



Comparación entre algoritmos estimadores en la severidad de fallas para los sistemas del diagnóstico de turbinas de gas

Comparison of fault severity estimation algorithms for gas turbine diagnostic systems

Blancas-Hernández Gerardo

Instituto Politécnico Nacional
Escuela Superior de Ingeniería Mecánica y Eléctrica Unidad
Culhuacán
Sección de Estudios de Posgrado e Investigación
Correo: gerbh25@gmail.com
<https://orcid.org/0000-0002-1783-1631>

Loboda Igor

Instituto Politécnico Nacional
Escuela Superior de Ingeniería Mecánica y Eléctrica Unidad
Culhuacán
Sección de Estudios de Posgrado e Investigación
Correo: igloboda@gmail.com
<https://orcid.org/0000-0002-4442-5540>

Gonzales-Castillo Iván

Instituto Politécnico Nacional
Escuela Superior de Ingeniería Mecánica y Eléctrica Unidad
Culhuacán
Sección de Estudios de Posgrado e Investigación
Correo: chrivangc@gmail.com
<https://orcid.org/0000-0002-0730-546X>

Rendón-Cortés Karen Anaid

Instituto Politécnico Nacional
Escuela Superior de Ingeniería Mecánica y Eléctrica Unidad
Culhuacán
Sección de Estudios de Posgrado e Investigación
Correo: anaid_2418@hotmail.com
<https://orcid.org/0000-0003-2S89-3354>

Resumen

El objetivo de este estudio es comparar la estimación de la severidad de fallas empleando los dos enfoques principales que se utilizan para el diagnóstico de conducto de flujo en los motores de turbina de gas. El estudio empieza con la simulación de diferentes fallas de un motor por su modelo no lineal basado en física (modelo termodinámico). El primero de los enfoques usa mediciones simuladas y técnicas de identificación del sistema que estiman los parámetros de falla especiales. Ellos permiten localizar las fallas de los componentes del motor y determinar su severidad. El segundo enfoque se basa en la teoría del reconocimiento de patrones y utiliza principalmente modelos basados en datos. La clasificación de fallas necesaria para este enfoque se puede componer de patrones simulados para cada clase de falla. Con el fin de obtener resultados más seguros y generales la comparación se realizó independientemente para tres diferentes clasificaciones, cada una tiene sus propios parámetros de falla. Los resultados obtenidos demuestran que en general, la exactitud del segundo enfoque es mayor que la del primero, aunque para la última clasificación las exactitudes de enfoques son comparables. La mayor dificultad que se presentó y también la mayor contribución de este trabajo fue determinar la forma de estimar la severidad en el primer enfoque. Para resolver este problema proponemos utilizar una red artificial. Otra novedad consiste en la comparación de dos enfoques principales para diagnosticar turbinas de gas en la función de estimación de la severidad de fallas. Existen muchos estudios cuyo principal objetivo es comparar diferentes técnicas del diagnóstico de las turbinas, pero ninguno de ellos compara sus capacidades de estimación de la severidad.

Descriptores: Diagnóstico de turbinas de gas, severidad de fallas, estimadores de severidad.

Abstract

The objective of this study is to compare the estimation of failure severity using the two main approaches used for the diagnosis of flow duct in gas turbine engines. This study starts with the simulation of different faults of an engine by its nonlinear physics-based model (thermodynamic model). The first approach uses simulated measurements and system identification techniques that estimate special fault parameters, which allow to localize faults and determine their severity. The second approach is based on pattern recognition theory and mainly uses data-driven models. The fault classification required for this approach can be made up of simulated patterns for each class of failure. In order to obtain safer and more general results, the comparison was carried out independently for three different classifications, each one having its own failure parameters. The results obtained show that in general the accuracy of the second approach is greater than that of the first, although for the last classification the accuracy of the approaches is comparable. The greatest difficulty that arose and also the greatest contribution of this work was determining how to estimate severity in the first approach. To solve this problem, we propose to use an artificial neural network. Another novelty is the comparison of two main approaches to diagnose gas turbines in the function of estimating the severity of failures. There are many studies whose main objective is to compare different techniques for diagnosing turbines, but none compare their severity estimation capabilities.

Keywords: Gas turbine diagnosis, failure severity, severity estimators.

INTRODUCCIÓN AL DIAGNÓSTICO DEL CONDUCTO DE FLUJO

Existen muchos aspectos de mantenimiento de turbinas de gas que son afectados por las fallas y el deterioro (Boyce, 2002; Soares, 2007; Giampaolo, 1997). Algunos de estos son la confiabilidad y la seguridad de los motores, así como los costos de operación. Gracias a los sistemas de monitoreo que se han efectuado se han logrado reducir considerablemente las afectaciones a las turbinas. Estos sistemas incluyen diferentes técnicas como la termografía, el análisis de la acústica y de las vibraciones, así como el diagnóstico de conducto de flujo.

El diagnóstico del conducto de flujo permite observar el estado de salud de los componentes que integran a las turbinas de gas. En este análisis se puede considerar que son el deterioro o degradación y las averías incipientes lo que puede dañar al motor. No obstante, además de estos defectos, también pueden detectarse e identificarse anomalías en los sistemas de medición y control. Igualmente, el diagnóstico permite estimar los rendimientos principales del motor que no se miden, como la potencia del eje, el empuje, la eficiencia general del motor, el consumo de combustible específico y el margen de estabilidad del compresor.

Como cualquier tipo de diagnóstico técnico, el diagnóstico del conducto de flujo se puede dividir en tres etapas generales, que a su vez, se encuentran relacionadas entre sí (Rao, 1996). La primera es la supervisión de la salud del motor, que se refiere a la detección de la falla. La segunda, se refiere a la identificación de la falla, que implica un diagnóstico detallado. Por último, la tercera etapa consiste en la predicción del tiempo restante de la vida útil del motor. Los métodos de diagnóstico de turbinas de gas también se pueden clasificar según la dedicación a las etapas mencionadas.

Además de las etapas generales, estos métodos se dividen en dos enfoques generales (Amare *et al.*, 2019; Jardine, 2006; Butler, 2006 y Volponi *et al.*, 2003). El primer enfoque emplea técnicas de identificación del sistema y usa modelos basados en la física, además de requerir un completo y detallado conocimiento del sistema (Mikael, 2019). En nuestro caso, el sistema es la turbina de gas y el enfoque se llama análisis del conducto de flujo conocido en inglés como: «*gas path analysis*» (Volponi, 2014). Los modelos usados en este enfoque relacionan variables del conducto de flujo monitoreadas con parámetros de fallas especiales que permiten simular la degradación de los componentes del motor.

En el área de diagnóstico, el objetivo de la identificación de turbinas de gas es encontrar los parámetros de falla que minimizan la diferencia entre las variables generadas por el modelo y las medidas (Stamatis *et al.*, 1990). Normalmente, estos modelos son complejos y

requieren una cantidad significativa de recursos computacionales. El segundo enfoque (Ogaji, 2003 y Ganguli, 2013) se basa en la teoría del reconocimiento de patrones y utiliza principalmente modelos basados en datos y diferentes técnicas del reconocimiento, como redes neuronales, lógica difusa o máquinas de soporte vectorial. En estos modelos se puede obtener una relación de variables de entrada y salida de los datos reales disponibles sin la necesidad de conocer la teoría respecto al sistema analizado. La clasificación necesaria de las fallas se compone de las desviaciones en las mediciones causadas por diferentes fallas.

Ahora bien, el primer enfoque determina los parámetros de falla capaces de simular el deterioro, como se mencionó anteriormente. Es por ello que este enfoque sirve para tomar decisiones en el espacio de diagnóstico de los parámetros de falla. En el segundo enfoque, se realiza la clasificación usando las desviaciones de variables monitoreadas, por este motivo las decisiones tomadas están en el espacio de diagnóstico de variables monitoreadas. Así, cada enfoque opera en su propio espacio diagnóstico.

