

PARÁMETRO H: ANÁLISIS DE LA AUTOSIMILARIDAD DE UN TRÁFICO VoIP

Sergio A. Villiani¹, Diego R. Rodríguez Herlein²

¹ Facultad Ciencias Económicas y Sociales – UCALP
sergio.villiani@ucalpvirtual.edu.ar

² Unidad Académica Río Gallegos - UNPA
Campus universitario - Oficina B 18
dherlein@uarg.unpa.edu.ar

Resumen. Los modelos tradicionales de tráfico permiten controlar la variabilidad de la demanda y, se puede ejercer control de manera de garantizar algunos niveles de Calidad de Servicio (QoS). La naturaleza autosimilar del tráfico multimedia impone nuevos desafíos en las estrategias para configurar y garantizar una calidad de servicio extremo a extremo. Dada su creciente utilización, resulta interesante conocer las características del tráfico que genera. Estudios previos ponen en evidencia las características autosimilares del tráfico. Esta propiedad se puede cuantificar a través del parámetro de Hurst. El presente trabajo es un estudio del comportamiento del tráfico de VoIP en una red LAN real y las recomendaciones de configuración de los elementos de la red, mediante la evaluación del parámetro H. La plataforma de VoIP está basada en Microsoft® Lync Server 2010 y SIP gateways para la interconexión con la red de telefonía pública. En cuanto a los clientes, existen teléfonos IP con clientes Lync incorporados y teléfonos USB (handset USB), con lo cual el tráfico de la PC y el tráfico de voz compiten sin ningún tipo de priorización. El escenario en el cual se tomaron las muestras fue solamente las llamadas salientes a la PSTN y las conferencias ya que las llamadas entre internos son punto a punto.

Palabras clave: VoIP, Tráfico, Autosimilaridad, Hurst, QoS

1 Introducción

La Autosimilaridad se define como la apreciación de una estructura estadísticamente similar a lo largo de un amplio rango de escalas, es decir, que la señal en términos estadísticos posee un aspecto parecido, aunque se varíe la escala. Es un concepto relacionado a la invariabilidad o persistencia de las características estadísticas de un proceso estocástico, frente a los cambios de escala temporales. Se puede clasificar como Autosimilaridad Determinística y Estadística.

La noción de fractal [1], introducida por Mandelbrot, se utiliza principalmente para el estudio de estructuras irregulares y fragmentadas que se presentan invariantes en diferentes escalas. Esta característica se denomina autosimilitud, ya que cada una de las partes, cualquiera sea su resolución, se presenta semejante al todo. Esto significa que observando tales objetos con diferentes niveles de aproximaciones las

características geométricas se preservan [2]. Ejemplos de fractales determinísticos son Curva de Koch, Conjunto de Cantor [3], Triángulo de Sierpinski y Alfombra de Sierpinski.

Se dice que un proceso posee autosimilaridad estadística [4] si las estadísticas no cambian cuando cambia la escala temporal. Los procesos que presentan este tipo de autosimilitud permiten modelar el tráfico autosimilar. Para medirla se pueden utilizar estadísticas de segundo orden, que permiten capturar la variabilidad de los procesos. Dicha invarianza a la escala se puede definir en términos de la autocorrelación.

La *autosimilitud estadística en el sentido estricto* [1], se define de la siguiente manera: dado un proceso estocástico $\{X(t), t \in \mathbb{R}\}$, un factor escalar $a > 0 \in \mathbb{R}$ y un parámetro H tal que $0,5 < H < 1$ donde se cumpla la condición (1),

$$\{X_a(t_1), X_a(t_2), \dots, X_a(t_n)\} = \{a^H X(t_1), a^H X(t_2), \dots, a^H X(t_n)\} \quad (1)$$

Se dice que dicho proceso es autosimilar con parámetro H , lo que significa que ambas secuencias poseen la misma distribución de probabilidad. H se denomina **Parámetro de Hurst** y es una medida de la persistencia del comportamiento del proceso y de la *Dependencia de Largo Rango*.

