

Estimación de variables determinantes en la caída de presión asociada al sistema de filtros de una turbina a gas

Estimation of determinant variables in the pressure drop associated with the filter system of a gas turbine

MSc. Manuel Marqués-Rodríguez^I, marqueses@cantv.net, Dr. Luis Oscar Oliva-Ruiz^{II}

^IInstituto Universitario de Tecnología “Dr. Federico Rivero Palacio”, Departamento de Procesos Químicos, Caracas, Venezuela; ^{II}Universidad de Oriente, Santiago de Cuba, Cuba.

Resumen

Se desarrolla una metodología para obtener una aproximación, a través de redes neuronales artificiales, que permita estimar la caída de presión en el sistema de filtros para aire, a partir de datos operatorios para mejorar la disponibilidad de una unidad de generación eléctrica. Se parte de 28 variables predictivas y una variable objetivo, en base a un análisis de sensibilidad se disminuye el número de variables predictivas y se concreta el diseño de la estructura multicapa de nodos. Se determina cuántas y cuáles variables predictivas son necesarias, para un ajuste con un coeficiente de determinación mayor a 0,99 encontrando que una, es la cantidad mínima necesaria, la estructura final es 1-12-1 con un coeficiente de determinación de 0,997 40. El modelo desarrollado permite simular dicha variable y provee una herramienta para el incremento de la disponibilidad operacional en las unidades de generación, en lo que respecta al filtrado de aire.

Palabras clave: simulación, termoeléctrica, turbina a gas, red neuronal.

Abstract

A methodology was developed to approximate, through artificial neural networks to estimate the pressure drop in the system of air filters, from operative data and increase the availability of the electric generation unit. It starts with 28 predictor variables and target variable, based on a sensitivity analysis of the number of predictors is reduced and the design of the structure of the multilayer perceptron concrete. It determines how many and which predictor variables are necessary for a fit with a coefficient of determination more than 0.99 found that one is the minimum amount required, the final structure is 1-12-1 with a coefficient of determination of 0,997 40. The model developed to simulate the variable and provides a powerful tool for increasing the operational availability of generation units in regard to air filtration.

Keywords: simulation, thermoelectric, gas turbine, neural net.

Introducción

Según información de la Corporación Eléctrica Venezolana, para marzo del año 2010 todas las plantas generadoras del sistema eléctrico nacional (SEN)

venezolano se encuentran totalmente interconectadas. No obstante, inclusive bajo la condición de que todas operen a su máxima capacidad, no logran cubrir la demanda en todo el territorio nacional, pues existe un déficit de 800 MW, cuyo efecto es perceptible a través de los programas de racionamiento del fluido eléctrico iniciados en el año 2009 y que aún persisten.

Dicho racionamiento crea una situación de operación a condición crítica, por lo que la falta de disponibilidad de manera programada o no, de varias unidades, da origen a una variación repentina y significativa en la potencia generada con respecto a la potencia solicitada en el SEN. Entre las causas que pueden provocar la salida de servicio de varias unidades al mismo tiempo, se tienen las paradas por mantenimiento, que al coincidir producen los efectos ya mencionados.

En una unidad de generación, las paradas por mantenimiento al sistema de filtros se realizan a partir de un número de horas señalado por el proveedor del turbogenerador; sin embargo dicho criterio es impreciso pues no considera los cambios climáticos particulares a cada región, por lo que un criterio más preciso es la caída de presión máxima, señalada por el fabricante de los filtros de reposición, criterio que también es impreciso pues a pesar que los filtros son sustituidos por un similar, con las mismas especificaciones técnicas, la realidad es que en la práctica la caída de presión máxima permisible, cambia con cada lote que se compra. Lo que da lugar a que la caída de presión medida no constituya un criterio concluyente respecto a la condición de los filtros y por ende a funcionamientos deficientes en estos, con sustitución o falla de estos, antes de lo esperado, cuando su vida útil aún no se ha completado.

Siendo el cambio de los filtros para el aire debido a la obstrucción de estos, la causa que con más frecuencia motiva la parada de una unidad y provoca la coincidencia de estas según los señalamientos del fabricante (Siemens), se hace necesario discriminar la prioridad en el orden de parada de las unidades, para tal fin, se desarrolla una metodología que permita estimar la caída de presión en el sistema de filtros de una unidad generadora a partir de variables operatorias,

la cual en trabajo posterior será acoplada a la técnica de “análisis en la ruta del gas”, conocida por sus siglas en inglés como GPA (gas path analysis).

Estimar la variable asociada a la obstrucción de los filtros, en un sistema tan complejo como lo es una unidad de generación, puede requerir extensos y laboriosos desarrollos teóricos, además de simplificaciones que pueden llevar a resultados inexactos, sin embargo a partir de la literatura consultada se tiene, que es posible realizar el modelado de un proceso como éste, sin necesidad de desarrollar las ecuaciones teóricas que rigen su comportamiento.

