

MODELOS DE TRÁFEGO: DEPENDÊNCIA DE CURTA DURAÇÃO vs. DEPENDÊNCIA DE LONGA DURAÇÃO

Anibal D. Angulo Miranda e Alessandro Anzaloni

Divisão de Engenharia Eletrônica – Instituto Tecnológico de Aeronáutica - ITA
Pça. Mal. Eduardo Gomes, 50, - V. Das Acácias, CEP:12228-900 S. J. dos Campos, SP, Brasil

RESUMO

No passado recente a revelação de um novo paradigma na caracterização de tráfego em redes de dados de alta velocidade foi bastante surpreendente e ao mesmo tempo complexo, devido à falta de ferramentas de análise matemática para desenhar e dimensionar os atuais sistemas de redes de alto desempenho considerando este novo modelo. Muito trabalho está sendo desenvolvido para conseguir um conjunto de ferramentas de análise que abranja tanto as características de tráfego com dependência de curta duração assim como o tráfego com dependência de longa duração. O propósito deste artigo é mostrar de forma clara e objetiva as diferenças entre estes dois grupos de modelos de tráfego, isto é, os modelos clássicos e os modelos atuais desde o ponto de vista estatístico, como um compendio final e completo deste fascinante tópico no modelamento de tráfego.

1. INTRODUÇÃO

No ano de 1994 surge como fruto de uma pesquisa previa no fim da década dos 80 e inicio da década dos 90 o artigo [1] titulado “*On the self-similar nature of Ethernet traffic*” (ganhador em 1995 do *William J. Bennett Award* da *IEEE Communications Society*, e no ano de 1996 o *W. R. G. Baker Prize Award* também da *IEEE*), a partir desse artigo e dessa data o mundo da engenharia de tráfego das atuais redes de dados e modelos para a caracterização nunca mais seria o mesmo [2][3]. Os antigos paradigmas de considerar o comportamento do tráfego de redes como obedecendo às leis Poissonianas ou de forma mais geral às regras Markovianas, foram colocados num cenário altamente questionado.

Nesses estudos analíticos de amostras empíricas de dados de LAN/WAN [1] mostra-se de maneira irrefutável que o comportamento estatístico do tráfego das fontes e destinos finais, que atravessam a grande rede, esta longe de apresentar uma regularidade estatística e de convergir no limite para um processo Gaussiano ordinário (ruído branco Gaussiano) [4][5].

Segundo esses estudos, as características estatísticas do tráfego de dados em redes LAN/WAN atuais, diferem de maneira surpreendente dos modelos clássicos (refera-se a [6] e às referências nesse artigo entre outros), este tráfego de dados coletado apresenta detalhes (rajadas) em varias escalas de observação, isto é, as características estatísticas são degeneradas lentamente de forma quase independente da escala de observação (é um processo estocástico lento). Portanto, a velha hipótese da suavização do tráfego agregado, válida nos modelos Markovianos [7], nunca seria atingida.

A principal implicância que isto traz é no desenvolvimento de algoritmos para evitar o congestionamento de tráfego de dados, caso eles sejam baseados nos modelos clássicos praticamente a vazão ou perda de dados será bastante considerável [3],

coseqüentemente isto gerará uma degradação na qualidade de serviço fornecida pela rede e requisitada pelas fontes finais de transmissão e recepção de dados.

A finalidade deste artigo é mostrar de forma clara e precisa a grande diferença entre os modelos clássicos e modelos atuais de tráfego. Para tal propósito o artigo é dividido da seguinte maneira. Brevemente na Seção 2 é apresentada a teoria dos processos WSS¹ de tempo discreto, na Seção 3 apresentam-se os modelos de tráfego propriamente ditos, com os respectivos testes que verificão as grandes diferenças destes modelos, na Seção 4 são apresentadas as características qualitativas de ambos tipos de processos e finalmente na Seção 5 são dadas as conclusões do trabalho.

2. PROCESSOS WSS DE SEGUNDA ORDEM DE TEMPO DISCRETO

Esta Seção fornece a teoria básica dos processos estocásticos estacionários no sentido amplo (WSS) de segunda ordem de tempo discreto. Esta escolha não traz nenhuma limitação devido a que: (1) o tráfego nas redes ATM e redes de alta velocidade é de natureza discreta e (2) normalmente são considerados modelos com variância finita que possuem algum tipo de estacionariedade, em tal caso os processos WSS constituem uma escolha apropriada.

