



## بهینه سازی فرآیند چند پاسخ با استفاده از شبکه های عصبی و الگوریتم ژنتیک

محمد رضا امین ناصری\*، رضا برادران کاظم زاده، علی سلماس نیا و مجتبی صالحی

### چکیده:

در بیشتر مسایل بهینه سازی دنیای واقعی با تنظیم متغیر های فرایند برای دستیابی به سطوح مطلوب متغیرهای خروجی (متغیرهای پاسخ) مواجه هستیم. متدهای معمول بهینه سازی اغلب با تخمین رابطه بین متغیر پاسخ با متغیرهای کنترلی آغاز می شوند. در میان این تکنیک ها، متدولوژی سطح پاسخ<sup>۱</sup> (RSM) به علت سادگی توجه بسیاری را در طی سال های اخیر به خود جلب کرده است ولی در بعضی موارد ارتباط بین متغیر پاسخ با فاکتورهای کنترلی آنقدر پیچیده است که از یک طرف نمی توان با مدل های رگرسیون چند جمله ای به تخمین مناسبی از آن دست یافت و از طرف دیگر، حل چنین مساله بهینه سازی با روش های دقیق<sup>۲</sup> با مشکلاتی همراه است. رویکرد جایگزین ارائه شده در این مقاله، استفاده از شبکه عصبی مصنوعی برای تخمین توابع پاسخ و الگوریتم ژنتیک در فرآیند بهینه سازی است. این رویکرد همچنین به کمک روش تاگوچی سعی در برطرف کردن محدودیت معمول رویکرد های چند پاسخ که غفلت از اثر پراکندگی سطوح پاسخ است دارد.

### کلمات کلیدی

بهینه سازی مسایل با چندسطح پاسخ، روش تاگوچی، شبکه های عصبی مصنوعی، الگوریتم ژنتیک

### ۱. مقدمه

تنظیم متغیرهای ورودی قابل کنترل به یک فرآیند صنعتی برای دستیابی به شرایط عملیاتی مناسب یکی از مسایل معمول در کنترل کیفیت است. یک طرح مقاوم<sup>۳</sup> در تنظیم متغیرهای کنترلی، اثرات مکانی و پراکندگی مشخصه کیفی (متغیر پاسخ) را تواما در نظر می گیرد. روش تاگوچی [۱،۲] رویکردی است که عمدتاً برای دستیابی به یک طرح مقاوم مورد استفاده قرار می گیرد. این روش کیفیت محصول را با استفاده از نسبت سیگنال به

اختلال<sup>۳</sup> (SN) ارزیابی می کند. ترکیب بهینه به دست آمده از روش تاگوچی از یک طرف میانگین متغیر پاسخ را به مقدار هدف نزدیک می کند و از طرف دیگر واریانس آن را کاهش می دهد. در بیشتر مسایل صنعتی با بیش از یک متغیر پاسخ سر و کار داریم و بهبود همزمان آنها از اهمیت ویژه ای برخوردار است. مشکل معمول در بهینه سازی همزمان متغیر های پاسخ، متفاوت و گاهی متضاد بودن بودن جهت بهینگی آن ها است. در نتیجه بهینه سازی فرآیند تولید نسبت به یک متغیر پاسخ منجر به مقادیر غیر بهینه سایر پاسخ ها می شود. ولی روش تاگوچی هنگام برخورد با مسایل چند پاسخ به صورت مجزا به بهینه سازی متغیرهای پاسخ می پردازد و نهایتاً طبق نظر مهندس فرآیند ترکیب بهینه متغیر های طرح مشخص می شود. از این رو طراحی روشی که به بهینه سازی همزمان پاسخ ها بپردازد از اهمیت خاصی برخوردار است.

نکته قابل توجه دیگر در فرآیند بهینه سازی پاسخ ها تخمین رابطه بین پاسخ و متغیر های کنترلی است. در موارد بسیاری روابط رگرسیونی توانایی تخمین مناسب رابطه بین پاسخ و متغیر های طرح را ندارند. در این موارد، یک ابزار جایگزین مناسب برای

تاریخ وصول: ۹۰/۲/۱۲

تاریخ تصویب: ۹۰/۳/۲۵

\*نویسنده مسئول مقاله: دکتر محمد رضا امین ناصری دانشیار مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران  
amin\_nas@modares.ac.ir  
دکتر رضا برادران کاظم زاده، دانشیار مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران  
rkazem@modares.ac.ir  
علی سلماس نیا، دانشجوی دکتری مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران  
ali.salmasnia.85@gmail.com  
مجتبی صالحی، دانشجوی دکتری مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران  
m\_salehi61@yahoo.com

1. Response Surface Methodology

2. exact method

3 - Robust Design

<sup>3</sup> - Signal to Noise

اندازه و پیچیدگی مساله بستگی دارد. دسته اول شامل قرار دادن نمودارهای کانتور پاسخ ها بر روی یکدیگر و پیدا کردن منطقه ای است که پاسخ‌های مختلف ارضاء می‌شوند. Myers و Montgomery [۸] بیان می‌کنند که این رویکرد فقط زمانیکه تعداد متغیرهای طرح کم باشد می‌تواند موثر باشد. دسته دوم فرموله کردن مساله چند پاسخه به صورت یک مساله بهینه سازی محدودیت دار است. رویکردهای موجود در ادبیات را که به این دسته می‌پردازند، می‌توان به دو زیر مجموعه کلی تقسیم کرد. در زیر مجموعه اول یک متغیر پاسخ به عنوان تابع هدف انتخاب می‌شود و بقیه پاسخ‌ها به عنوان محدودیت در مدل وارد می‌شوند. مشکل اصلی این رویکرد ها آن است که انتخاب یک متغیر پاسخ به عنوان تابع هدف در بیشتر موارد کار آسانی نیست. در زیرمجموعه دوم از یک عملگر می‌نیمیم یا ماکزیمم ساز در تابع هدف استفاده می‌شود و همه متغیرهای پاسخ به عنوان محدودیت در مدل وارد می‌شوند.

