



Diagnóstico de fallos mediante clasificadores: Análisis de robustez en ambientes de incertidumbre

JM. Bernal-de Lázaro

Dept. de Automática y Computación
Universidad Tecnológica de La Habana,
Habana, Cuba
jbernal@automatica.cujae.edu.cu

O. Llanes-Santiago

Dept. de Automática y Computación
Universidad Tecnológica de La Habana,
Habana, Cuba
orestes@tesla.cujae.edu.cu

A. Prieto-Moreno

Dept. de Automática y Computación
Universidad Tecnológica de La Habana,
Habana, Cuba
albprieto@automatica.cujae.edu.cu

A. Silva-Neto

Dept. de Ingeniería Mecánica
Instituto Politécnico do Rio de Janeiro
Rio de Janeiro, Brasil
ajsneto@iprj.uerj.br

C. Cruz Corona

Dept. de Ciencia de la Computación
Universidad de Granada
Granada, España
carloscruz@decsai.ugr.es

Resumen—La presencia de ruidos e interferencias es un fenómeno común en los procesos de transmisión y procesamiento de datos que se producen en ambientes industriales. Teóricamente, en ausencia de ruidos e interferencias, la información implícita en los datos transmitidos puede ser mejor aprovechada. Sin embargo, la realidad es que el ruido resulta intrínseco a los sistemas eléctricos y entornos industriales, por lo que es recomendable considerar su efecto al trabajar con la información de los sensores en el proceso. En este contexto, el problema de la robustez para sistemas de diagnóstico de fallos puede ser definido como la capacidad de maximizar la detectabilidad y aislabilidad de los fallos, al mismo tiempo que se minimiza el efecto de perturbaciones, ruidos y cambios en los estados del sistema. El objetivo de este trabajo es estudiar los enfoques de diagnóstico de fallos, con énfasis en su robustez y aplicación en ambientes industriales ruidosos. Para ello, se propone un índice que permite evaluar el desempeño global de un diagnosticador en términos de su robustez durante su etapa de diseño. 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. Para ejemplificar la utilidad del índice propuesto, se compara el desempeño de tres clasificadores: Árboles de Decisión (AD-ID3), Redes Neuronales Artificiales (RNA) y Máquinas de Soporte Vectorial (MSV), aplicados todos al diagnóstico de fallos en el Tanque Reactor Continuamente Agitado (CSTR).

Index Terms—Diagnóstico de fallos; Clasificación; Robustez

I. INTRODUCCIÓN

Durante los últimos 30 años, el diagnóstico de fallos (DF) como área de investigación, ha recibido una considerable atención [1], [2], [4], [5]. Estas publicaciones se centran en tres cuestiones primordiales dentro del diseño de los sistemas de diagnóstico de fallos, estas son: robustez, sensibilidad y rendimiento. De acuerdo con la definición dada por [9] y [10], el problema de la robustez en el diagnóstico de fallos puede entenderse como la capacidad de maximizar la detectabilidad y aislabilidad de los fallos, al mismo tiempo que se minimiza el efecto de perturbaciones, ruidos y cambios en las entradas/salidas, o estados del sistema. A partir de esta definición,

se han desarrollado numerosos estudios relacionados con el análisis de la robustez en sistemas de diagnóstico que utilizan modelos matemáticos puros. Sin embargo, muy pocos estudios han investigado el impacto del ruido en los sistemas de diagnóstico basados en datos históricos. En este contexto, el tema de la robustez ha sido abordado mayormente desde el punto de vista de la insensibilidad del sistema de diagnóstico a datos fuera de rango (*outliers*), datos ausentes (*missing data*), y valores muy puntuales de ruido. Aunque se han hecho progresos considerables en este sentido, un problema persistente en el campo del diagnóstico de fallos basado en datos es que los estudios comparativos entre clasificadores no consideran el efecto del ruido o simplemente realizan un análisis de robustez local simulando valores constantes para el ruido en los datos. Por lo general, estas comparaciones se enfocan en una zona de trabajo donde se asume niveles ruido muy bajos que se consideran invariantes. En los procesos reales, sin embargo, es posible que la conexión/desconexión de equipos y diferentes fuentes de ruido externas modifiquen los datos obtenidos del proceso, introduciéndoles mayor variabilidad. Se requiere, por tanto, de un indicador que cuantifique el desempeño del sistema de diagnóstico en términos de insensibilidad ante este cambio y permita comparar el desempeño de diferentes herramientas de clasificación empleadas en las tareas de diagnóstico de fallos. Una alternativa a este problema es el indicador de robustez aquí propuesto.

