

Um Algoritmo Adaptativo para Predição da Regularidade Local de Tráfego de Redes

Flávio Henrique Teles Vieira, Lee Luan Ling, Christian Jorge e Jeferson Stênico

Resumo—Neste artigo, investigamos a estimação adaptativa de expoentes de Hölder pontuais de fluxos reais de tráfego de redes. O expoente de Hölder pode ser usado para indicar o grau de regularidade local de um processo em um determinado instante de tempo. Primeiramente, apresentamos um algoritmo para estimação em janelas de tempo dos expoentes de Hölder baseado no cálculo dos coeficientes wavelets. Em seguida, analisamos algumas propriedades das séries temporais formadas pelos expoentes de Hölder, tais como a sua função de autocorrelação. Além disso, desenvolvemos um algoritmo adaptativo para predição dos expoentes de Hölder referentes aos traços de tráfego de redes considerados. Por fim, comparamos através de simulações o algoritmo proposto de predição com outros existentes na literatura.

Palavras-Chave—Tráfego de Redes, Regularidade Local, Modelagem Multifractal, Expoente de Hölder, Algoritmo de Predição.

Abstract—In this work, we investigate the adaptive estimation of the pointwise Hölder exponents of real network traffic flows. The Hölder exponent can be used to indicate the local regularity degree of a traffic process at a time instant. First of all, we present an algorithm for the estimation of the pointwise Hölder exponents based on the decay trends of wavelet coefficients in time windows. Next, we analyze some properties of the Hölder time series such as the autocorrelation function. Furthermore, we develop an adaptive algorithm for the prediction of pointwise Hölder exponents derived from the considered traffic flow data. Finally, we compare by simulations the proposed prediction algorithm to other existing algorithms in the literature.

Index Terms—Network Traffic, Local Regularity, Multifractal Modeling, Hölder exponent, Prediction Algorithm.

I. INTRODUÇÃO

As redes de comunicação modernas devem prover uma grande variedade de serviços multimídia que apresentam diferentes requisitos de qualidade de serviço (QoS) e características estatísticas. Como consequência, a gerência de recursos de rede (por exemplo, *buffers*) e o controle de congestionamento se tornam tarefas cada vez mais não triviais.

Felizmente, de tempos em tempos, ocorrem evoluções significativas em termos da compreensão e caracterização das propriedades do tráfego de redes, o que conduz a novos modelos e ferramentas. Por exemplo, se sabe que as propriedades em escala do tráfego de pacotes existem e em

escalas maiores de tempo, este pode ser modelado por um processo monofractal cujas leis em escalas são governadas pelo parâmetro de Hurst correspondente [8]. Além disso, evidências da existência de comportamento multifractal de fluxos contribuíram para uma compreensão mais completa a cerca do tráfego de redes de comunicação [5]. A teoria multifractal é capaz de explicar o comportamento do tráfego em escalas de tempo da ordem de algumas centenas de milissegundos [2]. Neste sentido, modelos de tráfego multifractal são usados para caracterizar processos de tráfego que são altamente irregulares e apresentam leis de escala mais complexas do que as de processos monofractais. A quantificação destas irregularidades pode ser feita através do expoente de Hölder que provê uma medida da regularidade local e do nível de rajadas presentes nos fluxos de tráfego.

A análise da regularidade local (nível de rajadas) dos fluxos de tráfego é uma ferramenta interessante para o controle de congestionamento quando se deseja obter alocação justa e eficiente de recursos. De fato, fluxos de tráfego com maiores níveis de rajada causam uma utilização menos eficiente dos recursos de rede [1][4].

Neste trabalho, nos focamos na estimação e predição dos expoentes de Hölder, assim como na verificação de algumas de suas propriedades. Usando estes resultados, desenvolvemos um algoritmo para predição adaptativa dos expoentes de Hölder pontuais, ou seja, dos níveis instantâneos de rajadas nos fluxos de tráfego de redes. Mais precisamente, os expoentes de Hölder são preditos a cada instante com base na amostra anterior do fluxo de tráfego.

Este artigo está organizado da seguinte forma. Na Seção II, primeiramente recordamos a definição de expoente de Hölder. Em seguida, avaliamos a possibilidade de estimação dos expoentes de Hölder em janelas de tempo. Na Seção III, apresentamos um algoritmo adaptativo para predição dos expoentes de Hölder pontuais. Na Seção IV, analisamos a eficiência do algoritmo proposto em prever a regularidade local dos processos de tráfego em cada instante de tempo. Finalmente, na Seção V, apresentamos as conclusões obtidas.

