

مقایسه‌ی بین روش‌های بهینه‌سازی پارامتری و ناپارامتری قبل از ساخت

مصیب رحمانی، محمدرضا محمودی

گروه آمار، دانشگاه علامه طباطبایی

بخش آمار، دانشگاه شیراز

با توجه به نقش کلیدی بهبود مستمر کیفیت و کاهش هزینه در اقتصاد دنیای صنعتی امروز، و احتیاج به رقابت در قیمت و کیفیت، بسیاری از سازمان‌های آگاه از وضعیت رقابت، تمرکز خود را بر بهینه‌سازی طراحی محصولات و یا فرایندها، معطوف نموده‌اند. از جمله مهمترین روش‌های بهینه‌سازی آماری می‌توان به روش‌های بهینه‌سازی پارامتری و روش‌های بهینه‌سازی ناپارامتری اشاره کرد. یکی از جدیدترین و موثرترین روش‌های پارامتری به‌کار رفته در این زمینه، روش رویه پاسخ دوگان (DRS) است که در زمینه‌ی بهینه‌سازی پارامتری سامانه‌ها، در اوایل دهه‌ی ۱۹۹۰ معرفی گردید. از طرفی، به دنبال کاستی‌های این روش در مواجهه با مواردی که نمی‌توان مدل پارامتری را به‌طور دقیق برازش داد، روش‌های بهینه‌سازی ناپارامتری در اواخر دهه‌ی ۱۹۹۰ معرفی شدند که موفقیت خود را در رسیدن به نقاط بهینه‌ی سراسری، به اثبات رساندند. در این پژوهش، کارایی روش ناپارامتری نسبت به روش پارامتری، با یک مطالعه موردی و بر اساس معیار MSD نشان داده شده است.

واژه‌های کلیدی: رویه پاسخ دوگان، بهینه‌سازی پارامتری، بهینه‌سازی ناپارامتری.

۱ مقدمه

هدف اصلی بهینه‌سازی سامانه‌ها، کاهش بهینه‌ی هزینه‌ی کل محصول است که دارای دو مولفه‌ی عمده، یکی هزینه‌های قبل از فروش (هزینه‌ی ساخت) و دیگری هزینه‌های بعد از فروش محصول به مشتری (هزینه‌ی به‌کارگیری) است. در این ارتباط، می‌توان فعالیت‌های تحقق یک محصول را به سه بخش عمده فعالیت‌های قبل از ساخت، فعالیت‌های حین ساخت و فعالیت‌های بعد از ساخت تفکیک نمود. از سه فعالیت مذکور، دو فعالیت اول تاثیر بسیار زیادی در هزینه‌ی کل یک محصول دارند. مراحل روش بهینه‌سازی مربوط به فعالیت‌های قبل از ساخت، باعث بهینه‌شدن هزینه‌های واحد ساخت و به‌کارگیری می‌

شود در حالی که روش های بهینه سازی مربوط به فعالیت های حین ساخت، در مرحله تولید به کار گرفته می شود. در بهینه سازی قبل از ساخت، تلاش بر آن است که با شناسایی علل اغتشاش، کاهش تغییرپذیری در سامانه ها از طریق حذف یا کنترل آن ها صورت پذیرد که این امر مستلزم ایجاد هزینه های گزاف است. همچنین تلاش عمده در بهینه سازی سامانه ها بر آن است که تحت حدود رواداری پهن، یعنی تحت شرایط به کارگیری مواد و قطعات با درجه ی پایین تر، تجهیزات ارزان تر و شرایط محیط به کارگیری با دامنه گسترده تر، از طریق تعیین مقادیر عوامل قابل کنترل نافذی که کمترین اثر را در هزینه ساخت دارند، این کار طوری صورت گیرد که اولاً حساسیت عملکرد نسبت به عوامل اغتشاش کاهش یابد (کاهش پراکندگی) و ثانیاً میانگین مشخصه کیفیت مورد نظر به مقدار آرمانی نزدیکتر شود (کاهش اریبی). این کار می تواند از طریق مینیمم کردن میانگین توان دوم خطا^۱ (MSD) خطا به منظور کاهش همزمان اریبی و پراکندگی انجام گیرد. MSD به صورت زیر تعریف می شود:

