

## Estimación de “H” con transformada ondita

Reinaldo Scappini<sup>1</sup>, Luis Marrone<sup>2</sup>,

<sup>1</sup> UTN Facultad Regional Resistencia, calle French 414 Resistencia, Rep. Argentina  
[rscappini@gmail.com](mailto:rscappini@gmail.com)

<sup>2</sup> LINTI, Facultad de Informática-UNLP, calle 50 y 120 La Plata, Rep. Argentina  
[lmarrone@linti.unlp.edu.ar](mailto:lmarrone@linti.unlp.edu.ar)

**Abstract.** El análisis de tráfico se ha convertido en un proceso fundamental a la hora de evaluar la performance de una red. También se ha tornado crítico en la actualidad por la presencia de componentes auto-similares en él. Esta componente cambia el paradigma del modelo de tráfico utilizado hasta hace unos pocos años con serias dificultades analíticas; por lo menos comparándolos con los utilizados hasta el momento. Un parámetro clave en este nuevo modelo es el parámetro “H” o de “Hurst” por lo que importa una correcta detección y estimación. Presentamos con esa motivación los resultados obtenidos de la aplicación de un “script” basado en la transformada ondita o “wavelets”.

**Keywords:** tráfico, autosimilaridad, onditas, parámetro H, QoS, performance, modelos

### 1 Introducción

Una actividad fundamental en la evaluación de performance y diseño de las redes telemáticas, es el análisis del tráfico que transportan, materializado en parámetros tales como, tiempos de arribo, longitud de los mensajes, tiempos de transmisión, comportamiento en diferentes escalas de tiempo, etc. Este conocimiento permite optimizar los recursos de las redes, y también posibilita, que los servicios ofrecidos, cuenten con la calidad requerida. El logro este objetivo, es un área activa de estudio e investigación.

Promediando el año 1990, estudios realizados sobre muestras de tráfico tomadas de redes en funcionamiento, han demostrado en forma inequívoca que el tráfico tiene propiedades autosimilares, esto es, la existencia de patrones estadísticos o comportamientos que se repiten a diferentes escalas de tiempo. Un tráfico con características autosimilares, afecta en forma negativa el desempeño de la red. Se puede observar que el retardo promedio de los mensajes resulta mucho mayor que lo previsto por el análisis de colas tradicional.

Esto representa un inconveniente por partida doble. Una peor performance y la imposibilidad de un tratamiento analítico completo.

En este escenario, con tráfico originado en diversas fuentes, con sus respectivas características y particularidades, abordar un estudio para cuantificar o medir de manera apropiada la demanda que los usuarios imponen sobre los recursos de una red, requiere del uso de modelos que representen de una manera eficaz y eficiente un comportamiento compatible con las características observables en el tráfico real.

Surgen entonces, dos desafíos de importancia central:

## 2 Reinaldo Scappini<sup>1</sup>, Luis Marrone<sup>2</sup>,

- El desarrollo de modelos generales que abarquen las principales características del tráfico a estudiar.
- El desarrollo de aplicaciones, que utilizando esos modelos, permitan obtener conclusiones válidas.

El éxito de los modelos autosimilares radica en su capacidad de capturar las complejas dependencias que muestra el tráfico a distintas escalas de tiempo mediante el uso de pocos parámetros, en particular el parámetro de Hurst " $H$ ".

Dada la importancia del mismo en la caracterización del tráfico, es necesaria su correcta detección y estimación.

Si bien este trabajo muestra en forma resumida las ventajas de un método particular, todos los detalles y desarrollos teóricos se pueden encontrar en un trabajo previo [1] donde se analizaron en mayor profundidad.

En particular brindaremos los resultados obtenidos aplicando "LDestimate" [2], una script para la estimación del parámetro "H" implementada para el software Matlab® y basada en la transformada wavelet u ondita.

## 2 ¿Por qué utilizar la transformada Ondita ("Wavelets")?

En la lectura de diversos estudios e investigaciones realizados en los últimos años sobre el tráfico autosimilar en las redes telemáticas, se evidencian las ventajas que aportan los métodos basados en las wavelets u onditas, atendiendo a criterios de validez, confianza estadística y eficiencia computacional. En consecuencia, la utilización de las wavelets se ha convertido en una útil y eficaz herramienta para tareas de análisis, detección, estimación, modelado y simulación en el ámbito del tráfico autosimilar.