Leahy *et al* (2008) /1/ plantean el uso de redes neuronales artificiales (RNA) en la predicción de una variable, destacan la importancia de la selección apropiada de las variables predictivas, evitando una cantidad excesiva y redundante de estas y que la selección se puede guiar a partir del conocimiento del sistema físico a modelar. En el presente trabajo se combinan el conocimiento de las características operativas del sistema y el análisis de sensibilidad como criterios de selección.

Tung en el año 2009 /2/ Indica que la calidad en la generación está relacionada con el sistema de mantenimiento, tal que permita mayor disponibilidad en el trabajo de la unidad generadora. Si se establece como criterio de parada de las unidades en lo que se refiere al mantenimiento en el sistema de filtros para el aire, una variable asociada a la operación de estos, como la caída de presión, puede ser posible predecir el orden de parada de las unidades de generación, con lo que se tendrá mayor disponibilidad en estas.

Fast *et al* en el año 2009 /3/ desarrollan un modelo multipropósito para turbinas industriales mediante redes neuronales artificiales, señalan el uso de solo tres variables predictivas, hacen la selección de los datos en base al conocimiento sobre la operación y a los datos disponibles, remueven de estos la información asociada a la operación transitoria. En el presente trabajo no se remueven los datos asociados a la operación no estacionaria, por otro lado destaca que no reseñan el valor de algún parámetro general para la calidad del modelo, aunque

presentan de forma gráfica el error en el ajuste, el cual se considera elevado, el mismo puede ser debido al empleo de una cantidad insuficiente de variables predictivas.

Bartolini *et al* en el año 2011 /4/ elaboran un modelo en redes neuronales artificiales para describir el rendimiento de una unidad de generación a gas, destaca que eliminan de los datos valores: fuera del rango de medición y transitorios y que además completan los datos faltantes para luego normalizar todos los datos, trabajan con una cantidad fija de variables predictivas para elaborar cuatro modelos cada uno asociado a una variable, con un rendimiento en el peor de los casos con respecto al coeficiente de determinación de 0,9962. Estos autores obtienen un elevado rendimiento para sus cuatro modelos que atribuyen en parte al tratamiento de los datos, sin embargo no hay un caso de control sin este tratamiento que permita comparar. En el presente trabajo se logran mejores rendimientos sin este tipo de tratamiento a los datos.

Melesse *et al* (2011) /5/ trabajan en la predicción de una variable mediante la técnica de RNA en particular el tipo multicapa de nodos (*multilayer perceptron*, MLP), usan varios grupos de variables predictivas y distribuciones de los datos, obteniendo un coeficiente de determinación (R^2) de 0,97 en el mejor de los casos, también mediante la comparación de los resultados con cada grupo de variables predictivas, logran establecer el grado de influencia de estas sobre la variable objetivo. En el presente trabajo se evalúa la influencia una por una de cada variable predictiva, metodología que permite establecer de manera más exacta la influencia asociada a una variable.

Tan *et al* (2012) /6,7/ utilizan redes neuronales como herramienta para evitar fallas en la operación de un equipo y mantenerla segura y confiable, para lo cual desarrollan un modelo con RNA de cuatro capas, a partir de varios grupos de variables formados a partir de once variables predictivas y una variable objetivo. Sin embargo no hacen ensayos con todas las combinaciones de variables posibles, por lo que en teoría es posible obtener un mejor rendimiento al

señalado, a diferencia del presente trabajo en el que se discrimina una por una la importancia de cada variable.

Barad *et al*/en el año 2012 /7/ señalan que en el monitoreo de motores tipo turbina de gas, para un buen funcionamiento mecánico y la procura de una buena eficiencia, se requiere un modelo para manejar los datos y señalan que el método más reseñado es con redes neuronales artificiales, teniendo en cuenta la complejidad del sistema físico objeto de estudio. De lo anterior se puede afirmar que este método constituye, como herramienta matemática, una alternativa capaz de modelar la caída de presión en los filtros para aire, a partir de las variables operatorias correspondientes.

Dicha herramienta se encuentra respaldada con su presencia en distintos programas, tal como el Matlab /8/, lo que facilita su aplicación, pues el investigador no tiene que elaborar el software, además es notoria, por tener la capacidad para representar funciones en sistemas que responden a principios físicos claramente establecidos /9, 10/.

Por lo tanto, constituye el objetivo del presente trabajo: desarrollar una metodología para obtener una aproximación, a través de redes neuronales artificiales, que permita estimar la caída de presión en los filtros para el aire presentes en el sistema de admisión, a partir de datos operatorios. Para mejorar la disponibilidad de la unidad generadora al acoplar está en trabajo posterior, a la técnica GPA. (amerita repetirse gas path analysis).

El desarrollo de dicha metodología implica varios procedimientos, que en orden de ocurrencia son: preselección de las variables de trabajo, reducción de la cantidad variables predictivas, diseño del muestreo y el diseño de la red neuronal. En el presente trabajo se presentan resultados parciales en las diferentes etapas del procedimiento, el enfoque sistémico dado a este, sienta las bases para la selección de los parámetros que se requieren para el desarrollo del modelo.