II. REGULARIDADE LOCAL DO TRÁFEGO DE REDES

O expoente de Hölder pontual é capaz de descrever o grau de regularidade local de um processo, o que é interessante para a caracterização das rajadas de dados em redes de computadores. De fato, o expoente de Hölder tem se tornado um parâmetro útil na caracterização de tráfego que é complexo e apresenta um comportamento rico em rajadas [6]. O expoente de Hölder pontual é definido da seguinte forma:

Flávio Henrique Teles Vieira, Escola de Engenharia Elétrica e de Computação, Universidade Federal de Goiás, Av. Universitária, n. 1488 - 74605-010, Setor Leste Universitário, Goiânia, Goiás, email: flavio@eee.ufg.br

L. L. Ling, C. Jorge e J. Stênico, Departamento de Comunicações, FEEC, Unicamp, CP 6101, 13.083-852, Campinas, São Paulo. Este trabalho foi parcialmente financiado pela FAPESP (Proc.06/60363-6).

Definição 1 (Expoente de Hölder pontual): Seja α um número real estritamente positivo, K uma constante e $x_0 \in R$. A função $f : R \rightarrow R$ é $C^\alpha(x_0)$ se existir um polinômio P_n de grau $n < \alpha$ tal que

$$|f(x) - P_n(x - x_0)| \leq K |x - x_0|^\alpha \quad (1)$$

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

$$\alpha_p(x_0) = \sup\{\alpha > 0 \mid f \in C^\alpha(x_0)\} \quad (2)$$

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 [3].

A. Estimativa da Regularidade Local

Um dos motivos do desenvolvimento do algoritmo de estimativa dos expoentes de Hölder originalmente proposto em [6] foi o desejo de se correlacionar irregularidades locais do tráfego de redes WAN com mecanismos específicos de rede como ações para estabelecimento de conexões, controle de taxa dos fluxos, etc.

Seja um processo de tráfego contendo 2^n amostras na escala de tempo j . Denotemos por $d_{j,k}$ os coeficientes wavelet obtidos pela correlação da processo/função f com a função wavelet-mãe ψ (a wavelet ψ possui média zero e é transladada por $2^j k$ e dilatada por 2^{-j} com $j, k \in Z$), ou seja [9]:

$$d_{j,k} = 2^{-j} \int_{-\infty}^{\infty} f(x) \psi(2^{-j} x - k) dx \quad (3)$$

O grau de variação da função f é proporcional a magnitude do coeficiente wavelet $d_{j,k}$ no ponto $2^j k$ [2]. Essa propriedade pode ser utilizada para se caracterizar as singularidades do processo que podem ser explicitamente quantificadas pelo decaimento dos valores absolutos dos coeficientes wavelets $d_{j,k}$ [3].

A estimativa do expoente de Hölder pontual para uma amostra k_0 pode ser feita considerando os seguintes passos [6]:

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

$$x_j(k) = \log_2(2^j + |2^j k - x_0|) \quad (4)$$

$$y_j(k) = \log_2(|d_{j,k}|) \quad (5)$$

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

1. A reta D deve estar acima de todos os pontos $(x_j(k), y_j(k))$, ou seja:

$$\forall j, \forall k, y_j(k) \geq \alpha x_j(k) + C \quad (6)$$

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

$$\lim_{m \rightarrow \infty} y_{j_m}(k_m) - (\alpha x_{j_m}(k_m) + C) = 0 \quad (7)$$

Passo 3) Calcule α_{max} o maior coeficiente angular encontrado em todas as retas D satisfazendo (6) e (7). O coeficiente α_{max} é o expoente de Hölder pontual do sinal para a amostra k_0 .

A fim de se obter determinada precisão com o algoritmo descrito acima, alguns aspectos devem ser considerados, como por exemplo, as funções wavelet, o número de escalas j (que é limitada pelo número de amostras do processo), etc. Em nossa implementação, utilizamos a wavelet-mãe Morlet cujo suporte é limitado ao intervalo $[-4, 4]$ [9].

Outra consideração importante diz respeito a “nuvem” de pontos $(x_j(k), y_j(k))$ para estimativa do expoente de Hölder no ponto k_0 . Adotamos a restrição $3 \leq x(j, k) \leq \log_2(2^n) - 2$, para obtenção da nuvem de pontos sendo 2^n o número de amostras do processo. Esta condição garante que um número de amostras suficiente seja considerado, permitindo que o expoente de Hölder para o instante de tempo k_0 seja estimado como o coeficiente angular da reta que toca o topo dessa nuvem de pontos [3]. A Figura 1 mostra o traço de tráfego Internet *lbl-pkt-5*, assim como os correspondentes expoentes de Hölder pontuais para esta série [10].