مهمترین ایراد وارد شده به این رویکرد ها توجه صرف آن‌ها به متغیر پاسخ با می‌نیمیم درجه رضایت و غفلت از میزان درجه رضایت سایر پاسخ‌ها است که این امر در بعضی موارد منجر به جواب‌های غیر منطقی می‌شود. از جمله این رویکردها می‌توان به Del Castillo و Montgomery (۱۹۹۶) [۹]، تحقیقات Kim و Lin در سال‌های ۲۰۰۶ [۱۰]، Plante (۱۹۹۹) [۱۱] اشاره کرد. دسته سوم رویکرد‌هایی هستند که از سه گام تشکیل می‌شوند. ابتدا مدل پاسخ‌های مورد علاقه ایجاد می‌گردد سپس در مرحله دوم یک رویکرد برای ترکیب مدلها استفاده می‌شود و در نهایت با استفاده از یک روش بهینه سازی مدل را بهینه می‌کند. بیشتر رویکردهای بهینه سازی چند پاسخه موجود در ادبیات به این دسته اختصاص دارند و عمده تفاوت بین آن‌ها در روش تجمیع پاسخ‌ها و روش بهینه سازی مورد استفاده است. روش‌های مختلفی برای انجام گام اول یعنی تخمین رابطه بین پاسخ و متغیرهای طرح وجود دارد. معمول ترین متد برای انجام این کار روش حداقل مربعات<sup>۱</sup> (OLS) است ولی در حالت کلی روش انتخاب شده برای این منظور به میزان پیچیدگی رابطه بستگی دارد. در بعضی موارد مقادیر بزرگ میانگین مربع خطا<sup>۲</sup> مدل‌های رگرسیون که نشان از کیفیت ضعیف توصیف روابط مذکور دارد مشاهده می‌شود kim و همکاران [۱۲] این مشکل در بیشتر موارد به دو علت رخ می‌دهد. (۱) نقض فرض استقلال متغیرهای ورودی (۲) پیچیده بودن رابطه بین پاسخ و متغیرهای کنترلی [۱۳].

در این موارد استفاده از شبکه‌های عصبی مصنوعی<sup>۳</sup> (ANN) توصیه شده است [۳،۷]. معروفترین روش‌های تجمیع برای انجام

دستیابی به یک تخمین مناسب شبکه‌های عصبی مصنوعی هستند. Su و Hsieh [۳] یک رویکرد بر اساس شبکه‌های عصبی و متد تاگوچی پیشنهاد دادند. اما این روش فقط زمانیکه یک متغیر پاسخ داریم قابل کاربرد است.

Tong و Hsieh [۴] در سال ۲۰۰۱ رویکردی برای حل مسایل با چند سطح پاسخ با استفاده از شبکه‌های عصبی ارائه کردند. در این رویکرد از دو شبکه عصبی یکی برای کشف بردار فاکتورهای کنترلی بهینه و دیگری برای تخمین پاسخ‌ها استفاده می‌شود. Noorossana و همکاران [۵] نیز در کاری مشابه استفاده از شبکه‌های عصبی مصنوعی را به عنوان یک رویکرد جایگزین برای تخمین متغیرهای پاسخ معرفی کردند.

آنها با استفاده از تابع مطلوبیت Ortiz و همکاران [۶] به تجمیع متغیرهای پاسخ پرداختند و از الگوریتم ژنتیک در فاز بهینه سازی استفاده کردند. Hsieh [۷] در سال ۲۰۰۶ با استفاده از دو شبکه عصبی برای حل مسایل چند پاسخه ارائه کرد که بر خلاف سایر رویکرد‌های بر مبنای شبکه عصبی، اثر فاکتورهای کنترلی روی متغیر پاسخ را به دست می‌آورد. هیچکدام از سه رویکرد بهینه سازی چند پاسخه مذکور اثر پراکنندگی پاسخ‌ها را در نظر نمی‌گیرند. به عبارت دیگر، این رویکرد ها فرض می‌کنند که واریانس متغیرهای پاسخ روی فضای آزمایشی ثابت است. از آنجاییکه در بیشتر مسایل دنیای واقعی با روابط پیچیده بین پاسخ و فاکتورهای کنترلی مواجه هستیم. از این رو، در این مطالعه به ارائه روشی برای بهینه سازی مسایل با چند سطح پاسخ وقتیکه روابط رگرسیونی توانایی تخمین مناسب رابطه بین پاسخ و متغیرهای طرح را ندارند می‌پردازیم.

با توجه به آنکه فرض ثابت بودن واریانس متغیرهای پاسخ روی فضای آزمایشی در بیشتر مسایل غیر عملی است رویکرد ارائه شده با در نظر گرفتن واریانس پاسخ‌ها سعی در انتخاب مقادیری برای متغیرهای کنترلی دارد که پاسخ‌ها حداقل حساسیت را نسبت به فاکتورهای غیر کنترلی (اختلال) داشته باشند. ویژگی قابل ذکر دیگر رویکرد پیشنهادی در نظر گرفتن وزن نسبی پاسخ‌ها است. در بخش ۲ این تحقیق به مرور ادبیات بهینه سازی مسایل با چند سطح پاسخ می‌پردازیم. بخش ۳ تئوری شبکه‌های عصبی مصنوعی را بازبینی می‌کند. الگوریتم ارائه شده در بخش ۴ معرفی می‌شود. برای نمایش تاثیر پذیری رویکرد ارائه شده یک مثال عددی در بخش ۵ آورده شده است. نهایتاً، در بخش ۶ خلاصه ای از ویژگی‌های رویکرد ارائه شده و نتایج به دست آمده آورده شده است.

## ۲. مرور ادبیات

روش‌های مختلفی برای بهینه سازی مسایل با چند سطح پاسخ پیشنهاد شده است، Ortiz و همکارانش [۶] روش‌های موجود را به سه دسته اساسی طبقه بندی می‌کنند. عملکرد هر روش به

<sup>1</sup> - Ordinary List Square

<sup>2</sup> - Mean Square Error

<sup>3</sup> - Artificial Neural Network

توجه است که مدل Conlon و Khuri نوع خاصی از رویکرد Pignatiello است هنگامیکه  $C = \sum_{\hat{y}(x)}^{-1}$  در نظر گرفته شود Vining [20] در سال 1998 مدل Pignatiello را با جایگزین کردن  $\sum_{\hat{y}(x)}$  به جای  $\sum_{y(x)}$  اصلاح کرد. مزیت اصلی این جایگزینی توانا ساختن مدل به در نظر گرفتن کیفیت پیش بینی پاسخ ها در فرآیند بهینه سازی است. Ames و همکارانش [17] رویکرد تابع زبان کیفیت را بر اساس مدل های سطح پاسخ برای حل مسایل با چند سطح پاسخ ارائه کردند. هدف اصلی این رویکرد صرفا تجمیع پاسخ ها و می نیمم سازی انحراف آنها از مقادیر هدف است. طبق نظر Ko و همکارانش [18] یک رویکرد مناسب برای تجمیع متغیر های پاسخ باید دارای سه ویژگی اریبی کم، مقاومت<sup>5</sup> بالا و کیفیت بالای پیش بینی باشد. بدین معنی که مقدار مورد انتظار پاسخ ها به اهدافشان نزدیک باشد و واریانس پاسخ ها و واریانس پاسخ های پیش بینی شده کم باشد.