La confiabilidad de las decisiones finales sobre las fallas se define por la matriz de confusión («*confusion matrix*») que incluye las probabilidades del reconocimiento correcto e incorrecto de fallas de todas las clases. Varios criterios de la eficiencia de los algoritmos de diagnóstico se construyen basándose en esta matriz (Craig, 2008). Usualmente estos criterios se usan cuando se comparan los algoritmos del segundo enfoque o de diferentes enfoques (Donald, 2010; Steven & Butler, 2006). Dentro del primer enfoque, el mejor algoritmo todavía se determina por la exactitud de estimación de los parámetros de falla (Kamboukos & Mathioudakis, 2005) que no es un criterio de la eficiencia terminal de diagnóstico.

En adición al reconocimiento correcto de las fallas, la estimación de la severidad de la falla encontrada es también una función importante del diagnóstico. Esta severidad se refiere a la gravedad de los problemas causados por la falla en los componentes del motor diagnosticado. En los algoritmos que pertenecen al primer enfoque, valores absolutos de los parámetros de falla se interpretan como severidades (Kamboukos & Mathioudakis, 2005). Sin embargo, si alguna clase de falla se describe por varios parámetros, una medida de acción total de estos parámetros (medida de severidad) es necesaria, pero prácticamente no se usa. Tampoco se emplea en los algoritmos del segundo enfoque (Donald *et al.*, 2013 y Steven & Butler, 2006). Así, la severidad de fallas se determina raramente y no hay estudios dedicados al problema de la exactitud de la estimación de severidad.

En cambio, el principal objetivo de este estudio es realizar una comparación de los algoritmos en la estimación de severidad de fallas usando la exactitud de la estimación como criterio. Tal comparación de diferentes técnicas estimadoras de severidad presenta una novedad. Este estudio contribuye a completar la comparación de los dos enfoques del diagnóstico del conducto de flujo previamente realizada en Loboda *et al.* (2019), ya que ahí no se consideraba todavía la estimación de la severidad de fallas.

METODOLOGÍA DE LA COMPARACIÓN DE TÉCNICAS ESTIMADORAS DE SEVERIDAD

FUNDAMENTOS DEL DIAGNÓSTICO DE TURBINAS DE GAS

Aunque algunos estudios de fallas reales existen (Cruz, 2018), son trabajos raros y no determinan la severidad de fallas. Por lo tanto, con el fin de llevar a la práctica una buena comparación de dos algoritmos para la estimación de severidad de fallas, se creó un conjunto de datos simulados. Para esto, se ocupó el *software GasTurb*. Este programa ha sido desarrollado desde el inicio de los 90's por Joachim Kurzke, especialista en el rendimiento de turbinas de gas que ha trabajado desde 1970 en el área de su simulación. *GasTurb* presenta software profesional para cálculos de rendimiento de turbinas de gas. Es diseñado para ingenieros, gerentes e investigadores. Se utiliza en todo el mundo en una serie de industrias, así como en ciencia y educación (GasTurb, 2021). Este software ofrece una simulación no lineal basada en física para los tipos más comunes de turbinas. Se describe por la ecuación:

$$\vec{Y} = F(\vec{U}, \vec{\theta}) \quad (1)$$

Donde \vec{Y} representa al vector de las variables monitoreadas, \vec{U} al vector de las condiciones de operación y $\vec{\theta}$ al vector de los parámetros de salud. El vector $\vec{\theta}$ está compuesto por la suma de valores nominales de motor sano $\vec{\theta}_0$ y un vector de parámetros de falla $\Delta\vec{\theta}$. Por lo tanto:

$$\vec{\theta} = \vec{\theta}_0 + \Delta\vec{\theta} \quad (2)$$

El vector de parámetros de falla introduce pequeños cambios en los mapas de los componentes para que de esta forma se tome en consideración una condición actual de cada componente. Los desplazamientos del comportamiento provocados por los parámetros de falla se observan en la Figura 1.

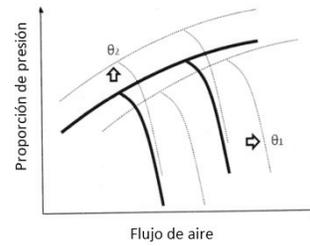


Figura 1. Diagrama del desplazamiento del comportamiento del mapa del compresor provocado por el deterioro

En este trabajo se simuló las fallas con un modelo lineal (Loboda, 2010). Este modelo se describe por la siguiente ecuación:

$$\overline{\delta Y} = H \overline{\delta \theta} \quad (3)$$

donde $\overline{\delta Y}$ y $\overline{\delta \theta}$ son vectores de cambios relativos de \vec{Y} y $\vec{\theta}$, y H es la matriz de coeficientes de influencia. La matriz H se determinó introduciendo variaciones pequeñas en el modelo no lineal (1) y obteniendo variables monitoreadas correspondientes. Al final cada elemento de la matriz se calcula por:

$$H = \frac{\delta Y_i}{\delta \theta_j} \quad (4)$$

En donde i corresponde al número de una variable monitoreada y j al número de un parámetro de falla. La variación $\delta \theta$ tiene un valor constante de 1 %.

Para tener una simulación realista, errores aleatorios $\varepsilon \delta \vec{Y}$ se agregan al vector de desviaciones $\overline{\delta Y}$, resultando en:

$$\overline{\delta Y^*} = H \overline{\delta \theta} + \varepsilon \delta \vec{Y} \quad (5)$$

Para simplificar el diagnóstico, las desviaciones relativas se transforman a las normalizadas según la ecuación:

$$Z_i^* = \frac{\delta Y_i^*}{a_i} \quad (6)$$

Donde a_i es la amplitud de errores aleatorios en δY_i^* . Al aplicar las técnicas de reconocimiento de patrones, el vector \vec{Z}^* presenta un patrón.

CLASIFICACIÓN DE FALLAS

Para reconocer fallas numerosas en un motor, estas se agrupan en clases. La clasificación total está compuesta por un número relativamente pequeño q de clases D1, D2, D3...Dq, las cuales representan posibles fallas típicas.

cas en el motor. Cada clase incluye las averías que tienen lugar en uno o más componentes del motor y tienen una gravedad variable. La clase se determina cambiando un parámetro de falla (clase de falla singular) o variando de forma independiente algunos parámetros de falla (clase de fallas múltiple).

Adicionalmente se toma una clase sana. La clase sana está compuesta por los patrones de las demás clases que se encuentren dentro de los límites de un motor saludable. Esto se hace para ejemplificar el comportamiento de los motores sin falla.

En la Figura 2 se muestran las clases de falla D1, D2 y D3 dentro del espacio de diagnóstico \bar{Z} . La representación de la clase sana es el círculo de radio $R = 1$.

