

Universidade Federal de Goiás
Escola de Engenharia Elétrica, Mecânica e de Computação
Programa de Mestrado em Engenharia Elétrica e de Computação

**Análise de Desempenho de Sistemas de
Comunicação OFDM-TDMA Utilizando
Cadeias de Markov e Curva de Serviço**

Victor Hugo Teles Costa

Área de Concentração: Engenharia de Computação
Orientador: Prof. Dr. Flávio Henrique Teles Vieira

Goiânia – GO
Novembro / 2013

Victor Hugo Teles Costa

Análise de Desempenho de Sistemas de Comunicação OFDM-TDMA Utilizando Cadeias de Markov e Curva de Serviço

Dissertação apresentada ao Programa de Pós-Graduação Strictu Sensu da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás com vistas à obtenção do título de Mestre em Engenharia Elétrica e de Computação.

Engenharia de Computação

Escola de Engenharia Elétrica, Mecânica e de Computação

Universidade Federal de Goiás

Orientador: Prof. Dr. Flávio Henrique Teles Vieira

Goiânia – GO

Novembro / 2013

Dados Internacionais de Catalogação na Publicação (CIP)
GPT/BC/UFG

C837a Costa, Victor Hugo Teles.
Análise de desempenho de sistemas de comunicação OFDM-TDMA utilizando cadeias de Markov e curva de serviço [manuscrito] / Victor Hugo Teles Costa. – 2013.
121 f. : il., figs., grafs., tabs.

Orientador: Prof. Dr. Flávio Henrique Teles Vieira.
Dissertação (Mestrado) – Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação, 2013.
Bibliografia.
Inclui lista de figuras, tabelas, abreviaturas e siglas.

1. Teoria de filas. 2. Sistemas de comunicação sem fio. 3. Método de Kernel. 4. Curva de serviço. I. Título.

CDU: 004.7:621.39

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR AS TESES E DISSERTAÇÕES ELETRÔNICAS (TEDE) NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: ☒ **Dissertação** ☐ **Tese**

2. Identificação da Tese ou Dissertação

Autor:	Victor Hugo Teles Costa		
E-mail:	victor@vcosta.com.br		
Seu e-mail pode ser disponibilizado na página?	☒ Sim	☐ Não	
Vínculo empregatício do autor			
Agência de fomento:		Sigla:	
País:	UF:	CNPJ:	
Título:	Análise de Desempenho de Sistemas de Comunicação OFDM-TDMA Utilizando Cadeias de Markov e Curva de Serviço		
Palavras-chave:	Teoria de Filas, Sistemas de Comunicação Sem Fio, OFDM-TDMA, Método de Kernel, MMFM, Processo Envelope, Curva de Serviço, QoS		
Título em outra língua:	Performance Analysis of OFDM-TDMA Wireless Systems Based on Markov Chain and Service Curve		
Palavras-chave em outra língua:	Queueing Analysis, Wireless Systems, OFDM-TDMA, Kernel Density Estimation, MMFM, Envelope Process, Service Curve. QoS		
Área de concentração:	Engenharia de Computação		
Data defesa: (dd/mm/aaaa)	06/12/2013		
Programa de Pós-Graduação:	Programa de Mestrado em Engenharia Elétrica e de Computação		
Orientador:	Prof. Dr. Flávio Henrique Teles Vieira		
E-mail:	flavio@emc.ufg.br		


*Necessita do CPF quando não constar no SisPG

3. Informações de acesso ao documento:

Concorda com a liberação total do documento ☒ SIM ☐ NÃO¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF ou DOC da tese ou dissertação.

O sistema da Biblioteca Digital de Teses e Dissertações garante aos autores, que os arquivos contendo eletronicamente as teses e ou dissertações, antes de sua disponibilização, receberão procedimentos de segurança, criptografia (para não permitir cópia e extração de conteúdo, permitindo apenas impressão fraca) usando o padrão do Acrobat.



Assinatura do autor

Data: 05 / 02 / 2014

¹ Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.



FOLHA DE APROVAÇÃO

**"Análise de Desempenho de Sistemas de
Comunicação OFDM – TDMA Utilizando Cadeias
de Markov e Curva de Serviço"**

VICTOR HUGO TELES COSTA

Dissertação defendida e aprovada pela banca examinadora constituída pelos senhores:

Flávio Henrique Teles Vieira – Orientador (EMC/UFG)

Priscila Solís Barreto - UNB

Rodrigo Pinto Lemos – EMC/UFG

Goiânia, 06 de dezembro de 2013

*Este trabalho é dedicado a meus avós, que, em sua simplicidade,
muito me ensinaram, e à minha namorada, Debbie, que, independente das
circunstâncias, sempre esteve ao meu lado.*

Agradecimentos

É com grande satisfação que me encontro no final de mais uma etapa de minha vida. Foram dois anos de muito esforço e, graças a Deus, muitos desafios foram vencidos.

Agradeço imensamente à minha família pelo suporte que sempre me deu. Sou eternamente grato aos meus pais, que lutaram pela minha educação e saúde mesmo nos momentos em que não dispúnhamos de muitos recursos. As oportunidades que tive na vida se devem ao suor deles. Agradeço à minha mãe pela infinita paciência e amor que demonstrou ao longo de minha vida. Seu consolo e carinho muitas vezes me reergueram para seguir meu caminho. Agradeço aos meus avós que, na sua simplicidade, me ensinaram a humildade e o valor das pessoas. Sou grato por sempre me acolherem com muita alegria.

Também agradeço à minha namorada e querida companheira, que há anos está ao meu lado e, junto à minha família, integra meu alicerce.

Muito obrigado ao meu orientador, Professor Dr. Flávio Vieira, por todo o apoio e experiência compartilhada e também por ter me possibilitado novas oportunidades de crescimento profissional desde que nos conhecemos.

Resumo

Este trabalho apresenta um modelo baseado em Cadeias de Markov e aprimorado com o uso do método de Kernel de estimação não-paramétrica e de MMFM (*Markov Modulated Fluid Model*) com o objetivo de avaliar e descrever o desempenho do enlace de transmissão em sistemas OFDM-TDMA. Para tal, modelos de tráfego baseados no Método de Kernel e em MMFM com ajuste da função de autocorrelação são propostos. A partir do modelo implementado para o sistema OFDM-TDMA, foram obtidas equações para estimação de parâmetros de QoS como retardo e tamanho médio da fila no *buffer*. Os resultados obtidos confirmam que o modelo proposto é bastante eficiente ao descrever os indicadores de desempenho do sistema. O uso de MMFM para modelar o processo de chegada de pacotes aprimora os estimadores de parâmetros de QoS tornando as estimativas bem próximas dos valores obtidos com as simulações. Também deduziu-se uma equação para a curva de serviço de Sistemas OFDM-TDMA. Em seguida, utilizando-se desta curva de serviço e do conceito de Processo Envelope foi proposta uma equação para estimação de probabilidade de transbordo do *buffer* em sistemas OFDM-TDMA. Os resultados obtidos mostram que as estimativas de probabilidade de transbordo baseadas na curva de serviço do sistema se aproximam bem dos resultados da simulação e a complexidade computacional do cálculo necessário para obtê-los é significativamente reduzida em relação ao modelo definido utilizando Cadeias de Markov.

Palavras-chaves: Teoria de Filas. Sistemas de Comunicação Sem Fio. OFDM-TDMA. Método de Kernel. MMFM. Processo Envelope. Curva de Serviço. QoS.

Abstract

This paper presents a model based on Markov Chains and enhanced with the use of Kernel Density Estimation and of MMFM (Markov Modulated Fluid Model) in order to evaluate the performance of the transmission link in OFDM-TDMA systems. For that purpose, traffic models based on the Kernel method and the MMFM with adjusted autocorrelation function are proposed. From the model implemented for the OFDM-TDMA system, it was derived equations for estimation of QoS parameters such as delay and average queue size in the buffer. The obtained results confirm that the proposed model is efficient in describing the link performance indicators. The use of MMFM to model the arrival process improves the QoS parameter estimates of the queueing model making their values very close to those of the simulation results. It was also developed an equation to the OFDM-TDMA system's service curve. Through this equation and the concept of Envelope Process, it was proposed an equation to estimate the probability of buffer overflow in OFDM-TDMA systems. The results show that the estimates of the overflow probability based on the system's service curve are very close to the ones obtained by simulations and that the computational complexity to obtain them is significantly reduced compared to the model based on Markov Chains due to the absence of matrix computation.

Key-words: Queueing Analysis. Wireless Systems. OFDM-TDMA. Kernel Density Estimation. MMFM. Envelope Process. Service Curve. QoS.

Lista de ilustrações

Figura 1 – Ilustração de uma subportadora nos domínios do tempo e da frequência	24
Figura 2 – Subportadoras ortogonais sobrepostas	25
Figura 3 – Estrutura da Transmissão OFDM	25
Figura 4 – Cenário da transmissão da informação 1101011000 utilizando modulação BPSK	27
Figura 5 – Diagrama de Constelação da modulação QPSK	28
Figura 6 – Diagrama de Constelação da modulação 16-QAM	29
Figura 7 – Divisão das Subportadoras em Subcanais na transmissão OFDMA . . .	30
Figura 8 – Divisão do Acesso ao Canal OFDM pelo Tempo	31
Figura 9 – Componentes Gerais de um Sistema de Fila	32
Figura 10 – Densidade de probabilidade para diferentes valores de λ	39
Figura 11 – Polígono composto de cópias repetidas de um pentagrama (LAUWERIER, 1991)	46
Figura 12 – Processo de construção da cascata binomial (VIEIRA; LING, 2008) . .	49
Figura 13 – Número de pacotes que chegam em cada <i>frame</i> considerando a série <i>voip-call-1</i>	53
Figura 14 – Número de pacotes que chegam em cada <i>frame</i> considerando a série <i>dec-pkt-1</i>	53
Figura 15 – Número de pacotes que chegam em cada <i>frame</i> considerando a série <i>new-zealand-isp</i>	54
Figura 16 – Função densidade de probabilidade que descreve a série <i>voip-call-1</i> . .	54
Figura 17 – Função de probabilidade acumulada que descreve a série <i>voip-call-1</i> . .	55
Figura 18 – Função densidade de probabilidade que descreve a série <i>dec-pkt-1</i> . . .	55
Figura 19 – Função de probabilidade acumulada que descreve a série <i>dec-pkt-1</i> . . .	56
Figura 20 – Função densidade de probabilidade que descreve a série <i>new-zealand-isp</i>	56
Figura 21 – Função de probabilidade acumulada que descreve a série <i>new-zealand-isp</i>	57
Figura 22 – Taxa de fluxo de pacotes da série <i>voip-call-1</i>	58
Figura 23 – Taxa de fluxo de pacotes da série <i>dec-pkt-1</i>	59
Figura 24 – Taxa de fluxo de pacotes da série <i>new-zealand-isp</i>	60
Figura 25 – Função de autocorrelação da série <i>voip-call-1</i>	62
Figura 26 – Função de autocorrelação da série <i>dec-pkt-1</i>	63
Figura 27 – Função de autocorrelação da série <i>new-zealand-isp</i>	63

Figura 28 – Cenário do sistema considerado: uma Estação Base conectada a várias Estações Assinantes	65
Figura 29 – Modelo da Transmissão OFDM-TDMA	65
Figura 30 – Função massa de probabilidade da taxa de transmissão total para diferentes valores de SNR no Cenário 1	74
Figura 31 – Função massa de probabilidade da taxa de transmissão total para diferentes valores de SNR no Cenário 2	74
Figura 32 – Função massa de probabilidade da taxa de transmissão total para diferentes valores de SNR no Cenário 3	75
Figura 33 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1	77
Figura 34 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2	78
Figura 35 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3	79
Figura 36 – Probabilidade da fila do usuário se encontrar em cada estado possível obtida a partir de simulação do Cenário 1	80
Figura 37 – Probabilidade da fila do usuário se encontrar em cada estado possível obtida a partir de simulação do Cenário 2	80
Figura 38 – Probabilidade da fila do usuário se encontrar em cada estado possível obtida a partir de simulação do Cenário 3	81
Figura 39 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1 para SNR = 8 dB	82
Figura 40 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1 para SNR = 12 dB	83
Figura 41 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1 para SNR = 16 dB	84
Figura 42 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2 para SNR = 8 dB	85
Figura 43 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2 para SNR = 12 dB	86
Figura 44 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2 para SNR = 16 dB	87
Figura 45 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3 para SNR = 8 dB	88
Figura 46 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3 para SNR = 12 dB	89
Figura 47 – Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3 para SNR = 16 dB	90

Figura 48 – Probabilidade do <i>buffer</i> se encontrar vazio no Cenário 1	91
Figura 49 – Probabilidade do <i>buffer</i> se encontrar vazio no Cenário 2	91
Figura 50 – Probabilidade do <i>buffer</i> se encontrar vazio no Cenário 3	92
Figura 51 – Probabilidade do <i>buffer</i> se encontrar cheio no Cenário 1	92
Figura 52 – Probabilidade do <i>buffer</i> se encontrar cheio no Cenário 2	93
Figura 53 – Probabilidade do <i>buffer</i> se encontrar cheio no Cenário 3	93
Figura 54 – Tamanho médio da fila no Cenário 1	94
Figura 55 – Tamanho médio da fila no Cenário 2	94
Figura 56 – Tamanho médio da fila no Cenário 3	95
Figura 57 – Atraso médio dos pacotes transmitidos no Cenário 1	95
Figura 58 – Atraso médio dos pacotes transmitidos no Cenário 2	96
Figura 59 – Atraso médio dos pacotes transmitidos no Cenário 3	96
Figura 60 – Probabilidade de transbordo do <i>buffer</i> no Cenário 1	97
Figura 61 – Probabilidade de transbordo do <i>buffer</i> no Cenário 2	97
Figura 62 – Probabilidade de transbordo do <i>buffer</i> no Cenário 3	98
Figura 63 – A resposta ao impulso da concatenação de dois circuito linear é (a) a convolução da resposta ao impulso individual, a curva de formação da concatenação de dois reguladores é (b) a convolução das curvas individuais modeladas (BOUDEC; THIRAN, 2001)	100
Figura 64 – Exemplos de funções de entradas e saídas (BOUDEC; THIRAN, 2001)	102
Figura 65 – Exemplo de restrição por curva de chegada, demonstrando um efeito cumulativo da função $R(t)$ limitado pela curva de chegada $\alpha(t)$	104
Figura 66 – Curva de serviço do usuário 1	108
Figura 67 – Curva de serviço do usuário 1 no cenário considerado do sistema OFDM- TDMA	110
Figura 68 – Probabilidade de transbordo do <i>buffer</i> do usuário no cenário conside- rado do sistema OFDM-TDMA	111
Figura 69 – Probabilidade de transbordo do <i>buffer</i> no Cenário 1	112
Figura 70 – Probabilidade de transbordo do <i>buffer</i> no Cenário 2	113
Figura 71 – Probabilidade de transbordo do <i>buffer</i> no Cenário 3	113
Figura 72 – Probabilidade de transbordo do <i>buffer</i> no Cenário 4	114
Figura 73 – Probabilidade de transbordo do <i>buffer</i> no Cenário 5	114

Lista de tabelas

Tabela 1 – Modulação BPSK	27
Tabela 2 – Modulação QPSK	28
Tabela 3 – Parâmetros estatísticos - Série <i>voip-call-1</i>	61
Tabela 4 – Parâmetros estatísticos - Série <i>dec-pkt-1</i>	61
Tabela 5 – Parâmetros estatísticos - Série <i>new-zealand-isp</i>	62
Tabela 6 – Cenários do sistema OFDM-TDMA considerados	73
Tabela 7 – Cenários do sistema OFDM-TDMA considerados	112

Lista de abreviaturas e siglas

AWMM	<i>Adaptive Wavelet Based Multifractal Model</i>
BER	Probabilidade de Erro de Bit (<i>Bit Error Rate</i>)
BPSK	<i>Binary Phase Shift Keying</i>
CDMA	<i>Code Division Multiple Access</i>
CGMD	<i>Cascade with Generalized Multiplier Distributions</i>
fBm	<i>fractional Brownian motion</i>
FDD	<i>Frequency Division Duplex</i>
FFT	<i>Fast Fourier Transform</i>
ISP	<i>Internet Service Provider</i>
LRD	<i>Long Range Dependency</i>
LTE	<i>Long-Term Evolution</i>
MAN	<i>Metropolitan Area Network</i>
mBm	<i>multifractional Brownian motion</i>
MIT	<i>Massachusetts Institute of Technology</i>
MMFM	<i>Markov Modulated Fluid Model</i>
MWM	<i>Multifractal Wavelet Model</i>
OFDM	<i>Orthogonal Frequency Division Multiplexing</i>
OFDMA	<i>Orthogonal Frequency Division Multiple Access</i>
PSK	<i>Phase Shift Keying</i>
QAM	<i>Quadrature Amplitude Modulation</i>
QoS	<i>Quality of Service</i>
QPSK	<i>Quadrature Phase Shift Keying</i>

RF	Radiofrequência
SNR	Relação Sinal-Ruído (<i>Signal-to-Noise Ratio</i>)
TDD	<i>Time Division Duplex</i>
TDMA	<i>Time Division Multiple Access</i>
WAN	<i>Wide Area Network</i>
WiMAX	<i>Worldwide Interoperability for Microwave Access</i>
WLAN	<i>Wireless Local Area Network</i>
WMAN	<i>Wireless Metropolitan Area Network</i>

Lista de símbolos

$A(t)$	Quantidade acumulada de pacotes que chegam ao <i>buffer</i> no intervalo $[0, t)$
b	Número médio de pacotes na fila do usuário (<i>backlog</i>)
B	Largura de banda do canal de transmissão
C	Nível de modulação máximo
$c_{m,n}(t)$	Nível de modulação de um símbolo OFDM transmitido em t por uma subportadora m para o usuário n
d	Atraso médio de um pacote (<i>delay</i>)
Δf	Largura de banda de cada subportadora
$f(v)$	Função densidade de probabilidade que descreve o processo de chegada de pacotes do usuário
$F(v)$	Função distribuição de probabilidade acumulada que descreve o processo de chegada de pacotes do usuário
f_s	Frequência de amostragem
$\gamma_{m,n}(t)$	SNR instantânea num símbolo OFDM transmitido em t por uma subportadora m para o usuário n
H	Parâmetro de Hurst
$H(t)$	Expoente de Hölder
K_r	Processo estocástico que define a série de tráfego agregada na escala de tempo r
L	Tamanho médio dos pacotes
λ	Número médio de pacotes que chegam por <i>frame</i> por usuário
$\mathbf{P}$	Matriz de probabilidade de transição da Cadeia de Markov
P_{ber}	Probabilidade de erro de bit

$P_{c_{m,n}}(c)$	Probabilidade de uma subportadora m utilizar um nível de modulação c na transmissão para o usuário n
$p_{i,j}$	Probabilidade de transição da Cadeia de Markov do estado i para o estado j
π_i	Probabilidade de o sistema se encontrar no estado i da Cadeia de Markov em regime permanente
π	Vetor das probabilidades de o sistema se encontrar em cada estado possível da Cadeia de Markov em regime permanente
$\pi_i(n)$	Probabilidade de o sistema se encontrar no estado i da Cadeia de Markov no tempo n
$\pi(n)$	Vetor das probabilidades de o sistema se encontrar em cada estado possível da Cadeia de Markov no tempo n
$\pi(x)$	Probabilidade de o <i>buffer</i> do usuário conter x pacotes
$Pr_{m,n}(r_m)$	Probabilidade de uma subportadora m transmitir com taxa r_m para o usuário n
P_{transb}	Probabilidade de transbordo do <i>buffer</i> de um usuário
$Q(t)$	Quantidade total de tráfego armazenado no <i>buffer</i> no intervalo $[0, t)$
M	Número de subportadoras do canal OFDM
N	Número de usuários
N_{FFT}	Número de subportadoras do canal OFDM
R	Número máximo de pacotes transmitidos durante um <i>frame</i>
$r(c)$	Número de pacotes transmitidos durante um <i>frame</i> por subportadora
r_m	Taxa de transmissão de pacotes numa subportadora m
$r_{m,n}$	Função massa de probabilidade da taxa de transmissão de pacotes por uma subportadora m para o usuário n
$\mathbf{R}_n$	Função massa de probabilidade da taxa de transmissão total de pacotes para o usuário n
$S(t)$	Curva de serviço do sistema de transmissão
$S_n(t)$	Curva de serviço do sistema de transmissão para o usuário n

T	Duração de um <i>frame</i> OFDM
$\mathbf{U}$	Matriz de probabilidade de transição que representa o escalonamento <i>round-robin</i>
V	Número máximo de pacotes que podem entrar na fila de transmissão durante um <i>frame</i>
X	Tamanho do <i>buffer</i> do usuário

Artigos Publicados

1. Vieira, F. H. T.; Costa, V. H. T.; Gonçalves, B. H. P. Neural Network Based Approaches for Network Traffic Prediction. In: Xin-She Yang. Artificial Intelligence, Evolutionary Computing and Metaheuristics: In the Footsteps of Alan Turing. Heidelberg: Springer, 2013.
2. Vasques, T. L. V.; Vieira, F. H. T.; Gonçalves, B. H. P.; Costa, V. H. T.; Araújo, S. G. Modelo Baseado em Cadeias de Markov para Estimção de Vazão em Redes PLC Homeplug. In: MOMAG 2012, João Pessoa, 2012.
3. Vieira, F. H. T.; Santos Júnior, J. A.; Costa, V. H. T. Aplicação de Cálculo de Rede para Estimção de Retardo e Tamanho Médio da Fila em Sistemas OFDM-TDMA com Policiamento de Tráfego. In: MOMAG 2012, João Pessoa, 2012.
4. De Sousa, M. A.; Vieira, F. H. T.; Carlson, C. M. F.; Gonçalves, B. H. P.; Costa, V. H. T. Sistema de Apoio à Decisão MILP-Fuzzy para o Planejamento de Redes de Acesso em Telecomunicações. In: Rodrigues, L. C. de A.; Steiner, M. T. A.; Lopes, H. S. Metaheurísticas em Pesquisa Operacional. Omnipax, 2012.
5. Costa, V. H. T.; Deus Júnior, G. A. Sistemas de Comunicações Sem Fio: LTE. In: III Seminário de Pesquisa - IX Conpeex: Congresso de Pesquisa, Ensino e Extensão - UFG, Goiânia, 2012.
6. Costa, V. H. T.; Vieira, F. H. T.; Souza, G. B. de C. Performance Modeling and Analysis of OFDM-TDMA-based Wireless Systems Based on Queueing Theory. In: International Workshop on Telecommunications, Santa Rita do Sapucaí, 2013.
7. Costa, V. H. T.; Fernandes, J.; Gonçalves, B. H. P.; Vieira, F. H. T.; Alves, L. Estimção do tempo médio de resposta do servidor em plataformas de ensino a distância do tipo cliente-servidor utilizando modelo baseado em teoria de filas. In: X Encontro Anual de Computação. 2013.
8. Gonçalves, B. H. P.; Vieira, F. H. T.; Costa, V. H. T. Modelagem multifractal betamwm adaptativa para tráfego de redes de computadores. In: X Encontro Anual de Computação. 2013.
9. Costa, V. H. T.; Vieira, F. H. T.; Gonçalves, B. H. P. Modelagem e Análise De Desempenho De Sistemas De Comunicação OFDM-TDMA Baseadas Em Teoria De Fila. In: XXXI Simpósio Brasileiro de Telecomunicações, Fortaleza, 2013.

