

Estimação de Banda Efetiva Dinâmica em Redes de Computadores Utilizando uma Modelagem Auto-Regressiva Nebulosa

Flávio Henrique Teles Vieira, Gabriel Rocon Bianchi, Lee Luan Ling e Rodrigo Pinto Lemos

Resumo—Neste artigo a modelagem auto-regressiva (AR) nebulosa descrita em [1] é usada para modelar e prever o tráfego de redes de alta velocidade. Este modelo aproxima um processo não-linear complexo variante no tempo por uma combinação de processos auto-regressivos lineares locais usando um algoritmo de classificação (clustering) nebuloso. A partir deste modelo, propomos um método para calcular a banda efetiva do tráfego em que se usa os coeficientes lineares da modelagem AR nebulosa, considerando o tráfego estacionário em curtos intervalos de tempo. Propomos assim, um método de alocação de taxa através da banda efetiva calculada dinamicamente para prover controle eficiente do tráfego das redes. Finalmente, simulações com traços reais de tráfego demonstram a validade e desempenho das predições e do método de alocação de taxa baseada na banda efetiva dinâmica.

Palavras-Chave— Modelagem difusa, predição, tráfego de redes, alocação de taxa, perda de bytes.

Abstract—In this paper a fuzzy autoregressive (AR) model described in [1] is used to model and predict high-speed network traffic. This model approximates a complex nonlinear time-variant process by combining linear local autoregressive processes using a fuzzy clustering algorithm. We propose a method to estimate the traffic effective bandwidth at regular intervals, assuming the traffic can be described by AR models obtained with the fuzzy modeling. The linear coefficients of the fuzzy-AR modeling are used to estimate the effective bandwidth for the network traffic considering it is stationary at short time intervals. Using this traffic modeling, an effective bandwidth based rate allocation method is suggested to provide efficient traffic management. Finally, simulations with real traffic traces demonstrate the validity and performance of the predictions and the rate allocation method based on dynamic effective bandwidth.

Index Terms— Fuzzy modeling, prediction, network traffic, rate allocation, byte loss.

Flávio Henrique Teles Vieira, Gabriel Rocon Bianchi e Lee Luan Ling, pertencem à Unicamp, Departamento de Comunicações (DECOM), São Paulo, Brasil, e-mails: flavio,bianchi,lee@decom.fee.unicamp.br.

Rodrigo Pinto Lemos pertence à Universidade Federal de Goiás (UFG), Goiânia, GO, Brasil, email: {lemos@eee.ufg.br}. Este trabalho teve apoio da Ericson Research (Contrato UNI-20/2320).

I. INTRODUÇÃO

Redes de alta velocidade oferecem grande flexibilidade e eficiência através da multiplexação estatística de diferentes tipos de tráfego com características estatísticas particulares. Esta flexibilidade em acomodar diferentes fontes de tráfego pode levar a maiores problemas de congestionamento. Um modelo preciso de tráfego é necessário para o controle de congestionamento em redes de alta velocidade. Se os modelos de tráfego de rede não forem precisos, eles podem superestimar ou subestimar os recursos disponíveis da rede.

Para prover garantia de qualidade de serviço (QoS) para usuários, como perda de bytes e atraso, os fluxos de tráfego nos *switches* precisam ser controlados. O conceito de banda efetiva simplifica a alocação de recursos da rede porque pode associar um valor de banda para um fluxo de dados e deste modo estimar a capacidade do enlace para garantir qualidade de serviço desejada. Pela teoria dos grandes desvios que se baseia no decaimento exponencial da probabilidade de cauda de uma fila, pode-se calcular a banda efetiva de uma ou várias fontes de tráfego.

Quando o processo de tempo de chegada e tamanho de pacotes têm propriedades estocásticas “simples”, soluções baseadas em teoria de filas existem para retardos de fila e probabilidades de perda de pacote [8]. Estas soluções podem ser usadas para alocação de banda e dimensionamento de *buffer*. Entretanto, os fluxos de tráfego nas modernas redes multiserviço exibem freqüentemente um comportamento estocástico mais complexo tornando mais difícil e desafiadora uma apropriada alocação de banda e dimensionamento de *buffer*.

