



ارائه نمودار کنترل مبتنی بر توصیف داده بردار پشتیبان برای پایش پروفایل‌های خطی ساده در فاز ۲

نگین خاکساری^a، مونا ایوبی^b، امیرحسین امیری^c

^a(دانشجوی کارشناسی ارشد، دانشگاه آزاد اسلامی واحد تهران غرب، گروه مهندسی صنایع، تهران)

^b(استادیار، دانشگاه آزاد اسلامی واحد تهران غرب، گروه مهندسی صنایع، تهران)

^c(دانشیار، دانشگاه شاهد گروه مهندسی صنایع، تهران)

نویسنده مسئول: مونا ایوبی، (ayoubi.m@wtiau.ac.ir)

چکیده: در بسیاری از فرآیندها کیفیت محصولات، توسط یک رابطه رگرسیونی میان یک یا چند متغیر پاسخ و یک یا چند متغیر مستقل توصیف می‌شود که به این رابطه پروفایل گفته می‌شود. از طرفی امروزه رایانه‌ها ثبت داده‌ها در کسب‌وکارها را در حجم‌های بالا امکان‌پذیر ساخته‌اند، این موضوع سبب شده تا استخراج دانش مناسب دشوار شود، که شامل بخش‌های کنترل کیفیت نیز می‌شود. یکی از الگوریتم‌های داده‌کاوی، رویکرد طبقه‌بندی یک طبقه‌ای است که هدف مشترکی با نمودارهای کنترل که از مهم‌ترین ابزارهای کنترل کیفیت هستند، دارد. روش ماشین بردار پشتیبان از الگوریتم‌های طبقه‌بندی یک طبقه‌ای است. در این مقاله، یک نمودار کنترل مبتنی بر توصیف داده بردار پشتیبان برای پایش پروفایل‌های خطی ساده در فاز ۲ توسعه داده می‌شود. عملکرد نمودار کنترل پیشنهادی بر اساس معیار میانگین طول دنباله تحت تغییرات مختلف در پارامترهای رابطه پروفایلی و توزیع‌های مختلف عناصر خطا مورد بررسی قرار می‌گیرد. نتایج نشان می‌دهد که نمودار کنترل پیشنهادی از عملکرد مناسبی در کشف تغییرات در پارامترهای پروفایل‌های خطی ساده در فاز ۲ برخوردار است.

کلمات کلیدی: طبقه‌بندی یک طبقه‌ای؛ توصیف داده بردار پشتیبان؛ پروفایل خطی ساده؛ فاز ۲؛ کنترل فرآیند آماری.

۱. مقدمه

یکی از زیر شاخه‌های کنترل کیفیت آماری، کنترل فرآیند آماری است که امروزه در دنیای صنعتی با توجه به تولیدکنندگان انبوه و رقابت بالای موجود در به دست آوردن سهم بازارها، چه بازارهای کوچک و چه جهانی، کاربرد زیادی دارد. ایجاد هر نوع تغییر یا اختلال در فرآیند در کیفیت محصولات تولیدی تأثیرگذار خواهد بود، بنابراین شناسایی انحرافات با دلایل امری مهم در حفظ کیفیت است که توسط کنترل فرآیند آماری انجام می‌شود. نمودارهای کنترل از جمله ابزارهای مهم کنترل فرآیند آماری به شمار می‌آیند. بنابراین این نمودارها ابزار مناسبی برای ایجاد تمایز بین انحرافات با دلایل و انحرافات تصادفی هستند. در بسیاری از موارد در عمل، کیفیت یک محصول یا فرآیند توسط یک رابطه رگرسیونی که یک یا چند متغیر پاسخ (متغیر وابسته) را به یک یا چند متغیر پیشگو (متغیر مستقل) مرتبط می‌کند، تعریف می‌شود. این رابطه رگرسیونی اصطلاحاً پروفایل نامیده می‌شود. پروفایل، رگرسیون تکرار شونده است، یعنی به رابطه رگرسیونی اطلاق می‌شود که در هر نمونه (زیرگروه) از فرآیند یا محصول تکرار شود. پایش پروفایل‌ها یکی از حوزه‌های موجود در علم کنترل فرآیند آماری است که به دلیل وجود واحدهای صنعتی و خدماتی با مشخصه‌های کیفی به صورت پروفایل، دارای کاربردهای بسیاری است و تحقیق در این حوزه به شدت مورد نیاز است. از طرفی با ظهور رایانه در چند دهه اخیر، ثبت داده‌ها در کسب‌وکارها رونق پیدا کرده و امروزه پایگاه‌های داده بزرگی به وجود آمده است. این موضوع سبب شده است که استخراج داده‌های مناسب و تصفیه کردن آنها، به منظور بدست آوردن پارامترهای مورد نیاز در نمودارهای کنترل دشوار شود. با تخصصی شدن علوم و پیچیده شدن فرآیندهای کسب و کار استفاده مناسب از اطلاعات و داده‌ها بسیار حائز اهمیت قرار گرفته است و این امر توسط علم داده‌کاوی گسترش یافته است. وظیفه داده‌کاوی، کاویدن و استخراج از منابع عظیم داده است تا اطلاعات گرانبهایی که در حجم انبوهی از اطلاعات سطحی پنهان شده است را استخراج کند. ادغام علوم مختلف موجب توسعه یافتن و گسترش علوم می‌شود. با توجه به اهمیت علم کنترل فرآیند آماری در صنایع، تعداد زیاد مشخصه‌های کیفی به صورت پروفایل در کسب و کارها و وجود پایگاه‌های داده‌ای عظیم، امر بررسی و استخراج داده‌های مناسب و پالایش شده برای بدست آوردن پارامترها و آماره‌های مورد نیاز در نمودارهای کنترل کیفیت و بررسی تحت کنترل و یا خارج از کنترل بودن داده‌های فرآیند از اهمیت به سزایی برخوردار است. از طرف دیگر، با توجه به پیش فرض‌های موجود در نمودارهای کنترل سنتی و این حقیقت که در دنیای واقعی این پیش فرض‌ها اکثراً صادق نیستند، نیاز به توسعه نمودارها برای پایش انواع مختلف داده‌ها احساس می‌شود. در اکثر تحقیقات انجام شده نمودارهای کنترل از نظر آماره مورد نظر (تحت کنترل بودن و یا خارج از کنترل بودن آماره) بررسی شده‌اند، اما این امر که خود داده‌های مورد بررسی (عامل مورد بررسی) می‌توانند تحت تأثیر چند عامل دیگر باشد مورد توجه قرار نگرفته است. لذا ایجاد یک مدل جدید برای بدست آوردن نمودارهای کنترل پیشرفته‌ای که با استفاده از علم داده‌کاوی بتوانند نمودارهایی قوی ایجاد و متغیرهای مورد بررسی را با خطای ناچیزی پایش کنند، علاوه بر گسترش علم کنترل کیفیت آماری می‌تواند پژوهشی بسیار کارآمد در دنیای صنعتی به شمار آید و فاصله علوم نظری را با فرآیندهای واقعی کمتر کند و در اکثر کسب و کارهای پیچیده امروزی مورد استفاده قرار گیرد.