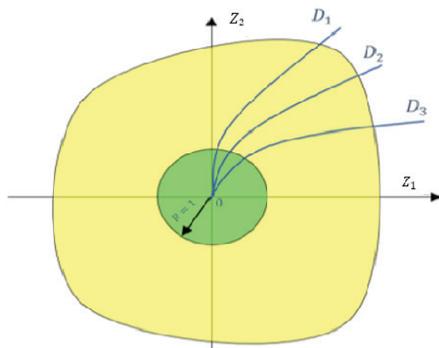


Figura 2. Clases en el espacio diagnóstico \bar{Z}

SEVERIDAD DE FALLAS

El propósito de este trabajo es comparar los dos algoritmos con el criterio de la exactitud en la estimación de severidad de fallas. Para obtener la severidad relativa de falla \bar{S} se decidió contemplar una severidad máxima S_{max} que sirve como referencia. Por lo tanto, en una forma general la severidad se define por:

$$\bar{S} = \frac{S}{S_{max}} \tag{7}$$

Ya que en este estudio se formaron clasificaciones con diferentes tipos de clases, la severidad exacta para clases singulares se especifica por:

$$\bar{S} = \frac{\delta\theta}{\|\delta\theta_{max}\|} \tag{8}$$

Para clases con dos parámetros de falla se calculó por:

$$\bar{S} = \frac{\sqrt{\delta\theta_1^2 + \delta\theta_2^2}}{\sqrt{\delta\theta_{1max}^2 + \delta\theta_{2max}^2}} \tag{9}$$

Para clases con más de dos parámetros de falla se usa como valor máximo el límite $\|\bar{Z}_{Arq}\|$ de la frontera de Arquímedes (Pérez *et al.*, 2017), y la severidad se determinó por:

$$\bar{S} = \frac{|\bar{Z}^*|}{|\bar{Z}_{Arq}|} \tag{10}$$

ESTIMACIÓN DE SEVERIDAD DE FALLAS

En esta sección se presentan cuatro pasos del procedimiento de estimación de severidad de fallas por los algoritmos de enfoques diferentes. El procedimiento se desarrolló en el ambiente de Matlab.

PASO 1

Para determinar y probar los algoritmos estimadores de severidad, así como estimar sus errores en promedio, se simulan grandes cantidades de fallas de todas las clases de la clasificación aceptada. Con este motivo se generan aleatoriamente los vectores $\delta\theta$, se calcula la severidad exacta \bar{S} para cada vector y se determinan los vectores de desviaciones δY^* y \bar{Z}^* con las ecuaciones (5) y (6). Dependiendo qué tipo de fallas presente, la severidad exacta \bar{S}_0 se calcula en el espacio $\delta\theta$ por la ecuación (8) o la ecuación (9). En el espacio \bar{Z} se utiliza la expresión (10). Todo el conjunto de estos vectores Y^* y sus severidades conocidas \bar{S} forman la muestra de entrenamiento de la red neuronal artificial escogida, perceptrón multicapa, el entrenamiento ocurre en el paso tres. De la misma manera se forma la muestra de prueba para validar los algoritmos estimadores de severidad. La única diferencia entre los conjuntos es otra serie de números aleatorios para determinar la severidad de fallas y errores en las desviaciones. La muestra de prueba se usa para estimar parámetros de falla $\hat{\delta\theta}$ en el paso dos y para validar la red de entrenamiento en el paso tres.

PASO 2

Una vez que la muestra de prueba fue creada se usa la matriz inversa en estimar los parámetros de falla para el enfoque uno, según la expresión:

$$\hat{\delta\theta} = H^{-1} \delta Y^* \tag{11}$$

Esta matriz se aplica cuando el número de variables monitoreadas es igual al número de parámetros de fa-

IIa. En el caso de exceso de variables monitoreadas se aplica el método de mínimos cuadrados que resulta en:

$$\hat{\delta\theta} = (H^T H)^{-1} H^T \delta\bar{Y} \quad (12)$$

Con los parámetros encontrados $\hat{\delta\theta}$ se estima la severidad de igual manera que en el cálculo de la severidad exacta. La estimación de la severidad \hat{S} para este espacio de parámetros de falla depende del tipo de clase a la que pertenece el vector $\hat{\delta\theta}$. Si en la clasificación se encuentran clases simples, la estimación dependerá únicamente de un solo parámetro de falla actual y se determinará por la ecuación (8). Sin embargo, si la clase es múltiple con dos parámetros de falla se aplicará la ecuación (9).

Cuando las clases de fallas se construyan por más de dos parámetros $\delta\theta$, como mencionamos anteriormente, la severidad se determinará por la ecuación (10) en el espacio de desviaciones. Por ello, no podemos estimar la severidad directamente para el enfoque uno.

Para resolver este problema se propone utilizar el perceptrón, también en el espacio $\delta\theta$ para estimar la severidad en tales clases. En este caso, los conjuntos de entrenamiento y validación se obtienen por la transformación de las muestras del paso 1 usando las ecuaciones (11) o (12). El error de la estimación de la severidad se define por la expresión simple, en donde \hat{S} representa al valor estimado de severidad de cada uno de los enfoques y S_0 es el valor exacto de la severidad:

$$E_{abs} = \hat{S} - S_0 \quad (13)$$

PASO 3

Dentro del enfoque dos que se opera en el espacio $\delta\bar{Y}$ se usa el perceptrón multicapa para estimar la severidad (Demuth, 2007; Haykin, 2009). El uso de esta red neuronal artificial RNA es la razón principal por la cual formamos dos muestras de datos en el paso uno. La primera muestra se aplica para entrenar a la red y la segunda para validarla. Se utilizó el método de entrenamiento Levenberg-Marquardt (función trainlm de Matlab). Una vez seleccionado el método de entrenamiento se definen otros parámetros de la red que se muestran a continuación. El primer punto que se debe decidir es la cantidad de neuronas en la capa oculta de la RNA. Este tamaño determina la capacidad para aproximar funciones complejas. Otro parámetro para definir es la cantidad de épocas. Esta cantidad representa el número de

iteraciones que realizará el proceso de entrenamiento. Los óptimos valores de estos parámetros se escogen a través de cálculos de ajuste del perceptrón. Después del ajuste, al tener el valor \hat{S} estimado por el perceptrón, se determina el error por la misma ecuación (13) usada dentro del primer enfoque.

PASO 4

El último paso de este proceso es la comparación de la exactitud de los algoritmos estimadores de severidad. La comparación se efectúa usando el error de estimación de la severidad definido por la ecuación (13). Primero se analizan y se comparan las gráficas de errores construidas contra el número de patrones para ambos enfoques. Estas gráficas se comparan para cada clase de la clasificación utilizada. Después se comparan para cada clase los errores medios cuadráticos. La comparación descrita ayudará a concluir cuál de los dos enfoques asegura mayor exactitud de la estimación de severidad de fallas.

RESULTADOS

CONDICIONES DE CÁLCULOS

Para realizar la metodología descrita se ha utilizado un motor de tipo turbo eje, que se puede observar en la Figura 3 publicada en Loboda *et al.* (2019), el cual lleva tres componentes principales: un compresor axial, una turbina de alta presión y una turbina de potencia.

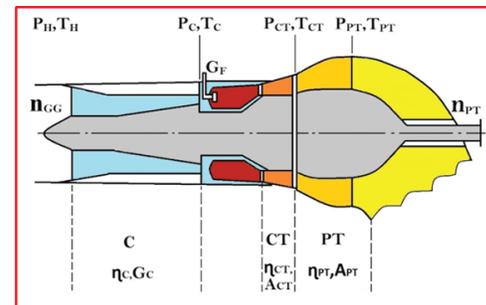


Figura 3. Motor Turboeje con los parámetros utilizados

En las siguientes tablas se pueden observar las mediciones escogidas. En la Tabla 1 se especifican las condiciones ambientales y de operación, donde la velocidad de rotación del compresor es la principal variable controlada. En la Tabla 2 se muestran las variables monitoreadas escogidas para este trabajo.

Tabla 1. Condiciones ambientales y de operación

Núm.	Descripción	Sim
1	Presión ambiental	P_H
2	Temperatura de entrada	T_H
3	Velocidad de rotación de la turbina de potencia	n_{pt}
4	Velocidad del eje del generador de gas	n_{GG}

Tabla 2. Variables monitoreadas

Núm.	Descripción	Sim	$\sigma_{\delta\bar{Y}}$
1	Presión del compresor	P_C	0.0050
2	Presión de la turbina del compresor	P_{Ct}	0.0050
3	Temperatura del compresor	T_C	0.0084
4	Temperatura de la turbina del compresor	T_{Ct}	0.0049
5	Temperatura de la turbina de potencia	T_{pt}	0.0067
6	Flujo de masa del combustible	G_f	0.0067

En la Tabla 3 se observan los parámetros de falla, los cuales representan correcciones a la eficiencia y la capacidad de flujo de cada uno de los componentes del motor.

