



RESUMEN DE TESIS:

Diagnóstico de fallos en procesos industriales empleando técnicas de aprendizaje basadas en métodos kernel*.

DOCTORANTE: José M. Bernal-de-Lázaro^{1,2}

¹ Centro de Referencia para la Educación Avanzada (CREA), Cujae, Habana, Cuba.

² Departamento de Automática y Computación, Cujae, Habana, Cuba.

jbernal@crea.cujae.edu.cu

Resumen: Este artículo resume las contribuciones principales de la tesis de doctorado con título: “*Application of learning techniques based on kernel methods for the fault diagnosis in industrial processes*”. Esta tesis se centra en el análisis y diseño de sistemas de diagnóstico de fallos (DDF) basados en datos históricos. Específicamente esta tesis ofrece: (1) nuevos criterios para el ajuste de los métodos kernel que se emplean en la selección de características con alto poder discriminante para el diagnóstico de fallos, (2) una propuesta de enfoque de monitorización de procesos mediante técnicas de estadística multivariada que incorpora información reforzada sobre la dinámica de los estadísticos T^2 de Hotelling y SPE, cuya combinación con métodos kernel mejora la detección de fallos de pequeña magnitud; (3) un índice de robustez para comparar el desempeño de herramientas de clasificación teniendo en cuenta su insensibilidad ante posibles ruidos y/o perturbaciones en los datos históricos.

Palabras Clave: Diagnóstico de fallos, Métodos kernel, Robustez, Metaheurísticas.

1. Introducción

La importancia del diagnóstico de fallos en las industrias modernas es cada vez mayor [1–3]. La demanda de productos de calidad y la necesidad de mantener los procesos en un estado de funcionamiento seguro ha estimulado intensamente el desarrollo de métodos de diagnóstico de fallos [4]. En este mismo contexto, el propio aumento en tamaño y complejidad de la industria actual ha incrementado la necesidad de disponer de potentes sistemas de supervisión y monitorización, los cuales por demás, requieren ser robustos ante las perturbaciones y los ruidos externos sin que ello implique perder sensibilidad ante fallos de pequeña magnitud [5, 6]. Una solución viable para cumplir lo anterior, fundamentalmente en industrias complejas como por ejemplo, la industria siderúrgica, petroquímica y biofarmacéutica, es el uso de la información contenida en las grandes bases de datos históricos que son recopilados por los sistemas de Supervisión, Control y Adquisición de Datos [7]. El procesamiento y análisis de esta información por medio de herramientas de clasificación y métodos kernel ha demostrado ser una alternativa factible, que puede facilitar las tareas de diagnóstico aportando fiabilidad y robustez a los sistemas de supervisión [5, 8, 9].

*Dirigida por el Ph.D Orestes Llanes-Santiago y el Ph.D Alberto Prieto-Moreno del Departamento de Automática y Computación de la Cujae, Habana, Cuba; y el Ph.D Antônio José da Silva-Neto del Departamento de Ingeniería Mecánica y Energía, Instituto Politécnico IPRJ-UERJ, RJ, Brasil

A partir de lo anterior, esta tesis explora el uso de técnicas de aprendizaje basadas en métodos kernel para alcanzar mejores desempeños para el diagnóstico de fallos en procesos industriales. En particular, se desarrollan varias propuestas dirigidas al ajuste de las herramientas de pre-procesamiento kernel: Análisis de Componentes Independientes (KICA), Análisis Discriminante de Fisher (KFDA) y Análisis de Componentes Principales (KPCA); las cuales, en combinación con otras técnicas de la Inteligencia Computacional y Reconocimiento de Patrones, se utilizan para mejorar el desempeño de los sistemas de diagnóstico (DDF) basados en datos [7, 10]. La primera propuesta que se realiza en la tesis está orientada a mejorar la detección de fallos pequeños y/o de lento desarrollo mediante un enfoque kernel-MEWMA con dinámica reforzada, y una mejor interpretación de la tasas de falsas alarmas y tasas de fallos detectados que se combinan en único indicador de desempeño [5]. En esta primera propuesta se realiza además un empleo riguroso de los algoritmos de optimización: Evolución Diferencial (DE), y el Optimización de Enjambre de Partículas (PSO).

