

**APLICACIONES DE LAS SERIES DE TIEMPO EN MODELOS DE TRÁFICO PARA UNA RED DE DATOS****Applications of Time Series Model for Traffic of a Data Network****RESUMEN**

En las redes modernas de comunicaciones es importante poder aplicar modelos matemáticos para explicar la relación que existe entre la capacidad de la red, el tráfico y el nivel de desempeño que la misma puede alcanzar. Como dicho tráfico es de naturaleza estadística se suele representar mediante algún proceso estocástico adecuado, con lo que se constituyen diferentes modelos de tráfico. Este artículo pretende iniciar al lector en Modelos estadísticos con series de tiempo para poder realizar un control más oportuno y eficiente en forma integrada a diferentes niveles de la jerarquía funcional de la red.

**PALABRAS CLAVES:** arima, autocorrelación, correlación, estocástico, modelo de tráfico, serie de tiempo, red de comunicaciones.

**ABSTRACT**

*In the modern networks of communications is important to be able to apply mathematical models to explain the relation exist between the capacity of the network, the traffic and the level of performance that the same one can reach. As this traffic is statistical, it represents by means of stochastic process, with which different models from traffic are constituted.*

*This paper tries to initiate to the reader in statistical Models with time series to be able to make more opportune and efficient control in form integrated at different levels from the functional hierarchy of the network.*

**KEYWORDS:** arima, autocorrelation, correlation, stochastic, traffic models, time series, networks of communications.

**1. INTRODUCCIÓN**

A lo largo del desarrollo de las redes de comunicaciones en los últimos cien años, se han propuesto diferentes modelos de tráfico, cada uno de los cuales ha resultado útil dentro del contexto particular para el que se propuso.

Dada la independencia entre los tiempos de llegada de los paquetes en una red telefónica, se ha podido desarrollar una completa teoría matemática que modela los efectos de estas demandas sobre recursos limitados de comunicación, como es la teoría de colas, ampliamente utilizada en el modelamiento de redes tradicionales de comunicaciones. El principal resultado de este tipo de modelos no correlacionados es la fórmula Erlang, pues con ella se han dimensionado las redes telefónicas durante casi todo un siglo. [1].

Sin embargo, las redes modernas de comunicaciones deben ofrecer no solo servicios de voz y datos sino muchos otros (imágenes, video, audio, texto, control, etc.), cada uno de ellos con diferentes criterios de calidad de servicio (QoS) y, en consecuencia con muy diferentes requerimientos para la red.

Estas nuevas características en las capacidades y en las demandas, empiezan a develar inconsistencias entre los modelos tradicionales y las medidas observadas, especialmente en lo referente a estructuras de correlación que se expanden a lo largo de diferentes escalas de tiempo, lo cual invalida los resultados tradiciones de la teoría de tráfico que se basaban en modelos no correlacionados, pues el nuevo tráfico sobre las redes es complejo para ser modelado mediante técnicas desarrolladas para la red telefónica. [1].

El fenómeno de correlación hace que la variabilidad se extienda a muchas escalas de tiempo, comprometiendo la validez de las técnicas de control diseñadas para los modelos tradicionales de tráfico. Por esta razón, ha sido necesario desarrollar modelos adicionales de tráfico capaces de representar estas correlaciones

y que tengan en cuenta las características del tráfico real, en especial las correlaciones que existen entre los tiempos entre llegadas, completamente ausentes en los modelos no correlacionados. [1].

Ahora, las series de tiempo tienen como objetivo central desarrollar modelos estadísticos que expliquen el comportamiento de una variable aleatoria que varía con el tiempo permitiendo estimar pronósticos futuros de dicha variable aleatoria. [2].

Por tanto los modelos de tráfico a través de series de tiempo son beneficiosos para: la planeación de cobertura, reservación de recursos, monitoreo de la red, detección de anomalías, y producción de modelos de simulación más exactos, en la medida en que pueden pronosticar el tráfico en un tiempo de escala determinado. [3].

En la planeación para futuras necesidades de cualquier sistema complejo, la exactitud en el pronóstico de tráfico, es realmente importante para definir capacidad futura requerida y planear los cambios. Un modelo bastante exacto podría predecir varios años hacia el futuro, cuya habilidad es una ventaja para la planeación de futuros requerimientos. [4].