Para tal fim, é necessário introduzir algumas definições adicionais. Seja $X = \{X_n\}_{n=0}^{\infty}$ um processo estocástico de tempo discreto estacionário no sentido amplo, com uma função de densidade espectral de potência denotada por $f(v)$, $-\pi < v < \pi$, e uma função de autocovariância dada por $r(k)$, $k \geq 0$. Portanto, é possível escrever [7]

$$r(k) = \int_{-\pi}^{\pi} e^{ikv} f(v) dv \quad k \geq 0 \quad (1)$$

Devido à relação bi-unívoca entre pares de transformadas de Fourier, a função de densidade espectral de potência $f(\bullet)$ é definida como a transformada inversa da função de autocovariância (ou autocorrelação), isto é

$$f(v) = \frac{1}{2\pi} \sum_{k=0}^{\infty} r(k) e^{-ikv} \quad -\pi < v < \pi \quad (2)$$

Para inferir se um determinado processo estocástico possui intrinsecamente características com dependência de longa

¹ Pelas siglas em inglês *Wide Sense Stationary* (WSS)

(DLD) ou curta duração (DCD) é necessário definir uma nova sequência temporal conhecida como o processo agregado dado por $X = \{X_n\}_{n=0}^{\infty}$ e definido matematicamente como

$$X_j^{(m)} = \frac{1}{m} (X_{j-m+1} + \dots + X_j) \quad m \geq 1 \quad (3)$$

Basicamente, o processo agregado é obtido dividindo a serie de tempo original em m blocos não sobre-postos. O índice, j , etiqueta o bloco e cada bloco tem um comprimento m , assim a eq. (3) pode ser rescrita como

$$X_j^{(m)} = \frac{1}{m} \left[\sum_{i=(j-1)m+1}^{jm} X_i \right] \quad j=1,2,\dots \quad (4)$$

A eq. (4) representa a nova serie de tempo (suavizada) e cada elemento dessa serie corresponde ao valor médio empírico calculado para cada bloco m . Portanto, o processo $X_j^{(m)}$ é equivalente ao processo original X sobre uma escala de tempo que foi m vezes reduzida. É possível mostrar que para $m > 1$ o processo $X_j^{(m)}$ é WSS [9][10]. Define-se $Var[X_j^{(m)}]$ como a variância do processo $X_j^{(m)}$; portanto, $Var[X_j^{(m)}] = r^{(m)}(0)$. A sequência $\{Var[X_j^{(m)}] \mid m \geq 1\}$ pode ser completamente especificada pela função de autocovariância original $r(\bullet)$.

Pode-se escrever o processo $Var(X_j^{(m)})$ como [11][12]

$$Var[X_j^{(m)}] = \frac{\sigma^2}{m} + \frac{2}{m^2} \sum_{k=1}^m (m-k)r(k) \quad (5)$$

A eq. (5) pode ser ainda escrita como

$$Var[X_j^{(m)}] = \frac{\sigma^2}{m} \left[1 + 2 \sum_{k=1}^m \left(1 - \frac{k}{m} \right) r(k) \right] \quad (6)$$

Na seguinte Seção, a eq. (6) será de muita utilidade para verificar a dependência de longa e curta duração, em outras palavras, para ver se o processo possui ou carece de memória.

3. MODELOS DE TRÁFEGO

3.1 Processos com Dependência de Curta Duração (DCD)

Um processo estocástico WSS denotado por X com uma função de autocovariância $r(k)$, $k \geq 0$ é dita que possui uma dependência de curta duração se satisfaz as seguintes (essencialmente) equivalentes condições

$$(a) \quad \sum_{k=0}^{\infty} r(k) < +\infty$$

$$(b) \quad f(0) < +\infty$$

$$(c) \quad \lim_{m \rightarrow \infty} \{m Var[X_j^{(m)}]\} < +\infty$$

As condições acima são (essencialmente) equivalentes, cada uma implica a outra, isto é, (a) \rightarrow (b) \rightarrow (c), porém o contrario não é mais válido, ou seja, (c) não implica (b) ou (a).

