

Esquema de Escalonamento de Fluxos de Dados Baseado nas Singularidades Locais do Tráfego Internet

Flávio Henrique Teles Vieira, Christian Jorge, & Lee Luan Ling

Abstract—The modern network traffic is composed of complex flows that present different statistical characteristics and quality of service requirements. This integration of flows motivates the introduction of new traffic congestion control and management schemes. In this work, we propose a new traffic flow scheduling scheme that incorporates the local singularity data of traffic processes. For this end, we initially verify the application of an algorithm that is based on the decay of wavelet coefficients in time windows to estimate the pointwise Hölder exponents. These exponents quantify the degree of traffic singularities. Next, we develop an adaptive prediction algorithm for the pointwise Hölder exponents of a traffic process. The simulations confirm that the proposed scheduling scheme provides lower data loss rate as well as higher link utilization than the GPS (Generalized Processor Sharing) scheme greatly used in network traffic routers.

Index Terms— Network Traffic, Scheduling, Prediction, Multifractals, Hölder Exponent.

Resumo—A integração de vários tipos de serviços nas redes de comunicações atuais traz consigo a necessidade de se introduzir novos esquemas de gerenciamento e controle de tráfego. Em alguns casos, os esquemas atuais podem ter sua eficiência reduzida devido ao comportamento repleto de diferentes singularidades locais dos fluxos de tráfego. Propomos neste artigo um esquema de escalonamento de fluxos de dados que utiliza informações da regularidade local de tráfego representada pelo expoente de Hölder pontual. Para tal, inicialmente verificamos a aplicação de um algoritmo de estimação dos expoentes de Hölder baseado no decaimento dos coeficientes wavelets em janelas de tempo. Em seguida, desenvolvemos um algoritmo adaptativo de predição dos expoentes de Hölder. Esse algoritmo de predição é incorporado na estratégia proposta de escalonamento de fluxos. As avaliações e simulações realizadas mostram que o esquema de escalonamento proposto provê uma menor perda de dados e uma utilização do enlace maior em comparação ao esquema de escalonamento GPS (Generalized Processor Sharing) convencional, implementado em muitos roteadores.

Palavras chave—Tráfego de Redes, Escalonamento, Predição, Multifractais, Expoente de Hölder.

Manuscrito recebido em 11 de Junho de 2007; revisado em 14 de Novembro de 2007.

F. H. T. Vieira (flavio@decom.fee.unicamp.br), C. Jorge (christian@fee.unicamp.br) e L. L. Ling (lee@decom.fee.unicamp.br) pertencem ao Departamento de Comunicações (DECOM) da FEEC (Faculdade de Engenharia Elétrica e de Computação) da UNICAMP. Av. Albert Einstein - 400 - 13083-852- Campinas - SP.

I. INTRODUÇÃO

Os serviços oferecidos pelas redes IP (Internet Protocol) atuais estão evoluindo do modelo de ‘melhor-esforço’ de transmissão da informação para um paradigma com várias classes de serviços, cada qual com seus requisitos de qualidade de serviço (QoS). Prover tais requisitos de qualidade de serviço usando a tecnologia IP é uma tarefa desafiadora para a engenharia de tráfego de redes.

Mecanismos preventivos são usados para alocar recursos com antecedência a fim de se evitar a ocorrência de congestionamentos. Nestes mecanismos, o algoritmo empregado de predição das características do tráfego desempenha um papel fundamental [2] [14]. Sabe-se que o desempenho de predição do tráfego depende de fatores tais como: quantidade de informações disponíveis do processo, a escala de tempo utilizada e o intervalo de predição. Um fator que tem grande influência no desempenho da predição é a própria natureza do tráfego [12] [14].

Na última década ocorreram mudanças significativas na compreensão do comportamento do tráfego de redes. Inicialmente houve a descoberta da propriedade de invariância à escala (*scaling*) do tráfego de pacotes [1]. Neste caso, modela-se o tráfego como um processo monofractal, cuja lei de escalas é determinada pelo parâmetro de Hurst. Entretanto em [6], verificou-se na verdade um comportamento multifractal do tráfego em escalas menores que algumas centenas de milissegundos. Esse comportamento se origina devido aos mecanismos do protocolo TCP/IP (Transmission Control Protocol) que fragmentam unidades de informação de uma camada de rede, em unidades menores na próxima camada [6].

Um processo multifractal é caracterizado por irregularidades (singularidades) locais mais acentuadas, com leis de escalas mais complexas do que se supunham os modelos monofractais. Neste contexto, costuma-se empregar o conceito de expoente de Hölder, oriundo da análise multifractal, para caracterizar a regularidade local do processo de tráfego, ou seja, o grau de rajadas presente nos dados [13].

A análise da regularidade local é importante para o gerenciamento e controle de congestionamento da rede por fornecer informações que podem tornar os esquemas de alocação de recursos mais eficientes. Com relação a isso, sabe-

se que um fluxo de tráfego de dados com alto grau de rajadas (grau alto de irregularidade) proporciona um menor aproveitamento dos recursos [1].

Assim sendo, este artigo contribui para o gerenciamento e controle preventivo do tráfego de redes através da proposta de uma nova disciplina de escalonamento de fluxos de dados em roteadores que leva em consideração as regularidades locais dos fluxos. Mostraremos que esta disciplina de escalonamento resulta em uma melhor distribuição da taxa de transmissão de um enlace para o escoamento dos fluxos presentes e uma menor perda de dados com relação à disciplina de escalonamento GPS (Generalized Processor Sharing).

O artigo está organizado da seguinte forma. Na seção II, caracterizamos a regularidade local de uma função utilizando a transformada wavelet. Na seção III, apresentamos um algoritmo para a estimação em janelas da regularidade local de fluxos de tráfego. A Seção IV é dedicada ao desenvolvimento de um novo algoritmo adaptativo de predição de séries temporais. Nesta mesma seção são analisados os erros de predição dos expoentes de Hölder. Na Seção V, propomos um esquema de escalonamento que incorpora a predição dos expoentes de Hölder pontuais como critério de alocação das taxas de transmissão de cada fluxo. Finalmente na Seção VI, apresentamos as conclusões obtidas.

II. CARACTERIZAÇÃO DA REGULARIDADE LOCAL

A. Análise Wavelet

A transformada wavelet pode caracterizar o comportamento local e em escala de um sinal (processo) através de uma representação do mesmo no espaço e no domínio da frequência. Conceitualmente, a transformada wavelet é um produto-convolução do sinal analisado com a wavelet-mãe ψ . Uma das ferramentas mais utilizadas da análise wavelet é o coeficiente wavelet. Os coeficientes wavelet $d_{j,k}$ são obtidos ajustando-se a wavelet-mãe ψ a uma determinada escala j e transladando-a até um ponto $2^j k$ do sinal, com $j, k \in \mathbb{Z}$, ou seja [4]

$$d_{j,k} = 2^{-j} \int_{-\infty}^{\infty} f(x) \psi(2^{-j} x - k) dx \quad (1)$$

com $j, k \in \mathbb{Z}$.

Pode-se dizer que com o aumento do valor de $d_{j,k}$ tem-se um aumento na variação do sinal no ponto $2^j k$ [6]. Esta propriedade é importante para a caracterização das singularidades de um sinal por meio do decaimento do valor absoluto dos coeficientes wavelet $d_{j,k}$ [9].

