

# Predicción de Tráfico en Redes Multiservicios aplicando Redes Neuronales

Mag. Ing. Mario M. Figueroa de la Cruz, Dr. Ing. Pablo Cesar Rovarini

Mag. Lic. Claudia I. Solorzano, Ing. Hugo Ibarra

mfiguero@gmail.com, provarini@gmail.com, clausol2@yahoo.com.ar, hugo.l.ibarra@gmail.com

Universidad Tecnológica Nacional – Facultad Regional Tucumán

Rivadavia 1050 – San Miguel de Tucumán - Argentina

**Resumen:** *Este trabajo de investigación busca como objetivo general obtener un modelo aplicable a la Reingeniería en Redes Globales Multiservicios basado en Inteligencia Artificial, que permita posteriormente la implementación de un prototipo de software adaptable a su ambiente, con la capacidad de resultar una herramienta importante en aplicaciones reales sobre problemas de gran complejidad.*

**Abstract:** *This research seeks to obtain a general objective of the reengineering model applicable to Multiservice Global Networks based on in Artificial Intelligence, subsequently allowing the implementation of a software prototype adapted to their environment, with the ability to be an important tool in applications on actual problems of great complexity.*

**Palabras clave:** Predicción de Tráfico, Redes Neuronales, Redes Multiservicio

## 1. Introducción

El auge de las telecomunicaciones ha producido una transformación de las tecnologías de la información y de la comunicación, cuyo impacto ha afectado a todos los sectores de la sociedad [5]. Las redes Multiservicios [1] se han convertido para empresas y organizaciones públicas o privadas en la manera más rápida, eficiente y segura de transmitir información, compartir aplicaciones, administrar recursos, intercambiar datos entre usuarios internos; agilizan en un paso gigante al mundo, porque grandes cantidades de información se trasladan de un sitio a otro, siendo su función principal interconectar redes o equipos terminales que se encuentran ubicados a grandes distancias. Estos cambios en el escenario de las TI están activando, individual y colectivamente, el crecimiento exponencial en el tráfico de los sitios. Las empresas tendrán que reaccionar a este crecimiento ya que si no se aumentan anchos de banda y se prioriza los nuevos tráficos, se encontrarán con que las aplicaciones deberán competir por recursos congestionados [4].

Este trabajo busca desarrollar un modelo de sistema informático utilizando algoritmos de Inteligencia Artificial, específicamente las Redes Neuronales, para predecir el tráfico en las Redes Globales multiprotocolo.

## 2. Líneas de Investigación: Diseño de Redes Multiservicios

En el proceso de diseño de una red multiservicio [1] [3] o adaptación de una red existente [5] a los nuevos entornos se deben considerar varios factores donde el tráfico es el director de las diferentes alternativas a considerar. En una primera aproximación, se deben considerar lo siguiente:

1. Empezar a analizar la red WAN de la empresa o entidad, unificando, en un mismo medio, voz, datos y video.
2. Adquisición de nuevas infraestructuras por crecimiento de nuevas necesidades. Se realiza ya en un ambiente de una red multiservicio, adquiriendo

teléfonos IP, switches preparados para telefonía IP con calidad de servicio (QoS), etc.

3. Sustitución tecnológica se va realizando en función de que el equipamiento está ya obsoleto o inservible.
4. Necesidades de seguridad en las conversaciones de voz y la transmisión de datos.
5. Reducción de pérdidas de información y conectividad que afectan los procesos productivos.
6. Justificación de costes basados en nuevas aplicaciones que aumentarán la productividad y rentabilidad de negocios y tareas administrativas.

### 2.1 Resultados y Objetivos

En la elaboración de un modelo experimental para pruebas y diagnósticos [6], se deben considerar los siguientes pasos:

1. Realización del diseño de la estructura de red, teniendo en cuenta tanto su topología física como lógica.
2. Selección de Estadísticas de Tráfico. Se deben seleccionar las variables de tráfico de las cuales se desee generar datos, estas estadísticas permitirán conocer el desempeño de la red.
3. Simulación de la red de comunicación diseñada. Una vez definido el diseño, se procede a las respectivas simulaciones que imitarán el funcionamiento del modelo de red creado cuando evoluciona en el tiempo.
4. Recolección de estadísticas, datos del escenario de red: Coleccionar estadísticas que describan el comportamiento de la red de datos.
5. Construcción del modelo neuronal. Determinación de la arquitectura y los parámetros necesarios para obtener el modelo de predicción, entrenamiento, simulación.
6. Entrenamiento y Simulación del Modelo Neuronal óptimo adoptado.