La segunda propuesta se enfoca en establecer las pautas y criterios que permiten una configuración adecuada de los parámetros kernel, para la extracción de características de alto poder discriminante con el objetivo de facilitar los procesos de aislamiento e identificación de fallos [8]. Finalmente, esta tesis propone un índice de robustez que permite comparar diferentes clasificadores teniendo en cuenta el nivel de rechazo a ruidos y perturbaciones. El índice de rechazo por nivel propuesto garantiza que el clasificador seleccionado es aquel que con mayor probabilidad será insensible al ruido presente en los datos, y por tanto, el más adecuado para las tareas de diagnóstico de fallos.

2. Particularidades de los sistemas industriales y su diagnóstico

Para procesos industriales muy complejos, el obtener modelos analíticos, o particularizar modelos generales existentes puede requerir gran cantidad de tiempo y esfuerzo [3]. Por ello, utilizar la información histórica del proceso resulta una alternativa viable para llevar a cabo las tareas de detección y aislamiento de fallos [2, 11]. En este contexto, las investigaciones y publicaciones actuales muestran que la comunidad científica dedicada a estos temas, se encuentra centrada en tres cuestiones primordiales para los sistemas DDF, estas son: robustez, sensibilidad, y rendimiento [12, 13]. Dado el entorno industrial donde se aplican, es bien conocido que la presencia de perturbaciones y ruidos puede afectar significativamente el rendimiento de los sistemas de diagnóstico [6]. Esto implica que tales sistemas deben ser robustos ante ruidos e incertidumbres sin perder sensibilidad en el diagnóstico de los fallos, fundamentalmente ante fallos de pequeña magnitud que pueden ser enmascarados por perturbaciones.

Desatender estas características puede incidir negativamente en el desempeño de los sistemas de DDF [6]. Como consecuencia de ello, por ejemplo, pueden generarse numerosas falsas alarmas que estimulan a que los operadores, con el tiempo, ignoren los mensajes del sistema de diagnóstico, llegando incluso a desconectar alguna protección o alarma que se activa continuamente. Por otra parte, también cabe la posibilidad de no detectar fallos importantes en el proceso, lo cual pudiera tener consecuencias catastróficas. En este sentido, un adecuado balance entre robustez y sensibilidad, unido a una rápida detección en línea, constituyen sin duda, la clave del éxito para garantizar el alto rendimiento de los sistemas de diagnóstico de fallos empleados en los procesos industriales.

2.1. Objetivo general e hipótesis preliminar

El objetivo de esta tesis es proponer nuevas estrategias de trabajo que, a partir del uso de métodos kernel y herramientas de clasificación enfocadas en la extracción de información útil contenida en los grandes volúmenes de datos históricos generados por los procesos industriales, permitan obtener sistemas de diagnóstico más robustos y sensibles a la ocurrencia de fallos de pequeña magnitud.

A partir de lo anterior, como hipótesis preliminar se plantea que si se tiene un proceso o sistema tecnológico caracterizado por su ergodicidad y presentar patrones, en forma de señales, que describen todos los estados de funcionamiento normal y fallos; entonces, el empleo de métodos kernel y herramientas de clasificación, enfocadas en la extracción de información y conocimiento, permitirá obtener sistemas de diagnóstico con mejores índices de desempeño, que sean sensibles a la ocurrencia de fallos de pequeña magnitud y robustos ante ruidos y/o perturbaciones.

