

ESTIMAÇÃO DE INTERVALO DE CONFIANÇA PARA PREDIÇÃO DE TRÁFEGO DE REDES USANDO UM MODELO FUZZY AUTO-REGRESSIVO

FLÁVIO H. T. VIEIRA E LEE L. LING

Departamento de Comunicações (DECOM), Universidade Estadual de Campinas
Albert Einstein, 400 – Caixa Postal 6101 – 13.083-970, São Paulo, Brasil
E-mails: {flavio, lee}@decom.fee.unicamp.br

Abstract— In this paper we model and predict high-speed network traffic through a Fuzzy Autoregressive model. This model approximates a complex nonlinear time-variant process by a combination of linear local autoregressive (AR) processes using a fuzzy clustering algorithm. We divide the fuzzy modeling algorithm approach in two parts: a coarse tuning and a fine tuning method. In coarse tuning, we train the fuzzy model with the Fuzzy C-regression Model (FCRM), while in the fine tuning a gradient descent algorithm is applied to precisely adjust the fuzzy model parameters. After presenting the fuzzy model training algorithm, we propose an approach to estimate the confidence intervals for the Fuzzy-AR model based predictions. The traffic predictions are incorporated in a rate allocation scheme in order to provide efficient traffic management. Finally, we validate the confidence prediction interval estimation approach through simulations with real traffic traces and demonstrate the validity of the rate allocation scheme

Keywords— Fuzzy Model, Confidence Interval, Prediction, Autoregressive Model, Network Traffic.

Resumo— Neste artigo, uma modelagem auto-regressiva (AR) nebulosa é usada na previsão do 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 através de algoritmos de classificação (*clustering*) nebulosos. Neste trabalho, dividimos o treinamento do modelo auto-regressivo nebuloso em 2 estágios: ajuste aproximado e ajuste fino. No estágio de ajuste aproximado, o treinamento é realizado aplicando-se o algoritmo FCRM (Fuzzy C-regression Model). Já a fase de ajuste fino consiste em um treinamento baseado no algoritmo de gradiente descendente para ajustar de maneira precisa os parâmetros do modelo Fuzzy-AR. Após apresentar o algoritmo de treinamento aplicado, propomos uma abordagem para estimar o intervalo de confiança para as previsões obtidas pelo modelo AR nebuloso. As previsões de tráfego aliadas as suas estimativas de intervalo de confiança são incorporadas em um esquema de alocação de taxa em um enlace de rede a fim de prover controle eficiente dos recursos. Finalmente, validamos as abordagens propostas através de simulações com traços reais de tráfego e verificamos o desempenho do esquema de alocação de taxa baseado no limitante superior do intervalo de confiança de previsão.

Palavras-chave— Modelo Nebuloso, Intervalo de Confiança, Predição, Modelo Auto-regressivo, Tráfego, Redes.

1 Introdução

Muitos estudos em modelagem nebulosa têm sido realizados desde que a teoria *fuzzy* foi inicialmente desenvolvida (Bezdek, 1993; Kim, 1997). A razão para estas pesquisas é que os modelos nebulosos são mais apropriados para descrever determinados sistemas em relação a modelos lineares e até mesmo alguns tipos de redes neurais. 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 Chen (2000).

O modelo nebuloso sugerido por Takagi e Sugeno em (Takagi, 1985) tem uma capacidade excelente, porém é complexo e demanda um elevado tempo de processamento (Mendel, 2001). O modelo nebuloso de Sugeno e Yasukawa (Sugeno, 1993) é mais fácil de ser implementado, mas precisa de mais regras nebulosas do que o modelo de Takagi e Sugeno.

O modelo fuzzy apresentado em Kim (1997) pode descrever um determinado sistema desconhecido com um pequeno número de regras nebulosas como o modelo de Takagi e Sugeno e é de fácil implementa-

ção como o modelo de Sugeno e Yasukawa. Ou seja, este modelo nebuloso reúne as características desejadas dos modelos mencionados.

Neste artigo, avaliamos o desempenho de um modelo nebuloso auto-regressivo quanto à previsão da intensidade de tráfego em uma rede de dados. Encontramos agrupamentos (*clusters*) para as séries de tráfego, onde cada agrupamento é descrito por um processo auto-regressivo (AR).