Materiales y métodos

Con respecto al diseño del experimento, considerando que se cuenta con registros históricos operativos de una unidad de generación de 104,4 MW (ISO), se debe en primer lugar realizar una pre selección de las variables asociadas al objeto de estudio, para luego realizar el diseño del muestreo y por último el diseño de la red neuronal artificial.

Se procede a una preselección de las variables asociadas al objeto de estudio, en correspondencia al objetivo del presente trabajo y con el apoyo de herramientas estadísticas, según criterio de expertos mediante la técnica de tormenta de ideas, con lo que se establece la cantidad de 29 variables, según se muestra en la tabla 1, de las cuales 28 son predictivas y una se corresponde a la variable objetivo: diferencia de presión causada por el filtro en la línea de aire (DP1).

El diseño del muestreo se inicia con la recopilación en una unidad de generación de 104,4 MW (ISO) de datos históricos correspondientes a las 29 variables preseleccionadas, por un periodo de tiempo que se corresponde a un ciclo de trabajo de los filtros, con lo que se tiene un conjunto de 3458 mediciones de las 29 variables asociadas al objeto de estudio, durante 1729 h a intervalos de 30 min, para un total de 100282 datos.

Con respecto a los datos, el sistema de adquisición existente en la central termoeléctrica, descarta cualquier valor que se encuentre fuera del rango de trabajo o fuera del margen de tolerancia del medidor. Adicionalmente se sabe que la data recogida viene directamente del proceso en campo y se asume que es estable entre mediciones consecutivas.

El diseño de la red neuronal parte de la selección del tipo de RNA, en este caso se trabaja con el MLP por ser la más usada en artículos científicos con aplicaciones técnicas a nivel mundial según Maier *et al* /11/ y ser ampliamente conocida como estimador universal según Hontoria *et al* /12/. Esta tendrá una arquitectura elemental, que consta de tres partes, la sección de entrada, la capa intermedia y capa de salida. Una estructura con estas características se muestra

en la figura 1. En la sección de entrada se ubican los nodos correspondientes a las variables de entrada, cada nodo tiene conexión con todas las neuronas de la siguiente capa. La capa intermedia, con un número de neuronas a ser establecido, a las que se les asigna como función de activación la tangente sigmoidea de manera que la RNA pueda dar seguimiento a relaciones no lineales en la variable a simular. La capa de salida con una sola neurona y función de activación lineal la cual es seleccionada por ser adecuada para funciones continuas, a la que llega cada una de las señales provenientes de la capa intermedia /13/.

Tabla 1
Variables de trabajo, unidades y símbolo asignado

Símbolo	Variable	Unidades
T	Tiempo	S
T1	Temperatura promedio de entrada del aire al compresor	K
P1	Presión de entrada del aire al compresor	Pa
Dp1	Diferencia de presión causada por el filtro en la línea de aire	Pa
P2	Presión del aire a la salida del compresor	Pa
T2	Temperatura del aire a la salida del compresor	K
T3	Temperatura promedio de salida en la turbina	K
T4	Temperatura promedio de los gases de salida de la unidad	K
W1	Velocidad de la turbina	Rev/s
T5	Temperatura en la parte superior del sello del aspa fija 1	K
T6	Temperatura en la parte inferior del sello del aspa fija 1	K
T7	Temperatura en la parte superior del sello del aspa fija 2	K
T8	Temperatura en la parte inferior del sello del aspa fija 2	K
T9	Temperatura en la parte superior del sello del aspa fija 3	K
T10	Temperatura en la parte inferior del sello del aspa fija 3	K
T11	Temperatura de entrada del aire que refrigera el rotor de la turbina	K
T12	Temperatura de salida del aire que refrigera el rotor	K
V1	Vibración cojinete del compresor en dirección "x"	M
V2	Vibración cojinete del compresor en dirección "y"	M
V3	Vibración cojinete de la turbina en dirección "x"	M
V4	Vibración cojinete de la turbina en dirección "y"	M
T13	Temperatura del cojinete del compresor	K
T14	Temperatura del cojinete de la turbina	K
P3	Presión de entrada del combustible en el múltiple de distribución	Pa (g)
T15	Temperatura de entrada del combustible a las cámaras de combustión	K
Dp2	Diferencia de presión en la placa orificio para medir el flujo de combustible	Pa
Po1	Posición de la válvula reguladora de flujo de combustible	%
P4	Presión de entrada del combustible a los quemadores	Pa (g)
I1	Potencia reactiva	Mva

La red neuronal así creada, está compuesta por neuronas simples que operan en paralelo y se encuentran interconectadas entre sí hacia adelante (*feed forward*). En éste caso se trabajara con un algoritmo de entrenamiento supervisado, pues se le suministran patrones de entrada con su respectivo patrón de salida, según el método de propagación de error hacia atrás (*back propagation*) de Levenberg-Marquardt, típico en redes de una sola capa intermedia con funciones de transferencia no lineal diferenciable, además de rápido y confiable /14-16/.