**2. SERIE DE TIEMPO**

El estudio de series de tiempo tiene como objetivo central desarrollar modelos estadísticos que expliquen el comportamiento de una variable aleatoria que varía con el tiempo, o con la distancia, o según un índice; y que permiten estimar pronósticos futuros de dicha variable aleatoria.

Por ello, el manejo de las Series de Tiempo es de vital importancia en planeación y en áreas del conocimiento donde evaluar el efecto de una política basada sobre una variable, y/o

**CESAR A. HERNANDEZ S.**

Ingeniero Electrónico, M. Sc.  
Profesor Auxiliar  
Universidad Distrital Francisco José de Caldas  
cahernandezs@udistrital.edu.co

**LUIS FERNANDO PEDRAZA M.**

Ingeniero Electrónico, M. Sc.  
Profesor Asistente  
Universidad Militar Nueva Granada  
Pedrazaluis2001@yahoo.es

**ANDRES ESCOBAR DIAZ**

Ingeniero Electrónico, M Sc.  
Profesor Asistente  
Universidad Distrital Francisco José de Caldas  
andresed@gmail.com

conocer predicciones de sus valores futuros, aportan criterios que disminuyen el riesgo en la toma de decisiones o en la implementación de políticas futuras. [2].

Una serie de tiempo es una sucesión de un proceso estocástico  $Z_t$  generado al obtener una y solo una observación de cada una de las variables aleatorias que definen el proceso estocástico. Estas observaciones son tomadas a intervalos de tiempo o de distancia iguales, según lo indica el índice  $t$  que genera la sucesión. En este sentido, la serie es una realización de un proceso estocástico. [2].

Como  $Z_t$  es un valor que toma la variable aleatoria  $Z_t$  en el tiempo  $t$ , si  $t < n$ ,  $Z_t$  es una observación del pasado; si  $t = n$ ,  $Z_t$  es la observación presente; y si  $t > n$ ,  $Z_t$  es un valor que tomará la variable  $Z_t$ . Es claro que los valores de  $Z_t$  para  $t > n$  no son desconocidos, uno de los objetivos es estudiar métodos para estimarlos. Generalmente se está interesado en pronósticos de variables aleatorias futuras, esto es, en predecir valores que toma  $Z_t$  cuando  $t > n$ , si se considera  $n$  como origen o como valor presente. [2].

En el contexto de Series de Tiempo, pronosticar significa predecir valores futuros de una variable aleatoria basándose en el estudio de la estructura definida por las observaciones pasadas de variables que explican su variación, suponiendo que la estructura del pasado se conserva en el futuro. [5].

Es importante anotar que existen factores o eventos que influyen en la calidad de un pronóstico. Estos factores pueden ser internos o controlables y externos o incontrolables.

El éxito de la planeación depende de estos factores o eventos. Sin embargo, observe que los factores externos sólo pueden pronosticarse y tenerse en cuenta a la hora de tomar decisiones, mientras que los internos además de pronosticarse pueden controlarse mediante decisiones acordes con la política de la empresa y con los factores externos que actúan sobre ellos.

## 2.1 Componentes de una Serie de Tiempo

Una serie de tiempo puede tener las siguientes componentes:

### 2.1.1 Tendencia

Esta componente representa la trayectoria suavizada que define la serie en el rango de variación del índice y se halla observando la forma funcional de la gráfica de la serie ( $Z_T$  vs  $t$ ) a lo largo del tiempo. La tendencia puede ser: constante, lineal, cuadrática, exponencial, etc.

### 2.1.2 Componente Estacional

Esta componente se presenta cuando la serie tiene patrones estacionales que se repiten con una frecuencia constante produciendo en su gráfica un efecto periódico.

Se llama periodo estacional y se notará por  $s$ , al mínimo número de periodos (unidades de  $t$ ) que tarda el patrón en volver a presentarse.

### 2.1.3 Componente Aleatorio

Esta componente representa los cambios que sufre la serie ocasionados por fenómenos externos no controlables.