طبقه‌بندی یک طبقه‌ای از رویکردهای موجود برای انجام داده‌کاوی است. از جمله رویکردهای طبقه‌بندی یک طبقه‌ای می‌توان به روش ماشین بردار پشتیبان اشاره کرد که متناسب با نیاز موجود در کنترل فرآیند آماری، داده‌ها را به دو قسمت تقسیم می‌کند. این روش توسط سوکچترات و همکاران [۱] مورد بررسی قرار گرفت.



که از اولین تلاش‌ها برای همگام‌سازی داده‌کاوی و کنترل کیفیت آماری است. در ابتدا از روش‌های طبقه‌بندی یک طبقه‌ای برای گسترش نمودارهای کنترلی که دارای چند متغیر به صورت مستقل هستند، استفاده شده و نتیجه این پژوهش‌ها نشان داد که نمودارهای کنترل یک طبقه‌ای محور دارای قابلیت بیشتری نسبت به نمودارهای T^2 در فرآیند نرمال، هستند. با مشاهده موفقیت‌آمیز بودن این پژوهش، دامنه تحقیقات به نمودارهای چندمتغیره و وابسته گسترش یافت که جیتپیتاکرت [۲] حیطه نمودارهای کنترل و الگوریتم طبقه‌بندی یک طبقه‌ای را گسترش داد و نشان داد که نمودارهای کنترل طبقه‌بندی یک طبقه‌ای نسبت به نمودارهای کنترل چندمتغیره قدیمی در همه سناریوها ارجحیت دارند. یک روش دیگر موجود از بین طبقه‌بندی کننده‌ها که در نمودارهای کنترل قابل استفاده است، رگرسیون بردار پشتیبان نام دارد که می‌توان از آن برای پیش‌بینی مقدار متغیر در سری‌های زمانی استفاده کرد. دو و لو [۳] به بررسی فرآیند چندمتغیره همبسته با استفاده از نمودار حداقل فاصله اقلیدسی و روش رگرسیون بردار پشتیبان در فاز یک پرداختند. آنها یک حداقل فاصله اقلیدسی جدید برای افزایش نظارت بر تغییرات میانگین فرآیندهای خودهمبسته ارائه کردند. نتایج تجزیه و تحلیل آنها نشان داد که نمودار کنترل حداقل فاصله اقلیدسی توسعه یافته از دیگر نمودارهای کنترل برای شناسایی تغییرات کوچک در میانگین فرآیندهای خودهمبسته مؤثرتر است. در ادامه توجه پژوهشگران بیشتری به این حوزه جلب شد، به‌طوری‌که دو پژوهش تکمیلی در ادامه مسیر پژوهش‌های انجام شده توسط گانی و لیمام [۴] انجام گرفت. ابتدا تحقیقات آنها نشان داد که نمودار K بر اساس توصیف داده بردار پشتیبان، نسبت به تغییرات کوچک در بردار میانگین حساس است، درحالی که نمودار KNN بر اساس نزدیک‌ترین داده همسایه، نسبت به تغییرات متوسط در بردار میانگین حساس می‌باشد. همچنین، گانی و لیمام [۵] یک نمودار یک طبقه‌ای محور جدید که از الگوریتم شرح میانگین k داده استفاده می‌کند و آن را نمودار KM نامیدند را طراحی کردند. آنها نشان دادند که از نظر میانگین طول دنباله، نمودار KM عملکرد بهتری نسبت به نمودار KNN در شناسایی تغییرات کوچک در بردار میانگین را دارد. با توجه به نمودارهای مورد بررسی در تحقیقات موجود، استفاده از نمودارهای یک طبقه‌ای محور در فرآیندهای چندمتغیره در شرایط مستقل و سپس در شرایط همبسته مورد توجه قرار گرفته بودند. در ادامه این نمودارهای تک‌متغیره بودند که هنوز به آنها توجهی نشده بود که مارتینز رگو و همکاران [۶] نمودارهای تک‌متغیره همبسته را مد نظر قرار دادند و نمودارهای جمع تجمعی (CUSUM) برنولی را در فاز یک با استفاده از روش‌های ماشین بردار پشتیبان و ماشین بردار پشتیبان وزن‌دهی شده توسعه دادند. در این کار، اصلاح الگوریتم طبقه‌بندی یک طبقه‌ای کرنل منفعل-تهداجمی پیشنهاد شده است و با یک نمودار CUSUM برنولی ادغام شده است. طبقه‌بندی یک طبقه‌ای، توصیف داده‌ها را فراتر از فضای اقلیدسی ممکن می‌سازد و نمودار CUSUM به طور رسمی نقاط تغییر را شناسایی می‌کند. یاکوپولوس و همکاران [۷] پایش فرآیندهای تک‌متغیره خود همبسته را با نمودارهای \bar{x} و میانگین متحرک موزون نمایی (EWMA) در فاز یک با استفاده از ماشین بردار پشتیبان مورد توجه قرار دادند. بعد از بررسی فرآیند تک‌متغیره خود همبسته نویل و همکاران [۸] نمودار تک‌متغیره مستقل P را با روش شبکه عصبی و KDD ادغام کردند. کانگ و همکاران [۹] از شبکه عصبی در فرآیندهای مستقل چندگانه برای پیدا کردن عیوب از دو منبع واحد روابط با مشتریان و واحد تولید استفاده کردند. روش‌های بسیاری برای استفاده از طبقه‌بندی کننده‌های یک طبقه‌ای برای ادغام با نمودارهای کنترل وجود دارد. ژاو و همکاران [۱۰] با استفاده از توصیف نزدیک‌ترین داده همسایه و شبکه عصبی، فرآیندهای تک‌متغیره را پایش کردند. آنها همچنین از الگوریتم ژنتیک برای جستجوی بهترین مقادیر پارامترهای ماشین بردار پشتیبان استفاده کردند و نشان دادند که روش ارائه شده می‌تواند الگوهای غیرتصادفی نمودارهای کنترل را به طور مؤثر تشخیص دهد. با وجود گستردگی حوزه‌های صنعتی که از نمودارهای کنترل استفاده می‌کنند، مشخصه‌های کیفی با واریانس بالا نیز در بین آنها به چشم می‌خورد. لو و همکارانش [۱۱] با انجام پژوهش خود این موضوع که دو روش ماشین بردار پشتیبان و تحلیل مولفه‌های اصلی (PCA) در شناسایی داده‌هایی که خیلی دور از مرکز افتاده‌اند و همچنین در همپوشانی داده‌های نرمال و خطاها، موفق نبوده است را نشان دادند و بیان کردند که این محدودیت‌ها را می‌توان با استفاده از روش‌های LFDA یا شبکه عصبی مصنوعی برطرف کرد. ژیاو و همکاران [۱۲] به منظور حل مشکل ضعف عملکرد نمودارهای یک طبقه‌ای محور ماشین بردار پشتیبان زمانی که نقاط دور افتاده در نمونه‌ها وجود دارد، یک روش جدید که ابتدا بعضی از "نقاط دور افتاده مشکوک" را شناسایی می‌کند و آنها را حذف می‌کند و در نتیجه مرز تصمیمی بدست می‌آید که "هسته گروه" را دربرمی‌گیرد، ارائه کردند. به غیر از قرار گرفتن آماره‌های کنترل خارج از حدود کنترل که موجب خارج از کنترل شدن فرآیند می‌شود، الگوهای نمودارهای کنترل هستند که می‌توانند فرآیند را از حالت طبیعی خارج کنند. گاوری و چاکرابورتی [۱۳] از طبقه‌بندی کننده‌ها در نمودارهای کنترل برای شناخت الگوهای غیر تصادفی استفاده کردند. لو و همکارانش [۱۴] این موضوع که داده‌های مشاهده شده از فرآیند می‌توانند ترکیبی از الگوها باشند را مد نظر قرار دادند. آنها فرآیندهای چندمتغیره و مستقل را بررسی کردند و نتیجه حاصل نشان داد که طرح پیشنهاد شده به صورت مؤثری قابلیت تشخیص الگوهای ترکیبی نمودار کنترل و مدل‌های ماشین بردار پشتیبان را دارا است. نتایج نشان می‌دهد که این روش ترکیبی می‌تواند بهترین نرخ طبقه‌بندی را ایجاد کند. همچنین لین و همکاران [۱۵] تاثیرات الگوهای نمودار کنترل در داده‌های خودهمبسته با استفاده از روش ماشین بردار پشتیبان را بررسی کردند. آنها نمودارهای کنترل تک‌متغیره و خود همبسته را مد نظر قرار دادند و با استفاده از روش‌های شبکه عصبی و توصیف داده بردار پشتیبان نمودارهای \bar{x} را توسعه دادند. نتایج مقایسات آنها عملکرد بهتر در دقت و سرعت تشخیص را نشان داد. این نتایج نشان می‌دهد که روش‌های ماشین بردار پشتیبان دارای پتانسیل بزرگی برای شناسایی الگوهای نمودار کنترل به صورت آنلاین هستند. از دیگر پژوهش‌های انجام شده در زمینه شناخت الگوها، پژوهشی است که توسط ژو و همکاران [۱۶] انجام شده است. آنها از روش‌های مبتنی بر ماشین بردار پشتیبان برای پایش فرآیندهای تک‌متغیره و مستقل در نمودار \bar{x} استفاده کردند. زانتوپولوس و رزاقی [۱۷] از دیگر افرادی بودند که بر روی تشخیص الگوهای نمودار کنترل چندمتغیره