Fig. 1 Estructura de una RNA con interconexión hacia adelante.

Es bien conocido, que redes neuronales con una capa intermedia son capaces de aproximar funciones no lineales acotadas de forma satisfactoria y que más capas intermedias puede causar sobre entrenamiento por el número excesivo de neuronas, por lo cual en el presente trabajo se empleará una sola capa intermedia.

Los datos para la RNA no reciben ningún tratamiento previo, son discriminados en tres grupos, que de forma simultánea e independiente participan en la elaboración de la RNA, el primero para entrenamiento, con el 70% de los datos y es usado para el proceso de ajuste de los parámetros de la RNA (pesos y sesgos), el segundo para validación con 15%, siendo usado para evitar el sobre entrenamiento y el tercero para verificación con 15%. Debe hacerse la distribución de los grupos de forma que los datos contenidos en los dos primeros,

sean representativos de la totalidad de la data y que los datos usados para verificación no hayan sido usados en los otros dos grupos.

$$R^2 = \left(\frac{\sum_1^m (Y_{\text{cal}} - \bar{Y}_{\text{cal}}) * (X_{\text{med}} - \bar{X}_{\text{med}})}{[\sum_1^m (Y_{\text{cal}} - \bar{Y}_{\text{cal}})^2 * \sum_1^m (X_{\text{med}} - \bar{X}_{\text{med}})^2]^{1/2}} \right)^2 \quad (1)$$

donde

X_{med} es la propiedad observada;

\bar{X}_{med} es la propiedad observada promedio;

Y_{cal} es la propiedad calculada;

\bar{Y}_{cal} es la propiedad calculada promedio y m el número total de datos.

Resultados y discusión

Con respecto a las 28 variables predictivas a partir de las cuales se hará la simulación, los parámetros estadísticos básicos tales como mínimo, máximo, promedio, media, moda y desviación estándar (SD) son presentados en la tabla 2. Con respecto a la variable objetivo, diferencia de presión en los filtros, su información estadística se presenta en la misma tabla.

De entre las 28 variables de entrada, algunas presentan una SD muy pequeña, tal como la “vibración” con un orden de magnitud de 10^{-6} , esto debido a su muy lenta variación con el desgaste natural a lo largo del tiempo, y otras con una elevada SD tal como la presión de entrada de combustible a los quemadores, con un orden de 10^5 , debido a los frecuentes cambios de potencia en la unidad.

Tabla 2
Datos estadísticos de las variables consideradas

SÍMBOLO	MÍNIMO	MÁXIMO	PROMEDIO	MEDIA	MODA	SD
t	1 033 200	7 430 400	4 237 200	4 230 000	- - - - -	1 867 680
T1	285,51	299,96	292,61	292,30	291,39	2,84
P1	92 167,51	93 191,30	92 666,28	92 666,28	92 666,28	165,46
DP1	262,51	761,28	490,63	472,51	420,01	104,82
P2	86 643,21	1 252 432,14	1186 260,71	210,71	1218 657,14	631,07
T2	298,70	683,15	664,92	672,59	671,48	52,93
T3	298,51	825,92	807,65	819,81	819,81	76,77
T4	255,37	810,92	790,09	804,76	804,48	85,11
W1	0,00	61,516	58,58	60,00	60,00	9,09
T5	306,85	640,26	627,48	635,92	635,03	44,55
T6	310,63	636,31	620,98	627,31	624,59	43,15
T7	309,22	613,20	597,70	603,53	603,42	40,13
T8	311,31	619,53	604,87	610,65	613,81	40,84
T9	307,14	605,81	591,09	598,87	598,53	40,46
T10	309,81	585,65	568,48	573,42	573,70	36,16
T11	296,76	529,76	517,48	521,92	521,53	31,13
T12	255,37	310,92	305,86	306,65	310,92	8,41
V1	1,52E-06	9,14E-05	3,16E-05	2,94E-05	2,87E-05	8,68E-06
V2	1,01E-06	1,00E-04	4,18E-05	4,08E-05	4,77E-05	8,05E-06
V3	1,77E-06	1,33E-04	8,15E-05	8,25E-05	8,33E-05	1,27E-05
V4	-7,62E-07	1,21E-04	6,31E-05	5,84E-05	5,81E-05	1,60E-05
T13	306,70	360,92	356,87	357,87	357,48	7,00
T14	306,76	364,81	361,03	362,09	361,48	7,65
P3	1516,42	2 608 946,43	2 089 914,29	671,43	2094 050,00	980,35
T15	282,25	311,42	289,81	288,54	286,83	4,27
DP2	-173,25	37 775,29	32 630,08	33 522,61	33 627,62	5 365,71
PO1	0,00	44,09	38,16	39,11	0,00	6,15
P4	3 032,85	1 348 932,14	1 275 867,86	264,29	1 308 953,57	271,42
I1	-7,31	50,08	10,19	8,00	0,00	9,18

El ajuste de la RNA ejecuta de forma simultánea el entrenamiento con 2 484 series de datos, la validación con 532 y la verificación con 532 series, esto, con la finalidad de establecer los pesos y los sesgos de interconexión entre las variables que llegan a los nodos de entrada y el nodo de salida, este último donde se obtiene la variable que se requiere simular.

