

Identificación de Fallas en un Intercambiador de Calor

Celina Rea^β, Cristina Verde^α, Ruben Morales-Menendez^γ

^αUNAM, Instituto de Ingeniería
verde@servidor.unam.mx
Tecnológico de Monterrey, Campus Monterrey
^βPrograma de Graduados en Ingeniería
^γDirección Asociada de Investigación
{A00608453, rmm}@itesm.mx

Abstract. Se propone el uso de Análisis de Componentes Principales Dinámicos (*DPCA*) para realizar detección de fallas en un Intercambiador de Calor (*IC*) industrial. Tomando datos de operación nominal, se generó una matriz dinámica con un retraso en las mediciones, obteniendo así los componentes principales y valores de variabilidad que describen al sistema. Con esta información se modelan las condiciones normales del proceso y vía umbrales estadísticos, se reconocen las fallas en los sensores. El residuo en el subespacio de las componentes residuales, permitirá identificar la falla: *DPCA* podrá diagnosticar. Se implementan fallas en el *IC* para emular desperfectos en los sensores, observando su proyección en los espacios principales y residuales, así como el diagnóstico de la variable que contribuye a maximar el residuo donde sucedió la falla.

Palabras clave: Análisis de Componentes Principales Dinámicos, Detección de Fallas, Tablas de Contribución Residual.

1 Introducción

La administración de eventos anormales, en un sistema de control supervisorio, tiene como objetivo detectar la causa original de estos y realizar acciones para llevar al proceso al punto normal de operación. Si bien las tareas de control se han automatizado, gran parte de los manejos de situaciones anómalas reside en operadores. Estadísticas industriales demuestran que el 70% de los accidentes en la industria son causados por errores humanos [1]. El diagnóstico se dificulta al tener cientos de variables de proceso, además de contar con información insuficiente e incompleta debido a fallas o sesgos en la instrumentación del proceso.

Se tienen diferentes enfoques para la detección y diagnóstico de fallas. Hay tres grandes enfoques basados en: modelos *cuantitativos*, modelos *cualitativos* y basados en el *historial* de operación del proceso [2]. La mayoría de los trabajos basados en modelos *cuantitativos* sólo aplican a sistemas univariados y lineales, limitando su efectividad.

Los trabajos basados en modelos *cualitativos*, requieren del entendimiento físico o químico del proceso, como grafos bipartitas y las búsquedas topográficas

M. A. Moreno, C. A. Cruz, J. Álvarez, H. Sira (Eds.)
*Special Issue: Advances in Automatic Control and Engineering
Research in Computing Science 36, 2008, pp. 3-12*

y sintomáticas. No siempre garantiza la identificación y requiere gran manejo computacional.

Los métodos basados en el *historial* de operación del proceso intentan extraer la máxima información de archivos de datos y requieren un conocimiento mínimo del comportamiento del proceso. Aquí se encuentra el método de análisis de Componentes Principales (*PCA*), el cual permite transformar los datos obtenidos directamente del proceso en un espacio de menor dimensión y mantiene la información importante del proceso [3]. Al usar *PCA* se asume que las muestras actuales son estadísticamente independientes de las anteriores, lo cual es generalmente inválido para procesos de carácter dinámico, pues se tienen correlaciones y autocorrelaciones que necesitan ser tomadas en cuenta para describir la variabilidad de forma completa [4].

Se han desarrollado diversos trabajos y aplicaciones relacionados a este estudio. En [5], para determinar el estado de los sensores se utiliza el indicador *Sensor Validity Index* en un proceso de tratamiento de aguas residuales, con resultados mejores que al utilizar *PCA*. [6] utiliza *PCA* para monitorear las explosiones en reactores, indica que el estadístico Q es más sensible a desviaciones en la instrumentación que el T^2 , pues representa las relaciones implícitas entre variables. En [7], se estandarizan los datos en línea al estimar nuevos valores medios para evitar la generación de falsas alarmas, identificando correctamente obstrucciones en las tuberías de tanques interconectados.

Por otra parte, poco se ha reportado sobre las aplicaciones en intercambiadores de calor (*IC*). En [8] se propone un algoritmo para pronósticar un muestreo adelante la distribución de probabilidad de fallas o estados del *IC*. La estimación se basa en el algoritmo *Rao-Blackwell Particle Filtering* [9], el resultado se introduce para ajustar el sistema de control del proceso. En [10] la generación de residuos estructurados permite identificar fallas en el proceso, sin diagnosticar al elemento en disfunción. Existe un estudio basado en técnicas estadísticas presentado por [11], donde se utiliza *PCA* para evaluar el funcionamiento correcto de un reactor de colada continua. Se simula una falla cambiando el coeficiente de transferencia de calor del *IC*.