Para ello, la estructura de este trabajo es la siguiente. En la Sección 2 se discuten las consideraciones generales para el análisis de la robustez en sistemas de diagnóstico basados en datos. En la Sección 3 se realiza la propuesta de indicador de robustez, y se exponen sus aplicaciones potenciales. La aplicación del índice de robustez propuesto en el proceso de prueba Tanque Reactor Continuamente Agitado (CSTR) y el estudio comparativo de los clasificadores se realiza en la Sección 4. Por último, se emiten las conclusiones del trabajo.

II. CONSIDERACIONES GENERALES

En el control de un proceso, una interferencia puede ser considerada como un tipo de perturbación externa generada por acoplamiento eléctrico y magnético (motores, equipos de alta potencia, etc), o debido a fenómenos naturales (tormentas, etc). Dado su origen conocido, el efecto de una interferencia periódica, intermitente, o aleatoria, puede ser minimizado por la sustitución de acoplamiento eléctrico y electromagnético; acciones que deben ir acompañadas además, del uso de conexiones apantalladas y protecciones eléctricas en las líneas de transmisión. Por otro lado, la contaminación de señales debido al ruido es un concepto más general al considerar cualquier efecto aleatorio e impredecible (con acción temporal o constante), que distorsiona una señal original que es medida, transmitida y procesada. El incremento en la variabilidad de los datos transmitidos suele ser, por lo general, uno de los efectos más notables en las señales ruidosas. Cuando variabilidad incorporada por el ruido adiciona incertidumbre a la información contenida en una señal, es posible que la información original sea parcialmente enmascarada, modificada o imposible de identificar.

Un ruido puede afectar significativamente el desempeño de un diagnosticador incorporando variabilidad adicional en los datos, lo cual modifica negativamente las fronteras de decisión del clasificador [11]. Este fenómeno es fácil de entender si consideramos al clasificador como un algoritmo o función matemática que divide el espacio de características (síntomas), en tantas regiones como clases (fallos) existen [7]. Por ejemplo, considérese un espacio de características consistente en dos clases mutuamente excluyentes. La tarea del clasificador de diagnóstico es asignar una etiqueta de clase \hat{y}_i a una nueva observación $x_i = \{\nu_1, \dots, \nu_d\}$, dado $\hat{y}_i = f(x_i)$ con una etiqueta de clase predicha $\hat{y}_i \in \{c_1, c_2\}$ y ν_j variables medidas. El efecto del ruido en las mediciones puede hacer aparentemente similar el comportamiento de dos clases distintas, resultando en una mayor probabilidad de confundir los patrones de fallos diferentes.

Bajo esta filosofía, se pueden considerar varios escenarios cuando existe un aumento en la variabilidad de los datos. Una posible situación a considerar sería tener un diagnosticador robusto que mantiene un bajo error de clasificación, independientemente del nivel de variabilidad en los datos. Otro posible escenario es que, como resultado del efecto del ruido, el clasificador evaluado presente un deterioro importante en su desempeño mientras aumenta la variabilidad de los datos. A fin de comparar los clasificadores propuestos, en lo adelante, se establecerá que un diagnosticador robusto es aquel que mantiene altos indicadores de desempeño, independiente del efecto negativo de ruidos y/o perturbaciones externas. Desde el punto de vista de modelado se considerará, además, que se trata de un problema multivariable con k clases que representan los estados de operación del sistema, tal que el efecto de un ruido en las variables medidas puede ser modelado como:

$$X(t) = S(t) + \Gamma(t) \quad (1)$$

donde el comportamiento habitual en las mediciones del proceso es representado por $S(t) \sim N(\mu_s, \Sigma_S)$ y $\Gamma(t) \sim N(0, \sigma_\Gamma^2 I)$ es la incertidumbre adicional incorporada por el ruido. En procesos reales, por lo general, no se cuenta con información sobre el tipo y cantidad de ruido implícito en las mediciones; pero esta información puede ser supuesta a priori. Además, con el objetivo de facilitar el estudio de la robustez de los clasificadores, se asume que el ruido (i.i.d.) es acotado y cada columna de $S(t)$ es de la forma $s_j(t) \sim N(\mu_{s_j}, \sigma_{s_j}^2)$, donde $j = \{1, \dots, p\}$ denota la variable medida. A partir de esto, $\mu_{s_j} \pm 3\sigma_{s_j}$ determina el rango específico dentro del cual se tiene un 99,73% de información válida para las distribuciones de cada una de las variables [6]. Por tanto, para una variabilidad en los datos que es acotada entre $\pm 3\sigma_{s_j}$ respecto al comportamiento nominal del proceso, $X(t)$ puede contener información de $S(t)$, incluso si $\Gamma(t) \neq 0$; fuera de este intervalo es más difícil obtener altos desempeños en las tareas de clasificación debido a la mezcla de clases.

