

## Análisis de la calidad de ajuste de una red neuronal autoajustable aplicada en la predicción de fallas en un aerogenerador de baja potencia

SALINAS-HERNÁNDEZ, Andrés<sup>1†</sup>, RICO-ESPINO, José Guadalupe<sup>2</sup>, JIMÉNEZ-GRAJALES<sup>1</sup>, Ma. Ángela M. y RAMÍREZ-LÓPEZ, Raúl<sup>1</sup>

<sup>1</sup>Instituto Tecnológico de Querétaro, Línea: Automatización y Sustentabilidad, Av.Tecnológico s/n, Centro, C.P. 76000 Querétaro, Querétaro, México

<sup>2</sup>CIATEQ, Gerencia de TI-Electrónica y Control, Av. Manantiales No. 23-A, Parque Industrial Bernardo Quintana, C.P. 76246, El Marqués, Querétaro, México

Recibido Agosto 15, 2017; Aceptado Noviembre 25, 2017

### Resumen

En el proceso de identificación de las señales que se encuentran presentes en un determinado sistema, resulta muy conveniente conocer de manera a priori los comportamientos que éste tendrá con base a diferentes valores de entrada, así como contar con herramientas que permitan realizar aproximaciones de dichos comportamientos debido a que la mayoría de los sistemas son analizados dinámicamente. Una técnica eficaz para poder obtener estas aproximaciones del comportamiento del sistema es mediante el uso de redes neuronales, las cuales aprenden las señales objetivo con base a un número de etapas de entrenamiento. Sin embargo, resulta conveniente validar la significancia de factores como la topología utilizada y el número de etapas de entrenamiento con respecto a la calidad de ajuste de la señal de salida y el tiempo de procesamiento que consume la red neuronal en operación. Para ello, se pueden emplear métodos como el del presente trabajo, que consiste en someter a un diseño de experimentos dichos factores. Este trabajo se realizó considerando la señal de aceleración del eje de baja velocidad de un aerogenerador de baja potencia en condiciones de falla mecánica.

**Red neuronal, Diseño de experimentos, Energía eólica, Calidad de ajuste, Simulación**

### Abstract

During the process of identifying the signals that are present at a specific system, it is convenient to know the possible behaviours of the system's output(s) a priori with different levels of the input signal(s), as well as having tools that allow estimations of such outputs given that most systems are analyzed dynamically. An efficient technique that can be used to obtain such estimations are neural networks, which can learn the target signals based on a certain training epochs number. However, it is convenient to validate the significance of the factors like the topology of the network and the number of epochs with the adjustment quality of the output signal and the processing time that the network consumes during its operation. For that, one can employ methods such as the one presented in this work, which consists in subject these factors into an experiment design. This work was done considering the low-speed shaft acceleration signal of a low-speed wind turbine in failure conditions.

**Neural network, design of experiments, Wind power, Adjustment quality, simulation**

**Citación:** SALINAS-HERNÁNDEZ, Andrés, RICO-ESPINO, José Guadalupe, JIMÉNEZ-GRAJALES, Ma. Ángela M. y RAMÍREZ-LÓPEZ, Raúl. Análisis de la calidad de ajuste de una red neuronal autoajustable aplicada en la predicción de fallas en un aerogenerador de baja potencia. Revista de Investigación y Desarrollo.2017, 3-10: 60-68.

† Investigador contribuyendo como primer autor.

## Introducción

### Diseño de experimentos

El diseño de experimentos es una técnica estadística que sirve para medir la posible influencia de factores relacionados con un proceso sobre la respuesta del mismo; la medición se logra realizando cambios en los valores de los factores de influencia y observando su efecto sobre una variable de interés. Una vez concluido este proceso de prueba, se realiza el análisis de los resultados, los cuales se resumen en un valor cuantitativo que expresa la significancia del efecto de los factores sobre la variable de interés, observada. (Gutiérrez Pulido & De la Vara Salazar, 2008).