3. Organización de la tesis y contribuciones al estado del arte

Las contribuciones de esta tesis están dirigidas a realizar mejoras en la etapa de diseño de los sistemas DDF, a partir de proponer nuevas estrategias de trabajo permitan obtener sistemas de diagnóstico más completos. Bajo este principio, la tesis que en el presente trabajo se resume está estructurada en cuatro capítulos.

3.1. Capítulo 1: Revisión Bibliográfica y casos de estudio

El propósito del Capítulo 1 es analizar los antecedentes que existen en la literatura científico-técnica sobre el problema de diagnóstico de fallos con datos históricos, así como su combinación con métodos analíticos, y enfoques basados en conocimiento. Para ello, se resumen los trabajos que se han realizado con anterioridad en esta temática mostrando la motivación para trabajar en el diseño de sistemas de diagnóstico más robustos y eficientes. Se resumen además, las principales herramientas kernel utilizadas en las tareas de diagnóstico de fallos, y los problemas que respecto a su aplicación práctica, constituyen líneas abiertas a investigación. Por último, se presentan los casos de estudio que se emplean para probar las propuestas de esta tesis, que son el Tennessee Eastman Process (TEP) y el Tanque Reactor Isotérmico Continuamente Agitado (CSTR). Este primer capítulo, muestra que a pesar de la gran cantidad de estudios realizados en el área del diagnóstico de procesos, no existe un método universal con el cual sea posible enfrentar cualquier problema de diagnóstico de fallos. De ahí que la tendencia de las investigaciones actuales este dirigida a integrar diferentes herramientas para brindar soluciones complementarias, y mejorar el desempeño de los sistemas de diagnóstico de fallos.

A partir de consideraciones prácticas, el Capítulo 1 de esta tesis muestra que para sistemas industriales, resulta conveniente potenciar aquellas técnicas y enfoques que permiten obtener sistemas de diagnóstico sensibles a fallos de pequeña magnitud, pero robustos ante ruidos e incertidumbres. La revisión realizada sugiere, además, que los sistemas de diagnóstico deben tener al menos tres componentes fundamentales. En primer lugar, un método basado en datos históricos y análisis de tendencias para detectar de manera rápida cualquier posible cambio en el proceso. Esta característica resulta crucial en sistemas industriales complejos donde fallos de pequeña magnitud y/o lento desarrollo suelen ser enmascarados por la ocurrencia de otros fenómenos en el proceso. Como segundo aspecto, debe considerarse un método que permita la selección de atributos relevantes para reconocer las características que identifican a cada uno de los estados de operación. Como tercer aspecto es recomendable que los sistemas de diagnóstico de fallos tengan en cuenta el uso de herramientas discriminantes que permitan el aislamiento de los fallos, y de ser posible, incorporen simultáneamente algún método basado en conocimiento para proporcionar explicaciones y razonamientos causa-efecto a los operadores, a fin de asistirlos en la toma de decisiones asociadas a las tareas de diagnóstico y mantenimiento en el proceso.

En este contexto, son numerosas las publicaciones que recientemente incorporan los enfoques kernel en cada una de las etapas anteriores. Sin embargo es una realidad que, para tales herramientas, aún persisten problemas por resolver que limitan su aplicabilidad. En el caso particular del diagnóstico de fallos, en el Capítulo 1 de esta tesis, se destaca que:

1. Pocas funciones kernel han sido exploradas.
2. No están definidos cuáles son los criterios o indicadores que permiten un mejor ajuste de la función kernel.
3. No existe un estudio que relacione la naturaleza de los fallos con el desempeño de determinadas funciones kernel y por tanto, permita determinar cuál de ellas es la más adecuada para realizar las tareas de diagnóstico.

La tesis analizada en el presente trabajo, se enfoca fundamentalmente en brindar soluciones alternativas a los dos primeros problemas. Es importante señalar que dada la extensión de la literatura en este campo de investigación, es difícil incluir todos los aspectos relacionados con el diagnóstico de fallos. Sin embargo, la información referenciada en el primer capítulo de esta tesis, brinda a los lectores una introducción a estudios más avanzados en el tema de diagnóstico de fallos basado en métodos kernel, y resume además, el estado del arte en esta área de investigación durante los últimos cinco años.