III. ÍNDICADOR DE ROBUSTEZ PROPUESTO

El rechazo de ruido por nivel es la capacidad de un clasificador de no ser afectado por la variabilidad en los datos, como resultado de un ruido acotado. Entonces, la sensibilidad al ruido por parte del clasificador, representada matemáticamente por el índice de robustez J_{RIL} se determina como:

$$J_{RIL} = H [(I_m^1 + V) (I_{max}^0 - I_{min}^0)] \quad (2)$$

donde I_m^1 , I_{max}^0 y I_{min}^0 se calculan usando el método de los trapecios y brindan una medida del área bajo las curvas de tendencia del error de clasificación. Para un nivel de ruido, que varía con un incremento $\Delta\eta$ en un rango de $\eta_0 \leq \eta \leq \eta_{max}$, I_{min}^0 y I_{max}^0 son calculadas como sigue:

$$I_{lim}^0 = \int_1^q E_{lim}(f(X)|\eta_i) d\eta \quad (3)$$

$$I_{lim}^0 = \Delta\eta \left[\frac{E_{lim}|_{\eta=\eta_0}}{2} + \sum_{i=1}^{N_i-1} E_{lim}|_{\eta=\eta_i} + \frac{E_{lim}|_{\eta=\eta_{i+1}}}{2} \right] \quad (4)$$

Considerando que:

$$I_{lim}^0 = \begin{cases} I_{max}^0, & \text{si } E_{lim} = E_{max} \\ I_{min}^0, & \text{si } E_{lim} = E_{min} \end{cases} \quad (5)$$

La diferencia entre I_{max}^0 y I_{min}^0 modela el comportamiento del clasificador teniendo en cuenta el intervalo de confianza para cada uno de los errores estimados. Por otra parte, I_m^1 está asociado con la tendencia del valor medio obtenido para el error de clasificación (E).

$$I_m^1 = \int_1^q \eta_i^\ell \bar{E}(f(X)|\eta_i) d\eta \quad (6)$$

$$I_m^1 = \Delta\eta \left[\eta_0^\ell \left(\frac{\bar{E}|_{\eta=\eta_0}}{2} \right) + \sum_{i=1}^{N_i-1} \eta_i^\ell (\bar{E}|_{\eta=\eta_i}) + \frac{\eta_{i+1}^\ell (\bar{E}|_{\eta=\eta_{i+1}})}{2} \right] \quad (7)$$

En las ecuaciones (4) y (7) los valores constantes η_0 , η_{max} y $\Delta\eta$ se definen por el investigador. La relación entre estos



parámetros está dada por $H = \Delta\eta/(\eta_{max} - \eta_0)$. En tanto, la variabilidad σ_γ adicionada por un ruido $\Gamma(t)$ a una variable de $S(t)$ es:

$$\sigma_\gamma = \sqrt{(\eta - 1)\sigma_s} \quad \eta \in \mathbb{R}^+, \eta \geq 1 \quad (8)$$

donde el nivel de severidad η que caracteriza la relación entre $X(t)$ y $S(t)$, cuando los mismos proceden de una distribución normal, puede ser obtenido como:

$$\eta = \left(\frac{\Psi_X}{\Psi_S} \right)^2 = \left[\frac{(\sigma_x/\mu_s) \times 100}{(\sigma_s/\mu_s) \times 100} \right]^2 \quad (9)$$

En este contexto, el parámetro V considera la rapidez con que se deteriora el desempeño del clasificador a medida que se incrementa la variabilidad en los datos y está dado por:

$$V = \sum_{i=2}^N (\bar{E}_i - \bar{E}_{i-1}) / (\eta_i - \eta_{i-1}) \quad (10)$$

donde $\ell \in \mathbb{N}$ es un parámetro de magnificación usado en (7) y (10), a fin de penalizar aquellos clasificadores que ante elevados niveles de ruido, presentan un deterioro significativo en su desempeño. Diferentes valores de este parámetro, permiten dar mayor peso al comportamiento del clasificador según I_m^1 o V . Para todos los casos analizados en el presente trabajo, el valor de este parámetro se fijó como $\ell = 2$.