O artigo está organizado da seguinte forma. Na seção 2, descrevemos o algoritmo de treinamento aplicado ao modelo auto-regressivo nebuloso. Propomos na seção 3 uma abordagem para estimação do intervalo de confiança de previsão relacionada ao modelo auto-regressivo nebuloso. Finalmente na seção 4, apresentamos os resultados das simulações realizadas para validar as propostas. Concluimos na seção 5.

2 Modelagem Auto-Regressiva Nebulosa

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

Regra R^l : Se $y(n)$ é $M_1^l(q_{11}^l, q_{12}^l)$

e $y(n-1)$ é $M_2^l(q_{21}^l, q_{22}^l), \dots,$

e $y(n-p+1)$ é $M_p^l(q_{p1}^l, q_{p2}^l)$

então $y(n+1) = a_{l,0} + a_{l,1}y(n) + \dots + a_{l,p}y(n-p+1)$ (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:

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

A saída do modelo auto-regressivo nebuloso pode ser calculada através das regras nebulosas pelas seguintes equações:

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

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

Para se determinar os parâmetros consequentes $a_{l,j}$, o primeiro passo é decidir qual regra toma conta de quais dados. Para isto, aplicamos neste trabalho o algoritmo de classificação nebuloso FCRM (*Fuzzy C-regression Model*), uma versão modificada do FCM (*Fuzzy C-means*), desenvolvendo *clusters* com formas hiperplanas (Kung, 2005). Entretanto, o algoritmo FCRM identifica os parâmetros do modelo nebuloso de modo aproximado. Para melhorar o treinamento, utilizamos um procedimento de ajuste fino baseado em algoritmo de gradiente descendente. Além disso, determinamos os parâmetros do modelo nebuloso a fim de minimizar um índice de desempenho, tomado como sendo o EQMN (Erro Quadrático Médio Normalizado) de predição.

2.1 Ajuste Aproximado por FCRM

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

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

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 nebuloso através dos seguintes passos:

Passo 1) Inicie com $M=0$. Defina uma matriz U de dimensão cxn como em Jang (1997):

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

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

e

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

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 (Chen, 2000):

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

Calcule uma nova matriz U através da 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-*Weighed Recursive Least Squares*) segundo as equações:

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

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

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

onde $k=1,2,\dots,n$ e $l=1,2,\dots,c$. O algoritmo WRLS é inicializado com $S(0) = \alpha I$, $\alpha > 100$.

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

Estimativas para os parâmetros q_{j1}^l e q_{j2}^l das funções de pertinência gaussianas podem ser obtidas pelas seguintes equações (Kim, 1997):

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

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

2.2 Ajuste Fino por Algoritmo de Gradiente Descendente

Nesta seção descrevemos um procedimento para ajustar precisamente os parâmetros consecuentes $A_l = [a_{l,0}, a_{l,1}, \dots, a_{l,p}]^T$ e de premissa q_{jk}^l . O conceito de gradiente descendente pode ser aplicado para reduzir o erro de predição (ou modelagem), obtendo procedimentos de ajuste fino para os parâmetros consecuentes e de premissa, os quais são descritos abaixo.

- 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:

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

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 consecuentes:

Os parâmetros consecuentes $A_l = [a_{l,0}, a_{l,1}, \dots, a_{l,p}]^T$ do modelo auto-regressivo nebuloso de tráfego são ajustados de forma precisa pela equação:

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

onde γ é uma outra taxa de aprendizagem.

Uma vez que os parâmetros q_{jk}^l s e $a_{l,j}$ s foram determinados, predições a um passo $\hat{y}(n+1)$ da série de tráfego podem ser obtidas por meio das equações (1), (3) e (4).

Inicialmente o ajuste aproximado descrito na seção 2.1 tem um papel mais importante na estimação dos parâmetros do modelo. Com a convergência do cálculo

dos parâmetros do modelo, a aplicação de apenas o procedimento de ajuste fino produz resultados adequados (Chen, 2000). Em outras palavras, os parâmetros do modelo AR nebuloso podem ser ajustados utilizando-se o procedimento de ajuste fino, evitando-se o custo computacional relacionado ao cálculo realizado no ajuste aproximado. A modelagem nebulosa apresentada neste estudo tem excelente convergência sendo capaz de prever o tráfego de pacote em redes como será mostrado na seção 4.

3 Intervalo de Confiança para Predição por Modelo AR Nebuloso

Nesta seção, descrevemos como intervalos de confiança de predição podem ser estimados para o modelo Fuzzy-AR. Para tal, expressamos a saída do modelo Fuzzy-AR de forma a possibilitar a estimação dos intervalos de confiança de predição.