Na Fig. 1 pode ser observada a condição (a) e na Fig. (2) a condição (b) dos processos com dependência de curta duração (DCD), que no caso foi escolhido um processo Markoviano




Figura 1 Função de auto-correlação de um processo DCD




Figura 2 Função de densidade espectral de um processo DCD

A condição (c) é obtida da eq. (6) considerando a condição (a). Das Figuras 1 e 2 é fácil verificar a dependência de curta duração do processo considerado. Um processo DCD é geralmente caracterizado por um decaimento do tipo exponencial da $r(k)$, resultando assim, numa convergência de $\sum_{k=0}^{\infty} r(k)$.

Portanto, esta condição faz com que o comportamento da densidade espectral de potência seja semelhante com a de um ruído branco puro de segunda ordem, isto é, terá um valor espectral finito e constante em quase todo o espectro de frequências. Isto explica uma assunção comumente feita na modelagem de tráfego tradicional, que como na análise de series temporais clássica, as observações separadas por um atraso (lag) temporal longo são consideradas praticamente independentes.

3.2 Processos com Dependência de Longa Duração (DLD)

Por outro lado, existem outra classe de processos os quais possuem as características de dependência de longa duração, como definidas a seguir

Um processo estocástico WSS denotado por X com uma função de autocovariância $r(k), k \geq 0$ é dita que apresenta uma dependência de longa duração se satisfaz as seguintes condições

- (a) $\sum_{k=0}^{\infty} r(k) = +\infty$
- (b) $f(0) = +\infty$
- (c) $\lim_{m \rightarrow \infty} \{m \text{Var}[X_j^{(m)}]\} = +\infty$

Sem perda de generalidade, o fato da função de autocovariância seja não sumável sugere que valores de autocovariâncias para atrasos longos são individualmente pequenos, porém seu efeito acumulativo é bastante considerável. As funções de autocovariância para processos DLD decaem mais lentamente do que exponencialmente; tipicamente eles obedecem alguma lei de potência, este comportamento é conhecido também como decaimento hiperbólico.

A condição (c) pode ser visualizada a partir da eq. (6) considerando a condição (a), é possível mostrar que essa somatória pode ser aproximada pela seguinte relação

$$\sum_{k=0}^{\infty} r(k) \approx C m^{1-\alpha} \tag{7}$$

Onde o valor do parametro α será $0 < \alpha < 1$. Um exemplo de uma função com decaimento hiperbólico é aquela com a seguinte estrutura matemática $r(k) \approx C_{r(k)} |k|^{-\alpha}$ para $k \rightarrow \infty$.

A Fig. 3 apresenta este comportamento e a Fig. 4 reflete este fato no domínio da frequência.




Figura 3 Função de autocorrelação para um processo DLD




Figura 4 Função de densidade espectral de um processo DLD

As condições (a), (b) e (c) dadas acima para processos DLD são muito gerais. Para ser mais específicos considerando as características quantitativas dos processos com DLD, considerar as seguintes condições equivalentes com $0 < \alpha < 1$

- (A) $r(k) \approx k^{-\alpha} L_1(k)$ para $k \rightarrow \infty$
- (B) $f(v) \approx v^{\alpha-1} L_2(v)$ para $v \rightarrow 0$
- (C) $\text{Var}[X_j^{(m)}] \approx m^{-\alpha} L_3(m)$ para $m \rightarrow \infty$

Onde $L_1(\bullet), L_2(\bullet),$ e $L_3(\bullet)$ são funções que variam lentamente.

Portanto, nesta Seção foram apresentadas as principais diferenças de ambos modelos com DCD e DLD nos domínios do tempo e da frequência. Na seguinte Seção apresentam-se as diferenças qualitativas relevantes a estes modelos.

4. CARACTERÍSTICAS QUALITATIVAS DOS MODELOS DE TRÁFEGO

Nesta Seção são apresentados as características qualitativas mais significativas dos modelos com dependências de longa duração (DLD) e de curta duração (DCD) desde quatro diferentes perspectivas, sendo que todas as análises feitas nestas sub-seções farão uso do processo agregado (eq. (4)). Os testes estatísticos são realizados tanto no domínio do tempo como no domínio da frequência, estes são:

- (1) Análise da variância-tempo do processo agregado (domínio do tempo).
- (2) Análise baseada na estatística R/S (domínio do tempo).
- (3) Análise do índice de dispersão (IDC) (domínio do tempo).
- (4) Análise do estimador de máxima verossimilhança de Whittle local (domínio da frequência).