Los cálculos comparativos se realizaron para tres diferentes clasificaciones especificadas en la Tabla 4. A

cada clasificación le corresponden sus propias muestras de entrenamiento y validación. En la Tabla 5 se muestran los parámetros de la red para cada una de las clasificaciones, estos parámetros son con los que la red trabaja de forma optimizada.

Tabla 3. Parámetros de falla

Núm.	Descripción	Sim
1	Capacidad del compresor	δG_C
2	Eficiencia del compresor	$\delta \eta_C$
3	Capacidad de la turbina de alta presión	δA_{hpt}
4	Eficiencia de la turbina de alta presión	$\delta \eta_{hpt}$
5	Capacidad de la turbina de potencia	δA_{pt}
6	Eficiencia de la turbina de potencia	$\delta \eta_{hpt}$

Tabla 4. Clasificaciones del estado del motor

Clasificaciones	Clases													Clase Sana		
	D ₁	D ₂	D ₃	D ₄	D ₅	D ₆	D ₇	D ₈	D ₉	D ₁₀	D ₁₁	D ₁₂	D ₁₃			
	G_C	η_C	A_{hpt}	η_{hpt}	A_{pt}	η_{pt}	G_C	A_{hpt}	A_{pt}	η_C	η_C	A_{hpt}	η_{hpt}	A_{pt}	η_{pt}	
1	X	X	X	X	X	X										
2	X	X	X	X	X	X	X	X	X							
3		X	X	X	X	X	X	X	X	X	X	X	X	X	X	X

Tabla 5. Parámetros de las redes neuronales, su clasificación y al espacio al que pertenece

Clasificación	Espacio diagnóstico	Cantidad de neuronas	Épocas	Meta mínima
1	Y	40	100	0.000015
2	Y	40	100	0.000015
3	Y	45	250	0.000015
3		50	250	0.000015

CLASIFICACIÓN 1

Esta clasificación está compuesta por seis clases singulares. Para la estimación en el espacio de parámetros de falla, debido a que solo se usan clases con falla simple, se tomó el resultado de la ecuación (7) como el valor estimado de severidad. En el espacio de variables monitoreadas se usó la RNA con los parámetros de la Tabla 5.

En las Figuras 4, 5 y 6 se muestran las estimaciones de severidad en ambos espacios y la severidad actual. En la Figura 4 se observa cómo los dos enfoques tratan de acercarse a la severidad actual. Se puede ver que ambas estimaciones repiten en general el comportamiento de la severidad actual (exacta). Sin embargo, la estimación de espacio δY está más cercana al valor exacto.

En las Figuras 5 y 6, se puede observar el comportamiento de todas las estimaciones de severidad para los espacios $\delta\theta$ (enfoque uno) y δY (enfoque dos). Se pre-

sentan las estimaciones y los valores exactos de severidad para la clase 1, y la relación con las otras cinco clases. En la Figura 5 se muestran los errores de la estimación en el espacio $\delta\theta$. Estos errores tienen el mismo nivel para todas las clases. Al contrario, en la Figura 6 podemos ver los errores de la estimación de severidad en el enfoque uno. Estos errores son más grandes para la clase actual (clase 1) y decrecen para las demás clases. Comparando las Figuras 5 y 6, se puede concluir que el nivel de errores para el enfoque dos es significativamente menor.

La Tabla 6 muestra el error promedio del enfoque uno. Las filas muestran las clases actuales a las que pertenecen los patrones analizados y las columnas son la representación de las clases de estimación de la severidad. Podemos ver que todos los errores promedio son bastante altos y son independientes de la clase actual, pero se mantienen en el mismo nivel según su clase de estimación.

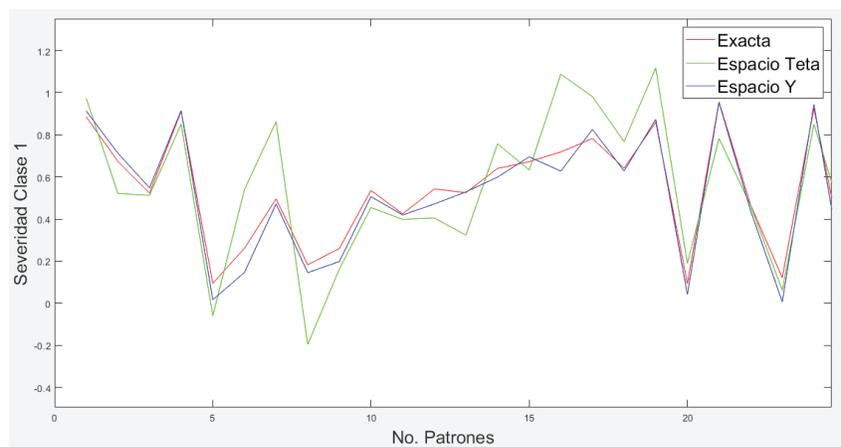


Figura 4. Comportamiento de las severidades para la clase 1 de la clasificación 1

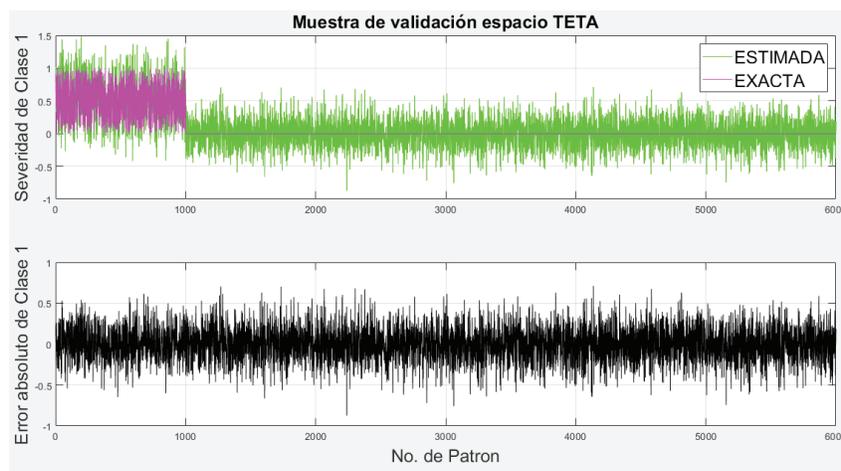


Figura 5. Severidades del enfoque uno, a) valores exactos y estimados, b) errores

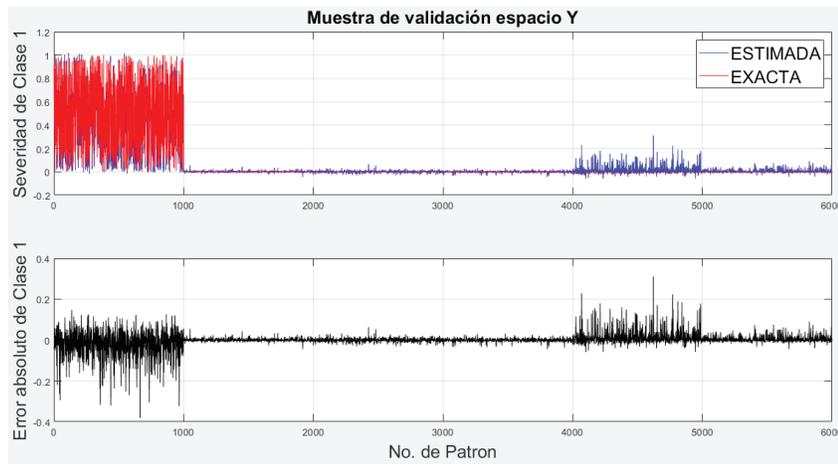


Figura 6. Severidades del enfoque dos, a) valores exactos y estimados, b) errores

La Tabla 7 muestra los errores promedio del enfoque dos. Podemos ver que cada valor de la diagonal es, en general, mayor que otros elementos de la fila. Es decir, los errores de estimación de la severidad de la clase actual de fallas son más grandes que los errores de las demás clases.