تحقیق کرده‌اند. آنها از ماشین بردار پشتیبان وزن‌دهی شده برای کنترل فرآیندهای اتوماتیک و تشخیص عیب در اوایل وقوع آن استفاده کردند و نشان دادند که مزایای ماشین بردار پشتیبان وزن‌دهی شده بیشتر از ماشین بردار پشتیبان سنتی است.

با توجه به این که نتایج حاصل از استفاده روش طبقه‌بندی یک طبقه‌ای در نمودارهای کنترل موفقیت‌آمیز بوده، گسترش این روش‌ها برای انواع مختلف نمودارهای کنترل مفید خواهد بود. گستره وسیع فرآیندهای موجود نیاز به نمودارهای قدرتمند برای پایش هر فرآیند به صورت تخصصی را ایجاد کرده است. بنابراین در این مقاله، با توسعه رویکرد طبقه‌بندی کننده یک طبقه‌ای بر اساس بردار داده پشتیبان برای پایش مشخصه کیفی به صورت پروفایل خطی ساده در فاز ۲، یک شکاف تحقیقاتی مهم پوشش داده می‌شود. ساختار مقاله بدین صورت است که در بخش ۲، مدل پروفایل خطی ساده و مفروضات آن معرفی می‌شوند. در بخش ۳، رویکرد نمودار کنترل پیشنهادی تشریح خواهد شد. در بخش ۴ نیز نتایج ارزیابی عملکرد روش پیشنهادی گزارش می‌شود. در بخش ۵ نیز به نتیجه‌گیری و پیشنهادات برای مطالعات آتی پرداخته می‌شود.

۲. مدل پروفایل خطی ساده در فاز ۲ و مفروضات آن

موارد بسیاری وجود دارند که در آنها کیفیت یک محصول یا فرآیند توسط یک رابطه رگرسیونی میان یک یا چند متغیر پاسخ و یک یا چند متغیر مستقل توصیف می‌شود که اصطلاحاً پروفایل نامیده می‌شود. یکی از انواع پروفایل‌ها، پروفایل خطی ساده است که در آن یک متغیر پاسخ فقط با یک متغیر مستقل در ارتباط است. مدل تحت کنترل پروفایل خطی ساده در نمونه Z ام از فرآیند با مفروض بودن مقادیر ثابت برای متغیرهای مستقل X_i و فرض داشتن n مشاهده به صورت (۱) با معادله زیر نشان داده می‌شود:

$$Y_{ij} = \beta_0 + \beta_1 X_i + \varepsilon_{ij} \quad i = 1, 2, \dots, n \quad (1)$$

رابطه فوق را می‌توان به شکل ماتریسی به صورت زیر نشان داد:

$$y = X\beta + \varepsilon \quad (2)$$

$$\begin{bmatrix} Y_{1j} \\ \vdots \\ Y_{nj} \end{bmatrix} = \begin{bmatrix} 1 & X_1 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} \varepsilon_{1j} \\ \vdots \\ \varepsilon_{nj} \end{bmatrix}$$

یا

به طوری که Y_{ij} متغیر پاسخ برای مشاهده i ام، (برای $i = 1, \dots, n$) از نمونه Z ام (برای $j = 1, 2, \dots, n$) است و X_i متغیر مستقل i ام خواهد بود که در تمام نمونه‌ها ثابت است. $\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$ بردار ضرایب پروفایل نام دارند. عناصر خطای ε_{ij} مستقل و هم توزیع هستند و دارای واریانس ثابت σ^2 هستند. (از آنجایی که رویکرد پیشنهادی مبتنی بر روش توصیف داده بردار پشتیبان، نیازی به پیش فرض نرمال بودن داده‌ها ندارد، در این مقاله فرض می‌شود که عناصر خطا و در نتیجه مشاهدات، از دو توزیع نرمال و غیر نرمال (گاما) تبعیت می‌کنند.