3.2. Capítulo 2: Métodos kernel para detectar fallos de pequeña magnitud

En este capítulo de la tesis se presentan dos contribuciones que están dirigidas a mejorar el diseño de un sistema de diagnóstico. La primera propuesta es un procedimiento para la detección de fallos de pequeña magnitud basado en un enfoque de kernel-MEWMA con dinámica reforzada. El esquema básico de esta nueva contribución se muestra en el esquema de la Figura 1.

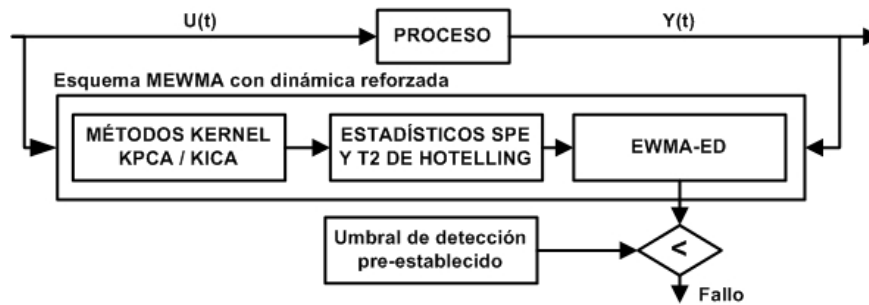


Figura 1: Esquema de detección vía kernel-MEWMA con dinámica reforzada.

El mecanismo de detección anterior combina las ventajas de los métodos kernel y el enfoque EWMA con dinámica reforzada propuesto por el autor para filtrar los estadísticos SPE y T^2 de Hotelling. En este caso, los métodos kernel utilizados fueron KICA y KPCA, aunque otros algoritmos kernel también podrían ser considerados. Es importante señalar que KICA y KPCA se aplican de manera independiente, sin embargo, en ambos casos se logra mejorar la separabilidad lineal de los patrones a partir de eliminar información redundante en los datos, lo cual facilita la detección de fallos con SPE y T^2 de Hotelling. En tanto, el uso posterior del enfoque EWMA-ED disminuye el efecto que la variabilidad en estos estadísticos, y hace más rápida la detección de los fallos. En el Capítulo 2 de la tesis que se resume en el presente trabajo, se demuestra que en comparación con el filtrado convencional empleando Medias Móviles Ponderadas Exponencialmente (EWMA), la propuesta de EWMA-ED reduce la diferencia de los pesos en cada muestreo, y aumenta simultáneamente el aporte dinámico de las estimativas anteriores. Como resultado, en el enfoque EWMA-ED la profundidad de memoria es expandida, y la influencia del valor actual sigue siendo notable, lo que permite detectar rápidamente cualquier cambio brusco en la dinámica del proceso sin perder sensibilidad a cambios de pequeña magnitud. Para evaluar estas potencialidades el enfoque kernel-MEWMA con dinámica reforzada fue aplicado en el problema de prueba TEP, mostrando una alta capacidad para detectar, con pocas falsas alarmas y bajos tiempos de latencia, todos los fallos considerados, independientemente de su naturaleza o magnitud. En comparación con otros enfoques kernel previamente reportados en la literatura de diagnóstico de fallos [14–17], esta propuesta demostró que es posible mejorar el desempeño del sistema de detección ante fallos de pequeña magnitud al considerar la dinámica anterior del proceso, y realizar un ajuste adecuado de las herramientas involucradas.