Si en lugar de establecer las equivalencias a nivel de Distribución de Probabilidad [5] se lo realiza a nivel de estadísticas de 2º orden, como lo son la Función de Autocorrelación R y la Varianza $Var[X]$, de la secuencia temporal que representa el proceso estocástico, se está frente a una *Autosimilaridad en Sentido Amplio*.

Cuando se trata de estudiar el tráfico de una red de datos, se pueden considerar procesos estocásticos definidos en puntos discretos del tiempo. Lo que significa el promedio de los valores de cada bloque no solapados de tamaño m . El promedio del k -ésimo bloque es el valor de la k -ésima variable aleatoria del proceso agregado $X_k^{(m)}$.

Siendo $\gamma_k^{(m)}$ la Autocovarianza de $X_k^{(m)}$ en términos de estacionariedad de segundo orden se puede afirmar lo siguiente:

- *Autosimilaridad exacta de segundo orden*: $X(t)$ es exactamente autosimilar de segundo orden con parámetro de Hurst H , donde $0,5 < H < 1$

$$\text{si } \rightarrow \gamma(k) = \frac{\sigma^2}{2} [(k+1)^{2H} - 2k^{2H} + (k-1)^{2H}] \quad (2)$$

- *Autosimilaridad asintótica de segundo orden*: $X(t)$ es asintóticamente autosimilar de segundo orden con parámetro de Hurst H , donde $0,5 < H < 1$

$$\text{si } \rightarrow \lim_{m \rightarrow \infty} \gamma^{(m)}(k) = \frac{\sigma^2}{2} [(k+1)^{2H} - 2k^{2H} + (k-1)^{2H}] \quad (3)$$

De acuerdo a las definiciones anteriores, las distribuciones de X y $X^{(m)}$ están vinculadas a través de una relación de escala que involucra al parámetro de Hurst (4).

$$X =_d m^{1-H} X^{(m)} \quad (4)$$

$=_d$: significa que ambos procesos poseen la misma distribución de probabilidades y la ecuación se satisface tanto para $m \geq 0$ como para $m \rightarrow \infty$.

La relación del parámetro de Hurst con la varianza (5) es la siguiente:

$$\begin{aligned} & Var(X^{(m)}) \\ & = m^{2H-2} Var(X) \end{aligned} \begin{cases} Var(X^{(m)}) = \frac{1}{m} Var(X) & \text{para } H = \frac{1}{2} \\ Var(X^{(m)}) = \frac{1}{m^\beta} Var(X) & \text{para } \frac{1}{2} < H < 1 \quad 0 < \beta < 1 \rightarrow H = 1 - \frac{\beta}{2} \end{cases} \quad (5)$$

$$\text{función de autocorrelación } \rightarrow r(k) = \frac{\gamma(k)}{Var(k)} \quad (6)$$

Cuya aproximación asintóticamente exacta es la siguiente expresión (7),

$$r(k) = \frac{1}{2} [(k+1)^{2H} - 2k^{2H} + (k-1)^{2H}] \approx H(2H-1)k^{2H-2} \quad k \rightarrow \infty \quad (7)$$

En particular

$$r(k) = ck^{-\beta} \quad \text{para } \frac{1}{2} < H < 1 \quad \wedge \quad 0 < \beta < 1 \quad \wedge \quad c > 0 \quad (8)$$

La función decae muy lentamente (en forma hiperbólica), lo que conduce a la propiedad de que la función de autocorrelación es no sumable. Cuando esto se cumple el proceso estacionario $X(t)$ tiene una *Dependencia de Rango Largo (LRD)* [7]. La LRD, es una característica relacionada con el comportamiento de la correlación de un proceso estocástico, en particular con su invariabilidad frente a las traslaciones temporales.