- Análisis, interpretación y evaluación de los resultados de Predicción. Interpretar y evaluar los resultados predictivos producidos por el modelo de RN.

### 3. Construcción del Modelo Neuronal

Las Redes Neuronales Artificiales [8] [9] [10] son modelos de predicción, que al igual que los indicadores técnicos, usan datos del pasado, pero con la ventaja de permitir incorporar la información de múltiples indicadores junto con información fundamental, explotando la ventaja de ser un modelo no paramétrico y permitiendo inferir resultados futuros.

En la construcción de la Red Neuronal se utilizó la herramienta Nntool (Neural Network Toolbox) perteneciente a Matlab, modelando una red neuronal Backpropagation.

#### 3.1 Diseño de Estructura de la Red

En el diseño de la estructura de red de datos, se utilizó la herramienta Opnet Modeler [7], versión académica. Este simulador permite diseñar, construir y estudiar redes, dispositivos, protocolos y aplicaciones de comunicaciones, con una gran flexibilidad para poder variar las características de cada elemento de la red.

#### 3.2 Recolección de Estadísticas del Tráfico de red

Antes de iniciar la simulación es necesario especificar las estadísticas que se quieren recopilar. La selección de las estadísticas se puede hacer de diferentes maneras, obtener resultados globales del escenario, resultados específicos de cada nodo, resultados de enlaces y resultados de demanda de tráfico. Los modelos de tráfico considerados son:

- Data Base
- Email
- Ftp
- Ethernet
- Http
- IP
- TCP
- Voice
- VPN

#### 3.3 Selección de variables

Determinar qué variables de entrada son importantes en el pronóstico es un punto crítico [8] y [9]. En este caso, el interés en la predicción involucra emplear como entradas datos técnicos en lugar de fundamentales por las características mismas de la investigación.

En este trabajo se definen tres variables de entrada:

- Tiempo: Tiempo transcurrido en segundos.
- Usuarios: cantidad de usuarios en la red.
- Ancho de banda: Cantidad de información o de datos que se puede enviar a través de una conexión de red en un período dado definido en bps.

### 3.4 Conjuntos de entrenamiento y prueba

Del total de datos de la muestra, se divide en dos conjuntos, llamados de **entrenamiento** y **prueba** [9] [10]. El conjunto de entrenamiento es el más grande y es utilizado por la red neuronal para aprender los patrones existentes en los datos. El conjunto de prueba, que varía del 10% al 30% del conjunto de entrenamiento, se utiliza para evaluar la capacidad de generalización de una red ya entrenada. Se selecciona la red que se desempeña mejor de acuerdo con el conjunto de prueba, con el menor número de errores. Algunas veces también se incluye un conjunto de validación el cual debe consistir de las observaciones más recientes.

El conjunto de prueba puede ser seleccionado ya sea aleatoriamente del conjunto de entrenamiento o consistir de un conjunto de observaciones ubicadas inmediatamente después del conjunto de entrenamiento.

### 3.5 Diseño de la red en Opnet Modeler

Se define una red WAN para pruebas, entre las provincias de Salta y Tucumán (Figuras 1 y 2) en la Rep. Argentina.

La red correspondiente a Tucumán está compuesta por una red LAN, teléfonos IP, y un router que se conecta a la red de Salta, mediante un enlace PPP DS1 (enlace punto a punto). La red de Salta contiene los servidores y teléfonos IP conectados a un router.

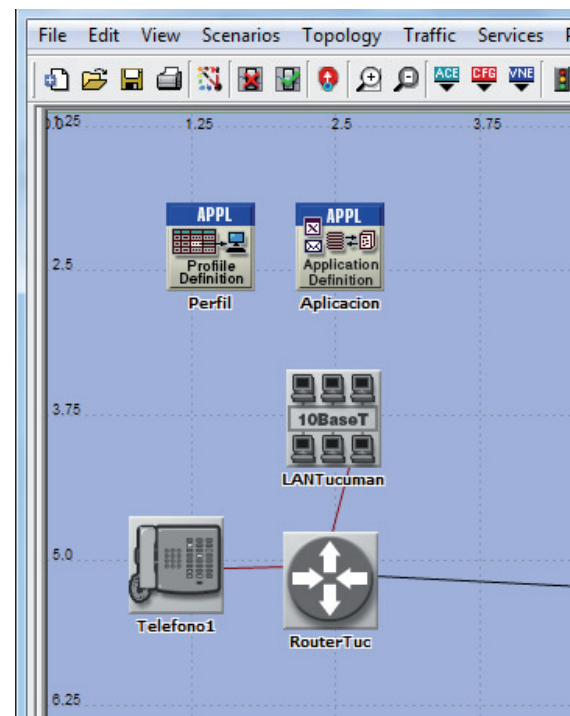


Figura 1. Esquema de LAN Tucumán (Arg.).