Se recurre al diseño factorial cuando se desea estudiar y analizar los efectos de varios factores sobre una o varias respuestas, y pueden tratarse de factores tanto cualitativos como cuantitativos. Uno de estos diseños es cuando se incluyen tres factores de interés. Cada diseño cuenta con un modelo que expresa a la variable de respuesta en función del efecto de los factores incluidos y sus interacciones. Para el caso del diseño con tres factores, el modelo de efectos se establece como:

$$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + \varepsilon_{ijkl} \quad (1)$$

En donde  $\mu$  es el valor promedio estimado,  $\alpha_i$ ,  $\beta_j$  y  $\gamma_k$  los efectos de los niveles  $i$ -ésimo,  $j$ -ésimo y  $k$ -ésimo respectivamente, los efectos de interacción dobles, el efecto de interacción triple, así como el error aleatorio  $\varepsilon_{ijkl}$ , con  $l$  siendo las réplicas del experimento. Por tanto, se cuentan en total con 7 hipótesis a probar, las cuales corresponden a la siguiente notación:

$$H_0 = \text{Efecto } x = 0$$

$$H_1 = \text{Efecto } x \neq 0$$

$$x = \{A, B, C, AB, AC, BC, ABC\}$$

En donde  $H_0$  establece que el efecto del factor  $x$  no es significativo sobre la respuesta, mientras que  $H_1$  establece que sí lo es.

### Redes neuronales artificiales

Se considera a una red neuronal artificial (RNA) como un modelo programado para funcionar similarmente a las neuronas biológicas de los seres vivos. Estas redes neuronales se conforman por varias unidades de procesamiento conocidas como neuronas, las cuales se encuentran interligadas por conexiones que representan a las sinapsis de las neuronas biológicas.


Las RNAs buscan la solución de problemas complejos de la manera en que funcionaría el cerebro humano; una de sus características es que presentan la capacidad de “aprendizaje”, lo cual se liga con el concepto de adaptación y estimación de los parámetros a los que está sujeta la RNA. Tanto la topología de la red como el método de aprendizaje y la robustez de la misma son acorde a la aplicación donde se requiera.

Uno de los tipos de RNAs más prácticos corresponde al algoritmo de retropropagación (Rumelhart & McClelland, 1987). el cuál permite una respuesta muy fina, considerando cualquier función no-lineal. Esta surge del análisis de la red ADALINE, la cual incorporó una minimización del error mediante el decrecimiento acorde a la dirección del gradiente de la función del error (Widrow & Hoff Jr., 1960):

$$E_p = \frac{1}{2} \sum_{k=1}^m (e_k^p)^2 \quad (2)$$

La topología utilizada por la RNA de retropropagación se conoce como multicapa, la cual se puede ver representada en la figura 1. Una de las principales ventajas que surgen del uso de redes multicapas en conjunto con el algoritmo de retropropagación es que permiten resolver problemas estocásticamente ante sistemas o funciones no lineales.

Lo cual permite obtener soluciones muy aproximadas en casos complejos; así mismo, utilizando el número adecuado de neuronas en las capas de la red, se pueden obtener procesamientos robustos y aprendizaje profundo (Wasserman & Schwartz, 1988).



**Figura 1** Topología de red neuronal artificial multicapa  
Fuente: (Rumelhart & McClelland, 1987)

### Aerogeneradores de baja potencia


Los sistemas de producción de energía eólica, en la actualidad, se consideran tan variados como los métodos en los cuales se realiza la conversión de la energía cinética del viento en electricidad. Una de estas variaciones corresponde a los aerogeneradores o turbinas eólicas de baja potencia, los cuales producen un rango de entre 1 y 100 kW de potencia eléctrica. La función principal de este tipo de turbinas es la microgeneración de electricidad, destinada a abastecer de energía a pequeños negocios, hogares y/o comunidades.

Las turbinas eólicas están compuestas de tres secciones principales:

- Rotor.
- Góndola.
- Torre.

En cuestión de análisis, las primeras dos secciones son esenciales, debido a que la torre queda excluida en parte del sistema mecánico móvil de la turbina.

Uno de los elementos principales que forman parte de estas secciones es el tren de potencia mecánico, también conocido como la transmisión de potencia mecánica (figura 2); este elemento se considera crítico, debido a que puede presentar escenarios de falla asociados a cada uno de los sub-elementos que lo conforman, cada uno con diferentes niveles de severidad (Chammas, et al., 2013).



