

PREDIÇÃO DO TRÁFEGO ATM UTILIZANDO WAVELETS E FILTROS DE WIENER

M. J. P. DANTAS

R.P. LEMOS

Univ. Católica de Goiás - Dep. Matemática e Física
Av. Universitária 1069, Setor Universitário
74605-010 Goiânia, Goiás, Brasil

Univ. Federal de Goiás - Escola de Eng^a Elétrica
Praça Universitária S/N
74605-220 Goiânia, Goiás, Brasil

RESUMO

Neste trabalho modela-se o processo de incrementos do tráfego ATM como ruído gaussiano fracionário com parâmetro de Hurst H . O parâmetro H é estimado diretamente a partir das medições de tráfego através de análise de *wavelets*. Obtido H , determina-se a autocorrelação do modelo e projetam-se filtros de Wiener para a predição do tráfego ATM. O preditor é avaliado utilizando dados das medições da *Bellcore* para tráfego Ethernet, convertidos para a equivalente representação de células ATM.

1. INTRODUÇÃO

Tem-se atualmente uma boa aceitação da modelagem fractal para caracterizar o tráfego agregado em redes ATM. Muitas pesquisas demonstraram a presença de auto-similaridade e longa dependência em tráfego VBR de vídeo, Ethernet, e outros que contribuem nessas redes [1][2][3]. Demonstraram ainda que a agregação de tráfego de natureza fractal até intensifica este comportamento [4].

A auto-similaridade do tráfego impacta no funcionamento da rede, diretamente sobre a multiplexagem estatística, que não consegue absorver variações de tráfego que apresentam comportamento de persistência temporal. Isto significa que, se o tráfego estiver crescendo, existe uma grande probabilidade de que isto continue ocorrendo por um período de tempo suficiente para ocasionar atrasos e perda de células, até o congestionamento da rede. Sendo assim, devem-se fornecer, para os mecanismos de controle, parâmetros identificados com a natureza fractal do tráfego, no sentido de ajustar o funcionamento da multiplexagem estatística. Este trabalho propõe a predição do tráfego segundo modelos fractais como uma das maneiras de se fornecer esses parâmetros.

2. MODELOS DE TRÁFEGO ATM

Processos auto-similares têm sido utilizados para modelar o comportamento fractal do tráfego[3][9]. Isto se deve ao fato de que os processos de incrementos desses modelos são estacionários de longa dependência, propriedades que tem sido verificadas no processo de incrementos do tráfego[1][2][3]. Esses processos são denominados processos estocásticos $1/f$ e constituem uma importante classe de modelos para diferentes aplicações em processamento de sinais, tendo sido apontada recentemente para aplicações em tráfego de redes[7][9]. Dois modelos têm se destacado na literatura: o movimento browniano

fracionário (fBm) e o ruído gaussiano fracionário (fGn). Em princípio, utiliza-se o fGn por ser ele o único processo auto-similar gaussiano, o que favorece a tratabilidade matemática no desenvolvimento de aplicações.

O movimento browniano fracionário (fBm), proposto por Mandelbrot e Van Ness, apresenta as importantes características de possuir variações não-estacionárias e ser auto-similar, podendo ser definido nos seguintes termos[5][10].

Definição fBm: O movimento Browniano fracionário (fBm), discreto com parâmetro H , $0 < H < 1$ é um processo estocástico não-estacionário, $B_H[n]$, $n \in \mathbb{Z}$, do tipo gaussiano e H -sssi, tal que $B_H[0] = 0$ e seus incrementos são estacionários com distribuição normal de dimensão finita.

No sentido de formar a base matemática desse trabalho, é importante destacar as seguintes propriedades estatísticas do fBm:

- Sua função de autocorrelação, dada por:

$$R[n, k] = E\{B_H[n]B_H[k]\} = \frac{\sigma^2}{2} \left[|n|^{2H} + |k|^{2H} - |n-k|^{2H} \right] \quad (1)$$

reflete a não-estacionariedade do processo, pois é variante com deslocamento temporal.

- Sua variância é enunciada como:

$$Var\{B_H[n]\} = \sigma^2 |n|^{2H} \quad (2)$$

- Sua densidade espectral de potência é dada empiricamente por:

$$S_{BH}(\omega) = \sigma^2 / |\omega|^{2H+1} \quad (3)$$

A interpretação da densidade espectral de potência como um espectro generalizado demonstra a auto-similaridade, ou seja:

$$B_H[n] = a^{-H} B_H[an-b], \quad a > 0 \text{ e } \forall b \quad (4)$$

O processo dos incrementos do movimento browniano fracionário é chamado de ruído gaussiano fracionário (fGn) e apresenta dependência de longo prazo e variância de decaimento lento (alta variabilidade), quando $1/2 < H < 1$, sendo definido como:

Definição fGn: $X[n]$, $n \in \mathbb{Z}_+$ é ruído gaussiano fracionário com parâmetro H se corresponde ao processo de incrementos de um movimento browniano fracionário (fBm) com parâmetro H , sendo dado por:

$$X[n] = B_H[n] - B_H[n-1] \quad (5)$$

Avaliando as propriedades estatísticas do fGn pode-se verificar que sua função de autocorrelação é dada por:

$$R_x(k) = \frac{V_H}{2} \left(|k-1|^{2H} + |k+1|^{2H} - 2|k|^{2H} \right) \quad (6)$$

para

$$V_H = \Gamma(1-2H) \frac{\cos \pi H}{\pi H} \quad (7)$$

3. PREDIÇÃO DO TRÁFEGO ATM

Inicialmente, é importante esclarecer que, dada a indisponibilidade de dados de tráfego de uma rede ATM em pleno funcionamento, efetuou-se a conversão de arquivos de medições de tráfego ethernet da *Bellcore*, agregando-se os pacotes a intervalos regulares de tempo e dividindo o total de bytes pelo equivalente a uma célula ATM. Acredita-se que esse procedimento não prejudica a análise, uma vez que as propriedades fractais do tráfego ethernet também foram observadas em outros tipos de tráfego que também contribuem para a agregação do tráfego em uma rede ATM[1][2][3].

Neste trabalho propõe-se que o processo de incrementos do tráfego ATM seja modelado como ruído gaussiano fracionário com parâmetro de Hurst H . A partir da autocorrelação do modelo, dada por (6), projetam-se filtros de Wiener para a predição do tráfego ATM.

O ajuste do modelo fGn ao tráfego de incrementos exige a estimação do parâmetro H para o tráfego medido. Para obter esta estimativa, decompõe-se o processo de incrementos $\{X[n]\}$ em diversas escalas através de análise de *wavelets*. Em cada escala calcula-se a variância dos coeficientes *wavelet*, no sentido de formar um gráfico variância \times escala. Em seguida, obtém-se uma estimativa do parâmetro H através da aplicação de regressão linear sobre o gráfico [6], conforme figura 1. A partir das funções de autocorrelação $R_x[k]$ do modelo fGn para o parâmetro H estimado, projeta-se um filtro de Wiener de ordem M . A predição é então efetuada recursivamente de forma a se obter os valores seguintes da seqüência $\{X[n]\}$, conforme descrito na Figura 2.

Como o processo de incrementos é estacionário, as saídas do filtro de Wiener são estimativas ótimas no sentido dos mínimos quadrados dos incrementos de tráfego:

$$\hat{X}[n+k | n] = \sum_{m=1}^M h^o[m] X[n-m] \quad (8)$$


Os coeficientes ótimos do preditor são calculados a partir de:

$$\mathbf{h}^o = \mathbf{R}_{xx}^{-1} \mathbf{r}_{xx} \quad (9)$$

onde

$$\mathbf{r}_{xx} = [R_x(k), R_x(k+1), R_x(k+2), \dots, R_x(k+M)]^T \quad (10)$$

e



$$\hat{H} = \frac{(\alpha + 1)}{2}$$

Figura 1: Estimação de H por regressão linear sobre as variâncias

$$\mathbf{R}_{xx} = \begin{bmatrix} R_x(0) & R_x(1) & \dots & R_x(M-1) \\ R_x(1) & R_x(0) & \dots & R_x(M) \\ \vdots & \vdots & \ddots & \vdots \\ R_x(M-1) & R_x(M) & \dots & R_x(0) \end{bmatrix} \quad (11)$$

onde $R_x(\cdot)$ é a função de autocorrelação do modelo fGn calculada a partir de (6) e (7).

O erro quadrático médio normalizado teórico e_T da predição é dado por:

$$e_T = 1 - \frac{\mathbf{h}^{oT} \mathbf{r}_{xx}}{V_H} \quad (12)$$

enquanto que o erro quadrático normalizado simulado e_S da predição é descrito por:

$$e_S = \frac{1}{N\sigma^2} \sum_{i=1}^N (X[i] - \hat{X}[i])^2 \quad (13)$$

A estimativa do valor de H só depende das variâncias nas escalas da decomposição *wavelet*. Para implementá-la em tempo real, percebendo-se alteração significativa no valor de H , recalcula-se o filtro de Wiener, e continua-se o processo de predição.




Figura 2: Algoritmo de predição dos incrementos de tráfego, utilizando filtro de Wiener, projetado com base no modelo fGn.