Como se menciona en las referencias bibliográficas [3] Pág. 84, y [4] Pág. 23; entre las ventajas del estudio del tráfico autosimilar por medio de wavelets u onditas podemos mencionar:

- La wavelets u onditas ofrecen un marco teórico que se puede aplicar tanto a procesos autosimilares, procesos LRD (Long Range Dependence, o dependencia de rango largo), trazas muestrales etc. Pudiendo hacer un análisis en el dominio de la escala, de forma que se adapta "naturalmente" a las necesidades de poder estudiar un comportamiento en este dominio.
- Permite la división controlada de un proceso madre de variabilidad extrema, en subprocesos a diferentes escalas tornando manejable su comportamiento, aprovechando la independencia de los subprocesos obtenidos, se pueden emplear herramientas de la estadística clásica sobre las secuencias de los coeficientes wavelets, y de esta forma poder diseñar estimadores simples y eficientes.
- Los bancos de filtros de análisis y síntesis, proporcionan una forma computacionalmente eficiente de llevar a cabo tareas de análisis y síntesis de procesos autosimilares.

## 2.1 Relación entre las Wavelets y los procesos Hss, Hsssi y LRD

Hss es un proceso puramente autosimilar, Hsssi es autosimilar con incrementos estacionarios, LRD es cuando presenta dependencia de rango largo.

Si bien no es motivo de este trabajo, el estudio de la transformada Wavelet u Ondita, por cuestiones de contexto es importante señalar que existe un cuerpo teórico llamado análisis multiresolución (MRA) que propone la existencia de una función llamada Wavelet madre y cuyo producto interno con la señal "S" representada por el proceso estocástico  $X(t)$ , da como resultado dos conjuntos de coeficientes llamados aproximación  $a_s(j, k)$  y detalles  $d_s(j, k)$  respectivamente, que preservan las características de la señal original y permiten su estudio a distintos niveles de escalas frecuenciales y temporales. El parámetro  $j$  representa el nivel de escala también denominado octava y el parámetro  $k$  la traslación o desplazamiento temporal.

Si la señal  $X(t)$  es proceso un proceso estocástico que presenta un fenómeno de escala representado por el exponente " $\alpha$ ", los coeficientes correspondientes a su transformada wavelet, tendrán las siguientes características:

El conjunto  $\{d_X(j, k), j=1, 2, \dots, J, k \in \square\}$ , es un proceso estacionario para cada octava  $j$ , si el N° de momentos desvanecientes de la wavelet madre  $\psi_0$ , es  $N \geq \frac{\alpha-1}{2}$ . La varianza del conjunto  $d_X(j, k)$  reproduce el comportamiento de escala subyacente, dentro de un rango de octavas  $j_1 \leq j \leq j_2$ . Dado que el valor medio de la wavelet es cero por la condición de admisibilidad, el segundo momento de  $d_X(j, k)$  es proporcional a  $2^{j\alpha}$ , donde  $j_1, j_2$  y  $\alpha$ , dependen del tipo de fenómeno de escala que exhiba el proceso original  $X(t)$ . Se cumplen entonces, las siguientes relaciones entre estos tres parámetros de la siguiente ecuación:

$$E[d_X(j, k)^2] \approx 2^{j\alpha} \quad (1)$$

Si  $X(t)$  es Hsssi  $\rightarrow \alpha = 2H + 1$ , y  $-\infty < j < \infty$

Si  $X(t)$ , presenta LRD,  $\alpha = 2H - 1$ ;  $j_2 = \infty$ , y  $j_1$  debe identificarse en función de los datos obtenidos en el análisis.

En caso de que el proceso obedezca una ley de potencias, pero en un determinado rango de frecuencias,  $f_1 \leq f \leq f_2$ , ( a este tipo de procesos se los denomina genéricamente procesos  $1/f$  ),  $\gamma$  corresponde a la ley de potencias expresada y el rango de escalas  $(j_1, j_2)$ , debe obtenerse partiendo de las frecuencias  $(f_1, f_2)$ .

