

## Cancelación de Ruido a través de Técnicas Neurales

Fidel Ernesto Hernández Montero, Wilfredo Falcón Urquiaga  
Grupo de Investigación para el Desarrollo de Equipos y Sistemas, Universidad de Pinar  
del Río, Calle Martí #270 Final, CP 20100, Cuba.  
E-mails: fidel@netupr.upr.edu.cu, falcon@netupr.upr.edu.cu

### Abstract

*The subject of this work is to apply neural techniques to the noise cancellation in a transmission line (e.g., return line of sensors, phone line).*

*Basically, several models of Artificial Neural Networks (ANN) are developed, trying to solve the subject and the obtained results in each one of them are compared. The application of these nets is based, in principle, in that during the process of training, the neural architecture can learn the statistic of certain aleatory signal (e.g., noise). Then, later it will be possible to extract this noise from certain polluted useful signal when presenting this combination of signals (i.e., signal useful plus noise) to the input of the network and to act the network as a noise pattern "recognizer", isolating this noise from the useful sign.*

*During the investigation, two samples of noise were dealt: a sample of stationary noise (Gaussian white noise) and a sample of non-stationary noise (impulsive noise).*

*The index employed to check the effectiveness of the operation of the ANN was the correlation between the useful signal without contamination and the signal obtained to the output of the neural network when the useful signal contaminated by the noise is in the input.*

### 1. Introducción

Las señales, durante su transmisión, siempre se encuentran bajo la influencia de otras señales no deseadas. Incluso, cualquier procesamiento que se realice a una señal tiende a introducir perturbaciones desagradables en ella misma. A estas perturbaciones que contaminan la señal transmitida o procesada se le llama ruido, y constituye una señal molesta que no guarda relación alguna con la útil [1].

Las señales eléctricas indeseables provienen de una gran variedad de fuentes, generalmente clasificadas como interferencias producidas por el hombre, así como por el ruido proveniente de causas naturales [2]. Las interferencias producidas por el hombre provienen de otras fuentes, tales como falsos contactos,

iluminación fluorescente, instrumentos o utensilios eléctricos, etcétera; este tipo de ruido puede ser cancelado eliminando la fuente que lo genera. El ruido natural se clasifica en perturbaciones erráticas naturales que ocurren irregularmente, así como en ruido fluctuante que aparece en los sistemas físicos. El primero incluye a las perturbaciones atmosféricas, tormentas eléctricas y radiación electromagnética, entre otros. El segundo tipo de ruido, que incluye, por ejemplo, el ruido circuital, es completamente aleatorio y constituye el objeto de trabajo en este estudio.

Con un trabajo cuidadoso de ingeniería, se pueden reducir muchas señales indeseables, aunque siempre permanecen con determinada magnitud, imponiendo requerimientos a los sistemas.

El método empleado para llevar a cabo la extracción o cancelación de ruido en este trabajo está basado en el uso de Redes Neuronales Artificiales (RNA).

Este método puede ser más efectivo debido a que en muchos sistemas (por ejemplo, el entorno de la Bioingeniería, las Telecomunicaciones o la Electrónica, en general), las señales que se transmiten y que se ven afectadas por ruidos, viajan por una línea de transmisión, de la que es muy difícil, sino casi imposible, extraer una muestra bien correlacionada de ruido o señal deseada para realizar detección por correlación, filtrado adaptativo u otra técnica adaptativa. Aquí, el empleo del método aplicando técnicas neuronales, constituiría una solución más adecuada y viable, ya que en este sólo se manejaría el conjunto señal deseada más ruido.

#### 1.1. Procesamiento estadístico de señales

La extracción o cancelación de ruido ocupa un pequeño lugar en el amplio espectro constituido por las técnicas de procesamiento estadístico de señales y, en una de sus variantes, guarda estrecho vínculo con métodos de predicción de señal o patrones dinámicos.