Seja y a saída do modelo Fuzzy-AR dada por:

$$y_i = f(x_i, \theta^*) + \mathcal{E}_i \quad (17)$$

onde x_i é a entrada do modelo no instante de tempo i , θ^* representa os valores reais para as componentes do vetor θ da função que descreve o sistema a ser modelado e \mathcal{E}_i é o erro associado à função f na modelagem do sistema ou processo em questão. Assume-se que o erro \mathcal{E}_i seja uma variável gaussiana independente e identicamente distribuída com variância σ^2 e média zero.

Denotemos por $\hat{\theta}$ a estimativa de mínimos quadrados de θ^* , ou seja, estimativa obtida pela minimização da seguinte função de erro:

$$S(\theta) = \sum_{i=1}^n [y_i - f(x_i, \theta^*)]^2 \quad (18)$$

A saída predita do modelo fuzzy para a entrada x_0 é dada por:

$$\hat{y}_0 = f(x_0, \hat{\theta}) \quad (19)$$

No caso de o modelo fornecer predições precisas do comportamento do sistema, então pode-se afirmar que o valor $\hat{\theta}$ é próximo de θ^* . Em adição, se as variáveis $\hat{\theta}$ e \mathcal{E}_0 forem independentes, podemos escrever a variância dos erros de predição como (Chryssolouris, 1996):

$$\text{var}[y_0 - \hat{y}_0] \approx \text{var}[\mathcal{E}_0] + \text{var}[f_0^T \cdot (\hat{\theta} - \theta^*)] \quad (20)$$

onde

$$f_0^T = \left(\frac{\partial f(x_i, \theta^*)}{\partial \theta_1^*}, \frac{\partial f(x_i, \theta^*)}{\partial \theta_2^*}, \dots, \frac{\partial f(x_i, \theta^*)}{\partial \theta_p^*} \right) \quad (21)$$

Assumindo que o erro \mathcal{E}_0 tenha uma distribuição gaussiana com média zero e variância

$\sigma^2(N(0, \sigma^2 I_n))$, a distribuição de $(\hat{\theta} - \theta^*)$ pode ser aproximada por uma distribuição normal do tipo $N_p(0, \sigma^2 [F(\hat{\theta})^T F(\hat{\theta})]^{-1})$, onde $F(\hat{\theta})$ é a matriz Jacobiana dada por:

$$F(\hat{\theta}) = \frac{\partial f(x, \hat{\theta})}{\partial \hat{\theta}} = \begin{bmatrix} \frac{\partial f_1(x_1, \hat{\theta})}{\partial \hat{\theta}_1} & \frac{\partial f_1(x_1, \hat{\theta})}{\partial \hat{\theta}_2} & \dots & \frac{\partial f_1(x_1, \hat{\theta})}{\partial \hat{\theta}_p} \\ \frac{\partial f_2(x_2, \hat{\theta})}{\partial \hat{\theta}_1} & \dots & \dots & \frac{\partial f_2(x_2, \hat{\theta})}{\partial \hat{\theta}_p} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial f_n(x_n, \hat{\theta})}{\partial \hat{\theta}_1} & \frac{\partial f_n(x_n, \hat{\theta})}{\partial \hat{\theta}_2} & \dots & \frac{\partial f_n(x_n, \hat{\theta})}{\partial \hat{\theta}_p} \end{bmatrix} \quad (22)$$

e

$$\text{var}[y_0 - \hat{y}_0] \approx \text{var}[\varepsilon_0] + \sigma^2 f_o^T (F^T \cdot F)^{-1} f_o \quad (23)$$

Note que a matriz (22) tem dimensões n por p , onde n é o número de amostras usadas para obter $\hat{\theta}$ e p é o número de componentes do vetor θ .