Fig. 1 – À esquerda: amostras do traço de tráfego *lbl-pkt-5* na escala de 100 ms. À direita: expoentes de Hölder pontuais.

B. Estimativa do Expoente de Hölder Pontual em Janelas de Tempo

Nesta seção, propomos uma estratégia dinâmica para a estimativa 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 estimativa do expoente de Hölder pontual relativo a cada amostra do processo. 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 estimativa do expoente em cada instante de tempo.

A diminuição da quantidade de coeficientes wavelet utilizada em cada estimativa 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 200ms [10]. 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 [11]:

$$EQMN = \frac{E[(h_{ref} - h_{jan})^2]}{\sigma^2_{h_{ref}}} \quad (8)$$

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
EQMN DE ESTIMAÇÃO DOS EXPOENTES DE HÖLDER

	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.2. 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 2, verifica-se que ao se diminuir o tamanho da janela, aumenta-se a imprecisão (maior EQMN) 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. Note também que o erro quadrático médio de predição pode variar para cada série de tráfego considerada devido a diferentes dificuldades de predição de amostras dessas séries.

III. PREDIÇÃO DO EXPOENTE DE HÖLDER PONTUAL

Pode-se afirmar que a série temporal formada pelos expoentes de Hölder é mais apropriada para se realizar predição de suas amostras 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 predição. Neste trabalho nos focamos na predição dos expoentes de Hölder. Já um estudo sobre predição de amostras de séries de tráfego multifractais pode ser encontrado em [13]. A Figura 3 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 [1]. 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 predição de séries temporais, tais como o filtro LMS (Least-Mean Squares) e o filtro de Kalman para a predição dos valores dos expoentes de Hölder [11].

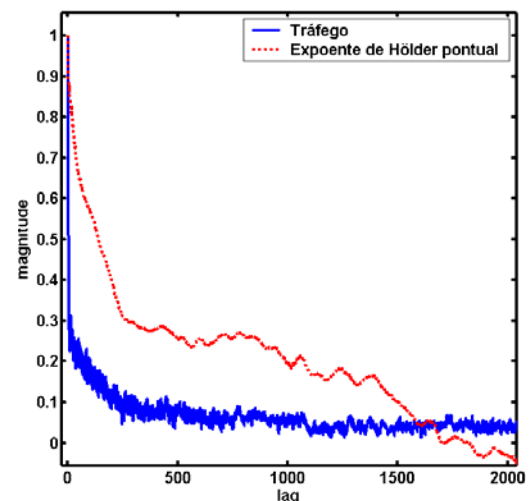


Fig. 3 – Função de autocorrelação das amostras de uma série de tráfego e de seus respectivos expoentes de Hölder pontuais.

Apresentaremos na próxima seção um algoritmo adaptativo de predição aplicado à predição 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, tornando possível se disponibilizar essa informação para os mecanismos de controle de tráfego.

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

Um dos algoritmos adaptativos de predição 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 [7][11]. 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 predições dos expoentes de Hölder.

Seja o modelo de sistema descrito pelas seguintes equações no espaço de estado [11]:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \boldsymbol{\eta}_1(k) \quad (9)$$

$$y(k) = \mathbf{u}^T(k)\mathbf{w}(k) + \eta_2(k) \quad (10)$$

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:

$$\mathbf{Q}(k) = E[\boldsymbol{\eta}_1(k)\boldsymbol{\eta}_1^T(k)] \quad (11)$$

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:

$$P(k) = E[\eta_2^2(k)] \quad (12)$$

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.

Como $\mathbf{w}(k)$ é 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) [11]. Temos então:

$$\boldsymbol{\eta}_1(k) = \frac{\tilde{\mu}}{\|\mathbf{u}(k)\|^2} [\mathbf{u}(k)e(k)] \quad (13)$$

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

Segundo a equação (10), o ruído de medida $\eta_2(k)$ é dado por:

$$\eta_2(k) = y(k) - \mathbf{u}^T(k)\mathbf{w}(k) = e(k) \quad (14)$$

Objetivamos o cálculo adaptativo dos ruídos de predição. Então, utilizaremos as seguintes equações recursivas para a média $\bar{\eta}_2(k)$ e a variância $P(k)$ de $\eta_2(k)$ [12]:

$$\bar{\eta}_2(k) = \frac{k-1}{k}\bar{\eta}_2(k-1) + \frac{1}{k}\eta_2(k) \quad (15)$$

$$P(k) = \frac{k-1}{k}P(k-1) + \frac{1}{k}(\eta_2(k) - \bar{\eta}_2(k))^2 \quad (16)$$