در پایش فرآیندهای پروفایلی نیاز به محاسبه مقادیر ضرایب پروفایل وجود دارد که در هر نمونه با استفاده از مقادیر X_i و Y_{ij} این ضرایب با معادلات زیر تخمین زده می‌شوند:

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_{ij} - \bar{x}_j) y_{ij}}{\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2} \quad (3)$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad (4)$$

۳. نمودار کنترل پیشنهادی برای پایش پروفایل خطی ساده در فاز ۲ مبتنی بر توصیف داده بردار پشتیبان

در طبقه‌بندی کننده‌های یک طبقه‌ای، فقط دو طبقه که نیاز به جداسازی آنها وجود دارد، تعریف می‌شود. این امر باعث شده که منطق این روش‌ها با نمودارهای کنترل که فرض می‌کنند فقط دو حالت تحت کنترل و خارج از کنترل برای مشخصه‌های کیفی مورد نظر برای پایش وجود دارد، یکسان باشد. بنابراین می‌توان از طبقه‌بندی کننده‌های یک طبقه‌ای در نمودارهای کنترل استفاده کرد. در رویکردهای طبقه‌بندی یک طبقه‌ای با استفاده از یک صفحه جدا کننده که ابرصفحه دایره‌ای نامیده می‌شود، دو طبقه به وجود می‌آید که در اینجا این دو طبقه بین داده‌های تحت کنترل و خارج از کنترل تمایز ایجاد می‌کند، یعنی داده‌های تحت کنترل را در یک طبقه و داده‌های خارج از کنترل را در طبقه‌ای دیگر قرار می‌دهد. با ایجاد تغییر در پارامترهای مدل طبقه‌بندی کننده، می‌توان در ابرصفحه دایره‌ای (صفحه جداکننده) انعطاف بیشتری ایجاد کرد و میزان داده‌هایی که درون طبقه اصلی (در اینجا داده‌های تحت کنترل فرض می‌شود) قرار می‌گیرد را افزایش و یا کاهش داد. لازم به ذکر است که این موضوع رابطه مستقیم با نرخ طبقه‌بندی اشتباه دارد، به عبارت دیگر هرچه ابرصفحه دایره‌ای، داده‌های بیشتری را دربرگیرد،

میزان داده‌های اشتباه (داده‌هایی که متعلق به آن طبقه نیستند) در طبقه بیشتر می‌شود. در این مقاله رویکرد طبقه‌بندی کننده یک طبقه‌ای مورد نظر، روش توصیف داده بردار پشتیبان است که برای پایش پروفایل خطی ساده در فاز ۲ گسترش داده می‌شود.

ماشین بردار پشتیبان یکی از الگوریتم‌های یادگیرنده با نظارت است که به صورت متداول برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. ماشین‌های بردار پشتیبان با استفاده از خواص هندسی و پیدا کردن یک ابرصفحه جدا کننده، یک مسئله بهینه‌سازی محدب را که به طور هم‌زمان خطای توزیع را حداقل و حاشیه هندسی بین طبقات را حداکثر می‌سازد، حل می‌کنند [۱۸]. مدل‌های غیرخطی ماشین بردار پشتیبان را از توابع کرنل خطی، چندجمله‌ای، توابع پایه‌ای شعاعی و غیره می‌توان ساخت. توصیف داده بردار پشتیبان تلفیقی از ماشین بردار پشتیبان و روش توصیف شده برای حل کردن مسائل طبقه‌بندی یک طبقه‌ای است [۱۹]. توصیف داده بردار پشتیبان مرز ابرصفحه دایره‌ای شکل (مجموعه‌ای از نقاط در یک فاصله ثابت از یک نقطه داده شده به نام مرکز) اطراف داده‌ها ایجاد می‌کند. یک خلاصه مختصر از الگوریتم توصیف داده بردار پشتیبان که بر اساس نمودارهای ارائه شده در [۲۰] است، به شرح زیر است:

یک مرکز از ابرصفحه دایره‌ای ایجاد کنید. R^2 را شعاع ابرصفحه دایره‌ای قرار دهید (به عنوان مثال، فاصله از مرز). $x_i = [x_{i1}, x_{i2}, \dots, x_{ip}]^T$ برای $i=1, 2, \dots, N$ یک دنباله از مشاهدات با p متغیر مستقل است. مرزهای توصیف داده بردار پشتیبان برای حداقل کردن اندازه ابرصفحه دایره‌ای در حالی که مشاهداتی که در ابرصفحه دایره‌ای هستند را حداکثر می‌کند، ایجاد می‌شود. مسئله این است که (تابع هدف):

$$\text{Minimize } R^2 + c \sum_{i=1}^N \xi_i \quad (5)$$

با محدودیت:

$$\|x_i - a\|^2 \leq R^2 + \xi_i \quad (6)$$

$\xi_i > 0$ متغیره اسلک است که اجازه می‌دهد x خارج از ابرصفحه دایره‌ای باشد. R^2 فاصله از مرز ابرصفحه دایره‌ای می‌باشد. C رابطه بین اندازه ابرصفحه دایره‌ای و خطای طبقه‌بندی اشتباه را کنترل می‌کند. پارامتر f که توسط کاربر تعیین می‌شود و نشان‌دهنده بخشی از داده‌هایی است که خارج از مرز قرار می‌گیرند، این گونه تعریف می‌شود:

$$f = \frac{1}{NC} \quad (7)$$

که N تعداد مشاهدات هدف است. برای مثال، وقتی که ۸۰٪ از نقاط داده‌ها، باید داخل مرز توصیف داده بردار پشتیبان باشد، با $f=0.2$ ساخته می‌شود. وقتی که f از ۰.۲ به ۰.۳ افزایش یابد، اندازه ابرصفحه دایره‌ای کوچک‌تر می‌شود اما خطای طبقه‌بندی اشتباه در طبقه هدف بزرگتر می‌شود. تابع هدف و محدودیت ارائه شده می‌تواند به وسیله رابطه لاگرانژ حل شود:

$$L(R, a, \alpha_i, \gamma_i, \xi_i) = R^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i \{R^2 + \xi_i - (\|x_i - a\|^2)\} - \sum_{i=1}^N \gamma_i \xi_i \quad (8)$$

که $\alpha_i \geq 0$ و $\gamma_i \geq 0$ ضرایب لاگرانژ هستند.

مشقات جزئی L با توجه به R, a و ξ_i و برابر صفر قرار دادن آنها، محدودیت‌های زیر را ایجاد می‌کند:

$$\sum_{i=1}^N \alpha_i = 1 \quad (9)$$

$$a = \sum_{i=1}^N \alpha_i x_i \quad (10)$$

$$\alpha_i = C - \gamma_i \quad (11)$$

هنگامی که این محدودیت‌ها در رابطه (۸) جایگزین شوند، مسئله بهینه‌سازی تبدیل می‌شود به:

$$L = \sum_i \alpha_i (x_i \cdot x_j) - \sum_{ij} \alpha_i \alpha_j (x_i x_j) \quad (12)$$

برای محاسبه مقادیر α_i ($i=1, 2, \dots, N$) می‌توان با به حداکثر رساندن رابطه (۱۲)، مقادیر α_i را با دو محدودیت $0 \leq \alpha_i \leq C$ و $\sum_{i=1}^N \alpha_i = 1$ بدست آورد. مانند ماشین بردار پشتیبان متداول، الگوریتم توصیف داده بردار پشتیبان می‌تواند مرزهای تصمیم منعطف‌تری را به وسیله جایگزین کردن ضرب داخلی با توابع کرنل، ایجاد کند. به عنوان مثال، تابع کرنل گوسی زیر را می‌توان با ضرب داخلی در رابطه (۱۲) جایگزین کرد:

$$K(x_i \cdot x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{s^2}\right) \quad (13)$$