IV. ROBUSTEZ DEL DIAGNÓSTICO EN EL CSTR

A continuación se evalúa la aplicación del índice de robustez J_{RIL} en el conocido proceso de prueba Tanque Reactor Continuamente Agitado (CSTR). Para ello, se emplean tres clasificadores diferentes y se incorpora variabilidad en el proceso según el esquema mostrado en la Figura 1.

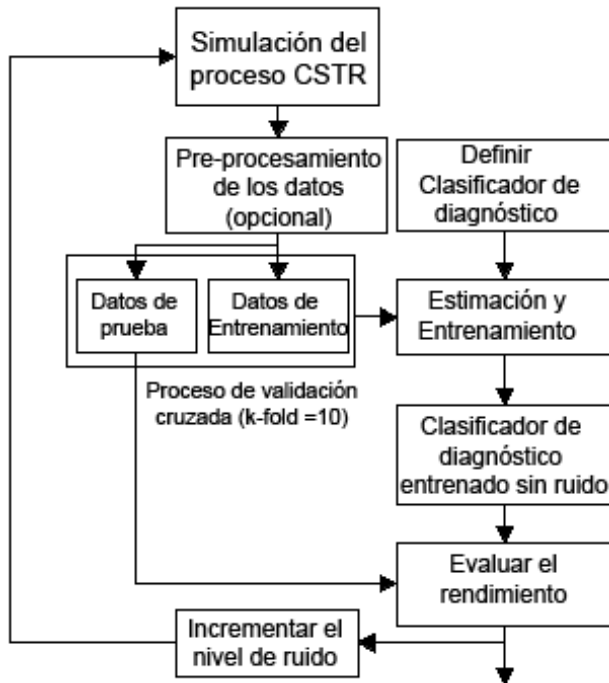


Figura 1. Flujograma empleado para los experimentos en el CSTR.

Para realizar la comparación de los clasificadores, se generan 91 conjuntos de datos históricos. El primer conjunto, describe la operación del CSTR considerando sólo la variabilidad típica en el proceso, y se utiliza para entrenar fuera de línea, cada uno de los clasificadores. Los conjuntos de datos históricos restantes, están asociados con la operación del proceso, a medida que se va incrementando el efecto del ruido. Todos los datos son recopilados fuera de línea, considerando la misma estructura y número de clases. Es decir, cada conjunto de datos históricos se forma a partir de nueve clases con 800 observaciones, que corresponden a cada uno de los fallos descritos en la Tabla I.

Cuadro I
DESCRIPCIÓN DE LOS FALLOS EN EL PROCESO CSTR.

No.	Descripción de los fallos	Valor
1	Variación abrupta en el flujo (Q_F)	10 L/min
2	Temperatura del reactor con una desviación	4 K
3	Incremento en la concentración (Aumento de C_{AF})	Pendiente $6 \cdot 10$ (mol/L)/min
4	Incremento en la concentración (Aumento de C_{AF})	Pendiente 0,1 K/min
5	Aumento de la temperatura (del flujo refrigerante T_{CF})	Pendiente 0,1 K/min
6	Variación abrupta en la presión en la línea de enfriamiento (P_U)	2,5 psi
7	Variación abrupta en la presión en la línea de salida del reactor (P_D)	5 psi
8	La válvula del refrigerante presenta juego. 20% del span	

En todos los casos, los datos generados son sometidos a un paso intermedio donde se estandarizan de acuerdo con el estado de operación normal. El error obtenido por los clasificadores, se almacena en cada iteración. Posteriormente, se determina el índice de robustez para $1 \leq \eta \leq 10$ y $\Delta\eta = 0,1$. El papel de los clasificadores consiste en identificar correctamente a cuál de los estados de fallos conocidos, corresponde una nueva observación del proceso.

IV-A. Clasificadores empleados.

En la literatura han sido abordadas múltiples herramientas discriminantes, con diferentes grados de éxito durante su aplicación a los problemas de diagnóstico de fallos. Seguidamente se presentan los aspectos básicos relacionados con las herramientas discriminantes utilizadas para probar el índice de robustez J_{RIL} .

Árboles de Decisión: Un Árbol de Decisión (AD) constituye un conjunto de condiciones organizadas en una estructura jerárquica para clasificar clases disjuntas. Cada rama, desde la raíz a las hojas, se puede interpretar como una regla, siendo los nodos hojas la clase asignada y los nodos internos los términos en conjunción (antecedente de la regla). Durante la clasificación con esta herramienta, cada elemento de su dominio es mapeado en un elemento de su rango, el cual es típicamente un identificador de clase o un valor numérico. En cada hoja del árbol se encuentra un elemento de rango;

mientras que en cada nodo interno se encuentra una prueba que tiene un conjunto de posibles resultados. Aunque este tipo de herramienta de clasificación no es la más competitiva en términos de predicción, en el presente trabajo se seleccionó para evaluar el índice de robustez propuesto por su simplicidad, fácil implementación e interpretación.

