

## Geração de Tráfego LRD de Alta Variabilidade Através do Ruído Gaussiano Fracionário Modulado por Pareto

Ricardo José Paiva de Britto Salgueiro<sup>1</sup>, Edilayne Meneses da Silva<sup>2</sup>,  
José Augusto Suruagy Monteiro<sup>3</sup>

<sup>1</sup>Universidade Católica de Pernambuco – UNICAP/ DEI  
Rua do Príncipe, 526 Boa Vista 50050-900 Recife, PE.

<sup>2</sup>Universidade Federal de Pernambuco – UFPE/ CIn  
Av. Prof. Luis Freire s/n – Caixa Postal 7851 – 50732-970 Recife, PE.

<sup>3</sup>Universidade Salvador – UNIFACS  
Rua Ponciano Oliveira, 126 Rio Vermelho 41950-275 Salvador, BA.

ricardo@unicap.br, ems@cin.ufpe.br, suruagy@unifacs.br

**Abstract.** *In this work, we present a Pareto modulated fractional Gaussian Noise for the characterization of traffic with long-range dependence and high variability. In our model, the difficulties of representation of a traffic with high variability are overcome through a classification algorithm based on clustering. The component of long-range dependence is captured using the distribution of Pareto for the definition of state residence time. Analysis done through the generation of series for representative video sources had shown the validity of the proposed model. Statistical equivalences had been ratified by means of the comparison of histograms and QQ-plot. The statistical multiplexing effect in a computer network, in terms of bits loss rate, was evaluated through simulation. The obtained results showed that the Pareto modulation, besides eliminating the occurrence of inherent negative values to a Gaussian Noise with high variability, gets series that determine a performance significantly better when compared with the original series.*

**Resumo.** *Neste trabalho, apresentamos o Ruído Gaussiano Fracionário modulado por Pareto para geração de tráfego com dependência de longo alcance e alta variabilidade. Em nossa modelagem, as dificuldades de representação de um tráfego com alta variabilidade são superadas através de um algoritmo de classificação baseado em clustering. A componente de dependência de longo alcance é capturada utilizando a distribuição de Pareto na definição do tempo de permanência em cada estado. Análises efetuadas através da geração de séries representativas de fonte de vídeo mostraram a validade do modelo proposto. As equivalências estatísticas foram ratificadas por meio da comparação de histogramas e gráfico quantis-quantis. O efeito da multiplexação estatística em redes de computadores, em termos da taxa de perdas de bits, foi avaliado através de simulações. Os resultados obtidos revelaram que a modulação por Pareto, além de eliminar a ocorrência de valores negativos inerentes a um Ruído Gaussiano com alta variabilidade, obtém séries que determinam um desempenho significativamente melhor quando comparados com a série original.*


## 1. Introdução

Os sistemas de telecomunicações passaram por profundas transformações no transcorrer destas últimas décadas. Inicialmente concebidos e implantados para permitir o transporte de voz analógica, estes sistemas foram adaptados e modificados acompanhando a crescente evolução da era digital. Os serviços de telecomunicações são hoje oferecidos para tráfego tanto de voz digital, como de dados e imagens, viabilizando o desenvolvimento de aplicações que originam um tráfego com alta variabilidade e que requerem uma grande quantidade de recursos na rede. Diante deste cenário, o desenvolvimento de modelos capazes de caracterizar o tráfego oferecido às redes de computadores pelas aplicações dos usuários é de grande relevância para o dimensionamento das redes e a garantia da qualidade de serviço — QoS (*Quality of Service*) desejada.

Aliado a este cenário está a definição da metodologia para estudo deste novo tráfego que inclui características não previstas anteriormente. Esta constatação surgiu a partir do trabalho de Leland *et al* que observou a presença de dependência de longo alcance — LRD (*Long Range Dependence*) em tráfego de redes de computadores [Willinger et al., 2004, Leland et al., 1994]. Esta nova nuance quebrou um paradigma no qual admitia-se que os modelos markovianos eram suficientes para a análise de qualquer tipo de tráfego. A partir de então, uma série de trabalhos publicados por diversos autores abordou a questão da evidência de LRD e a utilização de modelos markovianos ou de diferenciação fracionária (não markovianos). Inúmeras medições foram realizadas envolvendo tráfego em redes Ethernet [Perlingeiro and Ling, 1999, Alexander et al., 1995, Chen et al., 1995], tráfego provenientes de aplicações para páginas WWW [Crovella and Bestavros, 1995, Crovella et al., 1998, Crovella and Bestavros, 1996], tráfego em redes ópticas para backbone da internet [Yao et al., 2003] e tráfego de vídeo [Garrett, 1993, Rose, 1995, Fitzek and Reisslein, 2001], dentre outros. A confirmação da presença de LRD foi uma constante. A presença ou ausência de LRD em um tráfego de uma rede pode ser verificada pela avaliação do parâmetro de diferenciação da série temporal formada pelo conjunto de medidas desse tráfego. O valor do parâmetro de Hurst  $0 < H < 1$ , introduzido em [Hurst, 1951, Hurst, 1956], é que define a natureza fracionária do processo representativo do tráfego. Para  $0,5 < H < 1$ , dizemos que o processo possui LRD, para  $H = 0,5$ , as observações não são correlacionadas e para  $0 < H < 0,5$ , o processo apresenta dependência de curto alcance — SRD (*Short Range Dependence*) [Beran, 1994].

Desde a identificação da existência de LRD em séries temporais até a atualidade, uma variedade de algoritmos para geração de séries temporais com LRD foram propostos. Dentre tais métodos, destacamos o Método da Transformada Rápida de Fourier — FFT (*Fast Fourier Transform*) para geração de um Ruído Gaussiano Fracionário — FGN (*Fractional Gaussian Noise*), ou, abreviadamente, FGN-FFT [Paxson, 1995]. Uma característica fundamental do FGN-FFT é a sua eficiência computacional na geração de séries longas, ao contrário de outros métodos como o modelo Auto-regressivo Integrado de Média Móvel com Diferenciação Fracionária — FARIMA (*Fractional Autoregressive Integrated Moving Average*) [Garrett and Willinger, 1994] que empregam uma expressiva carga computacional quando submetido a geração de séries longas.