B. Expoente de Hölder Pontual

O expoente de Hölder pontual é capaz de descrever o grau de uma singularidade local, o que é interessante para a caracterização das rajadas de dados em redes de computadores. O expoente de Hölder pontual é definido da seguinte forma:

Definição 1 (Expoente de Hölder pontual): Seja α um número real estritamente positivo, K uma constante e $x_0 \in \mathbb{R}$.

A função $f : \mathbb{R} \rightarrow \mathbb{R}$ é $C^\alpha(x_0)$ se existir um polinômio P_n de grau $n < \alpha$ tal que

$$|f(x) - P_n(x - x_0)| \leq K |x - x_0|^\alpha \quad (2)$$

O expoente de Hölder pontual α_p da função f em x_0 é definido como

$$\alpha_p(x_0) = \sup\{\alpha > 0 \mid f \in C^\alpha(x_0)\} \quad (3)$$

Note que o polinômio P_n pode ser encontrado mesmo se o desenvolvimento da função f em série de Taylor ao redor de x_0 não existir.

C. Espectro Multifractal

O espectro multifractal (ou espectro de singularidades) provê informações sobre quais singularidades ocorrem em um dado processo e quais singularidades predominam.

Definição 2 (Espectro multifractal): Seja f uma função: $[a, b] \rightarrow \mathbb{R}$, $a < b$ e seja $\alpha(x)$ o expoente de Hölder pontual de f em cada ponto $x \in [a, b]$. O espectro multifractal $D(\alpha)$ de f é definido como

$$D(\alpha) = d_H(\{x \mid \alpha(x) = \alpha\}) \quad (4)$$

em que d_H denota a dimensão de Hausdorff [5].

Uma maneira muito utilizada para a estimação do espectro multifractal de um sinal com suporte compacto consiste na aplicação da transformada de Legendre [5] [13]. Para isso, inicialmente estima-se a função de partição $S(q, j)$ do processo analisado. A função de partição $S(q, j)$ é calculada em termos dos coeficientes wavelets $d_{j,k}$ do sinal pela seguinte equação

$$S(q, j) = \sum_k |d_{j,k}|^q \quad (5)$$

Seja $\tau(q)$ a função estrutura definida como [5]

$$\tau(q) = \lim_{j \rightarrow \infty} \frac{\log S(q, j)}{j \log 2} \quad (6)$$

Assim, o espectro multifractal $D(\alpha)$ do sinal analisado pode ser calculado como [13]

$$D(\alpha) = \tau^*(\alpha) \quad (7)$$

em que $\tau^*(\alpha)$ é a transformada inversa de Legendre da função estrutura $\tau(q)$, ou seja $\tau^*(\alpha) = \min_q (\alpha q - \tau(q))$.

A Figura 1 apresenta os expoentes de Hölder de um processo de tráfego Internet assim como o seu espectro multifractal de Legendre.

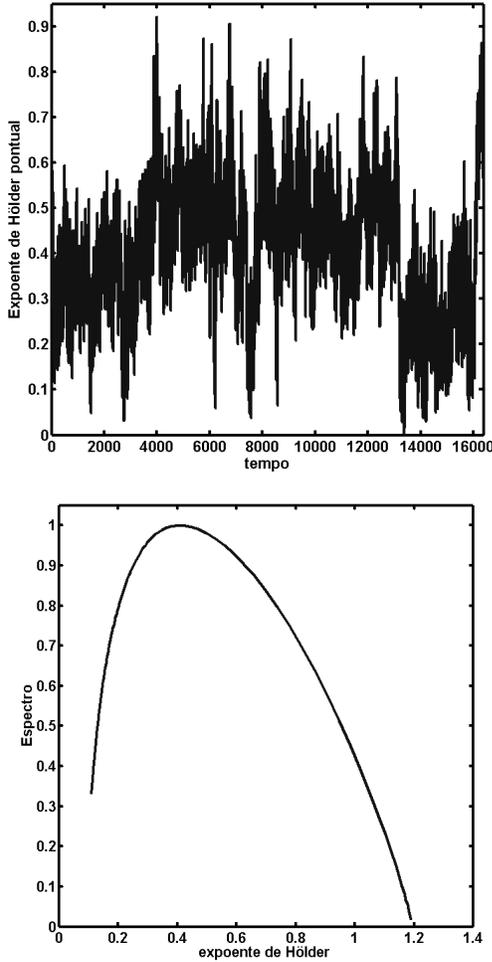


Fig. 1 - Acima: expoentes de Hölder pontuais referentes a um trecho da série de tráfego *lbl-pkt-5* na escala de tempo de 100 ms. Abaixo: espectro multifractal.

D. Tipos de Singularidades

Existem diferentes funções com um mesmo expoente de Hölder num determinado ponto, mas com comportamentos distintos ao redor desse mesmo ponto. Isso é devido ao tipo de singularidade que a função possui. Podemos destacar dois tipos [8] [19]:

Definição 3 (Singularidade não-oscilante): Seja $f_\alpha^{(-n)}$ a primitiva de n -ésima ordem da função f_α . Dizemos que f_α possui uma singularidade não-oscilante, com expoente de Hölder pontual α em x_0 , se

$$\forall n \in \mathbb{N} : f_\alpha^{(-n)} \in C^{\alpha+n}(x_0) \quad (8)$$

Desta forma, a função f_α deve ser regular o suficiente, para que dado um ponto x_0 com expoente de Hölder α , a derivada de f_α apresente expoente de Hölder $\alpha-1$ em x_0 e a integral de f_α apresente expoente de Hölder $\alpha+1$ no mesmo ponto. A função $f_\alpha(x) = |x - x_0|^\alpha$ representa o exemplo mais simples de singularidade não-oscilante em x_0 .

Definição 4 (Singularidade oscilante): seja $g_{\alpha,\beta}^{(-n)}$ a primitiva de n -ésima ordem da função $g_{\alpha,\beta}$. Pode-se dizer que $g_{\alpha,\beta}$ possui uma singularidade oscilante em x_0 , com expoente de Hölder pontual α e expoente de oscilação $\beta > 0$, se

$$\forall n \in \mathbb{N} : g_{\alpha,\beta}^{(-n)} \in C^{\alpha+n(1+\beta)}(x_0) \quad (9)$$

Este tipo de singularidade ocorre em funções cujo expoente de Hölder pontual em x_0 aumenta mais que a unidade quando integradas. Isto se deve aos efeitos da suavização das oscilações presentes, causados pela operação de integração da função [9]. A função $g_{\alpha,\beta}(x) = |x - x_0|^\alpha \operatorname{sen}\left(\frac{1}{|x - x_0|^\beta}\right)$ representa o exemplo mais simples de singularidade oscilante em x_0 .

E. Decaimento dos Coeficientes Wavelets

O expoente de Hölder h de uma função no ponto x_0 pode ser aproximado usando $|d_{a,b}| \sim a^h$, com os coeficientes wavelets máximos absolutos $|d_{a,b}|_{b \in \mathbb{Z}}$ imersos num cone do tipo $|x - x_0| \leq Ka$, onde K é uma constante [8][18]. Porém, esse tipo de análise só é condizente para singularidades não-oscilantes [8].

Para tráfego de redes, devido à alta irregularidade presente, devemos levar em consideração também as singularidades oscilantes que possuem expoente de oscilação $\beta > 0$. Nesse caso, os coeficientes wavelets máximos absolutos estão imersos num cone parabólico mais largo que o citado anteriormente, cuja equação é dada por $|x - x_0|^{1+\beta} \leq Ka$ [9].