Hay varios enfoques para el diseño de estructuras de arboles e pueden ser empleados. [8]. En este caso el AD fue implementado comenzando desde la raíz, donde se encuentra la variable medida que mayor información ofrece. Su construcción avanza a partir de las ramas del árbol, que son las variables ordenadas a partir de la información discriminante que ofrece cada una, hasta llegar a las hojas que corresponden con la clasificación de los fallos. Este procedimiento es conocido como Inducción de Arriba hacia Abajo (por su denominación en idioma inglés: *Top-Down Induction of Decision Trees*) [13]. El clasificador basado en Árboles de Decisión [12], fue implementado usando el algoritmo de partición ID3. A partir de minimizar criterios de entropía, este algoritmo determina el árbol que genera menor cantidad de encuestas a los sensores y que dispone de la información más rápidamente.

Redes Neuronales Artificiales: La siguiente herramienta discriminante que es probada, se basa en el uso de las Redes Neuronales Artificiales. Los clasificadores de este tipo, se caracterizan por su tolerancia al ruido y su capacidad para generalizar la información, por tanto, son ideales para evaluar el índice de robustez propuesto. En este caso, se utiliza una Red Neuronal del tipo perceptrón multicapa cuyos parámetros de entrada y salida están asociados con la cantidad de variables del proceso y el número de fallos, respectivamente. En este sentido se desarrolla una arquitectura con una sola capa oculta con 9 neuronas, que posee 14 entradas y 9 salidas que permiten distinguir los fallos simulados en el CSTR. La red fue creada, entrenada e implementada utilizando el algoritmo de entrenamiento Levenberg–Marquardt. El proceso de entrenamiento se realizó de manera iterativa para minimizar el error cuadrático medio (MSE, *Mean Squared Error*) entre la salida de la red y el vector de entrenamiento. En cada iteración, el gradiente del desempeño de la función MSE fue utilizado para ajustar los pesos y umbrales de la red. En este estudio, se empleó un $MSE = 10^{-6}$, y un valor mínimo para el gradiente de 10^{-8} , así como un número máximo de épocas igual a 100. El proceso de entrenamiento de la red, se detiene si cualquiera de las condiciones anteriores se cumple. Los pesos iniciales de la red fueron generados de manera aleatoria.

Máquinas de Soporte Vectorial: Las Máquinas de Soporte Vectorial, representan un clasificador basado en funciones kernel que es relativamente nuevo. Su principio de operación se fundamenta en la idea de usar un hiperplano para crear un clasificador, cuyo margen de separación entre clases sea máximo. En un problema de clasificación binario, \mathbf{w} es interpretada como la región entre los hiperplanos paralelos tal que $f(x) = \mathbf{w}^T \mathbf{x}_i + \mathbf{w}_0 = \pm 1$.

A partir de esto, la distancia de cualquier punto localizado en uno de los dos hiperplanos a la función de clasificación es igual a $\mathbf{d} = 1/\|\mathbf{w}\|$. La formulación del hiperplano queda definida entonces como:

$$J(\mathbf{w}, \mathbf{w}_0, \xi) = \min_{\mathbf{w} \neq 0} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^{\ell} \xi_i \quad (11)$$

$$\text{suje}to \ a : \quad y_i(\mathbf{w}^T + \mathbf{w}_0) \geq 1 - \xi_i \quad \xi_i \geq 0$$

donde $y_i \in \{-1, 1\}$ corresponde a la etiqueta de la clase asociada y C es el parámetro de regularización mediante el cual se logra un balance entre el error cometido y el ancho del margen. En caso de que x_i sea clasificada correctamente pero fuera del margen entonces, $\xi_i = 0$; si por el contrario, se encuentra dentro de éste, entonces $0 \leq \xi_i \leq 1$ y si ξ_i está mal clasificada $\xi_i \leq 1$. Utilizando la representación del problema en su forma dual, es posible entonces evaluar las condiciones de Karush-Kuhn-Tucker para obtener el correspondiente vector $\alpha = (\alpha_1, \dots, \alpha_\ell)$ de multiplicadores de Lagrange positivos. Cuando el conjunto de entrenamiento no es linealmente separable, se adopta la filosofía kernel para mapear los vectores característicos hacia un espacio de mayor dimensión, donde las clases son linealmente separables. Como resultado es posible reescribir el problema dual, tal que:

$$W(\alpha) = \max_{\alpha \neq 0} \sum_{i=1}^{\ell} \alpha_i - \frac{1}{2} \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} \alpha_i \alpha_j y_i y_j \mathbf{K}_{ij} \quad (12)$$

