



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

محمد رضا امین ناصری*, رضا برادران کاظم زاده, علی سلاماس نیا و مجتبی صالحی

چکیده:

در بیشتر مسایل بهینه سازی دنیای واقعی با تنظیم متغیر های فرآیند 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، متدولوزی سطح پاسخ^۱ (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 منا سبی از آن دست یافت و از طرف دیگر، حل چنین مساله بهینه سازی با روش های دقیق^۲ 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 پاسخه 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

اختلال^۳ (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 گاها 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 پاسخه 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

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^۲ در تنظیم متغیرهای کنترلی، اثرات مکانی و پراکندگی مشخصه کیفی (متغیر پاسخ) را توانما 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

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 سلاماس 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

² - Robust Design

اندازه و پیجیدگی مساله بستگی دارد. دسته اول شامل قرار دادن نمودارهای کانتور پاسخ ها بر روی یکدیگر و پیدا کردن منطقه ای است که پاسخ های مختلف ارضاء می شوند. Myers و Montgomery [۸] بیان می کنند که این رویکرد فقط زمانیکه تعداد متغیرهای طرح کم باشد می تواند 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 می پردازند، می توان به دو زیر مجموعه کلی تقسیم کرد. در زیر مجموعه اول یک متغیر پاسخ به عنوانتابع هدف انتخاب می شود و بقیه پاسخ ها به عنوان محدودیت در مدل وارد می شوند. مشکل اصلی این رویکرد ها آن است که انتخاب یک متغیر پاسخ به عنوانتابع هدف در بیشتر موارد کار آسانی نیست. در زیر مجموعه دوم از یک عملگر می نیم یا ماکریم ساز در تابع هدف استفاده می شود و همه متغیر های پاسخ به عنوان محدودیت در مدل وارد می شوند.

مهمترین ایراد وارد شده به این رویکرد ها توجه صرف آن ها به متغیر پاسخ با می نیم درجه رضایت و غفلت از میزان درجه رضایت سایر پاسخ ها است که این امر در بعضی موارد منجر به جواب های غیر منطقی می شود. از جمله این رویکردها می توان به Montgomery و Del Castillo [۹]، تحقیقات Kim و Lin [۱۰]، Plante [۱۱] در سال های ۲۰۰۶ و ۱۹۹۹ اشاره کرد. دسته سوم رویکردهایی هستند که از سه گام تشکیل می شوند. ابتدا مدل پاسخ های مورد علاقه ایجاد می گردد سپس در مرحله دوم یک رویکرد برای ترکیب مدلها استفاده می شود و در نهایت با استفاده از یک روش بهینه سازی مدل را بهینه می کند. بیشتر رویکردهای بهینه سازی چند پاسخه موجود در ادبیات به این دسته اختصاص دارند و عدمه تفاوت بین آن ها در روش تجمعی پاسخ ها و روش بهینه سازی مورد استفاده است. روش های مختلفی برای انجام گام اول یعنی تخمین رابطه بین پاسخ و متغیر های طرح وجود دارد. معمول ترین متد برای انجام این کار روش حداقل مربعات^۱ (OLS) است ولی در حالت کلی روش انتخاب شده برای این منظور به میزان پیجیدگی رابطه بستگی دارد. در بعضی موارد مقادیر بزرگ میانگین مربع خطأ^۲ مدل های رگرسیون که نشان از کیفیت ضعیف توصیف روابط مذکور دارد مشاهده می شود kim و همکاران [۱۲] این مشکل در بیشتر موارد به دو علت رخ می دهد. (۱) نقض فرض استقلال متغیر های ورودی (۲) پیچیده بودن رابطه بین پاسخ و متغیر های کنترلی [۱۳].

در این موارد استفاده از شبکه های عصبی مصنوعی^۳ (ANN) توصیه شده است [۳,۷]. معروف ترین روش های تجمعی برای انجام

دستیابی به یک تخمین مناسب شبکه های عصبی مصنوعی هستند. Su و Hsieh [۳] یک رویکرد بر اساس شبکه های عصبی و متند تاگوجی 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 شبکه های عصبی ارائه کردند. در این رویکرد از دو شبکه عصبی یکی برای کشف بردار فاکتور های کنترلی بهینه و دیگری برای تخمین پاسخ ها استفاده از شود. شبکه های عصبی مصنوعی Noorossana و همکاران [۵] نیز در کاری مشابه استفاده از تخمین متغیر های پاسخ معرفی کردند.