Dessa forma, para uma caracterização correta do comportamento local de um processo, devemos levar em consideração não apenas a amplitude dos coeficientes wavelets, mas também sua localização no tempo. Assim, utiliza-se a seguinte desigualdade [3]:

$$|d_{a,b}| \leq K(a + |x - x_0|)^h \quad (10)$$

Com base nessa desigualdade, Seuret et al. [15] propuseram um algoritmo para estimação dos expoentes de Hölder pontuais tanto para singularidades oscilantes quanto não-oscilantes. Na próxima seção descreveremos como os fundamentos deste método podem ser aplicados para se realizar a estimação dos expoentes de Hölder em janelas de tempo.

III. ESTIMAÇÃO DA REGULARIDADE LOCAL

Nesta seção, apresentamos um método para estimar a regularidade local de um processo de tráfego.

Seja um sinal amostrado contendo 2^n amostras na escala de tempo j onde quanto maior o seu valor, maior a escala considerada.

A estimação do expoente de Hölder pontual para uma amostra k_0 pode ser feita considerando os seguintes passos [15]:

Passo 1) Construa, em um mesma figura, para cada $0 < j \leq n$, a seguinte curva paramétrica (com parâmetro $k \leq 2^n$):

$$x_j(k) = \log_2(2^j + |2^j k - x_0|) \quad (11)$$

$$y_j(k) = \log_2(|d_{j,k}|) \quad (12)$$

Passo 2) Encontre todas as retas $D: y = \alpha x + C$ que satisfaçam as duas restrições a seguir:

1. D está acima de todos os pontos $(x_j(k), y_j(k))$, ou seja:

$$\forall j, \forall k, y_j(k) \geq \alpha x_j(k) + C \quad (13)$$

2. D toca uma das curvas paramétricas, ou seja, existe uma seqüência de pares (j_m, k_m) tal que

$$\lim_{m \rightarrow \infty} y_{j_m}(k_m) - (\alpha x_{j_m}(k_m) + C) = 0 \quad (14)$$

Passo 3) Calcule α_{max} o maior coeficiente angular encontrado em todas as retas D satisfazendo (13) e (14). O coeficiente α_{max} é o expoente de Hölder pontual do sinal para a amostra k_0 .

Note que a estimação do expoente de Hölder pontual para o instante amostral k_0 se dá inicialmente construindo-se uma “nuvem” de pontos $(x_j(k), y_j(k))$. O expoente de Hölder para o instante de tempo k_0 corresponde ao coeficiente angular da reta que se encaixa tão precisamente quanto possível no topo dessa “nuvem” [15]. Com relação ao número de pontos na obtenção da nuvem de pontos, utiliza-se a restrição $3 \leq x(j, k) \leq \log_2(2^n) - 2$, sendo 2^n o número de amostras do processo. Isto permite que seja levado em conta os coeficientes wavelets máximos absolutos em uma extensão suficiente de expoentes de oscilação β e gerar uma quantidade de pontos $(x_j(k), y_j(k))$ tal que seja possível uma construção precisa da reta que toca o topo desta “nuvem”. Para tal, utilizamos neste trabalho a função Morlet como wavelet-mãe [4].

A Figura 2 mostra o sinal $|x|^{0.7} \text{sen}\left(\frac{1}{|x|^{1.2}}\right)$ que apresenta uma singularidade oscilante, sua respectiva “nuvem de pontos” e a reta que toca o topo da nuvem.

A. Estimação do Expoente de Hölder Pontual em Janelas de Tempo

Nesta seção, propomos uma estratégia dinâmica para a estimação do expoente de Hölder pontual para um dado sinal. Esta estratégia se baseia na utilização de uma quantidade fixa de amostras consecutivas (janela de tempo) para a estimação do expoente de Hölder pontual relativo a cada amostra do sinal. Para cada amostra do processo estimamos o seu respectivo expoente de Hölder utilizando somente as amostras da janela ao invés de todas as amostras do processo. Dessa forma, utiliza-se uma menor quantidade de amostras (assim

como uma menor quantidade de coeficientes wavelet) para a estimação do expoente em cada instante de tempo.

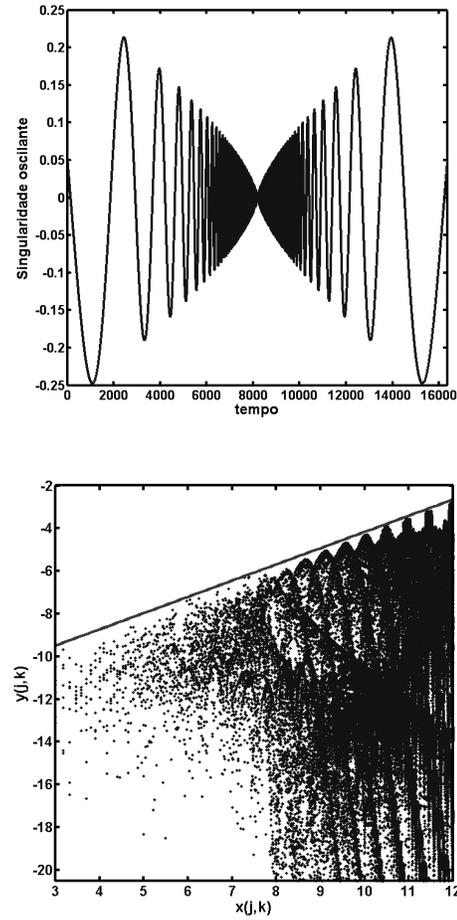


Fig.2. Acima: função $|x|^{0.7} \text{sen}(1/|x|^{1.2})$; Direita: “nuvem de pontos” associada ao ponto de singularidade oscilante da função. Abaixo: O coeficiente angular da reta é a estimativa do expoente de Hölder pontual.

A diminuição da quantidade de coeficientes wavelet utilizada em cada estimação possibilita um processamento mais rápido das informações, podendo ser usada em roteadores e *switches* como indicadores das condições de tráfego. Comparamos então os expoentes de Hölder pontuais estimados por meio de janelas de tempo com os expoentes de Hölder pontuais de referência. Definimos este último como sendo os expoentes de Hölder pontuais estimados utilizando-se todas as amostras disponíveis de um processo de tráfego (sem uso de janelas de tempo).

Utilizamos nas simulações processos que consistem das amostras de traços de tráfego Internet como: *dec1-pkt*, *dec2-pkt* e *lbl5-pkt* nas escalas de tempo de 100 e 200 ms. Estes traços contêm a quantidade de bytes transmitida em cada intervalo de tempo. Nas simulações, três tamanhos de janelas foram considerados: janela 12 ($2^{12} = 4096$ instantes de tempo), janela 13 (8192 instantes de tempo) e janela 14 (16384 instantes de tempo).

Como medida de desempenho da estimação dos expoentes de Hölder, utilizamos o conhecido erro quadrático médio normalizado (EQMN), definido como [10][16]:

$$EQMN = \frac{E[(h_{ref} - h_{jan})^2]}{\sigma^2_{h_{ref}}} \quad (15)$$

onde h_{jan} é o expoente de Hölder pontual estimado via janelamento, h_{ref} é o expoente de Hölder pontual usado como referência e $\sigma^2_{h_{ref}}$ é a variância dos expoentes de Hölder pontuais de referência.

