

آشکارسازی عیب با استفاده از یک پارچه‌سازی روش آنالیز متغیر استاندارد و آنالیز مؤلفه مستقل مبنی بر فاکتور برون هشته محلی

الهام توسلی‌پور، محمدتقی حمیدی بهشتی و امین رضانی

جزئی (PLS)^۲ برای آشکارسازی عیب در کاربردهای مختلف به کار گرفته شده‌اند [۴] تا [۶]. در سال ۲۰۰۴، آنالیز مؤلفه اصلی کرنل (KPCA)^۳ به عنوان یک روش نظارت فرایند غیر خطی پیشنهاد شد که روش مذکور نیازی به بهینه‌سازی غیر خطی ندارد [۷] و [۸]. به کار بردن روش PCA، به ناچار عملکرد محدودی را فراهم می‌کند. در واقع PCA بر این فرض استوار است که متغیرها توزیع گوسی دارند در صورتی که مؤلفه‌های اصلی استخراج شده از روش PCA در صنعت واقعی، به ندرت دارای توزیع گوسی هستند. از این رو در سال ۲۰۰۰ روش آنالیز مؤلفه مستقل (ICA)^۴ معرفی شد. ICA با در نظر گرفتن توزیع غیر گوسی برای متغیرها، داده‌های موجود را به داده‌های مستقل تبدیل می‌کند [۹]. روش ICA می‌تواند گسترش یافته روش PCA در نظر گرفته شود اگرچه هدف هر دو الگوریتم کاملاً متفاوت است. الگوریتم PCA سعی دارد تا مؤلفه‌های استخراج شده از این روش تا حد ممکن غیر همبسته شوند در حالی که الگوریتم ICA هر یک از مؤلفه‌ها را تا حد ممکن مستقل از یکدیگر می‌کند. در مجموع می‌توان گفت که ناوابستگی در فرایند PCA ضعیف و در فرایند ICA قوی است. در روش PCA به دلیل فرض گوسی بودن متغیرها، محاسبه حد کنترلی با در نظر گرفتن توزیع F و ... می‌تواند انجام شود اما در روش ICA، این کار از طریق روش تخمین چگالی کرنل (KDE)^۵ صورت می‌گیرد. این روش به انتخاب پارامتر هموارسازی بسیار حساس است. از این رو در [۱۰]، روش ICA با روش ماشین بردار پشتیبان (SVM)^۶ به منظور توسعه یک روش آشکارساز عیب هوشمند یک‌پارچه شده است. در سال ۲۰۱۰ آنالیز مؤلفه مستقل کرنل (KICA)^۷ به منظور افزایش دقت در استخراج کردن متغیرهای مستقل و همچنین کنترل کردن فرایندهای غیر خطی به کار گرفته شد [۱۱]. همچنین در [۱۲]، KPCA و KICA هم‌زمان برای آشکارسازی عیب مورد استفاده قرار گرفتند به گونه‌ای که هر دو نوع توزیع گوسی و غیر گوسی در فرایندهای صنعتی در نظر گرفته شود. سپس در مرحله بعد SVM به منظور عیب‌یابی مورد استفاده قرار گرفت. هر دو نوع روش ICA و PCA، محدودیت‌های مشترکی دارند. اولین محدودیت جدی آنها این است که توزیع خاصی را برای متغیرهای پنهان در نظر می‌گیرند. الگوریتم PCA برای متغیرهای پنهان توزیع گوسی و الگوریتم ICA توزیع غیر گوسی را در نظر می‌گیرند که با مشخصه‌های توزیع داده‌ها در صنعت سخت تطابق پیدا می‌کند زیرا داده‌ها در صنعت واقعی مخلوطی از توزیع گوسی و غیر گوسی هستند. کارهای اندکی در

چکیده: با توجه به اهمیت تشخیص و تصحیح سریع شرایط غیر عادی عیب در فرایندهای صنعتی، در این مقاله روشی جدید به منظور نظارت فرایند پیشنهاد شده است. در این روش هم‌زمان هم دینامیک فرایند و هم تأثیر داده‌های برون هشته در نظر گرفته شده است. ابتدا دینامیک فرایند به وسیله روش آنالیز متغیر استاندارد اعمال شده و سپس از الگوریتم آنالیز مؤلفه مستقل به منظور کاهش بعد داده‌ها استفاده شده است. همچنین حذف داده‌های برون هشته و محاسبه حد کنترلی بر اساس الگوریتم فاکتور برون هشته محلی صورت گرفته است که هیچ توزیع خاصی را برای متغیرهای فرایند در نظر نمی‌گیرد. از این رو با داده‌های موجود در صنعت تطابق دارد. همچنین به منظور افزایش اعتبار روش پیشنهادی در راستای آشکارسازی عیب، این الگوریتم بر روی فرایند TE شبیه‌سازی شده است و مقایسه‌ای با نتایج حاصل از پژوهش‌های دیگر صورت گرفته است. نتایج حاکی از آن است که الگوریتم پیشنهادی بهترین عملکرد را نسبت به سایر روش‌ها دارد.

کلید واژه: آنالیز متغیر استاندارد، آنالیز مؤلفه مستقل، فاکتور برون هشته محلی، فرایند TE.

۱- مقدمه

هدف نظارت در مهندسی فرایندها این است که رفتارهای غیر طبیعی شرایط عملکرد فرایند را آشکار نماید. در جهت تحقق این هدف، روش‌های بسیاری به کار گرفته شده است. در میان این روش‌ها، روش آنالیز مؤلفه اصلی (PCA)^۱ کاربرد بسیار زیادی دارد و در سال‌های اخیر پژوهش‌های بسیار زیادی در این زمینه صورت گرفته است. روش PCA نخستین بار در سال ۱۹۹۶ مطرح شد. در حقیقت PCA یکی از پرکاربردترین روش‌های کاهش بعد است که برای متغیرها، توزیع گوسی را در نظر می‌گیرد. PCA متغیرهای پنهان را به جای متغیرهای اندازه‌گیری شده در فرایند استفاده می‌کند زیرا آنها بهتر می‌توانند رفتار فرایند را توصیف کنند. PCA آماره‌هایی همچون T^2 و SPE را برای نظارت فرایند به کار می‌برد. در صورت ظاهر شدن مشکلی در فرایند، کواریانس ساختار فرایند تغییر می‌کند و این تغییر می‌تواند آشکار شود. در سال‌های بعدی به منظور عملکرد بهتر، PCA با روش‌های دیگری یک‌پارچه شد [۱] تا [۳]. به عنوان مثال، PCA و روش مجموع مربعات

این مقاله در تاریخ ۲۹ فروردین ماه ۱۳۹۳ دریافت و در تاریخ ۴ آبان ماه ۱۳۹۳ بازنگری شد.