### 3 Estimación mediante la script LDestimate

La script LDestimate, a diferencia de otras herramientas utilizadas en la estimación de “ $H$ ”, proporciona información extra acerca del contexto en el que se estima “ $H$ ”, esto es, tiene funciones accesorias que nos permiten escoger con bastante certeza la octava donde se inicia la alineación descartando las regiones que producen sesgo en el resultado, proporcionando además un estadístico que nos indica la “bondad del ajuste”, en función de los valores estudiados, y asegura que el rango escogido tenga una efectiva alineación, evidenciando el fenómeno de escala y no una simple aproximación promediada con eventuales desviaciones propias de la técnica de regresión lineal. En los otros métodos la estimación en forma general se hace tomando la máxima cantidad de datos y se pueden producir importantes desviaciones que no son tenidas en cuenta por carecer de estas funciones tales como mostrar el intervalo de confianza y la bondad del ajuste, se muestra a continuación los fundamentos del método y unos comentarios acerca de los parámetros involucrados

#### 3.1 Diagrama Log-escala – Estimación de $H$

La gran ventaja estadística del análisis Wavelet en el dominio de las escalas se evidencia en la expresión:

$$E[d_X(j, k)d_X(j, k')] \approx |k - k'|^{\alpha-1-2N} ; \text{ a medida que } |k - k'| \rightarrow \infty \quad (2)$$

Esto nos permite medir los promedios temporales y utilizarlos como estimaciones de los promedios estadísticos, y la falta de correlación entre los distintos coeficientes wavelets asegura que los estimadores temporales tengan una varianza pequeña.

Por otra parte la expresión  $E[d_X(j, k)^2] = 2^{j(2H+1)} E[d_X(0, k)^2]$ ; puede tomarse como un estimador del espectro de potencia del proceso en las inmediaciones de la frecuencia correspondiente a la octava  $j$ , y como se demuestra en [1], sec. 3.3.4 y 3.7, se puede estimar la varianza del proceso  $d_X(j, k)$ , según:

$$\mu_j = \frac{1}{n_j} \sum_{k=1}^{n_j} |d_X(j, k)|^2 \quad (3)$$

Donde  $n_j$  es el número de coeficientes en la octava  $j$ , y se observa que la varianza decrece conforme  $n_j$  aumenta, entonces la variable  $\mu_j$  es una forma eficiente de representar en forma compacta el comportamiento de segundo orden del proceso estudiado  $X_{(t)}$  en la octava  $j$ , y si se tiene en cuenta la expresión, los  $\mu_j$  son prácticamente independientes entre sí generando un desacoplamiento del comportamiento de  $X_{(t)}$  en las distintas octavas  $j$ , y dado que en el estimador la varianza decae hiperbólicamente en función de la octava  $j$ , se puede asumir que el

exponente de escala del proceso  $\alpha$ , lo podemos estimar como una regresión lineal de  $y_{(j)} \equiv \log_2(\mu_j)$ , como una función de la octava  $j$ .

En general se puede afirmar que un proceso que presenta LRD tiene una densidad espectral que obedece a:

$$f(\nu) \approx \frac{cf}{|\nu|^\alpha}, \text{ cuando } \nu \rightarrow 0 \quad (4)$$

Donde  $\nu$  es la frecuencia;  $cf$  es una constante positiva, y  $\alpha = 2H - 1$ .

Es sabido que la densidad espectral o potencia del proceso es proporcional al segundo momento de la variable y con relación a lo expuesto en el punto 3.1 (eq.1, 2 y 3), se pueden establecer equivalencias en ambas expresiones y expresar lo siguiente:

$$\log_2\left(E\left[d_x(j,k)^2\right]\right) = j\alpha + \log_2(c) \quad (5)$$

Lo que nos lleva a la siguiente aproximación:

$$\log_2(\mu_j) = j\alpha + \log_2(c) \quad (6)$$

A la gráfica de esta recta de regresión (eq.6) acompañada de los correspondientes intervalos de confianza en cada punto calculado, se la conoce como Diagrama Log-escala y de la pendiente se puede extraer el valor de  $\alpha$  y despejar el valor de  $H$ .

En realidad lo expuesto hasta aquí es el fundamento básico del método, donde la pendiente  $\alpha$ , se puede estimar en la región del diagrama donde los puntos se alinean entre dos octavas  $j_1, j_2$ , dado que es posible que no exista alineamiento en otras regiones.