Así, en esta clasificación se observó que para el espacio de parámetros de falla sus errores son altos y no

depende de la clase actual, sin embargo, tienen una relación baja con la clase de estimación. Para la severidad estimada en el enfoque dos se encontró que los errores son mucho más pequeños, pero estos dependen de la clase actual. Se puede concluir que en esta clasificación el enfoque uno que opera en el espacio de variables monitoreadas es más preciso.

Tabla 6. Errores promedio del espacio de parámetros de falla

Clases simuladas	Clases estimadas					
	D1	D2	D3	D4	D5	D6
D1	0.2085	0.2173	0.2119	0.2202	0.2182	0.2070
D2	0.3020	0.2954	0.2885	0.2866	0.2921	0.3057
D3	0.2228	0.2258	0.2226	0.2293	0.2300	0.2213
D4	0.2483	0.2546	0.2432	0.2462	0.2457	0.2556
D5	0.1968	0.1961	0.2029	0.2051	0.2019	0.1928
D6	0.4970	0.5158	0.4945	0.5102	0.5270	0.5003

Tabla 7. Errores promedio del espacio de variables monitoreadas

Clases simuladas	Clases estimadas					
	D1	D2	D3	D4	D5	D6
D1	0.0629	0.0068	0.0139	0.0063	0.0439	0.0785
D2	0.0073	0.1454	0.0272	0.1057	0.0074	0.0834
D3	0.0078	0.0116	0.0977	0.0102	0.0052	0.1271
D4	0.0077	0.1440	0.0291	0.1152	0.0076	0.0771
D5	0.0384	0.0068	0.0139	0.0054	0.0586	0.0704
D6	0.0122	0.01239	0.0332	0.0077	0.0115	0.2706

CLASIFICACIÓN 2

Esta clasificación está compuesta por seis clases singulares y tres clases con falla múltiple con dos parámetros de falla. Como se mencionó anteriormente, para la estimación de severidad en el espacio diagnóstico $\delta\theta$ en clases con un parámetro de falla se tomó la ecuación (8) como en la clasificación anterior. Sin embargo, en las clases con dos parámetros de falla se aplicó la ecuación (9). Para estimar la severidad en el espacio δY , de la misma manera que en la clasificación anterior, se usó la misma red neuronal artificial, pero con nuevos parámetros óptimos (Tabla 5).

La Figura 7 ejemplifica los resultados de los dos enfoques para algunos patrones de la clase 7. Podemos ver que las severidades estimadas en los dos espacios generalmente se aproximan a la exacta, pero con errores mayores que se observaron anteriormente.

Las Figuras 8 y 9 exponen el comportamiento de las estimaciones por los enfoques uno y dos y los errores correspondientes. Se presentan las severidades exactas para los patrones de la clase 7 y para todas las nueve clases, las estimaciones y los errores. Se observa en la

Figura 8 que los errores de estimación del enfoque uno son mayores para la clase actual 7 y las clases 1 y 2 formados por los mismos parámetros de falla que la clase 7. Para las demás clases los errores son prácticamente iguales. Los errores de todas las clases excepto la clase 7 son positivos debido a la ecuación (9). En la Figura 9 se puede ver que los errores del enfoque dos son más grandes para las mismas clases 1, 2 y 7, y positivos para las clases diferentes de la clase 7.

Comparando las Figuras 8 y 9, concluimos que en general el enfoque dos es más exacto.

La Tabla 8 muestra los errores promedio de la estimación del enfoque uno para esta clasificación. Esta tabla tiene las mismas características que las anteriores, en donde las filas muestran las clases actuales a las que pertenecen los patrones analizados y las columnas son la representación de las clases de estimación de la severidad. Podemos ver que los errores promedio son altos y dependientes de la clase actual, pero se mantienen en el mismo nivel según su clase de estimación. Además, en las clases 7, 8 y 9 el error promedio más alto se encuentra en los parámetros de falla simple que completan a la clase con falla múltiple.

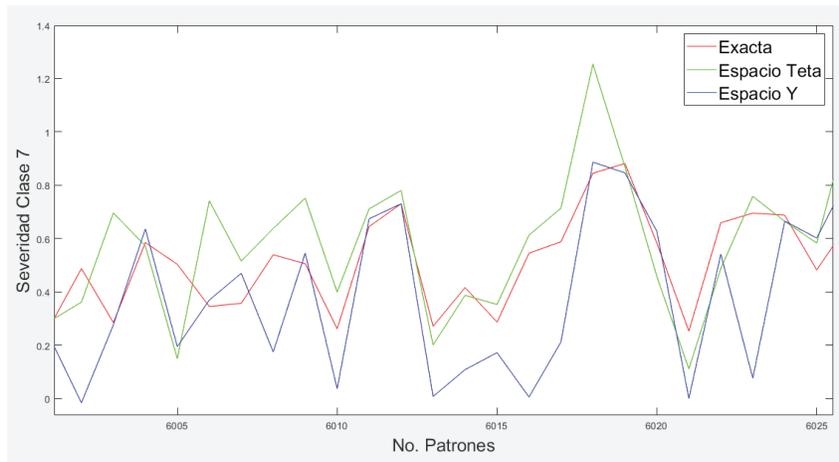


Figura 7. Comportamiento de las severidades para la clase 7 de la clasificación 2

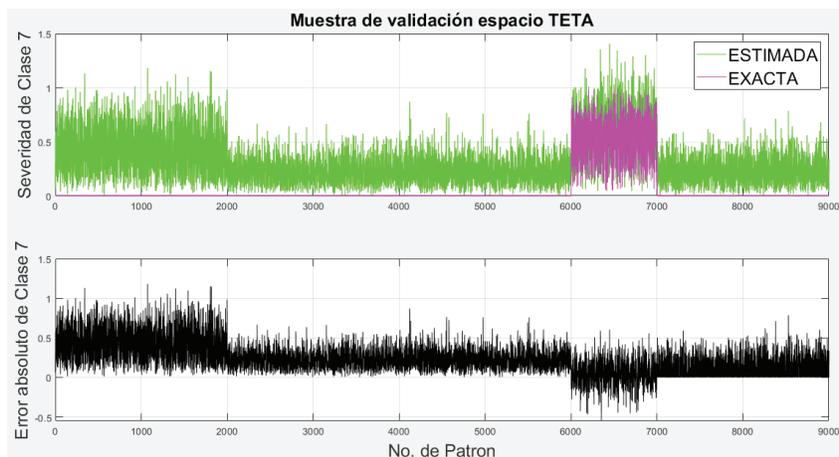


Figura 8. Severidades del enfoque uno, a) valores exactos y estimados, b) errores

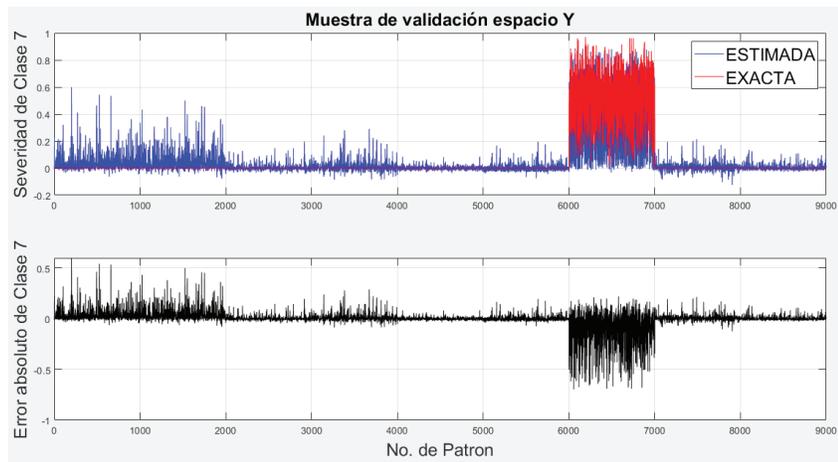


Figura 9. Severidades del enfoque dos, a) valores exactos y estimados, b) errores