El procesamiento estadístico matemático ocupa un área donde físicos y matemáticos se han venido introduciendo de forma activa para resolver un amplio rango de problemas. Se

pueden remontar sus orígenes al informe clasificado RCA de North, en 1943 y vuelto a publicar en [3]; el documento clásico [4] de Van Vleck y Middleton, en 1946; y los trabajos pioneros de Wiener [5]. En particular, los métodos clásicos de procesamiento estadístico de señales, en su búsqueda de hacer menos complejo todo el procesamiento matemático, se basan en tres suposiciones básicas: linealidad; sistema estacionario; y sistemas con estadísticas de segundo orden, enfatizando en los de tipo Gaussiano. Sin embargo, la mayoría, si no todas, de las señales físicas con las que se trata en aplicaciones de tiempo real son generadas por procesos dinámicos que son simultáneamente no lineales, no estacionarios, y no Gaussianos. Luego, el resultado final de diseñar un sistema de procesamiento de señales siguiendo las líneas tradicionales constituiría una solución no óptima. Una vía, a través de la cual la eficiencia del sistema se vería mejorada, sería considerar el uso de las RNA, combinadas con otras técnicas, en dependencia de la tarea en cuestión.

## 1.2. Razones para el empleo de RNA

Las RNA presentan un número importante de propiedades que hacen conveniente su uso en aplicaciones de procesamiento de señales. Específicamente, se mencionarán las siguientes cinco propiedades:

- Las RNA son dispositivos no lineales distribuidos.

Esta propiedad es un resultado directo del hecho de que cada unidad de procesamiento (neurona) de una red neural presenta internamente una función de activación no lineal. Por lo tanto, las RNA tienen la capacidad inherente de modelar las no linealidades principales contenidas en el mecanismo físico responsable de la generación del dato de entrada.

- Una RNA consiste en un procesador paralelo de forma masiva que tiene el potencial de ser tolerante a fallos.

Por ejemplo, un perceptrón multicapa, que representa una estructura muy popular para la implementación de RNA, consiste en un gran número de neuronas agrupadas en forma de capas, con cada neurona de una capa particular conectada a un gran número de nodos/neurona fuente de la capa previa. Esta forma de interconexión de manera global tiene el potencial de ser tolerante a fallo, en el sentido de que el funcionamiento no se ve degradado fuertemente bajo condiciones adversas de operación. Si una neurona o pesos sinápticos son dañados, la calidad del “recuerdo” de un patrón almacenado se deteriora, pero debido a la

naturaleza altamente distribuida de la red, el daño no se hace extensivo y la eficiencia no es degradada seriamente.

- Las RNA tienen la capacidad natural de adaptar sus parámetros libres a cambios estadísticos en el ambiente en el cual operan.

Mientras más adaptativo se haga un sistema no lineal, más robusto será su comportamiento y mejor su operación en ambientes no estacionarios. Sin embargo, para aprovechar al máximo la adaptatividad, debe existir una conveniente resolución de acuerdo a la disyuntiva estabilidad-plasticidad. Esto significa que las constantes de tiempo principales del sistema deberían ser lo suficientemente grandes como para ignorar perturbaciones espúreas, y lo suficientemente pequeñas como para responder a los cambios más significativos del ambiente. Los filtros adaptativos ordinarios también cuentan con la habilidad de ajustar sus parámetros de forma automática de acuerdo con las variaciones estadísticas del ambiente [6, 7]; no obstante, su capacidad adaptativa en el procesamiento de señales es limitada debido a su formulación estructural como simples combinadores lineales.

- Las RNA proporcionan un enfoque no paramétrico para la estimación no lineal de datos.