La segunda contribución al estado del arte que se realiza en este capítulo, consiste en representar la información obtenida del proceso de detección de fallos en un único indicador de calidad, y emplear esta filosofía para ajustar las técnicas kernel de pre-procesamiento que se emplean en la etapa de detección de fallos. En este caso, la nueva contribución parte del principio de que existe un alto nivel de subjetividad en la interpretación de la Tasa de Falsas Alarmas (FAR, *False Alarm Rate*) [18], y la Tasa de Detección de Fallos (FDR, *Fault Detection Rate*) [18], como indicadores para evaluar los procedimientos de detección de fallos. Por ejemplo, considérese dos mecanismos de detección de fallos diferentes, con $FAR_1 = 5\%$, $FDR_1 = 87\%$ y $FAR_2 = 12\%$, $FDR_2 = 92\%$, respectivamente. ¿Cuál de ellos resulta más conveniente para implementar en los procedimientos de detección de fallos, si en realidad, se necesita obtener de manera simultánea bajos valores de FAR y altos valores de FDR? Al no existir un único valor numérico que cuantifique el desempeño del sistema, resulta difícil comparar dos mecanismos de detección, salvo que sus diferencias sean obviamente notables.

Como alternativa de solución a este problema, en el presente capítulo se propuso unificar la información de los indicadores FAR y FDR, usando el Área bajo la curva ROC (AUC, *Area Under a Receiver Operating Characteristic Curve*) [19]. Para ello, se considera la detección de fallos como un proceso de clasificación con dos clases (fallo/no fallo), lo que permite obtener la llamada Matriz de Confusión C_{ij} [19], y representar la relación FAR *vs.* FDR en términos de probabilidad mediante la curva ROC. La idea detrás de esta representación es muy simple, y se basa en maximizar la separabilidad entre las clases (fallo/no fallo) para mejorar simultáneamente los valores de FAR y FDR. A partir de lo anterior, en este capítulo se propuso emplear la función objetivo formulada en (1) para ajustar los parámetros del kernel RBF que es empleado por KICA y KPCA durante el pre-procesamiento de los datos.

$$f(\mathbf{X}) = 1 - \frac{1}{c} \sum_{i=1}^c \text{AUC}^i \quad (1)$$

Nótese que en (1), el parámetro c corresponde al número de clases diferentes a la condición normal de operación (NOC) para el proceso. Como resultado, este criterio logra minimizar el error de clasificación entre (NOC, AOC^i), donde AOC^i identifica cada uno de los estados de operación anormal siendo $i = \{1, 2, \dots, c\}$. Para lograr un alto desempeño en la detección de fallos, cada proceso de clasificación binario debe cumplir que $\text{AUC} \approx 1$. En otras palabras, al maximizar la medida AUC en el proceso de detección de cada fallo, se logra minimizar el error de clasificación global de la etapa de detección de fallos.

Como parte del trabajo realizado en este capítulo, se derivaron las publicaciones [20] y [5].

3.3. Capítulo 3: Configuración de métodos kernel enfocados al diagnóstico de procesos.

El propósito del Capítulo 3 es presentar un procedimiento para configurar los métodos kernel empleados como herramientas de pre-procesamiento en el aislamiento de los fallos. Para ello, se utilizaron los métodos KPCA y KFDA, así como los kernel RBF y Wavelet cuyos parámetros se estiman usando criterios de desempeño que brindan una interpretación geométrica relacionada directamente con la función kernel empleada. El aislamiento de los fallos, se llevó a cabo mediante un clasificador basado en Redes Neuronal Artificiales (ANN) que fue evaluado en el proceso de prueba TEP.

Entre las medidas empleadas (ver Tabla 1): Alfa, Beta y Gamma, son criterios cuya aplicación para el ajuste de técnicas de pre-procesamiento kernel en el diagnóstico de fallos, constituye un nuevo aporte al estado del arte propuesto recientemente en [8]. El uso de estas medidas, permite desacoplar la selección de los parámetros kernel del ajuste de otros procedimientos involucrados en las tareas de diagnóstico. De esta manera, una función kernel puede ser combinada con diferentes herramientas de clasificación, agrupamiento o regresión, sin que por ello sea necesario reajustar sus parámetros.