### 2.1.4 Componente Cíclica

Esta componente se presenta en series que son afectadas por fenómenos físicos o económicos que ocurren con una periodicidad variable.

## 2.2 Tipos de series de Tiempo

Los métodos de pronóstico pueden clasificarse en dos grandes bloques: métodos cualitativos o subjetivos y métodos cuantitativos.

Debido a que el objetivo es desarrollar un modelo de tráfico se escogió los métodos cuantitativos de series de tiempo, estos métodos modelan las series de tiempo estudiando la estructura de correlación que el tiempo, o el índice, o la distancia induce en las variables aleatorias que originan la serie. [6] [7] [8].

Dentro de los métodos cuantitativos existen varios tipos de series de tiempo, entre los que se destacan: los modelos autorregresivos (AR), modelos de promedio móvil (MA), modelos autorregresivos y de promedio móvil (ARMA), modelos autorregresivos e integrados de promedio móvil (ARIMA), modelos autorregresivos e integrados de promedio móvil estacionales (SARIMA), modelos autorregresivos e integrados de promedio móvil fraccionales (FARIMA) y modelos multivariados (VARMA). [9] [10].

Para explicar la estructura de correlación entre las observaciones de una serie estacionaria se consideran básicamente dos modelos, el modelo autorregresivo en la ecuación 1 y el modelo de media móvil en la ecuación 2.

$$Z_t = \sum_{j=1}^{\infty} \pi_j Z_{t-j} + a_t \quad (1)$$

$$Z_t = \mu + \sum_{j=0}^{\infty} \psi_j a_{t-j} \quad (2)$$

Donde:  $Z_t$  es la realización del proceso estocástico en el tiempo  $t$ ,  $\pi_t$  es el coeficiente de ponderación de cada rezago de la variable dependiente,  $a_t$  es el ruido blanco y  $\psi_t$  es el coeficiente de ponderación de cada residuo rezagado de significancia relevante.

### 2.2.1 El modelo autoregresivo (AR)

Considera que el valor de la serie estacionaria en el tiempo presente  $t$  depende de todos los valores pasados que ha tomado la serie, ponderados por un factor de peso  $\pi_j$  que mide la influencia de ese valor pasado en el valor presente; y de una perturbación aleatoria presente.

Cuando solamente los últimos  $p$  valores pasados de la serie afectan significativamente el valor presente, el modelo se denomina autorregresivo de orden  $p$ , AR ( $p$ ). [9] [10].

### 2.2.2 El modelo media móvil (MA)

Considera que el valor de la serie estacionaria oscila o se desplaza alrededor de un valor medio  $\mu$ . Además supone que el desplazamiento de  $\mu$  en el tiempo presente  $t$  es ocasionado por infinitas perturbaciones ocurridas en el pasado, ponderados por un factor  $\Psi_j$ , que mide la influencia de dicha perturbación en el presente de la serie. Cuando sólo las últimas  $q$  perturbaciones pasadas afectan significativamente el valor presente de la serie,

el modelo se denomina Media Móvil de orden q notado MA (q).

Estos dos modelos básicos para series estacionarias se combinan para producir los modelos ARMA (p, q). En general las series de tiempo no son estacionarias pero por medio de transformaciones de varianza y de diferencias pueden ser transformadas en estacionarias. Los modelos ARIMA resultan al integrar a la serie estacionaria ARMA (p,q) estimada, las diferencias y las transformaciones que fueron necesarias para convertir la serie inicial en una serie estacionaria. [9] [10].