هیچکدام از روش های ذکر شده به طور همزمان از هر سه خاصیت برخوردار نیست. روش Pignatiello دو خاصیت اریبی و مقاومت را در نظر می گیرد. رویکرد Vining از دو ویژگی اریبی و کیفیت پیش بینی برخوردار است. تابع زبان کیفیت Ames و همکاران فقط میزان اریبی پاسخ ها را مد نظر دارد و Khuri و Conlon شرایط اقتصادی طرح و مقاومت آن را در نظر نمی گیرد. Ko و همکارانش خطای تصادفی  $\varepsilon_{new}(x)$  را به مقدار تخمین زده شده متغیر پاسخ  $\tilde{y}(x)$  اضافه کردند.

$(\tilde{y}_{new}(x) = \tilde{y}(x) + \varepsilon_{new}(x))$  به طوریکه  $\varepsilon_{new}(x)$  و  $\tilde{y}(x)$  مستقل از یکدیگر هستند و  $\varepsilon_{new}(x)$  همان توزیع  $\varepsilon(x)$  را دارد. آنها با محاسبه امید ریاضی تابع زبان  $\tilde{y}_{new}(x)$  به رابطه ای دست یافتند که از هر سه خاصیت اریبی، مقاومت و کیفیت پیش بینی برخوردار است.

از جمله اشکالات مشترک تابع فاصله و توابع زبان معرفی شده می توان به عدم تعیین ناحیه پذیرش و سوال بر انگیز بودن تناسب این رویکردها برای بهینه سازی پاسخ هایی که باید ماکزیمم یا می نیمم بشوند اشاره کرد [24]. مشکل اول ممکن است منجر به دستیابی به جوابی شود که تعدادی از متغیرهای پاسخ خارج از دامنه مطلوبشان قرار بگیرند و مشکل دوماز آنجایی نشات می گیرد که برای استفاده از این رویکرد ها باید یک مقدار هدف برای هر پاسخ در دست باشد.

مدل بهینه سازی مورد استفاده برای انجام گام سوم دسته سوم معمولا به میزان پیچیدگی فرآیند و تابع تجمیع پاسخ ها وابسته است. این مدل ها بر مبنای نوع تابع هدف به دو دسته کلی تکنیک های بهینه سازی توابع هدف مشتق پذیر و توابع هدف

گام دوم دسته سوم رویکرد های بهینه سازی ذکر شده در فوق، توابع مطلوبیت<sup>1</sup> [14,15]، توابع فاصله<sup>2</sup> [16]، توابع زبان<sup>3</sup> [17,18,19,20] و نسبت انطباق<sup>4</sup> [21] هستند. مفهوم مطلوبیت اولین بار توسط Harrington در 1965 معرفی شد و سپس توسط Derringer و Suich در 1980 بسط داده شد. از جمله ویژگی های توابع مطلوبیت معرفی شده توسط آنها می توان به سهولت درک روش و عدم برخورداری از پیچیدگی های ریاضی، امکان مقایسه معیارهای کیفی با واحدهای مختلف از طریق نگاشت آنها در بازه [0,1] و امکان تعیین دامنه مطلوب برای هر پاسخ و تاکید روش به قرار گرفتن تمام متغیر های پاسخ در ناحیه مطلوب اشاره کرد. مشکل اصلی این روش غفلت از اثر پراکندگی پاسخ ها است و اشکال دیگر آن مشتق پذیر نبودن در نقاط متناظر با بیشینه مطلوبیت (نقاط شکست) است.

از آنجاییکه روش های بهینه سازی مبتنی برگرادیان به تابع هدفی نیاز دارند که مشتق اول آن پیوسته باشد و با توجه به آنکه (i) روش های مبتنی برگرادیان عملکرد مناسبی در مسایل با محدودیت های غیر خطی دارند (ii) وجود گسترده نرم افزار های بهینه سازی مبتنی برگرادیان (iii) شهرت روش های بهینه سازی مبتنی برگرادیان در صنعت، تبدیل تابع مطلوبیت انفرادی Derringer و Suich به تابعی که مشتق اول آن پیوسته باشد مطلوب به نظر می رسد. برای رفع این مشکل Del Castillo و همکارانش [22] تابع مطلوبیت اصلاح شده را ارائه دادند. آنها تابع مذکور را در همسایگی نقاط مشتق ناپذیر با یک تابع پیوسته و مشتق پذیر تقریب زدند و بدین ترتیب امکان استفاده از روش های بهینه سازی مبتنی برگرادیان را امکان پذیر ساختند. Khuri و Conlon [16] یک الگوریتم بر اساس مفهوم فاصله عمومی ارائه کردند. فرم ساده تابع فاصله ارائه شده در این کار عبارت است از:

$$\text{distance}[y(x), T] = [\hat{y}(x) - T]^T \sum_{\hat{y}(x)}^{-1} [\hat{y}(x) - T]$$

به طوریکه  $T$  بردار مقادیر هدف (بهینه) و  $\sum_{\hat{y}(x)}$  ماتریس واریانس-کوواریانس پاسخ های پیش بینی شده است. Pignatiello [19] با بسط تابع زبان تک پاسخه Taguchi [23] یک تکنیک چند پاسخه بر اساس شاخص های می نیمم سازی انحراف متغیر پاسخ از مقدار هدف و حساسیت متغیر پاسخ به فاکتورهای غیر کنترلی (اختلال) پیشنهاد کرد. وی با مینیمم سازی امید ریاضی مربع خطا موزون زیر به اهداف مذکور دست پیدا کرد.

$$E[\text{loss}(y(x), T)] = [y(x) - T]^T C [y(x) - T] + \text{trace}(C \sum_{y(x)})$$

به طوریکه  $C$  ماتریس معین مثبت  $P \times P$  هزینه ها یا وزن ها است و  $\sum_{y(x)}$  ماتریس واریانس-کوواریانس پاسخ ها است. قابل

<sup>1</sup> - Desirability Functions

<sup>2</sup> - Distance Functions

<sup>3</sup> - Loss Functions

<sup>4</sup> - Proportion of Conformance

<sup>5</sup> Robustness

ارتباط بین متغیر پاسخ و فاکتورهای کنترلی مورد استفاده قرار گرفته است.

به طوریکه، تعداد نرون های لایه های ورودی و خروجی بر مبنای ابعاد بردارهای ورودی و خروجی انتخاب می شوند و تعداد مناسب نرون های لایه پنهان معمولاً با استفاده از آزمون و خطا و بر اساس شاخص هایی نظیر میانگین مربع خطا (MSE) یا مجذور میانگین مربع خطا (RMSE) تنظیم می شود. شرح مفصل الگوریتم پس انتشار برای شبکه عصبی چند لایه پیش خور را می توان در منابع مختلف جستجو کرد [۳۲].

