

PRONÓSTICO DE FALLAS DE SISTEMAS REPARABLES UTILIZANDO REDES NEURONALES ARTIFICIALES

RESUMEN

Este artículo propone una metodología que permite pronosticar el número de fallas en un sistema mediante el uso de redes neuronales artificiales. Se muestra el desarrollo de la metodología propuesta mediante su aplicación a las líneas primarias de distribución de energía de la ciudad de Pereira.

MARCELO ARBELÁEZ G.

Ingeniero Electricista
Profesor
Universidad Tecnológica de Pereira
marte@utp.edu.co

PALABRAS CLAVES: Procesos estocásticos puntuales, confiabilidad, redes neuronales artificiales.

ABSTRACT

This paper presents a methodology to forecast failures in a system using Artificial Neural Networks. The development of the methodology proposed is shown by its application to the primary lines of electric energy distribution of the city of Pereira.

KEYWORDS: Stochastic point processes, reliability, artificial neural networks.

1. INTRODUCCIÓN

En confiabilidad existen dos tipos de sistemas: los orientados a una misión y los continuamente operados. Estos últimos son los más abundantes y representativos dentro de las actividades humanas diarias.

Cuando es necesario estudiar el efecto de la disponibilidad de un sistema continuamente operado, el tipo de modelamiento empleado es el de sistema reparable. Para este tipo de sistemas, las fallas que ocurren durante la operación interrumpen el servicio continuo que éste brinda, ocasionando pérdidas a todos los agentes que dependen de él.

Dentro de los objetivos de la confiabilidad de sistemas están: la determinación del estado y el pronóstico de estados futuros del sistema para implementar acciones correctivas que mejoren su funcionamiento.

Para determinar el estado actual de un sistema, los datos históricos de la operación en el tiempo, de cada uno de sus componentes, representan el punto de partida para el análisis. Con esta información es posible encontrar los índices de confiabilidad que muestran el estado actual del sistema y realizar inferencia estadística basada en modelos probabilísticos.

Los procesos estocásticos puntuales permiten usar datos históricos para la obtención de modelos que puedan observar el comportamiento futuro del sistema.

En algunas ocasiones, las herramientas probabilísticas tradicionales no permiten encontrar los modelos analíticos debido a la complejidad que pueden presentar los datos empleados.

Las redes neuronales, son una herramienta adecuada para trabajar problemas matemáticos que no tienen forma analítica. Permiten aproximar funciones complejas y caracterizar comportamientos y predecir.

Se emplearán estas propiedades de las redes neuronales para obtener el modelo de la función de conteo del número de fallas $N(t)$ a partir de datos aleatorios continuos.

2. SECUENCIA OPERATIVA DE UN SISTEMA

En los sistemas reparables, para efectos de confiabilidad los eventos que llegan en el tiempo de forma aleatoria son las fallas. La figura 1 muestra el comportamiento de un sistema continuamente operado donde el tiempo de reparación es tan pequeño que se desprecia frente al tiempo transcurrido entre las fallas.




Figura 1. Secuencia Operativa de un Sistema

Los dos estados posibles para un sistema son: disponible e indisponible. La variable x corresponde a los tiempos entre fallas consecutivas y la variable t a los tiempos para que ocurran fallas.

3. PROCESOS ESTOCÁSTICOS PUNTUALES

El enfoque de modelamiento clásico centra su atención en los modelos de componentes reparables usando solamente distribuciones de probabilidad.

Según Ascher [1] este tipo de análisis no tiene en cuenta el cambio en el comportamiento del sistema en el tiempo. Reconocer esta característica requiere de pruebas que permiten determinar si el proceso es estacionario o cambia con el tiempo.

Este tipo de procesos presenta la característica de ser discretos en el estado (disponible o indisponible) y continuos en el tiempo.

Los procesos estocásticos puntuales son parte de la teoría de colas, y tienen una aplicación ampliamente extendida en telecomunicaciones.

La tendencia de un proceso de fallas de un sistema reparable, está relacionada directamente con la tasa de fallas, es decir, si el proceso no tiene tendencia o es estacionario, la tasa de fallas es constante, pero si el proceso tiene tendencia, la tasa de fallas puede aumentar o a disminuir.

La prueba de Laplace permite determinar cuál es la tendencia que tienen los datos históricos que serán ajustados a un proceso estocástico puntual.

Si se tiene una muestra de n tiempos para la ocurrencia de fallas t_1, t_2, \dots, t_n , se define el siguiente estadístico de prueba de tendencia de Laplace:

$$U_L = \frac{\left(\frac{1}{k} \sum_{i=1}^k t_i\right) - \frac{1}{2}T}{T \sqrt{\frac{1}{12k}}} \quad (1)$$

Donde,

k : Es igual a $(n-1)$, si las observaciones terminan en el último evento, de lo contrario es igual a n .