$$MSD = E[y(x) - T]^2 = \{E[y(x)] - T\}^2 + Var[y(x)]$$

که در آن T مقدار هدف، x متغیر ورودی و y(x) متغیر پاسخ می باشند. برای بهینه سازی سامانه ها می توان از روش های بهینه سازی پارامتری و ناپارامتری استفاده کرد. در این مقاله، از میان روش های بهینه سازی پارامتری، روش رویه ی پاسخ دوگان و از میان روش های بهینه سازی ناپارامتری، روش رگرسیون خطی موضعی^۲ (LLR) را معرفی کرده و در بخش پایانی این دو روش را به وسیله یک مطالعه ی موردی در فرایند رنگرزی و بر اساس معیار MSD مورد مقایسه قرار می دهیم.

۲ روش رویه پاسخ دوگان

از مهمترین روش های بهینه سازی پارامتری، روش رویه ی پاسخ دوگان است که وینینگ و مهیرز^۳ در سال ۱۹۹۰ این روش را معرفی کردند که در آن میانگین و واریانس جداگانه توسط مدل های رگرسیونی پارامتری مشخص می شوند، در این روش مکان های بهینه ی عوامل کنترل توسط روش های بهینه سازی به دست می آید. پیکل و همکاران^۴ (۲۰۰۶) برای

¹Mean Squared Deviations

²Local Linear Regression

³Vining and Myers

⁴Pickel, et al

برآورد میانگین از مدل زیر استفاده کردند که در این روش برای هر یک از آزمون‌های آزمایش (d) که n_i تکرار وجود دارد، میانگین \bar{y}_i و واریانس s_i^2 نمونه محاسبه می‌شوند:

$$\bar{y}_i = x_i' \beta + g^{1/2}(x_i^*; \gamma) \varepsilon_i \quad (1)$$

که در آن $x_i' = (1, x_{i1}, x_{i2}, \dots, x_{ik})$ بردارهای میانگین مدل رگرسیونی هستند که در حقیقت شامل متغیرهای قابل کنترل می‌باشند و $x_i^* = (1, x_{i1}^*, x_{i2}^*, \dots, x_{il}^*)$ بردارهای واریانس مدل رگرسیونی بوده و شامل متغیرهای اغتشاش هستند و ε_i ها ناهمبسته و دارای واریانس ۱ می‌باشند. در حالتی که متغیرهای اغتشاش قابل کنترل نباشند برای برآورد رویه‌ی واریانس از همان متغیرهای قابل کنترل $x_i' = (1, x_{i1}, x_{i2}, \dots, x_{ik})$ استفاده می‌شود. β و γ پارامترهای بردارهای به ترتیب $1 \times (k+1)$ و $1 \times (l+1)$ میانگین و واریانس مدل رگرسیونی بوده و تابع واریانس مدل رگرسیونی است. با توجه به تغییرات شدید واریانس‌های مدل برای برازش یک رویه، بهتر است که بر روی واریانس‌های نمونه‌ای یک تبدیل مناسب اختیار شود. در سال ۱۹۴۶ بارتلت و کندال^۵ نشان دادند اگر خطاها دارای توزیع نرمال باشند و پاسخ دارای تکرار باشد، می‌توان مدل لگاریتم خطی را برای واریانس به صورت زیر استفاده کرد:

$$\ln(s_i^2) = g^*(x_i^*) = x_i^{*'} \gamma + \eta_i \quad (2)$$

که η_i ها خطاهای تصادفی برای مدل واریانس می‌باشند. پیکل و همکاران برای برآورد پارامترهای این مدل از روش حداقل توان دوم معمولی^۶ (OLS) برای مدل واریانس و از الگوریتم برآورد حداقل توان دوم موزون^۷ (EWLS) برای مدل میانگین استفاده کردند که آخری دارای گام‌های زیر می‌باشد:

گام اول: به روش حداقل توان دوم معمولی در مدل واریانس، پارامترها (ضرایب مدل رگرسیونی) برآورد می‌شود.

$$\hat{\gamma}^{(OLS)} = (x^{*'} x^*)^{-1} x^* y^*$$

که در آن $y_{d \times 1}^*$ بردار تبدیل یافته لگاریتم واریانس مدل است.

⁵Bartlet and Kendal

⁶Ordinary Least Square

⁷Estimated Weighted Least Square

گام دوم: $\hat{\sigma}_i^2$ را به صورت زیر محاسبه نموده و از آن برای محاسبه ی ماتریس \hat{V} استفاده می شود.

$$\hat{\sigma}_i^2 = \exp(x_i^* \hat{\gamma}^{(ols)}) \quad \hat{V} = \text{diag}(\hat{\sigma}_1^2, \hat{\sigma}_2^2, \dots, \hat{\sigma}_d^2)$$

گام سوم: از \hat{V}^{-1} برای برآورد ماتریس میانگین مدل استفاده می شود.

$$\hat{\beta} = (x' \hat{V}^{-1} x)^{-1} x' \hat{V}^{-1} \bar{y} \quad x = (x_1, x_2, \dots, x_d)' \hat{\beta} = (x' \hat{V}^{-1} x)^{-1} x' \hat{V}^{-1} \bar{y}$$

$$x = (x_1, x_2, \dots, x_d)'$$

که در نتیجه مقدار برآورد میانگین و واریانس مدل به صورت زیر به دست می آیند:

$$\begin{aligned} \hat{E}(y_i)^{EWLS} &= x_i' \hat{\beta} \\ \hat{V}(y_i)^{(ols)} &= \exp(x_i^* \hat{\gamma}^{(ols)}) \end{aligned} \quad (3)$$

۱-۲ بهینه سازی توأم رویه های میانگین و واریانس

همانگونه که قبلا ذکر شد هدف اصلی بهینه سازی نزدیک کردن مقدار به دست آمده میانگین به مقدار هدف و کاهش هر چه بیش تر واریانس فرایند است، که با مینیمم کردن MSD به طور هم زمان به آن دست می یابیم. بنابراین، مقدار MSD می تواند به صورت زیر محاسبه می شود:

$$MSD = E[y(x) - T]^2 = \{E[y(x)] - T\}^2 + Var[y(x)]$$

که در آن T مشخص کننده مقدار هدف برای میانگین است. حال با استفاده از الگوریتم های بهینه سازی مانند الگوریتم ژنتیک حالت بهینه سامانه، که کمترین مقدار MSD را دارا می باشد، پیدا می شود.

۳ روش ناپارامتری

در مواقعی که نتوان رابطه ی تابعی مناسبی بین متغیرهای ورودی و پاسخ برقرار کنیم، نتایج به دست آمده از روش پارامتری به شکل جدی اریب است. برای جلوگیری از این مشکل

وینینگ و بوهن^۸ (۱۹۹۸)، برای بهینه‌سازی رویه‌های میانگین و واریانس استفاده از روش ناپارامتری را پیشنهاد دادند. همچنین اندرسون کوک و پرویت^۹ (۲۰۰۵) روش‌های مختلف بهینه‌سازی ناپارامتری را بررسی کردند و از این میان برای به دست آوردن برآورد میانگین و واریانس استفاده از روش رگرسیون چند متغیره موضعی (LLR) را پیشنهاد دادند.