10. Sousa, M. A. de; Souza, F.; Vieira, F. H. T.; Costa, V. H. T.; Campos, E. Interconexão De ERBs Em Um SMC - Um MILP Para Alocação e Dimensionamento De Enlaces SDH. In: XXXI Simpósio Brasileiro de Telecomunicações, Fortaleza, 2013.
11. Gonçalves, B. H. P.; Vieira, F. H. T.; Costa, V. H. T. Alocação Dinâmica De Slots De Tempo Multiusuário Para Redes OFDM-TDMA Baseada Em Banda Efetiva. In: XXXI Simpósio Brasileiro de Telecomunicações, Fortaleza, 2013.
12. Costa, V. H. T.; Vieira, F. H. T. Análise De Desempenho de Sistemas de Comunicação OFDM-TDMA Utilizando Teoria de Filas e Método de Kernel. In: X Seminário de Pós-Graduação - X Conpeex: Congresso de Pesquisa, Ensino e Extensão - UFG, Goiânia, 2013.

Sumário

Introdução	21
Análise de Desempenho Baseada em Teoria de Filas	23
1 Sistemas OFDM	24
1.1 Modulação Digital	26
1.1.1 Modulação PSK	26
1.1.2 Modulação QAM	27
1.2 Técnicas de Acesso Múltiplo	30
1.2.1 OFDMA	30
1.2.2 OFDM-TDMA	31
2 Teoria de Filas	32
2.1 Processos Estocásticos	32
2.1.1 Processo Estacionário	33
2.1.2 Processo Markoviano	33
2.1.3 Processo de Quase Nascimento e Morte	33
2.2 Cadeia de Markov em Tempo Discreto	34
2.2.1 Comportamento do Sistema em Estado Transiente	35
2.2.2 Comportamento do Sistema em Estado Estacionário	35
3 Modelagem de Fluxos de Tráfego de Redes de Computadores	37
3.1 Modelo de Poisson	39
3.2 Método de Kernel	40
3.3 <i>Markov Modulated Fluid Model</i>	41
3.4 Modelo Movimento Browniano Fractal (fBm)	43
3.4.1 Parâmetro de Hurst	45
3.4.2 Função de Autocorrelação	46
3.5 Processos Multifractais	47
3.6 Modelo Movimento Browniano Multifractal (mBm)	47
3.6.1 Expoente de Hölder e o Modelo mBm	48
3.7 Modelo Cascatas Multiplicativas	49
3.8 Modelo MWM	50
3.9 Modelo AWMM	51
3.10 Modelo CGMD	51
3.11 Simulações e Resultados: Avaliação dos Modelos de Tráfego	52

4	Análise de Desempenho de Sistemas OFDM-TDMA Utilizando Cadeias de Markov	64
4.1	Modelo do Sistema OFDM-TDMA	64
4.2	Transmissão OFDM	65
4.3	Formulação do Modelo baseado em Cadeias de Markov para o Sistema de Filas	67
4.4	Estimação de Parâmetros de QoS	71
4.5	Simulações e Resultados	73
5	Estimação de Probabilidade de Transbordo do <i>Buffer</i> em Sistemas OFDM-TDMA Utilizando Curva de Serviço Baseada em Cálculo de Rede	99
5.1	Cálculo de Rede Determinístico	99
5.1.1	Funções Cumulativas a Tempo Discreto <i>Versus</i> Modelos de Tempo Contínuo	101
5.1.2	Processo Envelope	103
5.1.3	Curvas de Serviço	105
5.2	Probabilidade de Transbordo do <i>Buffer</i> Utilizando Processo Envelope	106
5.3	Curva de Serviço Aplicada ao Cálculo da Probabilidade de Transbordo em Sistemas OFDM-TDMA	108
5.4	Simulações e Resultados	109
	Conclusões	115
	Referências	117

Introdução

Desde 1897, quando Guglielmo Marconi primeiramente demonstrou a utilidade do rádio na comunicação com navios, os métodos de comunicação sem fio vêm se desenvolvendo acentuadamente, com destaque para as últimas duas décadas devido ao grande desenvolvimento de sistemas de comunicações móveis.

Particularmente, os sistemas de comunicações móveis demoraram para se espalharem entre a população em geral, pois não havia tecnologia própria para o uso intensivo por vários usuários simultaneamente e nem tecnologia acessível que possibilitava a mobilidade dos dispositivos envolvidos. Foi a criação do conceito de telefonia celular, envolvendo reuso de frequência e *handoff*, pelo Laboratório Bell, nas décadas de 60 e 70, em conjunto com o desenvolvimento de *hardware* portátil de radiofrequência (RF), que possibilitou o nascimento da era da comunicação sem fio (RAPPAPORT, 2001), marcada pela disseminação do uso desta tecnologia. Desde então, os sistemas de comunicações sem fio constituem uma das áreas mais ativas com relação à evolução tecnológica.

Pode ser dito que, num primeiro momento, os usos dos sistemas de comunicações sem fio eram voltados principalmente para a transmissão de voz na telefonia. Porém, com o desenvolvimento de novas tecnologias, como as redes sem fio de computadores e a internet móvel, novos serviços passam a ser suportados no mesmo meio, como a transmissão de imagens, vídeo, e dados. Ao mesmo tempo, a demanda por esses serviços de grande utilidade cresce numa taxa muito elevada.

No entanto, diferentemente dos sistemas de comunicações com fio, os recursos que possibilitam os sistemas sem fio, largura de banda no espectro de radiofrequências e potência do transmissor, são muito limitados e, por consequência, a oferta dos serviços não cresce na mesma taxa da demanda, forçando ainda mais o desenvolvimento das tecnologias envolvidas.

Neste contexto de alto crescimento na demanda por acesso à Internet sem fio e serviços multimídia interativos, onde deve haver suporte a taxas de transmissão de dados elevadas, surgiu o OFDM (*Orthogonal Frequency Division Multiplexing*), técnica de multiplexação de sinais inovadora com elevada taxa de transmissão, eficiência espectral e alto desempenho contra interferências. Nas próximas seções o OFDM será abordado mais detalhadamente junto com as estratégias existentes para acesso por múltiplos usuários.

Atualmente, a modulação OFDM (*Orthogonal Frequency Division Multiplexing* (PRASAD, 2004)) é utilizado em uma gama de redes sem fio de alta velocidade, em redes

locais sem fio (WLAN) como o Wi-Fi (padrão IEEE 802.11 (IEEE, 2012)), em redes metropolitanas sem fio (WMAN) como o WiMAX (padrão IEEE 802.16 (IEEE, 2004)) e no LTE (3GPP, 2013). Todas estas tecnologias são promissoras no mundo contemporâneo das telecomunicações, tendo em vista a inovação trazida e os investimentos recentemente realizados para implantação e desenvolvimento dessas tecnologias em inúmeros países.

Para medir a qualidade de serviço (QoS) em nível de transmissão de pacotes, o comportamento da fila de pacotes deve ser analisado. Um modelo baseado em teoria de filas pode ser utilizado com o objetivo de obter parâmetros ótimos para que a configuração de um sistema atenda determinados requisitos de QoS. Por outro lado, esse modelo também pode ser útil para alocação adaptativa de recursos do sistema. Por exemplo, ao utilizar este modelo, a taxa de transmissão para cada usuário do sistema em um dado momento pode ser ajustada para que o número de pacotes bloqueados e o atraso se mantenham abaixo de um determinado nível.

Este trabalho apresenta um modelo fundamentado em Teoria de Filas, Cadeias de Markov, método de Kernel e MMFM (*Markov Modulated Fluid Model*) para avaliar o desempenho do enlace de transmissão em sistemas OFDM-TDMA. Enquanto a transmissão baseada em OFDM eleva a taxa de transmissão, o acesso por múltiplos usuários é garantido através de TDMA (*Time Division Multiple Access*) (TAROKH, 2009), a serem apresentados nas próximas seções. Um modelo de filas para o mecanismo OFDM-TDMA pode ser estabelecido (NIYATO; HOSSAIN, 2005). No entanto, para garantir maior fidelidade na representação, propomos neste trabalho a utilização de um modelo baseado em Teoria de Filas onde o processo de chegada de pacotes dos usuários seja modelado utilizando-se técnicas avançadas de modelagem de processos, especificamente o método de Kernel de estimação não-paramétrica (WEBB; COPSEY, 2011) e o MMFM com ajuste da função de autocorrelação de acordo com a dos fluxos de tráfego considerados (ROCHA; SANTOS; VIEIRA, 2011) (BOSMAN; MEI; NUNEZ-QUEIJA, 2012). Do modelo desenvolvido são derivados vários indicadores de QoS, como o número médio de pacotes na fila formada para transmissão, o atraso médio na transmissão de um pacote e a probabilidade de a fila de pacotes exceder o tamanho do *buffer*.

Além de um método baseado em Teoria de Filas para estimação da probabilidade de transbordo do *buffer*, é proposto nesse trabalho um método alternativo baseado em Curva de Serviço para estimação de parâmetros de QoS que apresenta menor complexidade computacional. Em outras palavras, este trabalho apresenta uma equação relativamente simples e bastante eficiente, baseada em Processo Envelope, para estimar a probabilidade de transbordo do *buffer* do usuário em sistemas OFDM-TDMA.

Os modelos obtidos podem ser usados não apenas para o projeto de sistemas de comunicação, mas também como base de um sistema de controle de admissão de usuários no sentido de que uma nova chamada pode ser admitida somente se a qualidade de serviço

para as outras chamadas se mantiver em determinado nível.

Análise de Desempenho Baseada em Teoria de Filas

A Teoria de Filas é importante na análise de desempenho de sistemas de transmissão por capturar, em sua essência, a dinâmica do canal de comunicação.

Diferentes trabalhos voltados para a análise de desempenho abordam os sistemas de comunicação sem fio baseados em OFDM em variados aspectos utilizando Teoria de Filas. Chen e Chen (2006) sugerem um modelo para avaliar o desempenho da alocação de subportadoras e derivam expressões para calcular indicadores de probabilidade de bloqueio de chamada e de utilização de banda. Wunder e Zhou (2009) propõem limitantes para o tamanho da fila e para o atraso de pacotes no *downlink* de sistemas OFDM. O modelo desenvolvido é aplicado no dimensionamento de sistemas LTE. Bouchti, Kafhali e Haqiq (2011) apresentam um modelo de análise de desempenho de sistemas OFDMA aplicado à tecnologia WiMAX. No entanto, esses trabalhos modelam a chegada de tráfego dos usuários a partir do modelo de Poisson, devido à simplicidade de análise. Porém, é um fato que o tráfego de rede real, em muitas vezes, não segue o comportamento descrito por esse modelo, limitando a utilidade desses trabalhos em situações do mundo real (PAXSON; FLOYD, 1995) (VIEIRA; LEE, 2009).

Neste trabalho, as soluções desenvolvidas levam em conta modelos mais sofisticados para a descrição de processos de tráfego real. A primeira abordagem de análise de desempenho desenvolvida aplica MMFM para determinação do processo de chegada de pacotes, obtendo, assim, um modelo mais preciso e aplicável a sistemas reais. A segunda proposta para estimação de parâmetros de QoS considera o modelo *Fractional Brownian Motion* (MAYOR; SILVESTER, 1997), modelo que retrata bem a característica de dependência de longa duração nos processos de tráfego real, o que torna a solução simples e bastante robusta.


O trabalho está organizado da seguinte forma. O capítulo 1 introduz a modulação OFDM, detalhando as modulações digitais e os métodos de acesso múltiplo utilizados. O capítulo 2 introduz a Teoria de Filas e Cadeias de Markov, enquanto o capítulo 3 faz uma breve revisão nos métodos existentes de modelagem de tráfego de redes. O capítulo 4 define a proposta inicial deste trabalho (um modelo de análise de desempenho do sistema OFDM-TDMA, baseado em Cadeias de Markov) e apresenta os resultados experimentais ao final. O capítulo 5 expõe uma breve introdução ao Cálculo de Rede Determinístico, apresentando as definições de Processo Envelope e Curva de Serviço e, por último, define uma equação bastante eficiente e computacionalmente simples para estimação da probabilidade de transbordo do *buffer* do usuário, apresentando, ao final, os resultados experimentais e comprovando a eficiência do que é proposto.

1 Sistemas OFDM

O OFDM (*Orthogonal Frequency Division Multiplexing* (PRASAD, 2004)) é uma técnica muito poderosa de multiplexação, sendo adotado como o esquema de transmissão no *downlink* do LTE (*Long-Term Evolution*) (3GPP, 2013) e também em outras tecnologias de comunicação sem fio como WiMAX (IEEE, 2004) e o Sistema Brasileiro de Televisão Digital (CPQD, 2006).

A multiplexação OFDM é baseada na transmissão paralela de dados em várias frequências ortogonais de faixas estreitas sobrepostas no espectro que compõe o canal de comunicação, também chamadas de subportadoras. O espectro de uma subportadora bem como a forma do pulso no domínio do tempo são ilustrados na Figura 1. A largura de banda da subportadora é dada pela frequência de amostragem dividida pelo número de subportadoras no canal ($\Delta f = f_S/N_{FFT}$), enquanto a duração do símbolo que ela carrega é dada pelo inverso desse resultado.


Figura 1: Ilustração de uma subportadora nos domínios do tempo e da frequência



O conjunto de subportadoras que forma o canal OFDM é ilustrado na Figura 2. Observa-se que N_{FFT} (número de subportadoras do canal) símbolos são transmitidos paralelamente. Nota-se também o espaçamento de Δf entre cada subportadora, o que garante a ortogonalidade. O fato de as subportadoras vizinhas serem ortogonais entre si elimina, em teoria, a interferência entre cada uma.

Sendo menor a largura de faixa de cada subportadora, há um maior período de exposição de cada símbolo de dados e, portanto, há maior resistência a interferência de multipercurso. Além disso, com uma menor taxa de símbolos em cada subportadora, é utilizado um intervalo de guarda entre cada símbolo, eliminando a interferência intersim-


Figura 2: Subportadoras ortogonais sobrepostas



Fonte: http://www.blinqnetworks.com/blog/article/the_number_of_sub_carriers_in_ofdm_impacts_nlos_backhaul_performance_more_t

bólica e tornando possível a utilização de ecos e espalhamentos do símbolo no tempo como ganho de diversidade. Esta característica junto com a ortogonalidade e sobreposição das subportadoras ocasiona uma grande eficiência espectral, fazendo com que o OFDM seja a melhor técnica de transmissão, em termos de desempenho, usada em redes sem fio na atualidade. A estrutura do OFDM é ilustrada na Figura 3.

Figura 3: Estrutura da Transmissão OFDM



Fonte: http://www.renesas.com/edge_01/technology/03/index.jsp

A implementação do OFDM é realizada através da aplicação do algoritmo FFT (*Fast Fourier Transform*). O número de subportadoras de um canal OFDM é dado, en-

tão, pelo número de símbolos amostrados pelo FFT. Dentre todas as subportadoras, há subportadoras de guarda (que ficam nos extremos do canal), pilotos (utilizadas para sincronização e estimação de canal), de controle e de dados.

É importante ressaltar que a transmissão é efetuada através de *frames*, que são consideradas as unidades de transmissão de dados e tem duração de vários símbolos OFDM. Um *frame* possui inúmeras informações além dos dados, como o mapeamento das modulações utilizadas e o mapeamento do *downlink* e do *uplink* (caso a comunicação seja *duplex*).

1.1 Modulação Digital

Uma grande vantagem da multiplexação OFDM é que os símbolos transmitidos em cada subportadora podem ser modulados com um tipo diferente de modulação digital e, além disso, há modulação adaptativa de acordo com a qualidade do canal de comunicação com o usuário. Alguns exemplos de modulação digital utilizados são o QPSK, o 16-QAM e o 64-QAM, detalhados a seguir.

1.1.1 Modulação PSK

O PSK (*Phase Shift Keying*) é uma forma de modulação em que a informação do sinal digital é embutida na fase da portadora. Neste esquema de modulação, cada símbolo s_i possui uma fase correspondente. Quando há uma transição de um símbolo s_j para um símbolo s_{j+1} , a fase da onda portadora se altera para a fase correspondente ao símbolo s_{j+1} . Formas particulares do PSK são a modulação BPSK (*Binary Phase Shift Keying*) e a modulação QPSK (*Quadrature Phase Shift Keying*).

Na modulação BPSK, cada símbolo transmitido é formado por um único bit. Quando o símbolo a ser transmitido for o bit 1, a fase da portadora será igual a 0° e, quando o símbolo for o bit 0, a fase da portadora será igual a 180° . Entre as vantagens do uso desta técnica estão a fácil implementação e a robustez, porém, não há eficiência espectral ao transmitir apenas um bit por símbolo.

A Figura 4 ilustra um cenário de transmissão utilizando a modulação BPSK, nela podemos observar a forma de onda resultante do chaveamento de fase.

A Tabela 1 relaciona as expressões da onda portadora do sinal e a ilustração do sinal modulado de acordo com o símbolo transmitido. Observa-se que a amplitude da onda é dada em função da energia do sinal ($A = \sqrt{\frac{2E_s}{T}}$).

Na modulação QPSK, cada símbolo transmitido é formado por dois bits, ou seja, há quatro fases distintas (espaçadas de 90°) correspondentes aos símbolos 00, 01, 10 e

Figura 4: Cenário da transmissão da informação 1101011000 utilizando modulação BPSK




Tabela 1: Modulação BPSK

Símbolo	Bit	Expressão	Sinal Modulado
s_1	0	$\sqrt{\frac{2E_s}{T}} \cos(\omega t + 0)$	
s_2	1	$\sqrt{\frac{2E_s}{T}} \cos(\omega t + \pi)$	

11. Esta técnica de modulação, apesar de ser um pouco mais complexa para implementar, tem maior eficiência espectral e mantém a robustez em suas aplicações.

Os símbolos, na modulação QPSK, podem ser representados por sinais ortogonais, que, por sua vez, podem ser representados no diagrama vetorial (também chamado de Diagrama de Constelação) da Figura 5. Os vetores que terminam nos vértices do quadrado pontilhado denotam os símbolos que podem ser transmitidos com essa modulação. O sinal modulado é definido como uma combinação de duas ondas, uma onda I (*In Phase*) em fase com a portadora ($\cos(\omega t)$) e outra onda Q (*Quadrature*) em quadratura ($\sin(\omega t)$), de acordo com a Tabela 2. Essa combinação permite obter quatro fases distintas e, portanto, representar quatro símbolos distintos.

1.1.2 Modulação QAM

O QAM (*Quadrature Amplitude Modulation*) é uma técnica de modulação na qual os símbolos, assim como no QPSK, são representados por vetores definidos como uma combinação de duas ondas, uma onda I (*In Phase*) em fase com a portadora ($\cos(\omega t)$) e outra onda Q (*Quadrature*) em quadratura ($\sin(\omega t)$). No entanto, há uma alteração na amplitude de cada uma dessas ondas dependendo do símbolo transmitido. Dessa forma, o conjunto símbolos possíveis de serem transmitidos pode ser maior.

Figura 5: Diagrama de Constelação da modulação QPSK




Tabela 2: Modulação QPSK

Símbolo	Bits	Expressão
s_1	00	$A[\cos(\omega t + \frac{\pi}{4})] = A[\cos(\omega t) \cos(\frac{\pi}{4}) - \sin(\omega t) \sin(\frac{\pi}{4})]$ $A[\cos(\omega t + \frac{\pi}{4})] = A \frac{\sqrt{2}}{2} [\cos(\omega t) - \sin(\omega t)]$
s_2	01	$A[\cos(\omega t + \frac{3\pi}{4})] = A[\cos(\omega t) \cos(\frac{3\pi}{4}) - \sin(\omega t) \sin(\frac{3\pi}{4})]$ $A[\cos(\omega t + \frac{3\pi}{4})] = A \frac{\sqrt{2}}{2} [-\cos(\omega t) - \sin(\omega t)]$
s_2	11	$A[\cos(\omega t + \frac{5\pi}{4})] = A[\cos(\omega t) \cos(\frac{5\pi}{4}) - \sin(\omega t) \sin(\frac{5\pi}{4})]$ $A[\cos(\omega t + \frac{5\pi}{4})] = -A \frac{\sqrt{2}}{2} [\cos(\omega t) - \sin(\omega t)]$
s_2	10	$A[\cos(\omega t + \frac{7\pi}{4})] = A[\cos(\omega t) \cos(\frac{7\pi}{4}) - \sin(\omega t) \sin(\frac{7\pi}{4})]$ $A[\cos(\omega t + \frac{7\pi}{4})] = -A \frac{\sqrt{2}}{2} [-\cos(\omega t) - \sin(\omega t)]$

A quantidade de informação transmitida com QAM pode ser parametrizada. O M-QAM pode transmitir M diferentes símbolos, ou L bits, onde $(L = \sqrt{M})$. Observa-se que a modulação 4-QAM, onde 4 diferentes símbolos podem ser transmitidos num instante (ou dois bits), é equivalente à modulação QPSK

Considerando que o k -ésimo símbolo é representado pelo vetor $(a_i \frac{d}{2}, b_j \frac{d}{2})$, sendo d a menor distância euclidiana entre os símbolos no Diagrama de Constelação e $\frac{d}{2} = \sqrt{E_s}$, o sinal correspondente é dado por:

$$s_k(t) = \sqrt{\frac{2E_s}{T}} [a_i \cos(\omega t) - b_j \sin(\omega t)] \quad (1.1)$$

onde $0 \leq t \leq T$, $k = 1, 2, \dots, M$ e para cada valor de k há uma combinação diferente dos


valores de i e j .