La selección definitiva de los parámetros de entrada es un aspecto importante, el cual requiere el conocimiento del proceso objeto de estudio y en la mayoría de los casos, ser asistido por herramientas estadísticas, de forma que solo las variables más importantes sean incluidas /18/. En el presente trabajo además

del conocimiento asociado al equipo, se realiza un análisis de sensibilidad, lo que de forma conjunta permite hacer la selección final.

El análisis de sensibilidad puede ser usado, para establecer la redundancia en la cantidad de variables de entrada y establecer la importancia relativa de las variables independientes seleccionadas, lo cual permite identificar el grado de influencia de éstas sobre la variable de salida. Estableciéndose a partir de las 28 variables predictivas, 28 casos a considerar por lo que se elaboran 28 modelos mediante RNA, cada uno con su correspondiente variable de entrada.

La consideración de R^2 es dada en la tabla 3 para cada uno de los 28 casos revisados, se muestra el coeficiente de determinación para el ajuste entre la salida real y la simulada. Se trabaja con 15 muestras para cada experiencia, por lo que dicho coeficiente se obtiene 15 veces para cada condición, luego se calcula su valor promedio y la desviación estándar de éste, la cual es cercana a cero en todos los casos. En dicha tabla se aprecia que las variables de mayor influencia (como una primera aproximación R^2 mayor a 0,69) son cinco, en orden de mayor a menor importancia: tiempo, vibración del cojinete del compresor en dirección "x", vibración del cojinete del compresor en dirección "y", vibración del cojinete de la turbina en dirección "x" y vibración del cojinete de la turbina en dirección "y", a partir de estas se hace la selección básica de las variables de entrada y estas son complementadas con otros análisis para la selección definitiva del modelo.

Tabla 3
Coeficiente de determinación promedio, mostrando tres valores típicos

SO #	SÍMBOLO	COEFICIENTE DE DETERMINACIÓN (R ²)			SD	
		VALORES	TÍPICOS	PROMEDIO		
1	T	0,997 62	0,998 25	0,997 70	0,998 01	0,000 36
2	T1	0,269 35	0,365 34	0,376 59	0,374 26	0,055 80
3	P1	0,567 04	0,562 57	0,568 17	0,566 97	0,001 29
	DP1					
4	P2	0,275 77	0,308 27	0,252 07	0,274 06	0,035 30
5	T2	0,110 58	0,109 87	0,095 72	0,096 83	0,019 48
6	T3	0,197 91	0,034 46	0,189 98	0,180 42	0,053 46
7	T4	0,264 33	0,263 71	0,266 85	0,260 99	0,010 24
8	W1	0,073 28	0,079 24	0,069 62	0,077 20	0,010 41
9	T5	0,242 81	0,296 73	0,310 19	0,286 76	0,023 67
10	T6	0,149 26	0,159 95	0,141 79	0,143 22	0,017 37
11	T7	0,209 28	0,197 33	0,227 84	0,200 54	0,021 89
12	T8	0,112 92	0,151 22	0,114 30	0,137 98	0,011 01
13	T9	0,190 33	0,191 11	0,189 99	0,186 10	0,015 12
14	T10	0,438 57	0,441 97	0,445 09	0,432 21	0,022 68
15	T11	0,244 91	0,245 98	0,249 58	0,244 17	0,007 18
16	T12	0,194 48	0,187 35	0,197 21	0,184 15	0,014 54
17	V1	0,843 47	0,846 28	0,832 66	0,842 30	0,004 44
18	V2	0,833 94	0,837 46	0,832 14	0,834 53	0,004 76
19	V3	0,686 56	0,723 87	0,736 32	0,732 02	0,012 78
20	V4	0,695 21	0,696 28	0,695 46	0,692 56	0,007 71
21	T13	0,135 50	0,142 56	0,123 37	0,129 96	0,014 15
22	T14	0,254 45	0,166 08	0,156 48	0,150 65	0,044 51
23	P3	0,462 29	0,461 41	0,450 92	0,460 46	0,003 61
24	T15	0,237 05	0,245 82	0,244 64	0,241 00	0,004 80
25	DP2	0,328 35	0,323 74	0,328 91	0,320 63	0,013 46
26	PO1	0,173 59	0,172 03	0,176 72	0,161 62	0,025 08
27	P4	0,428 56	0,415 02	0,415 07	0,417 66	0,017 81
28	I1	0,166 11	0,159 74	0,167 07	0,161 71	0,008 19

Con la finalidad de establecer, cuantas de las cinco variables señaladas, son necesarias para una simulación aceptable, se plantean cinco modelos en RNA, el primero con la primera variable, el segundo con las dos primeras y así sucesivamente. En la tabla 4, se muestra el coeficiente de determinación, su promedio luego de 15 consideraciones para cada caso y la desviación estándar. En la figura 2 se aprecia que cuando se trabaja solo con la primera variable se obtiene el mejor coeficiente de determinación.