Como parte del trabajo realizado en este capítulo, se derivaron las publicaciones [8] y [7].

3.4. Capítulo 4: Índice de robustez para evaluar diagnósticos

El objetivo de este capítulo es estudiar los enfoques de diagnóstico de fallos, con énfasis en su robustez y aplicación en ambientes industriales ruidosos. La principal contribución al estado del arte realizada en este capítulo es un índice que permite evaluar el desempeño global de un diagnosticador en términos de su robustez. El índice propuesto complementa el error de clasificación mediante un factor de penalización que refleja la capacidad de rechazo al ruido por parte del diagnosticador, considerando que la variabilidad adicionada por el ruido, no excede de $\pm 3\sigma$ respecto al comportamiento habitual de las variables. A fin de ejemplificar la utilidad del índice propuesto, en este capítulo se compara el desempeño de tres clasificadores: Árboles de Decisión (AD), Redes Neuronales Artificiales (ANN), y Máquinas de Soporte Vectorial (SVM), aplicados todos al diagnóstico de fallos en el proceso de prueba CSTR.

Tabla 1: Criterios empleados para optimización por relación directa.

| Medida de ajuste | Formulación básica | Referencias |
|--------------------|--|-------------|
| Alineación (KTA) | $A(\mathbf{K}_1, \mathbf{K}_2) = \frac{\langle \mathbf{K}_1, \mathbf{K}_2 \rangle_F}{\sqrt{\langle \mathbf{K}_1, \mathbf{K}_1 \rangle_F \langle \mathbf{K}_2, \mathbf{K}_2 \rangle_F}}$ | [21, 22] |
| Fisher | $J = \frac{tr(\mathbf{S}_B)}{tr(\mathbf{S}_W)}$ | [23, 24] |
| Alfa (α) | $\alpha(\mathbf{K}, \mathbf{y}) = \frac{\sum_{i=1}^n \sum_{j=i+1}^n (\mathbf{K}_{ij} - \bar{\mathbf{K}})(\mathbf{S}_{ij} - \bar{\mathbf{S}})}{\sqrt{\sum_{i=1}^n \sum_{j=i+1}^n (\mathbf{K}_{ij} - \bar{\mathbf{K}})^2 \sum_{i=1}^n \sum_{j=i+1}^n (\mathbf{S}_{ij} - \bar{\mathbf{S}})^2}}$ | [8, 23] |
| Beta (β) | $\beta(\mathbf{K}, \mathbf{y}) = \left \frac{\bar{k}_w - \bar{k}_b}{\sqrt{\frac{\sigma_w^2}{n_w} + \frac{\sigma_b^2}{n_b}}} \right $ | [8, 23] |
| Gamma (γ) | $\gamma(\mathbf{K}, \mathbf{y}) = (n - 2) \frac{n_w(\bar{\mathbf{Z}}_w - \bar{\mathbf{Z}}_{wb})^2 + n_b(\bar{\mathbf{Z}}_b - \bar{\mathbf{Z}}_{wb})^2}{\sum_{i=1}^{n_w} (\bar{\mathbf{Z}}_i - \bar{\mathbf{Z}}_w)^2 + \sum_{i=1}^{n_b} (\bar{\mathbf{Z}}_i - \bar{\mathbf{Z}}_b)^2}$ | [8, 23] |

La ventaja del índice propuesto, respecto a otros análisis de robustez local, radica en la capacidad de decisión que a partir de un único valor numérico brinda este indicador. Al utilizar el índice de robustez J_{RIL} no sólo se reduce el número de análisis comparativos a realizar, sino que además, se evita considerar cualquier criterio subjetivo en la selección de las herramientas de clasificación más adecuadas. Debe señalarse que, en el presente capítulo, el índice de robustez fue empleado para evaluar herramientas de diagnóstico basadas en datos. Sin embargo, en principio, este indicador puede ser empleado para evaluar el desempeño de cualquier sistema de diagnóstico, incluidos aquellos que utilizan enfoques basados en modelos.