#### ۴. رویکرد پیشنهادی

رویکرد پیشنهادی از چهار فاز اصلی طراحی آزمایش، نرمال سازی نسبت سیگنال به اختلال، طرحی شبکه عصبی مناسب و الگوریتم ژنتیک تشکیل می شود. در فاز اول متناسب با نوع مساله یک طرح آزمایش مناسب به منظور شناسایی نوع رفتار فرایند در قبال تغییرات فاکتورهای کنترلی ایجاد می شود. از آنجائیکه در این رویکرد سعی شده علاوه بر اثر مکانی، اثر پراکندگی پاسخ ها نیز در نظر گرفته شود به جای استفاده از مقادیر متغیرهای پاسخ از نسبت سیگنال به اختلال آنها استفاده می شود. با توجه به سابقه شبکه های عصبی در تخمین مناسب روابط غیرخطی و پیچیده، در فاز سه از این ابزار برای تخمین نسبت نرمال شده سیگنال به اختلال پاسخ ها بررسی می شود. نهایتاً از الگوریتم ژنتیک به عنوان یک ابزار بهینه سازی دقیق برای دستیابی به فاکتورهای کنترلی بهینه استفاده می شود.

#### ۴-۱. طراحی آزمایش<sup>۸</sup>

در کلیه زمینه های تحقیق، محققین از آزمایش ها با هدف کسب اطلاعاتی در مورد یک فرآیند یا یک سیستم خاص استفاده می کنند. طراحی آزمایش، یک آزمون یا مجموعه ای از آزمون ها است که به طور هدفمند تغییراتی در متغیر های ورودی یک فرآیند یا یک سیستم ایجاد می کند تا از این طریق، امکان مشاهده و شناسایی تغییرات ممکن در پاسخ خروجی و عوامل موثر بر آن فراهم شود [۱۳].

رویکرد ارائه شده با طراحی یک آزمایش آغاز می شود. طراحی آزمایش به ما کمک می کند داده های مورد نیاز برای آموزش و تست شبکه های عصبی را جمع آوری کنیم. طرح های RSM از قبیل مرکب مرکزی<sup>۹</sup> (CCD) یا باکس-بهنکن<sup>۱۰</sup> به علت توانایشان در پوشش مناسب فضای آزمایشی معمولاً به عنوان طرح هایی مناسب برای جمع آوری داده های مورد نیاز در نظر گرفته می شوند.

مشق ناپذیر قابل تقسیم هستند. از جمله معروفترین تکنیک های بهینه سازی توابع هدف مشتق ناپذیر می توان به سیمپلکس Nelder-Mead [۲۵] و Hooke-Jeeves [۱۴] و تکنیک های بهینه سازی توابع هدف مشتق پذیر به روش های بر مبنای گرادیان مانند گرادیان کاهشی تعمیم یافته<sup>۱</sup> (GRG) [۲۲] اشاره کرد.

از آنجائیکه روش های دقیق ذکر شده در مواجهه با توابع پیچیده غیر چند جمله ای و درجه بالا با مشکل رو به رو می شوند در طی سال های اخیر تکنیک های جستجوی هیوریستیک مانند الگوریتم ژنتیک [۲۶، ۲۷]، آنیل شبیه سازی شده [۲۸، ۲۹] و جستجوی ممنوعه [۳۰] مورد توجه بسیار قرار گرفته اند.

#### ۳. شبکه های عصبی مصنوعی

شبکه عصبی یک سیستم هوشمند مصنوعی است که از تعدادی گره (نرون) و اتصال تشکیل شده است. هر نرون تعدادی سیگنال ورودی به همراه وزن های متناظر با آنها (یعنی قدرت اتصال بین نرون ها) را دریافت می کند. بعد از تجمیع سیگنال های ورودی با استفاده از یک تابع فعال سازی<sup>۲</sup> سیگنال خروجی نرون به دست می آید. شبکه های عصبی بر مبنای نوع اتصالات بین نرون ها به دو دسته پیش خور<sup>۳</sup> و بازخور<sup>۴</sup> قابل تقسیم هستند. شبکه های پیش خور شبکه هایی هستند که در آنها هیچگونه اتصال افقی بین نرون های یک لایه یا اتصال با لایه های قبلی وجود ندارد. در حالیکه در شبکه های بازخور اتصال از یک لایه به لایه قبلی یا اتصافقی بین نرون های یک لایه وجود دارد. یادگیری عبارت است از فرایند تعدیل اوزان ارتباطی در یک شبکه عصبی، به گونه ای که در هنگام دریافت بردار ورودی، بردار خروجی مناسب را به عنوان پاسخ تولید کند.

در حالت کلی دو نوع یادگیری نظارتی و غیر نظارتی وجود دارد. در یادگیری نظارتی، مجموعه ای از بردارهای ورودی و بردارهای هدف متناظر با آنها برای تنظیم وزن های شبکه مورد استفاده قرار می گیرد. حال آنکه در یادگیری غیر نظارتی فقط مجموعه ای از بردارهای ورودی نیاز است. از مشهورترین شبکه های نظارتی می توان پرسپترون<sup>۵</sup>، شبکه عصبی پس انتشار<sup>۶</sup> (BPNN)، کوانتیزه بردار یادگیری<sup>۷</sup> (LVQ) را نام برد.

در این میان، شبکه عصبی پس انتشار به علت توانایی اش در دستیابی به راه حل های موثر برای انواع کاربردهای صنعتی [۳۱] و توان شبکه های عصبی در مدل سازی یک ارتباط غیرخطی بین ورودی و خروجی سیستم ها در این مطالعه برای مدل سازی

<sup>1</sup> - Generalized Reduced Gradient

<sup>2</sup> - Activation Function

<sup>3</sup> - Feed Forward

<sup>4</sup> - Feed Back

<sup>5</sup> - Perceptron

<sup>6</sup> - Back Propagation Neural Network

<sup>7</sup> - Learning Vector Quantization

<sup>8</sup> - Design of Experiment

<sup>9</sup> - Central Composite

<sup>10</sup> - Box-Behnken

#### ۴-۲. نسبت سیگنال به اختلال<sup>۱</sup>

فرآیند مقاوم، فرآیندی است که عملکردش کمترین حساسیت ممکن را نسبت به عوامل اختلال دارد. ناگوچی نسبت سیگنال به اختلال (SN) را به عنوان یک شاخص عملکرد مناسب برای دستیابی به یک فرآیند مقاوم معرفی کرد به طوری که با بیشینه سازی این نسبت، ترکیبی شدنی از پارامترهای فرآیند که تغییرپذیری مقادیر خروجی را کمینه و مقدار متغیر پاسخ را به عدد مورد نظر نزدیکتر می کند به دست می آید.