TABELA I
ERRO QUADRÁTICO MÉDIO NORMALIZADO

	Janela 12	Janela 13	Janela 14
série dec-pkt-1	0,4899	0,2483	0,0426
série lbl5	0,5423	0,4332	0,2116

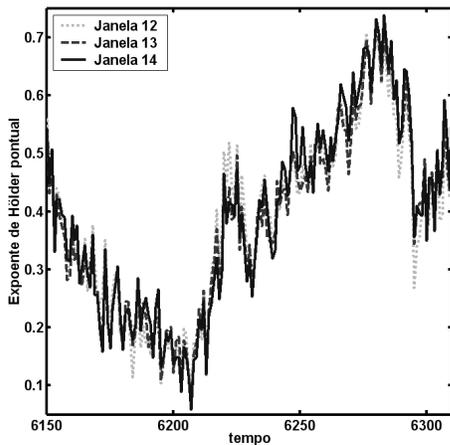


Fig.3. Expoentes de Hölder pontuais de amostras da série lbl-pkt-5 na escala de 100ms, estimados com três tamanhos diferentes de janelas de tempo.

Conforme mostram a Tabela I e a Figura 3, verifica-se que ao se diminuir o tamanho da janela, aumenta-se a imprecisão da estimação do expoente de Hölder pontual em relação aos expoentes de Hölder de referência. Em contrapartida, a estimação se dá de maneira mais rápida, devido à diminuição da quantidade de coeficientes wavelets relativos a cada janela de tempo. Além disso, os erros obtidos apontam que as regularidades locais do tráfego de redes podem ser de fato estimadas adaptativamente usando o algoritmo de estimação do expoente de Hölder pontual em janelas.

IV. PREDIÇÃO DO EXPOENTE DE HÖLDER PONTUAL

Pode-se afirmar que a série temporal formada pelos expoentes de Hölder é mais apropriada para se realizar previsão de suas amostras futuras do que a série correspondente de tráfego propriamente dita. Esta afirmação se fundamenta no decaimento da função de autocorrelação das séries formadas pelos expoentes de Hölder, que é mais simples de ser tratada pelos algoritmos de previsão. A Figura 4 apresenta a função de autocorrelação das amostras de um processo de tráfego e a série correspondente de expoentes de Hölder pontuais. Pode-se notar um decaimento assintótico mais lento da função de autocorrelação do processo de tráfego,

confirmando sua propriedade de dependência de longo prazo [12]. Entretanto, há um decaimento mais acelerado das funções de autocorrelação das séries de expoentes de Hölder pontuais, o que indica que tais séries não apresentam dependência de longo prazo. Isto sugere a possibilidade do uso de técnicas mais simples de previsão de séries temporais, tais como o filtro de Mínimos Médios Quadrados (Least-Mean Squares - LMS) e o filtro de Kalman [7] para a previsão dos valores dos expoentes de Hölder.

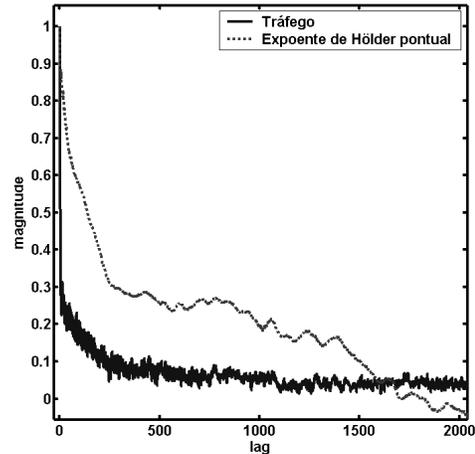


Fig. 4 – Função de autocorrelação das amostras de uma série de tráfego e de seus respectivos expoentes de Hölder pontuais. Esquerda: série lbl-pkt-5 na escala de tempo de 100 ms.

Apresentaremos na próxima seção um algoritmo adaptativo de previsão aplicado à previsão dos valores dos expoentes de Hölder estimados em janelas de tempo. Pretende-se portanto, estimar com antecedência as intensidades dos surtos de rajadas de cada fluxo de tráfego, disponibilizando essa informação para os mecanismos de controle de tráfego.

A. Algoritmo de Previsão com Estimação Adaptativa dos Ruídos do Sistema

Um dos algoritmos adaptativos de previsão mais usados é o filtro de Kalman. O filtro de Kalman é um estimador recursivo dos estados de um processo, muito utilizado em várias aplicações do mundo real [7]. Com base nestas equações recursivas de estimação, introduzimos um preditor que apresenta uma nova estratégia de atualização adaptativa dos ruídos do sistema, sendo o mesmo preciso para previsões dos expoentes de Hölder.

Seja o modelo de sistema descrito pelas seguintes equações no espaço de estado [7]:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \boldsymbol{\eta}_1(k) \quad (16)$$

$$y(k) = \mathbf{u}^T(k)\mathbf{w}(k) + \eta_2(k) \quad (17)$$

Nestas equações, $w(k)$ é o estado do sistema, $y(k)$ é a saída medida, $\mathbf{u}(k) = [u(k), u(k-1), \dots, u(k-N)]^T$ é o vetor de entradas do sistema, N denota a ordem do filtro e k é o instante

de tempo discreto, com $k \in Z$. O vetor $\boldsymbol{\eta}_1(k)$ é conhecido como ruído de processo, o qual se assume como sendo um processo gaussiano com média zero e covariância $Q(k)$ dada por:

$$\mathbf{Q}(k) = E[\boldsymbol{\eta}_1(k)\boldsymbol{\eta}_1^T(k)] \quad (18)$$

De modo semelhante, a variável $\eta_2(k)$ é conhecida como ruído de medida e modelada como um processo gaussiano com média zero e variância $P(k)$ dada por:

$$P(k) = E[\eta_2^2(k)] \quad (19)$$

Para que seja possível aplicar esse modelo de espaço de estados, é necessário que a covariância $Q(k)$ e a variância $P(k)$ sejam conhecidas. Na prática, é comum encontrar sistemas nos quais $Q(k)$ e $P(k)$ são desconhecidos, ou parcialmente conhecidos. Pode-se verificar que a escolha destes parâmetros influencia no desempenho do preditor. Dessa forma, propomos um método de estimação adaptativa destes parâmetros.

Seja $w(k)$ o vetor de coeficientes de um filtro transversal, o vetor $\boldsymbol{\eta}_1(k)$ pode ser visto como o ajuste dos coeficientes do algoritmo NLMS (Normalized Least-Mean Squares) [7]. Assim,

$$\boldsymbol{\eta}_1(k) = \frac{\tilde{\mu}}{\|\mathbf{u}(k)\|^2} [\mathbf{u}(k)e(k)] \quad (20)$$

em que $\tilde{\mu}$ é o passo de adaptação e $e(k)$ é o erro de estimação. Pode-se dizer que estamos usando um filtro NLMS para se estimar o ruído de processo $\boldsymbol{\eta}_1(k)$.