Tabla 8. Errores promedio del espacio de diagnóstico de parámetros de falla para la clasificación 2

Clases simuladas	Clases estimadas								
	D1	D2	D3	D4	D5	D6	D7	D8	D9
D1	0.2106	0.2000	0.2083	0.2207	0.2154	0.2119	0.6034	0.5699	0.6514
D2	0.2742	0.2863	0.2772	0.2944	0.2841	0.2828	0.6034	0.5699	0.6514
D3	0.2283	0.2195	0.2210	0.2370	0.2249	0.2316	0.6034	0.5699	0.6514
D4	0.2323	0.2442	0.2323	0.2467	0.2431	0.2406	0.6034	0.5699	0.6514
D5	0.1974	0.1872	0.2051	0.2066	0.2072	0.1994	0.6034	0.5699	0.6514
D6	0.4897	0.5207	0.5010	0.4932	0.4991	0.5127	0.6034	0.5699	0.6514
D7	0.4875	0.4800	0.2452	0.2602	0.2521	0.2499	0.1622	0.1744	0.1872
D8	0.2303	0.2322	0.4619	0.4712	0.2342	0.2361	0.2030	0.1251	0.1121
D9	0.3734	0.3912	0.3828	0.3781	0.5601	0.5643	0.2343	0.3196	0.2457

La Tabla 9 en el mismo formato que la tabla previa muestra los errores promedio del enfoque dos. Podemos ver que el comportamiento de la clasificación anterior se mantiene, dentro de cada fila el valor de la diagonal de la matriz es, en general, mayor que otros

elementos de la fila. Es decir, los errores de estimación de la severidad de la clase actual de fallas son más grandes que los errores de las demás clases. En comparación con la clasificación anterior, se puede ver que la misma diagonal mencionada, sube su nivel de error.

Tabla 9. Errores promedio del espacio de diagnóstico de variables monitoreadas para la clasificación 2

Clases simuladas	Clases estimadas								
	D1	D2	D3	D4	D5	D6	D7	D8	D9
D1	0.1160	0.0119	0.0152	0.0095	0.0405	0.0691	0.0779	0.0090	0.0565
D2	0.0103	0.1929	0.0271	0.0908	0.0095	0.0671	0.0832	0.0218	0.0128
D3	0.0136	0.0166	0.1362	0.0128	0.0095	0.1019	0.0257	0.0483	0.0162
D4	0.0069	0.1186	0.0262	0.2051	0.0067	0.0652	0.0420	0.1156	0.0100
D5	0.0387	0.0086	0.0114	0.0090	0.2516	0.0707	0.0138	0.0082	0.2223
D6	0.0138	0.0160	0.0367	0.0097	0.0125	0.2981	0.0205	0.0107	0.0499
D7	0.1789	0.1461	0.0404	0.0394	0.0188	0.0773	0.2117	0.0272	0.0313
D8	0.0067	0.0535	0.1394	0.1856	0.0071	0.0258	0.0378	0.1785	0.0070
D9	0.0409	0.0086	0.0105	0.0093	0.2617	0.1038	0.0184	0.0088	0.2791

Los resultados que se obtuvieron para esta clasificación son un poco distintos a los de la anterior. La mayor diferencia se encuentra en el espacio de parámetros de falla; los resultados muestran que los errores de las clases actuales 7, 8 y 9 tienen una relación con las clases de estimación formadas por los mismos parámetros de falla. Por ejemplo, la clase 7 que se muestra en la Figura 8 se construye por dos parámetros de falla y los errores de esta clase tienen correlación con las clases 1 y 2 formadas por los mismos parámetros de falla. En el espacio de variables monitoreadas se observó que el comportamiento es el mismo, los errores dependen de la clase a la que pertenecen. En general se puede observar que los errores siguen siendo mayores en el espacio de parámetros de falla.

CLASIFICACIÓN 3

Esta clasificación está compuesta por seis clases con falla simple, tres clases con falla múltiple con dos parámetros de falla, tres clases de falla múltiple con cuatro parámetros y una clase de motor sano.

Como se mencionó anteriormente, cuando las clases de fallas se construyen por más de dos parámetros $\delta\theta$ la severidad se determinará por la ecuación (10) en el espacio de desviaciones. Por ello, para el enfoque uno ahora no podemos estimar analíticamente la severidad. Para resolver este problema se propone utilizar el per-

ceptrón para estimar la severidad no solo para el enfoque dos sino también para el enfoque uno.

En la Figura 10 se puede observar cómo las severidades estimadas de ambos enfoques se intentan aproximar a la severidad exacta para la clase 10. Esta figura presenta algunos patrones de la clase 10 que es la primera clase con falla múltiple con 4 parámetros de falla. Aquí se observa bien que el margen de error de ambos enfoques es mayor que para las clasificaciones previas.

Las Figuras 11 y 12 ilustran todos los patrones de la clase 10 presentando los valores exactos de la severidad y las estimaciones por el enfoque uno y enfoque dos para las 12 clases. Como antes, los errores de estimación en la Figura 11 (enfoque uno) dependen de la clase actual. Sin embargo, a diferencia con las clasificaciones anteriores, los errores del enfoque uno ahora aumentaron. Esto se debe a dos situaciones: La primera es que la adición de 4 clases nuevas inclusive una clase de motor sin fallas aumentó la complejidad del reconocimiento de las fallas. La segunda se debe al cambio de técnica en la estimación de la severidad en el espacio de parámetros de falla. En la Figura 12, podemos ver los errores de la estimación del enfoque dos. A diferencia de las clasificaciones anteriores, el nivel de errores es mayor. Este nivel ahora es cercano al nivel de errores del enfoque uno (Figura 11). Además, el comportamiento de las estimaciones de severidad por ambos enfoques parece similar, que se explica por la misma red neuronal artificial usada.

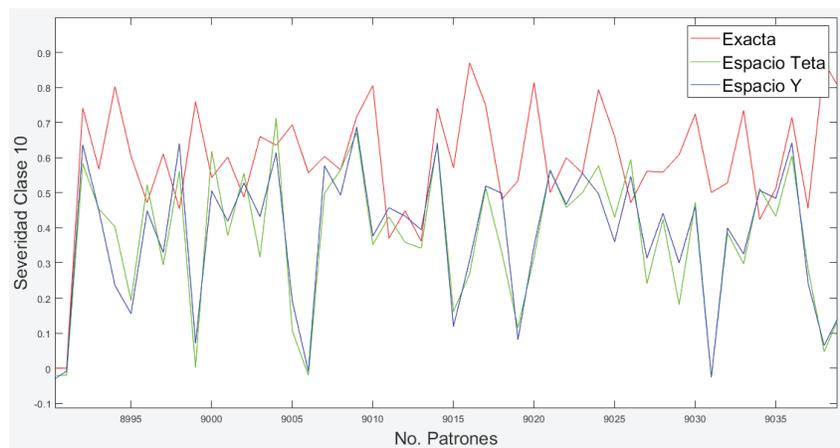


Figura 10. Comportamiento de las severidades para la clase 10 de la clasificación 3