الهام توسلی‌پور، دانشکده برق و کامپیوتر، دانشگاه تربیت مدرس، تهران (email: elham.tavasilipour@modares.ac.ir)

محمدتقی حمیدی بهشتی، دانشکده برق و کامپیوتر، دانشگاه تربیت مدرس، تهران (email: mbehesht@modares.ac.ir)

امین رضانی، دانشکده برق و کامپیوتر، دانشگاه تربیت مدرس، تهران (email: ramezani@modares.ac.ir)

1. Principal Component Analysis

2. Partial Least Squares

3. Kernel PCA

4. Independent Component Analysis

5. Kernel Density Estimation

6. Support Vector Machine

7. Kernel ICA

است که دینامیک فرایند در آن در نظر گرفته نشده است. آنالیز متغیر استاندارد (CVA)^۷ یکی دیگر از روش‌های کاهش بعد است که در سال ۱۹۳۶ معرفی شد [۲۱]. این روش برای فرایندهای دینامیکی به کار می‌رود. مهم‌ترین مزیت روش CVA این است که برای فرایندهایی با داده‌های بسیار وابسته نتایج بسیار خوبی می‌دهد، در نتیجه می‌تواند جایگزین خوبی برای روش PCA باشد. متغیرهای استاندارد استخراج شده در روش CVA دارای توزیع گوسی و غیر همبسته هستند و توزیع غیر گوسی متغیرها را در نظر نمی‌گیرند. برای برطرف کردن این مشکل در [۲۲] روش CVA با روش ICA یک‌پارچه شد تا مزایای هر دو روش را هم‌زمان با هم داشته باشد که نتایج نسبت به سایر روش‌های مرتبط بهبود یافته است اما در این مقاله نیز تأثیر داده‌های برون هشته در نظر گرفته نشده است.

به منظور فایده‌آمدن بر این مشکلات در این پژوهش، هم‌زمان هم دینامیک فرایند و هم کاهش بعد داده‌ها و هم تأثیر داده‌های برون هشته در نظر گرفته شده است. ابتدا دینامیک فرایند از طریق روش CVA در نظر گرفته شده که در نتیجه این الگوریتم، متغیرها تا حد ممکن غیر همبسته می‌شوند. سپس به منظور کاهش بعد داده‌ها روش ICA اعمال شده که با اعمال این روش نیز متغیرها تا حد ممکن مستقل از یکدیگر می‌شوند. در نتیجه هم توزیع گوسی و هم توزیع غیر گوسی متغیرها در نظر گرفته می‌شود. همچنین حذف داده‌های برون هشته بر اساس الگوریتم LOF صورت می‌گیرد. مهم‌ترین مزیت این الگوریتم این است که توزیع خاصی را برای متغیرهای فرایند در نظر نمی‌گیرد و به هر داده‌ای با هر توزیعی، درجه‌ای از برون هشته را نسبت می‌دهد و بنابراین با داده‌های موجود در صنعت تطابق دارد. چون LOF می‌تواند مرز قراردادی غیر خطی را به همراه شرایط عملکرد طبیعی در فضای متغیرهای پنهان محاسبه کند، محدوده کنترلی می‌تواند با دقت بیشتری نسبت به سایر روش‌های موجود تخمین زده شود و این امر موجب کاهش نرخ عدم تشخیص عیب می‌شود.

ساختار مقاله حاضر به این صورت است: ابتدا در بخش ۲ الگوریتم‌های ICA، LOF و CVA توضیح داده شده است. در بخش ۳ به طراحی الگوریتم پیشنهادی جهت آشکارسازی عیب پرداخته شده است. در بخش ۴ نتایج حاصل از شبیه‌سازی‌ها ارائه شده و در نهایت در بخش ۵ به بیان نتیجه‌گیری پرداخته شده است.

۲- الگوریتم‌های پیش‌نیاز

در این بخش ابتدا الگوریتم ICA و سپس الگوریتم‌های LOF و CVA به اختصار تشریح شده است.

۲-۱ الگوریتم ICA

در الگوریتم ICA فرض می‌شود که تعداد m متغیر اندازه‌گیری شده می‌تواند به صورت ترکیب خطی از d متغیر ناشناخته مستقل به صورت زیر نمایش داده شود [۹]

$$x_1, x_2, \dots, x_m \Rightarrow s_1, s_2, \dots, s_d, \quad d \leq m \quad (1)$$

مؤلفه‌های مستقل و متغیرهای اندازه‌گیری شده میانگین صفر دارند و رابطه بین آنها به صورت معادله زیر نشان داده می‌شود

$$X = AS \quad (2)$$

زمینه برطرف کردن این مشکل انجام شده که روش PCA و ICA را به طور زنجیره‌وار در دو مرحله انجام می‌دهند. در [۱۳] ابتدا ICA و سپس PCA برای استخراج کردن اطلاعات غیر گوسی و گوسی به کار گرفته شده است. در [۱۴] روش نظارت فرایند ابتدا با انجام دادن PCA و سپس ICA صورت گرفته است.

محدودیت دیگر آنها این است که فرض می‌کنند مشاهدات در یک زمان از نظر آماری نسبت به زمان‌های گذشته مستقل هستند. این فرض نامعتبر است زیرا داده‌ها در صنعت مشخصه دینامیک و وابستگی دارند. به منظور حل کردن این مشکل، روش آنالیز مؤلفه اصلی دینامیک (DPCA)^۱ پیشنهاد شد [۱۵]. این روش از یک ماتریس افزوده با متغیرهای تأخیر زمانی برای وارد کردن دینامیک فرایند استفاده می‌کند. در [۱۶]، روش DPCA به ICA گسترش داده شد و روش جدیدی را به وجود آورد که آنالیز مؤلفه مستقل دینامیک (DICA)^۲ نامیده شد. در این روش ابتدا ماتریس داده‌ها با متغیرهای تأخیر زمانی افزوده می‌شود و سپس روش ICA به منظور کاهش بعد به آن اعمال می‌گردد. نتایج نشان می‌دهند که DICA عملکرد بهتری نسبت به روش ICA دارد. در پژوهش دیگری DICA با روش SVM برای بهبود عملکرد عیب‌یابی فرایندها ترکیب شده است [۱۷].