Figura 2. Esquema de LAN Salta (Arg.).

Los perfiles y aplicaciones se pueden ver en la Figura 3, y fueron configurados para el tipo de tráfico http, ftp, base de datos y voz con una carga considerable:

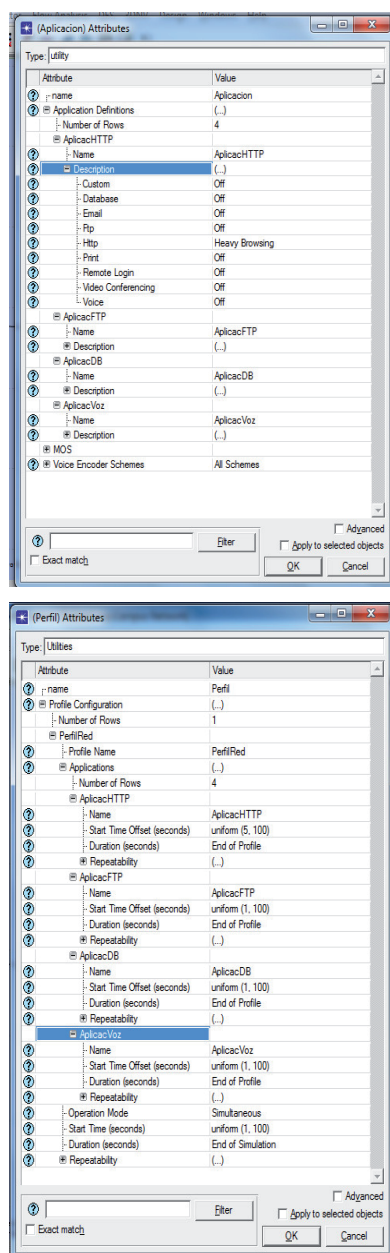


Figura 3. Perfiles y aplicaciones cargadas en Opnet Modeler.

### 3.6 Selección de Estadísticas de Tráfico

Las estadísticas se eligieron por nodo (ver Figura 4), es decir, tráfico enviado y recibido de los servidores (DB, HTTP, FTP).

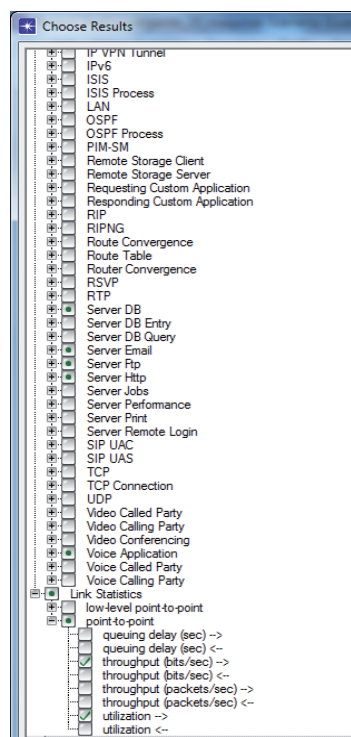


Figura 4. Estadísticas de tráfico.

### 3.7 Recopilación de Estadísticas del Tráfico

Una vez terminada la simulación, Opnet Modeler muestra las estadísticas elegidas anteriormente, brindando un gráfico (Figura 5 y 6) por cada estadística, los cuales servirán como entrada para el Modelo Neuronal, que para esta investigación las variables a considerar para conocer el nivel de tráfico que fluye a través de la red es mediante las estadísticas generadas por el servidor de base de datos, http y ftp.




Figura 5. Gráfico correspondiente a seis redes simuladas




Figura 6. Gráfico que representa el aumento en el N° de Usuarios en la red adoptada

## 4. Modelo Neuronal

El modelo de la Red Neuronal propuesto [8] para la predicción del tráfico proyectado por el servidor de base de datos se puede ver en la Tabla 1.

Red_http_backpropagation	Capa1	Capa2	Capa3
Cantidad de Neuronas por capa	750	50	1
Función de transferencia	TANSIG	TANSIG	TANSIG
Función de entrenamiento	TRAINLM		
Función de actualización de pesos	LEARNGDM		

Tabla1. Modelo Neuronal Red\_DB\_backpropagation.

El Modelo de Red Neuronal propuesto para la predicción del tráfico proyectado por el servidor de HTTP se puede apreciar en la Tabla2.