Segundo a equação (17), o ruído de medida $\eta_2(k)$ é dado por:

$$\eta_2(k) = y(k) - \mathbf{u}^T(k)\mathbf{w}(k) = e(k) \quad (21)$$

Objetivamos o cálculo adaptativo dos ruídos de predição. Então, utilizamos as seguintes equações recursivas para a média $\bar{\eta}_2(k)$ e a variância $r(k)$ de $\eta_2(k)$ [17]:

$$\bar{\eta}_2(k) = \frac{k-1}{k}\bar{\eta}_2(k-1) + \frac{1}{k}\eta_2(k) \quad (22)$$

$$r(k) = \frac{k-1}{k}r(k-1) + \frac{1}{k}(\eta_2(k) - \bar{\eta}_2(k))^2 \quad (23)$$

A matriz de covariância $Q(k)$ pode ser estimada através dos valores de variância do ruído de processo $\boldsymbol{\eta}_1(k)$. Seja o vetor $\boldsymbol{\eta}_1(k) = [\eta_{1,1}(k), \eta_{1,2}(k), \dots, \eta_{1,N}(k)]^T$. Cada $\eta_{1,j}(k)$, onde $j = 1, 2, \dots, N$, possui variância $q_j(k)$ que pode ser calculada recursivamente por:

$$q_j(k) = \frac{k-1}{k}q_j(k-1) + \frac{1}{k}(\eta_{1,j}(k) - \bar{\eta}_{1,j}(k))^2 \quad (24)$$

Dessa forma, a matriz de covariância $Q(k)$ é dada por:

$$\mathbf{Q}(k) = \begin{bmatrix} q_1(k) & \dots & 0 & 0 \\ \vdots & q_2(k) & \dots & 0 \\ 0 & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & q_N(k) \end{bmatrix} \quad (25)$$

Tomando como base as equações recursivas do filtro de Kalman, apresentamos a seguir as equações que regem o preditor proposto cuja saída é $y(k+1)$:

Algoritmo de Predição:

Passo 1) Calcula-se o ganho de Kalman $\mathbf{K}(k)$:

$$\mathbf{K}(k) = \frac{\mathbf{P}(k)\mathbf{u}(k)}{\mathbf{u}^T(k)\mathbf{P}(k)\mathbf{u}(k) + r(k)} \quad (26)$$

Passo 2) Atualiza-se os pesos:

$$\hat{\mathbf{w}}(k+1) = \hat{\mathbf{w}}(k) + \mathbf{K}(k)[y(k) - \mathbf{u}^T(k)\hat{\mathbf{w}}(k)] \quad (27)$$

Passo 3) Calcula-se a variância $P(k)$:

$$\bar{\eta}_2(k) = \frac{k-1}{k}\bar{\eta}_2(k-1) + \frac{1}{k}\eta_2(k) \quad (28)$$

$$P(k) = \frac{k-1}{k}P(k-1) + \frac{1}{k}(\eta_2(k) - \bar{\eta}_2(k))^2 \quad (29)$$

Passo 4) Calcula-se a matriz $Q(k)$:

$$q_j(k) = \frac{k-1}{k}q_j(k-1) + \frac{1}{k}(\eta_{1,j}(k) - \bar{\eta}_{1,j}(k))^2 \quad (30)$$

$$\mathbf{Q}(k) = \begin{bmatrix} q_1(k) & \dots & 0 & 0 \\ \vdots & q_2(k) & \dots & 0 \\ 0 & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & q_N(k) \end{bmatrix} \quad (31)$$

Passo 5) Atualiza-se $P(k)$:

$$\mathbf{P}(k+1) = \mathbf{P}(k) + \mathbf{Q}(k) - \mathbf{K}(k)\mathbf{u}^T(k)\mathbf{P}(k) \quad (32)$$

Passo 6) A saída do algoritmo de predição é dada por:

$$\hat{y}(k+1) = \mathbf{u}^T(k+1)\hat{\mathbf{w}}(k+1) \quad (33)$$

em que $K(k)$ é chamado de ganho de Kalman e $\hat{\mathbf{w}}(k+1)$ é a estimação do próximo estado do sistema.

B. Avaliação do Preditor Proposto

Avaliamos o desempenho do preditor proposto através de simulações utilizando os expoentes de Hölder pontuais estimados com as janelas 11 (2^{11} amostras), 12 (2^{12} amostras) e 13 (2^{13} amostras) para as séries de tráfego Internet dec-pkt-1, dec-pkt-2 e lbl-pkt-5.

Com relação à configuração do preditor proposto, adotou-se o valor de $N=7$ para a ordem do preditor; valor acima do qual

o EQM de predição em geral decai infimamente para as séries consideradas. Por meio de simulações, constatamos que o valor de $\tilde{\mu}$ que resultou em um melhor comportamento do preditor proposto foi de $\tilde{\mu} = 0,02$. Além disso, as condições iniciais consideradas foram:

$$\hat{w}(0) \cong 0 \quad (34)$$

$$K(0) = \hat{w}(0)\hat{w}(0)^T \quad (35)$$

Comparamos o desempenho do algoritmo de predição com o desempenho de outros preditores bastante utilizados na literatura. Consideramos como critério para avaliação do desempenho de predição, duas versões do erro quadrático médio normalizado (EQMN), definidos pelas seguintes equações [16]:

$$EQMN1 = \frac{E[(h_{pred} - h_{jan})^2]}{\sigma^2_{h_{jan}}} \quad (36)$$

$$EQMN2 = \frac{E[(h_{pred} - h_{jan})^2]}{E[(h_{ua} - h_{jan})^2]} \quad (37)$$

onde h_{jan} é o expoente de Hölder pontual estimado via janelamento, h_{pred} é o expoente de Hölder predito, $\sigma^2_{h_{jan}}$ é a variância dos expoentes de Hölder estimados e h_{ua} é o expoente de Hölder anterior a h_{jan} .

Basicamente, o EQMN nos fornece uma comparação entre o EQM do preditor avaliado com o EQM de um preditor mais simples. No cálculo do EQMN1 considera-se a média amostral do sinal analisado como preditor mais simples. Enquanto no cálculo do EQMN2, compara-se o EQM do preditor avaliado com o EQM de um preditor que considera a última amostra disponível do sinal como valor predito. É desejável que um preditor a ser empregado possua ambos EQMNs menores que a unidade. Caso contrário, pode-se concluir que seu desempenho será, na melhor das hipóteses, similar aos preditores mais simples citados.

Além do preditor proposto, os outros preditores avaliados são o filtro NLMS (preditor 1) e o filtro de Kalman (preditor 2). A ordem do filtro para os preditores 1 e 2 é a mesma para o preditor proposto ($N=7$). O valor do passo de adaptação $\tilde{\mu}$ do preditor 1 é escolhido de forma a obter o menor erro quadrático médio possível para cada série de tráfego analisada.

TABELA II - EQMNs PARA PREDIÇÃO DE AMOSTRAS DA SÉRIE DE TRÁFEGO *DEC-PKT-1* NA ESCALA DE TEMPO DE 100 MS E DE SEUS EXPOENTES DE HÖLDER PONTUAIS.

	EQMN1	EQMN2
série <i>dec-pkt-1</i>	0,7474	0,7129
expoentes de Hölder pontuais (janela 13)	0,3246	0,6317
expoentes de Hölder pontuais (janela 12)	0,3757	0,6347
expoentes de Hölder pontuais (janela 11)	0,3991	0,6350

Observando a Tabela II, pode-se constatar um melhor desempenho de predição para o preditor proposto em relação

aos demais analisados. De fato, além de possuir EQMNs menores que a unidade, o preditor proposto também possui EQMNs menores do que aqueles referentes aos preditores 1 e 2.