یکی دیگر از محدودیت‌های ICA و PCA در نظر نگرفتن داده‌های برون هشته است. در واقع این روش‌ها، داده‌های آموزشی را تمیز در نظر می‌گیرند، به این معنی که هیچ آلودگی (برون هشته‌گی) در داده‌های آموزشی وجود ندارد، در حالی که داده‌های برون هشته در فرایند باید تشخیص داده شده و حذف شوند. تأثیر داده‌های برون هشته ممکن است به نتایج نادرستی از جمله افزایش حد کنترلی و تخمین اشتباه پارامترها و ... منجر شود. افزایش حد کنترلی از مقدار طبیعی خود، موجب افزایش نرخ عدم تشخیص عیب می‌شود. به منظور حذف داده‌های برون هشته، در سال ۲۰۱۰ یک روش جدید به نام برون هشته‌گی تنظیمی (AO)^۳ برای ICA و بر پایه اندازه‌گیری مستطیلی پیشنهاد شد [۱۸]. عیب روش ذکر شده این است که وابستگی بین متغیرها در زمان‌های مختلف را در نظر نمی‌گیرد، در حالی که متغیرها در فرایندهای صنعتی از نظر دینامیکی به هم مرتبط هستند. برای برطرف کردن این مشکل، دینامیک فرایند به روش مذکور افزوده شد [۱۹]. شبیه‌سازی‌های نشان داده شده در این مقاله بهبود کاهش نرخ اخطار اشتباه^۴ (Type I error) را نسبت به سایر روش‌ها نشان می‌دهد. اما در بیشتر فرایندهای صنعتی کاهش نرخ عدم تشخیص عیب (Type II error) از اهمیت بیشتری برخوردار است. اگرچه در این روش هم دینامیک فرایند و هم تأثیر داده‌های برون هشته در نظر گرفته شده اما در این روش، اندازه‌گیری مستطیلی این محدودیت را دارد که نمی‌تواند با دقت خوبی مرز غیر خطی شرایط عملکرد نرمال را تخمین بزند.

از دیگر کارهایی که در زمینه حذف داده‌های برون هشته صورت گرفته است می‌توان به [۲۰] اشاره کرد. در این روش ICA با فاکتور برون هشته محلی (LOF)^۵ یک‌پارچه شده است. در حقیقت LOF یک روش کشف داده‌های برون هشته بر مبنای تراکم است. مشکل عمده این روش این

1. Dynamic PCA
2. Dynamic ICA
3. Missed Detection
4. Adjusted Outlier
5. False Alarm
6. Local Outlier Factor

می دهد که شیء ما دور از نمونه های ممکن قرار گرفته است، بنابراین مقدار LOF آن مقداری بزرگ می شود.

۳-۲ الگوریتم CVA

در یک نقطه عملکرد پایدار، سیستم دینامیکی غیر خطی می تواند به صورت یک مدل فضای حالت تصادفی به شکل زیر تقریب زده شود [۲۴]

$$\begin{aligned} x(k+1) &= Bx(k) + w(k) \\ y(k) &= Cx(k) + e(k) \end{aligned} \quad (۸)$$

که در آن B و C به ترتیب ماتریس های حالت و خروجی هستند. $w(k)$ و $e(k)$ خطاهای مدل سازی هستند که معمولاً دارای توزیع غیر گوسی فرض می شوند و $x(k)$ و $y(k)$ حالت و خروجی سیستم را در زمان k نشان می دهند.

ابتدا باید بردار اندازه گیری $y(k)$ به همراه q اندازه گیری گذشته و آینده به صورت زیر بسط داده شود

$$\begin{aligned} y_p(k) &= \begin{bmatrix} y(k-1) \\ y(k-2) \\ \vdots \\ y(k-q) \end{bmatrix} \in R^{mq} \\ y_f(k) &= \begin{bmatrix} y(k) \\ y(k+1) \\ \vdots \\ y(k+q-1) \end{bmatrix} \in R^{mq} \end{aligned} \quad (۹)$$

ماتریس های مشاهدات گذشته و آینده به صورت زیر تعریف می شوند

$$Y_p = [\hat{y}_p(k) \quad \hat{y}_p(k+1) \quad \dots \quad \hat{y}_p(k+N-1)] \in R^{mq \times N} \quad (۱۰)$$

$$Y_f = [\hat{y}_f(k) \quad \hat{y}_f(k+1) \quad \dots \quad \hat{y}_f(k+N-1)] \in R^{mq \times N} \quad (۱۱)$$

در معادلات بالا \hat{y} اختلاف بین بردار مشاهده شده از مقدار میانگین است. ماتریس های کواریانس بین مشاهدات گذشته و آینده به صورت زیر می توانند تخمین زده شوند

$$\begin{aligned} \sum_{pp} &= \frac{1}{N-1} Y_p Y_p^T \\ \sum_{ff} &= \frac{1}{N-1} Y_f Y_f^T \\ \sum_{fp} &= \frac{1}{N-1} Y_f Y_p^T \end{aligned} \quad (۱۲)$$

CVA تلاش می کند که بهترین ترکیب خطی را بین $c^T(\hat{y}_f(k))$ و $d^T(\hat{y}_p(k))$ به گونه ای پیدا کند که وابستگی بین این ترکیب ها بیشینه شود. حل مسئله بهینه سازی مقید می تواند در میان تجزیه مقادیر ویژه ماتریس H که به صورت زیر نشان داده می شود، به دست آید

$$H = \sum_{ff}^{-1} \sum_{fp}^{-1} \sum_{pp}^{-1} = U \sum V^T \quad (۱۳)$$

بعد از به دست آوردن تجزیه مقادیر ویژه، متغیر استاندارد $z(k)$ که بر اساس اندازه گیری های گذشته است به صورت زیر به دست می آید

$$z(k) = V^T \sum_{pp}^{-1} \hat{y}_p(k) = J \hat{y}_p(k) \in R^{mq} \quad (۱۴)$$

J ماتریس تبدیلی است که اندازه گیری های گذشته را به فضای متغیرهای استاندارد تبدیل می کند. فضای متغیرهای استاندارد می تواند به

که در آن X ماتریس داده ها و A ماتریس ترکیب ناشناخته و S ماتریس مؤلفه های مستقل هستند.

