

Alisson Assis Cardoso

**Alocação Adaptativa de Banda e Controle de
Fluxos de Tráfego de Redes Utilizando Sistemas
Fuzzy e Modelagem Multifractal**

Goiânia

Junho, 2014

Alisson Assis Cardoso

Alocação Adaptativa de Banda e Controle de Fluxos de Tráfego de Redes Utilizando Sistemas Fuzzy e Modelagem Multifractal

Dissertação de mestrado apresentada ao programa de Mestrado em Engenharia Elétrica e Computação da Universidade Federal de Goiás como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica e Computação.

Universidade Federal de Goiás – UFG

Escola de Engenharia Elétrica, Mecânica e de Computação – EMC

Programa de Pós-Graduação

Orientador: Flávio Henrique Teles Vieira

Goiânia

Junho, 2014

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

C268a Cardoso, Alisson Assis.
Alocação adaptativa de banda e controle de fluxos de
tráfego de redes utilizando sistemas fuzzy e modelagem
multifractal [manuscrito] / Álisson Assis Cardoso. - 2014.
xv, 133 f. : il., figs, tabs.

Orientador: Prof. Dr. Flávio Henrique Teles Vieira
Dissertação (Mestrado) – Universidade Federal de Goiás,
Escola de Engenharia Elétrica, Mecânica e Computação,
2014.

Bibliografia.

Inclui lista de figuras, abreviaturas, siglas e tabelas.

Apêndices.

1. Algoritmos 2. Modelagem Fuzzy 3. Tráfego de Rede -
Avaliação. I. Título.

CDU – 004.421:510.54



FOLHA DE APROVAÇÃO

"Alocação Adaptativa de Banda e Controle de Fluxos de Tráfego de Redes Utilizando Sistemas Fuzzy e Modelagem Multifractal"

ALISSON ASSIS CARDOSO

Dissertação defendida e aprovada pela banca examinadora constituída pelos senhores:

Flávio Henrique Teles Vieira – Orientador (EMC/UFG)

Cedric Luiz de Carvalho – INF/UFG

Leonardo da Cunha Brito – EMC/UFG

Marcos Antônio de Souza – EMC/UFG

Goiânia, 26 de junho de 2014

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 (a):		Alisson Assis Cardoso	
E-mail:		alsnac@gmail.com	
Seu e-mail pode ser disponibilizado na página? ☐ Sim ☒ Não			
Vínculo empregatício do autor			
Agência de fomento:		Coordenação de Aperfeiçoamento de Pessoal de Nível Superior	Sigla: CAPES
País:	Brasil	UF:	DF
		CNPJ:	00889834/0001-08
Título:	Alocação Adaptativa de Banda e Controle de Fluxos de Tráfego de Redes Utilizando Sistemas Fuzzy e Modelagem Multifractal		
Palavras-chave:	Análise Multifractal. Modelagem Fuzzy. Predição de Tráfego de Rede. Alocação de Banda. Controle de Tráfego de Rede. Funções de Base Ortonormal		
Título em outra língua:	Adaptive Bandwidth Allocation and Traffic Flow Control Using Fuzzy Systems and Multifractal Modeling		
Palavras-chave em outra língua:	Multifractal Analysis. Fuzzy Modeling. Network Traffic Prediction. Bandwidth Allocation. Traffic Flow Control. Orthonormal Basis Function		
Área de concentração:	Engenharia de Computação		
Data defesa: (dd/mm/aaaa)	26/06/2014		
Programa de Pós-Graduação:	Mestrado em Engenharia Elétrica e de Computação		
Orientador (a):	Prof. Dr. Flávio Henrique Teles Vieira		
E-mail:	flavio@eee.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 (a) autor (a)

Data: 20 / 08 / 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.

Agradecimentos

Ao meus pais, pelo incentivo, apoio e pelo carinho.

À minha esposa, pelo apoio e a compreensão do tempo dedicado ao mestrado.

À minha irmã e ao meu cunhado pelo incentivo para me esforçar cada vez mais.

À minha sobrinha Maria Augusta pela alegria e felicidade transmitida.

Ao meu orientador Prof. Dr. Flávio Henrique Teles Vieira por suas sábias orientações, conselhos e por sua infinita paciência.