Outro fator importante na verificação da eficiência de um preditor é o decaimento do erro quadrático com o tempo [2]. O decaimento temporal do erro quadrático de predição para a série *lbl-pkt-5* é mostrado na Figura 5. Esta figura nos mostra que o preditor proposto possui o decaimento mais íngreme deste erro, em comparação aos outros preditores analisados. Com poucas amostras iniciais, o erro quadrático do preditor proposto decai e se mantém abaixo dos outros preditores.

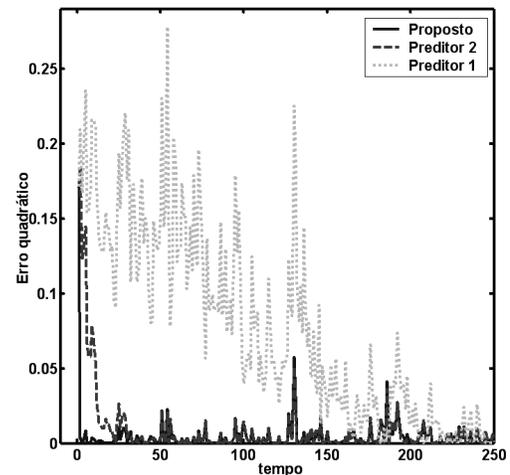


Fig. 5 - Erro quadrático de predição dos expoentes de Hölder de amostras da série *lbl-pkt-5* nas escalas de tempo de 100 ms.

V. DISCIPLINA DE ESCALONAMENTO UTILIZANDO OS EXPOENTES DE HÖLDER PONTUAIS

As disciplinas de escalonamento são úteis em pontos de multiplexação de dados pois permitem que vários fluxos ou sessões compartilhem de uma melhor forma a taxa de transmissão (capacidade) de um enlace. Dentre estas disciplinas, uma das mais conhecidas é a *Generalized Processor Sharing* (GPS) [11]. Uma de suas propriedades mais importantes é a proteção aos fluxos de dados. Esta propriedade refere-se ao isolamento dos fluxos de entrada do escalonador, não permitindo que um fluxo mal-comportado afete o desempenho dos demais fluxos.

Nesta seção propomos um novo esquema de escalonamento de fluxos de tráfego Internet tendo como base o GPS. A inovação deste esquema está na utilização do expoente de Hölder pontual como parâmetro de decisão da prioridade de cada fluxo em cada intervalo de tempo considerado. Nosso objetivo é obter uma melhor distribuição da taxa de transmissão do enlace aos fluxos e como consequência uma menor perda de dados.

A. Esquema de Escalonamento de Fluxos de Tráfego Utilizando Predição dos Expoentes de Hölder

O GPS é uma disciplina de escalonamento onde n fluxos de entrada compartilham um servidor de taxa fixa c . Um conjunto

de parâmetros $\{\varphi_i\}_{1 \leq i \leq n}$ determina a proporção da taxa de serviço que cada fluxo recebe. Cada fluxo i de entrada recebe ao menos $c_i = \left(\varphi_i / \sum_{j=1}^n \varphi_j \right) c$, que é sua taxa garantida. Caso

algum fluxo esteja ocioso em um determinado instante, sua taxa residual é distribuída proporcionalmente aos fluxos ativos.

Considere n fluxos de entrada, modelados como fluidos infinitamente divisíveis e cada qual com sua ponderação φ_i , onde $\sum_{i=1}^n \varphi_i = 1$. Cada fluxo i ($1 \leq i \leq n$) possui sua própria

fila (Figura 6) e parâmetro $\varphi_i(t)$. As duas regras que definem a disciplina de escalonamento GPS são as seguintes:

-o mecanismo de escalonamento é conservativo;
 -caso o fluxo i , durante o intervalo de tempo $[t, t+\Delta t]$, esteja com dados no *buffer* (*backlogged*), então

$$\frac{S(i, t, t + \Delta t)}{S(j, t, t + \Delta t)} \geq \frac{\varphi_i(t)}{\varphi_j(t)} \quad (38)$$

para todo $j = 1, 2, \dots, n$. O termo $S(i, t, t+\Delta t)$ é a quantidade de dados do fluxo i atendida no intervalo $[t, t+\Delta t)$. Os parâmetros $\{\varphi_i(t)\}_{1 \leq i \leq n}$, que são reais e positivos, são conhecidos como atribuições GPS (*GPS assignments*) e determinam o grau de prioridade do fluxo i em função do tempo t e são válidos para o intervalo de tempo $[t, t+\Delta t)$. Para cada fluxo i , sua taxa de serviço garantida g_i é dada por

$$g_i = \frac{tm_i}{\sum_{j=1}^n tm_j} c \quad (39)$$

em que tm_i é a taxa média do fluxo i e c é a taxa total de serviço. Esta taxa garantida é importante para evitarmos o fenômeno da negação de serviço (*starvation*) a fluxos com menores prioridades. Nesse caso, um fluxo mais prioritário monopolizaria a taxa total de serviço. Caso algum fluxo i não esteja mais com dados no *buffer* no intervalo de tempo Δt após a definição de $\varphi_i(t)$, sua taxa de serviço remanescente é redistribuída para algum fluxo ainda com dados no *buffer* e com maior prioridade em relação a outros na mesma situação. Isto se repete até a utilização total da soma das taxas remanescentes ou até o momento que todos os fluxos não possuam mais dados a serem transmitidos neste intervalo. Generalizando, sempre há a determinação dos parâmetros de prioridade $\varphi_i(t + k\Delta t)$ dos fluxos i para o intervalo de tempo $[t + k\Delta t, t + (k+1)\Delta t]$, com $k \in \mathbb{Z}$.

Nossa proposta consiste de se obter os parâmetros φ_k de distribuição das taxas residuais dos fluxos de maneira adaptativa e que reflita as necessidades instantâneas de cada fluxo. Para isso utilizamos o expoente de Hölder pontual α para a definição dos parâmetros φ_k em cada instante de tempo, ou seja:

$$\frac{S(i, t, t + \Delta t)}{S(j, t, t + \Delta t)} \geq \frac{\alpha_i(t)}{\alpha_j(t)} \quad (40)$$

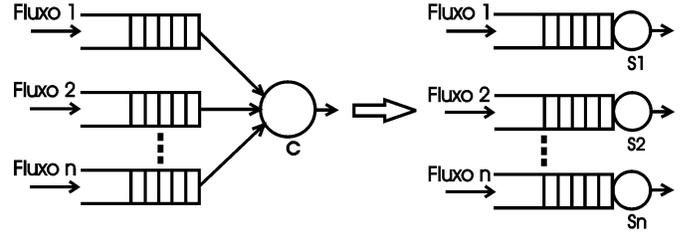


Fig.6. Decomposição e isolamento das filas num sistema GPS com N fluxos

O esquema completo do escalonador proposto está ilustrado na Figura 7, que é composto dos módulos de estimação e predição dos expoentes de Hölder e do módulo de escalonamento relativo à alocação de banda para cada fluxo. Novamente realizamos simulações para avaliar o esquema de escalonamento em questão utilizando-se os traços dec-pkt-1, dec-pkt-2 e lbl-pkt-5. Nas simulações, foram considerados diferentes tamanhos de escala de tempo (100 e 200 ms) e de janelas para estimação dos expoentes de Hölder pontuais (janelas 11, 12, e 13), assim como diferentes valores para a capacidade do enlace e tamanhos de *buffers*.