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:

$$q_j(k) = \frac{k-1}{k}q_j(k-1) + \frac{1}{k}(\eta_{1,j}(k) - \bar{\eta}_{1,j}(k))^2 \quad (17)$$

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

$$\mathbf{Q}(k) = \begin{bmatrix} q_1(k) & \dots & 0 & 0 \\ \vdots & q_2(k) & \dots & 0 \\ 0 & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & q_N(k) \end{bmatrix} \quad (18)$$

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 $\mathbf{K}(k)$:

$$\mathbf{K}(k) = \frac{\mathbf{P}(k)\mathbf{u}(k)}{\mathbf{u}^T(k)\mathbf{P}(k)\mathbf{u}(k) + r(k)} \quad (19)$$

Passo 2) Atualiza-se os pesos:

$$\hat{\mathbf{w}}(k+1) = \hat{\mathbf{w}}(k) + \mathbf{K}(k)[y(k) - \mathbf{u}^T(k)\hat{\mathbf{w}}(k)] \quad (20)$$

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

$$\bar{\eta}_2(k) = \frac{k-1}{k}\bar{\eta}_2(k-1) + \frac{1}{k}\eta_2(k) \quad (21)$$

$$P(k) = \frac{k-1}{k}P(k-1) + \frac{1}{k}(\eta_2(k) - \bar{\eta}_2(k))^2 \quad (22)$$

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

$$q_j(k) = \frac{k-1}{k}q_j(k-1) + \frac{1}{k}(\eta_{1,j}(k) - \bar{\eta}_{1,j}(k))^2 \quad (23)$$

$$\mathbf{Q}(k) = \begin{bmatrix} q_1(k) & \dots & 0 & 0 \\ \vdots & q_2(k) & \dots & 0 \\ 0 & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & q_N(k) \end{bmatrix} \quad (24)$$

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

$$\mathbf{P}(k+1) = \mathbf{P}(k) + \mathbf{Q}(k) - \mathbf{K}(k)\mathbf{u}^T(k)\mathbf{P}(k) \quad (25)$$

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

$$\hat{y}(k+1) = \mathbf{u}^T(k+1)\hat{\mathbf{w}}(k+1) \quad (26)$$

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

IV. AVALIAÇÃO DO ALGORITMO DE PREDIÇÃO 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 EQMN 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:

$$\hat{\mathbf{w}}(0) \cong 0 \quad (27)$$

$$K(0) = \hat{\mathbf{w}}(0)\hat{\mathbf{w}}(0)^T \quad (28)$$

No algoritmo de predição proposto assumimos que o ruído do processo e o ruído de medida são gaussianos com média zero e descorrelacionados. Para mostrar que essas considerações são razoáveis, avaliamos a função de autocorrelação e os histogramas de um componente do ruído de processo $\boldsymbol{\eta}_1(k)$ e do ruído de medida $\eta_2(k)$, respectivamente (Figuras 4 e 5). Nota-se claramente que os ruídos de processo $\boldsymbol{\eta}_1(k)$ e de medida $\eta_2(k)$ possuem cada um: média zero, distribuição gaussiana e são descorrelacionados. Resultados similares são obtidos para outros traços de tráfego de redes.




Fig.4 – À esquerda: função de autocorrelação de amostras de um componente do ruído $\boldsymbol{\eta}_1(k)$. À direita: histograma obtido com os valores de um dos componentes do ruído $\boldsymbol{\eta}_1(k)$.

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 [11][12]:

$$EQMN1 = \frac{E[(h_{pred} - h_{jan})^2]}{\sigma^2_{h_{jan}}} \quad (29)$$

$$EQMN2 = \frac{E[(h_{pred} - h_{jan})^2]}{E[(h_{ua} - h_{jan})^2]} \quad (30)$$

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} .




Fig. 5 – À esquerda: função de autocorrelação das amostras do processo de ruído de medida $\eta_2(k)$. À direita: histograma obtido com essas mesmas amostras.

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 processo 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 e o filtro de Kalman. A ordem do filtro considerada para os preditores NLMS e Kalman é a mesma para o preditor proposto ($N=7$). O valor do passo de adaptação $\tilde{\mu}$ do preditor NLMS é escolhido de forma a obter o menor erro quadrático médio possível para cada série de tráfego analisada. A principal diferença entre o preditor de Kalman e o preditor proposto é que o preditor de Kalman apresenta ruídos ($\boldsymbol{\eta}_1(k)$ e $\eta_2(k)$) com média zero e variância constante. Enquanto que em nossa proposta, as covariâncias $Q(k)$ e $P(k)$ são estimadas adaptativamente.