Este trabajo se organiza de la siguiente manera. En la sección 2 se incluye un análisis de Componentes Principales Dinámicos (*DPCA*). En la sección 3 se muestra el algoritmo de detección mientras que en la sección 4 se describe el algoritmo de diagnóstico. La sección 5 muestra el sistema experimental basado en un Intercambiador de Calor Industrial. En la sección 6 se presentan y discuten los resultados. Finalmente, en la sección 7 se incluyen las conclusiones y áreas de oportunidad identificadas en este trabajo.

2 Análisis de Componentes Principales Dinámicos

Sea $\mathcal{X}$ un conjunto de datos compuesto de n_t observaciones de p variables que forman parte de un proceso. En éste, puede haber variables tanto de entrada como de salida. El conjunto $\mathcal{X}$ se puede describir por la matriz:

$$\tilde{X}(t) = [X_1(t) \ X_2(t) \ \dots X_p(t)]_{(n_t \times p)} \quad (1)$$

Se asume que cada serie de datos p es estacionaria, en el sentido que sus medias y desviaciones estándares permanecen casi constantes para cada intervalo de tiempo. Si el proceso tiene carácter dinámico, existirá una dependencia temporal pues el valor actual de cada variable dependerá de valores pasados. Para incluir la correlación de los datos, se debe de aumentar el espacio de la columna de la matriz X para generar un mapa estático de las relaciones dinámicas, donde el aumento w es la cantidad de retrasos a incluir.

$$X(t) = [X_1(t) \dots X_1(t-w) X_p(t) \dots X_p(t-w)]_{(n_t \times (p \cdot (w+1)))} \quad (2)$$

Al realizar *PCA* en una matriz aumentada, un modelo Auto-Regresivo se extrae directamente de los datos. Para un enfoque multi variable, las variables medidas pueden estar en diferentes rangos de valores o unidades, por lo que es conveniente estandarizar los datos alrededor de sus respectivas medias y desviaciones estándares para obtener una matriz de datos estandarizada X_S con media cero y varianza unitaria, $X_{S,ij} \triangleq (X_{ij}(t) - \mu_j)/\sigma_j$ para $i=1, \dots, n_t$ y $j=1, \dots, p \cdot (w+1)$, donde μ_j es la media del j -ésimo componente de $\tilde{X}(t)$, que se asume invariante ante translaciones de tiempo; similarmente σ_j representa la desviación estándar del j -ésimo componente de $\tilde{X}(t)$.

Al aplicar la técnica de *PCA* sobre la matriz de datos estandarizada X_S se realiza *DPCA*. Este algoritmo descompone el espacio de las variables con base en la variabilidad de éstas y las ordena de la mayor variabilidad a la menor y permite alcanzar una reducción dimensional. Al obtener los componentes principales, se tiene una transformación lineal de las variables originales a un nuevo conjunto de variables que no están correlacionadas entre ellas. Para esto, se deberá de obtener la matriz de correlación R , de la cual se obtendrán los valores λ y vectores propios, generada por $R = (X_S X_S')/(n_t - 1)$ siendo λ_i y v_i los valores y vectores propios de R , con $\lambda_i \geq 0$, debido a que R es positiva semidefinida por construcción. Con *DPCA* se descompondrá a la matriz X_S en $X_S = t_1 v_1^t + \dots + t_p v_p^t + E$ con $V^T V = I$. La matriz V es la matriz de vectores de carga. Los vectores propios que se obtienen de V , ordenados de forma decreciente gracias a la magnitud de sus valores propios, formarán ahora dos matrices: $V_{[1,k]}$ que será la transformación de componentes principales y $V_{[k+1,p]}$, la de transformación de los componentes residuales. La matriz E contiene los componentes de la varianza de la matriz X_S que no se explican con $T_K V_K^T$.

El método gráfico *SCREE* (traducción literal de la palabra pedregal al idioma inglés) permite determinar la cantidad de componentes principales a retener, como fue propuesto por [12], graficando los valores propios de la matriz de covarianza R . Los más significativos y los más pequeños, estarán separados por el punto de inflexión, el cual indica la cantidad de componentes principales k a retener.