#### ۴-۲-۱. محاسبه نسبت سیگنال به اختلال

ناگوچی تعاریف زیر را برای نسبت SN مطابق با نوع متغیر پاسخ ارائه کرد.

i. بزرگتر-بهرتر (LTB). این تعریف زمانی کاربرد دارد که بیشینه سازی مشخصه کیفی مد نظر باشد:

$$\frac{S}{N} = -10 \log\left(\frac{1}{n} \sum_{i=1}^n \frac{1}{y_{ij}^2}\right)$$

به طوری که  $n$  = تعداد تکرار و  $y_{ij}$  = مقدار متغیر پاسخ مشاهده شده به طوری که  $i = 1, 2, \dots, n; j = 1, 2, \dots, k$

ii. کوچکتر-بهرتر (STB). این تعریف زمانی کاربرد دارد که کمینه سازی مشخصه کیفی مد نظر باشد:

$$\frac{S}{N} = -10 \log\left(\frac{1}{n} \sum_{i=1}^n \frac{1}{y_{ij}^2}\right)$$

iii. مقدار اسمی-بهرترین (NTB) این تعریف زمانی کاربرد دارد که کمینه سازی میانگین مربع خطا حول یک مقدار هدف از پیش تعیین شده مد نظر باشد.

$$\frac{S}{N} = -10 \log\left(\frac{\bar{y}^2}{s^2}\right)$$

$$\bar{y} = \frac{y_1 + y_2 + \dots + y_n}{n} \text{ و } s^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1}$$

#### ۴-۲-۲. نرمال سازی نسبت سیگنال به اختلال

نسبت های SN هر متغیر پاسخ را به وسیله فرمول زیر حساب کنید.

$$NSN_{ij} = \frac{SN_{ij} - SN_{\min,j}}{SN_{\max,j} - SN_{\min,j}}$$

به طوری که  $NSN_{ij}$  نسبت سیگنال به اختلال نرمال شده متغیر پاسخ  $z$  م در آزمایش  $i$  ام،  $SN_{ij}$  نسبت سیگنال به اختلال متغیر پاسخ  $z$  م در آزمایش  $i$  ام،  $SN_{\min,j}$  می نیمم نسبت های

سیگنال به اختلال متغیر پاسخ  $z$  م در مشاهدات آزمایشی و  $SN_{\max,j}$  ماکزیمم نسبت های سیگنال به اختلال متغیر پاسخ  $z$  م در مشاهدات آزمایشی هستند.

#### ۴-۳. تخمین نسبت های SN نرمال شده با استفاده از

##### شبکه های عصبی مصنوعی

در این گام، یک شبکه عصبی برای تخمین رابطه بین متغیرهای کنترلی و نسبت SN نرمال شده متناظر با هر متغیر پاسخ طراحی می شود. ورودی این شبکه ها متغیرهای کنترلی و خروجی هر یک از آن ها نسبت SN نرمال شده متناظر با یک متغیر پاسخ است. علت اصلی استفاده از شبکه عصبی در این رویکرد قابلیت یادگیری نگاشت های پیچیده و غیر خطی آن ها است.

#### ۴-۳-۱. انتخاب مجموعه داده های تست و مجموعه

##### داده های آموزش

حدود  $1/4$  از کل داده ها به عنوان داده های تست<sup>۲</sup> به طور تصادفی انتخاب می شوند و بقیه داده ها به عنوان داده های آموزش<sup>۳</sup> در نظر گرفته می شوند [۳۲].

#### ۴-۳-۲. تعیین ساختار و توپولوژی شبکه عصبی

برای تخمین هر نسبت SN نرمال شده از یک شبکه پس انتشار استفاده می شود که تعداد نرون های لایه اول آن برابر تعداد فاکتورهای کنترلی و تعداد نرون های لایه خروجی آن برابر یک است. از آنجایی که در مرحله قبل نسبت های SN را به گونه ای نرمال کردیم که نگاشت آن ها در بازه [0,1] قرار می گیرد بنابراین تابع فعال سازی لایه خروجی را تابع زیگموئیدی که برد آن نیز بازه [0,1] است انتخاب شده است.

#### ۴-۳-۳. طراحی شبکه عصبی مناسب برای تخمین

##### نسبتهای SN نرمال شده

در این بخش، آزمایشگر شبکه های مختلف پس انتشار را برای کشف شبکه مناسب مورد بررسی قرار می دهد. سپس برای هر شبکه، خروجی شبکه برای داده های تست و داده های آموزش با مشاهدات حاصل از آزمایش ها مقایسه می شوند. نهایتاً شبکه با کمترین MSE به عنوان شبکه بهینه انتخاب می شود.

#### ۴-۴. بهینه سازی با استفاده از الگوریتم ژنتیک

الگوریتم ژنتیک به دو دلیل مهم برای فرآیند جستجوی جواب بهینه انتخاب شده است. (۱)

روش های بهینه سازی بر مبنای گرادیان مانند GRG برای محاسبه گرادیان و جهت بهبود نیاز به سطوح پاسخ دارند در

<sup>۲</sup> - test data

<sup>۳</sup> - training data

<sup>۱</sup> - SN ratio

مقدار احتمال کمتر از ۰.۵، باشد مقدار ژن از والد اول گرفته می شود، در غیر این صورت از ژن متناظر والد دوم گرفته می شود. به منظور افزایش پراکندگی در جمعیت عملگر جهش مورد استفاده قرار می گیرد. در این مطالعه، از عملگر جهش تصادفی<sup>۸</sup> استفاده شده است. بدین ترتیب که یکی از کرموزوم های فرزند به طور تصادفی انتخاب می شود سپس یک ژن از آن را به طور اتفاقی انتخاب می کند. یک مقدار تصادفی از توزیع یکنواخت در بازه (۰-۱) تولید و جایگزین ژن اولیه می شود.

#### ۴-۴-۶. شاخص توقف

الگوریتم بعد از یک تعداد از پیش تعیین شده تکرار خاتمه می یابد.

### ۵. مثال عددی

در این بخش تاثیر پذیری رویکرد ارائه شده با استفاده از مثال (Tong et al., 2005) [۳۳] نمایش داده شده است. این مثال شامل پنج متغیر کنترلی  $(X_1, X_2, X_3, X_4, X_5)$  و دو متغیر پاسخ  $(Y_1, Y_2)$  است. به طوریکه  $Y_1$  متغیر پاسخ از نوع STB و  $Y_2$  از نوع LTB است. در حل مثال فرض شده است که دو متغیر پاسخ از اهمیت نسبی یکسانی برخوردار هستند بنابراین  $w_1 = w_2 = \frac{1}{2}$  در نظر گرفته شده اند. مشاهدات آزمایشی در جدول ۱ و نسبت های سیگنال به اختلال و سیگنال به اختلال نرمال شده در جدول ۲ نمایش داده شده اند. مطابق با رویکرد ارائه شده بعد از محاسبه نسبت های سیگنال به اختلال نرمال شده باید شبکه عصبی بهینه برای تخمین آن ها طراحی شود. از آنجاییکه شبکه های عصبی با یک یا دو لایه پنهان توانایی توصیف هرگونه رابطه غیر خطی بین ورودی ها و خروجی ها را دارند [۳۴] و از طرف دیگر افزایش تعداد لایه ها منجر به رشد سریع تعداد پارامترهای شبکه می شود در نتیجه در فرآیند شناسایی شبکه عصبی مناسب مطالعات خود را به شبکه های با دو لایه محدود می کنیم.