آنها با استفاده از تابع مطلوبیت Ortiz و همکاران [۶] به تجمعی متغیر های پاسخ پرداختند و از الگوریتم ژنتیک در فاز بهینه سازی استفاده کردند. Hsieh [۷] در سال ۲۰۰۶ با استفاده از دو شبکه عصبی روشنی برای حل مسایل چند پاسخه ارائه کرد که بر خلاف سایر رویکردهای برمبنای شبکه عصبی، اثر فاکتورهای کنترلی روی متغیر پاسخ را به دست می آورد. هیچکدام از سه رویکرد بهینه سازی چند پاسخه مذکور اثر پراکندگی پاسخ ها را در نظر نمی گیرند. به عبارت دیگر، این رویکرد ها فرض می کنند که واریانس متغیر های پاسخ روی فضای آزمایشی ثابت است. از آنجاییکه در بیشتر مسایل دنیا واقعی با روابط پیچیده بین پاسخ و فاکتور های کنترلی مواجه هستیم. از این رو، در این مطالعه به ارائه روشنی برای بهینه سازی مسایل با چند سطح پاسخ وقتیکه روابط رگرسیونی توانایی تخمین مناسب رابطه بین پاسخ و متغیر های طرح را ندارند می پردازیم.

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

۲. مرور ادبیات

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

^۱ - Ordinary List Square

^۲ - Mean Square Error

^۳ - Artificial Neural Network

توجه است که مدل Conlon و Khuri نوع خاصی از رویکرد Pignatiello است هنگامیکه $C = \sum_{y(x)}^{-1}$ در نظر گرفته شود Vining [۲۰] در سال ۱۹۹۸ مدل Pignatiello را با جایگزین کردن $\sum_{y(x)}$ به جای \sum 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 [۱۷] رویکرد تابع زیان کیفیت را بر اساس مدل های سطح پاسخ برای حل مسایل با چند سطح پاسخ ارائه کردند. هدف اصلی این رویکرد صرفاً تجمیع پاسخ ها و می نیمم سازی انحراف آنها از مقادیر هدف است. طبق نظر Ko و همکارانش [۱۸] یک رویکرد مناسب برای تجمیع متغیر های پاسخ باید دارای سه ویژگی اربی کم، مقاومت^۵ 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 اربی و مقاومت را در نظر می گیرد. رویکرد Vining از دو ویژگی اربی و Ames کیفیت پیش بینی برخوردار است. تابع زیان کیفیت Khuri و همکاران فقط میزان اربی پاسخ ها را مد نظر دارد و Conlon شرایط اقتصادی طرح و مقاومت آن را در نظر نمی گیرد. Ko و همکارانش خطای تصادفی $(x)_{new}^{\epsilon}$ را به مقدار تخمین زده شده متغیر پاسخ (x) \tilde{y} اضافه کردند.

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

از جمله اشکالات مشترک تابع فاصله و تابع زیان معرفی شده می توان به عدم تعیین ناحیه پذیرش و سوال بر انگیز بودن تناسب این رویکردها برای بهینه سازی پاسخ هایی که باید ماکریم یا می نیمم بشوند اشاره کرد [۲۴]. مشکل اول ممکن است منجر به دستیابی به جوابی شود که تعدادی از متغیرهای پاسخ خارج از دامنه مطلوبشان قرار بگیرند و مشکل دوم 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 عموماً 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 تابع هدف مشتق پذیر و تابع هدف

گام دوم دسته سوم رویکردهای بهینه سازی ذکر شده در فوق، توابع مطلوبیت^۱ [۱۴, ۱۵]، توابع فاصله^۲ [۱۶]، توابع زیان^۳ [۱۷, ۱۸, ۱۹, ۲۰] و نسبت انطباق^۴ [۲۱] هستند. مفهوم مطلوبیت اولین بار توسط Harrington در ۱۹۶۵ معرفی شد و سپس توسط Derringer و Suich در ۱۹۸۰ بسط داده شد. از جمله ویژگی های تابع 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 پراکنده^۵ 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 (۵) 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 Del Castillo و مطلوب به نظر می رسد. برای رفع این مشکل همکارانش [۲۲] تابع مطلوبیت اصلاح شده را ارائه دادند. آنها تابع همکارانش [۱۶] یک الگوریتم بر اساس مفهوم فاصله عمومی ارائه کردند. فرم ساده تابع فاصله ارائه شده در این کار عبارت است از:

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

به طوریکه T بردار مقادیر هدف(بهینه) و $\sum_{y(x)}$ ماتریس واریانس-کوواریانس پاسخ های پیش بینی شده است. Pignatiello [۱۹] با بسط تابع زیان تک پاسخه Taguchi [۲۳] 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 خطای موزون زیر به اهداف مذکور دست پیدا کرد.