Sustituyendo el producto punto por $\mathbf{K}_{ij} = \mathbf{k}(x_i, x_j)$ se obtiene la función de decisión generalizada mostrada anteriormente, tal que la misma queda expresada como:

$$f(x) = \mathbf{w}^T \mathbf{x}_i + \mathbf{w}_0 = \text{sign} \left(\sum_{i=1}^{sv} \alpha_i y_i \mathbf{k}(x_i, x_j) + \mathbf{w}_0 \right) \quad (13)$$

donde sv corresponde a los vectores soportes obtenidos para α_i multiplicadores de Lagrange que son no nulos. Para el diseño del clasificador MSV, en este caso se optó por utilizar la estrategia binaria (1 vs. Todos). De esta manera se requieren solo $(c - 1)$ máquinas soporte. Este enfoque de clasificación se implementó utilizando un kernel Gaussiano, cuyo parámetro de ajuste fue estimado con la medida Alfa propuesta por [3].

IV-B. Análisis y discusión de los resultados

A fin de evaluar el desempeño de los clasificadores de diagnóstico en el CSTR, se realizan dos experimentos que consisten en incorporar ruido en las variables Flujo del refrigerante (C_{AF}) y Concentración de alimentación (Q_C) de dicho proceso. El primer paso de cada uno de los experimentos, se centra en determinar el error de clasificación cuando los datos históricos tienen el nivel de ruido que normalmente influye sobre el sistema. De esta manera, es posible conocer el valor medio del error, que se desea mantener para cada uno de los clasificadores a medida que se va incrementando la variabilidad de los datos durante los sucesivos pasos del procedimiento para calcular J_{RIL} .

Las Tablas II, IV y III, ilustran los resultados obtenidos para el primer paso del procedimiento. Nótese que los mejores



resultados se obtienen con las MSV, seguidas por las RNA y el clasificador AD. La diferencia entre el desempeño de los clasificadores es pequeña, y hace pensar que desde el punto de vista práctico es equivalente utilizar cualquiera de ellos como diagnosticador.

Cuadro II
MATRIZ DE CONFUSIÓN OBTENIDA PARA EL CLASIFICADOR AD.

	NOC	F1	F2	F3	F4	F5	F6	F7	F8	TA(%)
NOC	717	0	83	0	0	0	0	0	0	89.63
F1	0	800	0	0	0	0	0	0	0	100.0
F2	211	0	589	0	0	0	0	0	0	73.63
F3	11	0	1	788	0	0	0	0	0	98.50
F4	0	0	0	0	800	0	0	0	0	100.0
F5	0	0	0	0	0	800	0	0	0	100.0
F6	0	0	0	0	0	0	800	0	0	100.0
F7	0	0	0	0	0	0	0	800	0	100.0
F8	11	0	1	0	0	0	0	0	788	98.50
TA(%)	75.5	100	87.4	100	100	100	100	100	100	95.58
E(%)	24.5	0	12.6	0	0	0	0	0	0	4.42

Cuadro III
MATRIZ DE CONFUSIÓN OBTENIDA PARA EL CLASIFICADOR RNA.

	NOC	F1	F2	F3	F4	F5	F6	F7	F8	TA(%)
NOC	619	0	181	0	0	0	0	0	0	77.38
F1	0	800	0	0	0	0	0	0	0	100.0
F2	114	0	685	1	0	0	0	0	0	85.63
F3	6	0	2	792	0	0	0	0	0	99.00
F4	0	0	0	0	800	0	0	0	0	100.0
F5	0	0	0	0	0	800	0	0	0	100.0
F6	0	0	0	0	0	0	800	0	0	100.0
F7	0	0	0	0	0	0	0	800	0	100.0
F8	5	0	1	0	0	0	0	0	794	99.25
TA(%)	85.12	100	77	99.99	100	100	100	100	100	95.7
E(%)	14.88	0	23	0.001	0	0	0	0	0	4.30

Cuadro IV
MATRIZ DE CONFUSIÓN OBTENIDA PARA EL CLASIFICADOR MSV.