در جهت کشف شبکه های عصبی مناسب برای تخمین نسبت سیگنال به اختلال نرمال شده متغیرهای پاسخ شبکه های پس انتشار پیش خور با پارامترهای مختلف آزمایش شدند. شبکه های مناسب با کمترین مقادیر MSE در جدول ۳ ارائه شده اند. در هر دو شبکه لایه های میانی از تابع فعال سازی تانژانت هیپربولیکی و لایه خروجی همچنان که قبلا اشاره شده بود از تابع فعال سازی زیگموئیدی استفاده می کنند. الگوریتم آموزش در هر دو شبکه لیونبرگ-مارکوآرت<sup>۹</sup> است و نسبت داده های تست به کل داده ها برای هر دو شبکه ۲۲،۲۲٪ است. به منظور مقایسه عملکرد

حالی که در این روش به جای محاسبه سطوح پاسخ از شبکه عصبی برای تخمین مقادیر نرمال شده نسبت های SN استفاده شده است. (۲) الگوریتم ژنتیک به عنوان یک رویکرد جستجوی احتمالی قدرتمند برای بهینه سازی توابع پیچیده شناخته شده است.

#### ۴-۴-۱. کد کردن راه حل<sup>۱</sup>

برای نمایش هر راه حل از یک رشته اعداد حقیقی در بازه (۰-۱) به طول تعداد متغیرهای کنترلی استفاده می شود. به طوریکه، هر ژن مقدار اختصاص داده شده به متغیر کنترلی متناظر با آن را نمایش می دهد.

#### ۴-۴-۲. راه حل اولیه<sup>۲</sup>

الگوریتم ژنتیک برای آغاز فرآیند جستجو به یک جمعیت اولیه نیاز دارد که می توان آن را با انواع روش های هیوریستیک تولید کرد. در این مقاله راه حل اولیه با تولید مقدار تصادفی از توزیع یکنواخت در بازه (۰-۱) برای هر ژن حاصل می شود.

#### ۴-۴-۳. ارزیابی<sup>۳</sup>

در این بخش، به منظور تعیین سطح عملکرد هر راه حل مقدار برازش متناظر با آن با استفاده از تابع زیر محاسبه می شود.

$$f(x) = \sum_{j=1}^n w_j NSN_j$$

به طوریکه  $f(x)$  نسبت سیگنال به اختلال نرمال شده موزون،  $w_j$  اهمیت نسبی متغیر پاسخ  $j$ ام،  $NSN_j$  نسبت سیگنال به اختلال نرمال شده متناظر با متغیر پاسخ  $j$ ام و  $n$  تعداد متغیرهای پاسخ است.

#### ۴-۴-۴. انتخاب<sup>۴</sup>

عملگر انتخاب دو راه حل از جمعیت را به عنوان والد برای تولید اولاد به وسیله عملگر های ادغام<sup>۵</sup> و جهش<sup>۶</sup> انتخاب می کند. مکانیزم استفاده شده در این بخش بر اساس مقدار برازش کرموزوم ها است. یعنی کرموزوم با مقدار برازش بهتر با احتمال بیشتری به عنوان والد انتخاب می شود.

#### ۴-۴-۵. عملگرهای ادغام و جهش

فرآیند ادغام از فرآیند ترکیب کرموزوم ها در طول تولید مثل در موجودات زنده شبیه سازی شده است. در این مطالعه از عملگر ادغام یکنواخت<sup>۷</sup> استفاده شده است. بدین معنی که ابتدا یک بردار احتمال به اندازه تعداد متغیر های کنترلی تولید می شود. اگر

<sup>1</sup> - solution encoding

<sup>2</sup> - initial solution

<sup>3</sup> -Evaluation

<sup>4</sup> -Selection

<sup>5</sup> -crossover

<sup>6</sup> -mutation

<sup>7</sup> -Uniform crossover

<sup>8</sup> - Random mutation

<sup>9</sup> - Levenberg-Marquardt

شبکه‌های عصبی و روش سطح پاسخ در تخمین نسبت NSN رگرسیونی نسبت NSN هر متغیر پاسخ استفاده شده است که متغیرهای پاسخ، از داده های آموزش برای تخمین مدل نتایج آن به شرح زیر است.

جدول ۱. مشاهدات آزمایشی

شماره آزمایش	فاکتورهای کنترلی					متغیرهای پاسخ	
	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	Y <sub>1</sub>	Y <sub>2</sub>
۱	-۱	-۱	-۱	-۱	-۱	۱۴.۳	۴.۰
۲	-۱	۰	۰	۰	۰	۱۵.۷	۴.۳
۳	-۱	۱	۱	۱	۱	۲۳.۲	۵.۶
۴	۰	-۱	-۱	۰	۰	۱۲.۱	۳.۷
۵	۰	۰	۰	۱	۱	۸.۷	۴.۹
۶	۰	۱	۱	-۱	-۱	۶.۵	۶.۱
۷	۱	-۱	۰	-۱	۱	۸.۹۹	۴.۲
۸	۱	۰	۱	۰	-۱	۱۱.۸	۴.۳
۹	۱	۱	-۱	۱	۰	۱۲.۴	۵.۳
۱۰	-۱	-۱	۱	۱	۰	۱۶.۲	۴.۶
۱۱	-۱	۰	-۱	-۱	۱	۲۶.۹	۴.۱
۱۲	-۱	۱	۰	۰	-۱	۱۰.۵	۵.۳
۱۳	۰	-۱	۰	۱	-۱	۱۶.۹	۳.۹
۱۴	۰	۰	۱	-۱	۰	۵.۰۶	۴.۷
۱۵	۰	۱	-۱	۰	۱	۷.۰۸	۵.۴
۱۶	۱	-۱	۱	۰	۱	۸.۷۶	۵.۲
۱۷	۱	۰	-۱	۱	-۱	۱۵.۱	۴.۶
۱۸	۱	۱	۰	-۱	۰	۵.۰	۵.۸