**Figura 2** Elementos del tren de potencia  
Fuente: (Hau, 2013)

### Metodología

#### Caso de estudio


El caso de aplicación corresponde a realizar un diseño de experimentos que permita determinar la influencia de ciertos factores sobre la calidad del ajuste de una RNA utilizando el algoritmo de retropropagación. Se ha tratado en tiempos recientes el modelado de los sistemas que componen al aerogenerador, el cual es la base para el diseño de cualquier método de detección de irregularidades (Simani, Farsoni, & Castaldi, 2015). Es notable mencionar que se han realizado estudios e implementación de estas técnicas en varios de los elementos móviles de las turbinas de alta potencia, como la caja de engranes (Feng, Qin, & Liang, 2015).

La finalidad de estructurar estos métodos de detección y prevención de fallas es poder llegar a la elaboración de instrumentos que sean capaces de tomar acciones concretas en base a los modelos sobre los que son fundamentados.

El desarrollo de algoritmos de decisión facilita la jerarquización y ejecución de estas acciones en base a la información que sea recabada por el sistema (Asuhaimi Mohd Zin, Saini, Wazir Mustafa, Rizal Sultan, & Rahimuddin, 2015).

La red neuronal se ha diseñado para realizar la etapa de identificación de señales de salida de la simulación de un aerogenerador de baja potencia sometida a una falla mecánica; la principal señal analizada es la aceleración angular del eje de baja velocidad del aerogenerador, la cual se mide a partir de una galga extensiométrica ubicada en un punto de unión entre el eje y la caja multiplicadora. La simulación del aerogenerador se realizó en el ambiente de trabajo de Matlab® con ayuda de la herramienta de simulación FAST® que ha diseñado y distribuido de manera abierta el NREL (Laboratorio Nacional de Energía Renovable, por sus siglas en inglés).

Una vez simulado este comportamiento, se obtuvo una señal de respuesta expresada en términos de la aceleración angular del eje de baja velocidad del aerogenerador, la cual pasa a la etapa de identificación mediante una red neuronal entrenada bajo el algoritmo de retropropagación. Esta señal, representada en la figura 3, muestra una falla causada por una ráfaga de viento simulada, la cual repercute sobre las vibraciones que son transmitidas en el eje de baja velocidad.



**Figura 3** Señal de referencia y aproximación de la red neuronal

Mediante la experimentación, se observaron tres factores que presentan una influencia sobre la aproximación que realiza la red neuronal en comparación con la señal de referencia:

- Número de neuronas en la capa oculta: al trabajar con un esquema de 3, 5 y 8 neuronas que conforman a la capa intermedia (oculta) de la red neuronal, se obtienen diferentes resultados en la aproximación.
- Número de muestras: esto se refiere al número de datos provenientes de la señal de referencia que se utilizan en la etapa de identificación de la señal objetivo. Obteniendo muestras de 10000, 5000 y 2000 datos, se observa una diferencia en el tiempo de procesamiento y en la aproximación de la RNA.
- Valor de la tolerancia del error absoluto: al momento de trabajar con el algoritmo de retropropagación, se considera como factor importante la minimización del error que consigue, siendo éste la diferencia entre la aproximación de la red y la referencia objetivo.

Para propósitos del proyecto, la variable de interés que sirvió como indicador de la calidad de ajuste de la identificación por medio de redes neuronales fue el promedio del error generado por el algoritmo. Así, el diseño de experimentos quedó de la siguiente manera:

Variables de diseño		
Número de muestras	Número de neuronas	Tolerancia de error absoluto
10000	8	0.01
5000	8	0.01
2000	8	0.01
10000	8	0.005
5000	8	0.005
2000	8	0.005
10000	5	0.01
5000	5	0.01
2000	5	0.01
10000	5	0.005
5000	5	0.005
2000	5	0.005

10000	3	0.01
5000	3	0.01
2000	3	0.01
10000	3	0.005
5000	3	0.005
2000	3	0.005

**Tabla 1** Variables de diseño

El diseño anterior se llevó a cabo en dos ocasiones para poder tener una estimación del error aleatorio.