O FGN-FFT utiliza a Transformada de Fourier de Tempo Discreto — DTFT (*Discrete Time Fourier Transform*), de modo que é gerada uma seqüência de números complexos no domínio da frequência, oriundos da densidade espectral do FGN. A série



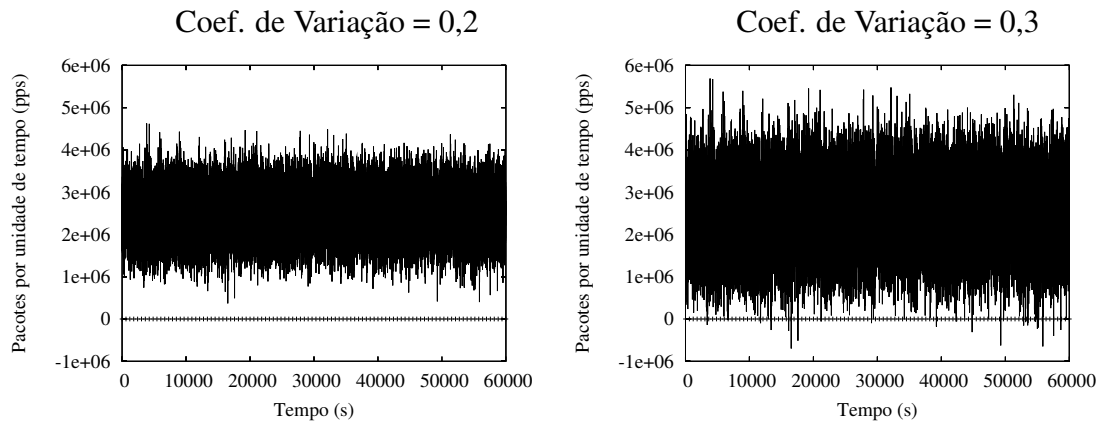
**Figura 1: Traço da medição do tráfego Ethernet da Bellcore (Telcordia) e o traço da geração equivalente através do FGN-FFT.**

temporal é, então, obtida através da transformada inversa DTFT. Como a DTFT e sua inversa pode ser computada rapidamente utilizando o algoritmo da Transformada Rápida de Fourier, Paxson refere-se ao método como FFT [Paxson, 1995].

A geração de um tráfego LRD pode ser efetuada a partir de um  $FGN(H, m_1, m_2)$ , onde  $H$  corresponde ao parâmetro de Hurst,  $m_1$ , o primeiro momento e  $m_2$  o segundo momento da série representativa do tráfego. Na figura 1, ilustramos comparativamente os traços da medição do tráfego Ethernet nos laboratórios da Bellcore (Telcordia) [Leland and Wilson, 1991, Leland et al., 1994] com os traços da série gerada pelo FGN-FFT com parâmetro de Hurst e primeiro e segundo momentos equivalentes. Pela figura, podemos observar a ocorrência de valores negativos na série gerada. Os valores negativos não possuem significado prático. Uma solução frequentemente adotada é o truncamento em zero para tais casos. Todavia, as propriedades estatísticas são alteradas.

A ocorrência de valores negativos em uma série gerada pelo FGN-FFT, deve-se à alta variação dos valores da série original. Tomando o coeficiente de variação, definido pela relação do desvio padrão pela média, como medida para expressar a variação em torno da média, verificamos que, para a representação de um tráfego de uma rede com uma taxa média de 2,5 Gbps através de um FGN, se o coeficiente de variação for 0,2, por exemplo, a série gerada possuirá valores apenas positivos. Em contrapartida, se o coeficiente de variação for 0,3, surgem valores negativos, como mostra a figura 2.

Em [de Britto Salgueiro, 2004] mostramos que os valores negativos acontecem também em outros modelos fracionários como com o FGN gerado a partir do algoritmo RMD (*Random Midpoint Displacement*) [Lau et al., 1995] e com o FARIMA. Xiaohu *et al.*, em [Xiaohu et al., 2003], apresentam o Movimento Estável Fracionário Linear — LFSM (*Linear Fractional Stable Motion*). O LFSM, segundo mostram os autores, consegue capturar a explosividade presente em traços de medições de tráfego efetuada nos laboratórios da Bellcore (Telcordia), mas é observada a presença de valores negativos em sua série gerada. Portanto, a geração de tráfego LRD de alta variabilidade requer cuidados. O uso de procedimentos que evitem a ocorrência de valores negativos pode ser preponderante em diversos casos na modelagem de sistemas em redes de computadores, tais como em definições para alocação de recursos em redes, elaboração de regras para dimensionamento de *buffers* nos comutadores das redes, predições de degradação de QoS causadas por congestionamento e de mecanismos de controle de congestionamento.



**Figura 2: Traços gerados através do FGN-FFT para um tráfego médio de 2,5 Gbps com coeficiente de variação de 0,2 e 0,3.**

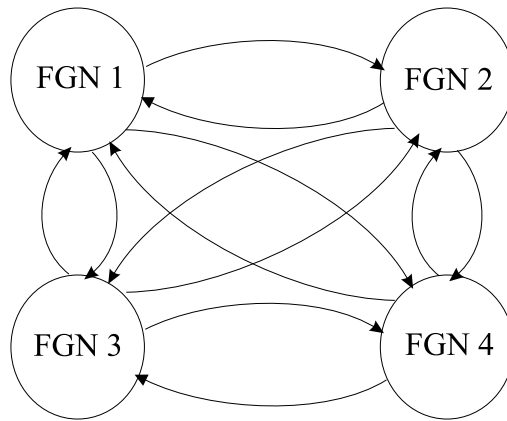
Neste trabalho, apresentamos um modelo capaz de capturar os momentos de primeira e segunda ordem da série temporal representativa do tráfego em redes de computadores, caracterizando um tráfego que possui alta variabilidade e LRD, sem, contudo, permitir a ocorrência de valores negativos. Na seção 2, apresentamos o FGN modulado por Pareto para geração de tráfego LRD de alta variabilidade e LRD. Nas seções 3 e 4, mostramos os resultados obtidos com o modelo na geração e análise de desempenho de uma rede submetida a um tráfego proveniente de uma fonte de vídeo, que apresenta uma alta variabilidade e LRD. Finalmente, na seção 5, tecemos nossas conclusões sobre o modelo aqui proposto.