همچنین می توان هدف ICA را به این صورت نیز بیان کرد: هدف یافتن ماتریس W به گونه ای است که سطرهای ماتریس بازسازی شده \hat{S} مطابق معادله زیر تا حد ممکن مستقل از یکدیگر شوند

$$\hat{S} = WX \quad (۳)$$

در (۳) ماتریس W در حقیقت معکوس ماتریس A می باشد. الگوریتم رایج برای یافتن مؤلفه های مستقل الگوریتم FastICA است که در [۹] تشریح شده است.

۲-۲ الگوریتم LOF

در این بخش، جزئیات الگوریتم LOF توضیح داده شده است [۲۳]. این الگوریتم می تواند برای حذف برون هشته ها و همچنین محاسبه حد کنترلی مورد استفاده قرار گیرد.

الف) فاصله k از شیء p : برای هر عدد صحیح مثبت k ، فاصله k از شیء p به صورت $k-distance(p)$ نمایش داده شده و برابر فاصله اقلیدسی بین p و هر شیء o متعلق به مجموعه D تعریف می شود.

ب) همسایگی فاصله k برای شیء p : اگر فرض کنیم که فاصله k از شیء p یعنی $k-distance(p)$ داده شده باشد، همسایگی $k-distance(p)$ شامل هر شیء است که فاصله آن از p بزرگ تر از $k-distance(p)$ نباشد یعنی

$$N_{k-distance(p)}(p) = \{q \in D \setminus \{p\} | d(p,q) \leq k-distance(p)\} \quad (۴)$$

نقاط q نزدیک ترین همسایگی p نامیده می شوند. همچنین از این پس $N_{k-distance(p)}$ برای سهولت به صورت $N_k(p)$ نشان داده می شود. ج) فاصله قابل دستیابی محلی برای شیء p : فاصله قابل دستیابی شیء p نسبت به شیء o به صورت زیر تعریف می شود

$$reach-dist_k(p,o) = \max\{k-distance(p), d(p,o)\} \quad (۵)$$

د) چگالی قابل دستیابی محلی (lrd) برای شیء p : به صورت زیر تعریف می شود

$$lrd_k(p) = \frac{1}{\sum_{o \in N_k(p)} reach-dist_k(p,o)} \quad (۶)$$

ه) فاکتور برون هشته محلی برای شیء p : به صورت زیر تعریف می شود

$$LOF(p) = \frac{\sum_{o \in N_k(p)} lrd_k(o)}{N_k(p)} \quad (۷)$$

فاکتور برون هشته محلی نقطه p درجه ای را می دهد که می تواند p را یک برون هشته در نظر بگیرد. در حقیقت، این معادله میانگین نرخ چگالی قابل دستیابی محلی شیء p و نزدیک ترین همسایگی های این شیء است. اگر شیء p یک شیء برون هشته نباشد، مقدار LOF آن نزدیک به یک می شود زیرا تراکم آن نزدیک به تراکم سایر نقاط در $N_k(p)$ می شود. اما اگر شیء p یک برون هشته باشد، مقدار LOF آن بزرگ تر از یک می شود زیرا نسبت تراکم p به تراکم سایر نقاط کم است و تفاوت بین صورت کسر و مخرج آن در (۷) زیاد می شود و این نشان

شیوه بیان شده در گام سوم محاسبه می‌شود. در نهایت هم حد کنترلی برای حالت درون خطی در هر دو فضا تعیین می‌شود. حد کنترلی ۹۹٪ توسط KDE محاسبه شده از $LOF(\hat{s}_{x_1})$ در فضای اصلی و $LOF(\hat{s}_{r_1})$ در فضای باقی‌مانده به دست می‌آید. به این ترتیب با به دست آمدن حدود کنترلی و ماتریس‌های W_{r_1} و W_{x_1} فاز مدل‌سازی به پایان می‌رسد.

۳-۲ فاز نظارت در الگوریتم CV-ICA(LOF)

گام اول: ابتدا باید ماتریس جدید داده‌های آزمایش \hat{y}_{pnew} را به دست آورد.

گام دوم: در این مرحله، متغیرهای استاندارد مطابق رابطه زیر محاسبه می‌شوند

$$\hat{z} = J\hat{y}_{pnew} = [\hat{x}^T : \hat{r}^T]^T \quad (21)$$

گام سوم: مؤلفه‌های مستقل در هر دو فضا مطابق روابط زیر به دست می‌آیند

$$\begin{aligned} \hat{s}_x^{new} &= W_{x_1}\hat{x} \\ \hat{s}_r^{new} &= W_{r_1}\hat{r} \end{aligned} \quad (22)$$

گام چهارم: سپس مقادیر LOF برای \hat{s}_x^{new} و \hat{s}_r^{new} محاسبه می‌شوند که به صورت $LOF(\hat{s}_x^{new})$ و $LOF(\hat{s}_r^{new})$ نمایش داده می‌شود. اگر $LOF(\hat{s}_x^{new}) > LOF(\hat{s}_{x_1})$ یا $LOF(\hat{s}_r^{new}) > LOF(\hat{s}_{r_1})$ آن نمونه به عنوان عیب شناخته می‌شود و در غیر این صورت به عنوان یک داده طبیعی در فاز نظارت تلقی می‌شود.

الگوریتم محاسبه مقادیر LOF در فاز نظارت دارای تفاوت‌هایی با فاز مدل‌سازی است که در [۲۰] به طور کامل تشریح شده است. در حقیقت در این بخش از الگوریتم تخمینی استفاده می‌شود. الگوریتم تخمینی نیاز به محاسبات کمتری نسبت به الگوریتم واقعی دارد و ضمن این که نتایج در مقایسه با الگوریتم واقعی تغییر چشم‌گیری نمی‌کند. در حقیقت در ازای از دست دادن بخش ناچیزی از اطلاعات، زمان اجرای محاسبات به مقدار قابل توجهی کاهش پیدا می‌کند.