3 Detección de Fallas

La primera tarea para el monitoreo de un proceso es la detección de una falla. Los estadísticos que representan la variabilidad en el espacio de componentes

principales y residuales son los de *Hotelling* T^2 y Squared Prediction Error, (*SPE*), también conocido como el estadístico Q .

La matriz de transformación que permite realizar la proyección al espacio con mayor variabilidad o de componentes principales es $Y = X_S V_k$. Con ésta, se podrá proyectar los datos a un espacio multivariado. Para detectar una falla, se deberá de trasladar esta información a un espacio univariable. El estadístico de Hotelling T^2 permite caracterizar el comportamiento normal de un proceso, con el propósito de realizar monitoreo en tiempo real y detección de fallas.

El parámetro estadístico de *Hotelling*, se obtiene como $T_{X_{S_i}}^2 = X_{S_i} S_k^{-1} X_{S_i}^T$, donde X_{S_i} es la i -ésima observación de la matriz X_S , mientras S_k es una matriz diagonal con los primeros k valores propios obtenidos de la matriz R .

Con esto, se puede definir un umbral de condición nominal. Un valor T^2 mayor a esta condición T_α^2 indicará un evento de fallo.

$$T_\alpha^2 = \frac{(n_t - 1)k}{n_t - k} F_\alpha(k, n_t - k) \quad (3)$$

$F_\alpha(k, n_t - k)$ es el punto crítico superior al $100\alpha\%$ de la distribución F con k y $n_t - k$ como grados de libertad. La condición de fallo será cuando $T_{X_{S_i}}^2 > T_\alpha^2$. El monitoreo con el estadístico T^2 sólo detecta cambios en las direcciones de los primeros k componentes. La variación en el espacio residual, formado por los componentes de $k+1$ a p se pueden monitorear con el estadístico Q (o *SPE*). Llámese V_r a la matriz $V_{[k+1, p]}$, entonces se obtiene $G = V_r V_r^T$. Esta matriz permite calcular el estadístico Q como $Q_{X_{S_i}} = X_{S_i} G X_{S_i}^T$.

El umbral que indicará condición de falla se calcula con

$$Q_\alpha = \theta_1 \left[\frac{h_o C_\alpha \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_o (h_o - 1)}{\theta_1^2} \right]^{\frac{1}{h_o}} \quad (4)$$

donde $\theta_i = \sum_{j=1}^p (\lambda_j)^i$, $h_o = 1 - \frac{2\theta_1 \theta_2}{3\theta_1^2}$, C_α es la desviación normal correspondiente al percentil $(1 - \alpha)$, con α nivel de confianza. Al igual que en el estadístico T^2 , si $Q_{X_{S_i}} > Q_\alpha$ se indica un evento de falla.

Aunque T^2 y Q son utilizados para monitorear los procesos, cada uno tiene una tarea específica de clasificación en un proceso [13]. T^2 mide la distancia al origen en el subespacio de los componentes principales. Éste contiene las variaciones normales de gran varianza del proceso que son comúnmente las señales, mientras el subespacio residual contiene principalmente ruido. El estadístico Q se encarga de medir la variabilidad que rompe la correlación normal del proceso, situación generada al haber un evento anormal. La región de comportamiento normal es más grande para T^2 que para Q , por esto las fallas con magnitudes de pequeñas a moderadas se pueden monitorear con el estadístico Q , mientras las fallas de gran magnitud excederán el umbral del estadístico T^2 .

4 Diagnóstico de Fallas

El algoritmo *DPCA* por si solo, no realiza diagnóstico de fallas. Para realizar esto, se propone la generación de un residuo con los componentes residuales al

ser este subespacio el que cuenta con mayor sensibilidad ante fallas. El residuo generado en el subespacio residual [14] es:

$$R_{Q_r} = X_{S_i} - X_{S_i} Q_r Q_r^T \quad (5)$$

Las tablas de contribución residual [15], son usadas para monitorear fallas en las variables presentes en la ecuación (1), ya que cuantifican la contribución de cada variable del proceso al evento en fallo. Aquellas variables que muestren una alta contribución al espacio residual son aisladas como las causantes de la falla.