## 2. Ruído Gaussiano Fracionário Modulado por Pareto

O Ruído Gaussiano Fracionário Modulado por Pareto — PMFGN (*Pareto Modulated Fractional Gaussian Noise*) é um modelo fracionário duplamente estocástico, no qual um processo de Pareto modula a transição de estados que determinam os parâmetros de um FGN para geração de séries temporais. A especificação de  $\text{PMFGN}(H, n, S^*, T, P)$  é dada em termos do parâmetro de Hurst ( $H$ ), do número de estados ( $n$ ), do conjunto de estatísticas de primeira e segunda ordem de interesse ( $S^*$ ), do tempo de permanência em cada estado ( $T$ ) e da matriz probabilidade de transição —  $P$ . O PMFGN deve ser parametrizado de modo a possuir um conjunto de estatísticas que indiquem uma variabilidade suficientemente pequena em cada estado. Desse modo, o FGN, pode ser utilizado sem a ocorrência de valores negativos.

O PMFGN é uma particularização do Modelo Fracionário Modulado por Pareto — PMFM (*Pareto Modulated Fractional Model*) definido em [de Britto Salgueiro, 2004], onde o processo fracionário para geração das séries temporais é um FGN. Em [de Britto Salgueiro et al., 2005], apresentamos uma versão resumida do PMFM contendo resultados preliminares com o uso do PMFGN. Aqui neste trabalho, além de detalhar nosso procedimento de modelagem, incluímos resultados comparativos do PMFGN com o FGN, e mostramos sua aplicabilidade tanto para seqüências codificadas em MPEG-1, como para seqüências codificadas em H.263.

A figura 3 exemplifica a modulação do PMFGN exibindo um diagrama de 4 estados. A cada estado está associado um FGN, gerado de acordo com os momentos de



**Figura 3: Um diagrama de estados representando a modulação de 4 processos FGN.**

primeira e segunda ordem e parâmetro de Hurst.

Nas subseções seguintes, abordamos as questões relativas à parametrização do PMFGN. Na subseção 2.1, apresentamos o procedimento para determinação do número de estados e do conjunto de estatísticas de primeira e segunda ordem com variabilidade suficientemente pequena a partir de uma série representativa de um tráfego com variabilidade alta. Posteriormente, descrevemos, na seção 2.2, as particularidades do processo de modulação por Pareto que adotamos.

### 2.1. Definição do Conjunto de Estatísticas de Primeira e Segunda Ordem

Dada uma série temporal com estatísticas de primeira e segunda ordem, definidas pelo conjunto  $S$ , indicando uma alta variabilidade, podemos obter um novo conjunto  $S^*$  formado por  $n$  subconjuntos com variabilidade suficientemente pequena, de modo que  $S \Leftrightarrow S^* = \{S^1, S^2, \dots, S^n\}$ .

Um procedimento de classificação estatística pode ser adotado para a obtenção do conjunto  $S^*$ . Neste trabalho, propomos o uso de um método baseado em *clustering* [Jain et al., 1999] para tal procedimento. Dessa forma, cada subconjunto de estatísticas de primeira e segunda ordem é relacionado a um *cluster*, as médias dos elementos inseridos nos *clusters* são denominadas de centróides e o *clustering* é efetuado avaliando a menor distância entre o componente em questão e cada centróide.

A literatura apresenta uma variedade de algoritmos de *clustering* de propósitos gerais ou específicos. Dentre esses, destacamos o algoritmo  $k$ -Means [Menasce et al., 1994], o qual adaptamos aos nossos objetivos. Optamos por um procedimento que possibilita a busca pelo número mais adequado de *clusters*, partindo de um determinado número  $k$ . Assim, se  $k$  *clusters* não forem suficientes para obtenção de um *clustering* no qual todos os *clusters* possuam um coeficiente de variação abaixo de um limiar desejado, o algoritmo acrescentará mais um *cluster*, repetindo o processo até a satisfação da condição, ou até um número máximo de vezes pré-estabelecido. Após essas alterações, renomeamos o algoritmo para  $k^+$ Means, simbolizando a possibilidade de aumento no número de *clusters*<sup>1</sup>. A figura 4 exhibe o algoritmo  $k^+$ Means.

<sup>1</sup>Ball e Hall, em [Ball and Hall, 1965] apud [Jain et al., 1999], propuseram o algoritmo ISODATA que é uma variação do  $k$ -Means, onde os *clusters* podem ser unificados e particionados na busca de um *clustering* ótimo. Portanto, o algoritmo  $k^+$ Means pode ser visto também como uma variação do ISODATA.

Após o estabelecimento dos *clusters*, o conjunto  $S^*$ , contendo as estatísticas de primeira e segunda ordem de interesse, pode ser definido. No caso, por exemplo, de uso de séries geradas pelo FGN, o conjunto  $S^*$  deve conter as médias  $\mu$  e os coeficientes de variação C.O.V. de cada *cluster*. Nesse caso, temos, então  $S^* = \{(\mu_1, \text{C.O.V.}_1), (\mu_2, \text{C.O.V.}_2), \dots, (\mu_n, \text{C.O.V.}_n)\}$ .

1. Escolha um número  $k$  de *clusters*.
2. Ordene a seqüência e divida em  $k$  blocos. Calcule a mediana de cada bloco e utilize cada mediana como estimativa inicial do centróide de cada *cluster*.
3. Examine cada ponto da seqüência, inserindo-o no *cluster* que possui o centróide com valor mais próximo. Estabeleça o novo centróide do *cluster* escolhido para atribuição como a média calculada após cada atribuição.
4. Calcule o coeficiente de variação de cada *cluster* e determine o coeficiente de variação máximo. Caso o coeficiente de variação máximo seja menor do que o limiar, ou caso o número máximo de passos seja executado, termine. Caso contrário, divida o *cluster* com o coeficiente de variação máximo em 2 *clusters* e recalcule o centróide de cada novo *cluster*.
5. Repita os passos 3 e 4 até satisfazer a condição de término.

