrial Engineering*, **46**(4), pp. 817-835 (2004).
2. Erzurumlu, T. and Oktem, H. "Comparison of response surface model with neural network in determining the surface quality of moulded parts", *Materials and design*, **28**(2), pp. 459-465 (2007).
3. Tsao, C. "Comparison between response surface methodology and radial basis function network for core-center drill in drilling composite materials", *The International Journal of Advanced Manufacturing Technology*, **37**(11), pp. 1061-1068 (2008).
4. Desai, K.M., Survase, S.A., Saudagar, P.S., Lele, S.S. and Singhal, R.S., "Comparison of artificial neural network (ANN) and response surface methodology (RSM) in fermentation media optimization: Case study of fer-

mentative production of scleroglucan", *Biochemical Engineering Journal*, **41**(3), pp. 266-273 (2008).

5. Gupta, A.K. "Predictive modelling of turning operations using response surface methodology, artificial neural networks and support vector regression", *International Journal of Production Research*, **48**(3), pp. 763-778 (2010).
6. Nelofer, R., Ramanan, R.N., Rahman, R.N.Z.R.A., Basri, M. and Ariff, A.B. "Comparison of the estimation capabilities of response surface methodology and artificial neural network for the optimization of recombinant lipase production by E. coli BL21", *Journal of Industrial Microbiology & Biotechnology*, **39**(2), pp. 1-12 (2012).
7. Li, T., Su, C. & Chiang, T. "Applying robust multi-response quality engineering for parameter selection using a novel neural-genetic algorithm", *Computers in Industry*, **50**(1), pp. 113-122 (2003).
8. Bashiri, M. and Hosseini-zhad, S.J. "Optimization of multiple response process by neural networks based on desirability concept", *International Journal of Industrial Engineering and Production Management*, **20**(4), pp. 53-63 (2010).
9. Gutierrez, E. and Lozano, S. "Data envelopment analysis of multiple response experiments", *Applied Mathematical Modelling*, **34**(5), pp. 1139-1148 (2010).
10. Hsu, C. "An integrated approach to enhance the optical", *International Journal of Production Economics*, **92**(3), pp. 241-254 (2004).
11. Delfa, G., Olivieri, A. and Boschetti, C. "Multiple response optimization of styrene-butadiene rubber emul-

- sion polymerization”, *Computers and Chemical Engineering*, **33**(4), pp. 850-856 (2009).
12. Lin, H.C., Su, C.T., Wang, C.C., Chang, B.H. and Juang, R.C. “Parameter optimization of continuous sputtering process based on Taguchi methods, neural networks, desirability function, and genetic algorithms”, *Expert Systems with Applications*, **39**(17), pp. 12918-12925 (2012).
 13. Chang, H. “A data mining approach to dynamic multiple responses in Taguchi experimental design”, *Expert Systems with Applications*, **35**(3), pp. 1095-1103 (2008).
 14. Chang, H. and Chen, Y. “Neuro-genetic approach to optimize parameter design of dynamic multiresponse experiments”, *Applied Soft Computing*, **11**, pp. 436-442 (2011).
 15. Hsieh, K. and Tong, L. “Optimization of multiple quality responses involving qualitative and quantitative characteristics in IC manufacturing using neural networks”, *Computers in Industry*, **46**(1), pp. 1-12 (2001).
 16. Noorossana, R., Davanloo Tajbakhsh, S. and Saghaei, A. “An artificial neural network approach to multiple-response optimization”, *The International Journal of Advanced Manufacturing Technology*, **40**(11), pp. 1227-1238 (2009).
 17. Hsieh, K. “Parameter optimization of a multi-response process for lead frame manufacturing by employing artificial neural networks”, *The International Journal of Advanced Manufacturing Technology*, **28**(5), pp. 584-591 (2006).
 18. Hsieh, K. “Employing artificial neural networks into achieving parameter optimization of multi-response problem with different importance degree consideration”, *Information Technology Journal*, **9**(5), pp. 918-926 (2010).
 19. Hsu, C. “Solving multi-response problems through neural networks and principal component analysis”, *Journal of the Chinese Institute of Industrial Engineers*, **18**(5), pp. 47-54 (2001).
 20. Sibalija, T.V., Petronic, S.Z., Majstorovic, V.D., Prokic-Cvetkovic, R. and Milosavljevic, A. “Multi-response design of Nd: YAG laser drilling of Ni-based superalloy sheets using Taguchi’s quality loss function, multivariate statistical methods and artificial intelligence”, *The International Journal of Advanced Manufacturing Technology*, **54**(5), pp. 537-552 (2011).
 21. Sibalija, T.V. and Majstorovic, V.D. “An integrated simulated annealing-based method for robust multiresponse process optimization”, *The International Journal of Advanced Manufacturing Technology*, **59**(9), pp. 1227-1244 (2012).
 22. Lee, D.H., Jeong, I.J. and Kim, K.J. “A posterior preference articulation approach to dual-response-surface optimization”, *IIE Transactions*, **42**(2), pp. 161-171 (2010).
 23. Lee, D.H., Kim, K.J. and Köksalan, M. “A posterior preference articulation approach to multiresponse surface optimization”, *European Journal of Operational Research*, **210**(2), pp. 301-309 (2011).
 24. Wong, W.K., Xia, M. and Chu, W.C. “Adaptive neural network model for time-series forecasting”, *European Journal of Operational Research*, **207**(2), pp. 807-816 (2010).
 25. Zadeh, L. “Optimality and non-scalar-valued performance criteria”, *IEEE Transactions on Automatic Control*, **8**, pp. 59-60 (1963).
 26. Haimes, Y.Y., Lasdon, L.S. and Wismer, D.A. “On a bicriterion formulation of the problems of integrated system identification and system optimization”, *IEEE Transactions on Systems Man, and Cybernetics*, **1**(3), pp. 296-297 (1971).
 27. Zeleny, M., *Multiple Criteria Decision Making*, McGraw-Hill, New York (1982).
 28. Miettinen, K.M., *Nonlinear Multiobjective Optimization*, Kluwer, Boston (1999).
 29. Steuer, R.E., *Multiple Criteria Optimization: Theory, Computation, and Application*, John Wiley and Sons, New York (1986).
 30. Del Castillo, E., Montgomery, D.C. and McCarville, D.R. “Modified desirability functions for multiple response optimization”, *J. Qual Technol*, **28**(3), pp. 337-345 (1996).
 31. Ortiz, F., Simpson, J.R., Pignatiello, J.J. and Heredia-Langner, A. “A genetic algorithm approach to multiple-response optimization”, *J. Qual Technol*, **36**, pp. 432-450 (2004).
 32. Derringer, G. and Suich, R. “Simultaneous-optimization of several response variables”, *Journal of Quality Technology*, **12**(4), pp. 214-219 (1980).
 33. Harrington, E. “The desirability function”, *Industrial Quality Control*, **21**(10), pp. 494-498 (1965).