T : Es igual a t_n si las observaciones terminan en el último evento, de lo contrario, es igual al periodo total de las observaciones.

Si:

$U_L = 0$ El proceso es estacionario.

$U_L > 0$ Existe tendencia creciente.

$U_L < 0$ Existe tendencia decreciente.

El número de fallas que se cuentan en un intervalo $(0, t]$ es $N(t)$; proceso entero de conteo de fallas hasta un tiempo t .

Tiene las siguientes características:

- $N(t)$ es un valor entero.
- $N(0) = 0$.
- $N(t) \geq 0$.
- Si $s < t$ entonces $N(t) - N(s)$ es igual al número de eventos en el intervalo (s, t) .

Dependiendo del proceso estocástico y de los datos, el número de fallas no tiene forma analítica o es muy difícil de obtener y no hay como tal una prueba de ajuste que permitan obtener de forma directa el modelo.

3.1 Proceso de Poisson Homogéneo

Es el proceso que representa una secuencia de tiempos entre fallas independiente e idénticamente distribuida (IID) que se ajustan a la distribución exponencial que tiene una tasa de eventos constante. Sus siglas en inglés HPP corresponden a "Homogenous Poisson Process". Este no tiene tendencia y el valor esperado del número de fallas para este proceso es:

$$E[N(t)] = \lambda \cdot t \quad (2)$$

Donde,

λ : es la tasa de ocurrencia de fallas.

t : es el periodo de estudio.

3.2 Procesos de Renovación

En este proceso, cuando ocurre una falla (evento), el sistema regresa al mismo estado que tenía antes. "Same as old". Los tiempos entre eventos forman una secuencia IID.

Es un proceso que no tiene tendencia y las características que lo definen estarán dadas por las distribuciones de probabilidad que se ajusten a los datos.

3.3 Proceso de Poisson No Homogéneo

A diferencia de los procesos anteriormente citados, este proceso, es un proceso con tendencia, es decir, los tiempos entre fallas pueden aumentar o disminuir, por lo tanto no forman una secuencia IID. Sus siglas en inglés NHPP corresponden a "Non Homogenous Poisson Process".

El valor esperado del número de eventos que ocurren es:

$$E[N(t)] = \int_0^t \lambda(t) dt \tag{3}$$

$\lambda(t)$: es la tasa de ocurrencia de fallas.
 t : es el periodo de estudio.

Esta definición muestra que la tasa de ocurrencia de fallas, varía con el tiempo, es decir, no es constante, como en los procesos anteriores.

3.4 Selección de un Modelo Para un Proceso de Llegada de eventos

Ascher [1] propone la siguiente metodología para la selección de un modelo de llegada de eventos:

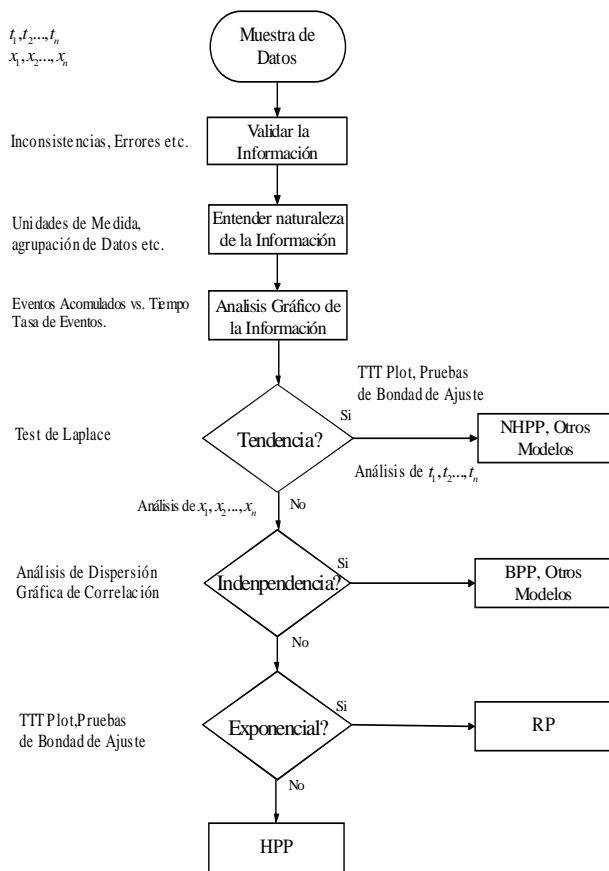


Figura 1. Diagrama de flujo para selección de un modelo.

4. REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales, son una técnica inspirada en las redes de neuronas biológicas que permiten emular de cierta manera el cerebro humano. Tal como éste, es necesario adquirir cierta información previa para poder aprender un comportamiento y después reproducirlo.