4. Conclusiones

Este trabajo aborda el tema del diseño de sistemas de diagnóstico utilizando métodos kernel y técnicas de clasificación para mejorar el desempeño de los mismos. Para esto se propuso emplear un enfoque kernel-MEWMA con dinámica reforzada, que a partir de aplicar técnicas de pre-procesamiento kernel y un enfoque EWMA con dinámica mejorada, permite obtener altos rendimientos con pocas falsas alarmas y bajos tiempos de latencia. En este contexto, además, fue posible representar las medidas FAR y FDR en función de un único indicador de desempeño, relacionado con la capacidad para distinguir entre los estados de operación normal y anormal que tiene el sistema de detección. Este indicador facilita la interpretabilidad de los resultados y además, puede ser empleado como criterio para ajustar los métodos kernel. La segunda propuesta estuvo dirigida a la selección adecuada de los parámetros kernel, donde se propuso un procedimiento que posibilita fijar pautas de diseño que pueden contribuir a obtener mejores prestaciones en los sistemas de diagnóstico basados en datos históricos. En la tercera propuesta se analizó la influencia negativa del ruido y la necesidad de contar con sistemas de diagnóstico que sean

robustos ante ruidos y/o perturbaciones, manteniendo un rendimiento satisfactorio. En este sentido, se formalizó un índice que permite valorar la robustez de un clasificador de diagnóstico y que, combinado con un análisis gráfico de su deterioro, puede ser empleado para identificar posibles alternativas de hibridación entre clasificadores para obtener desempeños superiores en términos de robustez. La ventaja del índice propuesto, radica en la capacidad de decisión que a partir de un único valor numérico brinda este indicador.

Con base en estos resultados, es posible afirmar que los objetivos trazados para la investigación fueron cumplidos; lográndose aportes al diseño de los sistemas de diagnóstico en tres aspectos: el pre-procesamiento de la información contenida en los datos históricos, la configuración de esquemas de clasificación destinados al diagnóstico de fallos, y el análisis de la robustez de las herramientas de clasificación involucradas con las tareas aislamiento e identificación de fallos.

5. Trabajos futuros

Como continuidad de la investigación presentada se considera: (1) evaluar la aplicabilidad del enfoque kernel-MEWMA en procesos por lotes, y (2) extender la aplicación del índice de robustez a sistemas de diagnóstico basados en modelos.

Agradecimientos

Los autores agradecen el apoyo ofrecido por FAPERJ, Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro, CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico, CAPES, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, de Brazil, y CUJAE, Instituto Superior Politécnico José A. Echeverría de Cuba.

Referencias

- [1] L. H Chiang, R. D Braatz, and E. L Russell. *Fault detection and diagnosis in industrial systems*. Springer, 2001.
- [2] Z Ge, C. Song, and G. Furong. Review of recent research on data-based process monitoring. *Industrial and Eng. Chemistry Research*, 52(10):3543–3562, 2013.
- [3] V. Venkatasubramanian, R. Rengaswamy, K. Yin, and S. N. Kavuri. A review of process fault detection and diagnosis: Part I: Quantitative model-based methods. *Computers and Chemical Engineering*, 27(3):293–311, 2003.
- [4] Y. Zhang and J. Jiang. Bibliographical review on reconfigurable fault-tolerant control systems. *Annual Reviews in Control*, 32(2):229–252, 2008.
- [5] J.M. Bernal-de Lázaro, A. Prieto-Moreno, O. Llanes-Santiago, D. Knupp-Campos, and A.J. Silva-Neto. Enhanced dynamic approach to improve the detection of small-magnitude faults. *Chemical Engineering Science*, 146:166–179, 2016.
- [6] R. J Patton and J. Chen. *Robust model-based fault diagnosis for dynamic systems*. Kluwer Academic Publishers, London, 1999.
- [7] J.M. Bernal-Lázaro, O. Llanes-Santiago, A. Prieto-Moreno, A. Ríos-Bolívar, and E. García-Moreno. Una propuesta de pre-procesamiento basada en kernels para el diagnóstico de fallos en procesos industriales. *XVI Congreso Latino-Americano de Control Automático, (CLCA)*, pages 594–599, Octubre 2014. , Cancún, México.
- [8] J.M Bernal-de Lázaro, A Prieto-Moreno, O Llanes-Santiago, and A.J. Silva-Neto. Optimizing kernel methods to reduce dimensionality in fault diagnosis of industrial systems. *Computers and Industrial Eng.*, 87:140–149, 2015.