که $s > 0$ عرض کرنل گوسی است که پیچیدگی مرز توصیف داده بردار پشتیبان را کنترل می‌کند. با توجه به نقطه z ، آماره D^2 که فاصله بین نقطه z و مرکز a را اندازه می‌گیرد، می‌تواند به وسیله رابطه زیر محاسبه شود:

$$D^2 = k(z \cdot z) - 2 \sum_i \alpha_i K(z \cdot x_i) + \sum_{ij} \alpha_i \alpha_j k(x_i \cdot x_j) \quad (14)$$

¹ hypersphere

در این مقاله، با توجه با اینکه در فاز ۲ مقادیر پارامترهای مدل پروفایل معلوم هستند، نقطه z برابر با مقادیر تحت کنترل بردار ضرایب پروفایل خطی ساده فرض می‌شود ($z = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$). همچنین برخلاف اکثر تحقیقات انجام شده در حوزه پروفایل‌ها که در هر نمونه تنها یک رابطه پروفایلی موجود است، در این مقاله فرض می‌شود در هر نمونه ۴ رابطه پروفایلی با استفاده از ۴ سری مقادیر متغیرهای پاسخ و مستقل وجود دارد. بنابراین، در هر نمونه جدید در فاز ۲، می‌توان ۴ بردار ضرایب پروفایلی ($\begin{bmatrix} \hat{\beta}_{01} \\ \hat{\beta}_{11} \end{bmatrix}, \begin{bmatrix} \hat{\beta}_{02} \\ \hat{\beta}_{12} \end{bmatrix}, \begin{bmatrix} \hat{\beta}_{03} \\ \hat{\beta}_{13} \end{bmatrix}, \begin{bmatrix} \hat{\beta}_{04} \\ \hat{\beta}_{14} \end{bmatrix}$) برآورد کرد. سپس با استفاده از روش بوت استرپ که نوعی نمونه‌گیری با جایگذاری از داده‌های موجود

است، می‌توان از ۴ بردار ضرایب برآوردشده، ۱۶ بردار ضرایب متفاوت ایجاد کرد. به عنوان مثال یکی از بردارهای بوت استرپی ایجاد شده $\beta_i = \begin{bmatrix} \hat{\beta}_{02} \\ \hat{\beta}_{14} \end{bmatrix}$ (برای

$i = 1, 2, \dots, 16$) است. ضرایب i و j ($i = 1, 2, \dots, 16$ و $j = 1, 2, \dots, 16$) موجود در رابطه (۱۴) شماره بردار بوت استرپ بدست آمده از نمونه فاز دو است. سپس با انتخاب تمام حالات از بین داده‌های بوت استرپی، فاصله کرنل برای رابطه فوق محاسبه می‌شود. ضرایب لاگرانژ α_i و α_j می‌تواند بوسیله به حداکثر رساندن رابطه (۱۲)، با استفاده از دو محدودیت $0 \leq \alpha_i \leq C$ و $\sum_{i=1}^N \alpha_i = 1$ بدست آید. K نیز نشان‌دهنده فاصله کرنل است.

با توجه به فرمول آماره D^2 مشخص است که فقط اعداد مثبت را شامل می‌شود، یعنی این آماره نمی‌تواند عددی کوچکتر از صفر باشد. بنابراین برای محاسبه حدود کنترل فقط نیاز به حد کنترل بالا وجود دارد. برای بدست آوردن حد کنترل بالا در این روش از رویکرد شبیه‌سازی به منظور دستیابی به میانگین طول دنباله (ARL) تحت کنترل مطلوب استفاده شده است. بعد از مشخص کردن میزان احتمال خطای نوع ۱ مطلوب و در نتیجه محاسبه میانگین طول دنباله در شرایط تحت کنترل، با استفاده از نتایج حاصل از ۵۰۰۰ بار شبیه‌سازی، حد کنترل بالا حاصل می‌شود. در ادامه با نمونه‌گیری در فاز ۲ برای هر نمونه آماره کنترل ساخته شده و سپس با حد کنترل مقایسه می‌شود. در صورتی که مقدار آن بزرگتر و یا برابر با حد کنترل بالا باشد، فرض می‌شود که فرآیند خارج از کنترل است. حال باید فرآیند متوقف شود و اقدامات اصلاحی لازم صورت پذیرد و سپس فرآیند می‌تواند دوباره به کار خود ادامه دهد.

مراحل پیشنهادی طراحی نمودار کنترل مورد نظر در فاز ۲ را به صورت خلاصه و گام‌به‌گام می‌توان این‌گونه بیان کرد:

گام اول: تولید ۴ پروفایل خطی ساده در هر نمونه برای پایش در فاز ۲ که شامل مقادیر متغیر پاسخ و مستقل است.

گام دوم: بدست آوردن مقادیر بردار ضرایب پروفایلی، با استفاده از ۴ نمونه مورد نظر که در گام قبل تولید شده است (با توجه به گام اول و موجود بودن ۴ پروفایل در هر نمونه می‌توان ۴ بردار β برآورد کرد).

گام سوم: ساخت نمونه‌های بوت استرپ با استفاده از نمونه بدست آمده در مرحله قبل. (بوت استرپ نوعی روش نمونه‌گیری با جایگذاری از میان داده‌های موجود است و با توجه به اینکه در گام دوم ۴ بردار دومتغیره از برآورد ضرایب پروفایل حاصل شده است، برای عرض از مبدا ۴ حالت انتخاب متفاوت و برای شیب نیز ۴ حالت انتخاب متفاوت وجود دارد که در مجموع ۱۶ نمونه بوت استرپی متفاوت می‌توان ایجاد کرد. (جهت حصول اطمینان از اینکه همه ۱۶ نمونه متفاوت در نمونه‌گیری‌های بوت استرپی موجود باشد، تعداد تکرارهای بوت استرپ ۵۰۰ در نظر گرفته شده است که ۱۶ نمونه متفاوت در این ۵۰۰ نمونه تکرار می‌شوند و سپس نمونه‌های تکراری حذف می‌شوند.)

گام چهارم: بهینه‌سازی مقادیر ضرایب لاگرانژ α_i و α_j در رابطه (۱۴) که با استفاده از برنامه‌ریزی کوادراتیک با هدف ماکزیمم کردن تابع

$$\sum_{i=1}^{16} \alpha_i (\beta'_i \beta_i) - \sum_{i=1, j=1}^{16} \alpha_i \alpha_j (\beta_i \beta_j)$$

با در نظر گرفتن محدودیت‌های مورد نظر $0 < \alpha_i < 1$ و $\sum_{i=1}^N \alpha_i = 1$ انجام می‌شود. (لازم به ذکر است که $(\beta_i \beta_j)$ ضرب داخلی دو بردار را نشان می‌دهد.)

گام پنجم: به منظور محاسبه آماره کنترل چهار مرحله زیر انجام می‌شود:

• محاسبه کردن فاصله کرنل بین تمام ترکیب‌های متفاوت موجود دوتایی (۱۶ ترکیب) از مجموعه داده‌های بدست آمده بوت استرپ در فاز ۲ (یعنی

$$\text{محاسبه‌ی } \left(\sum_{i=1, j=1}^{16} \alpha_i \alpha_j K(\beta_i \beta_j) \right)$$

• محاسبه فاصله کرنل بین داده‌های بدست آمده بوت استرپ در فاز ۲ و مقادیر ضرایب تحت کنترل پروفایل مورد نظر یعنی محاسبه $\sum_{i=1}^{16} \alpha_i K(z, \beta_i)$

• محاسبه فاصله کرنل بین نمونه مورد نظر برای پایش با خودش (که این مقدار با توجه به تابع کرنل برابر با ۱ خواهد شد.)