O intervalo de confiança de $100(1-\alpha)\%$ para o valor predito \hat{y}_o é representado por $\hat{y}_o \pm c$, onde o parâmetro c é dado pela seguinte equação (Chryssoulouris, 1996):

$$c = t_{n-p}^{\alpha/2} s (1 + f_o^T (F^T \cdot F)^{-1} f_o)^{1/2} \quad (24)$$

onde $t_{n-p}^{\alpha/2}$ é a função inversa da distribuição acumulada t de Student com $n-p$ graus de liberdade, avaliada para $\alpha/2$ e que se relaciona com $\text{var}[y_0 - \hat{y}_0]$ através da seguinte equação (Chryssoulouris, 1996):

$$t_{n-p}^{\alpha/2} \approx \frac{y_0 - \hat{y}_0}{\sqrt{\text{var}[y_0 - \hat{y}_0]}} \quad (25)$$

Sabe-se que um estimador s não polarizado para a variância σ^2 é obtido por:

$$s = \frac{\sum_{i=1}^n [y_i - f(x_i, \theta^*)]^2}{n - p} \quad (26)$$

A equação (24) para estimação do intervalo de confiança de predição pode ser aplicada ao modelo fuzzy considerado. A saída do modelo fuzzy-AR pode ser escrita como:

$$\hat{y}(n+1) = \frac{\sum_{l=1}^c w_l y_l(n+1)}{\sum_{l=1}^c w_l} = \sum_{i=1}^c \left(a_0^i \frac{w_i}{\sum_{j=1}^c w_j} + a_1^i \frac{w_i}{\sum_{j=1}^c w_j} x_1 + \dots + a_m^i \frac{w_i}{\sum_{j=1}^c w_j} x_m \right) \quad (27)$$

Assim, podemos expressar os parâmetros do modelo Fuzzy-AR em termos de θ_k da seguinte forma:

$$\theta_k = a_k^i \frac{w_i}{\sum_{j=1}^c w_j} \quad (28)$$

e aplicar o método de estimação de intervalo de confiança mencionado, uma vez que θ_k é obtido através de mínimos quadrados e não apresenta variação significativa (Papadopoulos, 2001).

Sabe-se que os métodos de estimação de intervalo de confiança existentes, como o acima descrito se tornam mais precisos a medida que o número de pontos de treinamento tende ao infinito, ou seja (Papadopoulos, 2001):

$$P(y_o \in \hat{y}_o \pm c) \rightarrow 1 - \alpha \quad (29)$$

Demonstraremos que a abordagem proposta de estimação de intervalo de confiança para o modelo fuzzy-AR provê resultados precisos mesmo quando o número de amostras do conjunto de treinamento não é grande.

4 Simulações e Resultados

As predições de tráfego de redes de computadores efetuadas pelo modelo nebuloso podem ser usadas no controle de tráfego dado que, conforme mostraremos, seus erros de predição são comparáveis a outros métodos tais como redes neurais (Vieira, 2003).

Avaliamos o desempenho de predição do modelo AR nebuloso por meio do erro quadrático médio normalizado dado por:

$$EQMN = \frac{1}{\sigma^2 p} \sum_{n=1}^p [y(n) - \hat{y}(n)]^2 \quad (30)$$

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 no intervalo de predição e p é o número de amostras de teste.

A fim de demonstrar que a modelagem AR nebulosa é capaz de predizer de forma satisfatória tráfego de redes, usamos nas simulações traços de tráfego TCP/IP (dec-pkt-1 e dec-pkt-2) obtidos da Digital Equipment Corporation¹. Consideramos a escala de 512ms para estas séries de tráfego TCP/IP. Também empregamos traços de tráfego Ethernete Internet obtidos da Bellcore¹. 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 e dec-pkt-2. A configuração considerada para o modelo auto-regressivo nebuloso foi de duas regras nebulosas

e cinco coeficientes $a_{l,j}$, $j=1,2,\dots,5$. Além disso, as

¹ <http://www.acm.org/sigcomm/ITA>

taxas de aprendizagem η e γ foram estipuladas como sendo 0,001 e 0,01, respectivamente. Após obter as previsões, examinamos a precisão da abordagem de estimação de intervalo de confiança.

Tabela 1: EQMN de Predição

Traço de Tráfego	MLP	FIR MLP	Fuzzy-AR
Bc-Octext	0,4077	0,4260	0,3107
Bc-Octint	1,21	0,7408	0,4152

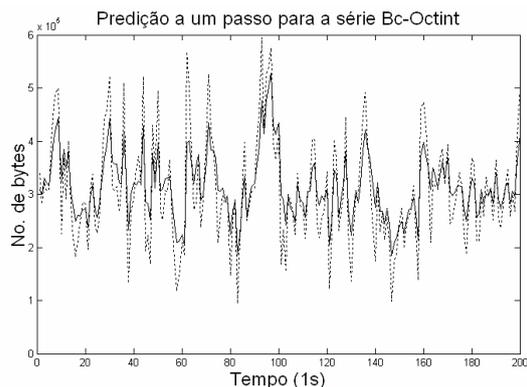


Fig. 1. Predição a um passo pela modelagem nebulosa (linha sólida). Série temporal de tráfego Bc-Octint (linha pontilhada).