El tipo de RNA no lineal, *feedforward* multicapa aprende de su ambiente en una forma supervisada. Estas redes, en particular, se someten a una sesión de entrenamiento durante la cual ajustan sus parámetros libres, de cierta manera y persiguiendo minimizar una función de costo. Típicamente, esta función de costo se define basándose en un criterio de error cuadrático medio, con el propio error de la señal definido como la diferencia entre una respuesta deseada y la salida actual de la red, producida en respuesta a una señal de entrada correspondiente. La RNA aprende de ejemplos conformando un mapa de la entrada-salida para el problema en cuestión, el cual da una idea de inferencia estadística no paramétrica. El término “no paramétrico”, se emplea en un sentido estadístico, indicando que no se requiere conocimiento acerca de la distribución probabilística principal.

- Las RNA, al operar de forma supervisada, son consideradas aproximadores universales.

Las redes *feedforward* multicapa son aproximadores universales en el sentido de que cualquier mapeo de entrada-salida continuo puede ser aproximado a un grado determinado, una vez dado un número suficiente de unidades ocultas [8-10]. Esta propiedad también está compartida por los métodos clásicos basados en

el empleo de funciones “suaves” tales como los polinomios algebraicos y trigonométricos.

### 1.3. Criterios para la aceptación de las RNA

Para evaluar un procesador de señales como “bueno”, figuran dos atributos particulares:

- Preservación óptima de la información disponible, y por consiguiente, funcionamiento óptimo en algún sentido estadístico.
- Robustez en el funcionamiento respecto a pequeñas variaciones en las condiciones ambientales.

Dados estos atributos, las RNA pueden ganar aceptación como herramientas para resolver problemas de procesamiento estadístico de señales, preferentemente a los métodos tradicionales, si:

- Emplear una red neural genera una diferencia significativa de la eficiencia estadística de un sistema, para una aplicación del mundo real; o puede proporcionar una reducción significativa en el costo de la implementación sin comprometer la eficiencia.
- Gracias a su estructura distribuida y masivamente paralela, una red neuronal ofrece una degradación menos aguda de la eficiencia, debido a los inevitables fallos de los componentes de la red.
- El ajuste de los parámetros en las RNA constituye una tarea más fácil, y por tanto, fácilmente acometida por usuarios inexpertos, que lo que sería con otros métodos no paramétricos.
- A través del uso de las RNA, solas o en combinación con otros dispositivos, es posible resolver problemas de procesamiento de señales, para los que no existen soluciones viables empleando métodos estándares.

Una limitación práctica de las RNA lo constituye el hecho de que durante el trabajo con datos del mundo real, el entrenamiento para una aplicación determinada puede tomar un tiempo muy largo; la longitud del entrenamiento estaría visto en el contexto de los recursos de cómputo disponibles. El tiempo de cómputo relativamente grande necesitado para entrenar una red neural se debe a la arquitectura de computación que se emplea corrientemente (serie por naturaleza), la cual está muy mal preparada para programar redes neurales.

Otra debilidad radica en que es a menudo dificultoso precisar cómo el conocimiento adquirido por la RNA sobre su ambiente se encuentra representado actualmente dentro de la red. Algunas herramientas de mostrar gráficamente, tales como el diagrama de Hinton

y el de lazo han sido desarrolladas para remediar esta dificultad [11, 12, 13].

## 2. METODOLOGÍA

### 2.1. Materiales

Todo el trabajo se realizó a través de simulaciones desde el *software* Matlab, ver. 5.1 de MathWorks, Inc. Con este programa fueron implementadas todas las muestras ruidosas, así como las arquitecturas de redes, tanto durante el entrenamiento, como durante la operación. El equipo computacional utilizado para las simulaciones se correspondió con un ordenador AcerOpen, en red sobre plataforma Windows NT.

### 2.2. Método

Inicialmente se obtienen varios patrones de determinado tipo de ruido, blanco Gaussiano o impulsivo, en dependencia del que se desee cancelar, para posteriormente emplearlos durante el entrenamiento de una arquitectura neural. Durante el entrenamiento, estos grupos específicos de patrones estarían dados a la entrada y se tendría como salida deseada el valor esperado para cada patrón de ruido y así conformar el correspondiente “mapeo” de entrada/salida inherente al aprendizaje supervisado.