۱-۳ روش رگرسیون چند متغیره موضعی (LLR)

در این روش تابع‌های میانگین و واریانس ناشناخته‌اند، اما تابع‌های هموار آن‌ها مانند تابع‌های تعریف شده در (۱) و (۲) در نظر گرفته می‌شود. برای رگرسیون چندگانه در نقطه $x_0 = (x_{01}, x_{02}, \dots, x_{0k})$ که در آن می‌خواهیم پیش‌بینی انجام دهیم تابع کرنل به صورت زیر تعریف می‌شود:

$$K(x_0, x_i) = \frac{1}{b^k} \prod_{j=1}^k k\left(\frac{x_{0j} - x_{ij}}{b}\right)$$

که در آن $k(z)$ یک تابع کرنل یک متغیره بوده و b پهنای باند یا پارامتر هموارساز است. در این روش می‌توان از تابع کرنل‌های مختلف استفاده کرد که در این مقاله از تابع کرنل گوسی^{۱۰} $K(z) = e^{-z^2}$ استفاده می‌شود. در این ارتباط باید متذکر شد که استفاده از تابع کرنل‌های مختلف تغییرات زیادی در نتیجه‌ی نهایی ایجاد نمی‌کند.

مایز و بیرچ^{۱۱} (۱۹۹۸) روش‌های مختلف انتخاب پهنای باند را بررسی و از آن میان روش $PRESS^{**}$ را پیشنهاد دادند. در این روش b طوری تعیین می‌شود که مقدار $PRESS^{**}$ به صورت زیر تعریف شده است مینیمم گردد.

$$PRESS^{**} = \frac{PRESS}{d - \text{trace}(H^{(LLR)}) + (d - (k + 1)) \frac{SSE_{\max} - SSE_b}{SSE_{\max}}}$$

که در آن SSE_{\max} بزرگترین مجموع توان دوم خطا در سرتاسر پهنای باند، SSE_b مجموع توان دوم خطا برای یک مقدار b خاص و k تعداد متغیرهای رگرسیونی است. همچنین

⁸Vining and Bohn

⁹Anderson-Cook and Prewitt

¹⁰Gaussian

¹¹Mays and Birch

پاسخ وقتی لامین مشاهده را از مدل کنار بگذاریم حاصل می شود. مایز و بیرچ ماتریس هموارسازی $H^{(LLR)}$ به صورت زیر تعریف کردند:

$$H^{(LLR)} = \begin{bmatrix} h_1^{(LLR)} \\ h_2^{(LLR)} \\ \vdots \\ h_d^{(LLR)} \end{bmatrix}$$

$$h_i^{(LLR)'} = x_i'(X'Q_iX)^{-1}X'Q_i\bar{y}$$

که در آن Q_i ها ماتریس های قطری از کرنل ها هستند و به صورت زیر تعریف می شوند:

$$Q_i = \text{diag}(\sqrt{q_{i1}}, \sqrt{q_{i2}}, \dots, \sqrt{q_{id}})$$

$$q_{ij} = \frac{K(x_i, x_j)}{\sum_{j=1}^d K(x_i, x_j)}$$

برای مشاهده های جدید نیز Q_0 به صورت زیر تعریف می شود:

$$Q_0 = \text{diag}(\sqrt{q_{01}}, \sqrt{q_{02}}, \dots, \sqrt{q_{0d}})$$

$$q_{0i} = \frac{K(x_0, x_i)}{\sum_{i=1}^d K(x_0, x_i)}$$

به طور مشابه برای مدل واریانس داریم:

$$Q_0^* = \text{diag}(\sqrt{q_{01}^*}, \sqrt{q_{02}^*}, \dots, \sqrt{q_{0d}^*})$$

$$q_{0i}^* = \frac{K(x_0^*, x_i^*)}{\sum_{i=1}^d K(x_0^*, x_i^*)}$$

بر اساس یافته های لین و کارول^{۱۲} (۲۰۰۰) براورد LLR برای واریانس در نقطه $x = x_0$ به صورت زیر به دست می آید:

$$\hat{Var}(y_0) = \hat{\sigma}_0^2 = \exp[x_0^{*'}(x_0^{*'}Q_0^*x_0^*)^{-1}x_0^{*'}Q_0^*y_0^*] = \exp[h_0^{(LLR)}y_0^*] \quad (4)$$