**Figura 4: Algoritmo  $k^+$ Means.**

## 2.2. Modulação por Pareto

A especificação do processo de modulação por Pareto corresponde à definição da matriz de probabilidades de transição e do tempo médio de permanência em cada estado.

A probabilidade de transição de um estado a outro do processo de modulação é determinada a partir da série temporal após o *clustering*. Um procedimento de discretização baseado nas médias dos *clusters* auxilia a identificação das transições de estados. Definindo um processo estocástico  $\mathbf{P}$  com estados  $\mathcal{S}_1, \mathcal{S}_2, \dots, \mathcal{S}_n$ ,  $n < \infty$ , a probabilidade de transição de um estado  $\mathcal{S}_i$  para um estado  $\mathcal{S}_j$  é determinada empiricamente tal que

$$p_{ij} = \frac{N_{ij}}{N_i}, \quad (1)$$

onde  $N_{ij}$  representa o número de vezes em que o sistema sai do estado  $\mathcal{S}_i$  e entra no estado  $\mathcal{S}_j$ , enquanto que  $N_i$  corresponde ao número de vezes que o sistema entra no estado  $\mathcal{S}_i$ .

O tempo médio de permanência em um estado pode, também, ser determinado empiricamente. Após uma análise na seqüência discretizada podemos calcular o número médio de valores da série que permanecem em cada um dos estados. Cada número médio calculado implica em um tempo médio de permanência em cada estado associado a uma matriz da taxa de transição ajustada aos dados empíricos. Desse modo, considere  $N_{ki}$  o número de valores da série que permanecem no estado  $\mathcal{S}_i$  durante a  $k$ -ésima visita a esse estado e  $N_i$ , tal como em 1, como o número de vezes que o sistema entra no estado  $\mathcal{S}_i$ . O número médio de valores da série que permanecem no estado  $\mathcal{S}_i$  pode, então, ser determinado por

$$Nq_i = \frac{1}{N_i} \sum_{k=1}^{N_i} N_{ki}. \quad (2)$$

**Tabela 1: Características da distribuição de Pareto transladada.**

<b>DISTRIBUIÇÃO DE PARETO TRANSLADADA</b>	
Parâmetros	$\alpha, \alpha < 0; \theta$
Faixa	$1 \leq x \leq \infty$
PDF	$f(x) = \frac{\alpha}{\theta} \left(\frac{\theta}{x+\theta}\right)^{\alpha+1}$
CDF	$F(x) = 1 - \left(\frac{\theta}{x+\theta}\right)^{\alpha}$
Média	$\frac{\theta}{\alpha-1}, \alpha > 1$
Variância	$\frac{\alpha}{\theta^{-\alpha}} \left( \frac{(1+\theta)^{2-\alpha}}{\alpha-2} - \frac{2\theta(1+\theta)^{1-\alpha}}{\alpha-1} + \frac{\theta^2(1+\theta)^{-\alpha}}{\alpha} \right) - \left(\frac{\theta}{\alpha-1}\right)^2, \alpha > 2$
nº aleatório	$\frac{1}{u^{1/\alpha}}$

A partir da equação 2 determinamos o tempo médio de permanência no estado  $\mathcal{S}_i$ . Se representarmos por  $t_{sc}$  a escala de tempo relativa ao tempo de de cada valor da série<sup>2</sup>, temos que o tempo médio de permanência no estado  $\mathcal{S}_i$  é, por sua vez, expresso por

$$T_i = t_{sc} Nq_i. \quad (3)$$

A característica de LRD da série é resgatada pela utilização da distribuição de Pareto transladada [Brichet et al., 1996] para determinação do tempo de permanência nos estados. A tabela 1 resume as características da distribuição de Pareto transladada. O parâmetro  $\alpha$ , mostrado na tabela, é obtido através da relação  $\alpha = 3 - 2H$ , onde  $H$  é o parâmetro de Hurst [Taqqu et al., 1997].

A distribuição de Pareto transladada corresponde à distribuição de Pareto acrescida de um parâmetro  $\theta$  que permite o ajuste de uma média desejada sem alterar o parâmetro  $\alpha$  e, por conseguinte, o parâmetro de Hurst. Podemos, então, aplicar a distribuição de Pareto transladada em nosso caso, controlando o parâmetro  $\theta$  para a obtenção de médias correspondentes aos tempos de permanência extraídos da seqüência em questão. Além dos parâmetros  $\alpha$  e  $\theta$ , a tabela 1 exibe a faixa de valores, a função densidade de probabilidade — PDF (*Probability Density Function*), a função de distribuição acumulada — CDF (*Cumulative Distribution Function*), a média, a variância e o método de geração de número aleatório.

Com base na probabilidade de transição e no tempo de permanência em cada estado, implementamos, através de simulação, um processo estocástico para a modulação. Em um processo de simulação orientada a eventos [MacDougall, 1987] após o término do tempo de permanência em um estado, deve ocorrer, obrigatoriamente, o evento transição. Isto significa que a probabilidade de permanência no estado é zero, o que nos induz à necessidade de um ajuste na matriz de probabilidades de transição. Desse modo, a partir da matriz de probabilidades de transição  $P$ , definimos a matriz de probabilidades de transição obrigatória  $P_o$ , como a matriz composta pelos elementos  $P_{oij}$  dado por

$$P_{oij} = \begin{cases} P_{ij} / (\sum_{j=1}^n P_{ij} - P_{ii}) & \text{caso } i \neq j \\ 0 & \text{caso } i = j, \end{cases} \quad (4)$$

onde  $P_{oij}$  indica a probabilidade de transição obrigatória do estado  $i$  para o estado  $j$ .

<sup>2</sup>No caso de uma seqüência de vídeo, por exemplo, cada valor da série pode representar a quantidade de bits em um quadro de imagem. O tempo de cada valor da série, nesse caso, refere-se ao tempo de transmissão de um quadro de imagem.