Esta variable seleccionada fue nuevamente considerada, con la finalidad de establecer la mejor estructura de la RNA, para lo cual se elaboraron como una primera aproximación catorce modelos en RNA, según se muestra en la tabla 5, variando el número de neuronas en la capa intermedia, igualmente se muestra

el coeficiente de determinación tres veces para cada caso, se calcula su valor promedio (para 15 simulaciones) y su desviación estándar. En caso de no mostrar tendencia asintótica se debe incrementar la cantidad de modelos.

Tabla 4
Coeficiente de determinación promedio cuando se incrementa la cantidad de variables a partir de la cual se realiza la simulación

CASO #	VARIABLES	COEFICIENTE DE DETERMINACIÓN (R ²)	
		PROMEDIO	SD
29	t	0,997 92	0,000 36
30	t,V1	0,995 79	0,001 48
31	t,V1,V2	0,994 59	0,001 69
32	t,V1,V2,V3	0,994 65	0,001 98
33	t,V1,V2,V3,V4	0,994 89	0,001 09

En la figura 3 se aprecia el efecto sobre el coeficiente de determinación que tiene el incremento del número de neuronas en la capa intermedia, observándose que la mejor arquitectura es aquella que contiene doce neuronas en dicha capa.

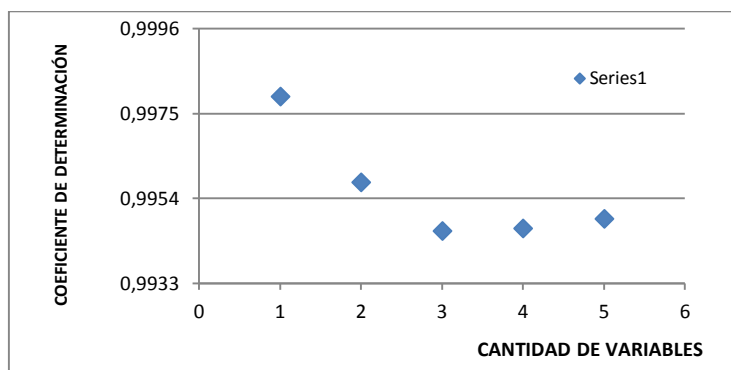


Fig.2 Efecto del número de variable usado en la simulación.

La estructura con un nodo en la sección de entrada, doce neuronas en la capa intermedia y una neurona en la capa de salida es la arquitectura que presenta el mejor rendimiento cuando se considera de forma global las tres fases de elaboración del modelo en RNA: entrenamiento, validación y verificación.

La figura 4 muestra los valores calculados por el modelo, en comparación con los valores reales de la diferencia de presión en los filtros para el aire. La pendiente de la línea de regresión para el modelo en RNA es 0,99 y difiere en 1% con respecto a la unidad, que corresponde a la pendiente del ajuste perfecto. El coeficiente de determinación es 0,997 40 por lo que las variables

seleccionadas para el modelo en RNA propuesto, permiten representar adecuadamente la diferencia de presión en los filtros para el aire.

Tabla 5
Comparación entre las distintas estructuras propuestas

CASO #	ESTRUCTURA	COEFICIENTE DE DETERMINACIÓN (R ²)				
		VALORES	TÍPICOS	PROMEDIO	SD	
34	1-1-1	0,988 94	0,988 92	0,988 92	0,988 89	0,000 07
35	1-2-1	0,991 72	0,991 65	0,991 58	0,991 89	0,000 48
36	1-3-1	0,993 04	0,993 47	0,991 62	0,992 36	0,001 13
37	1-4-1	0,995 00	0,993 92	0,993 92	0,993 79	0,000 79
38	1-5-1	0,992 61	0,994 40	0,992 16	0,994 06	0,000 96
39	1-6-1	0,995 52	0,995 69	0,995 54	0,995 34	0,000 48
40	1-7-1	0,995 65	0,996 04	0,995 26	0,995 97	0,000 29
41	1-8-1	0,995 74	0,996 17	0,995 88	0,996 10	0,00035
42	1-9-1	0,996 88	0,996 84	0,997 06	0,996 79	0,00036
43	1-10-1	0,997 04	0,996 88	0,996 80	0,996 77	0,000 31
44	1-12-1	0,995 82	0,997 46	0,997 29	0,997 11	0,000 51
45	1-14-1	0,997 86	0,997 97	0,997 10	0,996 27	0,003 76
46	1-16-1	0,996 40	0,997 68	0,997 77	0,997 48	0,000 55
47	1-18-1	0,998 18	0,996 98	0,997 52	0,997 54	0,000 50