4.1 Análise da Variância-tempo

Este método faz uso do processo agregado dado pela eq. (4). Pode-se mostrar que se o processo estudado apresenta uma variância amostral que decai lentamente, segue a seguinte lei

$$\text{Var}[X_j^{(m)}] \approx am^{-\beta} \tag{8}$$

Por outro lado, se o processo em questão apresenta uma variância amostral que decai rapidamente, a lei matemática será a seguinte

$$Var[X_j^{(m)}] \approx am^{-1} \quad (9)$$

As eq. (8) e (9) mostram as condições (c) tanto para processos com DLD e DCD descritas na Seção 3 respectivamente.

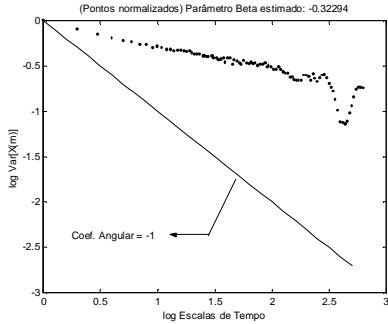


Figura 5 Análise da Variância-tempo para um processo DLD

As Figs. 5 e 6 mostram o comportamento das condições (c) (veja sub-seções 3.1 e 3.2), isto é, a $Var[X_j^{(m)}]$ para um processo DLD decai lentamente segundo a lei dada pela eq. (8), claramente a Fig. 5 mostra que o parâmetro β está no intervalo $-1 < \beta < 0$, isto significa que as propriedades estatísticas (no mínimo até de 2ª ordem) são degeneradas lentamente a medida que o intervalo de observação do processo estudado é incrementado. A Fig. 6 mostra que para um processo DCD a taxa de decrescimento de $Var[X_j^{(m)}]$ é proporcional ao recíproco do tamanho amostral, isto é, apresenta uma taxa de descida com um parâmetro $\beta = -1$, típico dos processos decorrelacionados e bastante utilizados como modelos de tráfego.

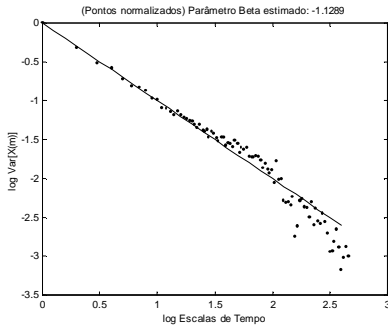


Figura 6 Análise da Variância-tempo para um processo DCD

4.2 A Estatística R/S

A estatística R/S (*rescaled reajusted range statistic*) esta baseada em um enfoque gráfico heurístico [1] que trata de obter a informação fractal ou não de um dado registro temporal.

Basicamente, mediante a utilização do processo agregado dado pela eq. (4) calcula-se a razão dada por $R(n)/S(n)$ para cada bloco de comprimento m não sobreposto dessa serie agregada

[1][13]. Matematicamente a razão dada por $R(n)/S(n)$ é definida como

$$\frac{R(n)}{S(n)} = \frac{1}{S(n)} [max(0, W_1, W_2, \dots, W_n) - min(0, W_1, W_2, \dots, W_n)] \quad (10)$$

Os termos W_k estão dados por $W_k = (X_1 + X_2 + \dots + X_k) - k\bar{X}(n)$. O termo dado por $S(n)$ é a variância amostral de $X_{t_1}, X_{t_2}, \dots, X_{t_n}$. O engenheiro civil H. E. Hurst encontrou na década dos 50 que muitas series temporais de ocorrência natural apresentavam um comportamento segundo a seguinte lei

$$E \left[\frac{R(n)}{S(n)} \right] \approx dn^H \quad (11)$$

Hurst observou que o parâmetro H oscilava tipicamente no intervalo $0.5 < H < 1$, a constante d da eq. (11) é finita positiva e independe de n . Naquela época, isto era bastante contraditório porque segundo a teoria essas series temporais deveriam obedecer a lei dada por

$$E \left[\frac{R(n)}{S(n)} \right] \approx dn^{0.5} \quad (12)$$

A eq. (12) é a definição clássica para o movimento Browniano (*random walk*) a eq. (11) é uma lei geral deste processo estocástico conhecido como movimento Browniano fracional.