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

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

¹ - Desirability Functions

² - Distance Functions

³ - Loss Functions

⁴ - Proportion of Conformance

⁵ Robustness

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

به طوریکه، تعداد نمونه های لایه های ورودی و خروجی بر مبنای ابعاد بردارهای ورودی و خروجی انتخاب می شوند و تعداد مناسب نمونه های لایه پنهان معمولاً با استفاده از آزمون و خطأ و بر اساس شاخص های نظری میانگین مربع خطأ (MSE) یا مجدد میانگین مربع خطأ (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 آنجاییکه در این رویکرد سعی شده علاوه بر اثر مکانی، اثر پراکندگی پاسخ ها نیز درنظر 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^۸

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^۹ (CCD) یا باکس-بهنکن^{۱۰} به علت تواناییشان در پوشش مناسب فضای آزمایشی معمولاً به عنوان طرح هایی مناسب برای جمع آوری داده های مورد نیاز در نظر گرفته می شوند.

مشتق 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 [۱۶] و تکنیک های بهینه سازی توابع هدف مشتق پذیر به روش های بر مبنای گرادیان مانند گرادیان کاھشی تعمیم یافته^۱ (GRG) [۲۲] اشاره کرد.

از آنجاییکه روش های دقیق ذکر شده در مواجه 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 [۲۹, ۲۸] 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 (نمونه) و اتصال تشکیل شده است. هر نمونه تعدادی سیگنال ورودی به همراه وزن های متناظر با آنها (یعنی قدرت اتصال بین نمونه ها) را دریافت می کند. بعد از تجمیع سیگنال های ورودی با استفاده از یکتابع فعال سازی^۲ سیگنال خروجی نمونه به دست می آید. شبکه های عصبی بر مبنای نوع اتصالات بین نمونه ها به دو دسته پیش خور^۳ و باز خور قابل تقسیم هستند. شبکه های پیش خور شبکه هایی هستند که در آنها هیچگونه اتصال افقی بین نمونه های یک لایه یا اتصال با لایه های قبلی وجود ندارد. حالیکه در شبکه های باز خور اتصال از یک لایه به لایه قبلی یا اتصال افقی بین نمونه های یک لایه وجود دارد. یادگیری عبارت است از فرایند تعديل 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^۴، شبکه عصبی پس انتشار^۵ (BPNN)، کوانتیزه بردار یادگیری^۶ (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

^۱-Generalized Reduced Gradient

^۲-Activation Function

^۳-Feed Forward

^۴-Feed Back

^۵-Perceptron

^۶-Back Propagation Neural Network

^۷-Learning Vector Quantization

^۸ - Design of Experiment

^۹ - Central Composite

^{۱۰} -Box-Behncken

سیگنال به اختلال متغیر پاسخ Z_m در مشاهدات آزمایشی و $SN_{max,j}$ ماکریم نسبت های سیگنال به اختلال متغیر پاسخ Z_m 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 متغیر های کنترلی و نسبت SN نرمال شده متناظر با هر متغیر پاسخ طراحی می شود. ورودی این شبکه ها متغیر های 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 $\frac{1}{4}$ از کل داده ها به عنوان داده های تست^۳ به طور تصادفی انتخاب می شوند و بقیه داده ها به عنوان داده های آموزش^۴ 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 آنجاییکه 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

۴-۲. نسبت سیگنال به اختلال^۵

فرآیند مقاوم، فرآیندی است که عملکردش کمترین حساسیت ممکن را نسبت به عوامل اختلال دارد. تاگوچی نسبت سیگنال به اختلال(SN)را به عنوان یک شاخص عملکرد مناسب برای دستیابی به یک فرآیند مقاوم معرفی کرد به طوریکه 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

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

a. بزرگتر-بهتر(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 طوریکه n = تعداد تکرار و y_{ij} = مقدار متغیر پاسخ مشاهده شده به طوریکه $i=1,2,\dots,n; j=1,2,\dots,k$. ii. کوچکتر-بهتر(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-بهترین(NTB) این تعریف زمانی کاربرد دارد که کمینه سازی میانگین مربع خطأ 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 طوریکه NSN_{ij} نسبت سیگنال به اختلال نرمال شده متغیر پاسخ Z_m در آزمایش i ام، SN_{ij} نسبت سیگنال به اختلال متغیر پاسخ Z_m در آزمایش i ام، $SN_{min,j}$ می نیم نسبت های

¹-SN ratio

² - test data
³ - training data

مقدار احتمال کمتر از ۵٪ باشد مقدار ژن از والد اول گرفته می شود، در غیر اینصورت از ژن متناظر والد دوم گرفته می شود. به منظور افزایش پراکنده‌گی در جمعیت عملگر جهش مورد استفاده قرار می‌گیرد. در این مطالعه، از عملگر جهش تصادفی^۸ استفاده شده است. بدین ترتیب که یکی از کرموزوم‌های 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 می‌یابد.