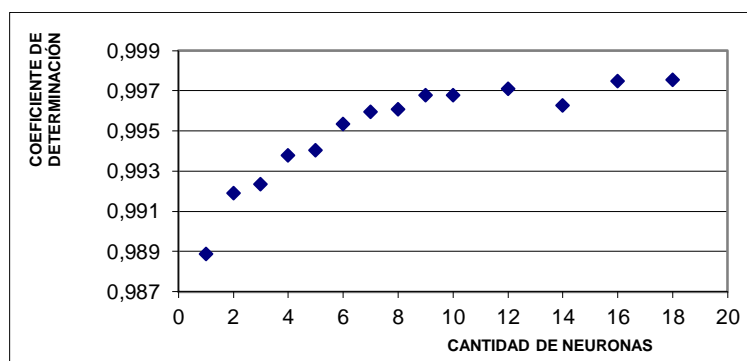


Fig. 3 Influencia del número de neuronas en la capa intermedia con respecto al coeficiente de determinación de la RNA.

Usando las variables y la topología optimizada para llevar a cabo las tres fases del desarrollo de la RNA se encuentra que los valores presentados por el modelo coinciden en alto grado con los valores observados, según se aprecia en la figura 5. Después de completadas todas las fases de elaboración, el modelo en RNA desarrollado es capaz de proveer resultados precisos y confiables.




Fig. 4 Coeficiente de determinación de la caída de presión en los filtros para el aire.

La estimación de la caída de presión en el sistema de filtros permitirá valorar en tiempo real el momento en que puede realizarse la parada de mantenimiento, mejorando la disponibilidad operacional del equipo.

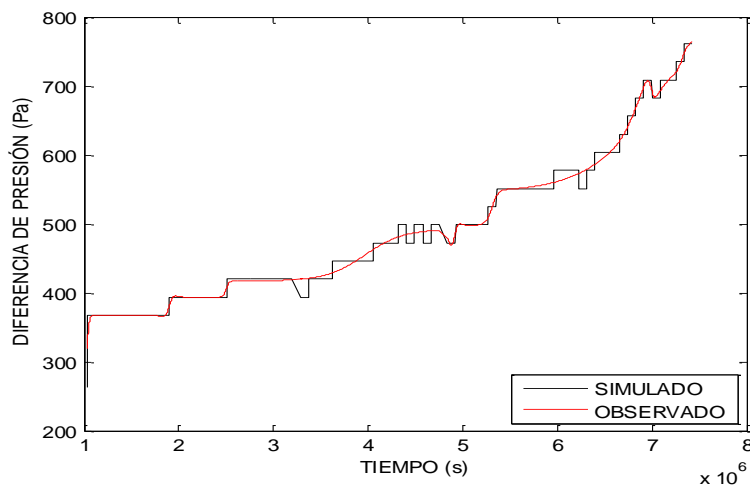


Fig. 5 Comparación de la caída de presión en los filtros para el aire.

Conclusiones

A partir de los resultados presentados, su análisis y su discusión se puede afirmar:

- 1. La técnica de redes neuronales artificiales permite discriminar de entre un conjunto de variables, la importancia relativa de cada una con respecto a la variable objetivo.**
- 2. La metodología planteada identifica mediante un análisis de sensibilidad, las variables que tienen mayor influencia sobre la diferencia de presión en los filtros para el aire, que en el presente caso se reduce a una, el tiempo.**
- 3. De igual forma mediante la aplicación de esta metodología, se establece la cantidad mínima de neuronas en la capa intermedia requerido para que el modelo desarrollado logre el máximo nivel de aproximación, lo que corresponde a doce.**
- 4. Se establece que para una red neuronal de tipo MLP con el algoritmo para propagación de error Levenberg-Marquardt, conformada por la sección de entrada, una capa intermedia y una capa de salida, la arquitectura que da el mejor ajuste de los datos, con el número óptimo de neuronas en la capa intermedia, es 1-12-1.**
- 5. Con la metodología desarrollada se logra una correspondencia entre el valor medido y el calculado, expresada a través del coeficiente de determinación, que corresponde a 0,99740.**
- 6. El modelo desarrollado presenta resultados satisfactorios para la variable objeto de estudio y su implementación provee de una herramienta para el incremento de la disponibilidad operacional en las unidades de generación.**