Muitos estudos em modelagem nebulosa têm sido realizados desde que a teoria *fuzzy* foi inicialmente desenvolvida [2]. A razão para estas pesquisas é que os modelos nebulosos têm vantagens para descrever determinados sistemas em relação aos modelos lineares. A modelagem nebulosa tem sido aplicada como um poderoso método para descrever processos desconhecidos reais, complexos com características não-lineares e variantes no tempo como o tráfego de redes de alta velocidade [7].

O modelo nebuloso sugerido por Takagi e Sugeno em 1985 [3] tem uma capacidade excelente, porém é complexo e consome muito tempo. O modelo nebuloso de Sugeno e

Yasukawa [4] é mais fácil de implementar, mas precisa de mais regras nebulosas do que o modelo de Takagi e Sugeno.

O algoritmo proposto em [1] pode descrever um determinado sistema desconhecido com um pequeno número de regras nebulosas como o modelo de Takagi e Sugeno e é de fácil implementação como o modelo de Sugeno e Yasukawa.

Propomos através de uma equação de banda efetiva para fontes estacionárias estimar a banda efetiva do tráfego em intervalos regulares de tempo de modo a garantir um limiar de perda nesses intervalos. Para isto assumimos que nesses intervalos o tráfego pode ser descrito pelos coeficientes lineares AR (auto-regressivos) obtidos com a modelagem nebulosa.

Nas seções II, III e IV, nós descrevemos o algoritmo de modelagem nebulosa. Na seção V, o método proposto para calcular a banda efetiva em tempo real é descrito. Na seção VI, demonstramos a validade e desempenho do nosso método através de simulações.

II. MODELAGEM AUTO-REGRESSIVA NEBULOSA

Nesta modelagem nebulosa, o tráfego é dividido em *clusters* através de agrupamentos nebulosos com cada *cluster* descrito por um modelo AR. O tráfego de dados então pode ser representado pela combinação de vários modelos AR via regras nebulosas como a que segue:

$$\begin{aligned} \text{Regra } R^l : & \text{ Se } y(n) \text{ é } M_1^l(q_{11}^l, q_{12}^l) \\ & \text{ e } y(n-1) \text{ é } M_2^l(q_{21}^l, q_{22}^l), \dots, \\ & \text{ e } y(n-p+1) \text{ é } M_p^l(q_{p1}^l, q_{p2}^l) \\ \text{então } & y_i(n+1) = a_{i,0} + a_{i,1}y(n) + \dots + a_{i,p}y(n-p+1) \end{aligned} \quad (1)$$

onde R^l ($l=1, \dots, c$) denota a l -ésima regra nebulosa; $y(n-j)$ ($j=0, \dots, p-1$) corresponde à série de tráfego no instante de tempo $n-j$; $y(n+1)$ é a saída da regra nebulosa R^l . Inerentemente, este é um modelo do tipo preditivo pela forma da saída do modelo. M_j^l s são funções de pertinência gaussianas com duas variáveis q_{jk}^l , $k=1,2$ na j -ésima função de pertinência nebulosa da l -ésima regra:

$$M_j^l(q_{j1}^l, q_{j2}^l) = \exp\left\{-\left(\frac{y(n-j) - q_{j1}^l}{q_{j2}^l}\right)^2\right\} \quad (2)$$

O modelo auto-regressivo nebuloso faz uso das regras nebulosas pelas seguintes equações:

$$\hat{y}(n+1) = \frac{\sum_{l=1}^c w_l y_l(n+1)}{\sum_{l=1}^c w_l} \quad (3)$$

$$w_l = \prod_{j=1}^p M_j^l(q_{j1}^l, q_{j2}^l) \quad (4)$$

ou seja, o modelo AR nebuloso em (1) é equivalente a uma combinação não-linear e variante no tempo de modelos auto-

regressivos locais.

Para identificar os parâmetros consequentes $a_{l,j}$, a primeira coisa a fazer é decidir qual regra toma conta de quais dados. Para isto, um modelo de regressão nebuloso de classificação (FCRM), uma versão modificada do FCM é aplicado, desenvolvendo *clusters* com formas hiperplanas [5]. Entretanto, o FCRM identifica os parâmetros do modelo nebuloso de modo aproximado, assim um procedimento de ajuste fino é em seguida aplicado baseado em algoritmo de gradiente descendente. Ambos procedimentos, de ajuste aproximado e fino, podem ser repetidos para achar um número apropriado de *clusters*. Mostraremos como determinar os parâmetros consequentes ótimos $a_{l,j}$ e os parâmetros de premissa q_{jk}^l a fim de minimizar um índice de desempenho tomado como sendo o EQMN (erro quadrático médio normalizado) de predição do modelo nebuloso.