Pode-se determinar os valores de a_i e b_j como na equação 1.2. Dessa forma, para $M = 16$, os valores das amplitudes a_i e b_j seriam como na equação 1.3 e o Diagrama de Constelação do 16-QAM poderia ser dado como ilustrado na Figura 6.

$$\{a_i, b_j\} = \begin{bmatrix} (-L+1, L-1) & (-L+3, L-1) & \cdots & (L-1, L-1) \\ (-L+1, L-3) & (-L+3, L-3) & \cdots & (L-1, L-3) \\ \vdots & \vdots & \ddots & \vdots \\ (-L+1, -L+1) & (-L+3, -L+1) & \cdots & (L-1, -L+1) \end{bmatrix} \quad (1.2)$$

$$\{a_i, b_j\} = \begin{bmatrix} (-3, 3) & (-1, 3) & (1, 3) & (3, 3) \\ (-3, 1) & (-1, 1) & (1, 1) & (3, 1) \\ (-3, -1) & (-1, -1) & (1, -1) & (3, -1) \\ (-3, -3) & (-1, -3) & (1, -3) & (3, -3) \end{bmatrix} \quad (1.3)$$

Figura 6: Diagrama de Constelação da modulação 16-QAM



Como o QAM pode transmitir um número superior de símbolos, a quantidade de informação transmitida num único símbolo é maior e, portanto, o QAM tem maior eficiência espectral na transmissão. Em sistemas LTE e WiMAX, por exemplo, são utilizadas as modulações QPSK, 16-QAM e 64-QAM dependendo da qualidade do canal. O 64-QAM é a modulação de maior eficiência espectral, ou seja, alcança maior taxa de transmissão na mesma largura de banda, e é utilizado nas situações em que a qualidade do canal é superior. Já o QPSK é a modulação de menor eficiência, porém, de maior robustez, sendo

utilizado quando a qualidade do canal está muito baixa. A maior robustez das modulações QPSK e 16-QAM deve-se ao fato de haver uma maior distância separando cada símbolo no Diagrama de Constelação, facilitando a interpretação dos símbolos em face ao ruído derivado do canal de comunicação.


1.2 Técnicas de Acesso Múltiplo

Com base na técnica de multiplexação OFDM, foram desenvolvidos alguns métodos de acesso a um canal de comunicação sem fio por múltiplos usuários. Basicamente, existem três métodos: OFDMA, OFDM-TDMA e OFDM-CDMA (TAROKH, 2009). O primeiro e o segundo baseiam-se na divisão do canal entre os usuários no tempo e em frequência, respectivamente, enquanto o último baseia-se na separação de usuários por codificação. Este trabalho tem foco nos métodos OFDMA e OFDM-TDMA.

1.2.1 OFDMA

O OFDMA (*Orthogonal Frequency Division Multiple Access*) promove o acesso múltiplo através da atribuição de um conjunto de subcanais para cada conexão no sistema, sendo cada subcanal formado por um subconjunto de subportadoras do canal OFDM, como ilustrado na Figura 7. O OFDMA pode suportar diferentes requisitos de QoS por usuário, atribuindo diferentes números de subcanais para cada um.

Figura 7: Divisão das Subportadoras em Subcanais na transmissão OFDMA




Fonte: <http://www.conniq.com/WiMAX/fdm-ofdm-ofdma-sofdma-03.htm>

A comunicação em via dupla (*duplex*) pode ser realizada através de TDD (*Time Division Duplex*), onde há alguns intervalos de tempo no canal que são dedicados ao *downlink* e outros ao *uplink*, ou FDD (*Frequency Division Duplex*), onde, para cada usuário, há subcanais dedicados ao *downlink* e subcanais dedicados ao *uplink*.

1.2.2 OFDM-TDMA

O TDMA (*Time Division Multiple Access*) promove o acesso múltiplo atribuindo o canal OFDM para cada usuário por um determinado período chamado *time slot*, que pode conter um ou mais *frames*, como mostrado na Figura 8.

Figura 8: Divisão do Acesso ao Canal OFDM pelo Tempo



Fonte: (NIYATO; HOSSAIN, 2005)


A alternância entre usuários pode ocorrer de diferentes formas. Neste trabalho, a alternância foi baseada no esquema de escalonamento *round-robin*, que é relativamente eficiente considerando a implementação bastante simples. A comunicação em via dupla pode ser realizada através de TDD.

2 Teoria de Filas

A Teoria de Filas é uma ferramenta matemática utilizada para analisar os processos de chegada, armazenamento e atendimento de uma fila. Através da Teoria de Filas, vários indicadores de desempenho, como a probabilidade de uma fila estar no seu limite ou estar vazia, o número médio de itens na fila, tempo médio de espera, taxa de vazão e de rejeição, podem ser obtidos analiticamente.

Os componentes gerais de um sistema de fila são mostrados na Figura 9. Neste modelo, os processos de chegada e atendimento podem ser aleatórios e descritos através de distribuições de probabilidade. Dessa forma, o número de itens na fila também é aleatório, uma vez que depende dos processos de chegada e atendimento. Portanto, um sistema de fila pode ser estudado no contexto de processos estocásticos.

Figura 9: Componentes Gerais de um Sistema de Fila



2.1 Processos Estocásticos

Um processo estocástico é definido como um conjunto de variáveis aleatórias $X(t)$ definidas num espaço de probabilidade comum. Em geral, t é considerado como tempo, onde $t \in T$, e T é um conjunto de pontos no tempo. Um processo estocástico pode ser classificado de acordo com o conjunto T , que pode ser contínuo ou discreto. $X(t)$ e X_t denotam os valores de uma variável aleatória com domínio contínuo e discreto, respectivamente.

Em Teoria de Filas, o estado do sistema é definido pelo número de itens na fila, que é uma variável aleatória X_t . Considere o número de itens que chegaram numa fila no período $[0, t]$. É claro que, para $t_i > t_j > 0$, há uma relação entre X_{t_i} e X_{t_j} . Em particular, X_{t_i} é igual a X_{t_j} somado ao número de itens que chegaram no intervalo $[t_j, t_i]$ subtraído do número de itens que foram atendidos no mesmo intervalo.

Um processo estocástico pode ser classificado de acordo com a relação entre suas variáveis aleatórias como segue:

2.1.1 Processo Estacionário

Um processo estocástico é considerado estacionário se o conjunto de todas as funções de distribuição de probabilidade das variáveis aleatórias for invariante no tempo.

Para um processo estacionário de ordem n , a seguinte relação seria válida:

$$P[X(t_1) = x_1, \dots, X(t_1) = x_n] = P[X(t_1 + \tau) = x_1, \dots, X(t_n + \tau) = x_n] \quad (2.1)$$

onde τ corresponde a uma quantidade de deslocamento no tempo.

2.1.2 Processo Markoviano

Um processo markoviano é um processo estocástico com um espaço de estados discreto. Ele tem a característica de não possuir memória, ou seja, o estado futuro depende apenas do estado atual do sistema. A transição do estado atual para um próximo é determinada por uma probabilidade de transição, função apenas do estado atual, como mostrado abaixo. Matematicamente, um processo markoviano é representado por (PAPOULIS; PILLAI, 2002):

$$\begin{aligned} P[X(t_{n+1}) = x_{n+1} | X(t_n) = x_n, X(t_{n-1}) = x_{n-1}, \dots, X(t_1) = x_1] \\ = P[X(t_{n+1}) = x_{n+1} | X(t_n) = x_n] \end{aligned} \quad (2.2)$$

Se o domínio do tempo do processo markoviano é discreto, este processo é também chamado de Cadeia de Markov. O processo markoviano é muito importante na análise de filas, uma vez que pode modelar o estado da fila.

2.1.3 Processo de Quase Nascimento e Morte

O processo de quase nascimento e morte é uma generalização do processo de nascimento e morte, que é um caso particular do processo markoviano no qual as transições só ocorrem entre estados vizinhos. O processo de quase nascimento e morte pode ser representado como:

$$P[X(t_{n+1}) = x_n + i | X(t_n) = x_n] = \begin{cases} p, & i \in \{-m, -m+1, \dots, 0, \dots, m-1, m\} \\ 0, & \text{caso contrário} \end{cases} \quad (2.3)$$

onde $p \in \mathbb{R}_+$ e $p \geq 0$, $m \in \mathbb{Z}_+$ e $x_n + i$ deve ser um estado contido no domínio de estados do processo, ou seja, $x_n + i \in S$.

A representação de um processo de nascimento e morte é um caso particular desta, com $m = 1$.

O processo de quase nascimento e morte tem um importante papel na análise de filas, uma vez que nos sistemas de filas as variações no número de itens da fila são limitadas, ou seja, há transições apenas para uma região vizinha do estado atual.

2.2 Cadeia de Markov em Tempo Discreto

Seja $P[X_n = j | X_{n-1} = i]$ a probabilidade de transição do estado i no tempo $n - 1$ ao estado j no tempo n . Esta probabilidade de transição é homogênea no tempo se:

$$p_{i,j} = P[X_n = j | X_{n-1} = i] = P[X_{n+\tau} = j | X_{n+\tau-1} = i] \quad (2.4)$$

onde, $n = 1, 2, \dots$, $\tau \geq 0$ e $i, j \in S$.

Com base nesta probabilidade de transição, uma matriz de probabilidade de transição da Cadeia de Markov pode ser definida como:

$$\mathbf{P} = \begin{bmatrix} p_{0,0} & p_{0,1} & \cdots & p_{0,j} & \cdots \\ p_{1,0} & p_{1,1} & \cdots & p_{1,j} & \cdots \\ \vdots & \vdots & \ddots & \vdots & \cdots \\ p_{i,0} & p_{i,1} & \cdots & p_{i,j} & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{bmatrix} \quad (2.5)$$

A soma total das probabilidades de transição de um estado i para outro qualquer deve ser um, ou seja, $\sum_{j \in S} p_{i,j} = 1$.

Uma das propriedades da Cadeia de Markov é a irredutibilidade. Uma Cadeia de Markov é irredutível se ela pode transitar de qualquer estado para todos os outros. Caso contrário, a Cadeia de Markov é redutível.

Ao estabelecer uma Cadeia de Markov e sua matriz de probabilidade de transição é possível obter a probabilidade de o sistema se encontrar em determinado estado. A partir disso, vários indicadores de desempenho relacionados com o sistema de filas podem ser levantados. Há dois tipos de probabilidades de o sistema se encontrar em determinado estado, a probabilidade quando o sistema se encontra num estado transiente e a probabilidade quando o sistema se encontra num estado estacionário. Os estados transiente e estacionário se referem ao estado do sistema e não a um estado específico dentro do espaço de estados da Cadeia de Markov.

2.2.1 Comportamento do Sistema em Estado Transiente

Um sistema de filas passa para um estado transiente temporariamente quando há uma alteração nos seus parâmetros. No estado transiente, a saída do sistema varia com o tempo. Porém, com o passar do tempo, caso o sistema seja estável, o sistema culminará no estado estacionário, onde não há flutuações na saída do sistema.

Um dos métodos para se obter a probabilidade em estado estacionário de o sistema se encontrar em determinado estado é utilizando a equação de Chapman-Kolmogorov. Seja $\boldsymbol{\pi}(n) = [\pi_0(n) \ \pi_1(n) \ \cdots \ \pi_i(n) \ \cdots]$ o vetor que contem a probabilidade do sistema se encontrar em cada estado i dentre o espaço de estados da Cadeia de Markov no tempo n . Como o próximo estado do sistema depende apenas do estado presente, podemos escrever cada uma dessas probabilidades como:

$$\pi_i(n) = \sum_{j \in S} \pi_j(n-1) p_{j,i} \quad (2.6)$$

Portanto, o vetor $\boldsymbol{\pi}(n)$ pode ser encontrado da seguinte forma:

$$\boldsymbol{\pi}(n) = \boldsymbol{\pi}(n-1) \mathbf{P} = \boldsymbol{\pi}(0) \mathbf{P}^n \quad (2.7)$$

Conhecendo a probabilidade do sistema se encontrar em cada estado no tempo n , o comportamento transiente do sistema pode ser estimado. Caso haja uma mudança nos parâmetros do sistema no tempo n , nos passos $n+1, n+2, \dots$ o sistema se encontrará em estado transiente e os indicadores de desempenho do sistema podem ser obtidos a partir das probabilidades encontradas. No entanto, no tempo $n+\tau$, onde $\tau \rightarrow \infty$, o sistema, caso seja estável, alcançará o estado estacionário novamente.

2.2.2 Comportamento do Sistema em Estado Estacionário

Um estado i é dito periódico se, partindo dele, o sistema retorna a este estado em d passos, onde d é chamado período do estado periódico i e deve ser maior que 1. Um estado j é dito recorrente se, partindo dele, o sistema retorna, eventualmente, a este estado. Se o tempo esperado para este retorno é infinito, o estado j é chamado recorrente positivo, mas se o tempo esperado for infinito, é chamado de recorrente nulo (PAPOULIS; PILLAI, 2002).

Se os estados da Cadeia de Markov são recorrentes e aperiódicos, então, a probabilidade do sistema estar no estado j é determinada por π_j .

$$\lim_{n \rightarrow \infty} \pi_j(n) = \pi_j \quad (2.8)$$

Esta é a probabilidade de estado estacionário do sistema se encontrar no estado j . As probabilidades do sistema se encontrar em cada estado em estado estacionário são dadas pelo vetor $\boldsymbol{\pi} = [\pi_0 \ \pi_1 \ \cdots \ \pi_i \ \cdots]$. Assim, para um sistema em estado estacionário, conhecendo a lei da probabilidade, estas probabilidades têm as seguintes propriedades:

$$\boldsymbol{\pi} = \boldsymbol{\pi} \mathbf{P} \quad (2.9)$$

$$\sum_{i \in S} \pi_i = 1 \quad (2.10)$$

Dessa forma, conhecendo a matriz de transição $\mathbf{P}$, é possível encontrar os valores de $\boldsymbol{\pi}$, uma vez que as equações fornecem $N + 1$ equações lineares com N variáveis, onde N é o número de estados contidos no espaço de estados da Cadeia de Markov que modela o sistema.

3 Modelagem de Fluxos de Tráfego de Redes de Computadores

A modelagem de tráfego é uma técnica para caracterizar fluxos de tráfegos de rede. O modelo de tráfego ideal deve apresentar características semelhantes às do tráfego de rede modelado. Estes modelos têm por objetivo facilitar o entendimento das características do tráfego modelado, parametrização das variáveis obtidas e possibilidade de simulações do comportamento do tráfego.

O modelo obtido ajuda no desenvolvimento de equipamentos, serviços e protocolos de rede, além de ter grande importância nas análises de desempenho e simulações de redes.

Na década de 20 o modelo clássico de tráfego de Poisson foi proposto para análise de sistemas de telefonia e posteriormente ajustado para a análise de fila em redes de dados (KLEINROCK, 1975). Este modelo tem como vantagem o fato de ser analiticamente tratável, permitindo que expressões matemáticas sejam diretamente derivadas para caracterização do desempenho de fila nos *buffers*. Mas com a chegada das redes com suporte a vários serviços, a natureza do tráfego mudou drasticamente, exibindo características bem diferentes das sugeridas por este modelo, um exemplo disso, é o comportamento fractal (VIEIRA; LEE, 2006).

Leland et al. (1994) constataram experimentalmente, que o tráfego coletado na rede *Ethernet* do *Bellcore Morristown Research and Engineering Center* exibia características fractais tais como autossimilaridade. A dependência de longa duração ou longa-dependência para uma série de tráfego é uma característica que implica em uma estrutura de correlação que decai mais lentamente do que uma exponencial (LELAND et al., 1994). Este decaimento da função de autocorrelação, relacionado também à autossimilaridade, foi observado no tráfego de redes de longa distância (WAN - *Wide Area Network*), metropolitanas (MAN - *Metropolitan Area Network*) (PAXSON; FLOYD, 1995) e no tráfego de Internet (CROVELLA; BESTAVROS, 1996), dentre outros. Foi constatado que estas propriedades, principalmente a dependência de longa duração, influenciam fortemente no projeto de redes e seu desempenho (PARK; WILLINGER, 2000), por isso não são coerentemente modeladas por processos poissonianos.

Muitos estudos revelam a alta taxa de variação do tráfego de Internet, com rajadas em uma gama de escalas de tempo em contraste da suposição de que rajadas de tráfego só existem em escalas curtas de tempo (PAXSON; FLOYD, 1995). Mostrou-se que es-

tas incidências de rajadas multiescalas têm um impacto significativo no desempenho das redes (ERRAMILLI; NARAYAN; WILLINGER, 1996). Os resultados apresentados por Erramilli, Narayan e Willinger (1996) mostram que a aplicação do conhecimento das características do tráfego em múltiplas escalas consegue melhorar a eficiência dos mecanismos de controle de tráfego (VIEIRA; LEE, 2006).

Propôs-se em diversas literaturas, modelos de tráfego com o objetivo de representar a característica autossimilar encontradas no tráfego de redes. Um modelo que pode apresentar de maneira simples e que abrange matematicamente as características autossimilares observadas no tráfego é o modelo de tráfego Browniano fracionário (*fractional Brownian traffic*, fBt). Contudo, verificou-se que em escalas de tempo da ordem acima de poucos segundos ou maiores, o comportamento do tráfego seria melhor representado por modelos autossimilares, mas em escalas de tempo menores, inferiores à ordem de poucos segundos, as características de tais modelos afastavam-se das apresentadas pelo tráfego real analisado (VIEIRA; LEE, 2006) (BIANCHI, 2005).

Outras propriedades mais complexas do tráfego de redes que os modelos monofractais foram descobertas, como as características multifractais. Os resultados indicam que o desempenho das filas depende mais da taxa de variação do tráfego em certas escalas de tempo do que do valor do parâmetro de Hurst H , que mede o grau de autossimilaridade de um processo (ERRAMILLI; NARAYAN; WILLINGER, 1996). A origem dessas propriedades consideradas presentes em pequenas escalas de tempo é atribuída à ação dos protocolos predominantes nas redes em questão, e dos mecanismos de controle de congestionamento ponto a ponto existentes na Internet, que determinam o comportamento do fluxo de informações entre diferentes camadas na hierarquia de protocolos TCP/IP (FELDMANN; GILBERT; WILLINGER, 1998).

Investigações envolvendo tráfego WAN TCP/IP constataram que essas diferentes propriedades e comportamentos do tráfego eram convenientemente descritos utilizando-se a análise multifractal (RIEDI; VÉHEL, 1997). Para muitos processos de tráfego de rede, seus gráficos de energia em escala dos coeficientes *wavelet* ou os de variância-tempo normalmente não têm comportamento linear. Muitos destes processos apresentam uma combinação de comportamentos fractais, com o parâmetro de Hurst variando em pequenas e diferentes escalas de tempo, ou seja, características multifractais. De fato, o desempenho de fila depende intensamente das irregularidades do tráfego em escalas de tempo pequenas devido à dinâmica complexa das redes de dados. Pesquisadores discutem que esta combinação de comportamentos em escala é melhor representada por processos multifractais (FELDMANN; GILBERT; WILLINGER, 1998).

Conhecendo as características principais do tráfego, pode-se selecionar o modelo de rede que melhor representará a série de tráfego de rede, sendo possível incorporar às simulações métodos analíticos e características semelhantes às reais.

3.1 Modelo de Poisson


O processo de Poisson é empregado na modelagem de processos físicos e desempenha um papel central na teoria de filas clássica. A razão para seu uso está no fato de que o modelo de Poisson possui uma série de propriedades que dão origem a resultados de estimativa de filas confiáveis. Em segundo lugar, também é considerado um bom modelo para um processo que envolve a chegada de um grande número de usuários similares e independentes (HOCK; HEE, 2008).

Mais precisamente, um processo de Poisson é um processo de contagem do número de eventos que ocorrem de forma aleatória dos pontos observados em um determinado intervalo de tempo $(0, t)$. Também se pode considerar como sendo um caso de limite de colocação em pontos aleatórios k para o intervalo de tempo de $(0, t)$. Se a variável aleatória $X(t)$ contendo o número de eventos de ponto nesse intervalo de tempo é distribuído de acordo com a distribuição de Poisson, então esse processo é um processo de Poisson (HOCK; HEE, 2008). A probabilidade de $X(t)$ ser igual a k segundo o modelo de Poisson é dada por:

$$P\{X(t) = k\} = \frac{e^{-\lambda t} (\lambda t)^k}{k!} \quad (3.1)$$

onde k é o número inteiro não negativo que representa o número de ocorrências, λ é a taxa de ocorrência destes eventos pontuais e λt é a média de uma variável aleatória de Poisson, que fisicamente representa o número médio de ocorrências do evento em um intervalo de tempo t .

Figura 10: Densidade de probabilidade para diferentes valores de λ



A Figura 10 apresenta a Função Densidade de Probabilidade (PDF - *Probability Density Function*) de um grupo de amostras da distribuição de Poisson para diferentes taxas de ocorrência (λ).