Si el proceso es estacionario y ergódico (la media de su conjunto es igual a la media temporal de una sola realización), el valor de $\beta = 1$ o lo que es lo mismo $H = \frac{1}{2}$, con lo cual la varianza de la media temporal decrece hasta cero con una pendiente $\frac{1}{m}$ y no presenta LRD. Al ser la variable independiente, el coeficiente de correlación $\rho = 0$, la función de autocorrelación $R_X = 0 \Rightarrow R_{X^{(m)}} \rightarrow 0$ en forma rápida o exponencial cuando $m \rightarrow \infty$, con lo cual no existe el efecto memoria, es decir se está en presencia una *Dependencia de Rango Corto o SRD*.

1.1 Métodos de estimación del Parámetro H

Un problema fundamental en el análisis series temporales que exhiben LRD, es la estimación del grado de autosimilaridad, o parámetro de Hurst. Algunos de los métodos propuestos para el cálculo de dicho parámetro [9] se observan en la siguiente figura (Fig.1)

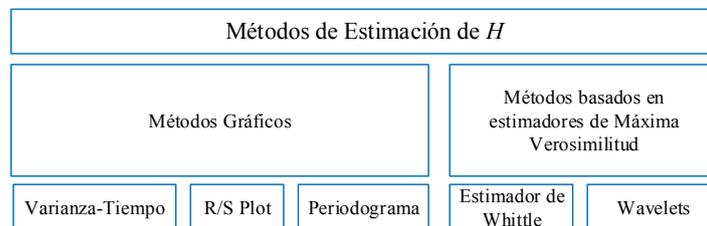


Fig. 1. Métodos de estimación del parámetro H

- *Método de Varianza-Tiempo:* La varianza de un proceso autosimilar de una serie agregada posee esta expresión (9) para valores grandes de m

$$Var[X^{(m)}] \approx \frac{Var(X)}{m^\beta} \quad (9)$$

Como $H = 1 - \frac{\beta}{2}$ y tomando el logaritmo

$$\log\{Var[X^{(m)}]\} \approx [\log Var(X)] - \beta \cdot \log(m) \quad (10)$$

Como $\log Var(X)$ es una constante independiente m de si se grafica $Var[X^{(m)}]$ vs m en un gráfico doble logarítmico, se obtiene una línea recta de pendiente $-\beta$. Si dicha recta está en el rango $(-1,0)$ se está en presencia de autosimilaridad.

- *Método de Re-escalado:* El método del rango de re-escalado calcula el estadígrafo R/S para diferentes intervalos temporales y permite establecer una relación entre la amplitud del intervalo de desviaciones acumuladas (rango estadístico R) y la desviación estándar de la misma (S), medido para un intervalo de tiempo (t). Para un proceso estocástico $X(t)$ el rango re-escalado de dicho proceso sobre un intervalo de tiempo N se define la relación $\frac{R}{S}$ de la siguiente manera (11):

$$\frac{R}{S} = \frac{\max_{1 \leq j \leq N} \{\sum_{k=1}^j [X_k - \mu_N]\} - \min_{1 \leq j \leq N} \{\sum_{k=1}^j [X_k - \mu_N]\}}{\sqrt{\frac{1}{N} \sum_{k=1}^j [X_k - \mu_N]^2}} \quad (11)$$

Siendo μ_N la media del proceso, medida sobre el período N

Para un proceso autosimilar si N es grande

$$\frac{R}{S} \cong \left(\frac{N}{2}\right)^H \text{ con } H > 0.5 \quad (12)$$

Aplicando logaritmos

$$\log\left(\frac{R}{S}\right) \cong H \cdot \log(N) - H \cdot \log(2) \quad (13)$$

Graficando $\left[\frac{R}{S}\right]$ vs N en un gráfico doble logarítmico se obtiene una recta cuya pendiente es el parámetro de Hurst. Los resultados posibles son:

- ✓ Si el proceso es un movimiento aleatorio, $H = \frac{1}{2}$ el gráfico será una línea horizontal.
 - ✓ Si es un proceso persistente es decir $H > \frac{1}{2}$ se obtendrá una línea creciente.
 - ✓ Si el proceso es antipersistente es decir $H < \frac{1}{2}$ se obtendrá una línea decreciente.
- *Método de Periodograma:* Para un proceso estocástico estacionario discreto, la autocorrelación (14) y la densidad espectral (15) se definen:

$$R(k) = E[X(t)X(t+k)] \quad (14)$$

$$S(\omega) = \sum_k R(k)e^{-jk\omega} \quad (15)$$

Si el proceso es ergódico en correlación, es decir, los promedios temporales son iguales a los promedios en conjunto, la función de autocorrelación se la puede estimar mediante (16),

$$R_N(k) = \frac{1}{N} \sum_{n=0}^{N-1-k} X(n+k)X(n) \quad (16)$$

La densidad espectral de un proceso estocástico $X(t)$ definido en instantes discretos, se puede estimar a lo largo de un período N de la siguiente manera (17),

$$I_N(\omega) = \frac{1}{2\pi N} \left\{ \sum_{k=1}^N X_k e^{jk\omega} \right\}^2 \quad (17)$$

Dicho estimador se conoce como **Periodograma o función de intensidad**.

- *Estimador de Whittle:* [11] Si las series observadas provienen de un proceso autosimilar con parámetro H y que se supone que posee una forma particular como el FBM (Movimiento Browniano Fraccionario), la densidad de potencia del proceso se puede expresar como $S(\omega, H)$, entonces H se puede estimar encontrando aquel valor de H que minimiza la siguiente expresión (18),

$$\int_{-\pi}^{\pi} \frac{I_N(\omega)}{S(\omega, H)} d\omega \quad (18)$$

Este es el Estimador de Whittle, si la serie $\{X_k\}$ tiene una longitud N, la integral se convierte en una suma discreta sobre las frecuencias $\omega = \frac{2\pi}{N}, \frac{4\pi}{N}, \dots, 2\pi$.

Además, se obtiene la varianza de la muestra, lo que permite calcular intervalos de confianza. La varianza de la muestra se expresa de la siguiente manera (19),

$$\text{Var}(\hat{H}) = 4\pi \left[\int_{-\pi}^{\pi} \left[\frac{\partial \log S(\omega)}{\partial H} \right]^2 d\omega \right]^{-1} \quad (19)$$

El estimador de Whittle supone que la serie temporal es un proceso autosimilar de una determinada forma y proporciona una estimación del parámetro de Hurst dentro de un intervalo de confianza [8].

2 Captura del tráfico

En la siguiente figura (Fig.2) se observa el escenario que representanta la topología y el punto donde se hicieron las capturas de tráfico.

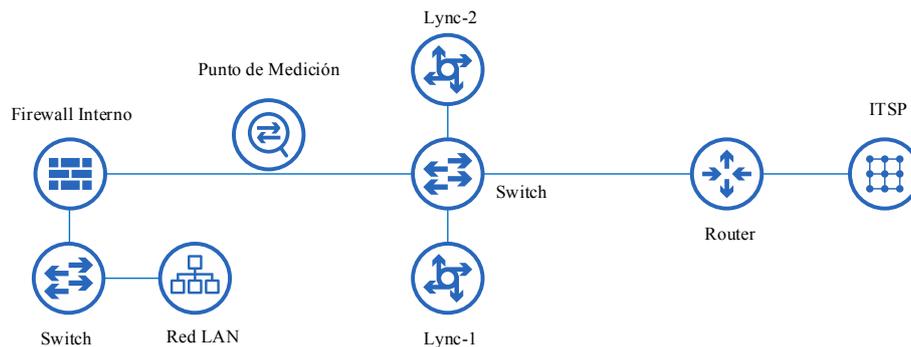


Fig. 2. Topología y punto de captura de tráfico

El Punto de Medición es donde concurren todas las llamadas entrantes y salientes (desde y hacia el proveedor ITSP) desde los clientes de la red LAN, todo el tráfico de VoIP pasa por los Servidores Lync además de la señalización SIP. En una llamada entre internos de la red, los servidores Lync intervienen en la señalización y la comunicación se realiza punto a punto entre estaciones.