۴- شبیه‌سازی‌ها و نتایج

۴-۱ فرایند TE

شرکت شیمیایی ایستمن، فرایند تسبی ایستمن (TEP) را برای وجود یک فرایند صنعتی واقعی برای ارزیابی روش‌های نظارت و کنترل به وجود آورده است. فرایند آزمایشی مبتنی بر شبیه‌سازی یک فرایند صنعتی واقعی است که در آن اجزا و شرایط کاری به دلایل خاصی تغییر کرده‌اند [۲۵]. این فرایند شامل ۴۱ متغیر اندازه‌گیری و ۱۲ متغیر کنترلی است. همه اندازه‌گیری‌های فرایند شامل اختلال گوسی می‌باشند. برای فاز مدل‌سازی از داده‌های کلاس عیب صفر (داده‌های بدون عیب) استفاده شده است. شبیه‌سازی فرایند TE شامل ۲۱ عیب از پیش تعیین شده است که در ادامه مطلب جزئیات ۲۰ عیب آمده است.

۴-۲ نتایج

همان گونه که قبلاً توضیح داده شد، این روش به دو فضای اصلی و فضای باقی‌مانده تقسیم می‌شود. در این بخش شبیه‌سازی‌های مربوط به هر دو فضا آورده شده است. همچنین هر ۵۲ متغیر موجود در فرایند TE

دو بخش مجزا تقسیم شود: فضای اصلی و فضای باقی‌مانده. این فضاها با تأثیر دامنه مقادیر ویژه $\sigma_i, i=1, 2, \dots, mq$ محاسبه می‌شوند. در شرایطی که $l < mq$ باشد، l مقدار ویژه اول مقادیر ویژه، فضای اصلی را تشکیل می‌دهند ($x(k) \in R^l$) و مقادیر ویژه باقی‌مانده، در فضای باقی‌مانده جای می‌گیرند ($r(k) \in R^{mq-l}$). بنابراین، متغیر استاندارد به صورت زیر می‌تواند نمایش داده شود

$$z(k) = [x(k)^T \quad r(k)^T]^T \quad (15)$$

جزئیات الگوریتم CVA در [۲۴] تشریح شده است.

۳- طراحی الگوریتم‌های آشکارسازی عیب

در این بخش به طراحی الگوریتم پیشنهادی جهت آشکارسازی عیب پرداخته می‌شود. آشکارسازی عیب در دو فاز مدل‌سازی و نظارت صورت می‌گیرد. ابتدا فاز مدل‌سازی برای روش CV-ICA(LOF) طراحی می‌گردد. منظور از نگارش CV-ICA(LOF)، به کارگیری روش CV-ICA با استفاده از آماره LOF می‌باشد. پس از به دست آوردن حد کنترلی، به بیان چگونگی آشکارسازی عیب در فاز نظارت پرداخته می‌شود. در ادامه جزئیات این الگوریتم تشریح می‌شود.

۳-۱ فاز مدل‌سازی در الگوریتم CV-ICA(LOF)

گام اول: ابتدا ماتریس داده‌های آموزشی $Y \in R^{m \times N}$ ، بارگذاری می‌شود. پس از تعیین مقدار تأخیر q که در این پژوهش، مقدار $q=3$ انتخاب شده است [۲۲]، متغیرهای استاندارد از (۱۵) به دست می‌آیند. گام دوم: در این مرحله پس از به دست آوردن متغیرهای استاندارد، مؤلفه‌های مستقل در هر دو فضای اصلی و باقی‌مانده مطابق روابط زیر محاسبه می‌شوند

$$\begin{aligned} \hat{s}_x &= W_x x = [\hat{s}_x(1) \hat{s}_x(2) \dots \hat{s}_x(N)] \\ \hat{s}_r &= W_r r = [\hat{s}_r(1) \hat{s}_r(2) \dots \hat{s}_r(N)] \end{aligned} \quad (16)$$

گام سوم: سپس الگوریتم LOF به مؤلفه‌های مستقل در هر دو فضای اصلی و باقی‌مانده \hat{s}_x و \hat{s}_r به صورت زیر اعمال می‌شود

$$LOF(\hat{s}_x) = [LOF(\hat{s}_x(1)) \dots LOF(\hat{s}_x(N))] \quad (17)$$

$$LOF(\hat{s}_r) = [LOF(\hat{s}_r(1)) \dots LOF(\hat{s}_r(N))] \quad (18)$$


گام چهارم: در این مرحله داده‌های برون هشته در هر فضا به طور جداگانه حذف می‌شوند. برای حذف برون هشته‌ها، با استفاده از مقادیر LOF یک تابع چگالی احتمال کرنل با استفاده از روش KDE تخمین زده می‌شود و سپس حد ۹۹٫۳٪ آن به عنوان مرز برون هشته‌گی تعیین می‌گردد. برای ماتریس داده‌ها، یک نمونه به عنوان یک داده برون هشته است، اگر $LOF(\hat{s}_j(i))$ for $j = x, r$ بزرگ‌تر از حد ۹۹٫۳٪ محاسبه شده توسط KDE با $LOF(\hat{s}_j(i))$ باشد.

گام پنجم: بعد از حذف داده‌های برون هشته از هر دو فضا، مجدداً ماتریس‌های x' و r' با N_x و N_r نمونه تشکیل می‌شوند. سپس الگوریتم ICA بر روی هر دو ماتریس در فضای اصلی و باقی‌مانده، به منظور به دست آوردن ماتریس‌های W_{x_1} و W_{r_1} برای حالت درون خطی اجرا می‌شود. این ماتریس‌ها از روابط زیر به دست می‌آیند


$$\hat{s}_{x_1} = W_{x_1} x' = [\hat{s}_{x_1}(1) \dots \hat{s}_{x_1}(N_x)] \quad (19)$$

$$\hat{s}_{r_1} = W_{r_1} r' = [\hat{s}_{r_1}(1) \dots \hat{s}_{r_1}(N_r)] \quad (20)$$

گام ششم: در این مرحله مقادیر $LOF(\hat{s}_{x_1})$ و $LOF(\hat{s}_{r_1})$ به همان




شکل ۳: تعداد متغیرهای استاندارد در نسبت مقادیر ویژه ۹۰٪.



شکل ۱: نمودار نشان دهنده مقدار ویژه برای هر متغیر استاندارد.

جدول ۱: نرخ عدم تشخیص عیب بر حسب درصد در مقایسه با نسبت های مختلف مقادیر ویژه در فضای اصلی و پارامتر K .

Fault ID	%۸۰ ($k=10$)	%۸۰ ($k=20$)	%۹۰ ($k=10$)
۱۳	۱,۳۷	۱,۵	۰,۷۵
۱۶	.	.	.
۱۷	۰,۶۲	۰,۶۲	۰,۳۸
۱۸	۱,۵	۱,۵	۰,۵
۲۰	۳,۱۲	۲,۷۵	۱,۳۸



شکل ۲: تعداد متغیرهای استاندارد در نسبت مقادیر ویژه ۸۰٪.