3.2 Método de Kernel

Os métodos de estimação paramétricos, como o de Poisson, muitas vezes são fracos, inadequados ou restritivos para modelar determinados processos. Por sua vez, os métodos não-paramétricos, como o método de Kernel, estimam o comportamento da população diretamente através dos dados amostrais. Esta abordagem gera melhores estimações para lidar com um número maior de situações.

O método de estimação *Kernel* é uma maneira não-paramétrica de estimar a função de densidade de probabilidade de uma variável aleatória. Pode ser interpretado como uma generalização do histograma.

O histograma é o método não-paramétrico mais antigo de estimação de densidade. É um estimador não contínuo. Consiste em definir retângulos como intervalos de largura h e contar o número de observações em cada um (Aqui o retângulo é o *Kernel* do estimador). Assim, a probabilidade de um evento X pertencer a um intervalo $\left[-\frac{h}{2}, \frac{h}{2}\right]$ é aproximadamente:

$$P\left(X \in \left[-\frac{h}{2}, \frac{h}{2}\right]\right) = \frac{1}{n} \# \left\{X_i \in \left[-\frac{h}{2}, \frac{h}{2}\right]\right\} \quad (3.2)$$

E uma estimativa para f seria:

$$f(x) = \frac{1}{nh} \# \left\{X_i \in \left[-\frac{h}{2}, \frac{h}{2}\right]\right\}, \quad \forall x \in \left[-\frac{h}{2}, \frac{h}{2}\right] \quad (3.3)$$

A idéia do histograma serve como base para o estimador *naive* (SILVERMAN, 1986), descrito a seguir. Considerando uma variável aleatória X , com densidade f , então:

$$f(x) = \lim_{h \rightarrow 0} \frac{1}{2h} P(x-h < X < x+h) \quad (3.4)$$

Fixando h , estima-se $P(x-h < X < x+h)$ pela proporção de observações da amostra pertencentes ao intervalo $(x-h, x+h)$. Assim, escolhendo h pequeno o suficiente, o seguinte estimador de f é encontrado:

$$f(x) = \frac{1}{2nh} \# \{X_i \in (x-h, x+h)\} \quad (3.5)$$

O que pode ser escrito da seguinte forma:

$$f(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h} w\left(\frac{x - X_i}{h}\right) \quad (3.6)$$

$$w(x) = \begin{cases} \frac{1}{2} & \text{se } |x| < 1 \\ 0 & \text{caso contrário} \end{cases} \quad (3.7)$$

O estimador de densidades baseado numa função *Kernel* é obtido substituindo a função w por uma função não negativa K , denominada *Kernel*, que satisfaz as seguintes condições:

$$K(x) \geq 0 \quad (3.8)$$

$$\int_{-\infty}^{+\infty} K(x) dx = 1 \quad (3.9)$$

Neste trabalho, assume-se K como a função normal de densidade de probabilidade com variância $\sigma = 1$ e média $\mu = 0$:

$$K(x) = \frac{1}{\sqrt{2\pi}} e^{\left(-\frac{x^2}{2}\right)} \quad (3.10)$$

Assim, o seguinte estimador *Kernel*, e, portanto, a equação da estimativa da PDF, é determinado:

$$f(x; h) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right) = \frac{1}{n} \sum_{i=1}^n K_h(x - X_i) \quad (3.11)$$

$$K_h(x) = \frac{1}{h} K\left(\frac{x}{h}\right) \quad (3.12)$$

onde h é denominado parâmetro de suavização e é positivo.

O parâmetro h foi calculado a partir do método de seleção de parâmetro de suavização proposto por Botev, Grotowski e Kroese (2010).

3.3 Markov Modulated Fluid Model

O MMFM (*Markov Modulated Fluid Model*) é tipicamente utilizado para modelagem de tráfego (BOSMAN; MEI; NUNEZ-QUEIJA, 2012). Nesse modelo, o estado corrente de uma Cadeia de Markov de nascimento-e-morte determina a taxa de fluxo de pacotes. No estado s , o tráfego chega a uma taxa λ_s . O espaço de estados da Cadeia de

Markov corresponde a um conjunto de níveis quantizados de taxas de chegada de tráfego. A Cadeia de Markov apresenta $S + 1$ estados, de zero a S , e a transição entre eles ocorre com taxas exponenciais de transição, que dependem do estado atual. O número de estados e as taxas de transição são determinadas a partir da média, da variância e da função de autocovariância da série de tráfego (ROCHA; SANTOS; VIEIRA, 2011).

No MMFM, a taxa exponencial $\rho_{i,j}$ de transição do estado i para o estado j é dado pela equação 3.13, onde α representa a taxa de nascimento e β a taxa de morte do processo de nascimento-e-morte.

$$\rho_{i,j} = \begin{cases} (S - i)\alpha, & i = j - 1 \\ i\beta, & i = j + 1 \\ 0, & c.c. \end{cases} \quad (3.13)$$

A probabilidade em estado estacionário de que cheguem λ_s pacotes em determinado intervalo de tempo, então, é determinada pelo MMFM na equação 3.14, onde U é o passo de quantização dos níveis de taxa de fluxo de pacotes (ROCHA; SANTOS; VIEIRA, 2011).

$$P\{\lambda = sU\} = f(\lambda_s) = \binom{S}{s} p^s (1 - p)^{S-s}, \quad p = \frac{\alpha}{\alpha + \beta} \quad (3.14)$$

Uma distribuição binomial com parâmetros média $E(\bar{\lambda})$, variância $\bar{Z}(0)$ e autocovariância $\bar{Z}(\tau)$ descreve o estado estacionário de λ . Esses parâmetros são dados, respectivamente, por:

$$E(\bar{\lambda}) = SUP \quad (3.15)$$

$$\bar{Z}(0) = SU^2 p(1 - p) \quad (3.16)$$

$$\bar{Z}(\tau) = \bar{Z}(0)e^{-(\alpha - \beta)\tau} \quad (3.17)$$

onde τ corresponde à variação do tempo.

A partir das equações 3.14 a 3.17, pode ser definido um algoritmo para ajuste dos parâmetros S , U , α e β de acordo com a série de tráfego considerada. Um algoritmo para tal fim foi apresentado em (ROCHA; SANTOS; VIEIRA, 2011). Os parâmetros obtidos definem um modelo MMFM do perfil de tráfego considerado e, a partir deste modelo, é possível gerar novas amostras.

Algoritmo: Ajuste dos parâmetros do modelo MMFM

1. Calcular a média e a variância da série temporal de tráfego real.
2. Calcular a função de autocovariância do tráfego utilizando a equação 3.18, onde $\lambda(t)$ é o processo de tráfego no tempo t e μ é a média da série do processo de tráfego.

$$Z(\tau) = E[(\lambda(t) - \mu)(\lambda(t + \tau) - \mu)] \quad (3.18)$$

3. Encontrar o parâmetro a do modelo utilizando um procedimento de Ajuste de Curva. A função de autocovariância do tráfego, dada pela equação 3.18, é aproximada pela equação 3.17, onde $a = \alpha + \beta$, o que resulta na equação 3.19. Ou seja, neste passo calcula-se o parâmetro de uma função exponencial que mais se aproxime da função de autocovariância da série de tráfego sob um intervalo de confiança de 95%.

$$Z(\tau) = Z(0)e^{-a\tau} \quad (3.19)$$

4. O valor encontrado para a é utilizado para calcular os parâmetros α e β , a partir das equações 3.20 e 3.21. Neste passo, é escolhido um valor para S . Observa-se que a Cadeia de Markov possui $S + 1$ estados possíveis.

$$\beta = \frac{aSZ(0)}{SZ(0) + E^2(\lambda)} \quad (3.20)$$

$$\alpha = a - \beta \quad (3.21)$$

5. Uma vez obtidos os parâmetros α e β , as taxas exponenciais da equação 3.13 são calculadas.
6. Calcular U a partir da seguinte equação:

$$U = \frac{Z(0)}{E(\lambda)} + \frac{E(\lambda)}{S} \quad (3.22)$$

7. Os valores dos parâmetros obtidos são utilizados para gerar amostras do modelo MMFM através de uma Cadeia de Markov de nascimento-e-morte.

3.4 Modelo Movimento Browniano Fractal (fBm)

No verão de 1827, Robert Brown, botânico e médico escocês, observou ao microscópio minúsculos grãos de pólen de plantas suspensas em um fluido e notou incrementos altamente irregulares. Verificou-se que partículas mais finas moviam-se mais rapidamente, e que o movimento era estimulado pelo calor e pela diminuição da viscosidade do líquido. Suas investigações foram publicadas em “*A Brief Account of Microscopical Observations*

Made in the Months of June, July and August 1827” (Um breve relato de observações microscópicas feitas nos meses de junho, julho e agosto de 1827). Ainda naquele século, foi postulado que o movimento irregular era causado por um grande número de colisões entre os grãos de pólen e as moléculas do líquido (que são microscopicamente pequenos em relação ao pólen). Os impactos ocorrem com muita frequência mesmo em pequenos intervalos de tempo, independentemente umas das outras, e o efeito de um acerto particular é considerado pequeno se comparado ao efeito total (WIERSEMA, 2008).

Por volta de 1900, Louis Bachelier, um estudante de doutorado em matemática na Sorbonne (Universidade de Paris), foi estudar o comportamento dos preços das ações na bolsa de Paris e observou incrementos altamente irregulares. Ele desenvolveu a primeira especificação matemática do incremento relatado por Brown que foi usado como um modelo para o incremento dos preços das ações. Na década de 1920, Norbert Wiener, um físico matemático do MIT (*Massachusetts Institute of Technology*), desenvolveu a estrutura matemática totalmente probabilística para este modelo. Este tipo de incremento passou a ser chamado de movimento browniano ou processo de Wiener. A proposição do processo é comumente denotada por B ou movimento Browniano W (WIERSEMA, 2008).

O nome movimento Browniano fractal veio de Mandelbrot e Van Ness, eles o definiram como uma integral estocástica relacionada ao movimento Browniano padrão (MANDELBROT; NESS, 1968) (SOTTINEN; VALKEILA, 2001):

$$Z_t = \int_{-\infty}^t k(t, s) dW_s \quad (3.23)$$

para um dado kernel determinístico k dependente de H (parâmetro de Hurst), onde W representa um processo de Wiener (movimento Browniano padrão) definido em $(-\infty, \infty)$, e t e s são dois instantes de tempo (intervalos de tempo).

Além da representação pela integral de Mandelbrot e Van Ness do movimento Browniano fractal, utiliza-se também representação semelhante onde a integração assume um intervalo finito $[0, t]$ (SOTTINEN; VALKEILA, 2001) (WIERSEMA, 2008):

$$Z_t = \int_0^t z(t, s) dW_s \quad (3.24)$$

onde:

$$z(t, s) = c_1 \left[\left(\frac{t}{s} \right)^{H-\frac{1}{2}} (t-s)^{H-\frac{1}{2}} - \left(H - \frac{1}{2} \right) s^{\frac{1}{2}-H} \int_s^t \left(u^{H-\frac{3}{2}} (u-s)^{H-\frac{1}{2}} \right) du \right] \quad (3.25)$$

Um movimento Browniano fractal (fBm), é um processo Gaussiano de tempo contínuo $B_H(t)$ em $[0, T]$, que começa em zero, tem média zero em $[0, T]$, apresentando a

seguinte função de covariância (RAO, 2010):

$$E[B_H(t)B_H(s)] = \frac{1}{2} (|t|^{2H} + |s|^{2H} - |t-s|^{2H}) \quad (3.26)$$

onde H é o parâmetro de Hurst (um número real entre 0 e 1), e seu valor determina algumas características importantes para o processo fBm.

Para $H = \frac{1}{2}$, os incrementos são independentes, para $H > \frac{1}{2}$ os incrementos são positivamente correlacionados (o processo é dito como sendo autossimilar) e para $H < \frac{1}{2}$ os incrementos são negativamente correlacionados (não existe autocorrelação) (MISHURA, 2008) (CLEGG, 2005).

A integral estocástica para $t \geq 0$ definida por Mandelbrot e Van Ness também pode ser definida pela equação (PELTIER; VEHEL, 1995):

$$B_H(t) = \frac{1}{\Gamma(H + \frac{1}{2})} \left\{ \int_{-\infty}^0 \left[(t-s)^{H-\frac{1}{2}} - (-s)^{H-\frac{1}{2}} \right] dW(s) + \int_0^t (t-s)^{H-\frac{1}{2}} dW(s) \right\} \quad (3.27)$$

onde W representa um processo de Wiener definido em $(-\infty, \infty)$.


Os fractais são estruturas complexas caracterizadas por três aspectos sempre presentes. O primeiro é quanto à classificação dos fractais, por meio do conceito de dimensão fractal, que representa uma ruptura com a geometria e as topologias tradicionais, pois permite que um objeto tenha como dimensão um valor não inteiro. A segunda característica dos fractais é a autossimilaridade, onde um fractal é invariante por mudança de escalas, ou seja, se uma parte do fractal for ampliada, tem-se uma figura similar a figura que se tinha antes, a Figura 11 mostra um exemplo de fractal. A terceira característica diz respeito à maneira como os fractais são construídos, na construção de um fractal, um determinado procedimento se repete infinitamente (WILLINGER et al., 1995).

3.4.1 Parâmetro de Hurst

O parâmetro de Hurst é utilizado em várias áreas da matemática aplicada, incluindo os fractais e a teoria do caos (OLIVEIRA; MENDES, 2006). Utiliza-se para caracterizar processos de memória longa e na análise espectral. A estimativa do parâmetro de Hurst foi originalmente desenvolvida em hidrologia e tem sido aplicado em áreas que vão desde a biofísica até redes de computadores. Porém, as modernas técnicas para estimação do parâmetro de Hurst vêm da matemática fractal (OLIVEIRA; MENDES, 2006).

Embora o parâmetro de Hurst seja bem definido matematicamente, a sua estimação é problemática. Todos os estimadores são vulneráveis às tendências dos dados, a periodicidade e outras fontes de erros. Muitos estimadores assumem formas específicas

Figura 11: Polígono composto de cópias repetidas de um pentagrama (LAUWERIER, 1991)



para cada aplicação. Neste trabalho utilizou-se o software SELFIS para estimação do parâmetro de Hurst. O SELFIS (*Self-similarity analysis*, análise de autossimilaridade) é um software baseado em Java para a estimação de autossimilaridade e análise de tráfego LRD (*Long Range Dependency*, Longa dependência). Este software é distribuído gratuitamente à comunidade (disponível em <http://alumni.cs.ucr.edu/~tkarag>) e atualmente, integra várias metodologias de estimação de LRD (KARAGIANNIS, 2010).

3.4.2 Função de Autocorrelação

A função de autocorrelação representa o grau de correlação de uma variável, em um instante de tempo, com ela mesma e em um instante de tempo posterior. Esta função permite que se analise o grau de irregularidade de um sinal.

A função de autocorrelação $\rho(k)$ para uma série estacionária $\{X_t, t \in N\}$ é dada pela equação (CLEGG, 2005):

$$\rho(k) = \frac{E[(X_t - \mu)(X_{t+k} - \mu)]}{\sigma^2} \quad (3.28)$$

onde $E[X_t]$, μ e σ^2 são respectivamente a esperança matemática, a média e a variância de X_t . As séries de tempo X_t são ditas de longa dependência se $\sum_{k=-\infty}^{\infty} \rho(k)$ divergir. Muitas vezes, a forma da função pode ser especificada por (CLEGG, 2005):

$$\rho(k) \approx C_\rho k^{-\alpha} \quad (3.29)$$

onde $C_\rho > 0$ e $\alpha \in (0, 1)$ e o símbolo $\approx$ significa assintoticamente igual, com $f(x) \approx$

$g(x) \rightarrow \frac{f(x)}{g(x)} = 1$ com $x \rightarrow 0$ (CLEGG, 2005). O parâmetro α é relacionado ao parâmetro de Hurst e dado pela equação (BATISTA, 2006):

$$\alpha = 2 - 2H \quad (3.30)$$

3.5 Processos Multifractais

A teoria multifractal foi apresentada por Mandelbrot no contexto de turbulência nos anos 70. A partir de então a teoria multifractal passou a ser usada em vários campos como o processamento de imagem, geofísica, etc. Para o tráfego de redes ser considerado multifractal, é preciso o mesmo possuir uma estrutura de forte dependência inerente, com incidência de rajadas em várias escalas (PARK; WILLINGER, 2000). Quando encontradas essas características, o desempenho da rede é pior que o considerado por modelos Gaussianos e de curta-dependência. O conceito de multifractalidade se estende facilmente aos processos estocásticos (VIEIRA; LING, 2008).

Para um processo estocástico $X(t)$ ser multifractal é necessário que se satisfaça a equação (VIEIRA; LING, 2007):

$$E [|X(t)|^q] = c(q)t^{\tau(q)+1} \quad (3.31)$$

onde t e q são intervalos da reta real, $\tau(q)$ e $c(q)$ são funções no domínio Q . Além disso, supõe-se que T e Q possuam comprimentos positivos, e que $0 \in T$, $[0, 1] \subseteq Q$.

A multifractalidade pode ser descrita em termos de momentos em que $\tau(q)$ é a função de escala e $c(q)$ é o fator de momento de um processo multifractal. Se $\tau(q)$ é linear em q , o processo é monofractal, senão é multifractal. Para processos auto-similares com parâmetro de Hurst H , pode-se mostrar que $\tau(q) = qH - 1$ e $c(q) = E [|X(1)|^q]$.

3.6 Modelo Movimento Browniano Multifractal (mBm)

O modelo mBm (movimento Browniano multifractal) introduzido em Peltier e Vehel (1995) é uma generalização do modelo de movimento Browniano fractal (fBm). Esta generalização ocorre com a troca do parâmetro de Hurst (H) por uma função denominada expoente de Hölder $H(t)$, introduzindo uma dependência entre a regularidade local e o instante de tempo t . Ou seja, enquanto a regularidade local num processo fBm é a mesma (constante), em um processo mBm, ela varia ao longo do tempo, sendo também definida pelo valor do expoente de Hölder $H(t)$.

O modelo mBm, apesar de ser uma generalização do processo fBm, possui algumas propriedades diferentes das do fBm. Um exemplo disso é a não estacionaridade dos incrementos do processo mBm. As propriedades do processo mBm são:

- Dada uma função de Hölder $H(t)$, o processo mBm $W(t)$ com $H(t)$ associada é contínuo;
- O processo mBm $W(t)$ com função de Hölder $H(t)$ associada apresenta autossimilaridade local (*local assintotic self-similar*) (MELO; FONSECA, 2004), ou seja:

$$\lim_{\rho \rightarrow 0^+} \left\{ \frac{W(t + \rho u) - W(t)}{\rho^{H(t)}} \right\}_{u \in \mathbb{R}^+} = \{B_{H(t)}(u)\}_{u \in \mathbb{R}^+} \quad (3.32)$$

onde $B_{H(t)}(u)$ é um processo fBm com parâmetro de Hurst $H = H(t)$, o valor da função $H(t)$ no instante de tempo t .

3.6.1 Expoente de Hölder e o Modelo mBm

O expoente de Hölder é capaz de descrever o grau de singularidade local de um processo, o que é interessante para a caracterização das rajadas de dados em séries de tráfego de redes (GUÉVEL; VÉHEL, 2010).

Sejam (X, d_X) e (Y, d_Y) espaços métricos. Uma função $f : X \rightarrow Y$ é dita uma função de Hölder com expoente $\beta > 0$, se para cada $x, y \in X$ com $d_X(x, y) < 1$ tem-se:

$$d_Y(f(x), f(y)) \leq c d_X(x, y)^\beta \quad (3.33)$$

para qualquer constante $c > 0$.

Seja $H : (0, \infty) \rightarrow (0, 1)$ uma função de Hölder com expoente $\beta > 0$. O movimento Browniano multifractal é um processo Gaussiano definido em $(0, \infty)$ e descrito por Peltier e Vehel (1995):

$$W_H(t) = \frac{1}{\Gamma\left(H(t) + \frac{1}{2}\right)} \left\{ \int_{-\infty}^0 \left((t-s)^{H(t)-\frac{1}{2}} - (-s)^{H(t)-\frac{1}{2}} \right) dB(s) + \int_0^t \left((t-s)^{H(t)-\frac{1}{2}} \right) dB(s) \right\} \quad (3.34)$$

onde $B(s)$ representa o movimento Browniano.

3.7 Modelo Cascatas Multiplicativas

Um dos modelos que possuem características capazes de modelar as propriedades de um processo multifractal são as cascatas multiplicativas. A construção de uma cascata multiplicativa é baseada na criação iterativa do processo em escalas mais finas, a partir de escalas mais amplas, de forma multiplicativa.


O modelo de cascatas multiplicativas originou-se do modelo conhecido como cascata binomial. Este modelo (cascatas multiplicativas), é um método para se obter um processo multifractal, que consiste de um procedimento iterativo no intervalo compacto $[0, 1]$ e para m_0 e m_1 (multiplicadores da cascata) dois números positivos cuja soma é 1. No estágio inicial $k = 0$ da cascata, se obtém a medida inicial μ_0 do processo com distribuição de probabilidade uniforme em $[0, 1]$. No próximo estágio $k = 1$, a medida μ_1 distribui massa utilizando a distribuição uniforme, sendo m_0 no subintervalo $[0, \frac{1}{2}]$ e massa igual a m_0 em $[\frac{1}{2}, 1]$. Em $k = 2$, o intervalo $[0, \frac{1}{2}]$ é subdividido em $[0, \frac{1}{4}]$ e $[\frac{1}{4}, \frac{1}{2}]$ e o mesmo acontece com intervalo $[\frac{1}{2}, 1]$ (VIEIRA; LING, 2008).