La metodología empleada para capturar el tráfico se basó en la herramienta tcpdump filtrando el tráfico UDP desde y hacia los hosts Lync-1 y Lync-2. Posteriormente dicha captura se analizó con el software Wireshark, las estadísticas básicas de la captura se observan en la siguiente tabla (Tabla 1).

Tabla 1. Estadísticas básicas de la captura de tráfico.

<i>Descripción</i>	<i>Valor</i>
Primer Paquete	09:39:46 a.m.
Último Paquete	02:06:58 p.m.
Tiempo Transcurrido	04:27:12
Paquetes Capturados	205276
Tiempo entre el primer y último paquete en segundos	16032,285
Promedio paquetes por segundo	12,804
Promedio tamaño del paquete en bytes	205,974
Tamaño de la captura en bytes	42281469
Promedio bytes por segundo	2637,27
Promedio Mbit por segundo	0,021

En la siguiente figura (Fig.3) se puede observar la distribución del tamaño de los paquetes capturados

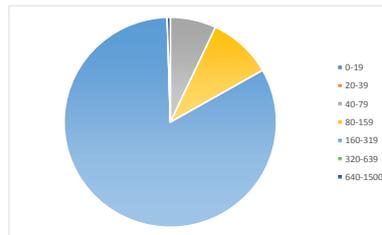


Fig. 3. Distribución del tamaño de los paquetes capturados (bytes)

En las siguientes figuras (Fig.4, 5 y 6) se presentan las gráficas de paquetes recibidos con diferentes longitudes de intervalo de tiempo, lo que permite apreciar la existencia de autosimilaridad [4] [7] en el tráfico capturado, ya que se observa un comportamiento similar para las distintas escalas de tiempo [12].

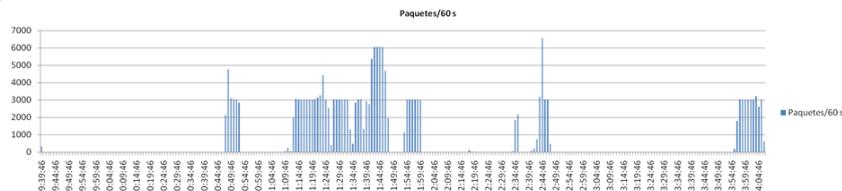


Fig. 4. Distribución de la recepción de los paquetes – Intervalo 60s.

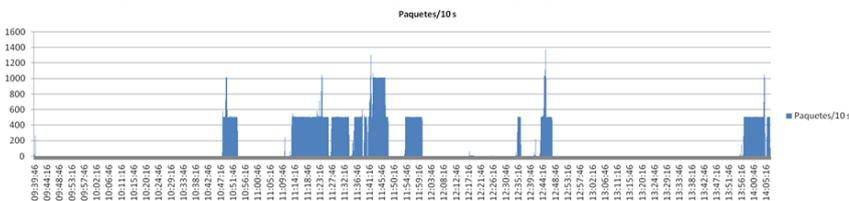


Fig. 5. Distribución de la recepción de los paquetes – Intervalo 10s

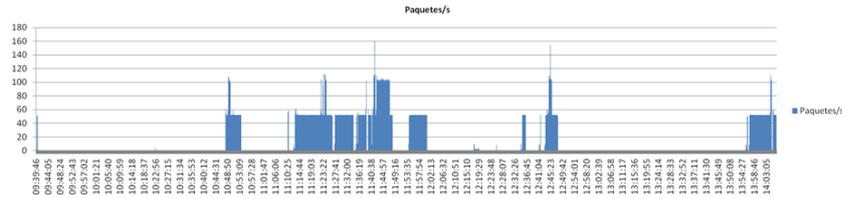
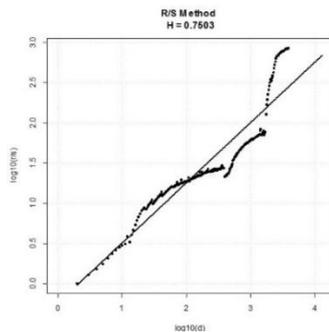