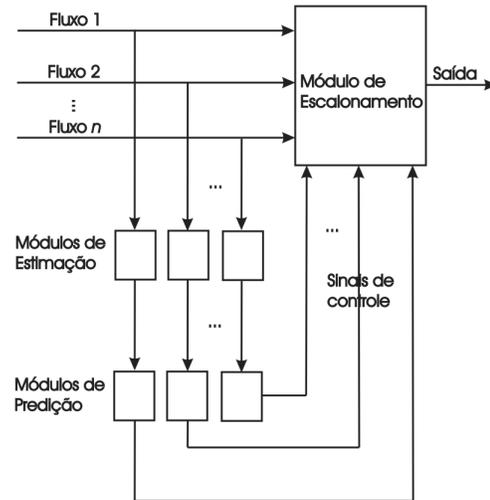


Fig.7 - Esquema completo do escalonador proposto.

Com objetivo de comparação, analisamos outros critérios para a definição dos parâmetros de prioridade $\varphi(t)$ de cada fluxo:

- 1 - $\varphi_i(t)$ diretamente proporcional à taxa média de chegada de cada fluxo (definido como GPS convencional).
- 2 - $\varphi_i(t)$ diretamente proporcional à taxa de chegada predita de cada fluxo, para o próximo instante de tempo.

Assim como para os expoentes de Hölder, verificamos através de simulações que os resultados da aplicação do preditor proposto para as séries de tráfegos consideradas são adequados. Por isso, em relação ao critério 2, utilizamos

também o preditor proposto para a predição a um passo da taxa de chegada de cada fluxo.

O intervalo de alocação de uma nova taxa para cada fluxo equivale ao intervalo de tempo entre duas amostras (100 ou 200ms). Neste ínterim, alguns fluxos podem ter uma taxa excessiva às suas necessidades momentâneas, sendo esta taxa redistribuída segundo os níveis de prioridade de cada fluxo. Outro fato que pode ocorrer é o de alguns fluxos terem uma taxa insuficiente às suas necessidades naquele intervalo, mesmo após a realocação das taxas excedentes oriundas de outros fluxos. Neste caso, há a ocorrência de perda de pacotes quando o tamanho do *buffer* não é estipulado adequadamente.

B. Resultados das Simulações com o Esquema de Escalonamento Proposto

As Tabelas III, IV e V resumem os resultados obtidos nas simulações realizadas na escala de tempo de 100 ms, escala na qual os traços de tráfego são multifractais [6]. Nestas simulações, os tamanhos do *buffer* são 16 Kbytes e 25 Kbytes e os valores da taxa de transmissão do enlace são 2,25 Mbps e 2,75 Mbps. Cada tabela retrata a porcentagem de perda de bytes, o ganho de desempenho sobre o GPS convencional e a utilização do enlace, em função dos critérios de escalonamento considerados. A porcentagem de perda de bytes está relacionada a quantidade total de bytes perdida em relação à quantidade total de bytes transmitida pelos fluxos. Definimos o ganho do escalonador proposto sob o GPS como a redução percentual da taxa de perda de Bytes do GPS proposto sobre o GPS comum. O ganho de desempenho sobre o GPS convencional é um indicador da eficiência do uso de um determinado critério de escalonamento em relação ao uso do critério baseado na taxa média (GPS convencional). Por último, a utilização do enlace é a razão da taxa média utilizada pelos fluxos em relação à taxa total de transmissão do enlace.

As seguintes tendências foram observadas nos resultados das simulações:

1. A diminuição do tamanho da janela de tempo na estimação do expoente de Hölder pontual (notação H Pont J nas Tabelas III, IV e V) aumenta a porcentagem de perda de bytes e diminui o ganho de desempenho do escalonador proposto em relação ao GPS convencional (notação Taxa Média). Isto se deve ao aumento das imprecisões na estimação dos expoentes de Hölder com a diminuição do tamanho da janela de tempo.

2. Para um mesmo tamanho de *buffer*, um aumento da taxa de transmissão total proporciona uma diminuição da perda de dados e um aumento no ganho de desempenho do escalonador proposto em relação ao GPS convencional. No entanto, uma porcentagem maior da taxa de transmissão total pode ficar inutilizada. Isso pode ocorrer para todos os escalonadores analisados.

3. Para um mesmo valor de taxa de transmissão total, o

aumento do tamanho do *buffer* proporciona uma diminuição da perda de dados, um aumento no ganho de desempenho do escalonador proposto em relação ao GPS convencional e uma melhor utilização da taxa de transmissão do enlace.

4. A diminuição da escala de tempo entre amostras proporciona uma diminuição da perda de dados, um aumento no ganho de desempenho do escalonador proposto em relação ao GPS convencional e um melhor aproveitamento da taxa de transmissão do enlace. Isto se deve a uma maior quantidade de ajustes dentro de um mesmo intervalo de tempo, obtendo uma alocação mais coerente de taxa a cada fluxo, apesar do aumento de informações que devem ser processadas na rede.

5. O uso da taxa de tráfego predita pelo preditor proposto (notação Taxa inst. nas tabelas) como critério de escalonamento, demonstrou um desempenho superior ao GPS convencional. No entanto, seu desempenho apresentou-se inferior ao do escalonador proposto na maioria dos casos. Isto ocorre principalmente quando se utiliza janelas de tempo mais largas para a estimação dos expoentes de Hölder pontuais.

TABELA III- DESEMPENHO DO ESCALONADOR PROPOSTO PARA TAXA DO ENLACE DE 2,25MBPS E BUFFER DE 16 KBYTES

Critério de escalonamento	Porcentagem de perda de bytes	Ganho sobre o GPS convencional	Utilização do enlace
Taxa média	0,0146	-	0,7664
Taxa inst.	0,0135	7,35 %	0,7673
H Pont Ref	0,0125	14,38 %	0,7681
H Pont J13	0,0127	13,01 %	0,7679
H Pont J12	0,0131	10,27 %	0,7676
H Pont J11	0,0136	6,85 %	0,7672

TABELA IV - DESEMPENHO DO ESCALONADOR PROPOSTO PARA TAXA DE 2,25 MBPS E BUFFER DE 25 KBYTES

Critério de escalonamento	Porcentagem de perda de bytes	Ganho sobre o GPS convencional	Utilização do enlace
Taxa média	0,0099	-	0,7701
Taxa inst.	0,0087	12,12 %	0,7710
H Pont Ref	0,0079	20,20%	0,7716
H Pont J13	0,0080	19,19%	0,7716
H Pont J12	0,0083	16,16%	0,7713
H Pont J11	0,0088	11,11%	0,7709

TABELA V - DESEMPENHO DO ESCALONADOR PROPOSTO PARA TAXA DE 2,75 MBPS E BUFFER DE 25 KBYTES

Critério de escalonamento	Porcentagem de perda de bytes	Ganho sobre o GPS convencional	Utilização do enlace
Taxa média	0,0017	-	0,6353
Taxa inst.	0,0013	23,53 %	0,6355
H Pont Ref	0,0010	41,18 %	0,6357
H Pont J13	0,0012	29,41 %	0,6356
H Pont J12	0,0012	29,41 %	0,6356
H Pont J11	0,0012	29,41 %	0,6356

VI. CONCLUSÕES

O uso de mecanismos dinâmicos e preventivos de controle de tráfego requer que as características locais do tráfego sejam preditas. A predição (e também o controle e gerenciamento) do tráfego encontra como obstáculo o fato de o mesmo ser

complexo e possuir irregularidades com intensidades elevadas, principalmente em pequenas escalas de tempo.