Considere o intervalo diádico $[t, t + 2^{-k}]$ em que $t = 0, \eta_1, \eta_2, \dots, \eta_k = \sum_{i=1}^k \eta_i 2^{-i}$. Sejam φ_0 e φ_1 as frequências relativas de 0's e 1's no desenvolvimento da cascata. A medida μ no intervalo diádico é dada por:

$$\mu[t, t + 2^{-k}] = m_0^{k\varphi_0} m_1^{k\varphi_1} \quad (3.35)$$

Este processo preserva a massa dos intervalos diádicos em cada estágio, por isso é chamado de cascata conservativa ou microcanônica. Em cada estágio da cascata os intervalos podem ser divididos em intervalos de $b \geq 2$ com tamanho igual, este processo é definido como cascata multinomial. Se os multiplicadores usados tiverem valor fixo para m_0 e $b = 2$, então a cascata multiplicativa é binomial determinística com função com escala: $\tau(q) = -\log_2(m_0^q m_1^q) + 1$ (VIEIRA; LING, 2008).

Figura 12: Processo de construção da cascata binomial (VIEIRA; LING, 2008)



Ao se permitir que os multiplicadores da cascata r sejam variáveis aleatórias independentes em $[0, 1]$, com densidade de probabilidade $f_R(x)$, obtém-se uma estrutura mais geral que a determinística, onde os multiplicadores são valores fixos (Figura 12). Desta forma, o processo multifractal obtido $\{\mu(t\Delta t_k)\}_{k=1}^{2^N}$ terá no estágio k da cascata um intervalo diádico de comprimento $\delta t_k = 2^{-k}$, que começa em $t = 0$, $\eta_1, \eta_2, \dots, \eta_k = \sum_{i=1}^k \eta_i 2^{-i}$, a medida μ :

$$\mu(\Delta t_k) = R(\eta_1)R(\eta_1, \eta_2) \cdots R(\eta_1, \eta_2, \dots, \eta_k) \quad (3.36)$$

onde $R(\eta_1, \eta_2, \dots, \eta_k)$ é o multiplicador no estágio k da cascata. Uma vez que os multiplicadores r são independentes e identicamente distribuídos (i.i.d.), pode-se demonstrar que a medida μ satisfaz a seguinte relação de escala:

$$E[\mu(\Delta t_k)^q] = (E[R]^q)^k = \Delta t_k^{-\log_2 E[R^q]} \quad (3.37)$$

Esta relação define um processo multifractal com função de escala $\tau(q) = -\log_2 E[R^q]$.

3.8 Modelo MWM

O modelo multifractal MWM (*Multifractal Wavelet Model*) proposto por Riedi et al. (1999) é baseado na wavelet (função utilizada para decompor e descrever processos) de Haar para caracterização de tráfego de redes cuja restrição de estrutura é construída por um modelo $W_{j,k}$.

$$W_{j,k} = A_{j,k} U_{j,k} \quad (3.38)$$

onde $A_{j,k}$ é a variável aleatória suportada no intervalo $[-1, 1]$, e $U_{j,k}$ representa uma aproximação de $X(t)$ para resolução de 2^{-j} .

O MWM é uma cascata multiplicativa no domínio *wavelet*. A transformada *wavelet* discreta (DWT - *Discrete Wavelet Transform*) é usada neste modelo devido a sua capacidade de representação multi-escala de sinais. A análise do MWM define uma base ortogonal dada por Φ (CHUI, 1995):

$$\Phi_{(s,l)}(x) = 2^{-\frac{s}{2}} \Phi(2^{-s}x - l) \quad (3.39)$$

onde s e l são números inteiros de tamanho e dilatação da função Φ para geração de *wavelets*.

Na obtenção de um processo segundo o modelo MWM é preciso aplicar a transformada *wavelet* discreta ao tráfego de rede, calcular os momentos de segunda ordem dos

coeficientes *wavelet* em cada escala, a média e a variância dos coeficientes na escala de maior resolução e calcular p_j , variável usada para capturar o decaimento de energia dos coeficientes *wavelet* em escala (RIBEIRO et al., 2000).

O MWM aproxima com eficiência as propriedades do fluxo de tráfego original em relação à distribuição marginal (produz distribuição aproximadamente lognormal) e sua estrutura de correlação; tendo grande destaque na modelagem de tráfego (VIEIRA; LING, 2008) (RIEDI et al., 1999).

3.9 Modelo AWMM

O AWMM (*Adaptive Wavelet Based Multifractal Model*, Modelo Adaptativo Multifractal Baseado em *Wavelet*) proposto por Vieira e Lee (2009) é um modelo desenvolvido baseado em algumas propriedades da *wavelet* de Haar e em cascatas multiplicativas. Este modelo multifractal, possui algumas vantagens sobre alguns modelos existentes em termos de poucos parâmetros de entrada e capacidade de atualização *online*.

O AWMM consiste em estimar o coeficiente de segunda ordem do momento da *wavelet* de Haar do produto par a par de amostras de uma cascata e amostras independentes e identicamente distribuídas (i.i.d.) de uma variável aleatória positiva e em seguida, obter os valores dos multiplicadores $A_{j,k}$ a fim de capturar a relação de energia *wavelet* $E(W_{j,k}^2)$. Ou seja, este modelo é capaz de capturar simultaneamente as funções $\tau(q)$ e $c(q)$ de processos multifractais e também o coeficiente de queda de energia *wavelet* (VIEIRA; LEE, 2009).

Para comparar as características auto-similares e as características multifractais estatística do modelo AWMM para aquelas do tráfego real, bem como às do modelo MWM, alguns testes foram realizados com dados estatísticos, tais como função de autocorrelação e espectro multifractal, conforme pode ser observado em Vieira e Lee (2006).

3.10 Modelo CGMD

O modelo CGMD (*Cascade with Generalized Multiplier Distributions*, Cascata com Multiplicador com Distribuição Generalizada) introduzido por Vieira e Lee (2006) apresenta multiplicadores determinados através de suas densidades de probabilidade estimadas a partir dos fluxos reais de tráfego de rede usando o método de Kernel e o método de Aceitação/Rejeição para obtenção de amostras segundo a PDF obtida.

A função densidade de probabilidade estimada pode ser paramétrica ou não paramétrica, assumindo ou não que os dados são extraídos de uma distribuição conhecida, respectivamente. Vieira e Lee (2006) seguiram a abordagem não-paramétrica para estimar os multiplicadores da cascata com base em dados observados.

O método de síntese CGMD consiste em um processo de cascata multiplicativa assumindo diferentes distribuições de multiplicadores em cada cascata. O procedimento envolve o processo de valor agregado obtido na escala mais grosseira da cascata, a densidade de probabilidade dos multiplicadores estimados pelo método de Kernel e os multiplicadores obtidos em cada fase, pelo método de Aceitação/Rejeição. Utiliza-se uma mistura Gaussiana para modelar a densidade de probabilidade real dos multiplicadores.

3.11 Simulações e Resultados: Avaliação dos Modelos de Tráfego

Neste trabalho, o sistema OFDM-TDMA é estudado no estado estacionário. Logo, assume-se que o processo de chegada de pacotes em regime permanente no sistema de filas considerado seja um processo estocástico estacionário de 1ª ordem. Dessa forma, pode ser estimada uma função densidade de probabilidade de uma variável aleatória que descreva bem o comportamento do tráfego de entrada do usuário. Portanto, são analisados três modelos de tráfego que serão posteriormente integrados ao modelo do sistema OFDM-TDMA: modelo de Poisson, método de Kernel e MMFM.

O tráfego real de redes IP apresenta elevada ocorrência de rajadas em várias escalas e longa dependência entre as amostras. O modelo de processo Poisson é ineficiente ao descrever tais características, como relatado por Paxson e Floyd (1995), o que torna a proposta deste trabalho interessante para aplicações reais.

Com o objetivo de avaliar o desempenho das técnicas de modelagem de tráfego consideradas neste trabalho, foram consideradas três séries de amostras reais de tráfego de redes IP: uma, que será aqui referenciada como *voip-call-1*, colhida em laboratório a partir de chamadas VoIP, outra, aqui referenciada como *dec-pkt-1*, colhida a partir de tráfego TCP/IP da rede da *Digital Equipment Corporation* (WRL, 1995) e outra, chamada de *new-zealand-isp*, composta por tráfego TCP e UDP capturado de um ISP da Nova Zelândia (WAND, 2010).

Cada amostra das séries registra a quantidade de *bytes* que formam o pacote transmitido. Neste experimento, considerou-se que as amostras foram coletadas a cada milissegundo. Os primeiros 1500 valores de cada uma das séries de tráfego consideradas são mostrados nas Figuras 13, 14 e 15.

Nas Figuras 16, 18 e 20 são exibidos o histograma e as estimativas da função densidade de probabilidade das séries de tráfego consideradas obtidas com o modelo de Poisson, com o método de kernel e com MMFM. As respectivas funções de probabilidade acumulada são mostradas nas Figuras 17, 19 e 21. O histograma é considerado uma estimativa simples da função densidade de probabilidade real da série, no entanto, por ser um método não-paramétrico, reproduz detalhes específicos e infere bem a o comportamento da variável aleatória em questão.



Figura 13: Número de pacotes que chegam em cada *frame* considerando a série *voip-call-1*Figura 14: Número de pacotes que chegam em cada *frame* considerando a série *dec-pkt-1*

Figura 15: Número de pacotes que chegam em cada *frame* considerando a série *new-zealand-isp*









Figura 16: Função densidade de probabilidade que descreve a série *voip-call-1*



Observa-se que a estimativa obtida a partir da distribuição de Poisson não reproduz detalhes específicos da variável aleatória. Como mostrado na Figura 16, na escala de tempo


Figura 17: Função de probabilidade acumulada que descreve a série *voip-call-1*Figura 18: Função densidade de probabilidade que descreve a série *dec-pkt-1*

analisada, o histograma mostra que a função densidade de probabilidade real define duas regiões claramente distintas com maior incidência de eventos. Esta característica não é visualizada na curva obtida com o modelo poissoniano.

Figura 19: Função de probabilidade acumulada que descreve a série *dec-pkt-1*Figura 20: Função densidade de probabilidade que descreve a série *new-zealand-isp*

De forma geral, como relatado por Paxson e Floyd (1995), séries de tráfego real não seguem o modelo de Poisson. Esta limitação torna o modelo pouco útil em aplicações reais.

O método de Kernel, sendo uma generalização do histograma e aplicado direta-

Figura 21: Função de probabilidade acumulada que descreve a série *new-zealand-isp*

mente sobre as amostras da série, fornece uma estimativa mais próxima da função densidade de probabilidade real (WEBB; COPSEY, 2011). O método de Kernel foi aplicado às séries em questão utilizando 256 centróides. Nota-se que a curva obtida descreve a densidade de probabilidade do processo de chegada de tráfego com mais detalhes que o modelo poissoniano, aproximando-se mais do comportamento descrito pelo histograma.

As Figuras 22, 23 e 24 mostram as amostras reais e as geradas com três modelos distintos: o MMFM, o método de Kernel e o modelo de Poisson. As Tabelas 3, 4 e 5 apresentam uma comparação entre as principais estatísticas das séries temporais reais e sintéticas. Como pode ser observado, os parâmetros estatísticos calculados para as séries sintéticas geradas com o MMFM e com o método de Kernel se aproximam mais dos parâmetros calculados para as séries reais.

As Figuras 25, 26 e 27 mostram a função de autocorrelação das séries reais e sintéticas. Observa-se que o MMFM apresenta uma função de autocorrelação mais próxima da obtida para o tráfego real do que os outros modelos considerados. O MMFM, ao tentar agregar ao modelo a relação de dependência das transições entre os níveis de taxas, consegue modelar significativamente a correlação temporal do processo de chegada de tráfego.


Figura 22: Taxa de fluxo de pacotes da série *voip-call-1*


Figura 23: Taxa de fluxo de pacotes da série *dec-pkt-1*


Figura 24: Taxa de fluxo de pacotes da série *new-zealand-isp*

Tabela 3: Parâmetros estatísticos - Série *voip-call-1*

Estatística	Tráfego real	Tráfego sint. MMFM	Tráfego sint. Kernel	Tráfego sint. Poisson
Variância	313,5448	332,6565	549,7678	97,4583
Média (pacotes/f)	97,6224	96,3088	99,2430	97,6776
Desvio padrão	17,7072	18,2389	23,4471	9,8721
Máximo (pacotes/f)	160	172	160	144
Mínimo (pacotes/f)	3	0	3	57
Máximo / Média	1,6390	1,7859	1,6122	1,4742
Coefficiente de correlação	-	0,1262	0,0003	-0,0063
Autossimilaridade (Parâmetro de Hurst)	0.8069	0.7962	0.5143	0.4929

Tabela 4: Parâmetros estatísticos - Série *dec-pkt-1*

Estatística	Tráfego real	Tráfego sint. MMFM	Tráfego sint. Kernel	Tráfego sint. Poisson
Variância	70,0245	74,4357	185,0711	64,3747
Média (pacotes/f)	64,0353	63,6115	60,5110	64,0253
Desvio padrão	8,3681	8,6276	13,6041	8,0234
Máximo (pacotes/f)	90	96	90	104
Mínimo (pacotes/f)	5	0	5	32
Máximo / Média	1,4055	1,5092	1,4873	1,6244
Coefficiente de correlação	-	0,2823	0,0810	-0,0001
Autossimilaridade (Parâmetro de Hurst)	0.8449	0.8069	0.5008	0.4958

Tabela 5: Parâmetros estatísticos - Série *new-zealand-isp*

Estatística	Tráfego real	Tráfego sint. MMFM	Tráfego sint. Kernel	Tráfego sint. Poisson
Variância	429,0579	456,2583	642,8697	650,0362
Média (pacotes/f)	66,0052	63,2548	70,8892	70,6485
Desvio padrão	20,7137	21,3602	25,3549	25,4958
Máximo (pacotes/f)	162	162	161	162
Mínimo (pacotes/f)	5	0	5	5
Máximo / Média	2,4544	2,5611	2,2712	2,2930
Coefficiente de correlação	-	0,2352	0,0059	0,0050
Autossimilaridade (Parâmetro de Hurst)	0.9443	0.7134	0.5049	0.4825




Figura 25: Função de autocorrelação da série *voip-call-1*

Figura 26: Função de autocorrelação da série *dec-pkt-1*Figura 27: Função de autocorrelação da série *new-zealand-isp*

4 Análise de Desempenho de Sistemas OFDM-TDMA Utilizando Cadeias de Markov

Neste capítulo, propõe-se um modelo baseado em Cadeias de Markov para análise de desempenhos de sistemas de comunicação OFDM-TDMA. Primeiramente, o cenário específico é estabelecido. Em seguida, modela-se, a transmissão no canal OFDM considerando modulação e codificação adaptativa num canal com desvanecimento rápido de Rayleigh. Então, a partir da função massa de probabilidade obtida para a taxa de transmissão total no canal e da função massa de probabilidade obtida para a taxa de chegada de pacotes, um modelo do comportamento da fila do usuário no sistema OFDM-TDMA é desenvolvido. Deste são derivados alguns indicadores de desempenho do sistema.

4.1 Modelo do Sistema OFDM-TDMA

O sistema considerado envolve uma estação base conectada a várias estações assinantes (Figura 28). O cenário envolve a transmissão *downlink* em um canal baseado na tecnologia OFDM-TDMA para promover acesso a múltiplas estações assinantes. A implementação do múltiplo acesso por divisão de tempo é feita com escalonamento *round-robin* e todos os usuários são atendidos com períodos de igual duração, assim como feito em (NIYATO; HOSSAIN, 2005). Há N usuários compartilhando um canal com M subportadoras. Cada usuário possui um próprio *buffer* localizado na estação base com tamanho estabelecido onde o tráfego de entrada é armazenado. O modelo deste sistema é ilustrado na Figura 29.

Num ciclo de transmissão, o canal é alocado para cada usuário durante uma janela de tempo para envio de um *frame*, totalizando, assim, N *frames* transmitidos ao final do ciclo. A duração de um intervalo de tempo dedicado a um usuário é de T segundos. Como ilustrado na Figura 8, o número de pacotes transmitidos num *frame* pode ser diferente dependendo do nível de modulação utilizado em cada subportadora. Pequenos intervalos de tempo são inseridos entre as transmissões de cada usuário com o intuito de evitar interferência.

O sistema representado considera apenas a transmissão no *downlink*, porem, o método TDMA pode suportar comunicação *duplex* com divisão no tempo (TDMA/TDD)

Figura 28: Cenário do sistema considerado: uma Estação Base conectada a várias Estações Assinantes





Figura 29: Modelo da Transmissão OFDM-TDMA



dedicando alguns intervalos de tempo do canal para transmissão no *uplink*.

4.2 Transmissão OFDM

Considera-se, neste trabalho, que o transmissor possui informações a respeito da qualidade do canal (como a relação sinal-ruído, ou *signal-to-noise ratio*, SNR) no ato da transmissão de um *frame*, o que possibilita a utilização de modulação e codificação adaptativas. Estas informações podem ser obtidas através do sinal piloto (COLERI et al., 2002).

Mediante o uso de modulação e codificação adaptativas, o número máximo de bits de informação por símbolo amostrado (Hz) que uma subportadora m pode transmitir para um usuário n durante um símbolo OFDM no tempo t pode ser escrito em função da SNR e da probabilidade de erro de bit (*Bit Error Rate*, BER). Apesar de haver várias aproximações desta função, todas elas são limitadas superiormente pela seguinte expressão

do nível de modulação (QIU; CHAWLA, 1999):

$$c_{m,n}(t) = \left\lfloor \log_2 \left(1 + \frac{-1,5}{\ln(5P_{ber})} \gamma_{m,n}(t) \right) \right\rfloor \quad (4.1)$$

onde $\gamma_{m,n}(t)$ é a SNR instantânea num símbolo OFDM transmitido durante t para uma subportadora m e usuário n , e P_{ber} é a probabilidade de erro de bit.

Seja C o nível de modulação máximo possível. Os níveis de SNR podem ser divididos em $C + 1$ intervalos consecutivos e disjuntos com limites definidos como Γ_c , onde $c = 0, 1, \dots, C$. Cada região definida equivale a um nível de modulação. Dessa forma, quanto maior a leitura da SNR, maior será o nível de modulação utilizado. Os limites desses intervalos não dependem dos usuários ou das subportadoras pelas quais ocorrerá a transmissão, mas apenas do nível de modulação. Então, a partir da equação 4.1, estes limites podem ser obtidos como:

$$\Gamma_c = \frac{(2^c - 1) \ln(5P_{ber})}{-1,5} \quad (4.2)$$

O maior nível de modulação é utilizado desde que a probabilidade de erro de bit se mantenha abaixo do limiar estabelecido. Dessa forma, o nível de modulação c é utilizado quando $\Gamma_c \leq \gamma_{m,n} \leq \Gamma_{c+1}$. Quando o nível de modulação é zero ($c = 0$), nenhum pacote é transmitido.

É considerado que a potência de transmissão é fixa e que o canal sofre desvanecimento rápido tipo Rayleigh. A média invariante no tempo da SNR para a subportadora m e usuário n é chamada $\bar{\gamma}_{m,n}$. A SNR recebida, $\gamma_{m,n}$, é, então, uma variável aleatória com a seguinte densidade de probabilidade:

$$p_\gamma(\gamma_{m,n}) = \frac{1}{\bar{\gamma}_{m,n}} \exp\left(-\frac{\gamma_{m,n}}{\bar{\gamma}_{m,n}}\right) \quad (4.3)$$

Assim, a probabilidade de um nível de modulação c ser escolhido para uma subportadora m e usuário n é dada como:

$$P_{c_{m,n}}(c) = \int_{\Gamma_c}^{\Gamma_{c+1}} p_\gamma(\gamma_{m,n}) d\gamma_{m,n} = \exp\left(-\frac{\Gamma_c}{\bar{\gamma}_{m,n}}\right) - \exp\left(-\frac{\Gamma_{c+1}}{\bar{\gamma}_{m,n}}\right) \quad (4.4)$$

Em cada *frame* transmitido com duração T , o número de pacotes r que podem ser transmitidos é definido em função do nível de modulação:

$$r(c) = \left\lfloor \frac{T \times c \times \Delta f}{L} \right\rfloor \quad (4.5)$$

onde $\Delta f = \frac{B}{M}$, B é a largura de banda do canal de transmissão, M é o número de subportadoras que compõem o canal OFDM e L é o tamanho do pacote transmitido em bits.

Para um usuário n , a probabilidade de se utilizar uma determinada taxa de transmissão de pacotes r_m numa subportadora m pode ser calculada da seguinte forma:

$$Pr_{m,n}(r_m) = \sum_{r_m=r(c)} P_{c,m,n}(c) \quad (4.6)$$

onde $c = 0, 1, 2, \dots, C$, $r_m = 0, 1, 2, \dots, R$ e $R = \left\lfloor \frac{T \times C \times \Delta f}{L} \right\rfloor$.

Para o usuário n , a função massa de probabilidade da taxa de transmissão de pacotes durante um *frame* numa subportadora m é obtida como na equação 4.7:

$$r_{m,n} = \left[Pr_{m,n}(0) \quad Pr_{m,n}(1) \quad Pr_{m,n}(2) \quad \dots \quad Pr_{m,n}(R) \right] \quad (4.7)$$

Então, a função massa de probabilidade da taxa de transmissão total ($\mathbf{R}_n$), envolvendo todas as M subportadoras do canal dedicado ao usuário n , é dada pela convolução das funções massa de probabilidade das taxas de transmissão de cada subportadora.

$$\mathbf{R}_n = r_{1,n} * r_{2,n} * \dots * r_{M,n} \quad (4.8)$$

4.3 Formulação do Modelo baseado em Cadeias de Markov para o Sistema de Filas

Foi desenvolvido um modelo analítico baseado em Cadeias de Markov de Tempo Discreto para analisar o desempenho do sistema de fila de um usuário específico que se encontra em estado estacionário. Dessa forma, dadas as funções massa de probabilidade da taxa de transmissão total e do tráfego de chegada (que, neste caso, é estimada a partir do método de Kernel ou do MMFM), o modelo proposto pode ser aplicado a qualquer uma das filas.