À CAPES pelo apoio financeiro.

Resumo

Neste trabalho propomos um modelo *fuzzy*, nomeado Fuzzy LMS com Autocorrelação Multifractal, cujos pesos são calculados através de informações providas da análise multifractal de séries temporais. Esses pesos são encontrados incorporando uma expressão analítica para a função de autocorrelação de um modelo multifractal no algoritmo de treinamento do modelo *fuzzy* que tem como base o filtro de *Wiener-Hopf*. Avaliamos então o desempenho de predição de tráfego de redes do modelo *fuzzy* proposto adaptativo com relação a outros preditores. Em seguida, propomos um esquema de alocação de banda para tráfego de redes baseado no algoritmo Fuzzy LMS com Autocorrelação Multifractal. Comparações com outros esquemas de alocação de banda em termos de taxa de perda de *bytes*, utilização do enlace, ocupação do *buffer* e tamanho médio da fila comprovam a eficiência do algoritmo no esquema utilizado. Além disso, propomos um outro algoritmo *fuzzy* adaptativo para controle de fluxos de tráfego que podem ser descritos pelo modelo multifractal β MWM, que chamamos de Fuzzy-LMS-OBF com alfa adaptivo, o qual utiliza Funções de Bases Ortonormal (FBO) e tem como base de treinamento, o algoritmo LMS. Propomos também uma equação para cálculo da taxa ótima de controle derivada do modelo Fuzzy LMS. Em seguida, avaliamos o desempenho do algoritmo de controle adaptativo proposto com relação a outros métodos. Através de simulações, mostramos que os esquemas de controle e alocação de taxa se favorecem do desempenho dos algoritmos *fuzzy* adaptativos propostos. Comparações com outros métodos em termos de tamanho médio e variância da fila no *buffer*, Taxa de Utilização do enlace e Vazão são apresentadas.

Palavras-chaves: Análise Multifractal. Modelagem Fuzzy. Predição de Tráfego de Rede. Alocação de Banda. Controle de Tráfego de Rede. Funções de Base Ortonormal.

Abstract

In this paper we propose a fuzzy model, called Fuzzy LMS com Autocorrelação Multifractal, whose weights are updated according to information from multifractal traffic modeling. These weights are calculated by incorporating an analytical expression for the autocorrelation function of a multifractal model in the training algorithm of the fuzzy model that is based on the Wiener-Hopf filter. We evaluate the prediction performance of the proposed network traffic prediction algorithm with respect to other predictors. Further, we propose a bandwidth allocation scheme for network traffic based on the fuzzy prediction algorithm. Comparisons with other bandwidth allocation schemes in terms of byte loss rate, link utilization, buffer occupancy and average queue size verifies the efficiency of the proposed scheme. Also, We propose an other adaptive fuzzy algorithm, called Fuzzy-LMS-OBF com alfa adaptivo , for traffic flow control described by the β MWM model. The proposed algorithm uses Orthonormal Basis Functions (OBF) and its training based on the LMS algorithm. We also present an expression for the optimal traffic source rate derived from Fuzzy LMS. Then, we evaluate the performance of the Fuzzy-LMS-OBF com alfa adaptivo algorithm with respect to other methods. Through simulations, we show that the proposed control scheme is benefited from the superior performance of the proposed fuzzy algorithm. Comparisons with other methods in terms of mean and variance of the queue size in the buffer, Utilization rate of the link, Loss rate and Throughput are presented.

Key-words: Multifractal Analysis. Fuzzy Modeling. Network Traffic Prediction. Bandwidth Allocation. Traffic Flow Control. Orthonormal Basis Function.