Na predição da série de tráfego Bc-Octint, obtivemos um EQMN de 0,3107 para os instantes de tempo 801 a 1701 e um EQMN de 0,3877 para todo traço de tráfego. A Figura 1 mostra a predição a um passo para a série Bc-Octint. A Tabela 1 compara o desempenho de predição do modelo AR nebuloso com o de outros métodos (Vieira, 2003). Observa-se que um menor EQMN é obtido pelo modelo Fuzzy-AR em comparação às redes neurais MLP e FIR-MLP. Em seguida, estipulamos o intervalo de confiança de predição desejado como sendo de 95%. Como resultado, obtivemos 95,07% das previsões dentro do intervalo de confiança, o que confirma que a abordagem proposta é válida na prática. Com relação ao traço de tráfego Bc-Octext, o EQMN de predição para os instantes de tempo 1000 a 2000 foi de 0,4152 e 0,4862 para toda a série de tráfego. Neste caso, 96,07% das previsões foram encontradas dentro do intervalo de confiança. Resultado este próximo ao intervalo de confiança desejado.

Em relação aos traços de tráfego Internet da DEC, encontramos 95,41% das previsões dentro do intervalo de confiança para a série de tráfego dec-pkt-1. A Figura 2 exibe o envelope estimado (limitante inferior e superior do intervalo de confiança de predição) para um intervalo de confiança de 95%. Para a série temporal de tráfego dec-pkt-2, um resultado similar foi obtido (95,21% das previsões dentro do intervalo de confiança).

Agora, investigamos a precisão da estimação do

intervalo de confiança para diferentes níveis de significância α . A Tabela 2 apresenta os resultados obtidos para a série de tráfego Bc-Octint.

Tabela 2: Porcentagem das Predições dentro do Intervalo de Confiança

Intervalo de Confiança Desejado	Resultado Obtido
95%	95,07%
85%	84,87%
80%	80,47%
75%	75,60%

As previsões realizadas com o modelo fuzzy-AR podem ser incorporadas em um esquema que aloca dinamicamente a taxa necessária de modo a evitar perda de bytes em um enlace de rede. Neste esquema, as bandas dos fluxos são previstas, permitindo que os protocolos de rede tenham tempo para fazer as mudanças necessárias na taxa (capacidade) do enlace. Aplicamos o limitante superior do intervalo de confiança de predição neste esquema de alocação de taxa. A razão para esta abordagem é que dessa forma pode-se garantir que a quantidade real de bytes a ser enviada por um nó da rede em um tempo futuro é menor do que a estimativa obtida, com probabilidade dada pela equação (29).

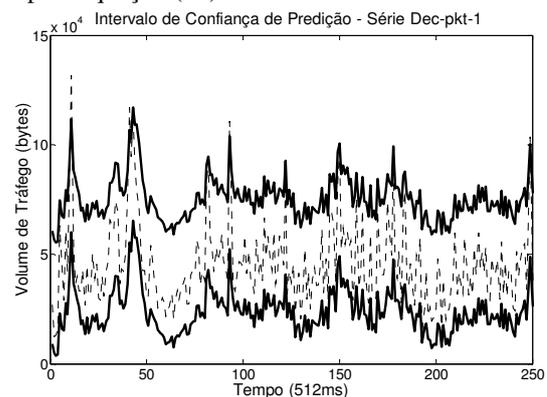


Fig. 2. (Linha sólida) Intervalo de confiança de 95% para predição usando o model fuzzy-AR. Traço de tráfego dec-pkt-1 (linha pontilhada).

O esquema de alocação de taxa foi avaliado da seguinte forma. Simulamos um enlace de rede com taxa variável e *buffer* de tamanho finito. Como entrada para o enlace de comunicação, utilizamos as amostras do traço de tráfego Bc-Octint. Intercalamos as fases de treinamento e teste onde 20 instantes de tempo consecutivos do traço de tráfego são designados a treinamento e 20 instantes de tempo consecutivos para teste e assim sucessivamente.