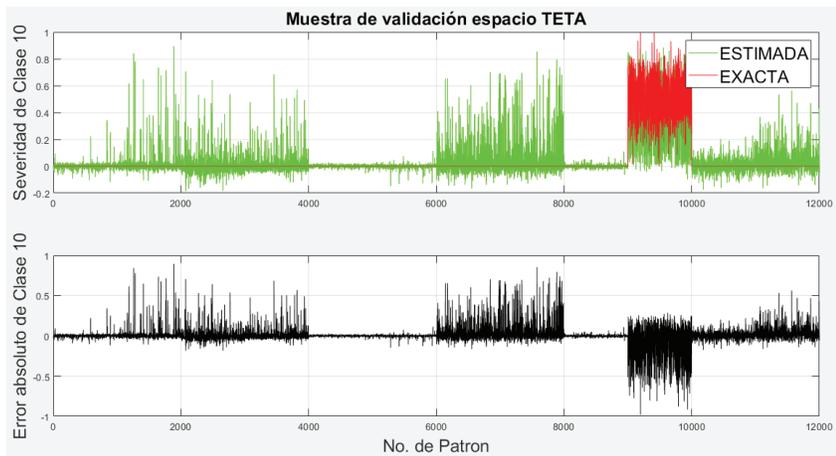


Figura 11. Severidades del enfoque uno, a) valores exactos y estimados, b) errores

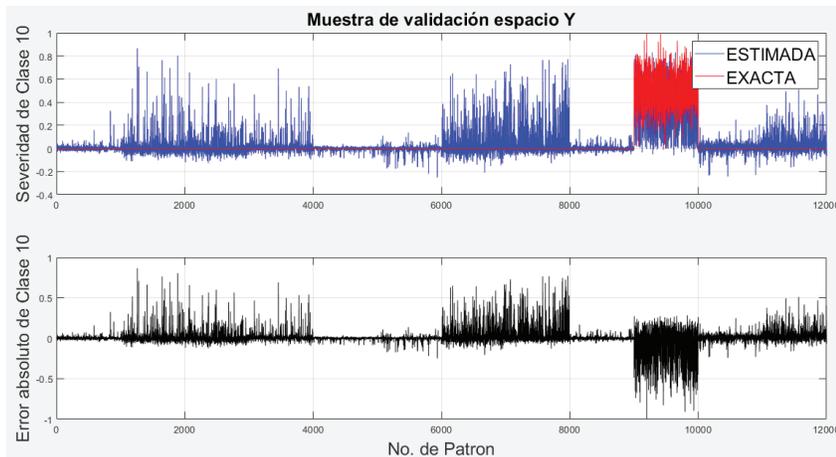


Figura 12. Severidades del enfoque dos, a) valores exactos y estimados, b) errores

La Tabla 10 muestra los errores promedio que se obtuvieron del enfoque uno (espacio de los parámetros de falla). Podemos ver que el comportamiento de los errores promedio es diferente a las clasificaciones anteriores. Dentro de cada fila el valor de la diagonal de la matriz presentada es, en general, mayor que otros elementos de la fila. Es decir, los errores de estimación de la severidad de la clase actual son más grandes que los errores de las demás clases.

La Tabla 11 muestra los errores promedio que se obtuvieron del enfoque dos. Podemos ver que se mantiene el comportamiento observado para las clasificaciones anteriores: dentro de cada fila el valor de la diagonal de la matriz es, en general, mayor que otros elementos de la fila. Es decir, los errores de estimación de la severidad de la clase actual son más grandes que los errores de las demás clases. En comparación con las clasificaciones anteriores, se puede ver que el nivel de errores del enfoque dos aumentó. Comparando las Tablas 9 y 10, podemos concluir que en general los errores del enfoque uno ahora igualan a los del enfoque dos. El mejoramiento del enfoque uno se explica por el uso de la red

neural artificial en este enfoque aplicado para la clasificación 3.

Comparando las Tablas 6, 8 y 10 que corresponden al enfoque uno, podemos concluir que el aumento del número de clases causa un incremento de errores de la estimación de severidad. La misma conclusión sigue de la comparación de las Tablas 7, 9 y 11 del enfoque dos. Esta tendencia mencionada es natural y se explica por aumento del número de parámetros que estimamos con el mismo volumen de datos de entrada. Lo mismo siempre sucede con las probabilidades de reconocimiento de fallas, sus errores crecen cuando incrementa el número de fallas consideradas.

Tabla 10. Errores promedio del espacio de diagnóstico de enfoque uno para la clasificación 3

Clases simuladas	Clases estimadas												
	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13
D1	0.1821	0.0115	0.0220	0.0106	0.0386	0.0151	0.0316	0.0156	0.0794	0.0169	0.0870	0.0530	0.0374
D2	0.0161	0.2364	0.0206	0.1054	0.0130	0.0159	0.1366	0.0634	0.0226	0.0425	0.0383	0.0371	0.0436
D3	0.0201	0.0189	0.2284	0.0167	0.0131	0.0162	0.0501	0.0680	0.0254	0.0262	0.0170	0.0614	0.0608
D4	0.0149	0.1277	0.0241	0.2181	0.0091	0.0171	0.0653	0.1950	0.0186	0.0505	0.0224	0.0626	0.0325
D5	0.0482	0.0175	0.0181	0.0168	0.2587	0.0185	0.0188	0.0139	0.3181	0.0166	0.0411	0.0462	0.0387
D6	0.0291	0.0118	0.0206	0.0182	0.0278	0.7443	0.0257	0.0211	0.0815	0.0141	0.0426	0.0552	0.3256
D7	0.1376	0.1559	0.0219	0.0371	0.0152	0.0143	0.3822	0.0421	0.0283	0.0682	0.1435	0.0769	0.0390
D8	0.0154	0.0506	0.1697	0.2045	0.0078	0.0111	0.0497	0.4048	0.0160	0.0844	0.0206	0.0739	0.0306
D9	0.0427	0.0123	0.0161	0.0166	0.2367	0.0593	0.0222	0.0156	0.4642	0.0144	0.0717	0.0655	0.0709
D10	0.0325	0.0842	0.0668	0.0861	0.0126	0.0127	0.1049	0.1451	0.0198	0.2935	0.0409	0.0936	0.0314
D11	0.1361	0.0415	0.0225	0.0258	0.0550	0.0209	0.1321	0.0262	0.1398	0.0327	0.4025	0.1095	0.0417
D12	0.0400	0.0305	0.0850	0.0474	0.0475	0.0241	0.0837	0.0998	0.1103	0.0831	0.1389	0.2972	0.0466
D13	0.0230	0.0206	0.0508	0.0233	0.0275	0.1080	0.0363	0.0240	0.0514	0.0111	0.0221	0.0279	0.3413

Tabla 11. Errores promedio del espacio de diagnóstico de enfoque dos para la clasificación 3

Clases simuladas	Clases estimadas												
	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13
D1	0.1933	0.0185	0.0202	0.0133	0.0412	0.0163	0.0370	0.0190	0.0730	0.0172	0.0910	0.0530	0.0298
D2	0.0142	0.2381	0.0284	0.1016	0.0138	0.0253	0.1308	0.0625	0.0205	0.0449	0.0405	0.0423	0.0303
D3	0.0172	0.0212	0.2119	0.0150	0.0119	0.0148	0.0442	0.0555	0.0242	0.0256	0.0206	0.0539	0.0635
D4	0.0132	0.1306	0.0227	0.2235	0.0118	0.0272	0.0649	0.1925	0.0197	0.0564	0.0211	0.0596	0.0219
D5	0.0426	0.0209	0.0202	0.0142	0.2618	0.0174	0.0216	0.0193	0.3156	0.0150	0.0492	0.0403	0.0314
D6	0.0201	0.0238	0.0290	0.0201	0.0136	0.7353	0.0306	0.0244	0.0647	0.0177	0.0348	0.0504	0.3481
D7	0.1379	0.1537	0.0246	0.0411	0.0144	0.0194	0.3825	0.0380	0.0314	0.0722	0.1415	0.0833	0.0375
D8	0.0116	0.0535	0.1564	0.2024	0.0100	0.0203	0.0499	0.4009	0.0227	0.0821	0.0199	0.0739	0.0249
D9	0.0379	0.0182	0.0148	0.0149	0.2328	0.0458	0.0208	0.0178	0.4628	0.0148	0.0704	0.0549	0.0668
D10	0.0296	0.0777	0.0635	0.0754	0.0110	0.0222	0.1087	0.1491	0.0247	0.289	0.0434	0.0889	0.0260
D11	0.1328	0.0449	0.0271	0.0253	0.0517	0.0254	0.1280	0.0233	0.1413	0.0306	0.4059	0.1139	0.0428
D12	0.0367	0.0312	0.0811	0.0441	0.0493	0.0293	0.0813	0.1016	0.1118	0.0826	0.1470	0.2971	0.0492
D13	0.0220	0.0261	0.0563	0.0203	0.0232	0.0994	0.0372	0.0269	0.0559	0.0144	0.0191	0.0299	0.3386