¹²Lin and Carroll

آن‌ها همچنین برای برآورد میانگین در نقطه $x = x_0$ از الگوریتم موزون رگرسیون خطی موضعی^{۱۳} (EWLLR) استفاده کردند که دارای گام‌های زیر می‌باشد:

گام اول: ابتدا با استفاده از رابطه (۴) $\hat{\sigma}_i^2$ را محاسبه و از آن برای محاسبه‌ی ماتریس \hat{V}^{-1} استفاده می‌گردد:

$$\hat{V}^{-1} = \text{diag}\left(\frac{1}{\hat{\sigma}_1^2}, \frac{1}{\hat{\sigma}_2^2}, \dots, \frac{1}{\hat{\sigma}_d^2}\right)$$

گام دوم: مقدار W_0 به‌عنوان وزن‌های متغیرهای جدید رگرسیونی به‌صورت زیر محاسبه می‌شود:

$$W_0 = Q_0 \hat{V}^{-1} Q_0'$$

گام سوم: از W_0 استفاده کرده و برآورد EWLLR میانگین در نقطه $x = x_0$ به‌صورت زیر به‌دست می‌آید:

$$\hat{E}(y_0)^{(EWLLR)} = x_0' (X_0' W_0 X_0)^{-1} X_0' W_0 y_0 \quad (5)$$

۲-۳ بهینه‌سازی با استفاده از روش ناپارامتری

پس از تعیین مقدار میانگین و واریانس برای نقاط مختلف همانند روش رویه‌ی پاسخ دوگان با استفاده از الگوریتم ژنتیک و براساس معیار MSD حالت بهینه سامانه پیدا می‌شود.

۴ مقایسه‌ی روش‌های بهینه‌سازی رویه‌ی پاسخ دوگان و ناپارامتری در فرایند رنگ‌گری

باکس و دراپر^{۱۴} (۱۹۸۷) در مطالعه‌ی بر روی توانایی دستگاه رنگ‌گری برای رنگ کردن پرچسپ‌ها که شامل متغیرهای سرعت (x_1) ، فشار (x_2) و فاصله (x_3) بود یک طرح عاملی

¹³Estimated Weighted Local Linear Regression

¹⁴Box and draper

۳ تا ۳ تکرار در هر آزمایش را برای بهینه‌سازی سامانه پیشنهاد دادند. مقدار هدف برای این آزمایش ۵۰۰ بوده و جدول داده‌های حاصل در این مطالعه را نشان می‌دهد.