Fig. 6. Distribución de la recepción de los paquetes – Intervalo 1s

3 Análisis Estadístico

De la captura original descrita en Captura de Tráfico, se procesó para filtrar el tamaño de los paquetes (bytes) en el intervalo de tiempo correspondiente a 11:41:00 y 11:48:00, dicho intervalo de tiempo es el que posee más cantidades de llamadas concurrentes. Para obtener las estadísticas se utilizó la herramienta informática R Project (<http://www.r-project.org/>), en su versión de 64 bits (2.15.3) [10].

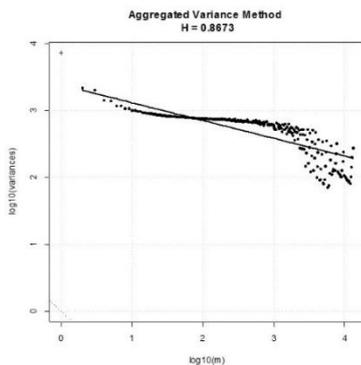
En las siguientes figuras (Fig.7, 8, 9, 10 y 11) se observa del lado derecho el cálculo del parámetro H en RStudio y en la izquierda la gráfica correspondiente, para cada uno de los métodos utilizados.



Cálculo de H

```
> rsFit(data[,1], levels = 400, cut.off = 10^c(0.1,
4.58), doplot=TRUE)
Title:
Hurst Exponent from R/S Method
Call:
rsFit(x = data[, 1], levels = 400, cut.off =
10^c(0.1, 4.58), doplot = TRUE)
Method:
R/S Method
Hurst Exponent:      H      beta
                   0.7502812 0.7502812
Hurst Exponent Diagnostic:
Estimate Std.Err t-value Pr(>|t|)
X 0.7502812 0.01176258 63.78541 2.84788e-183
Parameter Settings:
n levels minnpts cut.off1 cut.off2
39006 400 3 1 38018
```

Fig. 7. Cálculo de H – Método R/S



Cálculo de H

```
> aggvarFit(data[,1], minnpts = 3, levels = 400,
cut.off = 10^c(0.1, 4.58), doplot = TRUE, trace =
FALSE, title = NULL, description = NULL)
Title:
Hurst Exponent from Aggregated Variances
Call:
aggvarFit(x = data[, 1], levels = 400, minnpts =
3, cut.off = 10^c(0.1, 4.58), doplot = TRUE, trace =
FALSE, title = NULL, description = NULL)
Method:
Aggregated Variance Method
Hurst Exponent:      H      beta
                   0.8673216 -0.2653568
Hurst Exponent Diagnostic:
Estimate Std.Err t-value Pr(>|t|)
X 0.8673216 0.004678798 185.3727 0
Parameter Settings:
n levels minnpts cut.off1 cut.off2
39006 400 3 1 38018
```

Fig. 8. Cálculo de H – Varianza

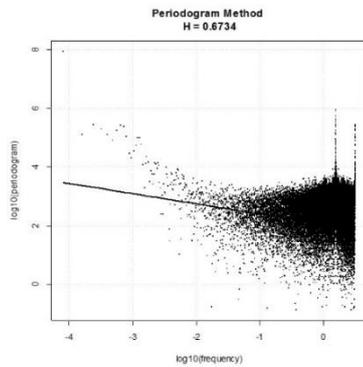


Fig. 9. Cálculo de H – Periodograma

Cálculo de H

```
> perFit(data[,1], cut.off = 0.1, method =
c("per", "cumper"),doplot = TRUE, title = NULL,
description = NULL)
Title:
Hurst Exponent from Periodgram Method
Call:
perFit(x = data[, 1], cut.off = 0.1, method =
c("per", "cumper"), doplot = TRUE, title = NULL,
description = NULL)
Method:
Periodogram Method
Hurst Exponent:      H      beta
                   0.6734411 -0.3468821
Hurst Exponent Diagnostic:
      Estimate Std.Err t-value Pr(>|t|)
X 0.6734411 0.01071573 62.84603      0
Parameter Settings:  n cut.off
                   39006      10
```