Una vez entrenada la arquitectura, esta es operada presentándole a la entrada la señal útil contaminada por el ruido (del mismo tipo con que fue entrenada), y, si la red entrenó correctamente, se obtendría a la salida un dato que se adecuaría con el valor medio o esperado (señal deseada). La forma en que se operará, se muestra en la Figura 1 y se corresponde con la forma de procesar series de tiempo a través de RNA (tareas de predicción estadística, por ejemplo).

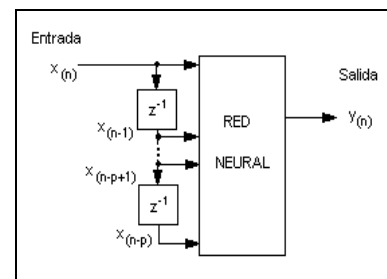


Figura 1: Forma de operación de la Red Neural

Así, el vector de entrada estaría representado en términos de las muestras de entradas pasadas.

Como se puede apreciar, el método implementado es análogo a la tarea de reconocimiento de patrones estándar con la única diferencia en que en este caso, los patrones a procesar son señales que varían en el tiempo y que habría que considerarlos entonces como patrones dinámicos.

Específicamente en este estudio, el índice que se toma para mostrar el comportamiento efectivo de la red es la **correlación** entre la señal a la salida de la red neural (esto es durante la operación) y la señal útil sin contaminar que se emplea como señal de prueba.

Por otra parte, este enfoque *feedforward* de cancelación de ruido hace más conveniente su aplicación en tareas afines con las telecomunicaciones y la bioingeniería, entre otros, debido a la diferencia de este respecto al enfoque adaptativo clásico de extracción de ruido. En este último, para realizar la cancelación, se requieren dos señales: una muestra compuesta por la señal útil más el ruido, y otra muestra conformada por una muestra bien correlacionada con el ruido contaminante. Como ya se planteó y resulta conocido, en ocasiones es muy difícil, o casi imposible, obtener la segunda señal; para ese caso, este enfoque *feedforward* empleado, en el que sólo se utiliza la señal útil contaminada por el ruido para efectuar su extracción, constituiría una solución más efectiva y viable.

### 3. Tipos de Redes Neurales Empleadas

Básicamente, las arquitecturas puestas en consideración son:

1. Una arquitectura *feedforward* de una capa y pesos fijos, configurando la estructura de un filtro FIR (*finite-duration impulse response*) promedio. Este modelo no incluye etapa de entrenamiento y sus pesos tienen valores fijos (1/cantidad de neuronas de la capa de entrada).
2. Una arquitectura *feedforward* con la misma estructura que el anterior, sólo que se implementa un algoritmo de entrenamiento LMS (*least-mean-square*) determinando la variación de los pesos sinápticos.
3. Arquitectura perceptrón multicapa estático, implementando la estructura con varias capas de neuronas ocultas y algoritmo de entrenamiento *Backpropagation* estándar.
4. Arquitectura perceptrón multicapa FIR o dinámico, implementando la estructura con varias capas de neuronas ocultas y algoritmo de entrenamiento *Backpropagation* temporal.

Esta última arquitectura (perceptrón multicapa FIR) constituye una extensión del diseño del perceptrón multicapa, estructura básica implicada en el reconocimiento de patrones, para que asuma una forma variante en el tiempo y por tanto, sea capaz de tratar con señales variantes en el tiempo. Tal extensión del diseño consiste, esencialmente, en modelar cada sinapsis de la red como si fuese un filtro FIR [11].

Esta modificación en el modelo general del perceptrón multicapa hace que no se pueda aplicar el algoritmo de entrenamiento *Backpropagation* estándar en el modo en que usualmente se propone y por este motivo, se implementa el algoritmo *Backpropagation* temporal [11] como generalización del estándar para el procesamiento de señales variantes en el tiempo.