Neste artigo, apresentamos um estudo sobre a estimação do expoente de Hölder pontual, o qual é capaz de indicar o grau da regularidade do tráfego. Verificamos que a estimação destes expoentes em janelas de tempo é possível e que o algoritmo empregado é adequado para tal, possibilitando um processamento mais rápido das informações.

O preditor proposto se mostrou robusto e preciso em escalas de tempo distintas, mesmo para processos com características complexas, como o tráfego de redes e as séries formadas pelos expoentes de Hölder pontuais.

Este trabalho contribui também com um esquema de escalonamento que incorpora o conhecimento da regularidade local do tráfego por meio dos expoentes de Hölder pontuais. Em nossa abordagem utilizamos o método das janelas de tempo para a estimação dos expoentes das amostras de cada fluxo, tornando a operação do escalonador mais dinâmica. Em situações em que há a necessidade de um menor tempo de processamento das informações, o tamanho da janela utilizada pode ser diminuído, às custas de uma menor precisão das estimativas.

Pode-se concluir que o esquema de escalonamento proposto possui melhor desempenho em relação à perda de bytes e utilização do enlace, comparado a escalonadores que usam como critério de distribuição de taxa, a taxa média (GPS convencional), o expoente de Hölder pontual médio e a predição da intensidade de tráfego. Isso ocorre porque o escalonador proposto utiliza a predição da informação de surtos de tráfego. A predição do comportamento em rajadas é importante para que ações sejam tomadas a tempo de modo a evitar congestionamento. Portanto, o escalonador proposto é uma ferramenta poderosa para engenharia de tráfego nas redes atuais.

Em trabalhos futuros, aplicaremos a disciplina de escalonamento proposta em cenários de rede envolvendo diferentes protocolos.

AGRADECIMENTOS

Os autores agradecem a Fapesp (Proc. 06/60363-6) pelo apoio à pesquisa.

REFERÊNCIAS

- [1] P. Abry, R. Baraniuk, P. Flandrin, R. Riedi, D. Veitch, "The multiscale nature of network traffic: Discovery, analysis, and modeling", *IEEE Signal Processing Magazine*, Vol. 19, No. 3, pp.28-46, maio 2002.
- [2] V. Alarcon-Aquino, J. A. Barria, "Multiresolution FIR neural-network-based learning algorithm applied to network traffic prediction", *IEEE Transactions on Systems, Man, and Cybernetics – part C: Applications and Reviews*, Vol. PP, No. 99, pp. 1-13, 2005.
- [3] A. Arneodo, E. Bacry, S. Jaffard, J. F. Muzy, "Singularity spectrum of multifractal functions involving oscillating singularities", *Journal of Fourier Analysis and Applications*, Vol. 4, No. 2, pp. 159-174, 1998.
- [4] I. Daubechies, *Ten Lectures on Wavelets*, Philadelphia: SIAM, 1992.
- [5] K. Falconer, *Fractal Geometry: Mathematical Foundations and Applications*, Nova York: John Wiley & Sons, 1990.
- [6] A. Feldmann, A. C. Gilbert, W. Willinger, T. G. Kurtz, "The changing nature of network traffic: scaling phenomena", *Computer Communications Review*, Vol. 28, No. 2, Abril 1998.
- [7] S. Haykin, *Adaptive Filter Theory*, Nova Jersey: Prentice Hall, 1991.
- [8] S. Jaffard, "Exposants de Hölder en des points donnés et coefficients d'ondelettes", *C. R. Acad. Sci, Paris*, Vol. 308, pp. 79-81, 1989.
- [9] S. Mallat, W. Hwang, "Singularity detection and processing with wavelets", *IEEE Transactions on Information Theory*, Vol. 38, No. 8, pp. 617-643, mar. 1992.
- [10] S. A. N. Ostring, H. Sirisena, "The influence of long-range dependence on traffic prediction", *Proceedings of the International Communications Conference, Helsinki*, pp. 1092-1101, jun. 2001.
- [11] A. K. Parekh, G. Gallager, "A generalized processor sharing approach to flow control in integrated services networks: the single-node case", *IEEE/ACM Transactions on Networking*, Vol. 1, No. 3, pp. 344-357, jun. 1993.
- [12] Y. Qiao, J. Skicewicz, P. Dinda, "An empirical study of the multiscale predictability of network traffic", *IEEE Proceedings of the International Symposium on High Performance Distributed Computing*, Vol. 0, pp. 66-76, 2004.
- [13] R. H. Riedi, J. Lévy-Véhel, "TCP traffic is multifractal: a numerical study", *Technical Report, INRIA Rocquencourt*, No. 3129, mar. 1997.
- [14] A. Sang, S. Q. Li, "A predictability analysis of network traffic", *Computer Networks*, Vol. 39, No. 4, pp. 329-345, jul. 2002.
- [15] S. Seuret, A. C. Gilbert, "Pointwise Hölder exponent estimation in data network traffic", *ITC Specialist Seminar, Monterey*, set. 2000.
- [16] K. Shah, S. Bohacek, E. Jonckheere, "On the predictability of data network traffic", *Proceedings of the American Control Conference*, Vol. 2, pp. 1619-1624, 2003.
- [17] P. Young, *Recursive Estimation and Time-series Analysis*, Nova York: Springer-Verlag, 1984.
- [18] Z. R. Struzik, "Determining Local Singularity Strengths and their Spectra with the Wavelet transform", *Fractals*, 8(1):469-475, Março 2000.
- [19] S. Seuret. Detecting and creating oscillations using multifractal methods. *Mathematische Nachrichten*, 279(11), 1195-1211, 2006.

Flávio Henrique Teles Vieira nasceu em Barra do Garças, MT em 25 de Outubro de 1978. Recebeu o título de bacharel em Engenharia Elétrica pela Universidade Federal de Goiás (UFG) em 2000, o título de Mestre em Engenharia Elétrica e de Computação pela Escola de Engenharia Elétrica da UFG em 2002. Em 2006 recebeu o título de Doutor em Engenharia Elétrica pela Faculdade de Engenharia Elétrica e Computação (FEEC) da UNICAMP. Iniciou em fevereiro de 2007 pós-doutorado no DECOM (Departamento de Comunicações)- FEEC- Unicamp. É membro da Sociedade Brasileira de Telecomunicações e atua nas seguintes áreas de pesquisa: Modelagem, predição e controle de tráfego de redes, redes de comunicações, sistemas inteligentes aplicados a telecomunicações. email: flavio@decom.fee.unicamp.br

Lee Luan Ling obteve o título de engenheiro eletricitista pela USP em 1980, mestre em Engenharia Elétrica pela UNICAMP em 1984 e PhD em Engenharia Elétrica pela Universidade de Cornell em 1991. Foi fundador e tem sido o coordenador do Laboratório de Reconhecimento de Padrões e Redes de Comunicações (LRPRC) da FEEC-UNICAMP desde 1994. Foi o chefe do Departamento de Comunicações em 2000. Desde 2002 ele tem sido Professor Titular pela FEEC-UNICAMP. Atualmente ele atua intensamente em duas áreas de pesquisa: Redes de Comunicações e Reconhecimento de Padrões. email: lee@decom.fee.unicamp.br