| i | x_{1i} | x_{2i} | x_{3i} | x_{1i} | x_{2i} | x_{3i} | \bar{y}_i | S_i |
|-----|----------|----------|----------|----------|----------|----------|-------------|--------|
| ۱ | -۱ | -۱ | -۱ | ۳۴ | ۱۰ | ۲۸ | ۲۴ | ۱۲.۴۹ |
| ۲ | ۰ | -۱ | -۱ | ۱۱۵ | ۱۱۶ | ۱۳۰ | ۱۲۰.۳۳ | ۸.۳۹ |
| ۳ | ۱ | -۱ | -۱ | ۱۹۲ | ۱۸۶ | ۲۶۳ | ۲۱۳.۶۷ | ۴۲.۸۳ |
| ۴ | -۱ | ۰ | -۱ | ۸۲ | ۸۸ | ۸۸ | ۸۶ | ۳.۴۶ |
| ۵ | ۰ | ۰ | -۱ | ۴۴ | ۱۷۸ | ۱۸۸ | ۱۳۶.۶۷ | ۸۰.۴۱ |
| ۶ | ۱ | ۰ | -۱ | ۳۲۲ | ۳۵۰ | ۳۵۰ | ۳۴۰.۶۷ | ۱۶.۱۷ |
| ۷ | -۱ | ۱ | -۱ | ۱۴۱ | ۱۱۰ | ۸۶ | ۱۱۲.۳۳ | ۲۷۲۵۲ |
| ۸ | ۰ | ۱ | -۱ | ۲۵۹ | ۲۵۱ | ۲۵۹ | ۲۵۶.۳۳ | ۴.۶۲ |
| ۹ | ۱ | ۱ | -۱ | ۲۹۰ | ۲۸۰ | ۸۱۲۴۵ | ۲۷۱.۶۷ | ۲۳.۶۷ |
| ۱۰ | -۱ | -۱ | ۰ | ۸۱ | ۸۱ | ۹۳ | ۸۱ | ۰ |
| ۱۱ | ۰ | -۱ | ۰ | ۹۰ | ۱۲۲ | ۳۷۶ | ۱۰۱.۶۷ | ۱۷.۶۷ |
| ۱۲ | ۱ | -۱ | ۰ | ۳۱۹ | ۳۷۶ | ۱۵۴ | ۳۵۷ | ۳۲.۹۱ |
| ۱۳ | -۱ | ۰ | ۰ | ۱۸۰ | ۱۸۰ | ۳۷۲ | ۱۷۱.۳۳ | ۱۵.۰۱ |
| ۱۴ | ۰ | ۰ | ۰ | ۳۷۲ | ۳۷۲ | ۳۹۶ | ۳۷۲ | ۰ |
| ۱۵ | ۱ | ۰ | ۰ | ۵۴۱ | ۵۶۸ | ۳۱۲ | ۵۰۱.۶۷ | ۳۸.۵ |
| ۱۶ | -۱ | ۱ | ۰ | ۲۸۸ | ۱۹۲ | ۵۱۳ | ۲۶۴ | ۶۳.۵ |
| ۱۷ | ۰ | ۱ | ۰ | ۴۳۲ | ۳۳۶ | ۷۵۴ | ۴۲۷ | ۸۸.۶۱ |
| ۱۸ | ۱ | ۱ | ۰ | ۷۱۳ | ۷۲۵ | ۱۹۹ | ۷۳۰.۶۷ | ۲۱.۰۸ |
| ۱۹ | -۱ | -۱ | ۱ | ۳۶۴ | ۹۹ | ۲۶۶ | ۲۲۰.۶۷ | ۱۳۳.۸۲ |
| ۲۰ | ۰ | -۱ | ۱ | ۲۳۲ | ۲۲۱ | ۴۴۳ | ۲۳۹.۶۷ | ۲۳.۴۶ |
| ۲۱ | ۱ | -۱ | ۱ | ۴۰۸ | ۴۱۵ | ۱۸۲ | ۴۲۲ | ۱۸.۵۲ |
| ۲۲ | -۱ | ۰ | ۱ | ۱۸۲ | ۲۲۳ | ۴۳۴ | ۱۹۹ | ۲۹.۴۴ |
| ۲۳ | ۰ | ۰ | ۱ | ۵۰۷ | ۵۱۵ | ۶۴۰ | ۴۸۵.۳۳ | ۴۴.۶۴ |
| ۲۴ | ۱ | ۰ | ۱ | ۸۴۶ | ۵۳۵ | ۴۶۸ | ۶۷۳.۶۷ | ۱۵۸.۲۱ |
| ۲۵ | -۱ | ۱ | ۱ | ۲۳۶ | ۴۲۶ | ۴۰۳ | ۴۷۶.۶۷ | ۵۵.۵۱ |
| ۲۶ | ۰ | ۱ | ۱ | ۶۶۰ | ۴۴۰ | ۱۱۶۱ | ۵۰۱ | ۴۳۸.۹۴ |
| ۲۷ | ۱ | ۱ | ۱ | ۸۷۸ | ۹۹۱ | | ۱۰۱۰ | ۱۴۲.۴۵ |

جدول ۱. داده‌های دستگاه رنگ‌گری .