Según las notas que acompañan esta script, el autor parte de la definición de LRD dada en términos del espectro de potencia  $f(\nu) \approx cf(\nu)^{-\alpha}$  cuando  $\nu \rightarrow 0$ , donde  $\nu$ , es la frecuencia,  $\alpha$  es el exponente de escala, que es adimensional, y  $cf$  es un coeficiente con dimensión de varianza y describe aspectos cuantitativos de la longitud o extensión del comportamiento LRD, y como ejemplo de la importancia de  $cf$  expresa que los intervalos de confianza de la estimación de la media de LRD son proporcionales a  $\sqrt{cf}$ . La script entrega una estimación de sendos parámetros  $\alpha$  y  $cf$  junto a otros que toman importancia según el contexto como se muestra a continuación.

- El diagrama Log-escala, nos proporciona una gráfica con la bondad de la estimación en cada punto como función de  $j_1$  (figura izquierda), lo que permite una mejor elección de las octavas  $j_1, j_2$
- Diferentes tipos de escala son posibles, sin embargo, el procedimiento de análisis es el mismo en cada caso. En primer lugar, el diagrama de Logscale se genera, y

6 Reinaldo Scappini<sup>1</sup>, Luis Marrone<sup>2</sup>,

examina los datos para encontrar un punto de corte inferior de la escala  $j_1$ , y otro punto de corte superior  $j_2$ , en los que la alineación (línea recta) se observa. Estos puntos de corte deben ser experimentados para encontrar un rango que se ajuste a la regresión de los intervalos de confianza sobre el Diagrama Logscale (Los valores iniciales se deben especificar en la lista de argumentos de "LDestimate", pero estos se pueden cambiar interactivamente).

- Para cada rango de alineación elegido, la función de los resultados de la estimación de la pendiente "alfa", toma valores reales. El valor de alfa, y el rango  $j_1, j_2$ , ayudará a determinar qué tipo de escala se presenta.
- Por conveniencia, alfa se transforma en valores de los parámetros relacionados, como el parámetro de Hurst  $H$ , o la dimensión fractal de la muestra (válida sólo si es gaussiana). El usuario debe determinar qué tipo de escala está presente.
- NOTA: en el caso de LRD, alfa es el parámetro pertinente directamente, sin embargo, a veces es reescrita como una «H», pero esta no es la H de auto-similitud estricta, es simplemente una convención para reescribir alfa de esta forma para procesos LRD.
- La experimentación con el número momentos desvanecientes  $N$  de la wavelet es necesario para: (a) asegurarse de que la onda detalles están bien definidas (con valores de  $H$  altos, serán necesarios valores más altos de  $N$ ,  $N = 1$  es suficiente para estudiar LRD), y (b) eliminar o disminuir la influencia de las tendencias deterministas, como ser tendencias lineales o variaciones de nivel medio, que pueden estar presentes. En ambos casos es conveniente un aumento de  $N$ , hasta lograr un diagrama Logscale estable.
- Una estadística de bondad de ajuste  $Q(j_1)$ , basado en Chi-Cuadrado se emite para ayudar con la elección del rango de escala, y se representa en el título del gráfico correspondiente (Fig. 1.), como se muestra a continuación:

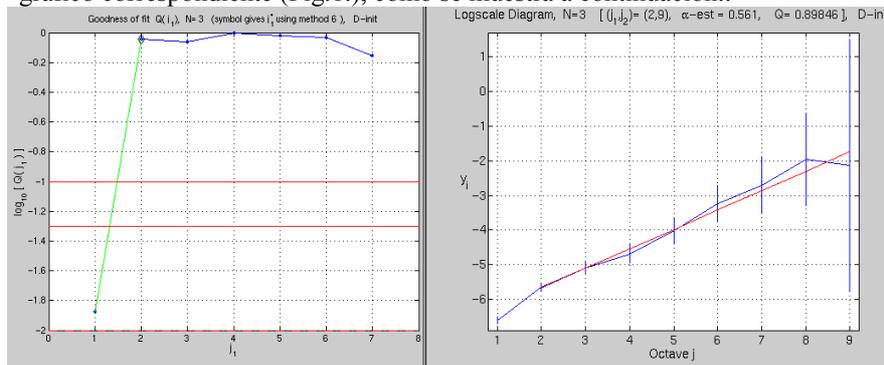


Fig. 1.