$$Cont_i = \frac{R_{Q_{r_i}}^2}{\sum_{j=1}^{n_i} R_{Q_{r_j}}^2} \quad (6)$$

5 Sistema Experimental

La industria química y petroquímica, alimentaria, etc utiliza ampliamente los Intercambiadores de Calor (IC). El objetivo es transferir calor de un fluido a otro, los cuales están separados por una barrera sólida. El IC utilizado es equipo industrial compacto de tubos y coraza para calentar agua utilizando vapor. Este equipo cuenta con 11 horquillas de tubo Cu-Ni, 3/4 plg de diámetro externo BWG-20 con arreglo triangular para calentar 10 gpm de agua, elevando la temperatura de 25°C a 70°C con vapor de 5 kg/cm². La presión del vapor es de 5–6 kg/plg², con una temperatura de 140–150°C. Además cuenta con un sistema de trapeo y un sistema de separación de humedad y rompedor de vacío para línea de vapor, Figura 1 a). Integrado al cuerpo del intercambiador se encuentra la instrumentación que permite su operación, Figura 1 b). Un *FieldPoint* de *National Instruments* se utiliza para monitorear las señales. La interfase de operación esta implementada en *LabView*, desde donde se puede operar en forma manual con un tiempo de muestreo deseado.

El sistema cuenta con dos transmisores de flujo, para el vapor y el agua a la entrada, se monitorean también las temperaturas del agua a la entrada y a la salida del IC, Figura 1. Como actuadores, se tienen dos válvulas de control para el vapor y el agua de entrada. Todas las señales se activan desde 4–20mA (0–100 % en recta de calibración). Para el estudio realizado con *DPCA* se ha monitoreado al siguiente vector de medición $\mathcal{X}(t) = [TT_2, FT_1, FT_2, TT_1]$, con un retraso, $w = 1$ segundo. El IC fué operado en lazo abierto, con una temperatura de entrada del agua de 23°C, 38% de apertura en la válvula de control del agua, 70% en la válvula de control de vapor con una temperatura de salida del agua de 32°C, en promedio. El sistema se muestreo a un segundo. De los datos almacenados, el 70% fué tomado para entrenamiento mientras el restante fue usado para la identificación y validación de las fallas.

Se graficaron los valores propios de la matriz de covarianza R , obteniendo el gráfico *SCREE* que se observa en la Figura 2a. Se retendrán 4 componentes principales. La varianza total del conjunto de datos es la sumatoria de los valores propios, siendo generalmente de valor p . Tomando los primeros cuatro componentes $T_4 = \sum_{j=1}^4 \lambda_j = 3.54 + 2.2 + 1.31 + 0.8 = 7.85$, y siendo $T_8 = 8$, se mantiene un 98.13% de la variabilidad total del conjunto original.





Fig. 1. En la figura izquierda se muestra una foto del Intercambiador de Calor (IC) Industrial. A su derecha, está el diagrama de instrumentación del IC. En éste, FT_1 es el transmisor de flujo de agua de entrada, FT_2 es el de flujo de vapor, TT_1 y TT_2 son los de temperatura de entrada y salida del agua. FV_1 y FV_2 son las válvulas de control de agua y vapor de entrada.

6 Resultados

Se simularon tres tipos de fallas para probar al algoritmo *DPCA*. La primer falla fue de tipo abrupta sobre una magnitud simulando el sesgo en un instrumento electrónico. La segunda falla, también de tipo abrupta, fué de magnitud cero para emular la desconexión del sensor. La última fué una falla donde el sensor suspende su funcionamiento en el valor medio de caracterización. Las tres fallas se presentan para $t > 240$ segundos, pudiéndose apreciar en la Figura 2b. Las magnitudes para los diferentes tipos de falla en los transmisores, se encuentran en la Tabla 1.

Table 1. Parámetros estadísticos de las mediciones

Transmisor	Magnitud Media	Desviación Estandar	Varianza	Magnitud Sesgo
FT_1	64.23%	1.26	1.58	9%
FT_2	32.17%	1.00	1.00	8%
TT_1	22.72°C	0.03	0.00	0.4°C
TT_2	31.86°C	0.23	0.05	2°C

Para el estadístico T^2 se utilizó $n_t=2896$ datos y $k=4$ componentes principales, dejando los 4 restantes para el cálculo del umbral del subespacio Q . En ambos el nivel de confianza se encuentra en $\alpha=0.95$, resultando las magnitudes de 9.51 y 0.066 para los umbrales T_α^2 y Q_α , respectivamente.