• جمع سه مقدار بدست آمده از مراحل قبلی با ضرایب تعریف شده برای هر کدام با توجه به رابطه (۱۴)

گام ششم: بدست آوردن مقدار حد کنترل بالا با استفاده از شبیه‌سازی تا دستیابی به ARL تحت کنترل مطلوب

گام هفتم: مقایسه مقدار آماره بدست آمده در گام پنجم با حد کنترل گام ششم
گام هشتم: در صورت تحت کنترل بودن آماره، به گام اول باز گذشته و نمونه بعدی پایش می‌شود و در صورت خارج از کنترل بودن آماره، مقدار طول دنباله محاسبه می‌شود.

گام نهم: تکرار گامهای ۱ تا ۹ به تعداد ۵۰۰۰ بار
گام دهم: بدست آوردن مقدار میانگین طول دنباله (ARL) به عنوان معیار سنجش عملکرد نمودار کنترل پیشنهادی

در ادامه و در بخش ۴، عملکرد روش پیشنهادی با استفاده از شبیه‌سازی و معیار میانگین طول دنباله ارزیابی و تحلیل می‌شود.

۴. ارزیابی عملکرد نمودار کنترل پیشنهادی با مشخصه‌های پروفایلی در فاز ۲ با استفاده از آماره‌های D^2 و تعیین حدود کنترل از طریق شبیه‌سازی
در این مقاله، به منظور ارزیابی عملکرد نمودار کنترل D^2 ، که نمودار یک‌طبقه‌ای محور بدست آمده از توصیف داده بردار پشتیبان است، از ۵۰۰۰ تکرار شبیه‌سازی مونت‌کارلو برای ارزیابی عملکرد نمودار کنترل D^2 استفاده می‌شود. مقدار میانگین طول دنباله در شرایط تحت کنترل ۲۰۰ فرض می‌شود و بر این اساس حد کنترل بالای نمودار کنترل D^2 در شرایط تحت کنترل با استفاده از شبیه‌سازی محاسبه می‌شود. مدل تحت کنترل پروفایل خطی ساده مورد نظر به صورت $y_{ij} = 3 + 2x_i + \varepsilon_{ij}$ است. ε_{ij} ها عناصر خطا و مستقل و هم‌توزیع هستند. همچنین دو توزیع برای تولید داده‌ها در نمودار پیشنهادی استفاده شده است. دو توزیع انتخاب شده، توزیع نرمال و توزیع گاما هستند. با توجه به مقادیر پارامترهای مدل تحت کنترل، بردار $\mathbf{z} = \begin{bmatrix} 3 \\ 2 \end{bmatrix}$ در آماره D^2 در نظر گرفته می‌شود. مقادیر متغیر مستقل نیز ثابت و برابر با ۲، ۴، ۶ و ۸ در نظر گرفته می‌شود. برای بررسی عملکرد نمودار در هر یک از توزیع‌های انتخاب شده، چهار پارامتر از مشخصه کیفی پروفایلی فرآیند برای توزیع نرمال و سه پارامتر برای توزیع گاما تغییر داده می‌شود.

۱.۴. شبیه‌سازی و ارزیابی عملکرد نمودار کنترل D^2 با توزیع داده‌های نرمال

در نمودار کنترل پیشنهادی، ابتدا عملکرد نمودار در شرایطی که عناصر خطا و در نتیجه مشاهدات در پروفایل مورد نظر از توزیع نرمال پیروی کنند، مورد بررسی قرار می‌گیرد. در این بخش، نمودار کنترل پیشنهادی با مشخصه کیفی به صورت پروفایل خطی ساده براساس توصیف داده بردار پشتیبان که داده‌های آنها از تابع توزیع نرمال با میانگین صفر و واریانس یک پیروی می‌کنند بررسی می‌شوند. چهار تغییر در پارامترهای پروفایلی نمودار کنترل، تغییر در عرض از مبدأ (پارامتر β_0)، تغییر در شیب (پارامتر β_1)، تغییر هم در عرض از مبدأ و هم شیب معادله رگرسیونی پروفایل به صورت هم‌زمان و تغییر در واریانس عناصر خطای پروفایل (σ^2) بررسی خواهند شد. در هر نمونه در فاز ۲، تعداد ۴ پروفایل با استفاده از تغییرات مورد نظر تولید می‌شود و سپس ضرایب هر یک برآورد می‌شوند. اولین تغییر مورد نظر برای نمودار کنترل پیشنهادی D^2 ، تغییر در عرض از مبدأ مشخصه کیفی پروفایل خطی ساده است، که با استفاده از رابطه $\beta_0 + \lambda\sigma$ که مقدار $\lambda\sigma$ را به پارامتر تحت کنترل β_0 اضافه می‌کند، انجام خواهد شد. مقادیر تعیین شده برای تغییرات با شیب افزایشی یکسان ۰/۲ در بازه (۲-۰/۲) قرار می‌گیرند. مقادیر میانگین طول دنباله بدست آمده از شبیه‌سازی نمودار برای این تغییر در جدول ۱ قابل مشاهده است. دومین تغییر در پارامتر شیب انتخاب شده است. در ادامه با ایجاد تغییر به وسیله رابطه $\beta_1 + \rho\sigma$ در مقدار تحت کنترل پارامتر β_1 در نمودار کنترل پیشنهادی D^2 مقادیر میانگین طول دنباله بدست آمده برای تغییرات با شیب ثابت ۰/۲ در بازه (۲-۰/۲) در جدول ۲ گزارش شده است. در جدول ۳ نیز مقادیر میانگین طول دنباله برای نمودار پیشنهادی تحت تغییرات در واریانس عناصر خطا با استفاده از یک ضریب به صورت $\gamma\sigma$ نشان داده می‌شوند. آخرین تغییر مورد نظر در پارامترهای مشخصه پروفایلی مربوط به تغییر هم‌زمان در β_0 و β_1 است. این امر با استفاده از رابطه $\lambda + \rho\bar{x} = 0$ و $\bar{x} = 5$ انجام می‌شود و نتایج میانگین طول دنباله آن در جدول ۴ خلاصه می‌شوند.