Es la probabilidad de observar que los datos, con las estimaciones de la varianza en cada escala realmente siga la forma de una recta para asegurar la efectividad de la regresión lineal. Un valor superior a 0,05 es aceptable y es aconsejable la

elección de  $j_{(1)}$ , a partir de donde se estabiliza el valor de  $Q(j_1)$ , La estimación visual de la región de alineación es difícil, cuando los intervalos de confianza se vuelven muy pequeños, en escalas pequeñas, en este caso la estadística  $Q(j_1)$ , es una mejor guía.

#### 4 Utilizando LDestimate

La script puede utilizarse como una función con 7 argumentos de entrada con la siguiente sintaxis:

**LDestimate(data,regu,j1,j2,discrete\_init,calcj1,printout)**

- data = Vector con los datos que se desean analizar (debe ser un vector fila).
- regu = N o número de momentos desvanecientes de la wavelet, este parámetro está relacionado con la regularidad de la estimación, a mayor valor mejoramos la bondad del ajuste Q, la variable regu está disponible desde 1 a 10. (sugiero empezar con 1 e ir aumentando para observar la variación de Q y el grafico de regresión respectivamente).
- j1 = octava de corte inferior debe ser  $\geq 1$ .
- j2 = octava de corte superior, su valor máximo está relacionada con la longitud de los datos, pero se puede cambiar interactivamente durante la ejecución de la script, sugiero arrancar con el valor 2 y luego ir probando otros valores.
- discrete\_init = con el valor 1 realiza la inicialización MRA para datos intrínsecamente discretos si el valor es cero, asume la de entrada de datos ya inicializado (es decir, ya está calculada la aproximación de secuencia o se utiliza un vector correspondiente a una aproximación).
- calcj1 = con el valor 1 realiza el cálculo de j1 optimo utilizando la script newchooseJ1 mencionada más arriba, si el valor es cero omite el cálculo. (sugiero dejarlo en 1).
- printout = con el valor 1 realiza los dos gráficos correspondientes a "Q" y la regresión del diagrama Log-escala. Con el valor cero no realiza los gráficos y solamente entrega los valores calculados.

#### 5 Análisis realizado

A continuación y a manera de muestra de las posibilidades de estudio que brinda esta metodología, se analizan una serie de trazas que están disponibles para su uso en la investigación conforme las políticas de cada fuente (más detalle a continuación en las correspondientes descripciones).

El análisis se realiza sobre muestras tomadas de siete tipos de enlaces:

## 8 Reinaldo Scappini<sup>1</sup>, Luis Marrone<sup>2</sup>,

1. Ethernet 10 Mbits.
2. Ethernet 100 Mbits.
3. Ethernet 1 Gbits.
4. Ethernet 10 Gbits.
5. OC12
6. OC48
7. OC192

- Trazas Ethernet 10 Mb: Son las clásicas trazas utilizadas en muchísimos trabajos y que fueran utilizadas en el trabajo seminal de Leland et.al [5]; Si bien trabajo es de mucha antigüedad, es considerado como el punto de partida en este campo de análisis y es muy útil como referencia, pues casi todos los estudios comparativos realizados por distintos investigadores lo utilizan
- Trazas Ethernet 100 Mb: Las trazas pertenecen a la colección: “WIDE-TRANSIT 100 Megabit Ethernet Trace (Anonymized)”. Se encuentran disponibles en [6].
- Trazas Gigabit Ethernet: Estas trazas corresponden a capturas realizadas por NLANR PMA, mediante una tarjeta Endace DAG4.2GE dual Gigabit Ethernet network. Las trazas encuentran disponibles en la página del proyecto en el link [7].
- Trazas 10 Gigabit Ethernet Cluster TeraGrid SDSC: Estas trazas se recogieron mediante un monitor del proyecto [PMA](#) [8] (Passive Measurement and Analysis)
- Trazas sobre Fibra Óptica: Tres grupos de trazas sobre fibra óptica, OC12 – OC48, y OC192; fueron facilitadas por el Proyecto [CAIDA](#) [9] (CAIDA: The Cooperative Association for Internet Data Analysis).