همان طور که جدول ۱ نشان می دهد، در میان این الگوریتم ها، الگوریتم پیشنهادی پایین ترین میانگین نرخ عدم تشخیص عیب را دارد. زیرا در این الگوریتم، هم زمان هم دینامیک فرایند و هم تأثیر داده های برون هشته در نظر گرفته شده است. الگوریتم LOF به هر داده ای صرف نظر از توزیع آن، درجه ای از برون هشته نسبت می دهد. از این رو با داده های موجود در صنعت تطابق دارد. همچنین روش DPCA بالاترین میانگین نرخ عدم تشخیص عیب را دارد زیرا در این روش تأثیر داده های برون هشته در نظر گرفته نشده و همچنین از روش PCA به منظور کاهش بعد داده ها استفاده شده است. به کار بردن روش CV-ICA با دو آماره I^2 و LOF موجب می شود که عیب های شماره ۳، ۹ و ۱۵ که دارای دامنه بسیاری کوچکی هستند و در اکثر روش ها نیز قابل تشخیص نیستند، به راحتی و با نرخ خطاهای پایینی آشکار شوند. الگوریتم I^2 CV-ICA نسبت به الگوریتم پیشنهادی نرخ خطای بالاتری دارد زیرا این الگوریتم از آماره I^2 جهت محاسبه حد کنترلی و حذف داده های برون هشته استفاده می کند. این آماره اندازه گیری نوع بیضی شکل را در محاسبات خود به کار می برد. به دلیل در نظر گرفتن توزیع خاص برای متغیرها، اختلاف بین آماره واقعی و تخمین زده شده زیاد می شود و همین امر موجب افزایش نرخ خطا در این الگوریتم می شود.

شکل های ۴ و ۵ روش پیشنهادی را برای عیب شماره ۳ در هر دو فضا نشان می دهند. همان گونه که از شکل ها مشخص است، مزیت الگوریتم پیشنهادی این است که در بیشتر نمونه ها دو فضا مکمل یکدیگر هستند. به این معنا که اگر در نمونه ای، فضای اصلی نتواند وقوع عیب را در فرایند تشخیص دهد، فضای باقی مانده وقوع آن عیب را آشکار می کند یا بالعکس. همین امر موجب برتری روش پیشنهادی نسبت به الگوریتم DICA (LOF) می شود. همچنین نتایج این الگوریتم در مقایسه با روش I^2 CV-ICA نیز بهبود یافته و دلیل آن هم در نظر گرفتن تأثیر داده های برون هشته در الگوریتم پیشنهادی است.

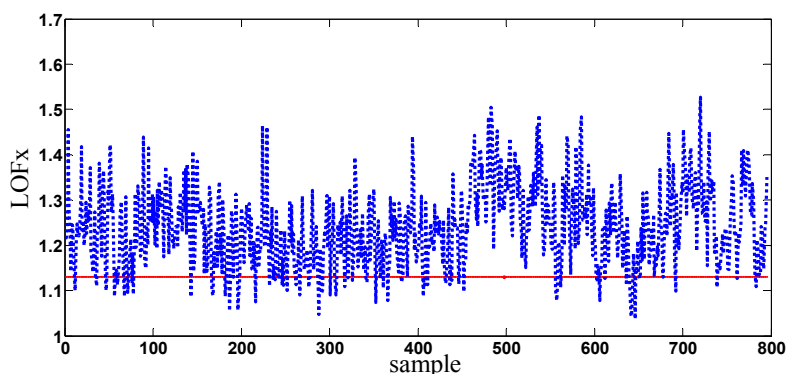
۵- نتیجه گیری

در این پژوهش، روشی جدید به منظور نظارت فرایند پیشنهاد شده که در این روش هم زمان هم دینامیک فرایند و هم تأثیر داده های برون هشته


برای شبیه سازی انتخاب شده است. در الگوریتم CVA، مقدار $q=3$ انتخاب شده است. با در نظر گرفتن هر ۵۲ متغیر مقدار $mq=3$ به دست خواهد آمد. نکته مهمی که در این الگوریتم وجود دارد، انتخاب تعداد مقادیر ویژه در فضای اصلی است. این انتخاب هیچ قانون خاصی ندارد اما به طور کلی اگر نسبت l مقدار ویژه تأثیرگذار موجود در فضای اصلی به کل مقادیر ویژه خیلی زیاد باشد، در این صورت فضای اصلی شامل اختلال های فیلتر نشده خواهد بود. برعکس اگر نسبت l مقدار ویژه تأثیرگذار موجود در فضای اصلی به کل مقادیر ویژه خیلی کم باشد، فضای اصلی بخش بسیار زیادی از اطلاعات را از دست خواهد داد. شکل ۱ نشان دهنده مقادیر ویژه برای هر متغیر استاندارد است. همچنین شکل های ۲ و ۳ نسبت مقادیر ویژه ۸۰٪ و ۹۰٪ را نشان می دهند.

در جدول ۱ چندین عیب مختلف و همچنین مقادیر l و k مرتبط با آنها آورده شده است. اگر مقایسه ای بین نرخ عدم تشخیص عیب، زمانی که نسبت مقادیر ویژه موجود در فضای اصلی به کل مقادیر ویژه ۸۰٪ و ۹۰٪ باشد صورت گیرد، کاملاً واضح است که انتخاب نسبت ۹۰٪، $l=109$ مناسب می باشد. در این حالت علاوه بر انتخاب نسبت مقادیر ویژه، پارامتر k موجود در الگوریتم LOF نیز تأثیرگذار است. همان گونه که در جدول مشخص است، این پارامتر برای نسبت ۸۰٪ یک بار برابر ۱۰ و بار دیگر برابر ۲۰ انتخاب شده است. همان طور که از جدول مشخص است، نرخ عدم تشخیص عیب در عیب شماره ۲۰ در بهترین حالت به ۱,۳۸٪ کاهش یافته است. این در حالی است که با انتخاب نسبت مقادیر ویژه ۸۰٪ این نرخ بیشتر می شود. در حقیقت در این پژوهش معیار انتخاب نسبت مقادیر ویژه در فضای اصلی به کل مقادیر ویژه مقایسه نرخ عدم تشخیص در عیب هایی است که بیشتر حائز اهمیت هستند. همچنین در هر سه حالت، هر دو نرخ خطا برای عیب شماره ۱۶ به صفر کاهش یافته است.