Tabela 2: Estatísticas dos *clusters* da seqüência dino obtidas pelo Método Baseado em *Clustering* – Algoritmo  $k^+$ Means para 7 *clusters*.

<i>CLUSTER</i>	MÉDIA	COEFICIENTE DE VARIAÇÃO
1	2.700	0,19
2	4.326	0,12
3	6.875	0,14
4	10.904	0,15
5	19.177	0,18
6	37.158	0,17
7	59.546	0,15

### 3. Modelagem de Tráfego com o PMFGN

Uma seqüência de vídeo codificado se caracteriza pela presença de LRD e uma alta variabilidade proveniente dos algoritmos de compressão e codificação, da própria dinâmica da cena, bem como da aleatoriedade do tempo de duração das cenas. Desse modo, para exemplificar o uso do PMFGN, utilizamos a seqüência dino, estudada em [Rose, 1995] e disponibilizada pelo autor<sup>3</sup>, que corresponde a cerca de meia hora de codificação em MPEG-1 do filme Jurassic Park. As estatísticas da seqüência dino ratificam a existência de alta variabilidade e LRD, exibindo uma média de 13.078 bits por quadro de imagem, um coeficiente de variação de 1,13 e um parâmetro de Hurst de 0,88.




Figura 5: Seqüência dino com 7 *clusters* definidas pelo algoritmo  $k^+$ Means.

Aplicando o algoritmo  $k^+$ Means à seqüência dino obtivemos os resultados mostrados na tabela 2. Esses resultados demonstram a possibilidade de *clustering* da seqüência dino em 7 *clusters* com coeficientes de variação menores que 0,2. Apresen-

<sup>3</sup>Em [ftp-info3.informatik.uni-wuerzburg.de/pub/MPEG](http://ftp-info3.informatik.uni-wuerzburg.de/pub/MPEG).



tamos uma ilustração gráfica da *clustering* efetuada pelo algoritmo  $k^+$ Means na figura 5.

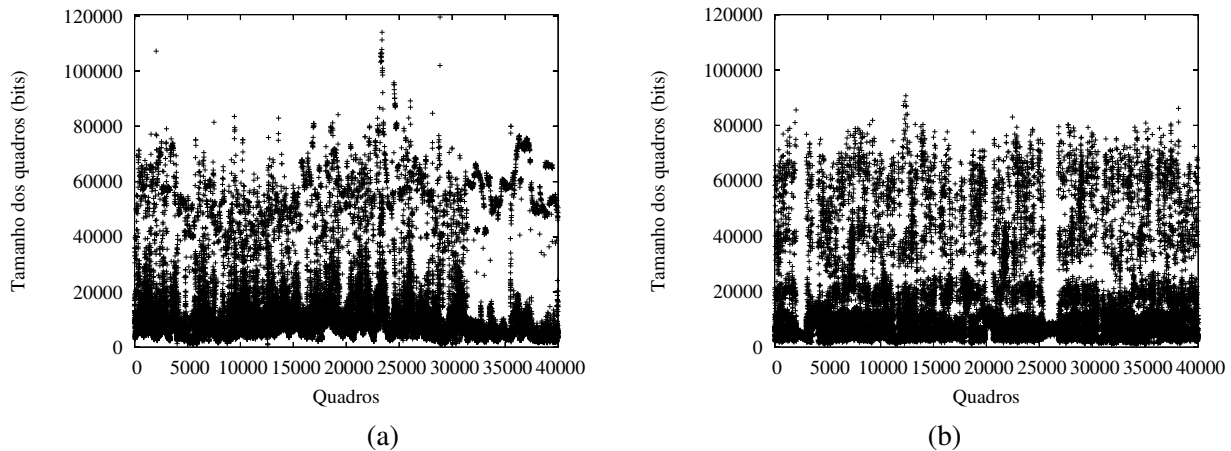
Utilizando a equação 1 para a seqüência dino com 7 *clusters* e estatísticas apresentadas na tabela 2, obtemos a seguinte matriz de probabilidades de transição:

$$P = \begin{bmatrix} 0,577 & 0,228 & 0,070 & 0,002 & 0,005 & 0,046 & 0,072 \\ 0,133 & 0,408 & 0,218 & 0,117 & 0,010 & 0,028 & 0,086 \\ 0,034 & 0,165 & 0,380 & 0,212 & 0,097 & 0,036 & 0,075 \\ 0,003 & 0,099 & 0,254 & 0,315 & 0,205 & 0,059 & 0,065 \\ 0,006 & 0,024 & 0,235 & 0,425 & 0,181 & 0,079 & 0,050 \\ 0,118 & 0,137 & 0,226 & 0,290 & 0,184 & 0,031 & 0,013 \\ 0,123 & 0,260 & 0,302 & 0,227 & 0,075 & 0,010 & 0,003 \end{bmatrix}. \quad (5)$$

A tabela 3 mostra os resultados obtidos com a seqüência dino para o número de quadros e o tempo médio de permanência em cada estado com o uso das equações 2 e 3, respectivamente.

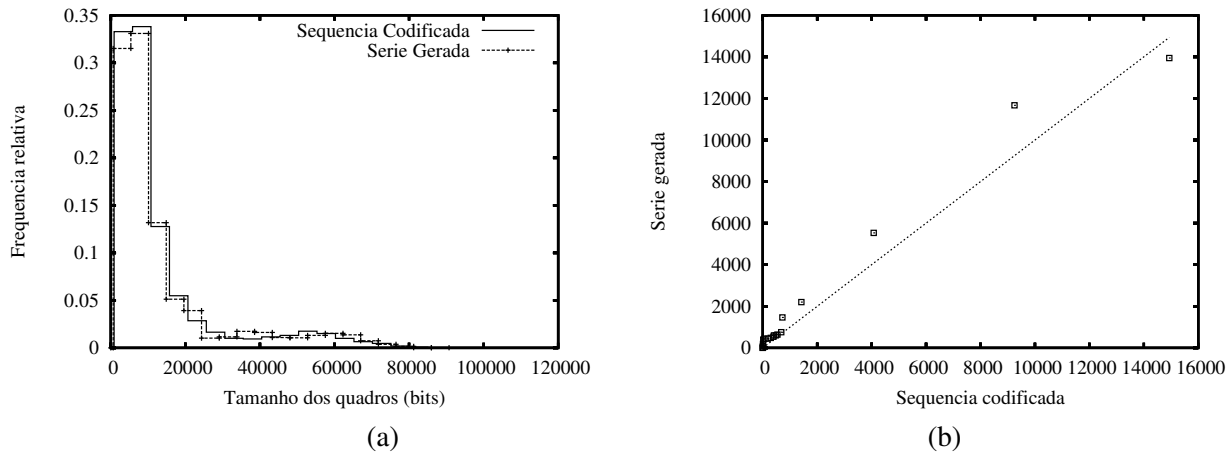
**Tabela 3: Permanência média nos estados para a seqüência dino em 7 *clusters* em uma taxa de 24 quadros por segundo.**