CONCLUSIONES

En este trabajo se estudió un problema todavía poco investigado, el problema de la estimación de severidad de fallas de turbinas de gas. Aunque hay algunos estudios de la severidad, no se encuentran trabajos completamente dedicados a este problema. En el área del diagnóstico de turbinas de gas se mantienen dos enfoques principales: enfoque uno, que opera en el espacio de parámetros de falla, y el enfoque dos, que hace diagnóstico en el espacio de variables monitoreadas. Este trabajo evalúa la calidad de estimación de la severidad por los algoritmos de cada enfoque.

Con el fin de saber con certeza desde qué espacio de diagnóstico es más exacto se realizaron tres diferentes clasificaciones. Para las dos primeras, los resultados demostraron que en el espacio de variables monitoreadas se obtuvo una mejor exactitud. Por otro lado, en la tercera clasificación, en donde se usó por primera vez la técnica de redes neuronales artificiales para el enfoque uno, la exactitud de los enfoques es básicamente la misma. Así, podemos concluir que usualmente el enfoque dos tiene una mayor exactitud en la estimación de severidad de fallas, aunque la integración de la red neuronal artificial en el enfoque uno permite mejorarlo considerablemente subiendo la

exactitud de este enfoque hasta la exactitud del enfoque dos.

REFERENCIAS

- Amare D. F., Aklilu, T., Syed I. & Konstantinos, G. (2019). A review on gas turbine gas-path diagnostics: State-of-the-art methods, challenges and opportunities. *Aerospace*, Vol. 6 (7), 1-53. <https://www.mdpi.com/2226-4310/6/7/83>
- Boyce, M. P. (2002). *Gas Turbine Engineering Handbook*. USA: Gulf Professional Publishing.
- Butler, S. P. (2006). An assessment methodology for data-driven and model based techniques for engine health monitoring. IGTI/ASME Turbo Expo 2006, May 8-11, Barcelona, 9 p.
- Cruz-Manzo, S. (2018). Analysis of performance of a twin-shaft gas turbine during hot-end damage in the gas generator turbine. ASME Turbo Expo 2018, 8p.
- Davison, C. R. *et al.* (2008). Review of metrics and assignment of confidence intervals for health management of gas turbine engines. IGTI/ASME Turbo Expo 2008, June 9-13, Berlin, 11 p.
- Demuth, H. B. (2007). *Neural Network Toolbox 5 User's Guide*. The MathWorks, Inc.
- Donald, S. L. (2010). *Propulsion Diagnostic Method Evaluation Strategy (ProDiMES) User's Guide*. Cleveland: Glenn Research Center.
- Donald, S. L., Sebastien, B., Olivier, L. & Xiaodong, F. (2013). Aircraft engine gas path diagnostic methods: Public benchmarking results. *Journal of Engineering for Gas Turbines and Power*, Vol. 136 (4). <https://doi.org/10.1115/1.4025482>
- Ganguli, R. (2013). *Gas turbine diagnostics*. NW: CRC Press, Taylor & Francis Group.
- Gasturb. (2021). Recuperado el 29 de junio de 2021 de <https://www.gasturb.de/>
- Giampaolo, A. J. (1997). *Gas turbine handbook*. USA: The Fairmont Press.
- Haykin, S. (2009). *Neural network and learning machines*. 3a ed. Ontario, Canada: Pearson Prentice Hall.
- Jardine, A. L. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20 (7), 1483-1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
- Kamboukos, Ph. & Mathioudakis, K. (2005). Comparison of linear and non-linear gas turbine performance diagnostics. *Journal of Engineering for Gas Turbines and Power*, 127 (1), pp. 49-56. <https://doi.org/10.1115/1.1788688>
- Loboda, I. (2010). Gas turbine condition monitoring and diagnostics en: *Gas turbines*. Croacia, Gurrappa Injeti, Sciyo. pp. 119-144. <https://www.intechopen.com/chapters/12088>
- Loboda, I. *et al.* (2019). Comparative analysis of two gas turbine diagnosis approaches. ASME Turbo Expo 2019: Turbomachinery Technical Conference & Exposition, Phoenix, USA, June 17-21, ASME Digital Collection, Volume 6, pp. V006T05A025-1 - V006T05A025-12.
- Mikael-Stenfelt, V. Z. (2019). Automatic gas turbine matching scheme adaptation for robust GPA diagnostics. ASME Turbo Expo 2019: Turbomachinery Technical Conference & Exposition, Phoenix, USA, June 17-21, 9 p.
- Ogaji, S. *et al.* (2003). Gas path fault diagnosis of a turbofan engine from transient data using artificial neural networks. IGTI/ASME Turbo Expo 2003, June 16-19, Atlanta, Georgia, USA, 10 p.
- Pérez-Ruiz, J. L., Loboda, I., Mir-Zárate L. A., Toledo-Velázquez M. & Polupan, G. (2017). Evaluation of gas turbine diagnostic techniques under variable fault conditions. *Advances in Mechanical Engineering*. 9 (10), 1-16. <https://doi.org/10.1177/1687814017727471>
- Rao, B. K. (1996). *Handbokk of condition monitoring*. U.K: Elsevier Advanced Technology.
- Soares, C. (2007). *Gas turbines: A handbook of air, land and sea applications*. USA: Butterworth-Heinemann.
- Stamatis, A.G., Mathioudakis, K. & Papailiou, K.D. (1990). Adaptive Simulation of Gas Turbine Performance. *Journal of Engineering for Gas Turbines and Power-transactions of The Asme*, 112, 168-175. <https://doi.org/10.1115/1.2906157>
- Steven, W. & Butler, K. R. (2006). An assessment methodology for data-driven and model based techniques for engine health monitoring. IGTI/ASME Turbo Expo 2006, May 8-11, Barcelona, Spain, 9 p.
- Volponi, A. J., DePold, H., Ganguli, R. & Daguang, C. (2003). The use of kalman filter and neural network methodologies in gas turbine performance diagnostics: A comparative study. *ASME Journal of Engineering for Gas Turbines and Power*, 125 (4), 917-924. <https://doi.org/10.1115/1.1419016>
- Volponi, A. J. (2014). Gas turbine engine health management: Past, Present, and Future Trends. *Journal of Engineering for Gas Turbines and Power-transactions of The Asme*, 136, 051201. <https://doi.org/10.1115/1.4026126>

Cómo citar:

Blancas-Hernández, G., Loboda, I., Gonzales-Castillo, I. & Rendón-Cortés, K. A. (2022). Comparación entre algoritmos estimadores en la severidad de fallas para los sistemas del diagnóstico de turbinas de gas. *Ingeniería Investigación y Tecnología*, 23 (01), 1-14. <https://doi.org/10.22201/fi.25940732e.2022.23.1.001>