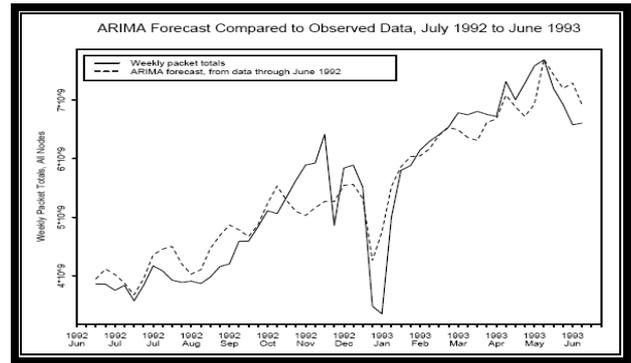
**2.3 Metodología Box-Jenkins**

Desarrollar un modelo basado en series de tiempo no es algo para nada fácil, sin embargo BOX y JENKINS lograron crear una metodología bastante practica para estimar los modelos de series de tiempo, dicha metodología es la siguiente: 1.) Por medio de transformaciones y/o diferencias se estabiliza la varianza, y se eliminan la tendencia y la estacionalidad de la serie; obteniéndose así, una serie estacionaria. 2.) Para la serie estacionaria obtenida se identifica y se estima un modelo que explica la estructura de correlación de la serie con el tiempo. 3.) Al modelo hallado en 2.) Se aplican transformaciones inversas que permitan establecer la variabilidad, la tendencia y la estacionalidad de la serie original. 4.) El modelo estimado se valida a través de la correlación de sus residuales, si estos llegan a presentar algún tipo de correlación entonces se vuelve a estimar nuevos parámetros, es decir se regresa al punto 2.) Para realizar una nueva iteración. El modelo definitivo se usa para pronosticar. [9] [10].

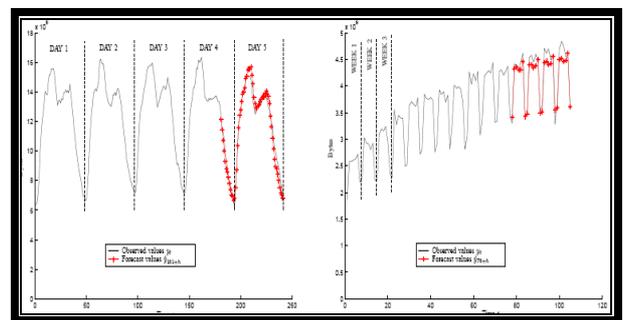
**3. INVESTIGACIONES**

**Nancy K. Groschwitz y George C. Polyzos** en su trabajo “A Time Series Model of Long-Term NSFNET Backbone Traffic” desarrollaron un modelo ARIMA para el trafico del backbone de la NSFNET, los datos de este experimento consistieron en todos los datos de trafico de cada día de los nodos que pertenecen al backbone entre agosto 1 de 1988 y el 30 de junio del 93, los datos fueron recolectados a través del protocolo de gestión de red SNMP. Los datos que se perdieron para algunos meses fueron estimados a través del mismo modelo de series de tiempo que se diseño. Como la forma de poder modelar a través de Arima es garantizar que la serie sea estacionaria, se diferencio hasta lograrlo, para el modelo identificado (p,q,d) fue (2,2,1). El modelo desarrollado fue capaz de predecir tráfico con resultados satisfactorios a un año completo. (ver figura 1).

**Dimitry Marakov** en su trabajo “Forecasting Seasonal Traffic Flows” desarrollo un modelo SARIMA (Seasonal AutoRegressive Integrated Moving Average) con base en las series de tiempo para pronosticar trafico estacional, aquí nuevamente los datos se obtuvieron a partir del protocolo SNMP a intervalos de 5 minutos, las constantes que identifican el modelo son (1,1,1)x(1,1,1), para los cuales el modelo se aproxima bastante al real. (ver figura 2).



**Figura 1.** Modelo ARIMA(2,2,1) desarrollado. (Groschwitz, 2000)



**Figura 2.** Modelo SARIMA desarrollado. (Marakov, 1998)

**Chandrashekhkar G. Dethel Y G. Wakde** en su trabajo “On the prediction of packet process in network traffic using FARIMA time-series model” desarrollaron un modelo FARIMA (p,d,q) (fractionally integrated autoregressive moving average process) aprovechando la dependencia de rango largo y la dependencia de rango corto que muestra el trafico al analizar la covarianza, la correlación y la autocorrelación de los datos. El modelo Farima tiene la siguiente forma:

$$X_t = \sum_{i=1}^p \phi_i X_{t-i} + Z_t + \sum_{i=1}^q \theta_i Z_{t-i} \tag{3}$$

Los datos en que se baso el modelo fueron tomados de las trazas de tráfico publicadas por Bellcore Networks.