Em geral, o aumento do número de regras nebulosas ou o número de coeficientes AR resultam em um modelo mais preciso, ou seja, em um menor EQMN [7].

III. AJUSTE APROXIMADO POR FCRM

O modelo AR linear local no l -ésimo *cluster* pode ser reescrito da seguinte forma:

$$y_i(n+1) = Z^T(n) A_l \quad (5)$$

onde $Z(n) = [1, y(n), y(n-1), \dots, y(n-p+1)]^T$ e $A_l = [a_{l,0}, a_{l,1}, \dots, a_{l,p}]^T$. Podemos obter de forma aproximada os parâmetros A_l do modelo AR pelos seguintes passos:

Passo 1) Inicie com $M=0$. Defina uma matriz U de dimensão cxn como em [6]:

$$U = \begin{bmatrix} u_{1,1} & u_{1,2} & \dots & u_{1,n} \\ u_{2,1} & u_{2,2} & \dots & u_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ u_{c,1} & u_{c,2} & \dots & u_{c,n} \end{bmatrix}$$

$$0 \leq u_{l,j} \leq 1, \text{ onde } 1 \leq l \leq c, 1 \leq j \leq n \quad (6)$$

e

$$\sum_{l=1}^c u_{l,j} = 1, \quad \forall j = 1, \dots, n \quad (7)$$

em que $u_{l,j}$ são valores aleatórios que satisfazem as restrições (6) e (7).

Passo 2) Na M -ésima iteração a função custo do algoritmo FCRM é dada por:

$$J = \sum_{l=1}^c \sum_{j=1}^n u_{l,j}^m d_{l,j}^2 \quad (8)$$

onde $d_{l,j} = \|y(j) - Z^T(j-1)A_l\|$. A condição necessária para que (8) atinja seu mínimo é que [7]:

$$u_{l,j} = \frac{1}{\sum_{l=1}^c \left(\frac{d_{l,j}}{d_{k,j}} \right)^{\frac{2}{m-1}}} \quad (9)$$

Portanto, calcula-se uma nova matriz U pela equação (9).

Passo 3) Se a função custo for menor do que um certo valor o algoritmo é finalizado, senão vá para o passo 4.

Passo 4) Usando os $u_{l,k}$ s obtidos no passo 2 calcule os parâmetros A_l pelo algoritmo de mínimos quadráticos recursivos ponderado (WRLS) descrito abaixo:

$$A_l(k+1) = A_l(k) + H(k)[y(k+1) - Z^T(k)A_l(k)] \quad (10)$$

$$H(n) = \frac{S(k)Z(k)}{\frac{1}{u_{l,k}} + Z^T(k)S(k)Z(k)} \quad (11)$$

$$S(k+1) = (I - H(k)Z^T(k)).S(k) \quad (12)$$

onde $k=1,2,\dots,n$ e $l=1,2,\dots,c$. No início do algoritmo WRLS temos $S(0) = \alpha I$, $\alpha > 100$.

Passo 5) Vá ao passo 2 e incremente M de um.

Pode-se obter estimativas de q_{j1}^l e q_{j2}^l para as funções de pertinência gaussianas pelas equações [1]:

$$q_{j,1}^l = \frac{\sum_{k=1}^n u_{l,k} y(k-j)}{\sum_{k=1}^n u_{l,k}} \quad (13)$$

$$q_{j,2}^l = \sqrt{\frac{\sum_{k=1}^n u_{l,k} (y(k-j) - q_{j,1}^l)^2}{\sum_{k=1}^n u_{l,k}}} \quad (14)$$

IV. AJUSTE FINO POR ALGORITMO DE GRADIENTE DESCENDENTE

Os parâmetros consequentes ótimos representados por A^* podem ser determinados pelo método de mínimos quadrados que é um problema de estimação linear. Já, a determinação dos q_{jk}^l s ótimos é não-linear. O método de ajuste fino possui um procedimento de ajuste dos parâmetros consequentes e de premissa:

a) Procedimento de ajuste dos parâmetros de premissa:

Os parâmetros de premissa q_{jk}^l s do modelo AR nebuloso podem ser ajustados pela equação:

$$\Delta q_{jk}^l(n+1) = \eta(y(n) - \hat{y}(n)).(y(n) - \hat{y}(n)). \frac{1}{\sum_{l=1}^c w_l} \frac{\partial w_l}{\partial q_{jk}^l} \quad (15)$$

onde η é uma taxa de aprendizagem, $y(n)$ é a intensidade de

tráfego atual, $\hat{y}(n)$ é a saída do modelo nebuloso e $e(n) = y(n) - \hat{y}(n)$, o erro de predição do modelo.

b) Procedimento de cálculo dos parâmetros consequentes:

Os parâmetros consequentes A do modelo nebuloso AR de tráfego são ajustados de forma precisa pela equação:

$$\Delta a_{l,j}(n+1) = \gamma(y(n) - \hat{y}(n)).w_l \frac{y(n-j)}{\sum_{l=1}^c w_l} \quad (16)$$

onde γ é uma outra taxa de aprendizagem.

Uma vez que os parâmetros q_{jk}^l s e $a_{l,j}$ s foram estimados a partir do tráfego real uma predição a um passo $\hat{y}(n+1)$ pode ser obtida pelos dados de tráfego em instantes anteriores por (1), (4) e (3).

Inicialmente o ajuste aproximado descrito na seção III tem o papel mais importante na estimação dos parâmetros do modelo. Com a convergência do cálculo dos parâmetros do modelo, só o ajuste fino é pode ser aplicado [7]. Portanto, pode-se atualizar o modelo com o ajuste fino evitando-se custo computacional com o cálculo realizado no ajuste fino. A modelagem nebulosa apresentada aqui tem convergência excelente sendo capaz de prever o tráfego de pacote em redes de alta velocidade como será visto na seção VI.

V. BANDA EFETIVA PARA FONTES ESTACIONÁRIAS

A banda efetiva é uma ferramenta útil para análise e descrição do tráfego em redes. Tem como limite inferior a taxa média e limite superior a taxa de pico do fluxo de tráfego. Pode-se dizer que a banda efetiva dado um tamanho de *buffer*, representa a taxa de serviço que é efetivamente necessária para servir um fluxo de tráfego respeitando uma determinada probabilidade de perda. Seja $X[0,t]$ o tráfego acumulado durante um intervalo de tempo $[0,t]$ para um fluxo de tráfego. A banda efetiva do fluxo de tráfego é definida pela equação [8].

$$\alpha(s) = \lim_{t \rightarrow \infty} \frac{1}{st} \log E(e^{sX[0,t]}) \quad (17)$$

que é uma função de $s > 0$. Na teoria de banda efetiva, s representa a taxa de decaimento exponencial assintótico da distribuição do tamanho da fila. Ou seja, quando a taxa de serviço é $\alpha(s)$, a cauda da distribuição de probabilidade do tamanho da fila Q é dada por:

$$P(Q > B) \approx \exp(-sB) \quad (18)$$

Coucorbetis e Walrand [9] estabeleceram que para uma dada probabilidade de perda de bytes menor do que $\exp(-sB)$ e para um processo estacionário gaussiano sua banda efetiva pode ser dada pela equação:

$$E = \mu + \frac{s\gamma}{2B} \quad (19)$$

onde B é o tamanho do *buffer*, μ é a média do processo e:

$$\gamma = \pi f(0) \quad (20)$$

comumente chamado de índice de dispersão, é dado em função da densidade espectral de potência na frequência zero. Portanto, γ pode ser estimado a partir dos dados de tráfego através de técnicas de estimação espectral. Coucorbetis e Weber ainda afirmam que esta banda efetiva não só é apropriada para fontes de tráfego gaussianas, mas também para outras fontes estacionárias, como por exemplo, para processos auto-regressivos [10]. A equação (19) expressa a banda efetiva em termos de dois parâmetros: a taxa média da fonte e seu índice de dispersão. Ela permite estimar a banda efetiva para o fluxo de tráfego através de medidas em tempo real. O índice de dispersão mede o quanto de rajadas possui a fonte (burstiness) [9].