4. RESULTADOS OBTIDOS

Para se avaliar separadamente a qualidade da predição e a adequação do fGn aos incrementos de tráfego, efetuou-se a predição de uma série sintética fGn, gerada pelo método *Random Midpoint Displacement* para $H = 0,8$, e da série Bc-aug (escala = 1 s), convertida das medições da *Bellcore*. Estimou-se o parâmetro H através da análise de *wavelets* e o valor encontrado para a série Bc-aug foi de 0,8107.

Pode-se observar na Figura 3 a comparação das curvas preditas com as desejadas, para o fGn e para o arquivo Bc-aug. Os resultados dos experimentos estão resumidos nas Tabelas 1(a) e 1(b). Os preditores são avaliados com ordem $M = 6$ e $M = 100$ para predição a 1 passo e a 5-passos.

Para ordem $M = 6$, para o fGn ($H = 0,8$) a 1 passo a frente, o erro teórico foi de 0,7031 e o simulado de 0,7899. Com 5 passos a frente, o erro teórico foi de 0,8982 e o simulado de 0,9430. Em [7] a predição de um fGn ($H = 0,8$), para ordem $M = 6$, com 5 passos a frente, resultou em um erro teórico de 0,8982 e simulado de 0,9305, também aqui obtido.

A predição da série Bc-aug ($\hat{H} = 0,8107$), para ordem $M = 6$ a 1 passo a frente, resultou no erro teórico de 0,6782 e no simulado de 0,8621. A predição com 5 passos a frente, para a mesma ordem, resultou no erro teórico de 0,8828 e no simulado de 1,5947.

Repetindo o experimento para o fGn, com ordem $M = 100$, obteve-se o erro teórico de 0,8743 e o simulado de 0,9297. Para a série Bc-aug a 5 passos a frente, para $M = 100$, obteve-se o erro teórico de 0,8568 e o simulado de 0,9622.

Embora o processo de incrementos Bc-aug apresente praticamente o mesmo H do fGn, ele difere de um processo gaussiano (ver Figura 4). Isto justifica os erros simulados serem maiores que os teóricos. Logo, o modelo não se ajusta perfeitamente aos dados, mas um modelo fractal mais justo pode ser mais difícil de tratar.

Para melhorar a predição, realizou-se uma espécie de “normalização” nos coeficientes ótimos do filtro, fazendo-se:

$$\mathbf{h}^c = \frac{\mathbf{h}^o}{\sum_m h^o[m]} \quad (14)$$

o que reduziu bastante os erros de simulação. A motivação foi o sinal predito acompanhar o sinal original, mas com amplitude menor. Então, ajustou-se a amplitude, mantendo-se a proporcionalidade entre os coeficientes do filtro, cuja soma passou a ser 1.

A Figura 5 apresenta a melhoria na predição com o ajuste nos coeficientes ótimos. O erro obtido para a predição de Bc-aug caiu de 0,8621 em (3.b) para 0,6736, bem mais próximo do erro teórico 0,6782.

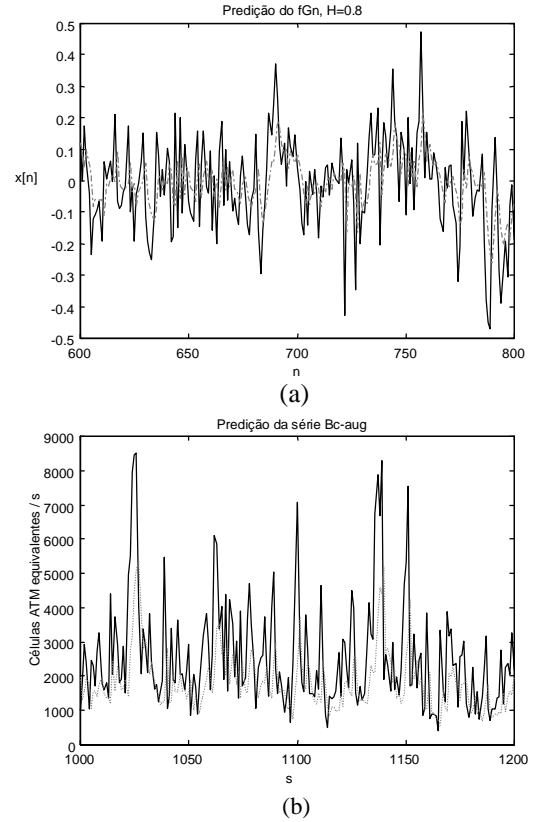


Figura 3: (a) Série fGn (linha cheia) e predição (linha tracejada), Wiener de ordem $M = 6$; (b) série Bc-aug (linha cheia) e predição (linha tracejada), Wiener de ordem $M=6$.