Lista de ilustrações

Figura 1 – Processo de construção de uma cascata multiplicativa.	20
Figura 2 – Função escala $\phi_{j,k}(t)$ e <i>wavelet</i> de Haar $\psi_{j,k}(t)$	23
Figura 3 – Árvore Binária dos coeficientes de escala.	24
Figura 4 – Função de autocorrelação real e do modelo Multifractal para o tráfego de rede Waikato VIII 20111029-110001-1.	27
Figura 5 – Função de autocorrelação real e do modelo Multifractal para a série de tráfego de rede dec-pkt-2 agregada em 512ms.	27
Figura 6 – Função de escala dos tráfegos de rede dec-pkt-2 agregada em 512ms e Waikato VIII 20111029-110001-1 agregada em 10ms, 100ms e 512ms.	29
Figura 7 – Função de escala da série de tráfego de rede SNU20100315 agregada em 100ms.	29
Figura 8 – Função de escala da série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms.	30
Figura 9 – Função de escala da série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.	30
Figura 10 – Espectro Multifractal da série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 10ms, 100ms e 512ms.	32
Figura 11 – Espectro Multifractal da série de tráfego de rede SNU20100315 agregada em 100ms e da série sintética do modelo fBm com $H = 0.9752$	33
Figura 12 – Espectro Multifractal da série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms e da série sintética do modelo fBm com $H = 0.8892$	33
Figura 13 – Espectro Multifractal da série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms e da série sintética do modelo fBm com $H = 0.8895$	34
Figura 14 – Função Gaussiana [Adaptado de Ross (2009)].	40
Figura 15 – Sistema Fuzzy [Adaptado de Wang (1994)].	41
Figura 16 – Fuzzificador <i>Singleton</i> e Gaussiano.	43
Figura 17 – Defuzzificação por Centro Médio (Centróide).	44
Figura 18 – Predição utilizando filtro Adaptativo.	45
Figura 19 – Filtro Linear.	46
Figura 20 – Fluxograma do algoritmo Fuzzy LMS com Autocorrelação Multifractal.	58
Figura 21 – Algoritmo Levenberg-Marquardt para atualização de α para a série de tráfego de rede Waikato VIII 20111029-110001-1.	61
Figura 22 – Mean Square Error para a série de tráfego Waikato VIII 20111029-110001-1 agregada em 10ms e com $n = 12$ para todos algoritmos.	62

Figura 23 – Mean Square Error para a série de tráfego Waikato VIII 20111029-110001-1 agregada em 100ms e com $n = 12$ para todos algoritmos. . . .	63
Figura 24 – Mean Square Error para a série de tráfego Waikato VIII 20111029-110001-1 agregada em 512ms e com $n = 12$ para todos algoritmos. . . .	64
Figura 25 – QQ-plot para a predição da série de tráfego de rede Waikato VIII 20111029-110001-1 utilizando o algoritmo Fuzzy LMS com Autocorrelação Multifractal com $n = 12$	66
Figura 26 – Algoritmo Levenberg-Marquardt para atualização de α para a série de tráfego de rede dec-pkt-2 agregada em 512ms.	67
Figura 27 – Mean Square Error para a série de tráfego dec-pkt-2 agregada em 512ms e com $n = 12$ para todos algoritmos.	68
Figura 28 – QQ-plot para a predição da série de tráfego de rede dec-pkt-2 agregada em 512ms e com $n = 12$ para todos algoritmos.	69
Figura 29 – Taxa de perda dada em relação a ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1.	71
Figura 30 – Taxa de Perda dada em relação ao tamanho do <i>buffer</i> para a série de tráfego de rede Waikato VIII 20111029-110001-1.	72
Figura 31 – Utilização Média em relação a ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1.	73
Figura 32 – Tamanho médio da fila no <i>buffer</i> em relação à ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1.	74
Figura 33 – Taxa de Perda obtida em relação ao tamanho do <i>buffer</i> para a série de tráfego de rede dec-pkt-2 agregada em 512ms.	75
Figura 34 – Taxa de perda obtida em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms.	76
Figura 35 – Utilização Média do enlace dada em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms.	76
Figura 36 – Tamanho média da fila no <i>buffer</i> em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms.	77
Figura 37 – Modelo do Sistema de Controle de Congestionamento.	79
Figura 38 – Fluxograma do algoritmo Fuzzy-LMS-FBO com alfa adaptativo.	85
Figura 39 – Função de Höder, parâmetros n_j e α para o tráfego de rede WaikatoVIII-20111027-213205-5.	86
Figura 40 – Função de Hölder, parâmetros n_j e α para a série de tráfego de rede SNU20100315.	87
Figura 41 – Erro quadrático médio de predição para o tráfego de rede Waikato VIII-20111027-213205-5.	91
Figura 42 – Gráfico QQ-plot para a predição da série de tráfego de rede Waikato VIII-20111027-213205-5.	93