Figura 7 Estatística R/S para um processo com DLD




Figura 8 Estatística R/S para um processo com DCD

Desta maneira Hurst generalizou a lei $n^{0.5}$ para a lei n^H . A discrepância entre a eq. (11) e a eq. (12) é conhecida atualmente como o *efeito Hurst* ou *fenômeno de Hurst*. Portanto, segundo a estatística R/S o comportamento de um processo com DLD obedece à eq. (11) e para um processo com DCD esse

comportamento é governado pela eq. (12). As Figs. 7 e 8 mostram ambos comportamentos

Os gráficos gerados a partir da estatística R/S são conhecidos com o nome de gráficos *pox* (*poxplots*). Este método gráfico da estatística R/S é bastante robusto [1], isto é, independe da distribuição marginal do processo estocástico estudado. Em forma geral, se H estiver bem definido no intervalo $0.5 < H < 1$, estes gráficos *pox* iniciam-se com uma etapa transiente que representa a natureza de dependência de curta duração intrínseca de toda série temporal. Caso a série temporal analisada corresponda a um processo com DCD esta etapa transiente não mudará, ou seja, os pontos calculados irão oscilar em torno do valor fixo dado por $H=0.5$ (Fig. 7). Porém, se o processo possui intrinsecamente uma natureza DLD essa etapa transiente muda para uma etapa estacionária e bem definida, isto é, os pontos calculados irão flutuar com um coeficiente angular bem definido no intervalo $0.5 < H < 1$ (Fig. 6).

4.3 Análise do índice de dispersão (IDC)

Uma medida de uso comum para capturar a variabilidade dos processos estocásticos é dada pelo índice de dispersão IDC (*Index of Dispersion for Counts*), tendo no passado recente e atualmente muita importância nas medições do tráfego de dados LAN/WAN em diferentes escalas de tempo. Para um dado intervalo de tempo, t , o IDC é dado pela variância do número de chegadas nesse intervalo de tempo t dividido pelo valor esperado (valor médio) da mesma quantidade. De acordo com [6] o índice de dispersão para um processo MMPP de dois estados é dado pela seguinte relação

$$IDC(t) = 1 + \frac{2(\lambda_1 - \lambda_2)^2 r_1 r_2}{(r_1 + r_2)^2 (\lambda_1 r_2 + \lambda_2 r_1)} - \frac{2(\lambda_1 - \lambda_2)^2 r_1 r_2}{(r_1 + r_2)^2 (\lambda_1 r_2 + \lambda_2 r_1) t} [1 - e^{-(r_1 + r_2)t}] \quad (13)$$

Onde λ_1 e λ_2 são as taxas médias dos processos de chegadas que obedecem a uma distribuição de Poisson e ω_1 e ω_2 são os tempos médios de permanência em ambos os estados. Notar que o IDC converge para um valor finito quando $t \rightarrow \infty$, ou seja

$$IDC(\infty) = \lim_{t \rightarrow \infty} \frac{Var(X_j^{(m)})}{E(X_j^{(m)})} = 1 + \frac{2(\lambda_1 - \lambda_2)^2 r_1 r_2}{(r_1 + r_2)^2 (\lambda_1 r_2 + \lambda_2 r_1)} \quad (14)$$

A Fig. 9 mostra o comportamento assintótico da eq. (14) que corresponde a um processo MMPP de dois estados.

O IDC para um processo com DLD apresenta, mais uma vez, um comportamento diferente. Segundo estudos realizados [1], para este tipo de processos, o IDC obedece à seguinte lei

$$IDC(t) = \frac{Var[X_j^{(m)}]}{E[X_j^{(m)}]} \approx ct^{2H-1} \quad (15)$$

Onde c é uma constante positiva finita que independe do tempo.




Figura 9. Análise do índice de dispersão para um processo com DCD

Note-se que quando o $\log[IDC(t)]$ é plotado em função de $\log(t)$, a eq. (15) resulta numa função linear do tempo com um coeficiente angular dado por $2H - 1$. O IDC para os processos com DLD cresce monotonamente por varias escalas de tempo. A Fig. 10 mostra tal comportamento.

Portanto, estas três análises mostram que o comportamento é totalmente diferente para processos com DCD e DLD. A seguinte sub-seção apresenta uma análise no domínio da frequência para ambos processos estudados.




Figura 10. Análise do índice de dispersão para um processo com DLD

4.4 O Estimador de Whittle Local

O estimador de máxima verosimilhança de Whittle local é o valor do vetor η que minimiza a função Q dada por

$$Q(\eta) = \sum_{j=1}^M \frac{I(v_j)}{f(v_j, \eta)} \quad (16)$$

Onde M é a parte inteira de $(N-1)/2$ sendo N o comprimento da serie temporal agregada, v_j são as componentes de frequência de Fourier dadas por $v_j = 2\pi j/N$ e $I(v_j)$ é a função periodograma do processo em questão.