Red_ftp_backpropagation	Capa1	Capa2	Capa3
Cantidad de Neuronas por capa	900	75	1
Función de transferencia	TANSIG	TANSIG	TANSIG
Función de entrenamiento	TRAINLM		
Función de actualización de pesos	LEARNGDM		

Tabla 2. Modelo Neuronal Red\_HTTP\_backpropagation.

El Modelo de Red Neuronal propuesto para la predicción del tráfico proyectado por el servidor de FTP se muestra en la Tabla 3.

Red_DB_backpropagation	Capa1	Capa2	Capa3
Cantidad de Neuronas por capa	650	100	1
Función de transferencia	TANSIG	TANSIG	TANSIG
Función de entrenamiento	TRAINLM		

Tabla 3 - Modelo Neuronal Red\_FTP\_backpropagation.

## 5. Entrenamiento y simulación

Los datos exportados de cada una de las redes, obtenidos del Opnet Modeler, poseen 500 valores correspondientes a 5 horas (18000 segundos) de simulación, o sea, un valor estadístico cada 36 segundos por cada protocolo.

Por cada protocolo simulado se toman los datos arrojados por las redes diseñadas durante las primeras 3 horas de simulación, obteniéndose así el conjunto de datos de entrada para formar la matriz de entrenamiento, con 300 valores estadísticos por red, teniendo un total de 1200 valores para el entrenamiento de la red neuronal.

Los datos restantes serán utilizados solo para la comparación entre la predicción de la red neuronal entrenada y los datos arrojados por el Opnet Modeler para determinar la tendencia que seguirá la red en un tiempo  $t+1$ .

Luego se importan los datos definidos para el entrenamiento de la red, como una matriz al espacio de trabajo de *Matlab*, utilizándose esta herramienta matemática para la construcción de dicho Modelo y dar lugar a la predicción a la que se quiere llegar.

### 5.1 Simulación

Una vez entrenadas las distintas redes, se procede a simularlas con los mismos datos que se entrenaron para corroborar si fue capaz de aprender.

A continuación se muestran las figuras 7, 8 y 9 correspondientes a las simulaciones de las redes neuronales.




Figura 7. Simulación de un servidor de base de datos.

En color verde se destaca el tráfico generado por el simulador Opnet Modeler y en color azul el tráfico simulado por la red neuronal *Red\_DB\_backpropagation*.




Figura 8. Simulación de un servidor http.

En color verde se destaca el tráfico generado por el simulador Opnet Modeler y en color azul el tráfico simulado por la red neuronal *Red\_HTTP\_backpropagation*.




Figura 9. Simulación de un servidor FTP.

En color verde se destaca el tráfico generado por el simulador Opnet Modeler y en color azul el tráfico simulado por la red neuronal *Red\_FTP\_backpropagation*.

## Conclusiones

A través del desarrollo del modelo experimental planteado, se explora y verifica la capacidad de las Redes Neuronales Artificiales como instrumento de modelización y predicción, poniendo de relieve la superioridad de las mismas en el modelado de acontecimientos predecibles.

La utilización de RNA como aproximación funcional, asegura la capacidad de representación y adaptación del modelo de predicción. Estas características constituyen requisitos fundamentales para reproducir la complejidad de los procesos actuales y poder adaptarse a la continua evolución de los mismos.

## Referencias Bibliográficas

1. Guides, Technical. The converged network infrastructure: An introductory, 2001.
2. Systems, Cisco. Technical Considerations for Converging Data, Voice and Video Networks. 2001. [www.cisco.com](http://www.cisco.com).
3. Figueroa de la Cruz, Mario. Redes de Nueva Generación. 2011.
4. Figueroa de la Cruz, Mario. Telefonía IP - Centrales Telefónicas Virtuales Capítulo 1. s.l.: Hispano Americana S.A, 2011.
5. Weiss, Gary M. Data mining in telecommunications. s.l.: Department of Computer and Information Science, 2005.
6. OPNET: Manual de Usuario. 2004. [http://www.opnet.com/university\\_program/teaching\\_with\\_opnet/textbooks\\_and\\_materials/materials/OPNET\\_Modeler\\_Manual.pdf](http://www.opnet.com/university_program/teaching_with_opnet/textbooks_and_materials/materials/OPNET_Modeler_Manual.pdf).
7. Rumelhart, D.E. Hinton, G.E. y Williams, R.J. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, USA: MIT Press. 1986.
8. SIMPSON., P.K. Artificial Neural Systems. s.l.: Pergamon Press, 1989.
9. Coakley, J. y Brown, C. "Artificial neural networks in accounting and finance: . s.l.: International Journal on Intelligent Systems in Accounting, 2000.