### 4. Resultados

Los resultados mostraron la efectividad del empleo de las RNA en tareas de procesamiento estadístico de señales, específicamente en la cancelación de ruido.

Más en detalle, fue posible constatar cómo la mejor arquitectura para este tipo de aplicación es, sin lugar a dudas, y contando con toda la teoría establecida, el modelo que incorpora intrínsecamente el factor *tiempo*, en este caso, el perceptrón multicapa FIR con el algoritmo de entrenamiento *Backpropagation* temporal. Y su efectividad se aprecia de manera más aguda cuando se trata con señales que no presentan un comportamiento estacionario.

A manera de ejemplo, se muestra a continuación una tabla (Tabla 1.) donde se aprecian algunos resultados obtenidos durante el trabajo (operación) con los diferentes modelos, en base a la **correlación** obtenida.

Tabla 1: Resultados en base a la correlación

Red empleada	Correlación (Ruido Blanco Gaussiano) (Mejor dato obtenido)	Correlación (Ruido Impulsivo + Blanco Gaussiano) (Mejor dato obtenido)
Red 1	0.7406	0.4629
Red 2	0.792	0.5401
Red 3	0.7012	0.40
Red 4	0.913	0.803

Red 1: Arquitectura *feedforward* de una capa y pesos fijos configurando la estructura de un Filtro FIR Promedio. Para el ejemplo referido, el mejor resultado obtenido recayó en

el modelo con 5 neuronas en la capa de entrada durante la detección de señal contaminada tanto por ruido blanco solo, como por ruido blanco más ruido impulsivo.

Red 2: Arquitectura *feedforward* con la misma estructura que la anterior, sólo que se implementa un algoritmo de entrenamiento LMS (Regla Delta) para ajustar los pesos sinápticos. Tanto para la presencia de ruido blanco, como de ruido blanco más impulsivo, el mejor valor de correlación que se obtuvo se correspondió con una arquitectura con 10 neuronas en la capa de entrada (1000 épocas de entrenamiento).

Red 3: Arquitectura perceptrón multicapa estático, implementando la estructura con varias capas de neuronas ocultas y algoritmo de entrenamiento *Backpropagation* estándar. Con la presencia de ruido blanco, el mejor valor de correlación se obtuvo con una estructura neural de dos capas: 2 neuronas en la capa de entrada y 7 en la capa oculta. Para el caso de ruido blanco más ruido impulsivo, el mejor dato se tuvo con 2 neuronas en la capa de entrada y 10 neuronas en la capa oculta. Para ambos casos, se implementaron 1000 iteraciones durante el entrenamiento.

Red 4. Arquitectura perceptrón multicapa FIR o dinámico, implementando la estructura con varias capas de neuronas ocultas y algoritmo de entrenamiento *Backpropagation* temporal. Durante la detección de señal contaminada sólo por ruido blanco, el resultado más alto de correlación obtenido se correspondió con un modelo de dos capas: 7 neuronas en la capa de entrada y 10 neuronas en la capa oculta. Para el caso de la incidencia de ruido blanco más impulsivo, la arquitectura óptima fue de 10 neuronas en la capa de entrada y 10 neuronas en la capa oculta. 500 iteraciones se generaron durante los entrenamientos debido al largo tiempo que toma dicho entrenamiento.

En todas las redes en estudio, se experimentó con una neurona en la capa de salida.

A modo de ejemplo, se tratará una señal sinusoidal de 1 Hz ( $f_s$ ) y amplitud unitaria, muestreada a una frecuencia de 10 Hz ( $f_m$ ) y contaminada por una señal de ruido blanco Gaussiano (Figura 2.). Constituye un ejemplo para el que  $f_m/f_s = 10$ , donde, para una aplicación práctica, este sería un factor importante. El proceso que se apreciará será el de operación cuando la red fue entrenada ya con muestras de dicho ruido.