Bibliografía

1. LEAHY, Paul. "Structural optimization and input selection of an artificial neural network for river level prediction". *Journal of Hydrology* [en línea]. 2008, vol. 355, p. 192–201. [consulta: 13 de febrero de 2014]. Disponible por internet: <http://www.ucc.ie/hydromet/files/Leahy.2008.pdf>>ISSN: 0022-1694.
2. TUNG-LIANG, Chen. "Real-time turbine maintenance system". *Experts Systems with Applications*. 2009, vol. 36, p. 8676-8681. ISSN: 0957-4174.
3. Fast, M. "Development and multi-utility of an ANN model for an industrial gas turbine". *Applied Energy* [en línea]. 2009, vol. 86, p. 9–17. [consulta: 13 de febrero de 2014]. Disponible por internet: <<http://www.sciencedirect.com/science/article/pii/S030626190800072X>> ISSN 0306-2619.
4. BARTOLINI, C. "Application of artificial neural networks to micro gas turbines". *Energy Conversion and Management* [en línea]. 2011, vol. 52, p. 781–788. [consulta: 13 de febrero de 2014]. Disponible por internet: <http://www.sciencedirect.com/science/journal/01968904/52/1>> ISSN: 0196-8904.
5. MELESSE, A. "Suspended sediment load prediction of river systems: An artificial neural network approach". *Agricultural Water Management* [en línea]. 2011, vol. 98, p. 855–866. [consulta: de 13 de febrero de 2014]. Disponible por internet: <http://www.deepdyve.com/lp/elsevier/suspended-sediment-load-prediction-of-river-systems-an-artificial-CXII5gbk0x>ISSN: 0378-3774.
6. TAN, W. "Optimum parameters for fault detection and diagnosis system of batch reaction using multiple neural networks". *Journal of Loss Prevention in the Process Industries* [en línea]. 2012, vol. 25, 138-141. [consulta: 13 de febrero de 2014]. Disponible por internet: <http://www.sciencedirect.com/science/journal/09504230/25/1>> ISSN: 0950-4230.

7. BARAD, Sanjay; RAMAIAH, P.; GIRIDHAR, R. y KRISHNAIAH, G. "Neural network approach for a combined performance and mechanical health monitoring of a gas turbine engine". *Mechanical Systems and Signal Processing*. 2012, vol. 27, p. 729-742. ISSN: 0888-3270.
8. AGUDELO, Andrés et al. "Efecto de la altitud en el análisis termo económico de un sistema de cogeneración". *DYNA* [en línea]. 2007, vol. 74, nº 152, p. 113-124. [consulta: 6 de marzo de 2010]. Disponible por internet: <<http://www.redalyc.org/articulo.oa?id=49615211>> ISSN: 0012-7353.
9. MILLÁN, Félix. "Predicción mediante redes neuronales artificiales de la transferencia de masa en frutas osmóticamente deshidratadas". *Interciencia* [en línea]. 2006, vol. 31, nº 3, p. 206-210. [consulta: 6 de marzo de 2010]. Disponible por internet: http://www.scielo.org.ve/scielo.php?script=sci_arttext&pid=S037818442006000300011&lng=es&nrm=iso>ISSN: 0378-1844.
10. MENA, Carlos. "Comparación de redes neuronales y regresión lineal para estimar productividad de sitio en plantaciones forestales, utilizando geomática". *Bosque* [en línea]. 2006, vol. 27, nº 1. [consulta: de 6 de marzo de 2010]. Disponible por internet: <http://www.redalyc.org/pdf/1731/173113287004.pdf>>ISSN: 0717-9200.
11. MAIER, Holger; JAIN, Ashu; DANDY, Graeme y SUDHEER, K. "Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions". *Environmental Modeling & Software*. 2010, vol. 25, p. 891-909. ISSN: 1364-8152.
12. HONTORIA, L.; AGUILERA, Javiera. y ZUFIRIA, Pedro. "An application of the multilayer perceptron: Solar radiation maps in Spain". *Solar Energy*. 2005, vol. 79, p. 523-530. ISSN: 0038-092X.
13. HAMED, Maged; KHALAFALLAH, Mona y HASSANIEN, Ezzat. "Prediction of waste water treatment plant performance using artificial

- neural networks”. *Environmental Modeling & Software*. 2004, vol. 19, p. 919-928. ISSN: 1364-8152.
14. HERNANDEZ, J. “Neural Networks for the heat and mass transfer prediction during drying of cassava and mango”. *Innovative Food Science and Emerging Technologies* [en línea]. 2004, vol. 5, p. 57-64. [consulta: 6 de marzo de 2010]. Disponible por internet:
http://www.researchgate.net/publication/229360569_Neural_networks_for_the_heat_and_mass_transfer_prediction_during_drying_of_cassava_and_mango ISSN: 1466-8564.
15. SAHOO, G.; RAY, C. y WADE, H.. “Pesticide prediction in ground water in North Carolina domestic wells using artificial neural networks”. *Ecological Modeling*. 2005, vol. 183, p. 29-46. ISSN: 0304-3800.
16. HERZOG, M.; MARWALA, T y HEYNS, P. “Machine and component residual life estimation through the application of neural networks”. *Reliability Engineering and System Safety*. 2009, vol. 94, p. 479-489. ISSN: 0951-8320.
17. DOMBAYCI, Omer y GOLCU, Mustafa. “Daily means ambient temperature prediction using artificial neural network method: A case study Turkey”. *Renewable Energy*. 2009, vol. 34, p. 1158-1161. ISSN: 0960-1481.
18. PANAGOUE, E. y KODOGIANNIS, V. “Application of neural networks as a non-linear modeling technique in food mycology”. *Expert Systems with Applications*. 2009, vol. 36, p. 121-131. ISSN: 0957-4174.