Na definição do modelo, é assumido que os estados da fila são observados ao final de cada janela de tempo onde ocorre a transmissão do *frame*. Os intervalos de tempo inseridos entre as transmissões de cada *frame* são desconsiderados para simplificar o modelo, uma vez que são muito inferiores ao tempo dedicado à transmissão do *frame*. No entanto, esse intervalo pode ser inserido no modelo ao dedicar uma janela de tempo com taxa de transmissão nula, onde não há atendimento a nenhum usuário, que equivalha ao intervalo.

Neste trabalho, o sistema OFDM-TDMA é estudado no estado estacionário. Portanto, assume-se que o processo de chegada de pacotes em regime permanente no sistema

de filas considerado seja um processo estocástico estacionário de 1ª ordem. Dessa forma, pode ser estimada uma função de densidade de probabilidade de uma variável aleatória que descreva bem o comportamento do tráfego de entrada do usuário.

O tráfego de entrada de cada usuário é modelado a partir de séries de amostras reais de tráfego de redes IP. A série deve possuir os valores agregados a cada T segundos, a duração da transmissão de um *frame*. A partir disso, o método de Kernel ou o MMFM é aplicado e, então, é obtida uma função de densidade de probabilidade $f(v)$ que descreve o processo de chegada de pacotes para cada usuário em estado estacionário. A função de distribuição acumulada, por sua vez, é denominada $F(v)$.

Considera-se, ainda, um número V correspondente ao máximo de pacotes que pode entrar na fila de transmissão durante um *frame*. A probabilidade de chegar V pacotes é definida como $f(V) = 1 - F(V - 1)$.

O comportamento da fila de pacotes de um usuário pode ser modelado como um processo de quase nascimento e morte (LEEWAARDEN; SQUILLANTE; WINANDS, 2009) e, dado o domínio discreto do tempo, uma matriz de probabilidade de transição da Cadeia de Markov, $\mathbf{P}$ (de elementos $\mathbf{p}_{x,x'}$), pode ser definida. Esta matriz é dada pela equação 4.9, onde R é a maior taxa de transmissão total e V o número máximo de pacotes que pode entrar na fila de transmissão durante um *frame*.

A matriz $\mathbf{P}$ é quadrada e suas linhas representam o número de pacotes (x) na fila, enquanto os valores $\mathbf{p}_{x,x'}$ representam a probabilidade de transição da fila do estado x para x' , ou seja, de x pacotes no presente para x' pacotes no início da transmissão do próximo *frame*.

Uma vez definida a matriz de transição $\mathbf{P}$, pode-se estimar as probabilidades do sistema se encontrar em cada estado em regime permanente e, a partir disso, determinar vários parâmetros de qualidade de serviço.

$$\mathbf{P} = \begin{bmatrix}
\mathbf{p}_{0,0} & \mathbf{p}_{0,1} & \dots & \mathbf{p}_{0,V} & \mathbf{0} & \dots & \dots & \dots & \mathbf{0} \\
\mathbf{p}_{1,0} & \mathbf{p}_{1,1} & \mathbf{p}_{1,2} & \dots & \mathbf{p}_{1,1+V} & \mathbf{0} & \dots & \dots & \mathbf{0} \\
\vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\
\mathbf{p}_{R,0} & \dots & \mathbf{p}_{R,R-1} & \mathbf{p}_{R,R} & \mathbf{p}_{R,R+1} & \dots & \mathbf{p}_{R,R+V} & \dots & \mathbf{0} \\
\mathbf{0} & \mathbf{p}_{R+1,1} & \dots & \mathbf{p}_{R+1,R-1} & \mathbf{p}_{R+1,R+1} & \mathbf{p}_{R+1,R+2} & \mathbf{p}_{R+1,R+1+V} & \mathbf{0} & \mathbf{0} \\
\vdots & \mathbf{0} & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\
\vdots & \ddots & \mathbf{0} & \mathbf{p}_{x,x-R} & \dots & \mathbf{p}_{x,x} & \dots & \mathbf{p}_{x,x+V} & \vdots \\
\vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\
\vdots & \ddots & \ddots & \ddots & \ddots & \mathbf{0} & \mathbf{p}_{X-1,X-R} & \dots & \mathbf{p}_{X-1,X} \\
\mathbf{0} & \dots & \dots & \dots & \dots & \dots & \mathbf{p}_{X,X-R} & \dots & \mathbf{p}_{X,X}
\end{bmatrix}$$

(4.9)

No sistema OFDM-TDMA, o conjunto de estados que a fila de um determinado usuário pode assumir num *frame* i é definido como:

$$\Delta = \{(\mathcal{X}_i, \mathcal{N}_i), 0 \leq \mathcal{X}_i \leq X, 1 \leq \mathcal{N}_i \leq N\} \quad (4.10)$$

onde $\mathcal{X}_i$ é o número de pacotes encontrados na fila, X é o tamanho do *buffer*, $\mathcal{N}_i$ corresponde ao usuário sendo servido durante o *frame* e N se refere ao número de usuários no sistema.

Uma vez que os usuários são servidos sequencialmente e de maneira circular, a seguinte matriz de transição pode representar o escalonamento *round-robin* admitido:

$$\mathbf{U} = \begin{bmatrix} 0 & 1 & 0 & \cdots & 0 \\ 0 & 0 & 1 & \cdots & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & 1 \\ 1 & 0 & 0 & \cdots & 0 \end{bmatrix} \quad (4.11)$$

A matriz $\mathbf{U}$ tem dimensões $N \times N$ e cada linha representa o usuário que está sendo servido no momento. Sendo assim, a linha n representa que o usuário n está sendo atendido pelo sistema no *frame* atual.

O número de pacotes que entram na fila de transmissão durante um *frame* é limitado por V , enquanto o número de pacotes que são transmitidos num *frame* é limitado por R . Dessa forma, surgem as relações 4.12 e 4.13:

$$A = \min(X - x, V) \quad (4.12)$$

$$D = \min(x, R) \quad (4.13)$$

A probabilidade de transição da fila de um usuário do estado x para x' depende de qual usuário está sendo atendido e, a partir do modelo obtido para processo de entrada de pacotes do usuário e da função massa de probabilidade da taxa de transmissão total, é determinada pela matriz diagonal $\mathbf{V}_{x,x'}$, de dimensões $N \times N$ dada por (NIYATO; HOSSAIN, 2005).

$$[\mathbf{V}_{x,x'}]_{i,i} = \begin{cases} \sum_{v-r=x'-x} f(v) [\mathbf{R}_n]_{r+1}, & i = n \\ f(x' - x), & i \neq n, x' \geq x \end{cases} \quad (4.14)$$

onde $x - D \leq x' \leq x + A$, $r = 0, 1, \dots, R$ e $v = 0, 1, \dots, V$. $\mathbf{R}_n$ é o vetor que contém a função massa de probabilidade da taxa de transmissão total para o usuário n (equação

4.8) cuja fila está sendo analisada. $[\mathbf{V}_{x,x'}]_{i,i}$ indica o elemento na linha i e coluna i da matriz diagonal $\mathbf{V}_{x,x'}$.

Os valores $\mathbf{p}_{x,x'}$, que formam a matriz de transição do sistema, são calculados segundo a equação 4.15. Observa-se que cada $\mathbf{p}_{x,x'}$ é uma matriz de dimensões $N \times N$.

$$\mathbf{p}_{x,x'} = \mathbf{U}\mathbf{V}_{x,x'} \quad (4.15)$$

Calculando-se todos os valores $\mathbf{p}_{x,x'}$, para $0 \leq x \leq X$ e $x - D \leq x' \leq x + A$, obtém-se a matriz de transição completa do sistema.

4.4 Estimação de Parâmetros de QoS

Os parâmetros de QoS são calculados a partir das probabilidades em estado estacionário do sistema se encontrar em cada estado possível. Essas probabilidades, dadas pelo vetor $\boldsymbol{\pi}$, podem ser calculadas a partir da matriz de transição $\mathbf{P}$ através da solução de um sistema linear, como mostrado anteriormente.

Como, para cada um dos X estados da fila, o modelo considera os N diferentes estados para o escalonamento *round-robin*, a probabilidade em estado estacionário da fila do usuário considerado conter x pacotes (onde $0 \leq x \leq X$) pode ser calculada como:

$$\pi(x) = \sum_{i=(x \times N)+1}^{(x+1) \times N} [\boldsymbol{\pi}]_i \quad (4.16)$$

A partir destes valores, pode-se obter o número médio de pacotes na fila (*backlog*):

$$b = \sum_{x=0}^X x\pi(x) \quad (4.17)$$

O atraso médio de um pacote (*delay*), definido como o tempo médio (em *frames*) que um pacote espera na fila desde sua chegada até sua transmissão, é dado pela lei de Little:

$$d = \frac{b}{\lambda} \quad (4.18)$$

onde λ é o número médio de pacotes que chegam por *frame*, obtido a partir da média da série de tráfego considerada depois de agregada em intervalos de tempo equivalentes à duração do *frame*.

A partir da lei da probabilidade total, a probabilidade da fila se encontrar no estado X é dada pela soma das probabilidades do *buffer* conter X pacotes dado que houve transbordo no *buffer* e do *buffer* conter X pacotes dado que não houve transbordo.

$$\pi(X) = P(X|T)P(T) + P(X|\bar{T})P(\bar{T}) \quad (4.19)$$

Uma vez que a fila de pacotes no *buffer* do usuário passa para o estado X toda vez que ocorre transbordo, $P(X|T) = 1$. Portanto:

$$\pi(X) = P(T) + P(X|\bar{T})P(\bar{T}) \quad (4.20)$$

Constata-se que, quando a média do fluxo de entrada da fila é inferior à média do fluxo de atendimento, a probabilidade do *buffer* conter X pacotes quando não há transbordo decresce com o aumento do *buffer*, pois a fila tende a ocupar um menor espaço dentro do *buffer* com o sistema em estado estacionário. Neste caso, a probabilidade de que haja transbordo, e, por consequência, a fila tenha X pacotes, é bastante superior à probabilidade da fila conter X pacotes quando não há transbordo, ou seja, $P(T) \gg P(X|\bar{T})P(\bar{T})$. Portanto, podemos aproximar a probabilidade de transbordo do *buffer* da seguinte forma:

$$P_{transb} \approx \pi(X) \quad (4.21)$$

Basicamente, todos os passos envolvidos neste método para a obtenção de estimativas dos parâmetros de QoS podem ser resumidos no seguinte algoritmo:

Algoritmo Proposto: Estimação de Parâmetros de QoS

1. Determinar a função massa de probabilidade da taxa de transmissão total do usuário n ($\mathbf{R}_n$ — equação 4.8);
2. Utilizando o método de Kernel (equação 3.11) ou MMFM (equação 3.14), determinar a função densidade de probabilidade do processo de chegada de tráfego em estado estacionário do usuário n ($f_n(v)$);
3. Encontrar, a partir de $\mathbf{R}_n$ e $f_n(v)$, a matriz de probabilidade de transição de estados da fila do usuário no sistema OFDM-TDMA ($\mathbf{P}$);
4. Calcular as probabilidades, em regime permanente, da fila do usuário se encontrar em cada estado possível ($\boldsymbol{\pi}$ — equações 2.9 e 2.10);
5. Calcular as estimativas dos parâmetros de QoS (equações 4.17, 4.18 e 4.21).

4.5 Simulações e Resultados

Nos experimentos realizados, foi analisado o desempenho da fila de um usuário no sistema OFDM-TDMA com 5 conexões ativas. O tráfego dos usuários foi modelado a partir das três séries antes consideradas neste artigo, *voip-call-1*, *dec-pkt-1* e *new-zealand-isp*.

Conforme a Tabela 6, três cenários distintos são considerados para a validação do modelo. Em cada cenário, uma das três séries é utilizada para definir o perfil de tráfego do usuário, como discriminado na tabela.

Tabela 6: Cenários do sistema OFDM-TDMA considerados

Cenário	1	2	3
Série	<i>voip-call-1</i>	<i>dec-pkt-1</i>	<i>new-zealand-isp</i>
N	5	5	5
M	512	512	512
B (MHz)	20,0	13,5	100
Δf (Hz)	39062,5	26367,19	195312,5
P	10^{-6}	10^{-6}	10^{-6}
C (bits/sím)	6	5	6
T (ms)	20	100	10
L (bytes)	59	329	239

Os cenários foram analisados com o objetivo de se estudar o desempenho do canal através da variação da média da relação sinal-ruído (SNR). Três modelos foram construídos, cada um baseado num modelo de tráfego distinto. Compara-se o desempenho dos modelos aqui propostos, baseados no método de Kernel e no MMFM, com o desempenho do modelo baseado em Poisson já apresentado por Niyato e Hossain (2005).

A partir do modelo considerado para o canal OFDM com base no desvanecimento rápido de Rayleigh (assumindo-se os parâmetros definidos na Tabela 6), foram obtidas as funções massa de probabilidade da taxa de transmissão total do canal (equação 4.8) mostradas nas Figura 30, 31 e 32 para um intervalo de valores de SNR. Como esperado, o aumento da relação sinal-ruído ocasiona uma melhoria na qualidade do canal, dado que a taxa média de transmissão é incrementada.

Uma vez determinadas as funções que descrevem a chegada de tráfego e a transmissão no canal OFDM para o usuário, o modelo implementado baseado em Cadeias de Markov para análise da fila no sistema OFDM-TDMA foi aplicado. Assumindo que o tamanho do *buffer* do usuário seja de 400 pacotes e que haja um limite de 200 pacotes para o tráfego que chega em um *frame* ($X = 400$ e $V = 200$), foram encontradas as probabilidades em estado estacionário da fila do usuário conter cada número possível de

Figura 30: Função massa de probabilidade da taxa de transmissão total para diferentes valores de SNR no Cenário 1






Figura 31: Função massa de probabilidade da taxa de transmissão total para diferentes valores de SNR no Cenário 2



pacotes, mostradas nas Figuras 33, 34 e 35.

Observa-se que, com o aumento da qualidade do canal, a probabilidade da fila ser menor eleva-se, uma vez que o transmissor passa a utilizar maiores níveis de modulação e, consequentemente, há aumento da taxa média de transmissão no canal.

Figura 32: Função massa de probabilidade da taxa de transmissão total para diferentes valores de SNR no Cenário 3



Com a finalidade de validar os resultados numéricos obtidos com o modelo analítico, foi desenvolvido um simulador do sistema OFDM-TDMA considerado utilizando o programa Matlab. As probabilidades, obtidas com a simulação, da fila do usuário se encontrar em cada tamanho possível podem ser visualizadas nas Figuras 36, 37 e 38.

Os resultados obtidos deixam clara a precisão do modelo em representar o comportamento da fila num sistema OFDM-TDMA real. O modelo implementado, devido à estimação não-paramétrica do tráfego de entrada, é capaz de retratar irregularidades que um modelo baseado em estimação paramétrica, como o poissoniano, não pode.

Observa-se que, devido ao escalonamento cíclico de conexões, a fila de pacotes do usuário tende a aumentar nas iterações em que o usuário não é atendido, formando diferentes regiões de maior probabilidade.

Com o intuito de se comparar mais facilmente os resultados obtidos, foram expostas, nas Figuras 39, 40 e 41 as probabilidades da fila do usuário se encontrar em cada estado possível no Cenário 1 para $\text{SNR} = \{8; 12; 16\}$ dB, nas Figuras 42, 43 e 44 as probabilidades da fila do usuário se encontrar em cada estado possível no Cenário 2 para $\text{SNR} = \{8; 12; 16\}$ dB e nas Figuras 45, 46 e 47 as probabilidades da fila do usuário se encontrar em cada estado possível no Cenário 3 para $\text{SNR} = \{8; 12; 16\}$ dB.

Os gráficos das Figuras 33, 34, 35, 36, 37 e 38 não incluem as probabilidades $\pi(0)$ e $\pi(X)$, as probabilidades do *buffer* se encontrar vazio e cheio, respectivamente. Na região definida de variação da SNR, os valores de $\pi(0)$ e $\pi(X)$ são bastante superiores aos valores de $\pi(x)$ para $0 < x < X$, o que dificultaria a visualização dos gráficos caso esses

valores fossem incluídos. O valor elevado da probabilidade do *buffer* se encontrar vazio se deve à existência de capacidade ociosa. Toda vez que a taxa de transmissão no *frame* é superior ao número de pacotes na fila somado com o número de pacotes chegando, o *buffer* fica vazio. Já o valor elevado da probabilidade do *buffer* se encontrar cheio é devido à ocorrência de transbordo de pacotes. Sempre que ocorre transbordo, o *buffer* permanece cheio ao final da transmissão do *frame*.

As Figuras 48, 49 e 50 mostram a probabilidade, para vários valores de SNR, do *buffer* se encontrar vazio para os Cenários 1, 2 e 3, respectivamente. Pode ser visto que a probabilidade da fila estar vazia aumenta com a melhoria da qualidade do canal, enquanto a probabilidade do *buffer* estar completo de pacotes decresce. Por outro lado, as Figuras 51, 52 e 53 mostram a probabilidade, para vários valores de SNR, do *buffer* se encontrar cheio para os Cenários 1, 2 e 3, respectivamente.


A partir da equação 4.17 foi obtido o número médio de pacotes no *buffer*, como mostrado nas Figuras 54, 55 e 56.

O atraso médio, calculado utilizando a equação 4.18, pode ser visualizado em função da SNR nas Figuras 57, 58 e 59 e a probabilidade de transbordo do *buffer* do usuário em função da SNR é mostrada nas Figuras 60, 61 e 62.


Nota-se que, à medida que se aumenta a SNR, há uma diminuição no tamanho médio de fila, no atraso médio da transmissão e na probabilidade de transbordo do *buffer* do usuário. Este efeito era de se esperar, pois, com a melhoria das condições do canal, o sistema OFDM-TDMA, ao aplicar modulação adaptativa, provê maiores taxas de transmissão.

Os resultados obtidos, analisados juntamente com os resultados das simulações realizadas, confirmam que o modelo é eficiente ao descrever os indicadores de desempenho considerados. A aplicação do MMFM e do método de Kernel na modelagem do processo de chegada de pacotes, quando comparado ao modelo de Poisson, aprimora as estimativas dos parâmetros de QoS, tornando seus valores mais próximos aos resultados das simulações. Dessa forma, pode ser dito que os modelos desenvolvidos representam bem o comportamento da fila de um usuário no sistema OFDM-TDMA.


Figura 33: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1



(a) Modelo baseado no MMFM




(b) Modelo baseado no método de Kernel




(c) Modelo baseado em Poisson


Figura 34: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2



(a) Modelo baseado no MMFM




(b) Modelo baseado no método de Kernel




(c) Modelo baseado em Poisson


Figura 35: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3



(a) Modelo baseado no MMFM



(b) Modelo baseado no método de Kernel



(c) Modelo baseado em Poisson

Figura 36: Probabilidade da fila do usuário se encontrar em cada estado possível obtida a partir de simulação do Cenário 1




Figura 37: Probabilidade da fila do usuário se encontrar em cada estado possível obtida a partir de simulação do Cenário 2




Figura 38: Probabilidade da fila do usuário se encontrar em cada estado possível obtida a partir de simulação do Cenário 3




Figura 39: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1 para $\text{SNR} = 8 \text{ dB}$




Figura 40: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1 para SNR = 12 dB




Figura 41: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 1 para SNR = 16 dB




Figura 42: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2 para $\text{SNR} = 8$ dB




Figura 43: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2 para $\text{SNR} = 12$ dB




Figura 44: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 2 para SNR = 16 dB




Figura 45: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3 para $\text{SNR} = 8$ dB




Figura 46: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3 para $\text{SNR} = 12$ dB




Figura 47: Probabilidade da fila do usuário se encontrar em cada estado possível no Cenário 3 para $\text{SNR} = 16$ dB






Figura 48: Probabilidade do *buffer* se encontrar vazio no Cenário 1Figura 49: Probabilidade do *buffer* se encontrar vazio no Cenário 2



Figura 50: Probabilidade do *buffer* se encontrar vazio no Cenário 3Figura 51: Probabilidade do *buffer* se encontrar cheio no Cenário 1



Figura 52: Probabilidade do *buffer* se encontrar cheio no Cenário 2Figura 53: Probabilidade do *buffer* se encontrar cheio no Cenário 3

Figura 54: Tamanho médio da fila no Cenário 1




Figura 55: Tamanho médio da fila no Cenário 2




Figura 56: Tamanho médio da fila no Cenário 3




Figura 57: Atraso médio dos pacotes transmitidos no Cenário 1




Figura 58: Atraso médio dos pacotes transmitidos no Cenário 2




Figura 59: Atraso médio dos pacotes transmitidos no Cenário 3







Figura 60: Probabilidade de transbordo do *buffer* no Cenário 1Figura 61: Probabilidade de transbordo do *buffer* no Cenário 2

Figura 62: Probabilidade de transbordo do *buffer* no Cenário 3

5 Estimação de Probabilidade de Transbordo do *Buffer* em Sistemas OFDM-TDMA Utilizando Curva de Serviço Baseada em Cálculo de Rede

Neste capítulo, introduz-se, inicialmente, a teoria de Cálculo de Rede Determinístico. Em seguida são definidos alguns conceitos fundamentais como funções cumulativas, processo envelope e curva de serviço, posteriormente utilizados na formulação de uma eficiente equação para estimação da probabilidade de transbordo do *buffer* de um usuário do sistema OFDM-TDMA. Ao final do capítulo, o modelo obtido é aplicado em diferentes cenários do sistema considerado e os resultados obtidos são contrapostos aos resultados de simulações.

5.1 Cálculo de Rede Determinístico

O Cálculo de Rede Determinístico, muito desenvolvido na última década, pode ser utilizado para estimar recursos a fim de prover qualidade de serviço (QoS) em redes e tem fornecido ferramentas poderosas para estimação do *backlog* e do retardo em uma rede com garantias de serviço para fluxos de tráfego individuais. Trabalhos pioneiros nesta área foram desenvolvidos por Cruz (1991a) e Cruz (1991b). Usando o conceito de envelopes de chegada e curvas de serviço (CRUZ, 1995), vários trabalhos têm demonstrado que os limitantes de *backlog* e de retardo podem ser concisamente expressos pela álgebra Min-Plus (AGRAWAL et al., 1999) (BOUDEC, 1998).