A equação de saída do modelo nebuloso descrito anteriormente pode ser escrita como:

$$\hat{y}(n+1) = \frac{\sum_{l=1}^c w_l y_l(n+1)}{\sum_{l=1}^c w_l} = \sum_{i=1}^c \left(a_0^i \frac{w_i}{\sum_{j=1}^c w_j} + a_1^i \frac{w_i}{\sum_{j=1}^c w_j} x_1 + \dots + a_m^i \frac{w_i}{\sum_{j=1}^c w_j} x_m \right) \quad (21)$$

onde os parâmetros do modelo nebuloso podem ser expressos como:

$$\theta_k = a_k^i \frac{w_i}{\sum_{j=1}^c w_j} \quad (22)$$

Os parâmetros do modelo auto-regressivo θ_k podem ser usados na estimação adaptativa de banda efetiva por (19) através de alguma técnica de estimação espectral. Utilizou-se para tal, o método da covariância modificada descrito em [11]. Com o método da covariância modificada encontra-se os parâmetros do modelo auto-regressivo pela solução de um conjunto de equações lineares e pela minimização da soma dos erros de predição quadráticos diretos e retrógrados. Em oposição à outros métodos de estimação espectral auto-regressivos, com o método da covariância modificada se obtém estimativas de espectros estatisticamente estáveis com alta resolução e não-sujeitos à divisão espectral [11].

V.Solo e R.A.Vesilo propuseram uma técnica de estimação adaptativa de banda efetiva aplicada a representações lineares de processos estocásticos [12]. Em [13] também é proposto um método para estimação "on-line" de banda efetiva. Mas diferente destas propostas, usamos um modelo nebuloso para encontrar os coeficientes lineares que modelam o processo e que servem para estimar a banda efetiva, garantindo um limite de perda de bytes para o tráfego em curtos intervalos de tempo. A banda efetiva apresentada nos artigos citados e presentes na literatura leva em consideração todo tráfego ou um grande número de amostras. Neste trabalho, propomos um

método para aplicar a banda efetiva estimada dinamicamente em qualquer ponto da série temporal de tráfego de modo a garantir um limite de perda de bytes em tempo real.

VI. SIMULAÇÕES E RESULTADOS

As predições de tráfego de redes de computadores efetuadas pelo modelo nebuloso podem ser usadas no controle de tráfego dado que seus erros de predição são comparáveis a outros métodos tais como redes neurais [14].

A fim de avaliarmos o desempenho das predições utilizou-se o erro quadrático médio normalizado dado por:

$$EQMN = \frac{1}{\sigma^2 p} \sum_{n=1}^p [y(n) - \hat{y}(n)]^2 \quad (23)$$

onde $y(n)$ é o valor real das séries de tráfego, $\hat{y}(n)$ é o valor predito, σ^2 é a variância da série real sob o intervalo de predição e p é o número de amostras de teste.

Para demonstrar que a modelagem nebulosa prediz e modela de forma satisfatória o tráfego, usamos dois traços de tráfego TCP/IP (dec-pkt-1.tcp e dec-pkt-2.tcp) obtidos da Digital Equipment Corporation [15]. Considerou-se 2048 amostras de tráfego com uma escala de agregação de 512ms para os traços de tráfego TCP/IP. Também usamos traços de tráfego Ethernet obtidos da Bellcore¹ que apresentam características auto-similares e multifractais. Estes traços são: Bc-Octext na escala de tempo de agregação de 1min com 2046 pontos e o traço de tráfego Bc-Octint com 1759 amostras na escala de tempo de 1s.

Foram efetuadas predições a um passo das séries temporais de tráfego Bc-Octext, Bc-Octint, dec-pkt-1.tcp e dec-pkt-2.tcp usando duas regras nebulosas e cinco coeficientes $a_{i,j}$, $j=1,2,\dots,5$. As taxas de aprendizagem η e γ foram 0,001 e 0,01, respectivamente. A Tabela I mostra o EQMN de predição para estas séries temporais e o intervalo considerado no cálculo das predições. A Figura 1 mostra a predição a um passo para a série Bc-Octint.