Para el análisis, se utilizó al transmisor de flujo de vapor FT_2 . Como se observa en las Figuras 3a y 3b, se detectaron las fallas de tipo sesgo y desconexión




Fig. 2. La figura izquierda muestra la gráfica SCREE para la matriz de covarianza R en el IC. En la derecha, se despliegan el tipo de fallas implementadas.




Fig. 3. La figura izquierda muestra el estadístico T^2 y Q para fallas en FT_2 de tipo sesgo, mientras que a la derecha se encuentran para la falla de tipo desconexión.

en el sensor del flujo de vapor con ambos estadísticos. En el caso de la falla de tipo sesgo, Figura 3a, el estadístico T^2 se ve afectado por la variabilidad de los componentes principales, presentando oscilaciones una vez que se dispara de su valor nominal, siendo estas de magnitudes considerables. Esta característica no se presenta en el espacio Q , pues cuenta con las componentes de menor variabilidad. Por esto, se sugiere el uso del estadístico Q para el monitoreo de sesgos, con el fin de evitar falsas alarmas.

Al introducir la falla que emulaba la desconexión, Figura 3b, los estadísticos T^2 y Q presentaron un aumento considerable en la magnitud de las proyecciones generadas. Si se considerase el implementar un filtro para suavizar el cambio del residuo, se sugiere el uso del estadístico T^2 , ya que las fallas de tipo desconexión presentan menor oscilación cuando el residuo se encuentra ya estable.

La Figura 4a presenta la contribución de cada variable ante las fallas previamente simuladas. Al ser el espacio residual más sensible a las fallas, se produce




Fig. 4. En la figura izquierda se encuentra la tabla de contribución residual para fallas en FT_2 de tipo cero y gradual, a su derecha se presenta la evolución de la contribución en FT_2 a través del tiempo.

una maximización en el cálculo de la ecuación (6) para el elemento en falla. Esto se puede apreciar en la quinta y sexta columna que se asocian al residuo del elemento FT_2 , el transmisor del flujo de vapor de entrada. Aunque las magnitudes de las proyecciones de la falla tipo sesgo en T^2 y Q eran considerablemente menores a las de tipo de desconexión, se puede apreciar que las contribuciones de ambas están muy apegadas. Esto es porque al tener un espacio de p variables, la sumatoria de contribuciones, desde $i=1$ hasta p , se acota a la unidad. Esto puede resultar en tablas de contribución residual que tengan un aporte muy parecido, impidiendo la estimación de la magnitud de la falla por un método gráfico.

En la Figura 4a, se obtuvo la contribución residual una vez que se terminó la simulación. En un proceso en línea se sugiere monitorear la contribución residual en periodos establecidos, para localizar al elemento en falla. Se monitoreó el cálculo del residuo en tres tiempos: 20 segundos antes de la falla, y a los 90 y 190 segundos después de la falla.

En la Figura 4b, se puede apreciar la evolución del residuo para los tres casos mencionados. Antes de la falla, los residuos predominantes son los generados por el sensor de temperatura de salida del agua y el transmisor de flujo de vapor de entrada, debido al factor de carga de los componentes residuales. Se observa que 90 segundos después de la falla, el residuo generado por la falla en el sensor de flujo vapor aumenta, quitándole contribución al resto de las variables, especialmente al transmisor de temperatura de la salida. Pasados los 190 segundos, el residuo generado por el transmisor de flujo de vapor se estabiliza en su valor final. Al tener un proceso en condición nominal y utilizar los datos para el entrenamiento de $DPCA$, se sugiere la creación de una plantilla de contribución residual. Puesto que estará realizada con residuos de rango nominal, permitirá comparar la evolución al presentarse cualquier falla, ya sea un sesgo o de desconexión, indicando el sitio donde ocurrió. Además de las fallas de sesgo y desconexión, se emularon disfunciones donde el sensor queda en desperfecto con

una magnitud dentro de su operación nominal, aquí denominada falla de tipo medio. La falla se simuló en $t = 240$ segundos.