نتایج روش پیشنهادی در مقایسه با روش های I^2 CV-ICA، DPCA و ICA در جدول ۲ آورده شده است. روش های مذکور برای مقایسه از [۲۲] آورده شده اند.



شکل ۴: نتیجه نظارت فرایند TE در روش CV-ICA(LOF) در عیب ۳ در فضای اصلی.



شکل ۵: نتیجه نظارت فرایند TE در روش CV-ICA(LOF) در عیب ۳ در فضای باقی مانده.

جدول ۲: نرخ عدم تشخیص عیب در فرایند TE در روش CV-ICA(LOF) بر حسب درصد.

Fault no. description	CV-ICA (I')	ICA	DPCA	CV-ICA(LOF)
1. A/C feed ratio, B composition constant	۰	۰/۴۱	۰	۰
2. B composition, A/C ratio constant	۰	۹۲/۹۲	۱/۲۵	۰
3. D feed temperature	۸/۲۱	۸۳/۸۶	۹۸/۵۴	۶/۴۲
4. Reactor cooling water inlet temperature	۰	۴/۵۸	۰/۱۲	۰
5. Condenser cooling water inlet temperature	۰	۰	۷۰/۹۱	۰
6. A feed loss	۰	۰	۱/۴۶	۰
7. C header pressure loss	۰	۰	۰	۰
8. A, B, C feed composition	۰/۶۳	۲/۷۱	۱/۸۷	۰
9. D feed temperature	۴/۲۱	۹۲/۷۱	۹۸/۱۲	۲/۱
10. C feed temperature	۰/۴۲	۸/۷۵	۱۶/۸۷	۰
11. Reactor cooling water inlet temperature	۰	۲۰/۸۳	۱۸/۱۲	۰
12. Condenser cooling water inlet temperature	۰	۱/۴۶	۲/۰۸	۰
13. Reaction kinetics	۰	۲/۵	۴/۲۵	۰/۷۵
14. Reactor cooling water valve	۰	۰/۲۱	۱/۶۷	۰
15. Condenser cooling water valve	۲/۱	۸۸/۵۴	۹۶/۸۷	۱/۷۶
16. Unknown	۰/۶۳	۱۹/۵۹	۷۳/۷۸	۰
17. Unknown	۰	۹/۵۸	۶/۸۷	۰/۳۸
18. Unknown	۱/۲۶	۱۵/۴۲	۱۳/۷۵	۰/۵
19. Unknown	۰	۲۴/۱۷	۱۲/۹۸	۰
20. Unknown	۰/۴۲	۶/۰۴	۲۱/۶۷	۱/۳۸
Average	۰/۸۹۴	۲۳/۷۱۴	۲۷/۰۵۹	۰/۶۶۴

LOF می‌تواند مرز قراردادی غیر خطی را به همراه شرایط عملکرد طبیعی در فضای متغیرهای پنهان محاسبه کند، محدوده کنترلی می‌تواند با دقت بیشتری نسبت به سایر روش‌های موجود تخمین زده شود و این امر موجب کاهش نرخ عدم تشخیص عیب می‌شود. سپس با استفاده از LOF

در نظر گرفته شده است. ابتدا از الگوریتم CVA برای در نظر گرفتن دینامیک و وابستگی بین متغیرهای فرایند و سپس از الگوریتم ICA به منظور کاهش بعد در داده‌ها استفاده شده است. داده‌های برون هشته با استفاده از الگوریتم LOF حذف شدند تا تأثیر آنها از میان برود. چون

- [16] M. L. Jong, Y. ChangKyoo, and L. In-Beum, "Statistical monitoring of dynamic processes based on dynamic independent component analysis," *Chem. Eng. Sci.*, vol. 59, no. 14, pp. 2995-3006, Jul. 2004.
- [17] M. Isaac, B. Raul, E. Gerard, and G. Moises, "DICA enhanced SVM classification approach to fault diagnosis for chemical processes," in *Proc. 19th European Symposium on Computer Aided Process Engineering, ESCAPE'09*, vol. 26, pp. 267-272, 2009.
- [18] H. Chun-Chin, C. Long-Sheng, and L. Cheng-Hsiang, "A process monitoring scheme based on independent component analysis and adjusted outliers," *Int. J. Prod. Res.*, vol. 48, no. 15, pp. 1727-1743, 2010.
- [19] H. Chun-Chin, C. Mu-Chen, and C. Long-Sheng, "A novel process monitoring approach with dynamic independent component analysis," *Control Eng. Pract.*, vol. 18, no. 3, pp. 242-253, Mar. 2010.
- [20] J. Lee, B. Kang, and S. H. Kang, "Integrating independent component analysis and local outlier factor for plant-wide process monitoring," *J. Process Control*, vol. 21, no. 7, pp. 1011-1021, Aug. 2011.
- [21] A. Norvalis, A. Negiz, J. DeCicco, and A. Cinar, "Intelligent process monitoring by interfacing knowledge-based systems and multivariate statistical monitoring," *J. Process Control*, vol. 10, no. 4, pp. 341-350, Aug. 2000.
- [22] Y. Yang, Y. Chen, X. Chen, and X. Liu, "Multivariate industrial process monitoring based on the integration method of canonical variate analysis and independent component analysis," *Chemometr. Intell. Lab.*, vol. 116, pp. 94-101, Jul. 2012.
- [23] M. M. Breunig, H. P. Kriegel, R. T. Ng, and J. Sander, "Identifying density-based local outliers," in *Proc. ACM Int. Conf. on Management of Data, SIGMOD'00*, pp. 93-104, 2000.
- [24] P. P. Odiwei and Y. Cao, "Nonlinear dynamic process monitoring using canonical variate analysis and kernel density estimations," *IEEE Trans. on Industrial Informatics*, vol. 6, no. 1, pp. 36-44, Mar. 2010.
- [25] L. H. Chiang, E. L. Russell, and R. D. Braatz, *Fault Detection and Diagnosis in Industrial Systems*, Springer, Urbana-champaign, London, Ch. 1, pp. 103-108.