Error promedio absoluto	
0.0099	0.01
0.01	0.01
0.0152	0.0147
0.0057	0.0061
0.0085	0.0088
0.0139	0.0142
0.01	0.01
0.01	0.01
0.0104	0.01
0.0064	0.0063
0.0085	0.0082
0.0101	0.0099
0.01	0.01
0.01	0.01
0.01	0.01
0.0078	0.0077
0.0083	0.0083
0.0093	0.0094

**Tabla 2** Variable de respuesta

Una vez realizado el experimento en orden completamente aleatorio, se registraron las dos respuestas observadas para cada corrida, y con estos datos se procedió a la ejecución del análisis del experimento mediante el software Minitab®, el cual nos proporciona el siguiente análisis de varianza (ANOVA):

Fuente	GL	SC Ajust.	MC Ajust.
Muestras	2	0.000061	0.000031
Neuronas	2	0.000016	0.000008
Tolerancia Error	1	0.00003	0.00003
Muestras*Neuronas	4	0.000044	0.000011
Muestras*Tolerancia	2	0.000012	0.000006
Neuronas*Tolerancia	2	0	0
Error	22	0.000002	0
Falta de ajuste	4	0.000002	0
Error puro	18	0	0
Total	35	0.00016	
Fuente	Valor F	Valor P	
Muestras	322.06	0	
Neuronas	81.85	0	

Tolerancia Error	314.91	0
Muestras*Neuronas	114.78	0
Muestras*Tolerancia	60.59	0
Neuronas*Tolerancia	2.54	0.102
Error		
Falta de ajuste	15.92	0

**Tabla 3** Resultados de ANOVA**Resumen del modelo**

S	R-cuad.	R-cuad. (ajustado)	R-cuad. (pred)
0.0003081	98.73%	97.98%	96.60%

Usando un nivel de confianza del 95% podemos concluir que existe una influencia significativa sobre la respuesta por parte de los 3 factores. Así también se presenta una interacción significativa entre el factor “número de muestras” con cada uno de los factores restantes, la cual influye sobre la calidad del ajuste del algoritmo.

Una vez verificados los supuestos del experimento, se procedió a elegir los mejores niveles de cada factor. Tomando en cuenta que se busca minimizar el error que proporciona la RNA, se eligieron aquellos valores que corresponden con el menor valor estimado, siendo estas 10000 muestras y 8 neuronas dentro de las capas de entrada y oculta.

En las gráficas se observa que el conjunto de resultados que nos da el segundo valor más pequeño de error es correspondiente a 5000 muestras, 3 neuronas en las capas y una tolerancia del error de 0.005, por lo que se diseñó un segundo experimento para probar si existe diferencia entre estas dos combinaciones de niveles en cuanto a la reducción del error absoluto y el tiempo de procesamiento del algoritmo.




Figura 4 Gráfica de interacción con ‘Promedio de error absoluto’ como variable de respuesta

Epoch	Tol. Error
500	0.01
500	0.01
500	0.005
500	0.005
1000	0.01
1000	0.01
1000	0.005
1000	0.005
1500	0.01
1500	0.01
1500	0.005
1500	0.005

Tabla 4 Variables y niveles de diseño del segundo experimento

El diseño del segundo experimento correspondió a un diseño por bloques, debido a que para observar la influencia de los diferentes niveles, se buscó observar la respuesta simultáneamente, agregando un factor de bloqueo en la tabla 4, denominando “Bloque 1” a los primeros valores sugeridos y “Bloque 2” a los segundos valores sugeridos. Tal como se realizó en el diseño anterior, se corrió la simulación dos veces, obteniendo los siguientes resultados:

Tiempo Proc. (seg)
204.1911
238.3971
813.6442
803.4207
278.3456
266.957
821.4873
756.1664
300.4392
295.2662

969.874
962.9335
69.5462
78.5284
260.5314
259.2544
79.7628
77.0599
502.9311
527.5751
73.4052
62.1986
737.642
721.3284

Tabla 5 Variables de respuesta

Los resultados del ANOVA para el segundo diseño quedaron de la siguiente manera:

Modelo lineal general: Prom. Error vs. Epoch, Tol. Error

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Tol. Error	1	1557261	1557261	251.92	0
Epoch	2	120018	60009	9.71	0.002
Bloque	1	443392	443392	71.73	0
Epoch*Tol. Error	2	83126	41563	6.72	0.007
Error	17	105087	6182		
Falta de ajuste	5	101769	20354	73.59	0
Error puro	12	3319	277		
Total	23	2308884			

Tabla 6 Resultados de ANOVA

Resumen del modelo

S	R-cuad.	R-cuad. (ajustado)	R-cuad. (pred)
78.6232	95.45%	93.84%	90.93%

Usando un nivel de confianza de 95%, se puede concluir que los tres factores influyen significativamente sobre el tiempo de respuesta del algoritmo; de igual manera, existe una influencia significativa generada por la interacción de los factores “Número de épocas de entrenamiento” y “Tolerancia del error promedio absoluto”. Después de corroborar el cumplimiento de los supuestos estadísticos del modelo, se procedió a seleccionar los mejores niveles para cada factor.