جدول ۲. نسبت سیگنال به اختلال و نسبت سیگنال به اختلال نرمال شده

شماره آزمایش	فاکتورهای کنترلی					نسبت SN		نسبت NSN	
	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	Y <sub>1</sub>	Y <sub>2</sub>	Y <sub>1</sub>	Y <sub>2</sub>
۱	-۱	-۱	-۱	-۱	-۱	-۲۳.۱۱	۱۲.۰۴	۰.۳۷۵۵۱۳	۰.۱۵۶۳۲۲
۲	-۱	۰	۰	۰	۰	-۲۳.۹۲	۱۲.۶۷	۰.۳۲۰۱۰۹	۰.۳۰۱۱۴۹
۳	-۱	۱	۱	۱	۱	-۲۷.۳۱	۱۴.۹۶	۰.۰۸۸۲۳۵	۰.۸۲۷۵۸۶
۴	۰	-۱	-۱	۰	۰	-۲۱.۶۶	۱۱.۳۶	۰.۴۷۴۶۹۲	۰
۵	۰	۰	۰	۱	۱	-۱۸.۷۹	۱۳.۸۰	۰.۶۷۰۹۹۹	۰.۵۶۰۹۲
۶	۰	۱	۱	-۱	-۱	-۱۶.۲۶	۱۵.۷۱	۰.۸۴۴۰۴۹	۱
۷	۱	-۱	۰	-۱	۱	-۱۹.۰۸	۱۲.۴۶	۰.۶۵۱۱۶۳	۰.۲۵۲۸۷۴
۸	۱	۰	۱	۰	-۱	-۲۱.۴۴	۱۲.۶۷	۰.۴۸۹۷۴	۰.۳۰۱۱۴۹
۹	۱	۱	-۱	۱	۰	-۲۱.۸۷	۱۴.۴۹	۰.۴۶۰۳۲۸	۰.۷۱۹۵۴
۱۰	-۱	-۱	۱	۱	۰	-۲۴.۱۹	۱۳.۲۶	۰.۳۰۱۶۴۲	۰.۴۳۶۷۸۲
۱۱	-۱	۰	-۱	-۱	۱	-۲۸.۶۰	۱۲.۲۶	۰	۰.۲۰۶۸۹۷
۱۲	-۱	۱	۰	۰	-۱	-۲۰.۴۲	۱۴.۴۹	۰.۵۵۹۵۰۸	۰.۷۱۹۵۴
۱۳	۰	-۱	۰	۱	-۱	-۲۴.۵۶	۱۱.۸۲	۰.۲۷۶۳۳۴	۰.۱۰۵۷۴۷
۱۴	۰	۰	۱	-۱	۰	-۱۴.۰۸	۱۳.۴۴	۰.۹۹۳۱۶	۰.۴۷۸۱۶۱
۱۵	۰	۱	-۱	۰	۱	-۱۷.۰۰	۱۴.۶۵	۰.۷۹۳۴۳۴	۰.۷۵۶۳۲۲
۱۶	۱	-۱	۱	۰	۱	-۱۸.۸۵	۱۴.۳۲	۰.۶۶۶۸۹۵	۰.۶۸۰۴۶
۱۷	۱	۰	-۱	۱	-۱	-۲۳.۵۸	۱۳.۲۶	۰.۳۴۳۳۶۵	۰.۴۳۶۷۸۲
۱۸	۱	۱	۰	-۱	۰	-۱۳.۹۸	۱۵.۲۷	۱	۰.۸۹۸۸۵۱

جدول ۳. خصوصیات شبکه های عصبی

شبکه	متغیر پاسخ	تعداد نرون های لایه های پنهان	MSE	
			تست	آموزش
۱	Y <sub>1</sub>	۶,۴	۰,۰۳۴	۱,۴۱×۱۰ <sup>-۱۳</sup>
۲	Y <sub>2</sub>	۶,۴	۰,۰۲۷	۵,۶۳×۱۰ <sup>-۱۳</sup>

$$NSN_{Y_1} = 0.5786 - 0.0361 * x_1 + 0.1488 * x_2 - 0.0271 * x_3 + 0.153 * x_4 + 0.1217 * x_5 + 0.33 * x_1 * x_2 + 0.2787 * x_1 * x_3 - 0.2514 * x_1 * x_4 + 0.1826 * x_1 * x_5 + 0.0178 * x_2 * x_3 + 0.1197 * x_2 * x_4 - 0.065 * x_2 * x_5 - 0.4553 * x_3 * x_4$$

$$(x_1, x_2, x_3, x_4, x_5) NSN_{Y_1} = 0.5505 + 0.1531 * x_1 + 0.3626 * x_2 + 0.2666 * x_3 + 0.0489 * x_4 + 0.1935 * x_5 + 0.1323 * x_1 * x_2 - 0.1951 * x_1 * x_3 + 0.3183 * x_1 * x_4 + 0.2804 * x_1 * x_5 + 0.0787 * x_2 * x_3 - 0.0676 * x_2 * x_4 - 0.0051 * x_2 * x_5 + 0.0885 * x_3 * x_4$$

جدول ۴. مقادیر MSE مدل های رگرسیون

	پاسخ	Y <sub>1</sub>	Y <sub>2</sub>
MSE	تست	۰,۱۸۲۳	۰,۰۹۸۷۸۶
	آموزش	۷,۵۶×۱۰ <sup>-۹</sup>	۱,۱۳۷×۱۰ <sup>-۸</sup>

- [4] Hsieh, K.L., Tong, L.I., *Optimization of Multiple Quality Responses Involving Qualitative and Quantitative Characteristics in IC Manufacturing using Neural Networks*. Computers in Industry 46, 2001, 1-12.
- [5] Noorossana, R, Davanloo, Tajbakhsh, S., Saghaei, A., *An artificial Neural Network Approach to Multiple-Response Optimization*. Int Adv Manuf Technol 40, 2009, 1227-1238.
- [6] Ortiz, F., Simpson, J.R., Pignatiello, J.J., Heredia-Langner, A., *A Genetic Algorithm Approach to Multiple-Response Optimization*. J Qual Technol 36: 2004, 432-450.
- [7] Hsieh, K.L., *Parameter Optimization of a Multi-Response Process for Lead Frame Manufacturing by Employing Artificial Neural Networks*. Int Adv Manuf Technol 28, 2006, 584-591.
- [8] Myers, R.H, Montgomery, D.C., *Response Surface Methodology: Process and Product Optimization using Designed Experiments*, 2<sup>nd</sup> edn. Wiley, New York, 2002.
- [9] Del Castillo, E., Montgomery, D.C., *A Non linear Programming Solution to the Dual Response Problem*. Journal of Quality Technology 25., 1993, pp. 199-204.
- [10] Kim, K.J., Lin, D.K.J., *Optimization of Multiple Responses Considering Both Location and Dispersion Effects*. European Journal of Operational Research 169, 2006, 133-145.
- [11] Plante, R.D., *Multicriteria Models for the Allocation of Design Parameter Targets*. European Journal of Operational Research, 115, 1999, 98-112.
- [12] Kim, K.J., Byun, J.H., Min, D., Jeong, I.J., *Multiresponse Surface Optimization: Concept, Methods, and future directions*. Tutorial, Korea Society for Quality Management, 2001.
- [13] Montgomery, D.C., Peck, E.A., Vinning, G., *Introduction to Linear Regression Analysis*, 3rd edn. Wiley, New York, 2001.