الهام توسلی پور در سال ۱۳۹۰ مدرک کارشناسی مهندسی برق کنترل خود را از دانشگاه صنعتی شاهرود و در سال ۱۳۹۲ مدرک کارشناسی ارشد مهندسی برق کنترل خود را از دانشگاه تربیت مدرس دریافت نمود. وی هم اکنون مشغول به تحصیل در مقطع دکتری رشته مهندسی برق در دانشگاه علم و صنعت ایران می باشد. زمینه های تحقیقاتی مورد علاقه ایشان عبارتند از: شناسایی سیستم، کنترل فرآیند، کنترل سیستم های تحمل پذیر عیب.

محمدتقی حمیدی بهشتی در سال ۱۳۶۳ مدرک کارشناسی مهندسی برق خود را از دانشگاه نبراسکا در امریکا و مدارک کارشناسی ارشد و دکتری مهندسی برق خود را به ترتیب در سال های ۱۳۶۶ و ۱۳۷۱ از دانشگاه ایالتی ویجیتا در کانزاس آمریکا دریافت نمود. دکتر بهشتی هم اکنون یکی از اعضای هیأت علمی گروه مهندسی برق کنترل دانشکده مهندسی برق و کامپیوتر دانشگاه تربیت مدرس می باشد. زمینه های علمی مورد علاقه نامبرده متنوع بوده و شامل موضوعاتی مانند کنترل بهینه، کنترل تطبیقی، کنترل شبکه های سیستم می باشد.

امین رضائی در سال ۱۳۸۰ مدرک کارشناسی مهندسی برق خود را از دانشگاه شهید بهشتی و در سال ۱۳۸۲ مدرک کارشناسی ارشد مهندسی برق خود را از دانشگاه صنعتی شریف و در سال ۱۳۹۰ مدرک دکتری مهندسی برق خود را از دانشگاه تهران دریافت نمود. دکتر رضائی هم اکنون یکی از اعضای هیأت علمی گروه مهندسی برق کنترل دانشکده مهندسی برق و کامپیوتر دانشگاه تربیت مدرس می باشد. زمینه های علمی مورد علاقه نامبرده متنوع بوده و شامل موضوعاتی مانند کنترل سیستم های تحمل پذیر عیب، سیستم های ارتباط از راه دور، سیستم های هوشمند حمل و نقل و سیستم های رویداد گسسته می باشد.

داده های بدون برون هشتگی، حد کنترلی برای فاز نظارت به دست آمد. جهت بررسی عملکرد الگوریتم پیشنهادی، مقایسه ای بین آن و روش های پیشین در فرآیند TE صورت گرفت. با اعمال روش مذکور به فرآیند TE، نرخ عدم تشخیص عیب در اکثریت عیب های این فرآیند به صفر کاهش یافت. دلیل این کاهش این است که این الگوریتم از دو فضای اصلی و باقی مانده که مکمل یکدیگر هستند، برای تشخیص وقوع عیب استفاده می کند. به این معنا که اگر در نمونه ای، فضای اصلی نتواند وقوع عیب را در فرآیند تشخیص دهد، فضای باقی مانده وقوع آن عیب را آشکار می کند یا بر عکس. این امر برتری روش پیشنهادی را در مقایسه با روش های مشابه نشان می دهد.

مراجع

- [1] J. V. Kresta, J. F. Macgregor, and T. H. E. Marlin, "Multivariate statistical monitoring of process operating performance," *Can. J. Chem. Eng.*, vol. 69, no. 1, pp. 35-47, 1991.
- [2] B. R. Bakshi, "Multiscale PCA with application to multivariate statistical process monitoring," *AIChE Journal*, vol. 44, no. 7, pp. 1596-1610, 1998.
- [3] W. Li, H. Yue, S. V. Cervantes, and J. Qin, "Recursive PCA for adaptive process monitoring," *J. Process Control*, vol. 10, no. 5, pp. 471-486, 2000.
- [4] B. M. Wise and N. B. Gallagher, "The process chemometrics approach to process monitoring and fault detection," *Comp. Chem. Eng.*, vol. 20, no. 1, pp. 65-78, 1996.
- [5] D. Dong and T. J. MacAvoy, "Nonlinear principal component analysis based on principal curves and neural networks," *J. Process Control*, vol. 6, no. 6, pp. 329-348, Jan. 1996.
- [6] P. Nomikos and J. F. MacGregor, "Monitoring batch processes using multiway principal component analysis," *AIChE Journal*, vol. 40, no. 8, pp. 1361-1375, Aug. 1994.
- [7] J. M. Lee, C. Yoo, S. W. Choi, P. A. Vanrolleghem, and I. B. Lee, "Nonlinear process monitoring using kernel principal component analysis," *Chem. Eng. Sci.*, vol. 59, pp. 223-234, 2004.
- [8] S. W. Choi, C. Lee, J. M. Lee, J. H. Park, and I. B. Lee, "Fault detection and identification of nonlinear process based on kernel PCA," *Chemometr. Intell. Lab.*, vol. 75, no. 1, pp. 55-67, 2005.
- [9] A. Hyvarinen and E. Oja, "Independent component analysis: algorithm and applications," *Neural Network Control*, vol. 13, no. 4-5, pp. 411-413, May/June. 2000.
- [10] C. Hsu, M. Chen, and L. Chen, "Intelligent ICA-SVM fault detector for non-gaussian multivariate process monitoring," *Expert Syst.*, vol. 37, no. 4, pp. 3264-3273, Apr. 2010.
- [11] W. Li and S. Hongbo, "Multivariate statistical process monitoring using an improved independent component analysis," *Chemical Engineering Research and Design*, vol. 88, no. 4, pp. 403-414, Apr. 2010.
- [12] Y. Zangh, "Enhanced statistical analysis of nonlinear using KPCA, KICA and SVM," *Chem. Eng. Sci.*, vol. 64, no. 5, pp. 801-811, Mar. 2009.
- [13] Z. Ge and Z. Song, "Process monitoring based on independent component analysis-principal component analysis (ICA-PCA) and similarity factors," *Ind. Eng. Chem. Res.*, vol. 46, no. 7, pp. 2054-2063, Mar. 2007.
- [14] X. Liu, L. Xie, U. Kruger, T. Littler, and S. Wang, "Statistical-based monitoring of multivariate non-gaussian systems," *AIChE J.*, vol. 54, pp. 2379-2391, 2008.
- [15] R. Storer, W. Ku, and C. Georgakis, "Disturbance detection and isolation by dynamic principal component analysis," *Chemometr. Intell. Lab.*, vol. 30, no. 1, pp. 179-196, Nov. 1995.