O vetor η envolve tanto as componentes de longa e curta dependência da serie temporal estudada. Quando analisa-se o movimento Browniano fracional ou os processos “ideais” f-ARIMA(0,d,0) [14][15], esse vetor η corresponde simplesmente aos valores de H (parâmetro de Hurst) ou d (parâmetro de diferença ou integrador) respectivamente.

Para utilizar-se o estimador de Whittle, é necessário assumir *a priori* o comportamento da densidade espectral de potência perto da origem. A função de densidade espectral a ser utilizada na eq. (16) é dada pela seguinte relação [1][12] (condições (b) e (B) da sub-seção 3.2)

$$f(v) \approx C_H |v|^{1-2H} \tag{17}$$

A eq. (17) corresponde ao comportamento assintótico do movimento Browniano fracional [14][16]. A eq. (18) apresenta uma estrutura que obedece a uma lei de potência (veja a Fig. 4). Portanto, tendo escolhido o modelo espectral do processo, este será ajustado para o espectro medido pelo processo de minimização dado por

$$R(H) = \log \left(\frac{1}{M} \sum_{j=1}^M \frac{I(v_j)}{v_j^{1-2H}} \right) - (2H-1) \frac{1}{M} \sum_{j=1}^M \log(v_j) \tag{18}$$

É bom lembrar que o comportamento dado pela eq. (18) é assumido tanto para os processos DCD como os DLD na minimização. O estimador de Whittle fornece ainda intervalos de confiança que podem ser calculados por 1.96σ onde σ é dado por $\sigma^2 = 4\pi R(\hat{H})/N_s$

A Fig. 11 mostra a minimização correspondente a um processo com DLD e a Fig. 12 mostra a minimização correspondente a um processo com DCD. Os resultados obtidos para ambos tipos de processos estão resumidos na Tabela 1.




Figura 11. Estimador de Whittle para um processo com DLD




Figura 12. Estimador de Whittle para um processo com DCD

	H (Parâmetro de Hurst)	Intervalo de Confidência
Processo com DCD	0,49	± 0.01
Processo com DLD	0,87	± 0.03

Tabela 1. Resultados do estimador de Whittle local

Pelos resultados obtidos e apresentados na Tabela I é possível inferir que evidentemente o processo com DCD mostra características Markovianas, devido que para tais processos verifica-se que possuem um parâmetro de Hurst $H \approx 0.5$, portanto carecem de memória, obedecendo assim à eq. (12). Por outro lado, para um processo com DLD o resultado é categórico, este processo apresenta um parâmetro de Hurst bem definido no intervalo $0.5 < H < 1$, que para este caso em particular é $H \approx 0.87$.

4.5 Medida de Desempenho de Uma Fila com Ambos tipos de Tráfego como processos de Entrada

Esta sub-seção apresenta brevemente uma análise de desempenho de uma fila tendo como processos de entrada tráfego com DCD e DLD em forma separada, como mostra a Fig. 13.




Figura 13. Modelo simples de fila.

A Fig. 13 mostra um modelo simples de fila sendo que, os resultados obtidos refletem claramente o risco de considerar-se o processo de entrada como sendo DCD ou DLD.

A Fig. 14 mostra a análise de desempenho da fila da Fig. 13, o processo com DCD apresenta claramente resultados clássicos da teoria de filas, é interessante mostrar que para um valor de $H \approx 0.5$ o desempenho do buffer coincide com o modelo de filas clássico $M/M/1$ (datagramas IP) e o modelo de fila $M/D/1$ (ATM).




Figura 14 Análise de desempenho de fila para processos com DCD e DLD

O panorama muda, mais uma vez, quando o processo de entrada apresenta características de DLD. Para este caso, com um fator de utilização da fila pequeno, o comprimento no tamanho do buffer aumenta consideravelmente (Fig. 14), este resultado é crítico sobretudo para o desenho de algoritmos de controle de congestionamento e de admissão de chamada.

5. CONCLUSÕES

Este artigo pretende fornecer um resumo claro e completo entre as características dos processos com DCD e DLD, este artigo não pretende mostrar resultados “novos”. Em relativamente pouco tempo a descoberta das características de dependência de longa duração (DLD) no comportamento do tráfego das atuais redes de alta velocidade tem produzido uma enorme pesquisa na área de engenharia de tráfego, portanto muitos artigos técnicos, mas ainda poucos livros, surgiram focalizando estes tópicos.