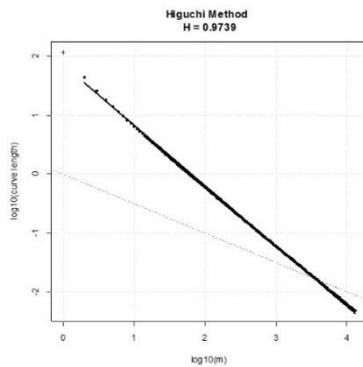


Fig. 10. Cálculo de H – Higuchi

Cálculo de H

```
> higuchiFit(data[,1], levels = 400, minnpts = 3,
cut.off = 10^c(0.1, 4.58), doplot = TRUE, trace =
FALSE, title = NULL, description = NULL)
Title:
Hurst Exponent from Higuchi Method
Call:
higuchiFit(x = data[, 1], levels = 400, minnpts =
3, cut.off = 10^c(0.1, 4.58), doplot = TRUE, trace =
FALSE, title = NULL, description = NULL)
Method:
Higuchi Method
Hurst Exponent:      H      beta
                   0.9739041 -1.0260959
Hurst Exponent Diagnostic:
      Estimate Std.Err t-value Pr(>|t|)
X 0.9739041 0.003075101 316.7064      0
Parameter Settings:  n levels minnpts cut.off1 cut.off2
                   39006      400      3      1      38018
```

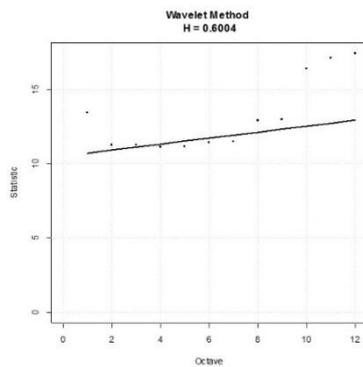


Fig. 11. Cálculo de H – Wavelet

Cálculo de H

```
> waveletFit(data[,1], length = NULL, order = 2,
octave = c(2, 8),doplot = TRUE, title = NULL,
description = NULL)
Title:
Hurst Exponent from Wavelet Estimator
Call:
waveletFit(x = data[, 1], length = NULL, order =
2, octave = c(2, 8), doplot = TRUE, title = NULL,
description = NULL)
Method:
Wavelet Method
Hurst Exponent:      H      beta
                   0.6003966 0.2007933
Hurst Exponent Diagnostic:
      Estimate Std.Err t-value Pr(>|t|)
X 0.6003966 0.04656874 12.8927 5.000241e-05
Parameter Settings:  length order octave1
octave2
                   32768      2      2
                   8
```

En la siguiente tabla (Tabla 2) se observan los valores obtenidos en los distintos métodos de cálculo del parámetro de Hurst.

Tabla 2. Cálculos del parámetro H por los distintos métodos.

<i>Método</i>	<i>Valor</i>
R/S	0.7502812
Varianza	0.8673216
Periodograma	0.6734411
Higuchi	0.9739041
Wavelet	0.6003966

Los métodos gráficos son de carácter práctico [9], ya que permiten obtener una idea aproximada si un conjunto de datos se ajusta a características autosimilares ($H > 0,5$) o si posee una dependencia de corto alcance ($H \approx 0,5$). El método de Wavelet presenta un mayor rigor estadístico y en este caso tiene un valor $H = 0.6003966$, con lo cual se puede afirmar que los datos obtenidos de la captura presentan un carácter autosimilar.

4 Conclusiones

El tráfico autosimilar en una red de datos puede tener impacto negativo en la performance de la misma incluyendo retrasos mayores en las colas de los elementos de conectividad y pérdida de paquetes.