**Yiannis Kamarianakis** en su trabajo “Forecasting Traffic Flow Conditions In An Urban Network: Comparison Of Multivariate And Univariate Approaches” desarrolla un modelo STARIMA (single space-time ARIMA), para el cual los resultados no son muy satisfactorios debido a la dependencia del modelo con la velocidad de los datos de las muestras de trafico.

**María Papadopouli, Haipeng Sheng, Elias Raftopoulos, Manolis Ploumidis, Felix Hernández** en su investigación: “Short-term traffic forecasting in a campus-wide wireless network”, caracterizaron el trafico de una infraestructura IEEE 802.11, lo cual puede ser beneficioso en muchos dominios, incluyendo la planeación, el cubrimiento, la reserva de recursos, el monitoreo de la red y la detección de anomalías. [3].

Este estudio se realizó con datos obtenidos en una escala horaria (es decir los datos se tomaron cada hora) para distintos APs (los que manejaban mayor tráfico) ubicados en la

universidad para los cuales se propusieron varios modelos de tráfico todos basados en una metodología de series de tiempo.

La extracción de la serie de tiempo original contó con un total de 488 APs (que pertenecen a tres series distintas de Cisco) ubicados en un área de 729 acres. Este proceso se realizó a través del protocolo SNMP, las solicitudes se enviaron entre las 9:00 a.m. del 29 de septiembre del 2004 y las 12 a.m. del 30 de noviembre del mismo año para un total de 63 días, tomando muestras cada hora para un total de 1471 datos tráfico de 1512 posibles, los valores perdidos correspondieron a diversas situaciones como por ejemplo la pérdida de señal.

Para algunos de los APs la carga de tráfico mostró una fuerte periodicidad diaria, como se puede observar en la figura 4, debido a esto el modelo desarrollado fue un ARIMA con característica de estacionalidad.

Es interesante destacar que en todas las investigaciones consultadas, aunque pocas, coinciden en que el comportamiento del tráfico moderno se ajusta muy bien a una serie de tiempo ARIMA, ya sea para una red alámbrica o una inalámbrica. Esto puede ser la causa de la autosemejanza detectada por muchos autores [11].

#### 4. MODELO DE TRÁFICO

El objetivo del presente artículo es mostrar las aplicaciones de un modelo de tráfico correlacional basado en series de tiempo. Para analizar detenidamente estas aplicaciones se partió del diseño de un modelo ARIMA, el cual se obtuvo luego de realizar las siguientes secciones en el desarrollo de la metodología.

La primera sección: Extracción de la serie de tiempo, describió la fuente de los datos y la caracterización de este proceso. La segunda sección: Preprocesamiento de los datos de la serie, explicó el tratamiento de los valores perdidos en la serie de tiempo y su importancia en el modelo. La tercera sección: Modelos correlacionados, demostró la importancia de modelos correlacionados sobre los incorrelacionados en el modelamiento de tráfico. La cuarta sección: Identificación del modelo, explicó la forma de seleccionar un modelo adecuado para la serie antes de estimar sus parámetros y de los distintos modelos de serie de tiempo que se desarrollaran en este trabajo. La quinta sección: Estimación de los parámetros y Validación preliminar del modelo, se desarrollaron varios modelos de tráfico, como: MA, AR, ARMA, ARIMA, etc. Debido al carácter de diagrama de flujo de la metodología de Box-Jenkins, de donde si el modelo no es adecuado es necesario reevaluar sus coeficientes; se realizó seguidamente la respectiva validación preliminar para cada modelo a fin de obtener resultados evaluados antes de pasar al siguiente modelo. La sexta sección: Evaluación del desempeño de los modelos desarrollados y selección del modelo definitivo, se enfocó a determinar en términos cuantitativos el desempeño de cada modelo desarrollado a través de su comportamiento en el tiempo y sus pronósticos de acuerdo con los datos reales de tráfico, que determinaron el mejor modelo de trabajo desarrollado. La séptima sección: Pronósticos de tráfico y exactitud del modelo definitivo, se realizaron varios pronósticos de tráfico con el modelo seleccionado y se evaluó la exactitud de dichos pronósticos.