Uma conclusão que pode ser feita é a de considerar o tráfego de redes como um ruído colorido e não como um ruído branco, isto porque segundo a teoria dos grandes números ou teorema central do limite garante a regularidade estatística quando varios processos com diferentes distribuições marginais são agregados, a través dos diferentes testes e resultados qualitativos deste artigo pode-se visualizar que tal afirmação, considerando-se o tráfego de redes, pode ser altamente questionado.

Finalmente o processo utilizado para os testes de DLD foram series de tempo que correspondem a tráfego Internet real coletado no nosso *gateway* da rede do Instituto Tecnológico de Aeronáutica (ITA).

AGRADECIMENTOS

Este trabalho é suportado economicamente pelo projeto Objetivo-6 ITA da Organização de Aeronáutica Civil Internacional (ICAO).

REFERÊNCIAS

- [1] LELAND, Willie E. , TAQQU, Murad S., WILLINGER, Walter, WILSON, Daniel V. On the Self-Similar Nature of Ethernet Traffic. IEEE/ACM Trans. On Networking, v. 2, n.1, p. 1-15, Feb. 1994.
- [2] STALLINGS, William. Viewpoints: Self-similarity upsets data traffic assumptions. IEEE Spectrum. p. 28-29, Jan. 1997.
- [3] WILLINGER, Walter., PAXSON, Vern. Where Mathematics Meets the Internet. Notice of the AMS. p. 961-970, September 1998.
- [4] TAQQU, Murad, S., WILLINGER, Walter., SHERMAN, Robert. Proof of a Fundamental Result in Self-similar Traffic Modeling. Computer Communication Review No 27, p. 5-23, 1997.
- [5] WILLINGER, Walter, TAQQU, Murad S., SHERMAN, Robert, WILSON, Daniel V. Self-Similarity Through High-Variability: Statistical Analysis of Ethernet LAN Traffic at the Source Level. IEEE/ACM Trans. on Networking, v. 5, n. 1, Feb. 1997.
- [6] HEFFES, H., LUCANTONI, David M. A Markov Modulated Characterization of Packetized Voice and Data Traffic and Related Statistical Multiplexer Performance. IEEE JSAC, Sept. 1986.
- [7] PAPOULIS, A. Probability, Random Variables, and Stochastic Processes. 3.ed. USA: McGraw-Hill, 1991.
- [8] KELLY, Frank, P., Modeling communication networks, present and future, The Clifford Paterson Lecture, No 144, p. 1-20, 1995.
- [9] BERAN, Jan, SHERMAN, Robert, TAQQU, Murad S., WILLINGER, Walter. Long-Range Dependence in Variable-Bit-Rate Video Traffic. IEEE Trans. Commun., p.1566-1579, 1995.
- [10] PAXSON, V. Fast Approximate Synthesis of Fractional Gaussian Noise for Generating Self-Similar Network Traffic. ACM SIGCOMM Computer Communication Review, v. 27, n. 5, Oct. 1997.
- [11] ADAS, Abdelnaser, MUKHERJEE, Amarnath. On Resource Management and QoS Guarantees For Long Range Dependent Traffic. In: IEEE INFOCOM'95. Proceedings... Boston : [s. n.], 1995.
- [12] BERAN, Jan. Statistics for Long-Memory Processes. USA : Chapman & Hall, 1994.
- [13] HUANG, C., DEVETSIKIOTIS, M., LAMBADARIS, I., KAYE, A. Modeling and Simulation of Self-Similar Variable Bit Rate Compressed Video: A Unified Approach. In: ACM SIGCOMM'95. Proceedings... Cambridge, MA: [s. n.], 1995.
- [14] TAQQU, Murad S., TEVEROVSKY, Vadim. Robustness of Whittle-type Estimators for Time Series with Long-Range Dependence, 1997. Preprint of Stochastic Models.
- [15] ANGULO MIRANDA, Anibal, D., Caracterização Auto-similar do Tráfego IP e Implicações Nas Redes ATM, Dissertação Tese de Mestrado, ITA Outubro 1998.
- [16] SAMORODNITSKY, G., TAQQU, Murad S. Stable Non-Gaussian Random Processes. Chapman & Hall, 1994.