En este caso, se proponen como ejemplos la operación de la red *feedforward* con pesos fijos (Filtro FIR Promedio) y la arquitectura perceptrón multicapa FIR, después de entrenada. El resultado de la operación en estos

modelos se muestra en las Figuras 3 y 4 y constituyen el producto de dar, a la entrada de las arquitecturas, la señal patrón más el ruido Gaussiano (Figura 2) en la forma mostrada en la Figura 1.




Figura 2 : Sinusoide más Ruido Blanco Gaussiano

Para ambos casos se identificarán las señales de la siguiente forma:

- Sinusoide pura patrón
- Señal a la salida de la red neural




Figura 3 : Operación de la red feedforward (pesos fijos)

Se puede apreciar en la Figura 3, cómo no se obtiene una buena correlación entre la señal sinusoidal y la señal a la salida de la red durante la operación con la red de pesos fijos.

Sin embargo, en la Figura 4 se puede notar la eficiencia del perceptrón multicapa FIR, al obtenerse un mejor índice de correlación.

En esta última arquitectura, para las primeras muestras, no se obtienen resultados adecuados, sin embargo, a medida que transcurre el tiempo, la eficiencia va en aumento, hasta llegar a estabilizarse en un valor.




Figura 4 : Operación de la red perceptrón multicapa FIR

## 5. Conclusiones

Es posible concluir que con el empleo de técnicas neuronales en la búsqueda de hacer mínima la influencia del ruido en determinada señal, se obtienen excelentes resultados, sobre todo cuando se emplean arquitecturas que contienen intrínsecamente el factor *tiempo*.

En los casos puestos en consideración, se obtuvieron los mejores resultados con la aplicación del modelo Perceptrón Multicapa FIR, empleando como algoritmo para el entrenamiento, el *Backpropation* temporal.

## Referencias bibliográficas

- [1] B. P. Lathi. Signals, Systems and Communication. John Wiley & Sons, Inc, p. 515-584, 1965.
- [2] A. B. Carlson. Communications Systems. An introduction to Signals and Noise in Electrical Communications.
- [3] D. O. North. An analysis of the factors which determine signal-noise discrimination in pulsed carrier systems. Proc. IEEE, vol. 51, p. 1011-1027, 1963.
- [4] J. H. Van Vleck y D. Middleton. A theoretical comparison and meter reception of pulsed signals in the presence of noise. J. Phys., vol. 17, p. 940-971, 1946.
- [5] N. Wiener. Extrapolation, Interpolation, and Smoothing of Stationary Series with Engineering Applications. Wiley, 1949. (Este libro fue originalmente emitido como Documento Clasificado del Consejo de Investigaciones de Defensa Nacional, en Febrero de 1942).
- [6] S. Haykin. Adaptive Filter Theory. Third Edition, Prentice-Hall, 1985.
- [7] B. Widrow y S. Stearns. Adaptive Signal Processing. Prentice-Hall, 1985.
- [8] G. Cibenko. Approximation by superpositions of a sigmoidal function. Math, Control, Signals, and Systems, vol. 2, p. 303-314, 1989.
- [9] K. Hornik, M. Stinchcombe, y H. White. Multilayer feedforward networks are universal approximators. Neural Networks, vol. 2, p. 359-366, 1989.
- [10] J. Park y I. W. Sandberg. Universal approximation using radial-basis function networks. Neural Computation, vol. 3, p. 246-257, 1991.
- [11] S. Haykin. Neural Networks: A Comprehensive Foundation. New York, Macmillan College Publishing Company, 1996.
- [12] G. E. Hinton y T.J. Sejnowski. Learning and relearning in Boltzmann machines. En Parallel Distributed Processing editado por D.E. Rumelhart and J.L. McClelland, MIT Press, 1986.
- [13] J. Wejchert y G. Tesauro. Visualizing processes in neural networks. IBM J. Res. and Dev., vol. 35, p. 244-253, 1991.