Luego de desarrollar la anterior metodología se llegó al modelo de tráfico descrito por la ecuación 4.

$$Z_t = -0.092467147 \times Z_{t-6} - 0.090197053 \times Z_{t-10} + 0.093022957 \times Z_{t-18} + a_t - 0.978862096 \times a_{t-1} - 0.009496113 \times a_{t-10} - 0.009945630 \times a_{t-18} \quad (4)$$

A continuación se desarrollaran aplicaciones para el modelo descrito por la ecuación 4, como son el Dimensionamiento del ancho de banda, y la Estimación de algunos parámetros de calidad de servicio.

#### 5. APLICACIONES DE UN MODELO DE TRÁFICO

A partir de un modelo de tráfico desarrollado, evaluado y seleccionado, como el que se muestra en la ecuación 4 se pueden obtener información importante a la hora de realizar la planeación y control de las redes de comunicaciones.

##### 5.1 Ancho de Banda

Se ha definido ancho de banda efectivo o simplemente ancho de banda como la banda en la que se concentra la mayor parte de la energía de la señal. El concepto de "la mayor parte de la energía de la señal" es algo subjetivo. Lo importante es que, aunque una forma de onda dada contenga frecuencias en un rango extenso, por cuestiones prácticas, cualquier sistema de transmisión solo podrá transferir una banda limitada de frecuencias. Lo cual hace que la velocidad de transmisión máxima en el medio este limitada. [12].

Ahora el ancho de banda es un parámetro que puede modificarse según la técnica de modulación que se utilice, por esto se analizó la relación que existe entre el ancho de banda y las diferentes técnicas de modulación digital, a partir del cociente entre velocidades de transmisión y ancho de banda para tres valores del factor de roll-off ( $\alpha$ ), los cuales se mencionan en la tabla 1. [13].

Técnica de Modulación	$\alpha = 0$	$\alpha = 0.5$	$\alpha = 1$
ASK	1.0	0.67	0.5
FSK	1.0	0.67	0.5
PSK	1.0	0.67	0.5
4 PSK	2.0	1.33	1.0
8 PSK	3.0	2.0	1.5
16 PSK	4.0	2.67	2.0

Tabla 1. Evaluación de Pronósticos. (Stallings, 2004)

De la tabla 1 se puede deducir que el ancho de banda se maximiza cuando la relación de cociente entre la velocidad de transmisión y el ancho de banda se minimiza, el valor mas pequeño de dicha relación es 0.5 por lo que el máximo ancho de banda necesario será equivalente al doble de la velocidad de transmisión.

De acuerdo a la conclusión anterior el ancho de banda necesario para una señal se puede determinar a partir del modelo de tráfico desarrollado multiplicando por dos el resultado arrojado por este, por lo que la expresión matemática para determinar el máximo ancho de banda necesario será:

$$B_t = -0.184934294 \times Z_{t-6} - 0.180394106 \times Z_{t-10} + 0.186045914 \times Z_{t-18} + 2 \times a_t - 1.957724192 \times a_{t-1} - 0.018992226 \times a_{t-10} - 0.01989126 \times a_{t-18} \quad (5)$$

Sin embargo algunos autores (Stallings, 2004) (Schwartz, 1994) definen el ancho de banda como la cantidad de información de datos que se puede enviar a través de un medio de transmisión en un periodo de tiempo dado, en este sentido se puede decir que el ancho de banda es equivalente a la velocidad de transmisión de datos.

**5.2 Parámetros de Calidad de Servicio**

Es importante que durante los periodos de congestión los flujos de trafico con distintos requisitos sean tratados de forma diferente y se les asigne una calidad de servicio (QoS) diferente. Por ejemplo, algunas aplicaciones de voz y video, son sensibles al retardo pero insensibles a la perdida de datos; mientras otras, como la transferencia de ficheros y el correo electrónico, son insensibles al retardo pero sensibles a las perdidas de datos. [12].

Debido a esto es necesario determinar parámetros de calidad de servicio que le garanticen al usuario final un adecuado servicio. A continuación se determinaran dos parámetros de calidad de calidad de servicio a partir del modelo de trafico seleccionado anteriormente (ARIMA(18,1,18)).