PERMANÊNCIA MÉDIA	ESTADOS						
	1	2	3	4	5	6	7
Quadros ( $Nq_i$ )	2,36	1,69	1,61	1,46	1,22	1,03	1,00
Tempo em ms ( $T_i$ )	98,33	70,42	67,08	60,83	50,83	42,92	41,67



**Figura 6: Comparação dos pontos da seqüência dino em (a) com sua geração em 7 estados através da modulação do FGN por Pareto em (b).**

A série gerada pelo PMGN a partir da seqüência dino, assumindo o FGN na geração das séries com as estatísticas exibidas na tabela 2, apresentou uma média de 13.542 bits por quadros, um coeficiente de variação de 1,12 e um parâmetro de Hurst de 0,72. A alta variabilidade e o efeito LRD pôde, então, ser capturado pelo PMFGN. Na figura 6, mostramos uma comparação do traço da seqüência dino com o traço da série gerada pelo PMFGN.



**Figura 7: Histogramas em (a) e gráfico quantis-quantis em (b) para a seqüência dino e sua geração em 7 estados através da modulação do FGN por Pareto.**

Visando ressaltar a equivalência estatística da seqüência dino com a série que geramos com 7 estados através da modulação do FGN por Pareto, exibimos, na figura 7 (a), a sobreposição dos histogramas da seqüência dino com o da série gerada e na figura 7 (b), o gráfico quantis-quantis da seqüência dino *versus* a série gerada. Os resultados obtidos demonstram a equivalência estatística entre as séries.


#### 4. Análise de uma Fila PMFGN/D/1/k

A análise de uma fila PMFGN/D/1/k foi efetuada através da implementação, via simulação, de um multiplexador estatístico. A entrada do multiplexador deve corresponder a arquivos com séries representativas de tráfego. Como saída e medida de QoS, utilizamos a taxa de perda de bits.

Para o caso de fontes de vídeo, como a seqüência dino, as taxas de transmissão são determinadas pelo padrão utilizado e possuem valores expressos em quadros por segundo. Contudo, estamos interessados em medidas de desempenho expressas em unidades de bits. Assim, consideramos as chegadas em dois níveis: o nível de quadros e o de bits. No nível de quadros a taxa é determinada pelo padrão utilizado e no nível de bits a taxa é dada pela quantidade de bits, extraída da seqüência e transmitidos no tempo de quadro.

A capacidade do canal (servidor da fila), dada em bits por segundo (bps), determina a taxa de saída do multiplexador, regulando o tempo de atendimento no servidor do sistema de fila. Os bits são enfileirados ao encontrar o servidor ocupado. Caso a fila tenha chegado ao seu limite de tamanho, o sistema registra uma perda. A taxa de perdas é, portanto, dada pela relação entre a quantidade de bits perdidos e a quantidade total de bits que entraram no sistema. O término da simulação ocorre após a entrada e saída de todos os bits da seqüência completa ou da seqüência computada até um número de quadros especificado.

Na figura 8 (a), ilustramos as curvas da taxa de perdas em função do comprimento da fila tanto para a seqüência dino como para a série gerada, considerando um canal com uma capacidade disponível  $W_d = 500$  kbps. Em outra instância, apresentamos na figura 8 (b), o gráfico da taxa de perdas em função da capacidade do canal para os dois casos



**Figura 8: Taxa de perda de bits para seqüência dino, sua geração através do FGN e do PMFGN: em (a) função do comprimento da fila em um canal com 500 kbps de capacidade disponível e em (b) em função da capacidade do canal com 256 Mb de comprimento da fila.**

em questão, admitindo uma fila de comprimento  $k = 256$  Mb.

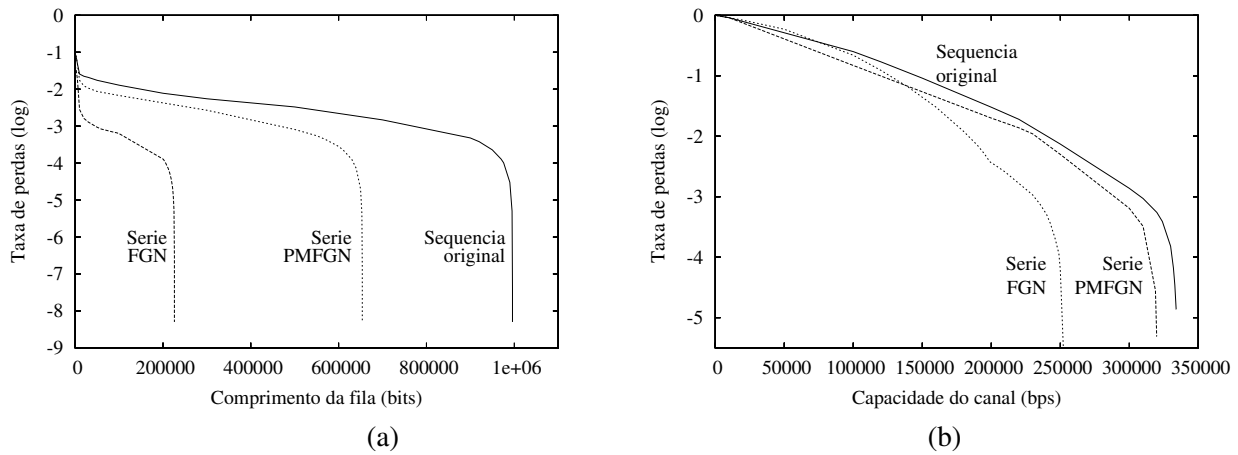
Pela figura 8(a), podemos ver que a série gerada, quando comparada com a original (seqüência dino), apresenta taxa de perdas ligeiramente maiores para filas pequenas e taxa de perdas menores para filas longas. Esse resultado coaduna com a interpretação dada em [Chen et al., 1995, Chien et al., 2003] para o efeito causado pelo parâmetro de Hurst na probabilidade de perda de células em relação ao tamanho da fila. Os autores observaram que o tamanho médio da fila aumenta com o aumento do parâmetro de Hurst. Em nosso caso, se por um lado a série gerada apresenta uma taxa média um pouco maior que a seqüência dino, por outro lado seu parâmetro de Hurst é menor. Assim, na região de fila pequena predomina o efeito da taxa média, enquanto que na região de fila longa predomina o efeito do parâmetro de Hurst.