4.1 Definición

Una red neuronal es una estructura paralela que procesa información en forma distribuida con base en conocimientos previos (memoria). La interconexión de varias neuronas forma una red neuronal, cuyos elementos básicos son: las entradas, los pesos, las bías, la función de transferencia y las salidas.

4.2 Tipos de Aprendizaje

En las redes neuronales artificiales el conocimiento se encuentra almacenado en los pesos de la interconexión y las bías. El proceso de aprendizaje también es llamado algoritmo de entrenamiento. En el proceso, lo que se hace es cambiar estos valores hasta que la salida sea la adecuada así:

1. La red es estimulada.
2. La red responde a ese estímulo.
3. La red modifica los parámetros libres en respuesta al estímulo.

Existen tres tipos de entrenamientos:

1. Supervisado.
2. No supervisado.
3. Por esfuerzo.

4.3 Pronóstico

La principal característica de las redes neuronales artificiales es su capacidad de usar datos históricos para después realizar pronósticos. Según [2] una de las redes más empleadas para tal labor es la red Backpropagation que es una generalización de los algoritmos de entrenamiento para redes multicapa.

La red Backpropagation es una red de aprendizaje supervisado en dos fases. En la primera fase se propaga un estímulo desde la primera capa hasta la salida. La diferencia entre la salida obtenida y la salida deseada es el error. En la segunda fase se hace una propagación hacia atrás del error partiendo de la capa de salida hasta la capa de entrada. Este proceso se repite hasta que se alcance el grado de aproximación deseado.

5. METODOLOGÍA PROPUESTA

El objetivo de la siguiente metodología es simular el comportamiento de una variable aleatoria que es propia de los procesos estocásticos puntuales y no tiene modelo analítico.

Los datos de entrenamiento para la red, corresponden a datos históricos organizados cronológicamente que corresponden para la entrada a los tiempos para falla $t_1..t_n$ durante un intervalo de tiempo y para la salida el número acumulado de fallas del sistema en el tiempo.

Mediante ensayo y error se encuentra que la red neuronal más apropiada es la Backpropagation, con funciones de transferencia sigmoideal en la capa oculta y purelin en la capa de salida, lo que da a la red una respuesta que es la superposición de funciones de transferencia de la capa de entrada.




Figura 2. Gráfica Simplificada de la Red Neuronal.

Para la figura 2:

- p: es el vector de entrada.
- R: es el número de entradas.
- w: es la matriz de pesos de las capas.
- S: es el número de neuronas por capa.
- a: es la salida por capa.

Una vez la red neuronal ha sido entrenada, está se comportará como la función de número de fallas de un proceso estocástico puntual, que permitirá realizar estimaciones de comportamientos futuros.

El procedimiento a seguir para ajustar la función de número de eventos empleando redes neuronales es el siguiente:

1. Organizar los tiempos para falla cronológicamente.
2. Con ellos obtener el número de eventos acumulados en el tiempo.
3. Se define el conjunto de entrenamiento de la red, con entradas iguales a los tiempos para falla, y las salidas el número de eventos acumulados en el tiempo. Como las funciones de transferencia solo van hasta 1, este conjunto debe estar normalizado.
5. Se diseña una red Backpropagation.
6. Se realiza el proceso de entrenamiento con rata de aprendizaje constante.

Así dado cualquier valor de tiempo para falla, la red entregará el respectivo número de fallas hasta ese tiempo.

6. CASO DE ESTUDIO

Las líneas primarias tienen gran importancia para la confiabilidad del servicio debido a que las salidas afectan sectores que tienen muchos usuarios. La reglamentación Colombiana [3] estableció indicadores de calidad del servicio llamados DES y FES. Esto justifica aún más que se realicen estudios de confiabilidad del comportamiento futuro del sistema.

Con la información obtenida de las bitácoras de las subestaciones de la Empresa de Energía de Pereira entre el año 2000 y 2004, se desarrollará la metodología propuesta para el caso del grupo de líneas primarias industriales de 13.2kV del sistema de distribución de la ciudad. Un total de 250 datos indican el momento de ocurrencia de la fallas en orden cronológico. La referencia [4] suministra más información acerca de las líneas industriales.

Mediante aplicativos desarrollados en MATLAB para el ajuste de datos a procesos estocásticos puntuales se obtienen los resultados que son mostrados en la tabla 1.

Prueba	Resultado
Test de Laplace	0.6043
Ajuste a HPP	Ninguno
Ajuste a Proceso de Renovación	Ninguno
Ajuste a NHPP	Ninguno

Tabla 1. Resultados de las técnicas Analíticas.

Los resultados muestran que los procedimientos probabilísticos tradicionales fracasaron en su intento por encontrar un modelo matemático que represente los datos históricos.