### 5.1 Procedimiento previo aplicado a las trazas

Debido al importante tamaño de los archivos de las trazas (típicamente del orden de los gigabytes), para poder procesarlos con PC's convencionales, a todas las trazas se las sometió al siguiente tratamiento: Se utiliza el software Wireshark [10], que es un conocido analizador de protocolos basado en tcpdump, que permite manipular trazas que utilicen formato compatible con el tcpdump y además cuenta con una utilidad de línea de comandos llamada Tshark [11], que resulta particularmente apropiada para esta tarea como se muestra a continuación:

- Se toma el primer millón de tramas de la traza y se lo convierte en un archivo con la extensión .pcap. La sintaxis del comando es: Tshark -r [nombre de la traza] -c 1000000 -w [nombre.pcap].
- Si se quiere trabajar con los tiempos entre arribos, creamos el archivo correspondiente, de la siguiente manera: Tshark -r [nombre.pcap] -e frame.time\_delta -T fields > nombre.txt. Esto lo que hace es, leer el archivo .pcap que se creó con el millón de trazas, y lo filtra mediante el contenido del campo timestamp, del que a su vez establece la diferencia con la lectura anterior creando el valor tiempo entre arribos para cada trama y luego guarda el archivo en formato ASCII.
- Del mismo modo si se desea trabajar con la longitud en bytes de la trama, se utiliza el campo frame.len para el filtrado de la siguiente forma: Tshark -r [nombre.pcap]

–e frame.len –T fields > nombre.txt. Obteniendo de esta forma la salida en formato ASCII que es la más cómoda para poder utilizarla con el Matlab.

Aclarados todos los detalles que permitirán repetir los análisis aquí expuestos, a continuación se muestra el resumen de los resultados del análisis efectuado a estas trazas, con el primer millón de datos para cada una de ellas, los datos corresponden a tiempos entre arribos y se muestran en la siguiente tabla.

## 6 Resultados obtenidos

Se exhiben los resultados de la estimación del parámetro  $H$  realizada con la script de Darryl Veitch, tomando una muestra de cada traza, conforme se describe anteriormente. Se aclara que las condiciones iniciales para todas las estimaciones son las mismas, es decir inicialmente se fijan los parámetros como:  $N=4$  momentos desvanecientes,  $j_1=2$ ;  $j_2=20$  y los tres parámetros restantes igual a uno, esto significa que la script calculará en función de los resultados iniciales para cada caso lo siguiente: El mejor valor para  $j_1$  como función del  $j_2$  que se encuentre como óptimo.

Tomando los valores sugeridos por la script para  $j_1$  y  $j_2$ , se repite la estimación obteniendo los datos que se muestran en la tabla 1:

Traza	Parámetro	$j_1$	$j_2$	$\alpha$	$\alpha[95\%]$	$H$	$H[95\%]$
10Mbit_pAug89.TL		9	16	0,642	[0,590, 0,693]	0,821	[0,795, 0,846]
10Mbit_pOct89.TL		6	16	0,51	[0,494, 0,527]	0,755	[0,747, 0,763]
100Mbit_Tokio(200701090800)		8	16	0,315	[0,280, 0,349]	0,657	[0,640, 0,675]
100Mbit_Tokio(200701091200)		6	16	0,304	[0,288, 0,321]	0,652	[0,644, 0,661]
Gigabit_Ethernet(20040130-132000-0)		10	16	0,557	[0,479, 0,634]	0,778	[0,740, 0,817]
10Gigabit_Ethernet(20040212-130000-0)		10	14	0,508	[0,286, 0,731]	0,754	[0,643, 0,865]
ampath-ac12.20070109.dag0.20070109-0000.anon		10	16	0,693	[0,616, 0,771]	0,847	[0,808, 0,885]
ampath-ac12.20070109.dag0.20070109-1500.anon		12	16	0,303	[0,106, 0,499]	0,651	[0,553, 0,750]
CC48-20020814-103000-0-anon.pcap		5	16	0,195	[0,184, 0,207]	0,598	[0,592, 0,603]
CC48-20020814-115000-0-anon.pcap		4	16	0,175	[0,167, 0,183]	0,588	[0,584, 0,592]
equinix-chicago.dirA.20090115-080100.UTC.anon		9	16	0,461	[0,410, 0,512]	0,73	[0,705, 0,756]
equinix-chicago.dirB.20090115-080100.UTC.anon		8	16	0,282	[0,248, 0,317]	0,643	[0,624, 0,659]

Table 1.