Fixamos o tamanho do *buffer* como sendo 70% do valor máximo da série de tráfego Bc-Octint, amostrada a cada 0,1s. A Tabela 3 mostra os dados de ocupação do *buffer* obtidos com o esquema de alocação baseado no limitante superior do intervalo de predição e com alocação de taxa baseada somente nas previsões. Pode-se observar por estes resultados que

uma ocupação do *buffer* mais bem comportada é obtida usando o esquema de alocação baseado no limitante superior do intervalo de predição.

Tabela 3: Ocupação do Buffer

	Alocação baseada em Predição	Alocação baseada em Intervalo de Confiança
Número máximo de bytes no buffer	2.477.700bytes	177.700 bytes
Número médio de bytes no buffer	1.526.000bytes	2019 bytes
Variância do número de bytes no buffer	6.359.400bytes	1.503,6 bytes

O comportamento de fila no *buffer* está diretamente relacionado à perda de bytes no enlace. Ao se alocar taxa usando apenas as predições, 6.837.700 bytes são perdidos. Usando a alocação de taxa baseada em limitante superior do intervalo de confiança de predição, obtém-se uma menor perda de bytes (250.730 bytes são perdidos, apenas 0,3% do total de tráfego). Esses resultados mostram que a predição do volume de tráfego pode não ser suficiente para prover a taxa necessária ao enlace devido aos erros de predição inerentes.

5 Conclusão

Os comportamentos complexos dos fluxos de tráfego em redes de alta velocidade fazem a modelagem e predição de tráfego tarefas difíceis e desafiadoras. Apesar deste fato, mostramos que o modelo AR nebuloso é adequado para predição de traços de tráfego reais com poucas regras nebulosas.

O conhecimento da magnitude do erro de predição através da estimação de seu intervalo de confiança é necessário para se assegurar o uso com segurança das predições realizadas por modelos para tráfego de redes. Neste artigo, demonstramos que a abordagem proposta de estimação de intervalo de confiança de predição para o modelo fuzzy-AR é válida para traços reais de tráfego. Verificamos que a exatidão do intervalo da confiança depende do número de amostras dos intervalos. Entretanto, resultados precisos foram obtidos para intervalos com poucas amostras. Além disso, a média das predições encontradas dentro dos intervalos é próxima do intervalo de confiança desejado.

Pode-se observar que uma perda menor de bytes é garantida ao se controlar a taxa do enlace através da abordagem baseada em intervalo de confiança de predição. De acordo com a análise realizada, podemos concluir que o esquema proposto de alocação de taxa é uma ferramenta útil para a alocação de recursos em redes de computadores atuais.

Referências Bibliográficas

- Bezdek, J. C. (1993). Editorial: Fuzzy models—What are they and why?, *IEEE Trans. Fuzzy Syst.*, vol. 1, pp. 1–6, Fev.
- Chen, B.-S.; Peng, S.-C. e Wang, K.-C. (2000). Traffic Modeling, Prediction, and Congestion Control for High-Speed Networks: A Fuzzy AR Approach. *IEEE Transactions on Fuzzy Systems*, Vol. 8, No.5, Outubro.
- Chrysolouris, G.; Lee, M. E Ramsey, A. (1996). Confidence interval prediction for neural network models, *IEEE Trans. Neural Networks* 7(1): 229-232.
- Jang, J. S. R.; Sun, C. T. e Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Englewood Cliffs, NJ: Prentice-Hall.
- Kim, E; Park, M; Ji, S. (1997). A new approach to fuzzy modeling, *IEEE Trans. Fuzzy Syst.*, vol. 5, pp. 328–337, Agosto.
- Kung, C. e Su, J.Y. (2005) T-S fuzzy modeling by FCRM clustering, *IEEE International Conf. on Systems, Man and Cybernetics*, Outubro.
- Mendel, J. M. (2001). *Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions*. Prentice Hall, 1st edition.
- Papadopoulos, G.; Edwards, P. J. e Murray, A. F. (2001). Confidence Estimation Methods for Neural Networks: A Practical Comparison, *IEEE Transactions on Neural Networks*, vol. 12, no. 6, Novembro.
- Sugeno, M. e Yasukawa, T. (1993). A fuzzy-logic-based approach to qualitative modeling, *IEEE Trans. Fuzzy Syst.*, vol. 1, pp. 7–31, Fev.
- Takagi, T. e Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control, *IEEE Trans. Syst., Man, Cybern.*, vol. SMC-15, pp. 116–132, Fev.
- Vieira, F. H. T. ; Lemos, R. P. e Lee, L.L. (2003). 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, Nov.