Figura 43 – Erro quadrático médio de predição para a série de tráfego de rede SNU20100315.	94
Figura 44 – QQ-plot para a predição do tráfego de rede SNU20100315 para o algoritmo Fuzzy-LMS-FBO com alfa adaptativo.	95
Figura 45 – Tamanho da fila no <i>buffer</i> para a série de tráfego Waikato VIII-20111027-213205-5 sem controle, método binário e o método proporcional.	97
Figura 46 – Tamanho da fila no <i>buffer</i> para a série de tráfego Waikato VIII-20111027-213205-5 e Waikato VIII 20110921-000000-0 utilizando algoritmo Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal.	97
Figura 47 – Tamanho da fila no <i>buffer</i> para a série de tráfego Waikato VIII-20111027-213205-5 e Waikato VIII 20110921-000000-0 utilizando os algoritmos Fuzzy-LMS-FBO's.	98
Figura 48 – Tráfego controlável depois da aplicação do controle fuzzy adaptativo.	99
Figura 49 – Comparação do tráfego controlável antes e depois do controle fuzzy adaptativo.	100
Figura 50 – Tamanho da fila no <i>buffer</i> para as séries de tráfego SNU20100315 e SNU20100317 sem controle, método binário e o método proporcional.	102
Figura 51 – Tamanho da fila no <i>buffer</i> para as séries de tráfego SNU20100315 e SNU20100317 utilizando os algoritmos Fuzzy-LMS-FBO's.	103
Figura 52 – Tamanho da fila no <i>buffer</i> para as séries de tráfego SNU20100315 e SNU20100317 utilizando algoritmo Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal.	103
Figura 53 – Tráfego controlável depois da aplicação do controle <i>fuzzy</i> adaptativo utilizando a série de tráfego de rede SNU20100315.	104
Figura 54 – Comparação do tráfego controlável antes e depois do controle fuzzy adaptativo utilizando o tráfego de rede SNU20100315.	105
Figura 55 – Fluxograma do algoritmo Fuzzy LMS Autocorrelação Multifractal β MWM.	116
Figura 56 – Fluxograma do algoritmo Fuzzy-LMS-FBO Levenberg–Marquardt.	117
Figura 57 – Erro Quadrático Médio de predição para a série de tráfego de rede SNU20100315 agregada em 100ms.	118
Figura 58 – Série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms.	121
Figura 59 – Histograma da série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms.	122
Figura 60 – Série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.	123
Figura 61 – Histograma da série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.	124
Figura 62 – Tráfego de rede Waikato VIII 20111029-110001-1.	125

Figura 63 – Histograma da série de tráfego de rede Waikato VIII 20111029-110001-1.	126
Figura 64 – Série de tráfego de rede dec-pkt-2 agregada em 512ms.	127
Figura 65 – Histograma da série de tráfego de rede dec-pkt-2 agregada em 512ms. .	128
Figura 66 – Série de tráfego de rede SNU20100315 agregada em 100ms.	129
Figura 67 – Histograma da série de tráfego de rede SNU20100315 agregada em 100ms.	130
Figura 68 – Série de tráfego de rede SNU20100317 agregada em 100ms.	131
Figura 69 – Histograma da série de tráfego de rede SNU20100317 agregada em 100ms.	132