Observando a figura 8(b), verificamos que os resultados alcançados pela série gerada foram, de modo geral, próximos ao da seqüência codificada. O fato da série gerada possuir uma taxa média um pouco maior que a seqüência codificada foi um pouco mais significativo nas regiões de baixas perdas, mas os resultados pode ser considerados satisfatórios.

Com o intuito de avaliar a influência da codificação nos resultados que apresentamos, utilizamos a seqüência jurassic<sup>4</sup>, que corresponde ao filme Jurassic Park codificado no padrão H.263 em taxa variável de bits, como entrada do multiplexador.

Na Figura 9(a), exibimos os resultados obtidos, considerando um canal com capacidade  $W_d = 256$  kbps. Podemos observar na figura que os resultados alcançados pelo PMFGM foram melhores que os obtidos pelo FGN. Todavia, comparando com a série original, notamos que os resultados do PMFGN são mais próximos nas regiões de fila pequenas. Constatamos que a diferença entre a taxa de perdas resultante da série gerada e da seqüência original é diretamente afetada pelo aumento do comprimento da fila.

<sup>4</sup>Geradas e disponibilizadas pelo Grupo de Redes e Telecomunicações da Universidade Técnica de Berlin em [www-tkn.ee.tu-berlin.de/research/trace/trace.html](http://www-tkn.ee.tu-berlin.de/research/trace/trace.html).



**Figura 9: Taxa de perda de bits para seqüência jurassic, sua geração através do do FGN e do PMFGN: em (a) função do comprimento da fila em um canal com 256 kbps de capacidade disponível e em (b) em função da capacidade do canal com 256 kb de comprimento da fila.**

Analisando a taxa de perda de bits para a seqüência jurassic e para a série gerada pelo PMFGN em função da capacidade do canal, podemos observar a Figura 9(b). Para uma fila de tamanho  $k = 256$  kbps, a figura mostra que a série gerada pelo PMFGN apresenta valores próximos, mas um pouco abaixo, aos da seqüência original em toda a faixa considerada de capacidades. Porém, os resultados alcançados com PFGN são sempre mais próximo da seqüência original que os obtidos com o FGN. Desse modo, o PMFGN demonstrou ser um modelo mais apropriado que o FGN para o estudo de dimensionamento de recursos de rede.

A série gerada para a seqüência jurassic apresenta taxa média e parâmetro de Hurst menores que a seqüência original. Para a seqüência original temos  $B_m = 545.040$  bps e  $H = 0,98$ , enquanto que para a série gerada temos  $B_m = 500.820$  bps e  $H = 0,89$ . Desse modo, obtemos perdas menores com a série gerada tanto nas situações com filas pequenas, como com filas longas, tal qual mostramos na Figura 9(a), e em toda a faixa de capacidade exibida na Figura 9(b).

## 5. Conclusão

Os resultados obtidos nas seções 3 e 4 demonstram a capacidade que o PMFGN possui em capturar as estatísticas de uma dada série temporal. A componente LRD pôde ser obtida com o uso da distribuição de Pareto na definição do tempo de permanência em cada estado. O algoritmo  $k^+$ Means mostrou ser eficaz na *clustering* das seqüências, determinando *clusters* com variações suficientemente pequenas para geração de séries características através do FGN, sem a ocorrência de valores negativos. Desse modo, a análise estatística dos resultados obtidos com as séries resultantes da modulação do FGN por Pareto ratificaram a adequação de nossa abordagem.

Os histogramas e gráficos quantis-quantis mostrados na seção 3 demonstraram a equivalência estatística entre a série codificada e a gerada pelo PMFGN. A análise de uma fila PMFGN/D/1/k demonstrou que o PMFGN produz resultados mais próximos dos obtidos com a seqüência codificada que o FGN. Todavia, pudemos observar, na seção

4, que podem ocorrer diferenças nos valores estimados de perdas e recursos alocados. Contudo, pudemos verificar, também, que as divergências podem ser previstas. Constatamos que enquanto as diferenças entre as estatísticas de primeira ordem afetam mais em situações de filas pequenas, as diferenças entre as estatísticas de segunda ordem, ou mais especificamente o parâmetro de Hurst, produzem um impacto maior em situações de filas grandes. Desse modo, é possível aferir se o resultado obtido com nossa abordagem está sendo superestimado ou subestimado. Resultados adicionais, apresentados em [de Britto Salgueiro, 2004], corroboram os aqui apresentados.

O Ruído Gaussiano Modulado por Pareto pode ser utilizado, portanto, como uma ferramenta eficiente para a geração do tráfego LRD de alta variabilidade e em estudos envolvendo alocação de recursos em redes, elaboração de regras para dimensionamento de *buffers* nos comutadores das redes, previsões de degradação de QoS causadas por congestionamento e de mecanismos de controle de congestionamento.