O Cálculo de Rede também pode ser visto como a teoria de sistemas que se aplica às redes de computadores, mas a principal diferença é que aqui se considera outra álgebra, onde as operações são alteradas da seguinte forma: adição torna-se o cálculo do mínimo, e a multiplicação torna-se adição.

Uma característica atrativa do Cálculo de Rede é que limitantes dos indicadores de desempenho de uma rede completa podem ser facilmente obtidos por meio de manipulações dos limitantes de cada nó.

Um regulador é um dispositivo que obriga um fluxo de entrada $x(t)$ a ter uma saída $y(t)$ que se conforma a um determinado conjunto de taxas de acordo com um envelope

de tráfego A (a curva de formação), à custa de, possivelmente, atrasar bits no *buffer*. A entrada e saída de fluxos acumulados são definidas, por Boudec (1998), como o número de bits visto no fluxo de dados no intervalo de tempo $[0, t]$. Essas funções são não-decrescentes com o tempo t . O parâmetro t pode ser contínuo ou discreto.


Seja a convolução Min-Plus entre A e x dada por:

$$y(t) = (A \otimes x)(t) = \inf_{s \in [0, t]} \{A(t - s) + x(s)\} \quad (5.1)$$

A convolução na teoria de sistemas tradicionais é tanto comutativa quanto associativa, e essa propriedade permite estender facilmente a análise de pequenos a grandes circuitos. Por exemplo, a resposta ao impulso do circuito da Figura 63a é a convolução da resposta ao impulso de cada uma das células elementares:

$$h(t) = (h_1 \otimes h_2)(t) = \int_0^t h_1(t - s)h_2(s) ds \quad (5.2)$$

Figura 63: A resposta ao impulso da concatenação de dois circuitos lineares é (a) a convolução da resposta ao impulso individual, a curva de formação da concatenação de dois reguladores é (b) a convolução das curvas individuais modeladas (BOUDEC; THIRAN, 2001)



A mesma propriedade é utilizada para o regulador. A saída do segundo regulador na Figura 63b é na verdade igual a $y(t) = (A \otimes x)(t)$, onde:

$$y(t) = (A_1 \otimes A_2)(t) = \inf_{s \in [0, t]} \{A_1(t - s) + A_2(s)\} \quad (5.3)$$

5.1.1 Funções Cumulativas a Tempo Discreto Versus Modelos de Tempo Contínuo

É conveniente descrever o fluxo de dados por meio da função acumulada $R(t)$, definida como o número de bits do fluxo no intervalo de tempo $[0, t]$. Por convenção, toma-se $R(0) = 0$, salvo indicação em contrário (BOUDEK; THIRAN, 2001).

Em sistemas reais, há sempre uma granularidade mínima (bit, palavra, célula ou pacote). Se $R(t)$ é uma função contínua, afirma-se que se tem um modelo fluido (*fluid model*) para o tráfego modelado. Caso contrário, pode-se convencionar que a função é contínua à direita ou à esquerda (BOUDEK; THIRAN, 2001). Para um sistema em análise, recebe-se dados de entrada, descrito por sua função cumulativa $R(t)$, e fornece-se os dados após um período variável. Tem-se $R^*(t)$ a função de saída, ou seja, a função cumulativa na saída do sistema analisado.


O sistema pode ser, por exemplo, um único *buffer* servindo a uma taxa constante, um nó de comunicação complexo, ou mesmo uma rede completa. A Figura 64 mostra a entrada e saída de funções para uma fila de servidor único, em que cada pacote tem exatamente 3 unidades de tempo para serem servidos. Como a saída da função de R_1^* (modelo fluido) é o pressuposto de que um pacote pode ser servido assim como um bit chegou primeiro (suposição de corte), e que a saída de pacotes podem ser observada bit a bit, a uma taxa constante.

Na Figura 64a, R_1 e R_1^* mostram uma função contínua no tempo contínuo (modelo fluido), assumindo que os pacotes chegam bit a bit, com a duração de uma unidade de tempo por chegada de pacotes. Para a Figura 64b, R_2 e R_2^* mostram uma função no tempo contínuo com descontinuidades em tempos de chegada de pacotes (tempos $\{1; 4; 8; 8; 6; 14\}$), supõem-se que as chegadas de pacotes são observadas apenas quando o pacote for recebido plenamente; os pontos na Figura 64b representam o valor (em bits) do ponto de descontinuidade. Por convenção, assume-se que a função é contínua à esquerda ou da direita. A Figura 64c mostra R_3 e R_3^* que representam um modelo em tempo discreto, o sistema é observado apenas nos tempos $\{0, 1, 2, \dots, 14\}$.


Convenção: Um fluxo é descrito por uma função $R(t)$ crescente com tempo contínuo, salvo indicação em contrário, considera-se os seguintes tipos de modelos:

1. Tempo discreto: $t \in \mathbb{N} = 0, 1, 2, 3, \dots$;
2. Modelo fluido: $t \in \mathbb{R}^+ = [0, +\infty)$ e R é uma função contínua;
3. Modelo de tempo contínuo geral: $t \in \mathbb{R}^+$ e R é uma função da esquerda ou da direita contínua.


Figura 64: Exemplos de funções de entradas e saídas (BOUDEEC; THIRAN, 2001)



(a)



(b)



(c)

Se for assumido que $R(t)$ tenha uma derivada $\frac{dR}{dt} = r(t)$ tal que $R(t) = \int_0^t r(s) ds$ (portanto, um modelo fluido), então r é chamado de função de taxa. Porém, verifica-se

que é muito mais simples considerar as funções acumuladas como R , em vez de funções de taxa. Ao contrário do que a álgebra convencional, com álgebra Min-Plus, não precisa de funções derivadas para ter as propriedades desejadas.

É sempre possível mapear uma função $R(t)$ para um modelo de tempo discreto $S(n)$, $n \in \mathbb{N}$ escolhendo um intervalo de tempo Δ e por amostragem:

$$S(n) = R(n\Delta) \quad (5.4)$$

Em geral, isso resulta em uma perda de informação. Para o mapeamento reverso, utiliza-se a seguinte convenção. Um modelo de tempo contínuo pode ser derivado de $S(n)$:

$$R'(t) = S\left(\left\lceil \frac{t}{\Delta} \right\rceil\right) \quad (5.5)$$

A função R' resultante é sempre contínua à esquerda e o mapeamento com $\Delta = 1$, $S = R_3$ e $R' = R_2$ é apresentado na Figura 64.

Com o mapeamento da equação 5.4, qualquer resultado de um modelo de tempo contínuo também se aplica a tempo discreto. Salvo disposição em contrário, todos os resultados aplicar-se-ão tanto para tempo contínuo quanto discreto. Modelos de tempo discretos são geralmente utilizados no contexto de modelos de pacotes fixos, em contraste, modelos de pacotes de tamanho variável são normalmente feitos com um modelo de tempo contínuo (não necessariamente fluido). Note que a modelagem de pacotes de tamanho variável requer alguns mecanismos específicos (BOUDEC; THIRAN, 2001).

5.1.2 Processo Envelope


Para oferecer garantias de QoS aos fluxos de dados é necessário suporte apropriado na rede (BOUDEC; THIRAN, 2001). Além disso, outro mecanismo possível de ser aplicado é limitar o tráfego enviado pelas fontes. Com as redes de serviços integrados (*IntServ*), isto é feito usando o conceito de Processo Envelope (MAO; PANWAR, 2006), ou Curva de Chegada, a seguir definido.

Dado uma função α definida para $t \geq 0$, diz-se que um fluxo R é limitado por α se todo $t \leq s$ (BOUDEC; THIRAN, 2001):

$$R(t) - R(s) \leq \alpha(t - s) \quad (5.6)$$

Pode se dizer que R tem α como uma curva de chegada, ou ainda que R é α -suave. Note que a condição máxima de sobreposição do conjunto de intervalos é ilustrada na Figura 65.

Figura 65: Exemplo de restrição por curva de chegada, demonstrando um efeito cumulativo da função $R(t)$ limitado pela curva de chegada $\alpha(t)$



Fonte: Junior e Vieira (2011)

No contexto de redes de pacotes de tamanho fixo, também se utiliza as curvas de chegada $kv_{T,\tau}$ onde $v_{T,\tau}$ é a função degrau definida por $t > 0$ para $v_{T,\tau}(t) = v_{T,0}(t + \tau)$ e 0 caso contrário. Nota-se que o $v_{T,\tau}(t) = v_{T,0}(t + \tau)$, portanto $v_{T,\tau}$ resulta de $v_{T,0}$ por uma mudança de tempo para a esquerda.

Os parâmetros T (o intervalo) e τ (a tolerância) são expressos em unidades de tempo. A fim de compreender o uso de $v_{T,\tau}$, considera-se um fluxo contendo pacotes de tamanho fixo, igual a k unidades de dados. Supondo-se que os pacotes são espaçados em pelo menos T unidades de tempo, tem-se o fluxo com curva de chegada $kv_{T,0}$.

Supondo-se agora que o fluxo é multiplexado com alguns outros, uma maneira de pensar neste cenário é assumir que os pacotes são colocados em uma fila, junto com outros fluxos. Este é tipicamente o que ocorre em uma estação de trabalho e no sistema operacional. A fila impõe um retardo variável e supõe-se que pode ser limitado (o retardo) por um valor igual a τ unidades de tempo. Sendo $R(t)$ a função de entrada para o fluxo no multiplexador e $R^*(t)$ a função de saída, se $R^*(s) \leq R(s - \tau)$ é válida, tem-se:

$$R^*(t) - R^*(s) \leq R(t) - R(s - \tau) \leq kv_{T,0}(t - s + \tau) = kv_{T,\tau}(t - s) \quad (5.7)$$

Assim R^* tem $kv_{T,\tau}$ como uma curva de chegada para um fluxo periódico, com período T e pacotes de tamanho k constante que apresentem um retardo variável $\leq \tau$, com $kv_{T,\tau}$ como curva de chegada. O parâmetro τ é frequentemente chamado de célula pontual de variação de retardo, pois corresponde a um desvio do fluxo periódico que pode ser observado em um ponto (BOUDEC; THIRAN, 2001).

Processos envelopes também são definidos na literatura através de modelos fractais, como o fBm (*fractional Brownian motion*) e o mBm (*multifractional Brownian motion*).

Um processo envelope $A(t)$ baseado no modelo de tráfego de pacotes fBm descreve com precisão fluxos de tráfego através da média (λ), desvio padrão (σ) e parâmetro de Hurst (H) (TAKADA; ANZALONI, 2006):

$$A(t) = \lambda t + k\sigma t^H \quad (5.8)$$

onde k é uma constante relacionada à probabilidade de violação do processo envelope (ϵ), calculada por $k = \sqrt{-2 \ln \epsilon}$.

Por outro lado, um processo envelope $A(t)$ baseado no modelo de tráfego de pacotes mBm descreve fluxos de tráfego através da média (λ), desvio padrão (σ) e expoente de Hölder (H) (TAKADA; ANZALONI, 2006):

$$A(t) = \lambda t + k\sigma \int_0^t H(x)x^{H(x)-1} dx \quad (5.9)$$

5.1.3 Curvas de Serviço

São consideradas as chegadas de tráfego em um único nó de uma rede. As chegadas de um fluxo no intervalo de tempo $[0, t)$ são dadas em termos da função $A(t)$. As saídas de um fluxo a partir do nó, no intervalo de tempo $[0, t)$, são denotadas por $D(t)$ com $D(t) \leq A(t)$.

Seja a convolução denotada por $*$ e a deconvolução é por $\otimes$ (BOUDEK; THIRAN, 2001).

Uma curva mínima de serviço para um fluxo é uma função S que especifica um limite inferior para o serviço prestado ao fluxo de tal forma que, para todo $t \geq 0$,

$$D(t) \geq A * S(t) \quad (5.10)$$

Uma curva de serviço máxima para um fluxo é uma função $\bar{S}$ que especifica um limite superior sobre o serviço prestado a um fluxo tal que, para todo $t \geq 0$,

$$D(t) \leq A * \bar{S}(t) \quad (5.11)$$

A curva de serviço mínima desempenha um importante papel no Cálculo de Rede, uma vez que ela provê garantias de serviço. Portanto, assim como ocorre na literatura relacionada, muitas vezes a curva mínima de serviço é denominada apenas como curva de serviço. Se nenhuma curva máxima de serviço é fornecida explicitamente, pode-se usar $\bar{S}(t) = Ct$, onde C é a capacidade do enlace para aproximar a curva de serviço real da rede (BURCHARD; LIEBEHERR; PATEK, 2001).

5.2 Probabilidade de Transbordo do *Buffer* Utilizando Processo Envelope

Nesta seção, é obtida uma equação para estimação da probabilidade de transbordo do *buffer* de um usuário com base no processo envelope do tráfego e na curva de serviço do sistema. A equação obtida pode ser utilizada para diferentes sistemas de transmissão, uma vez determinada a curva de serviço do sistema correspondente. Na seção seguinte, mostra-se a aplicação desta equação ao sistema OFDM-TDMA.

Proposição 1: Seja $E[K_r]$ a média do tráfego real de entrada agregado numa escala de tempo r , X o tamanho do *buffer* do usuário e $S(t)$ a sua curva de serviço, a probabilidade de transbordo do *buffer* do usuário em questão é dada por:

$$P_{transb} = \min_{\forall r} \frac{E[K_r]}{X + S(r)}$$

Proposição 2: Assumindo que o processo envelope do tráfego acumulado é descrito pelo processo envelope do modelo *fBm* (*fractional Brownian motion*) e considerando que λ e σ sejam a média e o desvio padrão do tráfego de entrada do usuário, respectivamente, a probabilidade de transbordo do *buffer* é dada por:

$$P_{transb} = \min_{\forall r} \frac{\lambda r + k\sigma r^H}{X + S(r)}$$

Prova:

Considere um sistema de fila única com um servidor com taxa de atendimento $s(t)$ e um *buffer* de comprimento X . A quantidade de tráfego que pode ser transmitida em um intervalo de tempo $[0, t)$, também chamada de curva de serviço, é, então, determinada por:

$$S(t) = \sum_{\tau=0}^{t-1} s(\tau) \quad (5.12)$$

Seja $A(t)$ a quantidade total de trabalho (pacotes) acumulado que chega ao *buffer* no intervalo $[0, t)$, a fila de pacotes formada, ou a quantidade total de tráfego armazenado no *buffer* no intervalo $[0, t)$, será dada por:

$$Q(t) = A(t) - S(t) \quad (5.13)$$

Agora seja W uma variável aleatória não negativa e w um possível valor de W . A

inequação de Markov estabelece que (PAPOULIS; PILLAI, 2002):

$$P\{W \geq w\} \leq \frac{E[W]}{w} \quad (5.14)$$

Sendo K_r o processo estocástico que define a série de tráfego agregada na escala de tempo r , pode-se escrever:

$$P\{K_r \geq X + S(r)\} \leq \frac{E[K_r]}{X + S(r)} \quad (5.15)$$

Observe que o processo K_r define a função $A(r)$.

A partir de simulações, constatou-se que, geralmente, $P\{K_r \geq X + S(r)\}$ é próximo de $\frac{E[K_r]}{X + S(r)}$ na escala r que gera o menor valor de $\frac{E[K_r]}{X + S(r)}$. Portanto, pode-se escrever:

$$P\{K_r - S(r) \geq X\} \approx \min_{\forall r} \frac{E[K_r]}{X + S(r)} \quad (5.16)$$

Dessa forma, a probabilidade de transbordo pode ser escrita como:

$$P_{transb} = P\{Q > X\} = \min_{\forall r} \frac{E[K_r]}{X + S(r)} \quad (5.17)$$

A esperança matemática do tráfego agregado ($E[K_r]$) pode ser obtida por meio de um processo envelope. Um processo envelope nada mais é que um limitante superior para o processo real de tráfego de pacotes acumulado e, portanto, seria uma estimativa de $A(t)$.

Partindo do modelo *fBm* (*fractional Brownian motion*), uma aproximação para o processo envelope de fluxos de tráfego real pode ser obtida pela seguinte equação (MAYOR; SILVESTER, 1997) (JUNIOR; VIEIRA, 2011):

$$\hat{A}(t) = \lambda t + k\sigma t^H \quad (5.18)$$

onde λ e σ são a média e o desvio padrão do tráfego de entrada, respectivamente; k é uma constante relacionada à probabilidade de violação do processo envelope (ϵ), calculada por $k = \sqrt{-2 \ln \epsilon}$, e H é o parâmetro de Hurst, que mede a autossimilaridade do processo de tráfego de entrada.

Dessa forma, $E[K_r] \approx \hat{A}(r)$, e a probabilidade de transbordo pode ser encontrada por:

$$P_{transb} = \min_{\forall r} \frac{\lambda r + k\sigma r^H}{X + S(r)} \quad (5.19)$$

5.3 Curva de Serviço Aplicada ao Cálculo da Probabilidade de Transbordo em Sistemas OFDM-TDMA

Deseja-se adequar a equação 5.19 para determinar a probabilidade de transbordo do *buffer* de um usuário no mesmo sistema OFDM-TDMA definido na seção 4.1. Para isso, é necessário determinar a curva de serviço do usuário nesse sistema.


Proposição 3: A curva de serviço de um usuário de um sistema OFDM-TDMA com escalonamento *round-robin* onde cada usuário é servido pelo mesmo intervalo de tempo T é dada por:

$$S_n(t) = cTP + cT \min \left\{ \frac{\max [t - PNT - (n - 1)T; 0]}{T}; 1 \right\}$$

Prova:

Assumindo que o sistema OFDM-TDMA descrito possua 4 usuários, a curva de serviço do usuário 1 (o primeiro a ser atendido, em $t = 0$) pode ser visualizada na Figura 66.

Figura 66: Curva de serviço do usuário 1



A ilustração mostra dois ciclos do escalonamento *round-robin*. Pode-se observar claramente que, nos primeiros T segundos de cada ciclo, o usuário 1 é atendido, enquanto, nos $3T$ segundos restantes, ele aguarda.

Assume-se que o coeficiente angular da reta que vai de $t = 0$ até $t = T$ seja dado por c , a média da taxa de atendimento no servidor do sistema OFDM-TDMA.

$$c = \sum_{r=0}^R r [\mathbf{R}_n]_{r+1} \quad (5.20)$$

Dessa forma, a curva de serviço do usuário 1 pode ser calculada como a soma do tráfego transmitido nos ciclos completos e do tráfego já transmitido no ciclo atual.

$$S_1(t) = S_{1C}(t) + S_{1A}(t) \quad (5.21)$$

O número de ciclos completos é dado por $P = \lfloor \frac{t}{NT} \rfloor$. Assim, o tráfego transmitido nos ciclos já completados é calculado por:

$$S_{1C}(t) = cTP \quad (5.22)$$

O tráfego transmitido no ciclo atual, por sua vez, é calculado por:

$$S_{1A}(t) = cT \min \left(\frac{t - PNT}{T}; 1 \right) \quad (5.23)$$

Logo, a curva de serviço do usuário 1 é dada por:

$$S_1(t) = cTP + cT \min \left(\frac{t - PNT}{T}; 1 \right) \quad (5.24)$$

O que pode ser generalizado para qualquer usuário como:

$$S_n(t) = cTP + cT \min \left\{ \frac{\max [t - PNT - (n - 1)T; 0]}{T}; 1 \right\} \quad (5.25)$$

Portanto, a probabilidade de transbordo do *buffer* de um usuário n no sistema OFDM-TDMA pode ser aproximada pelas equações 5.26 e 5.27, com base no processo envelope real e no processo envelope do modelo fBm, respectivamente.


$$P_{transb_n} = \min_{\forall r} \frac{E[K_r]}{X + S_n(r)} \quad (5.26)$$

$$P_{transb_n} = \min_{\forall r} \frac{\lambda r + k\sigma r^H}{X + S_n(r)} \quad (5.27)$$

5.4 Simulações e Resultados

Considerou-se o Cenário 1 descrito na seção 3.11 para o sistema OFDM-TDMA ($M = 512$, $N = 5$, $B = 20,0$ MHz, $P_{ber} = 10^{-6}$, $C = 6$, $T = 20$ ms e $L = 59$ bytes), sendo que um usuário é servido por apenas um *frame* por ciclo do escalonamento *round-robin* e fixando a SNR em 14 dB. A Figura 67 compara as curvas de serviço obtidas através da equação 5.25 e através de simulação.

Figura 67: Curva de serviço do usuário 1 no cenário considerado do sistema OFDM-TDMA




Com base nas equações 5.26 e 5.27, a Figura 68 apresenta a relação da probabilidade de transbordo do *buffer* do usuário com o aumento do tamanho deste, considerando as mesmas circunstâncias assumidas na seção 4.5, onde o tráfego dos usuários é modelado a partir de chamadas VoIP. A Figura 68 ainda mostra estimativas de probabilidade de transbordo obtidas com a equação 4.21 e com o método MSQ (*MultiScale Queueing*). O MSQ, bastante difundido em outros trabalhos, parte da análise multiescala do tráfego de entrada e considera que este seja descrito pelo modelo *MWM* (*Multifractal Wavelet Model*) (RIBEIRO et al., 2000).

Observa-se que a estimativa obtida com a equação 4.21 se aproxima bastante da simulação, porém o custo computacional para encontrá-la é significativamente elevado. Por outro lado os resultados das equações 5.26 e 5.27 se aproximam consideravelmente da probabilidade de transbordo real mantendo uma relativa simplicidade na obtenção das estimativas e possibilitando sua utilização para mensuração em tempo real.

Conforme a Tabela 7 e as Figuras 69 a 73, diferentes cenários são considerados para validar a eficiência das equações 5.26 e 5.27. Em cada cenário o perfil de tráfego do usuário é definido a partir de uma série distinta, como discriminado na tabela. As séries levadas em conta foram criadas a partir da coleta de amostras reais de tráfego de redes TCP/IP (WRL, 1995).