La Figura 5 muestra una detección ambigua con ambos estadísticos. Dentro del espacio T^2 , no se encuentra una falla hasta después de $t = 1,000$ segundos. En el espacio Q , se aprecia la presencia de una falla durante toda la simulación, incluso se tuvieron falsas alarmas previo a $t = 240$ segundos. Como se apreció en el gráfico *SCREE*, la selección de 4 componentes principales y 4 residuales permite la observación de las fallas en ambos espacios en el momento que la falla sucede, como se observa en las Figuras 3a y 3b. Este hecho permite confirmar que las fallas de tipo valor medio no son detectadas por *DPCA*, al estar de forma implícita en el entrenamiento. De la misma manera, la contribución residual arrojó resultados no óptimos al indicar falla en el sensor de temperatura del agua de entrada TT_1 cuando se simuló fallas de tipo valor medio en TT_1 , TT_2 , FT_1 y FT_2 .




Fig. 5. Estadístico T^2 y Q para la falla tipo valor medio en FT_2 .

7 Conclusiones

Se implementó el algoritmo *DPCA* para detección de fallas en los sensores de un *IC* industrial. A partir de un espacio multivariable formado por cuatro sensores, se extrajeron los componentes principales y residuales. Se monitoreó la operación en modo nominal, por medio de los estadísticos T^2 y Q , definiéndose como referencia. Se detectaron las fallas, al sobrepasar los umbrales T_α^2 y Q_α , con fallas que emulaban sesgos y desconexión en los sensores. Aprovechando la sensibilidad del espacio residual, se generaron tablas de contribución residual que permitieron identificar el sensor de falla, con lo que se dio la capacidad de diagnóstico al algoritmo *DPCA*. Se pudieron diagnosticar fallas que mantenían el valor medio de la señal, imposibles de detectar/diagnosticar via *DPCA* estándar. Se considera, a futuro, el desarrollo de una interfase, con la que se logrará obtener el modelo de referencia para detectar/diagnosticar fallas en línea e integrar un control tolerante a fallas.

References

1. S. J Bailey. From Desktop to Plant Floor, a CRT Is the Control Operators Window on the Process. *Control Eng.*, 31(6):86–90, 1984.
2. Venkat Venkatasubramanian, R Rengaswamy, K Yin, and S Kavuri. A Review of Process Fault Detection and Diagnosis. Part I. *Computers and Chemical Eng.*, (3):293–311.
3. J. Mina and C. Verde. Detección de Fallas Usando PCA. *Congreso Anual de la AMCA 2004*, 2004.
4. K.P. Detroja, R.D. Gudi, and S.C. Patwardhan. Plant-Wide Detection and Diagnosis Using CA. *Control Eng.*, 15(12):1468–1483, 2007.
5. R.H. Storer W.Ku and C. Georgakis. Disturbance Detection and Isolation by DPCA. *Chemometrics and Intelligent Laboratory Systems*, 30:179–196, 1995.
6. J. Liang Y.Liu and J. Qian. The Application of DPCA to Enhance Chunk Monitoring of an Industrial Fluidized-Bed Reactor. *Proc. of the 5th World Congress on Intelligent Control and Automation*, 2:1685–1688, 2004.
7. J. Mina and C. Verde. Fault Detection for Large Scale Systems Using DPCA. *Int. Journal of Computers, Comm. and Control*, 2(2):185–194, 2007.
8. R.Morales-Menendez, N. De Freitas, and D. Poole. State Estimation and Control of Industrial Processes using Particles Filters. *Proc. of the American Control Conference*, 1:579–584, 2003.
9. R.Morales-Menendez, N. De Freitas, and D. Poole. Real-Time Monitoring of Industrial Processes Using Particles Filters. *Proc. of the NIPS, The MIT Press*, 1:1457–1464, 2002.
10. R.A. Krishnan and N. Pappa. Real Time Fault Diagnosis for a Heat Exchange-A Model Based Approach. *IINDICON, 2005 Annual IEEE*, 11(13):78–82, 2005.
11. S. Kumar, E.B. Martin, and J. Morris. Detection of Process Model Changes in PCA Based Performance Monitoring. *Proc. of the American Control Conference*, 4:2719–2724, 2002.
12. R.B. Cattell. The SCREE Test for the Number of Factors. *Multivariate Behavioral Research*, 1:245–276, 1966.
13. S.J. Qin. Statistical Process Monitoring: Basics and Beyond. *Journal of Chemometrics*, 17:480–502, 2003.
14. R Isermann. *Fault Diagnosis Systems*. Springer, Landgraf-Georg-Strasse 4 64283 Darmstadt Germany, 1 edition, 2005.
15. P. Miller, R. Swanson, and C. Heckler. Contribution Plots: A Missing Link in Multivariate Quality Control. *Appl. Math. and Comp.*, 8(4):775–792, 1998.