**5.2.1 Retardo**

Para encontrar un modelo matemático para el retardo promedio de los paquetes en el sistema, es necesario conocer la tasa de salida y de llegada de los paquetes en el sistema. El modelo de tráfico desarrollado a partir de series de tiempo determina el valor de la tasa instantánea de llegada de paquetes, por lo que solo haría falta determinar la tasa de salida de los paquetes. Para obtener un modelo de retardo instantáneo se realiza un modelo en series de tiempo para los datos de tráfico de salida correspondientes a los datos de tráfico de entrada con los cuales se modeló la ecuación 4, el resultado es la ecuación 6.

$$Z_t = 0.1795532 \times Z_{t-9} + a_t - 0.0162852 \times a_{t-10} \quad (6)$$

Como los modelos para las tasas de llegada y salida de paquetes arrojan datos instantáneos (en bits por segundo) se puede calcular el tiempo de retardo instantáneo para un solo bit y asumir dicho resultado para todo el sistema con un grado de error significativamente bajo.

Denominando  $V_L(t)$  al modelo de trafico de la ecuación 4, y correspondientemente  $V_S(t)$  al modelo de trafico de la ecuación 6. Se tiene que el tiempo de llegada  $T_L$  para un único bit es:

$$T_L = \frac{1}{V_L (bps)} \times 1(bit) = \frac{1}{V_L} seg. \quad (7)$$

De la misma forma se tiene que el tiempo de salida  $T_S$  para un único bit es:

$$T_S = \frac{1}{V_S (bps)} \times 1(bit) = \frac{1}{V_S} seg. \quad (8)$$

Ahora se puede determinar el tiempo de retardo instantáneo  $T_R$  para un único bit como:

$$T_R = T_S - T_L = \frac{1}{V_S} - \frac{1}{V_L} \quad (9)$$

Sin embargo hay que hacer una salvedad importante, si el valor del tiempo de salida es menor al valor del tiempo de llegada, el retardo no queda definido como la diferencia, ya que para ese instante el retardo en teoría valdría cero. Digo en teoría a razón de que es posible que en ese momento existan aun paquetes en cola, por lo que los nuevos arribos tendrán que esperar un tiempo  $T_{R^*}$  determinado por el cociente del numero de paquetes en cola  $N_R$  entre la diferencia de las velocidades instantáneas de salida y llegada, como se indica en la ecuación 10.

$$T_{R^*} = \frac{N_R}{V_S - V_L} \quad (10)$$

Ahora el numero de paquetes  $N_{R^*}$  que experimentarían el retardo  $T_{R^*}$  esta dado por la ecuación 11, siempre y cuando durante dicho tiempo la diferencia entre la velocidad de salida y la velocidad de llegada permanezca constante y mayor que cero.

$$N_{R^*} = V_L \times T_{R^*} \quad (11)$$

Ahora si lo que se desea es determinar el retardo promedio  $E[T_R]$  en lugar del retardo instantáneo, entonces se toma el estadístico del valor esperado para un número "n" significativo datos de retardo instantáneo, es decir se realiza el promedio de "n" valores adyacentes de retardo instantáneo.

$$\overline{T_R} = E[T_R] = \sum_{i=1}^n \left( \frac{1}{V_S} \right)_i - \left( \frac{1}{V_L} \right)_i \quad (12)$$

**5.2.2 Encolamiento**

El parámetro de calidad de servicio denominado encolamiento, resulta muy sencillo de estimar teniendo con anterioridad el retardo promedio, ya que simplemente el número de paquetes en cola será equivalente al producto de la tasa de llegadas por el tiempo de retardo. [14].

$$N_R = V_L \times T_R \quad (13)$$

Nuevamente para estimar el valor promedio se calcula el valor esperado para un numero "n" de datos como se muestra en la ecuación 14.

$$\overline{N_R} = \overline{V_L} \times \overline{T_R} = \sum_{i=1}^n \frac{(V_L)_i - (T_R)_i}{n} \quad (14)$$

## 6. CONCLUSIONES

Las series de tiempo y en especial los modelos Autorregresivos e Integrados con Promedios Móviles (ARIMA), resultan realmente apropiados para modelar el tráfico moderno con características de correlación fuertes en la modelación del tráfico.