Lista de tabelas

Tabela 1 – Média, Variância e parâmetro de Hurst das séries de tráfego reais e das séries sintéticas geradas pelo modelo β MWM Adaptativo.	26
Tabela 2 – Erros Quadrático Médio para a série de tráfego de Waikato VIII 20111029-110001-1 agregada em 10ms.	59
Tabela 3 – Erros Quadrático Médio para a série de tráfego de Waikato VIII 20111029-110001-1 agregada em 100ms.	59
Tabela 4 – Erros Quadrático Médio para a série de tráfego de Waikato VIII 20111029-110001-1 agregada em 512ms.	60
Tabela 5 – Erros Quadrático Médio para a série de tráfego de rede dec-pkt-2 agregada em 512ms.	60
Tabela 6 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 10ms e com $n = 12$ para todos algoritmos.	62
Tabela 7 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 100ms e com $n = 12$ para todos algoritmos.	63
Tabela 8 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 512ms e com $n = 12$ para todos algoritmos.	65
Tabela 9 – Erros Quadrático Médio e Tempo Computacional para a a série de tráfego de rede dec-pkt-2 agregada em 512ms e com $n = 12$ para todos algoritmos.	68
Tabela 10 – Erros Quadrático Médios para a série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.	90
Tabela 11 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII-20111027-213205-5 agregada em 512ms e com $n = 12$ para todos algoritmos.	92
Tabela 12 – Tempo Computacional de execução em relação ao algoritmo Fuzzy LMS para a série de tráfego de rede Waikato VIII-20111027-213205-5 agregada em 512ms, com $n = 12$ para todos algoritmos.	92
Tabela 13 – Erros Quadrático Médio para a série de tráfego de rede SNU20100315 agregada em 100ms.	94
Tabela 14 – Erros Quadrático Médio e Tempo Computacional para a tráfego de rede SNU20100315 agregada em 100ms, com $n = 13$ para todos algoritmos.	95
Tabela 15 – Média e Variância da Fila no <i>Buffer</i>	101
Tabela 16 – Perda, Utilização e Vazão do <i>Buffer</i>	101

Tabela 17 – Média e Variância da Fila no <i>Buffer</i>	106
Tabela 18 – Perda, Utilização e Vazão do <i>Buffer</i>	106
Tabela 19 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede SNU20100315 agregada em 100ms, com $n = 12$ para todos algoritmos.	118
Tabela 20 – Dados Estatísticos da série de tráfego de rede Waikato VIII 20110921- 000000-0.	121
Tabela 21 – Dados Estatísticos da série de tráfego de rede Waikato VIII 20111027- 213205-5.	123
Tabela 22 – Dados Estatísticos da série de tráfego de rede Waikato VIII 20111029- 110001-1.	126
Tabela 23 – Dados Estatísticos da série de tráfego de rede dec-pkt-2.	127
Tabela 24 – Dados Estatísticos da série de tráfego de rede SNU20100315 agregada em 100ms.	129
Tabela 25 – Dados Estatísticos da série de tráfego de rede dec-pkt-2.	131

Lista de abreviaturas e siglas

fBm	<i>Fractional Brownian Motion</i>
β MWM	<i>Beta Multifractal Wavelet Model</i>
EQM	Erro Quadrático Médio
FBF	<i>Fuzzy Basis Function</i>
FBO	Função de Base Ortonormal
LMS	<i>Least Mean Square</i>
MWM	<i>Multifractal Wavelet Model</i>
QoS	<i>Quality of Service</i>
RLS	<i>Recursive Least Square</i>

Trabalhos Submetidos e Publicados

Trabalhos aprovados e/ou publicados:

- SOUZA, B. V. L. ; CARDOSO, A. A. ; VIEIRA, F. H. T. . Algoritmo de Predição de Tráfego de Rede Baseado na Função Autocorrelação de um Modelo Multifractal. In: *CBA 2012 - Congresso Brasileiro de Automática 2012*. Campina Grande, Paraíba, 2012.
- CARDOSO A. A., VIEIRA , F. H. T. Algoritmo Fuzzy de Predição de Tráfego de Redes de Dados com Treinamento Baseado em Filtro de Wiener com Função de Autocorrelação de um Modelo Multifractal. *XI Simpósio Brasileiro de Automação Inteligente – SBAI*. Fortaleza, 2013.
- CARDOSO, A. A. ; VIEIRA, F. H. T. ; ABRAHÃO, D. C. . Controle de tráfego de rede utilizando um algoritmo fuzzy baseado em modelo multifractal adaptativo. In: *CBA 2014 - Congresso Brasileiro de Automática 2014*. Belo Horizonte, Minas Gerais, 2014.
- CARDOSO, A. A. ; VIEIRA, F. H. T. ; PALHARES, P. H. . Algoritmo Fuzzy Baseado Em Modelo Multifractal Adaptativo E Funções De Base Ortonormais Para Controle De Tráfego De Rede. In: *XLVI SBPO - Simpósio Brasileiro de Pesquisa Operacional*. Salvador, Bahia, 2014.