Verificamos o desempenho do algoritmo proposto em prever os expoentes de Hölder levando em consideração diferentes janela de tempo, ou seja, janelas 11, 12, 13 e sem restrições de janela, conforme Tabela II. Já as Tabelas III e IV comparam o desempenho do algoritmo proposto com relação aos preditores NLMS e Kalman. Observando as tabelas apresentadas, pode-se constatar que além de possuir EQMNs menores que a unidade, o preditor proposto também possui EQMNs menores do que aqueles referentes aos preditores NLMS e Kalman. Mas note que apenas conseguimos esses resultados com o preditor de Kalman

porque utilizamos neste algoritmo os valores finais de $P(k)$ e $Q(k)$ do algoritmo proposto.

TABELA II

EQMNS DE 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

TABELA III

EQMN DE PREDIÇÃO DOS EXPOENTES DE HÖLDER PONTUAIS PARA O TRAÇO DE TRÁFEGO DEC-PKT-1 NA ESCALA DE 200MS (UTILIZANDO UMA JANELA 12).

	EQMN1	EQMN2
proposta	0.3104	0.5729
NLMS	0.3248	0.5994
Kalman	0.3106	0.5733

TABELA IV

EQMN DE PREDIÇÃO DOS EXPOENTES DE HÖLDER PONTUAIS PARA O TRAÇO DE TRÁFEGO LBL-PKT-5 NA ESCALA DE 200MS (UTILIZANDO UMA JANELA 12).

	EQMN1	EQMN2
proposta	0.1372	0.5825
NLMS	0.1423	0.6042
Kalman	0.1373	0.5826

Outro fator importante na verificação da eficiência de um preditor é o decaimento do erro quadrático com o tempo. O decaimento temporal do erro quadrático de predição para a série *lbl-pkt-5* é mostrado na Figura 6. Esta figura nos mostra que o preditor proposto possui um decaimento mais acelerado 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. 6 - Erro quadrático de predição dos expoentes de Hölder de amostras da série *lbl-pkt-5* nas escalas de tempo de 100 ms.

V. CONCLUSÕES

A predição (e também o controle) 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.

A predição do comportamento em rajadas é importante para que ações sejam tomadas a tempo de modo a evitar congestionamento. O preditor proposto se mostrou robusto e preciso em escalas de tempo distintas, mesmo para processos com características complexas, como é o caso das séries formadas pelos expoentes de Hölder pontuais. Em comparação a outros preditores lineares, o preditor proposto proporcionou menor erro quadrático médio de predição. Como no preditor proposto os ruídos de medida e de processo são calculados adaptativamente, o mesmo apresenta melhor desempenho de predição quando estes ruídos são variantes no tempo.

Em trabalhos futuros, aplicaremos o algoritmo de predição proposto em cenários de rede envolvendo diferentes protocolos.

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] 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.
- [3] S. Jaffard, “Exposants de Hölder en des points donnés et coefficients d’ondelettes”, *C. R. Acad. Sci, Paris*, Vol. 30, No. 8, pp. 79-81, 1989.
- [4] 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.
- [5] R. H. Riedi, J. Lévy-Véhel, “TCP traffic is multifractal: a numerical study”, *Technical Report, INRIA Rocquencourt*, No. 3129, Mar. 1997.
- [6] S. Seuret, A. C. Gilbert, “Pointwise Hölder exponent estimation in data network traffic”, *ITC Specialist Seminar, Monterey*, Setembro 2000.
- [7] D. A. Rolls, G. Michailidis and F.H. Campos. *Queuing analysis of network traffic: methodology and visualization tools*. *Computer Networks*, v. 48, pp. 447-473, 2005.
- [8] I. W. C. Lee and A. O. Fapojuwo. *Stochastic processes for computer network traffic modeling*. *Computer Communications*, 29, pp. 1-23, 2005.
- [9] I. Daubechies, *Ten Lectures on Wavelets*, Philadelphia: SIAM, 1992.
- [10] The Internet Traffic Archive: <http://ita.ee.lbl.gov/>
- [11] S. Haykin, *Adaptive Filter Theory*, Nova Jersey: Prentice Hall, 1991.
- [12] P. Young, *Recursive Estimation and Time-series Analysis*, Nova York: Springer-Verlag, 1984.
- [13] G. R. Bianchi, F. H. T. Vieira, L.L. Ling. “A Novel Network Traffic Predictor based on Multifractal Traffic Characteristics”, *IEEE Globecom*, v.2, 29 de Nov. a 3 de Dez., pp. 680 – 684, 2004.