	NOC	F1	F2	F3	F4	F5	F6	F7	F8	TA(%)
NOC	711	0	89	0	0	0	0	0	0	88.88
F1	0	800	0	0	0	0	0	0	0	100.0
F2	182	0	618	1	0	0	0	0	0	77.25
F3	15	0	1	784	0	0	0	0	0	98.00
F4	0	0	0	0	800	0	0	0	0	100.0
F5	0	0	0	0	0	800	0	0	0	100.0
F6	0	0	0	0	0	0	800	0	0	100.0
F7	0	0	1	0	0	0	0	799	0	99.86
F8	16	0	3	0	0	0	0	0	781	97.63
TA(%)	73.37	100	88.25	99.99	100	100	100	100	100	95.74
E(%)	26.63	0	11.75	0.001	0	0	0	0	0	4.26

Al menos para este nivel de variabilidad en los datos, las Tablas II, IV y III muestran que la precisión se encuentra siempre por encima del 95% lo que denota una elevada certeza en las decisiones tomadas usando este criterio. A fin de complementar estos resultados, en la Figura 2 se muestra el comportamiento de cada clasificador, teniendo en cuenta

el incremento en la variabilidad de los datos. Nótese que el análisis de robustez que mediante el índice J_{RIL} se muestra en la Figura 2 refleja que el desempeño anterior se deteriora significativamente a medida que aumentan los niveles de variabilidad en los datos como resultado de un ruido.

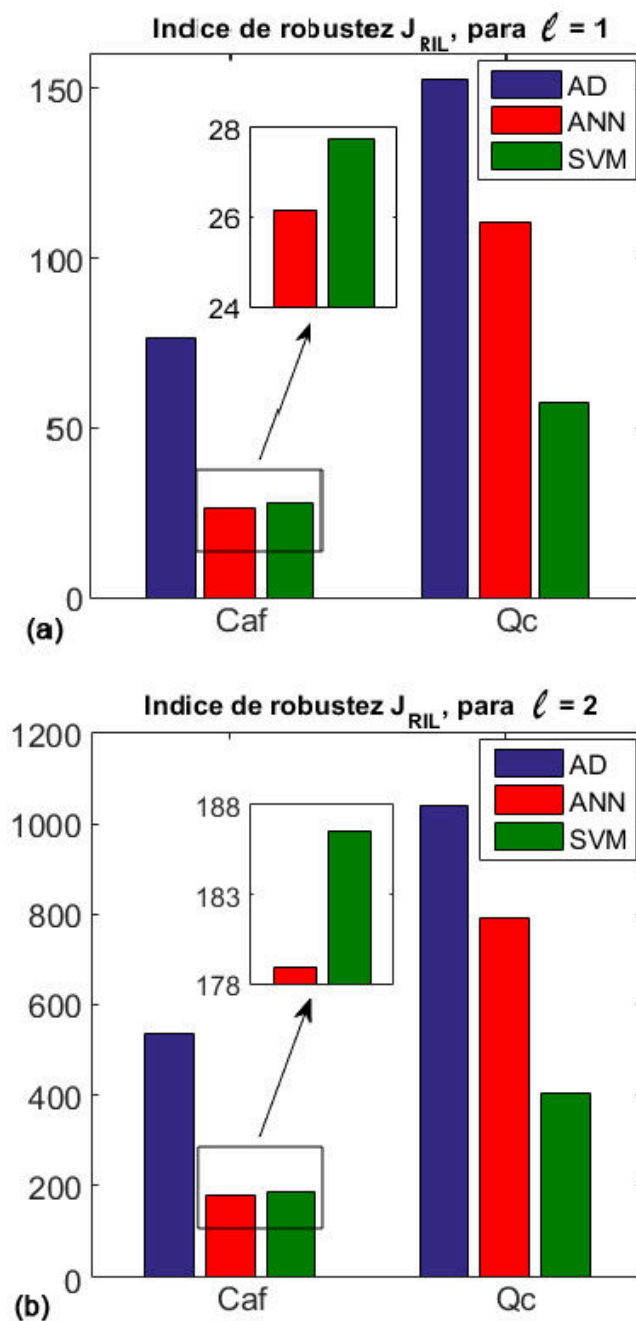


Figura 2. Comparando clasificadores mediante el índice de robustez J_{RIL} .