### 6.1 Tabla Comparativa de Resultados Obtenidos con Distintos Métodos de Estimación de “ $H$ ”.

La tabla 2, muestra los resultados de la estimación de  $H$ , utilizando las aplicaciones desarrolladas en [1], junto al resultado obtenido mediante la script de Darryl Veitch.

Traza \ Metodo	1	2	3	4
10 Mbit. pAug89.TL	0,802	0,737	<b>0,821</b>	0,756
10 Mbit. pOct89.TL	0,844	0,839	<b>0,755</b>	0,785
100 Mbit. Tokio (200701090800)	0,675	0,663	<b>0,657</b>	0,667
100 Mbit. Tokio (200701091200)	0,696	0,686	<b>0,652</b>	0,625
Gigabit-Ethernet (20040130-132000-0)	0,69	0,729	<b>0,778</b>	0,682
10 Gigabit Ethernet (20040212-130000-0)	0,93	0,979	<b>0,754</b>	0,883
ampath-oc12.20070109.dag0.20070109-0000.anon	0,685	0,727	<b>0,847</b>	0,683
ampath-oc12.20070109.dag0.20070109-1500.anon	0,638	0,678	<b>0,651</b>	0,684
OC48-20020814-103000-0-anon.pcap	0,58	0,651	<b>0,598</b>	0,626
OC48-20020814-115000-0-anon.pcap	0,66	0,645	<b>0,588</b>	0,637
equinix-chicago.dirA.20090115-060100.UTC.anon	0,653	0,667	<b>0,73</b>	0,642
equinix-chicago.dirB.20090115-060100.UTC.anon	0,693	0,698	<b>0,643</b>	0,637

Table 2.

1-Varianza/Tiempo 2-Rango Reescalado 3- Diagrama Log-Escale 4- Varianza/Octavas
--

Resultados en cursiva, se encuentran los resultados de la estimación de  $H$ , por el método del diagrama log-escala implementado mediante la script LDestimate de Darryl Veitch, que es el de mayor precisión y menor sesgo.

## Referencias Bibliográficas

- [1] [http://postgrado.info.unlp.edu.ar/Carreras/Magisters/Redes\\_de\\_Datos/Tesis/Scappini\\_Reinaldo.pdf](http://postgrado.info.unlp.edu.ar/Carreras/Magisters/Redes_de_Datos/Tesis/Scappini_Reinaldo.pdf)
- [2] [http://www.cubinlab.ee.unimelb.edu.au/~darryl/secondorder\\_code.html](http://www.cubinlab.ee.unimelb.edu.au/~darryl/secondorder_code.html)
- [3] [Kihong Park, Walter Willinger Self-Similar Network Traffic and Performance Evaluation Copyright 2000 John Wiley & Sons, Inc. ISBNs: 0-471-31974-0 (Hardback); 0-471-20644-X (Electronic).
- [4] [M. Alzate y A. Monroy, Uso de la transformada wavelet para el estudio de tráfico fractal en redes de comunicaciones. Revista Ingeniería Vol. 7 No. 1 Junio 2002 Páginas: 11 –24. Universidad Distrital Francisco José de Caldas.
- [5] [W. E. Leland, M. S. Taqqu, W. Willinger, and D. V. Wilson, On the self-similar nature of ethernet traffic (extended version), IEEE/ACM Transactions on Networking, vol.2, pp.1–15, Feb. 1994.
- [6] [http://imdc.datcat.org/collection/1-055M-0=WIDE-TRANSIT+100+Megabit+Ethernet+Trace+2007-01-09+\(Anonymized\)](http://imdc.datcat.org/collection/1-055M-0=WIDE-TRANSIT+100+Megabit+Ethernet+Trace+2007-01-09+(Anonymized))
- [7] <http://pma.nlanr.net/Special/sdsc1.html>
- [8] <http://pma.nlanr.net/Special/>
- [9] <http://www.caida.org/home/>
- [10] <http://www.wireshark.org/>