در این جدول با توجه به این که در مشاهده دهم و چهارم انحراف معیار نمونه ای صفر است، به جای $\log s_i^2$ از $\log(s_i^2 + 1)$ استفاده کرده و در روش رویه‌ی پاسخ دوگان رویه‌های میانگین و واریانس را تعیین می‌کنیم، همچنین در روش ناپارامتری از رابطه‌ی $PRESS^{**}$

برای پیدا کردن پهنای باند برای دو رویه‌ی میانگین و واریانس استفاده می‌کنیم که برای میانگین مقدار $0/52$ و برای واریانس مقدار $0/63$ به دست می‌آید. حال در هر یک از دو روش با برآورد مقدار واریانس و میانگین برای هر یک از داده‌هایی که توسط الگوریتم ژنتیک تولید می‌شوند مقدار MSD محاسبه و تولید داده‌های جدید به وسیله عملگرهای تلاقی و جهش تا جایی ادامه پیدا می‌کند که سامانه به حالت بهینه همگرا شود. تمامی محاسبات توسط نرم افزار R انجام داده شده و مکان‌های بهینه برای روش‌های پارامتری و ناپارامتری در جدول زیر آورده شده است:

| | x_1 | x_2 | x_3 | $\hat{E}[y_i]$ | $var[y_i]$ | MSD |
|----------------|-------|---------|----------|----------------|------------|------------|
| روش پارامتری | ۱ | $0/358$ | $-0/112$ | $497/619$ | $1722/693$ | $1729/362$ |
| روش ناپارامتری | ۱ | ۱ | $-0/352$ | $496/866$ | $1088/45$ | $1025/15$ |

جدول ۱. مقایسه‌ی روش‌های بهینه‌سازی پارامتری و ناپارامتری در داده‌های ماشین رنگ زنی .

همانگونه که ملاحظه می‌گردد، روش ناپارامتری مقدار MSD کم‌تری نسبت به روش پارامتری به دست می‌دهد، همچنین واریانس در روش ناپارامتری کاهش یافته است که نشان دهنده عملکرد بهتر این روش در مقایسه‌ی با روش پارامتری می‌باشد.

مراجع

- [1] Anderson-Cook, C.M., Prewitt, K., (2006), "Some Guideline for Using Nonparametric Methods for Modeling Data from Response Surface Design", Journal of Modern Applied Statistical Methods, 4, 106-119.
- [2] Bartlett, M.S., Kendall, D.G., (1946), "The statistical analysis of variance heterogeneity and the logarithmic transformation", Journal of the Royal Statistical Society, Series B 8,128-138.
- [3] Box, G., and Draper B. (1987), Empirical Model Building and Response Surface, Wiley, New York.
- [4] Lin, X., Carroll, R.J., (2000), "Nonparametric function estimation for clustered data when the predictor is measured without/with error", Journal of the American Statistical Association, 95, 520-534.

- [5] Mays, J. E. and Birch J. B.,(1998), "Smoothing Considerations in nonparametric and Semi-parametric Regression", Virginia Tech, Department of Statistics, Technical Report, No. 98-2, 24 pages.
- [6] Pickle, S.M., Robinson, T.J., Brich, J.B., and Anderson-cook, C.M. (2005), "Robust Parameter design : A semi-parametric approach," Technical report, No.05-7, Department of Statistics, Virginia Tech, Blacksburg, VA.
- [7] Vinning, G. G. and Myers, R. H. (1990). "Combining Taguchi and Response Surface Philosophies: A Dual Response Approach", Journal of Quality Technology, pp. 38-45.
- [8] Vinning, G.G., and Bohn, L. (1998), "Response Surface for the Mean and the Process Variance Using a Nonparametric Approach", Journal of Quality Technology, 30,282-291.