مقادیر MSE مدل های رگرسیونی در جدول ۴ ارائه شده است، همچنان که مشاهده می شود نتایج بر عملکرد بهتر شبکه های عصبی دلالت می کنند. نهایتاً فرآیند بهینه سازی الگوریتم ژنتیک منجر به تنظیم پارامتر بهینه  $(X_1, X_2, X_3, X_4, X_5) = (1, 1, -1, -1, 1)$  شد.

#### ۶. نتیجه گیری

در این مقاله برای غلبه بر ضعف مدل های رگرسیون چندجمله ای در تخمین رابطه ای مناسب بین متغیر های کنترلی و متغیر پاسخ در فرآیند های پیچیده و مشکلات روش های بهینه سازی دقیق در حل چنین مسائلی یک رویکرد جدید بر مبنای شبکه عصبی و الگوریتم ژنتیک ارائه شد. رویکرد ارائه شده علاوه بر پوشش دادن نقاط ضعف ذکر شده از چهار ویژگی مطلوب دیگر نیز برخوردار است. (۱) این رویکرد عدم قطعیت در فرآیند را کاهش می دهد. (۲) رویکردهای آماری سنتی موجود برای تخمین رابطه بین متغیر های کنترلی و متغیر پاسخ نیازمند یک سری فرضیات آماری هستند در حالیکه رویکرد ارائه شده بدون نیاز به هیچ فرضی قابلیت تخمین رابطه مذکور را دارد. (۳) رویکرد ارائه شده یک رویکرد عمومی برای حل مسائل بهینه سازی با چند سطح پاسخ است که برخلاف بیشتر رویکردهای موجود اهمیت نسبی متغیر های پاسخ را در نظر می گیرد. (۴) رویکرد مذکور فاقد پیچیدگی های ریاضی نامطلوب است و بنابراین برای مهندسی بدون پیش زمینه آماری قابل استفاده است.

#### مراجع

- [1] Peace, G.S., *Taguchi Methods: a Hands-on Approach*. Addison- Wesley, Boston, 1993.
- [2] Phadke, M.S., *Quality Engineering Using Robust Design*. Prentice- Hall, New York, 1989.
- [3] Su, C.T., Hsieh, K.L., *Applying Neural Networks to Achieve Robust Design for Dynamic Quality Characteristics*. Int J Qual Reliab Manage 15, 1998, 509-519.



- [30] Baykasoglu, A., Owen, S., Gindy, N., *A Taboo Search Based Approach to Find the Pareto Optimal Set in Multiple Objective Optimization*, Engineering Optimization 31, 1999, 731\_748.
- [31] Dayhoff, J.E., *Neural Network Architecture*. New York: Van Nostrand Reinhold, 1990.
- [32] Neural Ware Inc., *Neural Works Professional II/Plus and Neural Works Explorer*, Neural Ware Inc., Penn Centre West, 1990.
- [33] Tong, L.I., Wang, C.H., Chen, H.C., *Optimization of Multiple Responses Using Principal Component Analysing and Technique for Order Preference by Similarity to Ideal Solution*. Int J Adv Manuf Technol 27, 2005, 407-414.
- [34] Hagan, M.T., Demuth, H.B., Beale, M.H., *Neural Network Design*. PWS Publishing Co, 1996.
- [14] Derringer, G., Suich, R., *Simultaneous Optimization of Several Response Variable*, Journal of Quality Technology 12, 1980, 214\_219.
- [15] Harrington, E.C Jr., *The Desirability Function*. Ind Qual Control 21: 1965, 494-498.
- [16] Khuri, A.I., Conlon, M., *Simultaneous Optimization of Multiple Responses Represented by Polynomial Regression Functions*. Technometrics 23, 1981, 363-375.
- [17] Ames, A.E., Mattucci, N., Macdonald, S., Szonyi, G., Hawkins, D.M., *Quality Loss Function for Optimization across Multiple Response Surface*, Journal of Quality Technology 29, 1997, 339-346.
- [18] Ko, Y.H., Kim, K.J., Jun, C.H., *A New Loss Function-Based Method for Multiresponse Optimization*. Journal of Quality Technology 37, 2005, 50-59.
- [19] Pignatiello, JJ, Jr., *Strategies for Robust Multi-Response Quality Engineering*. IIE Trans 25: 1993, 5-15.
- [20] Vining, G.G., *A Compromise Approach to Multiresponse Optimization*. J Qual Technol 30(4), 1998, 309-313.
- [21] Chiao, C.H., Hamada, M.S., *Analyzing Experiments with Correlated Multiple Responses*. J Qual Technol 33(4): 2001, 451-465.
- [22] Del Castillo, E., Montgomery, D.C., McCarville, D.R., *Modified Desirability Functions for Multiple Response Optimization*. J Qual Technol 28(3): 1996, 337-345.
- [23] Taguchi, G., Elsayed, E.A., Hsiabg, T., *Quality Engineering in Production Systems*, McGraw-Hill, New York. 1989.
- [24] Wurl, R.C., Albin, S.L., *A Comparison of Multiresponse Optimization: Sensivity to Parameter Selection*. Quality Engineering 11, 1999, 405-415.
- [25] Nelder, J.A., Mead, R., *A Simplex Method for Function Minimization*. Comput 7: 1965, 308-313.
- [26] Cheng, B.C., Cheng, C.J., Lee, E.S., *Neuro-Fuzzy and Genetic Algorithm in Multiple Response Optimization*, Computers and Mathematics with Application 44, 2002, 1503\_1514.
- [27] Pasandideh, S.H.R, Niaki, S.T.A., *Multi-Response Simulation Optimization using Genetic Algorithm within Desirability Function Framework*, Applied Mathematics and Computation 175, 2006, 366\_382.
- [28] Tsoulos, I.G., Lagaris, I.E., *GenAnneal: Genetically Modified Simulated Annealing*, Computer Physics Communications 174, 2006, 846\_851.
- [29] Suppaitnarm, K.A., Seffen, G.T., Parks, P.J., Clarkson, *A Simulated Annealing Algorithm for Multi Objective Optimization*, Engineering Optimization 33, 2009, 59\_85.