- [9] Y. Motai. Kernel association for classification and prediction: A survey. *IEEE Transactions on Neural Networks and Learning Systems*, 26(2):208–223, 2015.
- [10] A. Prieto-Moreno, O. Llanes-Santiago, J. M. Bernal-de Lázaro, and E. Garcia-Moreno. Comparative evaluation of classification methods used in fault diagnosis of industrial processes. *IEEE Latin America Transactions*, 11(2):682–689, 2013.
- [11] V. Venkatasubramanian, R. Rengaswamy, S. N Kavuri, and K. Yin. A review of process fault detection and diagnosis: Part III: Process history based methods. *Computers and Chemical Engineering*, 27(3):327–346, 2003.
- [12] A. Das, J. Maiti, and RN. Banerjee. Process monitoring and fault detection strategies: A review. *International Journal of Quality and Reliability Management*, 29(7):720–752, 2012.
- [13] S. J. Qin. Survey on data-driven industrial process monitoring and diagnosis. *Annual Reviews in Control*, 36(2):220–234, 2012.
- [14] J. Fan and Y. Wang. Fault detection and diagnosis of non-linear non-gaussian dynamic processes using kernel dynamic independent component analysis. *Information Sciences*, 259(20):369–379, 2014.
- [15] N. Li and Y. Yang. Ensemble kernel principal component analysis for improved nonlinear process monitoring. *Industrial and Eng. Chemistry Research*, 54:318–329, 2014.
- [16] J. Lee, S. J. Qin, and L. In-Beum. Fault detection of non-linear processes using kernel independent component analysis. *The Canadian Journal of Chemical Engineering.*, 85(4):526–536, 2007.
- [17] Y. Zhang. Enhanced statistical analysis of nonlinear processes using KPCA, KICA and SVM. *Chemical Eng. Science*, 64(5):801– 811, 2009.
- [18] S. Yin, S. X Ding, A. Haghani, H Hao, and P. Zhang. A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark Tennessee Eastman process. *Journal of Process Control*, 22(9):1567–1581, 2012.
- [19] T. Fawcett. An introduction to roc analysis. *Pattern Recognition Letters*, 27(8):861–874, 2006.
- [20] J.M. Bernal-de Lázaro, A. Prieto-Moreno, O. Llanes-Santiago, and D. Knupp-Campos. An indirect kernel optimization approach to fault detection with kpca. In *Mathematical Modeling and Computational Intelligence in Engineering Applications*, pages 63–75. Springer, 2016.
- [21] N. Cristianini, J. Shawe-Taylor, A. Elisseeff, and J. Kandola. On kernel target alignment. In *NIPS*, volume 2, page 4, 2001.
- [22] C. H. Nguyen and T. B. Ho. An efficient kernel matrix evaluation measure. *Pattern Recognition*, 41(11):3366–3372, 2008.
- [23] P. Chudzian. Evaluation measures for kernel optimization. *Pattern Recognition Letters*, 33(9):1108–1116, 2012.
- [24] H. Xiong, M. N. S. Swamy, and M. O. Ahmad. Optimizing the kernel in the empirical feature space. *IEEE Transactions on Neural Networks*, 16(2):460–474, 2005.