۵. مثال عددی

در این بخش تاثیر پذیری رویکرد ارائه شده با استفاده از مثال (Tong et al [۳۳] نمایش داده شده است. این مثال شامل پنج متغیر کنترلی (x_1, x_2, x_3, x_4, x_5) و دو متغیر STB پاسخ (y_1, y_2) است. به طوریکه y_1 متغیر پاسخ از نوع $w_1 = w_2 = \frac{1}{2}$ 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 فرایند 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 از میانش شدنند. 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 هیبرabolیکی و لایه خروجی همچنان که قبل اشاره شده بود از تابع فعال سازی زیگموئیدی استفاده می کنند. الگوریتم آموزش در هر دو شبکه لیونبرگ-مارکوارت^۹ است و نسبت داده های تست به کل داده ها برای هر دو شبکه ۲۲٪ است. به منظور مقایسه عملکرد

حالیکه 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^۱

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^۲

الگوریتم ژنتیک برای اغاز 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^۳

در این بخش، به منظور تعیین سطح عملکرد هر راه حل مقدار برآش 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/ست.

۴-۴-۴. انتخاب^۴

عملگر انتخاب دو راه حل از جمعیت را به عنوان والد برای تولید اولاد به وسیله عملگر های ادغام^۵ و جهش^۶ انتخاب می کند. مکانیزم استفاده شده در این بخش بر اساس مقدار برآش کرموزوم ها است. یعنی کرموزوم با مقدار برآش 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^۷ استفاده شده است. بدین معنی که ابتدا یک بردار احتمال به اندازه تعداد متغیر های کنترلی تولید می شود. اگر

^۱ - solution encoding

^۲ - initial solution

^۳ -Evaluation

^۴ -Selection

^۵ -crossover

^۶ -mutation

^۷ -Uniform crossover

رگرسیونی نسبت NSN هر متغیر پاسخ استفاده شده است که نتایج آن به شرح زیر است.

شبکه های عصبی و روش سطح پاسخ در تخمین نسبت NSN متغیرهای پاسخ، از داده های آموزش برای تخمین مدل