جدول ۱. مقادیر میانگین طول دنباله نمودار کنترل پیشنهادی تحت تغییرات در عرض از مبدأ از β_0 به $\beta_0 + \lambda\sigma$ در توزیع نرمال

λ	۰/۲	۰/۴	۰/۶	۰/۸	۱	۱/۲	۱/۴	۱/۶	۱/۸	۲
ARL ₁	۱۸۲/۴	۱۳۹/۸	۹۴/۳	۵۸/۱	۳۵/۵	۲۲/۲	۱۳/۹	۹/۴	۶/۴	۴/۸

جدول ۲. مقادیر میانگین طول دنباله نمودار کنترل پیشنهادی تحت تغییرات در شیب از β_1 به $\beta_1 + \rho\sigma$ در توزیع نرمال

ρ	۰/۲	۰/۴	۰/۶	۰/۸	۱	۱/۲	۱/۴	۱/۶	۱/۸	۲
ARL ₁	۱۸۹/۵	۱۶۵/۲	۱۲۵	۸۳/۸	۴۹/۸	۲۵	۱۰/۶	۳/۸	۱/۷	۱/۱

جدول ۳. مقادیر میانگین طول دنباله نمودار کنترل پیشنهادی تحت تغییرات در واریانس عناصر خطا از σ به $\gamma\sigma$ در توزیع نرمال

γ	۱/۲	۱/۴	۱/۶	۱/۸	۲	۲/۲	۲/۴	۲/۶	۲/۸	۳
ARL ₁	۴۵/۸	۱۸/۳	۹/۹	۶/۳	۴/۸	۳/۸	۳/۲	۲/۸	۲/۵	۲/۳

جدول ۴. مقادیر میانگین طول دنباله نمودار کنترل پیشنهادی تحت تغییرات هم‌زمان در عرض از مبدا و شیب $\lambda + \rho\bar{x} = 0$ و $\bar{x} = 5$ در توزیع نرمال

ρ	-۰/۲	-۰/۳	-۰/۴	-۰/۵	-۰/۶	-۰/۷	-۰/۸	-۰/۹	-۱
ARL ₁	۳۲/۶	۱۰/۲	۴/۴	۲/۴	۱/۶	۱/۳	۱/۱	۱/۰۴	۱/۰۲

با توجه به نتایج جداول ۱ تا ۴، مقادیر میانگین طول دنباله در هر چهار تغییر β_0 ، β_1 ، عناصر خطا و تغییر هم‌زمان در شیب و عرض از مبدا، با افزایش میزان تغییر کاهش می‌یابند و نمودار کنترل پیشنهادی D^2 در شناسایی تغییرات بزرگ عملکرد بهتری نسبت به تغییرات کوچک دارد. در ارتباط با تغییرات β_1 که در جدول ۲ مقادیر میانگین طول دنباله خارج از کنترل آن ذکر شده است، مانند شناسایی تغییرات در β_0 ، هرچه مقادیر تغییر بزرگ‌تر می‌شود نتایج بهبود می‌یابد ولی به طور کلی این نمودار در شناسایی تغییرات کوچک‌تر در شیب کمی ضعیف عمل می‌کند. در شناسایی تغییرات واریانس در جدول ۳ در تمامی تغییرات نمودار کنترل پیشنهادی عملکرد بسیار مناسبی از خود نشان می‌دهد. این موضوع در جدول ۴ که تغییر هم‌زمان در شیب و عرض از مبدا را بررسی می‌کند نیز به چشم می‌خورد.

به‌طور کلی در مورد عملکرد نمودار کنترل پیشنهادی می‌توان اینگونه نتیجه‌گیری کرد که این نمودار در کشف تغییرات متوسط و بزرگ در پارامترهای رابطه پروفایلی زمانی که عنصر خطا از توزیع نرمال پیروی می‌کند از عملکرد مناسبی برخوردار است لیکن در شناسایی تغییرات کوچک در شیب پروفایل کمی ضعیف عمل می‌کند. همچنین نمودار کنترل پیشنهادی در شناسایی تغییر هم‌زمان در شیب و عرض از مبدا از عملکرد مطلوبی برخوردار است.

۲.۴. شبیه‌سازی و ارزیابی عملکرد نمودار کنترل D^2 با توزیع داده‌های گاما

در این بخش، ارزیابی عملکرد نمودار کنترل پیشنهادی با مشخصه کیفی به صورت پروفایل خطی ساده براساس توصیف داده بردار پشتیبان که عناصر خطا از توزیع گاما با پارامترهای (۱و۱) پیروی می‌کنند، انجام می‌شود. اولین تغییر مورد نظر تغییر در عرض از مبدا رابطه رگرسیونی مشخصه کیفی پروفایل خطی ساده است، که با استفاده از رابطه $\beta_0 + \lambda\sigma$ که مقدار $\lambda\sigma$ را به پارامتر تحت کنترل β_0 اضافه می‌کند، انجام خواهد شد و نتایج در جدول ۵ گزارش می‌شوند. مقادیر تعیین شده برای تغییرات برابر با حالت قبل در نظر گرفته شده‌اند. در ادامه با ایجاد تغییر به وسیله رابطه $\beta_1 + \rho\sigma$ در مقدار تحت کنترل پارامتر شیب β_1 در نمودار کنترل پیشنهادی مقادیر میانگین طول دنباله بدست آمده است و نتایج در جدول ۶ نشان داده شده‌اند. در جدول ۷ نیز مقادیر بدست آمده میانگین طول دنباله برای تغییرات هم‌زمان در β_0 و β_1 خلاصه شده‌اند. این امر با کمک گرفتن از رابطه $\lambda + \rho\bar{x} = 0$ و $\bar{x} = 5$ انجام می‌شود، که با ایجاد رابطه در ضرایب، در هر دو به‌طور هم‌زمان تغییر ایجاد می‌کند.

جدول ۵. مقادیر میانگین طول دنباله نمودار کنترل پیشنهادی تحت تغییرات در عرض از مبدا از β_0 به $\beta_0 + \lambda\sigma$ در توزیع گاما

λ	۰/۲	۰/۴	۰/۶	۰/۸	۱	۱/۲	۱/۴	۱/۶	۱/۸	۲
ARL ₁	۱۰۲/۹	۵۲/۱	۲۸/۳	۱۵/۴	۹/۲	۵/۸	۳/۴	۲/۸	۲/۲	۱/۸

جدول ۶. مقادیر میانگین طول دنباله نمودار کنترل پیشنهادی تحت تغییرات در شیب از β_1 به $\beta_1 + \rho\sigma$ در توزیع گاما

ρ	۰/۲	۰/۴	۰/۶	۰/۸	۱	۱/۲	۱/۴	۱/۶	۱/۸	۲
ARL ₁	۲۰۵/۷	۱۹۶/۷	۱۵۷/۲	۱۲۰/۲	۷۴/۴	۳۵/۹	۱۴/۳	۶/۵	۳/۴	۲/۳

جدول ۷. مقادیر میانگین طول دنباله نمودار کنترل پیشنهادی تحت تغییرات هم‌زمان در عرض از مبدا و شیب $\lambda + \rho\bar{x} = 0$ و $\bar{x} = 5$ در توزیع گاما

ρ	-۰/۲	-۰/۳	-۰/۴	-۰/۵	-۰/۶	-۰/۷	-۰/۸	-۰/۹	-۱
ARL ₁	۸/۸	۳/۱	۱/۷	۱/۳	۱/۱	۱/۰۸	۱/۰۳	۱/۰۲	۱/۰۱



با بررسی جداول ۵-۷ مشخص می‌شود که در هر سه تغییر مد نظر برطبق انتظار با افزایش مقادیر تغییرات، قدرت نمودار افزایش یافته است. در این توزیع نیز مانند توزیع نرمال، نمودار کنترل پیشنهادی در شناسایی تغییرات کوچک در شیب ضعیف عمل کرده است. لیکن در شناسایی سایر تغییرات عملکرد مناسبی از خود نشان داده است.