La figura 3 muestra la forma que tiene la función de conteo de fallas $N(t)$ de los datos históricos en el caso de las líneas primarias industriales de 13.2kV.




Figura 3. Eventos Acum. v.s Tiempo para falla.

Es de notar que a aunque la función de conteo de fallas aparenta ser lineal, no tiene punto a punto este comportamiento.

Inicialmente se aplica la metodología propuesta a una red Backpropagation con una arquitectura 1-6-1. El tiempo computacional que esta red necesita para su entrenamiento es de 3min.

Con el objetivo de aumentar el desempeño de la red neuronal, se aumenta el número de neuronas de la capa de entrada hasta 16. La arquitectura es entonces la de una red Backpropagation 1-16-1. El tiempo computacional que esta red necesita para su entrenamiento es de 7min.

La figura 4 muestra el comportamiento de las salidas de ambas redes y permite elegir la red que tiene el mejor comportamiento.

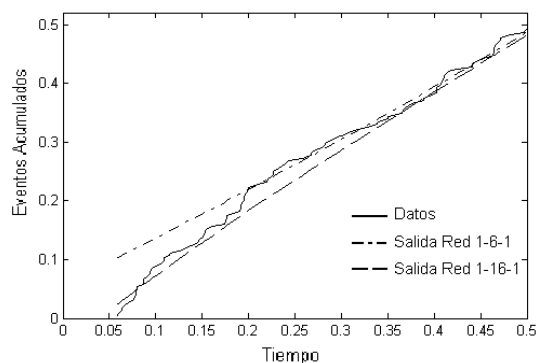


Figura 4. Comparación entre la forma de los datos y las salidas dadas por las redes.

La red de mejor comportamiento es la Backpropagation 1-16-1 que muestra un menor distancia a los datos. La figura 5 muestra la salida de esta red.

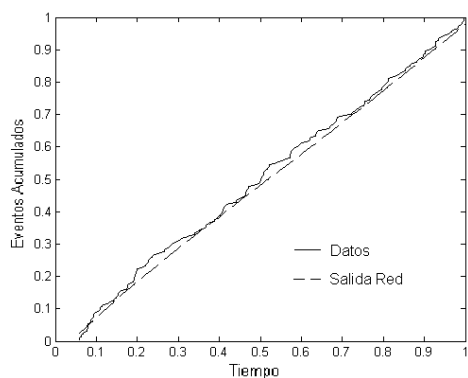


Figura 5. Comparación entre la forma de los datos y la salida dada por la segunda red.

La red entrenada permite generar las fallas del grupo de líneas dado el tiempo de operación. Esta propiedad puede ser entonces empleada, colocando la red dentro de la topología de un sistema de distribución que tiene conectados otros componentes como: interruptores de potencia, transformadores, para realizar una simulación de Monte Carlo que permite ver el comportamiento de

todo el sistema en conjunto para el mediano y largo plazo.

7. CONCLUSIONES Y RECOMENDACIONES

El método propuesto presenta la ventaja de realizar un ajuste punto a punto, que permite tener mayor precisión a la hora de realizar un estudio de confiabilidad en sistemas de potencia u otras aplicaciones.

El costo computacional elevado que requiere la red para su entrenamiento es desventajoso si se compara con el tiempo necesario para la implementación de metodologías tradicionales. Sin embargo, una vez entrenada su respuesta es en tiempo real.

Las redes neuronales artificiales resultan un medio muy flexible de realizar aproximaciones a problemas que no tienen una forma analítica. La aproximación realizada a diferencia de las técnicas clásicas, es no lineal, representando más precisamente el comportamiento de los datos.

La confiabilidad de sistemas es un área del conocimiento muy extendida que en la búsqueda de realizar aplicaciones, constantemente lleva a problemas matemáticos no lineales de difícil solución.

8. BIBLIOGRAFÍA

- [1] ASCHER, H. FEINGOLD, H. Repairable Systems Reliability: Modeling, Inference, Misconceptions and Their Causes, Marcel Dekker, 1984.
- [2] HAGAN, H. HOWARD, B. Neural Network Design, PWS, 1996.
- [3] CREG, Reglamento de Distribución, Resolución 070 de 1998.
- [4] ZAPATA, C. J. LEYES, M. PATIÑO, M. Índices de Confiabilidad de Circuitos Primarios de Distribución, Proyecto de Grado, Universidad Tecnológica de Pereira, 2004.
- [5] TORRES, A. Probabilidad, Variables Aleatorias y Procesos Estocásticos en Ingeniería Eléctrica, Universidad de los Andes, 1996.
- [6] ZAPATA, C.J. Confiabilidad de Sistemas Eléctricos, Universidad Tecnológica de Pereira”, 2005.