جدول ۱. مشاهدات آزمایشی

شماره آزمایش	فاکتورهای کنترلی					متغیرهای پاسخ	
	X ₁	X ₂	X ₃	X ₄	X ₅	Y ₁	Y ₂
۱	-1	-1	-1	-1	-1	۱۴.۳	۴.۰
۲	-1	۱۵.۷	۴.۳
۳	-1	1	1	1	1	۲۳.۲	۵.۶
۴	.	-1	-1	.	.	۱۲.۱	۳.۷
۵	.	.	.	1	1	۸.۷	۴.۹
۶	.	1	1	-1	-1	۶.۵	۶.۱
۷	1	-1	.	-1	1	۸.۹۹	۴.۲
۸	1	.	1	.	-1	۱۱.۸	۴.۳
۹	1	1	-1	1	.	۱۲.۴	۵.۳
۱۰	-1	-1	1	1	.	۱۶.۲	۴.۶
۱۱	-1	.	-1	-1	1	۲۶.۹	۴.۱
۱۲	-1	1	.	.	-1	۱۰.۵	۵.۳
۱۳	.	-1	.	1	-1	۱۶.۹	۳.۹
۱۴	.	.	1	-1	.	۵.۰۶	۴.۷
۱۵	.	1	-1	.	1	۷.۰۸	۵.۴
۱۶	1	-1	1	.	1	۸.۷۶	۵.۲
۱۷	1	.	-1	1	-1	۱۵.۱	۴.۶
۱۸	1	1	.	-1	.	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 ₁	X ₂	X ₃	X ₄	X ₅	Y ₁	Y ₂	Y ₁	Y ₂
۱	-1	-1	-1	-1	-1	-۲۳.۱۱	۱۲۰.۴	۰.۳۷۵۵۱۳	۰.۱۵۶۳۲۲
۲	-1	-۲۳.۹۲	۱۲.۶۷	۰.۳۲۰۱۰۹	۰.۲۰۱۱۴۹
۳	-1	1	1	1	1	-۲۷.۳۱	۱۴.۹۶	۰.۰۸۸۲۳۵	۰.۸۲۷۵۸۶
۴	.	-1	-1	.	.	-۲۱.۶۶	۱۱.۳۶	۰.۴۷۴۶۹۲	.
۵	.	.	.	1	1	-۱۸.۷۹	۱۳.۸۰	۰.۶۷۰۹۹۹	۰.۵۶۰۹۲
۶	.	1	1	-1	-1	-۱۶.۲۶	۱۵.۷۱	۰.۸۴۴۰۴۹	1
۷	1	-1	.	-1	1	-۱۹.۰۸	۱۲.۴۶	۰.۶۵۱۱۶۳	۰.۲۵۲۸۷۴
۸	1	.	1	.	-1	-۲۱.۴۴	۱۲.۶۷	۰.۴۸۹۷۷۴	۰.۲۰۱۱۴۹
۹	1	1	-1	1	.	-۲۱.۸۷	۱۴.۴۹	۰.۴۶۰۳۲۸	۰.۷۱۹۵۴
۱۰	-1	-1	1	1	.	-۲۴.۱۹	۱۳.۲۶	۰.۳۰۱۶۴۲	۰.۴۳۶۷۸۲
۱۱	-1	.	-1	-1	1	-۲۸.۶۰	۱۲.۲۶	.	۰.۲۰۶۸۹۷
۱۲	-1	1	.	.	-1	-۲۰.۴۲	۱۴.۴۹	۰.۵۵۹۵۰۸	۰.۷۱۹۵۴
۱۳	.	-1	.	1	-1	-۲۴.۵۶	۱۱.۸۲	۰.۲۷۶۳۳۴	۰.۱۰۵۷۴۷
۱۴	.	.	1	-1	.	-۱۴.۰۸	۱۳.۴۴	۰.۹۹۳۱۶	۰.۴۷۸۱۶۱
۱۵	.	1	-1	.	1	-۱۷.۰۰	۱۴.۶۵	۰.۷۹۳۴۳۴	۰.۷۵۶۳۲۲
۱۶	1	-1	1	.	1	-۱۸.۸۵	۱۴.۳۲	۰.۶۶۶۸۹۵	۰.۶۸۰۴۶
۱۷	1	.	-1	1	-1	-۲۳.۵۸	۱۳.۲۶	۰.۳۴۳۳۶۵	۰.۴۳۶۷۸۲
۱۸	1	1	.	-1	.	-۱۳.۹۸	۱۵.۲۷	1	۰.۸۹۸۸۵۱

جدول ۳. خصوصیات شبکه های عصبی

شبکه	متغیر پاسخ	تعداد نرون های لایه های پنهان	MSE	
			تست	آموزش
۱	Y ₁	۶,۴	۰.۰۳۴	۱.۴۱×۱۰ ^{-۱۳}
۲	Y ₂	۶,۴	۰.۰۲۷	۵.۶۳×۱۰ ^{-۱۳}

$$\begin{aligned} \text{NSN}_{Y_1} = & 0.5786 - 0.0361x_1 + 0.1488x_2 - 0.0271x_3 + 0.153x_4 + 0.1217x_5 + 0.33x_1x_2 + 0.2787x_1x_3 - 0.2514x_1x_4 \\ & + 0.1826x_1x_5 + 0.0178x_2x_3 + 0.1197x_2x_4 - 0.065x_2x_5 - 0.4553x_3x_4 \\ (\text{x}_1, \text{x}_2, \text{x}_3, \text{x}_4, \text{x}_5) \text{NSN}_{Y_1} = & 0.5505 + 0.1531x_1 + 0.3626x_2 + 0.2666x_3 + 0.0489x_4 + 0.1935x_5 + 0.1323x_1x_2 - 0.1951x_1x_3 \\ & + 0.3183x_1x_4 + 0.2804x_1x_5 + 0.0787x_2x_3 - 0.0676x_2x_4 - 0.0051x_2x_5 + 0.0885x_3x_4 \end{aligned}$$

جدول ۴. مقادیر MSE مدل های رگرسیون

پاسخ	Y_1	Y_2
MSE	۰،۱۸۲۳	۰،۹۸۷۸۶
تست آموزش	7.56×10^{-9}	1.137×10^{-8}

[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*, 2nd 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., Vining, 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

$$(x_1, x_2, x_3, x_4, x_5) = (1, 1, -1, -1, 1)$$

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 مسایلی 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 مسایل 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 قادر پیچیدگی های ریاضی نامطلوب است و بنابراین برای مهندسین 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, J.J., 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: Sensitivity 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] Suppapitnarm, K.A., Seffen, G.T., Parks, P.J., Clarkson, A *Simulated Annealing Algorithm for Multi Objective Optimization*, Engineering Optimization 33, 2009, 59_85.