## Referências

- Alexander, R., Brownlee, N., and Ziedins, I. (1995). Modelling Self-similar Network Traffic. Technical Report 92019, University of Auckland, New Zeland.
- Ball, G. H. and Hall, D. J. (1965). ISODATA, a movel method of data analysis and classification. Technical report, Stanford University, Stanford, CA.
- Beran, J. (1994). *Statistic for Long-Memory Processes*. Chapman & Hall.
- Brichet, F., Roberts, J., Simonian, A., and Veitch, D. (1996). Heavy Traffic Analysis of a Storage Model with Long Range Dependent On/Off Sources. *Queueing Systems*, 23:197–215.
- Chen, Y., Deng, Z., and Williamson, C. (1995). A Model for Self-Similar Ethernet Lan Traffic: Design, Implementations, and Performance Implications. In *Proceedings of the 1995 Summer Computer Simulation Conference (SCSC'95)*, pages 831–837, Ottawa, Ontario.
- Chien, S. F., Tan, C. P., Low, A. L. Y., You, A. H., and Takahashi, K. (2003). Buffering controls for IP packets in optical packet switching. In *APCC 2003 - The 9th Asia-Pacific Conference on Communications*, volume 2, pages 473 – 476.
- Crovella, M. E. and Bestavos, A. (1996). Self-Similarity in World Wide Web Traffic Evidence and Possible Causes. In *Proceedings of ACM Sigmetrics*, pages 160–169.
- Crovella, M. E. and Bestavos, A. (1995). Explaining World Wide Web Traffic Self-Similarity. Technical Report TR-95-015, Computer Science Department, Boston University, 111 Cummington St, Boston, MA 02215.
- Crovella, M. E., Taquq, M. S., and Bestavos, A. (1998). *Heavy-Tailed Probability Distributions in the World Wide Web*, chapter 1, pages 3–26. Chapman and Hall, New York.
- de Britto Salgueiro, R. J. P. (2004). *Uma Metodologia para Caracterização de Tráfego de Vídeo Baseada nos Momentos de Primeira e Segunda Ordem*. PhD thesis, Universidade Federal de Pernambuco - Centro de Informática, Recife.
- de Britto Salgueiro, R. J. P., da Silva, E. M., and Monteiro, J. A. S. (2005). Um modelo fracionário modulado por pareto para tráfego com alta variabilidade e dependência de

- longo alcance. In *Anais do 23<sup>o</sup> Simpósio Brasileiro de Redes de Computadores*, pages 1123–1126, Fortaleza-CE.
- Fitzek, F. and Reisslein, M. (2001). MPEG-4 and H.263 Video Traces for Network Performance Evaluation. *IEEE Network*, pages 40–49.
- Garrett, M. W. (1993). *Contributions Toward Real-Time Services on Packet Switched Networks*. PhD thesis, Graduate School of Arts and Sciences - Columbia University.
- Garrett, M. W. and Willinger, W. (1994). Analysis, Modeling and Generations of Self-Similar VBR Video Traffic. In *Proc. of SIGCOMM'94*, pages 269–280, London, UK. University College London.
- Hurst, H. E. (1951). Long-Term Storage Capacity of Reservoirs. *Trans. Amer. Soc. Civil Eng.*, 116:770–799.
- Hurst, H. E. (1956). Methods of Using Long-Term Storage in Reservoirs. *Trans. Amer. Soc. Civil Eng.*, (6059):519–543.
- Jain, A. K., Murty, M. N., and Flynn, P. J. (1999). Data clustering: a review. *ACM Computing Surveys*, 31(3):264–323.
- Lau, W.-C., Erramilli, A., Wang, J. L., and Willinger, W. (1995). Self-Similar Traffic Generation: The Random Midpoint Displacement Algorithm and Its Properties. In *Proc. IEEE ICC'95*, seattle, WA.
- Leland, W. E., Taqqu, M. S., Willinger, W., and Wilson, D. V. (1994). On the Self-Similar Nature of Ethernet Traffic (Extended Version). *IEEE/ACM Transactions on Networking*, 2(1):1–15.
- Leland, W. E. and Wilson, D. V. (1991). High Time-Resolution Measurement and Analysis of LAN Traffic: Implications for LAN Interconnection. In *Proceedings IEEE INFOCOM'91*, pages 1360–1366.
- MacDougall, M. H. (1987). *Simulating computer systems techniques and tools*. Computer Systems Series, The MIT Press.
- Menasce, D. A., Almeida, V. A. F., and Dowdy, L. W. (1994). *Capacity Planing and Performance Modeling*. Prentice-Hall, Inc.
- Paxson, V. (1995). Fast Approximation of Self-Similar Network Traffic. Technical report, Lawrence Berkeley Laboratory and EECS Division, University of California, Berkeley.
- Perlingeiro, F. R. and Ling, L. L. (1999). Data Characterization in Corporate Environment. In *Global Telecommunications Conference - Globecom '99*, pages 1173–1178.
- Rose, O. (1995). Statistical Properties of MPEG Video Traffic and their impact on Traffic Modeling in ATM Systems. Technical Report 101, Institute of Computer Science, University of Wurzburg, Am Hubland, 97074 Wurzburg, Germany.
- Taqqu, M., Willinger, W., and Sherman, R. (1997). Proof of a Fundamental Result in Self-Similar Traffic Modeling. *Computer Communications Review*, 27(2):5–23.
- Willinger, W., Paxson, V., Riedi, R. H., and Taqqu, M. S. (2004). Long-Range Dependence and Data Network Traffic. In Doukhan, P., Oppenheim, G., and Taqqu, M. S., editors, *Theory and Applications of Long-Range Dependence*, pages 373–407. Birkäuser, Boston.

- Xiaohu, G., Guangxi, Z., and Yaoting, Z. (2003). A new model for network traffic based on alpha-stable self-similar processes. In *The 11th IEEE International Conference on Networks, 2003. ICON2003*, pages 1 – 5.
- Yao, L., Agapie, M., Ganbar, J., and Doroslovacki, M. (2003). Long range dependence in Internet backbone traffic. In *IEEE International Conference on Communications, 2003. ICC '03*, volume 3, pages 1611 – 1615.