در بررسی و مقایسه عملکرد نمودار کنترل پیشنهادی برای پایش پروفایل خطی ساده با دو توزیع نرمال و گاما برای خطای تصادفی می‌توان گفت که نمودار کنترل پیشنهادی، تغییرات در پارامترهای پروفایل خطی ساده با توزیع خطای تصادفی غیرنرمال را سریعتر شناسایی کرده است به‌طوری‌که از سه تغییر یکسان بررسی شده برای دو توزیع تنها در حالت تغییر در β_1 ، نمودار کنترل پیشنهادی میانگین‌های طول دنباله کمتری را در توزیع نرمال نسبت به توزیع گاما از خود نشان داده است. بعلاوه این نمودار تحت دو توزیع مختلف بهترین عملکرد خود را در تغییر هم‌زمان در پارامترهای عرض از مبدا و شیب از خود نشان داده است.

۵. نتیجه‌گیری و پیشنهادها برای مطالعه آتی

در این مقاله، یک نمودار کنترل یک‌طبقه‌ای محور بر اساس رویکرد توصیف داده بردار پشتیبان برای پایش پروفایل‌های خطی ساده در فاز ۲ توسعه داده شد. عملکرد نمودار کنترل پیشنهادی تحت تغییرات مختلف در پارامترهای پروفایل‌های خطی ساده با استفاده از شبیه سازی مونت کارلو و معیار میانگین طول دنباله ارزیابی شد. همچنین آنالیز حساسیت روی توزیع خطای تصادفی پروفایل خطی ساده انجام شد و عملکرد روش پیشنهادی تحت دو توزیع نرمال و گاما مورد تحلیل قرار گرفت. به طور کلی نتایج نشان داد که روش پیشنهادی در کشف تغییرات متوسط و بزرگ در پارامترهای پروفایل از عملکرد مناسبی برخوردار است. همچنین آنالیز حساسیت روی توزیع خطای تصادفی حاکی از بهتر بودن عملکرد روش پیشنهادی تحت توزیع گاما است و بر اساس این توزیع مقادیر متوسط طول دنباله کمتری بدست می‌آیند. استفاده از نمودارهای یک‌طبقه‌ای محور برای پایش انواع دیگر پروفایل‌ها شامل پروفایل‌های چند متغیره یا غیر خطی می‌تواند به عنوان تحقیقات آتی مدنظر قرار گیرد. همچنین استفاده از سایر روشهای طبقه بندی یک طبقه ای همچون روش تجزیه و تحلیل متمایز برای پایش پروفایل‌ها می‌تواند موضوع جذابی برای محققان علم مهندسی کیفیت باشد.

منابع

- [1] Sukchotrat, T., Kim, S. B., & Tsung, F. (2009). One-class classification-based control charts for multivariate process monitoring. *IIE Transactions*, 42(2), 107-120.
- [2] Jitpitaklert, W. (2009). Integration of data mining algorithms and control charts for multivariate and autocorrelated processes, Ph.D. dissertation, The University of Texas at Arlington.
- [3] Du, S., & Lv, J. (2013). Minimal Euclidean distance chart based on support vector regression for monitoring mean shifts of auto-correlated processes. *International Journal of Production Economics*, 141(1), 377-387.
- [4] Gani, W., & Limam, M. (2013). Performance Evaluation of One-Class Classification-based Control Charts through an Industrial Application. *Quality and Reliability Engineering International*, 29(6), 841-854.
- [5] Gani, W., & Limam, M. (2014). A one-class classification-based control chart using the-means data description algorithm. *Journal of Quality and Reliability Engineering*, 2014, 1-9.
- [6] Martínez-Rego, D., Fernández-Francos, D., Fontenla-Romero, O., & Alonso-Betanzos, A. (2015). Stream change detection via passive-aggressive classification and Bernoulli CUSUM. *Information Sciences*, 305, 130-145.
- [7] Yiakopoulos, C., Koutsoudaki, M., Gryllias, K., & Antoniadis, I. (2017). Improving the performance of univariate control charts for abnormal detection and classification. *Mechanical Systems and Signal Processing*, 86, 122-150.
- [8] Noyel, M., Thomas, P., Thomas, A., & Charpentier, P. (2016). Reconfiguration process for neuronal classification models: Application to a quality monitoring problem. *Computers in Industry*, 83, 78-91.
- [9] Kang, S., Kim, E., Shim, J., Cho, S., Chang, W., & Kim, J. (2017). Mining the relationship between production and customer service data for failure analysis of industrial products. *Computers & Industrial Engineering*, 106, 137-146.
- [10] Zhao, C., Wang, C., Hua, L., Liu, X., Zhang, Y., & Hu, H. (2017). Recognition of control chart pattern using improved supervised locally linear embedding and support vector machine. *Procedia Engineering*, 174, 281-288.
- [11] Liu, Y., Pan, Y., Wang, Q., & Huang, D. (2015). Statistical process monitoring with integration of data projection and one-class classification. *Chemometrics and Intelligent Laboratory Systems*, 149, 1-11.
- [12] Xiao, Y., Wang, H., Xu, W., & Zhou, J. (2016). Robust one-class SVM for fault detection. *Chemometrics and Intelligent Laboratory Systems*, 151, 15-25.
- [13] Gauri, S. K., & Chakraborty, S. (2006). Feature-based recognition of control chart patterns. *Computers & Industrial Engineering*, 51(4), 726-742.
- [14] Lu, C. J., Shao, Y. E., & Li, P. H. (2011). Mixture control chart patterns recognition using independent component analysis and support vector machine. *Neurocomputing*, 74(11), 1908-1914.
- [15] Lin, S. Y., Guh, R. S., & Shiue, Y. R. (2011). Effective recognition of control chart patterns in autocorrelated data using a support vector machine based approach. *Computers & Industrial Engineering*, 61(4), 1123-1134.
- [16] Xie, L., Gu, N., Li, D., Cao, Z., Tan, M., & Nahavandi, S. (2013). Concurrent control chart patterns recognition with singular spectrum analysis and support vector machine. *Computers & Industrial Engineering*, 64(1), 280-289.
- [17] Xanthopoulos, P., & Razzaghi, T. (2014). A weighted support vector machine method for control chart pattern recognition. *Computers & Industrial Engineering*, 70, 134-149.
- [18] Vapnik, V.N. (1998) *Statistical Learning Theory*, Wiley, New York, NY.

[19] Tax, D.M.J. and Duin, R.P.W. (2004) Support vector data description. *Machine Learning*, 54(1), 45-66.

[20] Sukhotrat, T., Kim, S. B., Tsui, K. L., & Chen, V. C. (2011). Integration of classification algorithms and control chart techniques for monitoring multivariate processes. *Journal of Statistical Computation and Simulation*, 81(12), 1897- 1911.