El dimensionamiento del ancho de banda para el tráfico que se realizó a partir del modelo de tráfico ARIMA, heredó todas las características de este, en especial su exactitud, logrando obtener resultados de ancho de banda inclusive en tiempo real con errores bastante pequeños en relación a la magnitud de los residuales correspondientes y proporcionando a través de sus pronósticos de ancho de banda necesario en periodos futuros una herramienta poderosa para la planeación y control de redes de datos.

Es importante destacar que el valor calculado a través del modelo matemático para el ancho de banda tiene en cuenta el peor caso, por lo que para anchos de banda mínimos se puede sugerir la mitad del valor determinado por la ecuación correspondiente.

La ventaja de la determinación de parámetros de calidad de servicio a partir de modelos correlacionados como las series de tiempo y en especial el modelo ARIMA, se fundamenta para el caso de retardo promedio, en que la estructura de correlación presente en el tráfico, induce una estructura de correlación de características similares en los retardos.

Este hecho presenta unas implicaciones importantes de cara a la obtención de estimaciones del retardo medio con niveles de confianza y márgenes de error aceptables, pues los métodos habituales basados en la suposición de que la agregación destruye la estructura de correlación (como el método de Poisson) no funcionan cuando existe correlación a largo plazo, característica presente en la serie de tráfico Wimax que nos ocupa.

## REFERENCIAS BIBLIOGRAFICAS

- [1] ALZATE, Marco Aurelio. Modelos de tráfico en análisis y control de redes de comunicaciones. En: Revista de ingeniería de la Universidad Distrital Francisco José de Caldas. Bogotá. Vol. 9, No. 1 (Junio 2004); p. 63-87.
- [2] CORREA MORENO, Emilia. Series de tiempo: conceptos básicos. Medellín: Universidad Nacional de Colombia, Facultad de Ciencias, Departamento de matemáticas, 2004.
- [3] PAPADOPOULI, María; SHENG, Haipeng; RAFTOPOULOS, Elias; PLOUMIDIS, Manolis y HERNANDEZ, Felix. Short-term traffic forecasting in a campus-wide wireless network. 2004.
- [4] FILLATRE, Lionel; MARAKOV, Dimitry y VATON, Sandrine. Forecasting seasonal traffic flows. Computer Science Department, ENST Bretagne, Brest, Paris. 2003.
- [5] PAJOUH, Danech. Methodology for traffic forecasting. The French National Institute for Transport and Safety Research (INRETS). Arcueil. 2002.
- [6] DAVIS, R. A. Maximum likelihood estimation for MA(1) processes with a root on or near the unit circle. In: *Econometric theory*. Vol. 12, 1996. p. 1-29
- [7] DETHE, Chandrashekhar y WAKDE D.G. On the prediction of packet process in network traffic using FARIMA time series model. Department of Electronics, College of Engineering, India. 2003.
- [8] MAKRIDAKIS, Spyros G.; WHEELWRIGHT, Steven C. y HYNDMAN, Rob J. *Forecasting: methods and applications*. Tercera edición. USA: Editorial Wiley, 1997.
- [9] BOX, G. E. P. y JENKINS, Gwilym M. *Time series analysis: Forecasting and control*. Revised Edition. Oakland, California: Editorial Holden-Day, 1976.
- [10] GUERRERO GUZMAN, Víctor Manuel. *Análisis estadístico de series de tiempo económicas*. Segunda edición. México: Editorial Thomson, 2003.
- [11] YU, Guoqiang y ZHANG, Changshui. Switching ARIMA model based forecasting for traffic flow. State key laboratory of intelligent technology and system, Department of automation, Tsinghua University. 2003.
- [12] STALLINGS, William. *Comunicaciones y redes de computadores*. Séptima edición. Madrid: Prentice Hall, 2004.
- [13] COUCH, L. *Digital and analog communication system*. New Jersey: Prentice Hall, 2001.
- [14] CAMERANO FUENTES, Rafael. *Teoría de colas*. Bogota: Fondo de publicaciones Universidad Distrital Francisco José de Caldas, 1997.