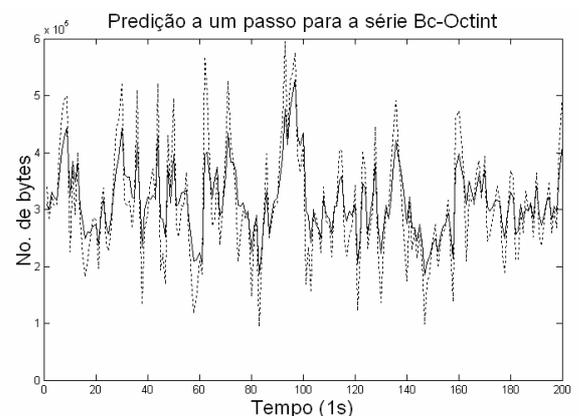


Fig.1. Predição a um passo pela modelagem nebulosa (linha sólida). Série temporal de tráfego Bc-Octint (linha pontilhada).

¹ <http://www.acm.org/sigcomm/ITA>

TABELA I
EQMN

Traço de Tráfego	Intervalo	EQMN
Bc-Octint	801-1701	0,3107
Bc-Octext	1000-2000	0,4152
Dec-pkt-1	1-2048	0,6987
Dec-pkt-2	1-2048	0,5836

A Tabela II faz uma comparação entre os valores de EQMN obtidos utilizando a modelagem nebulosa, uma rede neural MLP e uma rede recorrente treinada com algoritmo RTRL [14]. Pode-se notar que a modelagem nebulosa obtém erros de predição comparáveis aos métodos utilizando redes neurais.

TABELA II
EQMN

Traço de Tráfego	Intervalo	EQMN- <i>Fuzzy</i>	EQMN-MLP	EQMN-RTRL
Bc-Octint	801-1701	0,3107	1,21	0,3946
Bc-Octext	1000-2000	0,4152	0,4037	0,3850

Após constatar a eficiência de predição do modelo nebuloso aplicamos as predições na alocação de taxa em um enlace de rede de computadores. Simulamos um enlace de comunicação com taxa variável e *buffer* finito. As séries Bc-Octint, dec-pkt-1 e dec-pkt-2.tcp foram utilizadas na alocação dinâmica de taxa de transmissão. A Figura 2 apresenta as taxas alocadas pelas predições do modelo auto-regressivo nebuloso para o traço de tráfego dec-pkt-2.tcp. Foi obtido uma perda total de 0,3963% para 655.830.000 bytes. Mostraremos que uma alocação de taxa mais eficiente do que a baseada nas predições pode ser realizada, uma vez que as predições nem sempre acompanham bem os picos de maior intensidade de tráfego o que gera maiores perdas. Isto pode ser visto pela Figura 2.

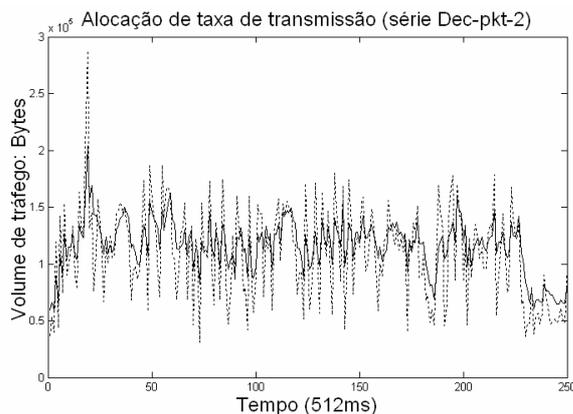


Fig. 2. Predição a um passo pelo modelo nebuloso (linha sólida). Traço de tráfego Dec-pkt-2 (linha pontilhada).

Em cada intervalo considerado utilizamos a média dos coeficientes AR no intervalo para a estimação da banda efetiva. A porcentagem de perda de bytes máxima (teórica) na Tabela III é dada por (18). Na mesma tabela, expomos a

máxima porcentagem de perda obtida nos intervalos. Conclui-se que podemos garantir que as perdas dentro dos intervalos serão menores do que o valor máximo dado por (18). Pode-se notar que a probabilidade de perda estipulada para os intervalos é maior do que as tradicionalmente analisadas para todo tráfego uma vez que estamos considerando um intervalo de tempo bem menor.