Tomando en cuenta la doble interacción, se recurrió a la gráfica de interacciones mostrada en la figura 5, en donde se observa que los mejores niveles corresponden a 500 épocas y a una tolerancia de 0.01 unidades.

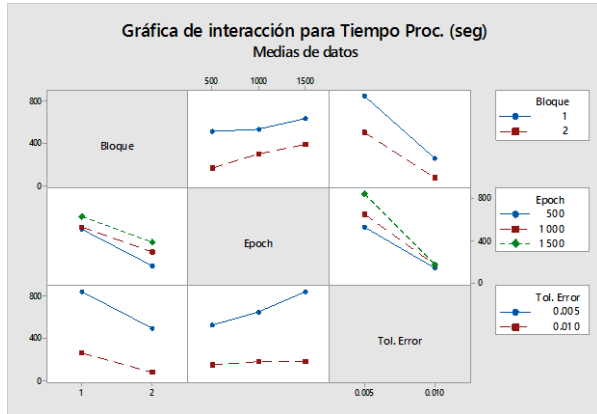


Figura 5 Gráfica de interacción con “Tiempo de procesamiento” como variable de respuesta

De igual manera, con la ayuda del factor de bloqueo, se pudo observar que las mejores respuestas se obtuvieron con el segundo nivel, los cuales corresponden a los segundos valores recomendados por el primer diseño (5000 muestras, 3 neuronas).

Una vez elegidos los mejores niveles, se procedió a realizar un tercer diseño de experimentos para elegir los mejores niveles de los factores “Número de épocas de entrenamiento” y “Tolerancia del error promedio absoluto” y su efecto sobre la respuesta “Error promedio absoluto generado por el algoritmo”. Este experimento se realizó sólo tomando los valores del bloque 2.

**Modelo lineal general: Prom. Error vs. Epoch, Tol. Error**

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Epoch	2	0.000004	0.000002	3.92	0.065
Tol. Error	1	0.000027	0.000027	60.25	0
Error	8	0.000004	0		
Falta de ajuste	2	0.000004	0.000002	150.64	0
Error puro	6	0	0		
Total	11	0.000034			

Tabla 7 Resultados de ANOVA, segundo experimento

**Resumen del modelo**

S	R-cuad.	R-cuad. (ajustado)	R-cuad. (pred)
0.0006694	89.49%	85.54%	76.35%

**Resultados**

Con un nivel de confianza del 95%, se pudo observar sólo el efecto de la tolerancia del error promedio absoluto influye significativamente sobre la respuesta del error promedio absoluto que devuelve el algoritmo.

Algo que se debe remarcar es que se cumplieron todos los supuestos estadísticos del experimento exceptuando el supuesto de independencia de los residuos. Esto se debió a que la respuesta del error tomando en cuenta un nivel de 0.01 en el factor “Tolerancia del error promedio absoluto” y cualquier nivel del factor “Número de épocas de entrenamiento” siempre será alrededor de 0.01, pues la naturaleza de la programación del algoritmo así lo dictamina. Por tanto, se puede asumir un resultado esperando de no cumplimiento en la prueba de varianzas para este experimento.

Finalmente, se utilizó el gráfico de efectos principales para seleccionar el mejor nivel del factor de la tolerancia del error promedio absoluto, observado en la figura 6.

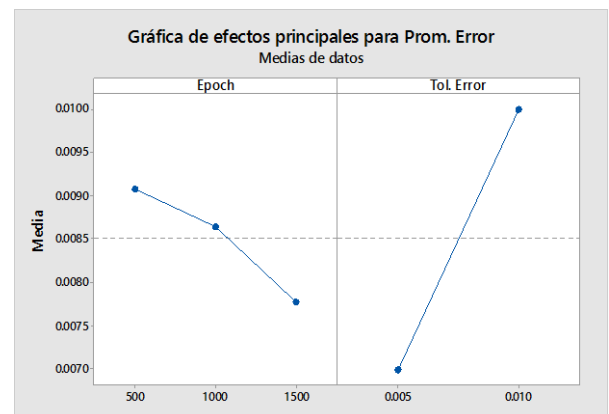


Figura 6 Gráfica de efectos principales para el tiempo de procesamiento, primer caso