Ordem do filtro	Série fGn $H = 0,80$	Série Bc-aug $\hat{H} = 0,8107$
1 passo		
M=6	$e_T = 0,7031$ $e_S = 0,7899$	$e_T = 0,6782$ $e_S = 0,8621$
M=100	$e_T = 0,6939$ $e_S = 0,7824$	$e_T = 0,6687$ $e_S = 0,6537$

(a)

Ordem do filtro	Série fGn $H = 0,80$	Série Bc-aug $\hat{H} = 0,8107$
5 passos		
M=6	$e_T = 0,8982$ $e_S = 0,9430$	$e_T = 0,8828$ $e_S = 1,5947$
M=100	$e_T = 0,8743$ $e_S = 0,9297$	$e_T = 0,8568$ $e_S = 0,9622$

(b)

Tabela 1: Comparação dos erros de predição do fGn e de Bc-aug: (a) Wiener de ordem $M = 6$ e $M = 100$ a 1 passo; (b) Wiener $M = 6$ e $M = 100$ a 5 passos.




Figura 4: (a) histograma de uma série fGn ($H=0,8$) 4096 pontos e (b) da série Bc-aug(s) ($\hat{H} = 0,8107$) 3142 pontos.




Figura 5: Predição de Bc-aug com ajuste dos coeficientes ótimos. Linha cheia (Bc-aug), linha tracejada (série predita).

Após o ajuste, o aumento de $M = 6$ para $M = 100$, implicou em redução insignificante do erro (ver Figura 6). Isto foi também observado em [7] para processos discretos no tempo e em [9] para processos LRD contínuos no tempo, onde Norros concluiu que “se deve prever o próximo segundo com base no último segundo, o próximo minuto com base no último minuto, etc”.

Na Figura 7, para a série Bc-octint, escala de 1 s ($\hat{H} = 0,8042$), obteve-se o erro teórico 0,6934, o simulado de 0,9140 antes do ajuste (a) e 0,3835 após (b). Em [10], utilizou-se LMS, obtendo-se um erro de 0,93368, $M=5$, para a mesma série.

5. CONCLUSÕES

O ajuste do modelo fGn aos incrementos de tráfego não é perfeito, mas um modelo mais justo pode ser de mais difícil tratamento. A divisão dos coeficientes ótimos do filtro de Wiener por sua soma resulta em redução do erro simulado, aproximando-o muito do limite teórico, o que valida o método aqui proposto.




Figura 6: Erro \times ordem do filtro. Série Bc-aug(s), 3142 pontos: acima sem correção, abaixo com correção.


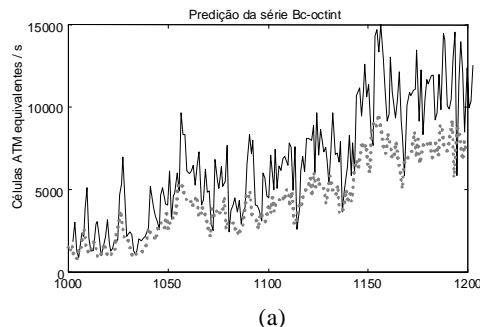


Figura 7: Comparação entre a predição de Bc-octint: (a) sem ajuste dos coeficientes ótimos, (b) com ajuste. Linha cheia (Bc-octint), linha tracejada (série predita).

6. REFERÊNCIAS

- [1] Leland, W., Taqqu, W. and Wilson, D., “On the self-similar nature of ethernet traffic”. *IEEE/ACM Transactions on Networking*, 2(1): 1-15, 1994.
- [2] Beran, J., Sherman, R., Taqqu, M. and Wilinger, W., “Long range-dependence in variable-bit-rate video traffic”. *IEEE Transactions on Communications*, 13(6): 400-410, 1995.
- [3] Vidács, A., “Self-Similar Traffic Modeling Techniques in ATM Networks”. *Master’s thesis*, Technical University of Budapest, 1996.
- [4] Patel, A. and Williamson, C., “Statistical multiplexing of self-similar traffic: theoretical and simulations results” 1997.
- [5] Wornell, G., *Signal Processing with fractals: A wavelets Based Approach*, Prentice Hall, New Jersey, 1996.
- [6] Abry, P. and Veitch, D., “Wavelets analysis of long-range dependent traffic”. *IEEE Transactions on Information Theory*, : 2-15, 1998.
- [7] Hirchoren, G. and Arantes, D.S., “Predictors for the discrete-time fractional Gaussian process”. *IEEE Transactions on Signal Processing*, : 49-53, 1998.
- [8] Haykin, S., *Modern Filters*. Macmillan Publishing Company, New York, 1989.
- [9] Norros, I., “On the prediction of fractional Brownian motion”. *Journal of Applied Probability*, 33: 400-410, 1996.
- [10] Carvalho, M.M., “Predição de Tráfego Auto-Similar em Redes de Faixa Larga”, *Dissertação de mestrado*, Unicamp, 1998.