En este caso cuando la variable C_{AF} se encuentra afectada por diferentes niveles de ruido, el clasificador con mejor desempeño está basado en Redes Neuronales. En tanto, las Máquinas de Soporte Vectorial resultan el clasificador más robusto cuando la variable Q_C está expuesta a diferentes

niveles de ruido. Según se ilustra en la Figura 2, el parámetro de magnificación ℓ permite resaltar las diferencias entre valores de robustez similares. Al comparar las gráficas de barras anteriores, es notable que el sistema de diagnóstico diseñado es más sensible al efecto del ruido en Q_C que en C_{AF} independientemente del clasificador empleado. En específico, el mayor deterioro se presenta para el clasificador basado en la herramienta de Árboles de Decisión. Teniendo en cuenta los resultados mostrados anteriormente, y considerando la similitud en el desempeño de los clasificadores sin un incremento de la variabilidad típica del proceso, se podría decir que en este caso no es recomendable emplear un clasificador basado en Redes Neuronales o en Árboles de Decisión. Una alternativa viable sería, seleccionar las Máquinas de Soporte Vectorial como clasificador a utilizar dado el alto rendimiento y nivel de rechazo al ruido que esta herramienta obtuvo durante las pruebas realizadas.

V. CONCLUSIONES

En el presente trabajo se discutió la influencia negativa del ruido en los procesos de clasificación que forman parte de las tareas de diagnóstico de fallos. Además, se resaltó la necesidad de contar con sistemas de diagnóstico que sean robustos ante ruidos y/o perturbaciones, manteniendo altos indicadores de rendimiento. A fin de identificar cuáles son las herramientas de clasificación que cumplen estos requisitos, se evaluó el índice de robustez J_{RIL} usando el proceso CSTR. Los resultados obtenidos de estos experimentos mostraron que el índice propuesto permite, a partir de un único valor, establecer cuál es el clasificador más robusto, dado un ruido que afecta a las señales medidas con un rango de variabilidad conocido. Sin embargo, el indicador propuesto no brinda información específica sobre el deterioro que tiene el clasificador a medida que aumenta la variabilidad en los datos. En este sentido, es recomendable complementar el índice de robustez con una representación gráfica del deterioro del diagnosticador. De esta manera sería posible valorar la sensibilidad del clasificador analizado e identificar además, posibles alternativas de hibridación que permitan alcanzar rendimientos superiores en términos de robustez. 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 solo se reduce el número de análisis comparativos a realizar, sino que además, se evita considerar cualquier criterio subjetivo a la hora de seleccionar las herramientas de clasificación más adecuadas.

VI. AGRADECIMENTOS

Los autores agradecen el apoyo financiero brindado por la Asociación Universitaria Iberoamericana de Postgrado (AUIP). También agradece la colaboración del Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) en Brasil, y de la Universidad Tecnológica de la Habana, CUJAE. Así como los Proyectos TIN201786647-P y TIN2017-86647-P (MINECO/AEI/FEDER, UE).

REFERENCIAS

- [1] M. Blanke, M. Kinnaert, J. Lunze, M. Staroswiecki, *Diagnosis and Fault-Tolerant Control*, Springer, 2006.
- [2] L. H. Chiang, R. D. Braatz, E. L. Russell, *Fault detection and diagnosis in industrial systems*, Springer, 2001.
- [3] P. Chudzian, "Evaluation measures for kernel optimization", *Pattern Recognition Letters*. 33, 1108–1116, 2012.
- [4] A. Das, J. Maiti, R. Banerjee, "Process monitoring and fault detection strategies: A review", *International Journal of Quality and Reliability Management*, 29(7), 720–752, 2012.
- [5] S. X. Ding, *Data-driven Design of Fault Diagnosis and Fault-tolerant Control Systems*, Springer, 2014.
- [6] D. C. Montgomery, *Introduction to Statistical Quality Control*, Wiley and Sons, 2005.
- [7] J. Korbicz, *Fault diagnosis: Models, Artificial Intelligence, Applications*, Springer Science and Business Media, 2003.
- [8] J. Hernández-Orallo, M.J. Ramírez-Quintana, C. Ferri, *Introducción a la Minería de Datos*, Prentice Hall and Addison-Wesley, 2004.
- [9] R.J. Patton, J. Chen, *Robust model-based fault diagnosis for dynamic systems*, Kluwer Academic Publishers, London, 1999.
- [10] K. Patan, M. Witczak, J. Korbicz, "Towards robustness in neural network based fault diagnosis", *International Journal of Applied Mathematics and Computer Science*. 18, 443–454, 2008.
- [11] J. A. Sáez, M. Galar, J. Luengo, F. Herrera, "Analyzing the presence of noise in multi-class problems: Alleviating its influence with the One-vs-One decomposition", *Knowledge and Information Systems*. 38 (2014) 179–206.
- [12] J. R. Quinlan, "Induction of decision trees", *Machine Learning*, 1(1):81–106, 1986.
- [13] L. Rokach, O. Maimon, "Top-down induction of decision trees classifiers: A survey", *IEEE Transactions on Systems, Man, and Cybernetics*, 35(4):476–487, 2005.