A Figure 3 mostra a banda efetiva estimada (linha tracejada) em curtos intervalos de tempo para a série temporal dec-pkt-1.tcp.

TABELA III
PORCENTAGEM DE PERDA DE BYTES NOS INTERVALOS

Traço de Tráfego	Tamanho do intervalo	Tamanho do buffer (bytes)	Perda máxima de bytes (teórico)	Perda máxima de bytes
Bc-Octint	20s	490.200	63,18%	47,38%
Dec-pkt-1	10 (x512ms)	139.330	31,62%	2,91%
Dec-pkt-2	10 (x512ms)	170.430	31,62%	16,71%

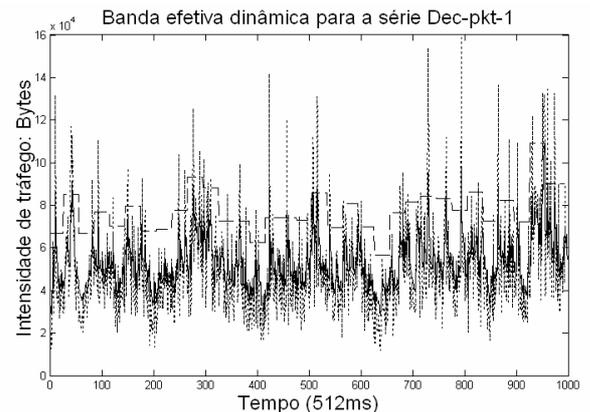


Fig. 3. Predição a um passo pela modelagem nebulosa (linha sólida). Série temporal de tráfego dec-pkt-1 (linha pontilhada). Banda efetiva dinâmica (linha tracejada).

A Tabela IV mostra a porcentagem de perda de bytes para as séries como um todo usando o método proposto baseado na banda efetiva calculada em intervalos curtos de tempo e usando as predições na alocação dinâmica de taxa de transmissão. Como pode ser visto, uma menor perda de bytes é atingida com o método baseado na banda efetiva calculada dinamicamente.

TABELA IV
PERDA DE BYTES TOTAL

Traço de Tráfego	Perda pelo método de banda efetiva dinâmica	Número de instantes de tempo	Perda usando predições
Bc-Octint	0,3600%	1700	1,1901%
Dec-pkt-1	0,0331%	2048	1,4732%
Dec-pkt-2	0,0329%	2048	0,3963%

Os seguintes dados foram obtidos com relação à ocupação do *buffer* usando a alocação de taxa baseada na predição e com o método de banda efetiva dinâmica para a série temporal de tráfego dec-pkt-1:

TABELA V
OCUPAÇÃO DO BUFFER

	Predição	Banda Efetiva Dinâmica
Número máximo de bytes no buffer	1.630.400 bytes	177.460 bytes
Número médio de bytes no buffer	505.840 bytes	3.274 bytes
Variância do número de bytes no buffer	1.099.000 bytes	628 bytes

A Tabela V mostra que se obtém uma ocupação do *buffer* mais bem comportada usando a alocação de taxa pela banda efetiva dinâmica. Com a predição realizada pelo modelo nebuloso foi obtida uma alocação de taxa média de 112.800bytes/s. Alocando esta taxa de forma única e constante (alocação estática de taxa) teríamos uma perda de 10.399.000 bytes para um *buffer* de tamanho 139.330 bytes. O método de alocação dinâmica de taxa pela banda efetiva proposto reduz este valor para 6.911 bytes perdidos. Uma perda de 0,0331% do tráfego total (2048 instantes de tempo). Portanto, o método proposto provê uma menor perda de bytes com um melhor uso do sistema (Figura 4). Aplicando somente as predições na alocação de taxa 1.698.700 bytes seriam perdidos. A Figura 4 relaciona a porcentagem de perda de bytes com o tamanho do *buffer* para os três métodos:

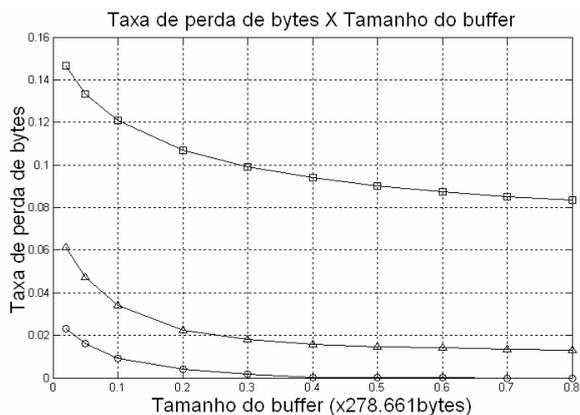


Fig.4. Relação entre a taxa de perda de bytes e o tamanho do buffer para a alocação estática de taxa (linha com quadrados), para as predições (linha com triângulos) e para o método com banda efetiva dinâmica (linha com círculos).