Al tomar en cuenta el gráfico, se puede observar que el mejor nivel corresponde a una tolerancia de 0.005, lo cual conlleva a que el tiempo de procesamiento sea mayor. Dado que la naturaleza del sistema es lenta, es posible hacer uso del algoritmo considerando como prioritaria la calidad del ajuste. Por tanto, el algoritmo funcionará de la mejor manera posible considerando los niveles de ambos experimentos: 5000 muestras, 3 neuronas en la capa de entrada e intermedia y una tolerancia del error promedio absoluto de 0.005, esto sin importar el número de épocas de entrenamiento que se deseen utilizar.

### Conclusiones

Los diseños de experimentos realizados brindaron la oportunidad de comprobar la influencia significativa que tienen los principales factores involucrados en el uso de una RNA para identificación y aproximación de funciones.

De lo observado, se puede considerar la robustez y facilidad que presenta el uso del algoritmo de retropropagación en el entrenamiento de redes multicapas, al lograr una aproximación significativamente acertada de un sistema de naturaleza lenta y de una cantidad elevada de datos.

Los resultados de este artículo se utilizarán en la última etapa de un caso de estudio de predicción de fallas, en donde al aerogenerador antes mencionado se le aplicará diferentes condiciones de falla y posteriormente se procederá a analizar las aproximaciones de dos topologías diferentes de RNAs en el dominio de la frecuencia, suponiendo la hipótesis de que en cada caso, el algoritmo será lo suficientemente robusto para proporcionar resultados similares en cuanto a calidad de ajuste.

### Agradecimientos

Este trabajo es parte de las actividades del proyecto “P07: Integración y consolidación de capacidades nacionales para el desarrollo de pequeños aerogeneradores mediante el diseño, construcción y pruebas exhaustivas de un aerogenerador con capacidad de 30 kW”, que se desarrolla en el contexto del Centro Mexicano de Innovación en Energía Eólica (CEMIE-Eólico) bajo los auspicios del Fondo CONACYT-SENER-Sustentabilidad Energética.

### Referencias

- Asuhaimi Mohd Zin, A., Saini, M., Wazir Mustafa, M., Rizal Sultan, A., & Rahimuddin. (19 de Mayo de 2015). New algorithm for detection and fault classification on parallel transmission line using DWT and BPNN based on Clarke's transformation. *Neurocomputing*, 168, 983-993.
- Chammas, A., Duviella, E., & Lecoeuche, S. (2013). Fault Diagnosis of Wind Turbine Drive Train Faults based on Dynamical Clustering. *52nd IEEE Conference on Decision and Control* (págs. 5650-5655). Florencia: IEEE.
- Feng, Z., Qin, S., & Liang, M. (2015). Time-frequency analysis based on Vold-Kalman filter and higher order energy separation for fault diagnosis of wind turbine planetary gearbox under nonstationary conditions. *Renewable Energy*, 45-56.
- Gutiérrez Pulido, H., & De la Vara Salazar, R. (2008). *Análisis y Diseño de Experimentos* (Segunda ed.). Ciudad de México: McGraw-Hill.
- Hau, E. (2013). Mechanical Drive Train and Nacelle. En E. Hau, *Wind Turbines. Fundamentals, Technologies, Application, Economics* (págs. 253-318). Berlin: Springer.



Rumelhart, D., & McClelland, J. L. (1987). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Foundations* (I ed., Vol. I). Cambridge, Massachusetts, Estados Unidos de América: MIT Press.

Simani, S., Farsoni, S., & Castaldi, P. (2015). Wind turbine simulator fault diagnosis via fuzzy modelling and identification techniques. *Sustainable Energy, Grids and Networks*, 45-52.

Wasserman, P., & Schwartz, T. (1988). Neural networks. II. What are they and why is everybody so interested in them now? (IEEE, Ed.) *IEEE Expert*, 3(1), 10-15.

Widrow, B., & Hoff Jr., M. E. (1960). Adaptive Switching Circuits. *IRE WESCON Convention Record* (págs. 96-104). Stanford: IEEE.