Una consecuencia práctica del efecto de la autosimilaridad es la necesidad de tener buffers más grandes en routers y switches que los previstos mediante el análisis y simulación de colas tradicional.

Pero estos buffers de mayor tamaño crean mayores retrasos en los flujos de datos. El producto retardo por ancho de banda causa inconvenientes en el tráfico multimedia.

Debido a la rafagosidad de tráfico inherente al tráfico de VoIP, la pérdida de paquetes y los retardos de la red son los problemas comunes que experimentan las aplicaciones multimedia tales como la VoIP.

En particular en este trabajo la plataforma analizada es basada en Microsoft® Lync Server 2010, la única manera de implementar Calidad de Servicio es habilitando DiffServ tanto en los servidores como en las PC clientes y todos los elementos de conectividad que existan entre los clientes y los servidores para garantizar el entorno de QoS.

Las directivas QoS se aplican a una sesión de inicio de usuario o a un equipo como parte de un objeto de directiva de grupo (GPO) que se vincula a un contenedor de Active Directory como un dominio, un sitio o una unidad organizativa (OU).

QoS basada en directiva permite:

- Definir la prioridad del tráfico: Para marcar el tráfico de red saliente mediante un valor específico de Punto de código de servicios diferenciados (DSCP), tal como se describe en RFC 2474.
- Administrar el uso del ancho de banda: Puede limitar de velocidad para el tráfico saliente. Con este límite, los componentes de QoS limitan el tráfico de red

saliente agregado que coincide con la velocidad especificada en la configuración de la directiva QoS.

References

1. Porras Castro, Stalin Efrain, Rivera Moreno, Paulo Cesar, *Análisis del algoritmo algebraico de asignación dinámica del buffer para sistemas de encolamiento bajo condiciones de tráfico autosimilar*, 2008.
- 2- MA. Alzate Monroy, 2001, *Introducción al tráfico autosimilar en redes de comunicaciones*, Ingeniería, ISSN-e 0121-750X, Vol. 6 Núm. 2 (2001), págs. 6-17.
- 3- S. Plaza, 2013, “*Introducción a los procesos infinitos y Fractales*”
- 4- W. E. Leland, M. S. Taqqu, W. Willinger and D. V. Wilson, *On the self-similar nature of Ethernet traffic (extended version)*, in IEEE/ACM Transactions on Networking, vol. 2, no. 1, pp. 1-15, Feb. 1994, doi: 10.1109/90.282603.
- 5- O.I. Sheluhin, S.M. Smolskiy and A.V. Osin, 2007, *Self-Similar Processes in Telecommunications*, Print ISBN:9780470014868 |Online ISBN:9780470062098 |DOI:10.1002/9780470062098, John Wiley & Sons, Ltd.
- 6- P. Bravo García, 2004, *Modelado fractal de tráfico de la red de Ingeniería Telemática*, Universidad Carlos III de Madrid. Departamento de Ingeniería Telemática.
- 7- K.Park and W.Willinger, 1999, *Self-Similar Network Traffic: An Overview*, Wiley Online Library
- 8- P.ULANOVVS ET AL., *Modeling Methods of self-similar traffic for network performance evaluation*, Scientific Proceedings of RTU. Series 7. Telecommunications and Electronics, 2002.
- 9- RG. Clegg, *A Practical Guide to Measuring the Hurst Parameter*, arXiv, Nov. 2006
- 10- Package ‘fArma’, “Rmetrics - Modelling ARMA Time Series Processes”, RStudio, <http://cran.nexr.com/web/packages/fArma/fArma.pdf> (Dic2019)
- 11- Christian Grimm., Georg Schluchtermann; *IP Traffic Theory and Performance*; SpringerVerlag; ISBN 978-3-540-70603-8; 2008.
- 12- Gagandeep Kaur, Dr. Vikas Saxena, Prof. J. P. Gupta; *Characteristics Analysis of Web Traffic with Hurst Index*; Proceedings of the World Congress on Engineering and Computer Science 2010 Vol I WCECS 2010, October 20-22, 2010, San Francisco, USA