VII. CONCLUSÃO

A complexa interação entre os fluxos de tráfego em uma rede de alta velocidade e suas características fazem a modelagem e predição de tráfego tarefas mais difíceis e desafiadoras. Porém, o modelo AR nebuloso foi usado na

predição de tráfego real e sua capacidade foi verificada com poucas regras nebulosas.

Mostramos que com o cálculo da banda efetiva em intervalos curtos de tempo pode-se assegurar um limite de perda de bytes nestes intervalos e conseqüentemente, obter uma perda global pequena, ou seja, para o traço de tráfego inteiro. Propomos um método de controle de congestionamento que explora a idéia de banda efetiva para curtos intervalos de tempo a fim de obter informação atualizada da real taxa necessária para o tráfego de dados em um *switch*. O esquema de alocação de taxa, de acordo com a análise realizada, é uma ferramenta poderosa na otimização dos recursos em uma rede de computador, uma vez que acarreta um melhor uso da rede com uma perda menor de bytes em relação a outros métodos.

REFERÊNCIAS

- [1] E. Kim, M. Park, S. Ji, and M. Park, "A new approach to fuzzy modeling", IEEE Trans. Fuzzy Syst., vol. 5, pp. 328-337, Aug. 1997.
- [2] J. C. Bezdek "Editorial: Fuzzy models—What are they and why?," IEEE Trans. Fuzzy Syst., vol. 1, pp. 1-6, Feb. 1993.
- [3] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control," IEEE Trans. Syst., Man, Cybern., vol. SMC-15, pp. 116-132, Jan./Feb. 1985.
- [4] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling", IEEE Trans. Fuzzy Syst., vol. 1, pp. 7-31, Feb. 1993.
- [5] J. C. Bezdek, Pattern Recognition with Fuzzy Objective Functional Algorithm. New York: Plenum, 1981.
- [6] J. S. R. Jang, C. T. Sun, and E. Mizutani, "Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence". Englewood Cliffs, NJ: Prentice-Hall, 1997.
- [7] B.-S. Chen, S.-C. Peng, and K.-C. Wang, "Traffic Modeling, Prediction, and Congestion Control for High-Speed Networks: A Fuzzy AR Approach" IEEE Transactions on Fuzzy Sytems, Vol. 8, No.5, October 2000.
- [8] F.Kelly. "Notes on Effective bandwidth", in Stochastic Networks: theory and applications, Royal Statistical Society Lecture Note Series, vol.4, pp.141-168. Oxford University Press, 1996.
- [9] C.Courcoubetis, G.Fouskas and R.R.Weber. "On the performance of an effective bandwidths formula". International Teletraffic Conference, 1994.
- [10] C.Courcoubetis and R.Weber. "Effective bandwidths for stationary sources. Probability in Inform. Eng. Sci, 9:285-296, 1995.
- [11] Monson H. Hayes. "Statistical Digital Signal Processing and Modeling". John Wiley of Sons., 1996.
- [12] V. Solo. "Adaptive estimation of effective bandwidth in ATM networks", Proc. 35th IEEE CDC, 1996.
- [13] J. Yang and M. Devetsikiotis. "On-line estimation, network design and performance analysis. Proceedings of International Teletraffic Congress- ITC 17, Elsevier Science, 2001.
- [14] F. H. T. Vieira, R. P. Lemos, L.L. Lee. "Alocação Dinâmica de Taxa de Transmissão em Redes de Pacotes Utilizando Redes Neurais Recorrentes Treinadas com Algoritmos em Tempo Real". IEEE Latin America, No. 1, November 2003.
- [15] <http://ita.ee.lbl.gov/html/contrib/DEC-PKT.html>