Os experimentos realizados para cada cenário demonstram coerência nos resulta-

Figura 68: Probabilidade de transbordo do *buffer* do usuário no cenário considerado do sistema OFDM-TDMA



dos obtidos para a probabilidade de transbordo do *buffer*. As estimativas calculadas se apresentaram muito próximas dos valores reais. Os resultados, portanto, validam a eficiência das equações 5.26 e 5.27 tornando-as opções facilmente aplicáveis e rápidas para medir a qualidade de serviço no sistema OFDM-TDMA.

A equação 5.26 faz uso do processo envelope real, obtido a partir da série do tráfego considerado, e, por isso, se aproxima mais da probabilidade de transbordo real. No entanto, a estimativa do processo envelope real em inúmeras escalas, como exigido pela equação, pode afetar no tempo demandado para cálculo da probabilidade de transbordo. Ao se considerar o modelo fBm, a equação 5.27 utiliza uma estimativa relevante do processo envelope e simplifica o cálculo significativamente mantendo resultados satisfatórios.

As estimativas obtidas com a equação 4.21 se mostraram ligeiramente mais próximas dos valores reais. Mas, apesar de o modelo baseado em Cadeias de Markov possibilitar a estimação de alguns parâmetros de QoS além da probabilidade de transbordo, sua aplicação é limitada devido à complexidade computacional envolvida. A probabilidade de transbordo é uma medida que expressa bem a qualidade de serviço, o que torna as equações 5.26 e, principalmente, 5.27 muito úteis em aplicações que exigem rápido processamento.

Tabela 7: Cenários do sistema OFDM-TDMA considerados

Cenário	1	2	3	4	5
Figura	69	70	71	72	73
Série	<i>dec-pkt-1</i>	<i>new-zealand-isp</i>	<i>lbl-pkt-4</i>	<i>lbl-pkt-5</i>	<i>lbl-pkt-5</i>
T (ms)	512	10	100	100	512
N	5	5	5	5	5
M	512	512	256	256	256
B (MHz)	8	100	2,5	1,7	1,6
P	10^{-6}	10^{-6}	10^{-6}	10^{-6}	10^{-6}
C (bits/sím)	5	6	5	5	5

Figura 69: Probabilidade de transbordo do *buffer* no Cenário 1




Figura 70: Probabilidade de transbordo do *buffer* no Cenário 2




Figura 71: Probabilidade de transbordo do *buffer* no Cenário 3




Figura 72: Probabilidade de transbordo do *buffer* no Cenário 4





Figura 73: Probabilidade de transbordo do *buffer* no Cenário 5



Conclusões

A modulação OFDM é uma técnica de multiplexação amplamente difundida nos sistemas de comunicações sem fio atuais. É caracterizada por sua alta resistência contra interferências intersimbólicas e de multipercurso, além da elevada eficiência espectral.

Este trabalho estuda o sistema de transmissão OFDM-TDMA e propõe um modelo baseado em Teoria de Filas para descrever o comportamento da fila do usuário. Para isto, foram estabelecidos modelos para a taxa de transmissão do sistema e a taxa de chegada de pacotes do usuário. O primeiro foi implementado levando em conta um canal com desvanecimento Rayleigh e considera o uso de Modulação e Codificação Adaptativa, assumindo que a informação de qualidade do canal (SNR) está disponível ao transmitir cada *frame*. O segundo modelo foi definido a partir da aplicação de técnicas de estimação do comportamento de processos de chegada de pacotes em regime permanente, como o método de Kernel e o MMFM.

Os trabalhos que estudam o comportamento da fila do usuário em sistemas OFDM desenvolvidos até então modelam a chegada de tráfego do usuário como um processo poissoniano. No entanto, o tráfego real muitas vezes não segue o comportamento definido pelo modelo de Poisson. O presente trabalho emprega o método de Kernel e o MMFM na modelagem do processo de chegada de tráfego, o que resulta em modelos mais aproximados dos sistemas reais.

Por meio do uso de Cadeias de Markov, foi possível descrever o comportamento da fila do usuário em estado estacionário, conhecendo a probabilidade da fila se encontrar em cada estado possível. A partir dessas probabilidades, foram definidos alguns indicadores úteis na análise do desempenho dos sistemas em questão: o número médio de pacotes na fila formada para transmissão, o atraso médio no envio de um pacote e a probabilidade de que haja transbordo no *buffer* do usuário.

Os indicadores obtidos foram testados por meio de simulações do sistema OFDM-TDMA. Os resultados são relatados na seção 4.5 deste trabalho. Verificou-se que o modelo é aprimorado com o uso do método de Kernel e do MMFM. As estimativas obtidas para os parâmetros de QoS foram bastante próximas dos resultados das simulações, confirmando a eficiência do algoritmo proposto.

Apesar do modelo ser preciso em descrever o comportamento do sistema, o esforço computacional exigido no cálculo das estimativas pode ser alto. A construção da matriz de transição da Cadeia de Markov e sua posterior solução no estado estacionário demandam

muitos recursos computacionais, dada a complexidade do cálculo matricial envolvido. Essa demanda impossibilita, nas circunstâncias atuais, a adaptação do modelo em tempo real tornando-o rígido perante a natureza não-estacionária do processo de chegada de tráfego. Uma forma de contornar esse problema seria determinar, de antemão, modelos para um conjunto de perfis de tráfego e, utilizando alguma técnica adaptativa para reconhecimento de padrões, encontrar o modelo mais apropriado para o perfil de tráfego corrente.

Uma outra abordagem para análise de desempenho do mesmo sistema foi desenvolvida. Esta consiste na estimação da probabilidade de transbordo do *buffer* do usuário do sistema OFDM-TDMA através de uma equação que leva em consideração o processo envelope fractal do tráfego de entrada e sobre a curva de serviço do sistema. Dessa maneira, foi possível embutir ao modelo formas precisas de descrever o processo de tráfego do usuário e o canal de transmissão do sistema.

Como foi visto na seção 5.4, a equação obtida provê resultados bastante satisfatórios. As estimativas de probabilidade de transbordo encontradas, comparadas com resultados de outros modelos, se aproximaram consideravelmente das probabilidades de transbordo obtidas com simulações, o que corrobora para a eficiência da equação apresentada. Observa-se que o modelo baseado em Cadeias de Markov fornece resultados mais próximos dos reais, proporcionando uma análise de desempenho do sistema bastante eficaz, porém, a custo muito elevado. A equação 5.27, no entanto, fornece resultados com prejuízo pequeno de precisão mas a muito baixo custo computacional, possibilitando até seu uso para análise de desempenho do sistema em tempo real.

Possíveis trabalhos futuros envolvem a evolução do modelo aqui desenvolvido buscando agregar mais detalhes dos sistemas reais, como prioridade de usuários e controle de admissão, além da adaptação do modelo para padrões específicos, como o LTE e o WiMAX, tornando-o específico e, portanto, mais apropriado para análise desses sistemas.

Referências

- 3GPP. *Evolved Universal Terrestrial Radio Access (E-UTRA) and Evolved Universal Terrestrial Radio Access Network (E-UTRAN); Overall description*. Valbonne, FR, 2013. 22, 24
- AGRAWAL, R. et al. Performance bounds for flow control protocols. *IEEE/ACM Transactions on Networking*, 1999. v. 7, n. 3, p. 310–323, jun 1999. 99
- BATISTA, C. A. Métodos emergentes de física-estatística aplicados a séries temporais. *Universidade Federal Rural de Pernambuco*, 2006. feb 2006. 47
- BIANCHI, G. R. *Um modelo multifractal aplicado à predição de tráfego de redes-proposta e avaliação*. Campinas, SP, BR: [s.n.], 2005. 38
- BOSMAN, J. W.; MEI, R. D. V. der; NUNEZ-QUEIJA, R. A fluid model analysis of streaming media in the presence of time-varying bandwidth. In: *24th International Teletraffic Congress*. [S.l.: s.n.], 2012. p. 1–8. 22, 41
- BOTEV, Z. I.; GROTHOWSKI, J. F.; KROESE, D. P. Kernel density estimation via diffusion. *Annals of Statistics*, 2010. Institutue of Mathematical Statistics, v. 38, n. 5, p. 2916–2957, 2010. 41
- BOUCHTI, A. E.; KAFHALI, S. E.; HAQIQ, A. Queueing performance analysis of cac scheme in ofdma based wimax system. In: *Next Generation Networks and Services (NGNS), 2011 3rd International Conference on*. [S.l.: s.n.], 2011. p. 62–67. 23
- BOUDEC, J. Y. L. Application of network calculus to guaranteed service networks. *IEEE/ACM Transactions on Information Theory*, 1998. v. 44, n. 3, p. 1087–1097, may 1998. 99, 100
- BOUDEC, J. Y. L.; THIRAN, P. Network calculus: A theory of deterministic queueing systems for the internet. In: *Lecture Notes in Computer Science*. [S.l.]: Springer Verlag, 2001. 10, 100, 101, 102, 103, 104, 105
- BURCHARD, A.; LIEBEHERR, J.; PATEK, S. *A Calculus for End-to-end Statistical Service Guarantees*. [S.l.], 2001. 105
- CHEN, J.-C.; CHEN, W.-S. E. Call blocking probability and bandwidth utilization of ofdm subcarrier allocation in next-generation wireless networks. *Communications Letters, IEEE*, 2006. v. 10, n. 2, p. 82–84, feb. 2006. 23
- CHUI, C. K. An introduction to wavelets. *IEEE Computational Sciences and Engineering*, 1995. v. 2, n. 2, p. 50–61, 1995. 50
- CLEGG, R. G. A practical guide to measuring the hurst parameter. In: *21st UK Performance Engineering Workshop*. [S.l.: s.n.], 2005. 45, 46, 47

- COLERI, S. et al. Channel estimation techniques based on pilot arrangement in ofdm systems. *Broadcasting, IEEE Transactions on*, 2002. v. 48, n. 3, p. 223 – 229, sep 2002. 65
- COSTA, V. H. T. et al. Estimação do tempo médio de resposta do servidor em plataformas de ensino a distância do tipo cliente-servidor utilizando modelo baseado em teoria de filas. In: *X Encontro Anual de Computação*. [S.l.: s.n.], 2013.
- COSTA, V. H. T.; JÚNIOR, G. A. de D. Sistemas de comunicações sem fio: Lte. In: *III Seminário de Pesquisa – IX Conpeex: Congresso de Pesquisa, Ensino e Extensão – UFG*. [S.l.: s.n.], 2012.
- COSTA, V. H. T.; VIEIRA, F. H. T.; SOUZA, G. B. de C. Performance modeling and analysis of ofdm/tdma-based wireless systems based on queueing theory. In: *International Workshop on Telecommunications*. [S.l.: s.n.], 2013.
- CPQD. Sistema brasileiro de televisão digital terrestre – arquitetura de referência. 2006. feb 2006. 24
- CROVELLA, M. E.; BESTAVROS, A. Self-similarity in world wide web traffic - evidence and possible causes. In: *ACM Sigmetrics*. [S.l.: s.n.], 1996. p. 160–169. 37
- CRUZ, R. L. A calculus for network delay, part i: Network elements in isolation. *IEEE Transaction of Information Theory*, 1991. v. 37, n. 1, p. 114–121, jan 1991. 99
- CRUZ, R. L. A calculus for network delay, part ii: Network analysis. *IEEE Transaction of Information Theory*, 1991. v. 37, n. 1, p. 132–141, jan 1991. 99
- CRUZ, R. L. Quality of service guarantees in virtual circuit switched networks. *IEEE Journal on Selected Areas in Communications*, 1995. v. 13, n. 6, p. 1048–1056, aug 1995. 99
- ERRAMILI, A.; NARAYAN, O.; WILLINGER, W. Experimental queueing analysis with long-range dependent traffic). *IEEE Transactions Networking*, 1996. v. 4, n. 2, p. 209–222, 1996. 38
- FELDMANN, A.; GILBERT, A.; WILLINGER, W. Data networks as cascades: Explaining the multifractal nature of internet wan traffic. In: *ACM Sigcomm*. [S.l.: s.n.], 1998. p. 42–55. 38
- GONÇALVES, B. H. P.; VIEIRA, F. H. T.; COSTA, V. H. T. Modelagem multifractal betamwm adaptativa para tráfego de redes de computadores. In: *X Encontro Anual de Computação*. [S.l.: s.n.], 2013.
- GUÉVEL, R. L.; VÉHEL, J. L. *Incremental moments and Hölder exponents of multifractional multistable processes*. 2010. Disponível em: <<http://alumni.cs.ucr.edu/~tkarag/Selfis/Selfis.html>>. 48
- HOCK, N. C.; HEE, S. B. *Queueing Modelling Fundamentals: With Applications in Communication Networks*. 2nd. ed. [S.l.: s.n.], 2008. 39
- IEEE. *IEEE Standard for Local and Metropolitan Area Networks – Part 16: Air Interface for Fixed Broadband Wireless Access Systems*. New York, NY, USA, 2004. 22, 24

- IEEE. *Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications*. New York, NY, 2012. 22
- JUNIOR, J. A. dos S.; VIEIRA, F. H. T. *Algoritmo de Policiamento de Tráfego para Redes OFDM-TDMA WiMAX Baseado em Modelagem Multifractal e Cálculo de Rede*. Dissertação (Mestrado) — Escola de Engenharia Elétrica e de Computação – Universidade Federal de Goiás, Goiânia, GO, BR, 2011. 104, 107
- KARAGIANNIS, T. *The Selfis Tool (Versão 0.1b)*. Copyright © University Of California, Riverside. 2010. Disponível em: <<http://alumni.cs.ucr.edu/~tkarag/Selfis/Selfis.html>>. 46
- KLEINROCK, L. *Queueing systems: Theory*. New York, NY, USA: John Wiley, 1975. 37
- LAUWERIER, H. *Fractals: Endlessly Repeated Geometric Figures*. Princeton, NJ: Princeton University Press, 1991. 8, 46
- LEEUWAARDEN, J.; SQUILLANTE, M.; WINANDS, E. Quasi-birth-and-death processes, lattice path counting, and hypergeometric functions. *Journal of Applied Probability*, 2009. v. 46, n. 2, p. 507–520, jun 2009. 68
- LELAND, W. E. et al. On the self similar nature of ethernet traffic (extended version). *IEEE/ACM Transactions on Networking*, 1994. v. 2, n. 1, p. 1–15, feb 1994. 37
- MANDELBROT, B. B.; NESS, J. W. V. Fractional brownian motions, fractional noises and applications. *SIAM Review*, 1968. v. 10, n. 4, p. 422–437, oct 1968. 44
- MAO, S.; PANWAR, S. S. A survey of envelope process an their applications in quality of service provisioning. *IEEE Communications*, 2006. v. 8, n. 3, p. 2–20, 2006. 103
- MAYOR, G.; SILVESTER, J. Time scale analysis of an atm queueing system with long-range dependent traffic. In: *Sixteenth Annual Joint Conference of the IEEE Computer and Communications Societies*. [S.l.: s.n.], 1997. p. 205–2012. 23, 107
- MELO, C. A. V.; FONSECA, N. L. S. An envelope process for multifractal traffic modeling. In: *IEEE ICC*. [S.l.: s.n.], 2004. 48
- MISHURA, Y. Stochastic calculus for fractional brownian motion and related processes. In: *Lecture Notes in Mathematics*. [S.l.]: Springer, 2008. v. 1929, p. 398. 45
- NIYATO, D.; HOSSAIN, E. Queueing analysis of ofdm/tdma systems. In: *Global Telecommunications Conference, 2005. GLOBECOM '05. IEEE*. [S.l.: s.n.], 2005. v. 6, p. 5 pp. 3712–3716. 22, 31, 64, 70, 73
- OLIVEIRA, L. C. B.; MENDES, E. A. *Estudo da teoria do caos e dos fractais, e dos sistemas complexos e suas possíveis aplicações em Matemática*. São Paulo, SP, BR: Exacta, 2006. 99-101 p. 45
- PAPOULIS, A.; PILLAI, S. *Probability, random variables, and stochastic processes*. [S.l.]: McGraw-Hill, 2002. (McGraw-Hill electrical and electronic engineering series). 33, 35, 107
- PARK, K.; WILLINGER, W. *Self-similar Network Traffic and Performance Evaluation*. New York, NY, USA: John Wiley and Sons, 2000. 37, 47

- PAXSON, V.; FLOYD, S. Wide area traffic: the failure of poisson modeling. *Networking, IEEE/ACM Transactions on*, 1995. v. 3, n. 3, p. 226–244, jun 1995. 23, 37, 52, 56
- PELTIER, R. F.; VEHEL, J. L. *Multifractional Brownian motion: definition and preliminary results*. [S.l.], 1995. 45, 47, 48
- PRASAD, R. *Ofdm for Wireless Communications Systems*. [S.l.]: Artech House, 2004. (Artech House universal personal communications series). 21, 24
- QIU, X.; CHAWLA, K. On the performance of adaptive modulation in cellular systems. *Communications, IEEE Transactions on*, 1999. v. 47, n. 6, p. 884–895, jun 1999. 66
- RAO, B. L. S. P. *Statistical Inference for Fractional Diffusion Processes*. India: John Wiley and Sons, 2010. (Wiley series in probability and statistics). 45
- RAPPAPORT, T. *Wireless Communications: Principles and Practice*. 2nd. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 2001. 21
- RIBEIRO, V. J. et al. Multiscale queueing analysis of long-range dependent traffic. In: *IEEE INFOCOM*. Tel Aviv, Israel: [s.n.], 2000. p. 1026–1035. 51, 110
- RIEDI, R. H. et al. Multifractal wavelet model with application to network traffic. *IEEE Transactions on Information Theory*, 1999. v. 45, n. 3, apr 1999. 50, 51
- RIEDI, R. H.; VÉHEL, J. L. Tcp traffic is multifractal: A numerical study. In: *INRIA Research Report*. [S.l.: s.n.], 1997. 38
- ROCHA, F. G. C.; SANTOS, C. B.; VIEIRA, F. H. T. Traffic modeling in plc networks using a markov fluid model with autocorrelation function fitting. *TEMA – Trends in Applied and Computational Mathematics*, 2011. v. 12, n. 3, p. 233–243, 2011. 22, 42
- SILVERMAN, B. *Density Estimation for Statistics and Data Analysis*. [S.l.]: Chapman and Hall, 1986. (Monographs on Statistics and Applied Probability). 40
- SOTTINEN, T.; VALKEILA, E. Fractional brownian motion as a model in finance. *University of Helsinki, Department of Mathematics*, 2001. p. 16, 2001. 44
- SOUSA, M. A. de et al. Sistema de apoio à decisão milp-fuzzy para o planejamento de redes de acesso em telecomunicações. In: *Metaheurísticas em Pesquisa Operacional*. [S.l.]: Omnipax, 2012.
- TAKADA, H. H.; ANZALONI, A. A multifractal traffic policing mechanism. *IEEE Communications Letters*, 2006. v. 10, n. 2, p. 120–122, fev 2006. 105
- TAROKH, V. *New Directions in Wireless Communications Research*. [S.l.]: Springer, 2009. 22, 30
- VASQUES, T. L. V. et al. Modelo baseado em cadeias de markov para estimação de vazão em redes plc homeplug. In: *MOMAG 2012*. [S.l.: s.n.], 2012.
- VIEIRA, F. H. T.; COSTA, V. H. T.; GONÇALVES, B. H. P. Neural network based approaches for network traffic prediction. In: *Artificial Intelligence, Evolutionary Computing and Metaheuristics*. [S.l.]: Springer Berlin Heidelberg, 2013, (Studies in Computational Intelligence, v. 427). p. 657–684.

- VIEIRA, F. H. T.; JÚNIOR, J. A. S.; COSTA, V. H. T. Aplicação de cálculo de rede para estimação de retardo e tamanho médio da fila em sistemas ofdm/tdma com policiamento de tráfego. In: *MOMAG 2012*. [S.l.: s.n.], 2012.
- VIEIRA, F. H. T.; LEE, L. L. Multifractal traffic modeling using a multiplicative cascade with generalized multiplier distributions. In: *IEEE International Conference on Communications*. [S.l.: s.n.], 2006. p. 509–514. 37, 38, 51
- VIEIRA, F. H. T.; LEE, L. L. Adaptive wavelet-based multifractal model applied to the effective bandwidth estimation of network traffic flows. *IET Communications*, 2009. v. 3, p. 906–919, 2009. 23, 51
- VIEIRA, F. H. T.; LING, L. L. Limitantes de desempenho de fila para tráfego multifractal de redes. *Infocomp*, 2007. v. 6, n. 4, p. 100–109, 2007. 47
- VIEIRA, F. H. T.; LING, L. L. Modelagem de tráfego de redes utilizando cascata multifractal generalizada. *Revista de Informática Teórica e Aplicada*, 2008. v. 15, n. 2, p. 87–104, 2008. 8, 47, 49, 51
- WAND. *WITS: Waikato Internet Traffic Storage – ISPD SL-II*. WAND Network Research Group. 2010. Disponível em: <<http://wand.net.nz/wits/ispsl/2/>>. 52
- WEBB, A. R.; COPSEY, K. D. Density estimation – nonparametric. In: _____. *Statistical Pattern Recognition*. 3rd. ed. [S.l.]: John Wiley & Sons, Ltd, 2011. p. 150–220. ISBN 9781119952954. 22, 57
- WIERSEMA, U. F. *Brownian Motion Calculus*. New York, NY, USA: John Wiley and Sons, 2008. 44
- WILLINGER, W. et al. Self-similarity in high-speed packet traffic: Analysis of modeling of ethernet traffic measurements. *Statistical Science*, 1995. n. 1, p. 71–86, dec 1995. 45
- WRL. *The Internet Traffic Archive: Hour-long Traces of Wide-Area Traffic from Digital Equipment Corporation, by Western Research Lab*. 1995. Disponível em: <<http://ita.ee.lbl.gov/html/traces.html>>. 52, 110
- WUNDER, G.; ZHOU, C. Queueing analysis for the ofdma downlink: Throughput regions, delay and exponential backlog bounds. *Wireless Communications, IEEE Transactions on*, 2009. v. 8, n. 2, p. 871–881, feb. 2009. 23