Trabalhos submetidos:

- CARDOSO, A. A. ; VIEIRA, F. H. T. ; PALHARES, P. H. . Network Traffic Control Using a Fuzzy OBF Algorithm Based on Adaptive Multifractal Model. In: *2014 International Telecommunications Symposium*. São Paulo, São Paulo, 2014.
- CARDOSO, A. A. ; VIEIRA, F. H. T. ; PALHARES, P. H. . A Fuzzy OBF Algorithm Based on Adaptive β MWM Multifractal Model for Network Traffic Control. In: *10th International Conference on Network and Service Management*. Rio de Janeiro, Rio de Janeiro, 2014.

Sumário

1	Modelagem Multifractal	19
1.1	Análise Multifractal	19
1.2	Cascatas Multiplicativas	19
1.3	Séries de Tráfego de Redes Consideradas Neste Trabalho	22
1.4	β MultiFractal Wavelet Model (β MWM)	22
1.5	MultiFractal Wavelet Model Adaptativo (β MWM Adaptativo)	24
1.5.1	Algoritmo para Estimação Adaptativa dos Parâmetros do β MWM	25
1.6	Função de Autocorrelação para Processos Multifractais	25
1.7	Função de Escala	28
1.8	Espectro Multifractal	30
2	Lógica Fuzzy	35
2.1	Conceitos Básicos	35
2.1.1	Princípio da Extensão	37
2.1.2	Relações Fuzzy	38
2.1.3	Modus Ponens Generalizado e Modus Tollens Generalizado	38
2.1.4	Implicações Fuzzy	39
2.1.5	Regras Fuzzy	39
2.1.6	Funções de Pertinência	40
2.2	Sistema Fuzzy	40
2.2.1	Inferência Fuzzy	41
2.2.1.1	Interpretações de uma regra SE-ENTÃO	41
2.2.2	Fuzzificador	42
2.2.3	Defuzzificador	43
3	Filtros Adaptativos	45
3.1	Filtro de Wiener	45
3.2	Algoritmo de Otimização do Gradiente-Descendente	48
3.3	Algoritmo de Otimização Levenberg-Marquardt	48
3.4	Mínimos Quadrados Médios (LMS - <i>Least Mean Square</i>)	49
3.5	Algoritmo Fuzzy LMS	50
3.5.1	Algoritmo Adaptativo LMS para Treinamento dos Parâmetros do Modelo Fuzzy	51
3.6	Algoritmo Fuzzy RLS	53
3.6.1	Atualização do parâmetro θ no Algoritmo Fuzzy RLS	54
4	Esquema de Alocação de Banda Utilizando Preditor Fuzzy Adaptativo de Tráfego de Redes Baseado na Função de Autocorrelação de um Modelo Multifractal	55

4.1	Algoritmo Fuzzy LMS com Autocorrelação Multifractal	55
4.1.1	Avaliação dos Preditores	57
4.1.1.1	Resultado para a Série de Tráfego de rede Waikato VIII 20111029-110001-1	60
4.1.1.2	Resultado para a Série de Tráfego de rede dec-pkt-2 agre- gada em 512ms	66
4.2	Esquema de Alocação de Banda Utilizando Predição Fuzzy	69
4.2.1	Avaliação do Desempenho de Alocação de Banda	70
4.2.2	Desempenho da Alocação de Banda para a Série de Tráfego de Rede Waikato VIII 20111029-110001-1	71
4.2.3	Desempenho de Alocação de Banda para a Série de Tráfego de Rede dec-pkt-2 512ms	75
5	Controle de Fluxos de Tráfego Utilizando Sistema Fuzzy com Base Orto- normal	78
5.1	Descrição do Sistema de Controle de Congestionamento	79
5.2	Funções de Base Ortonormal	81
5.2.1	Modelo do Polo Obtido a Partir da Função de Autocorrelação de Processos Multifractais	82
5.2.2	Algoritmo preditivo Fuzzy-LMS-FBO com alfa adaptativo	82
5.3	Cálculo da Taxa Ótima de Controle de Fluxos	86
5.4	Avaliação do Esquema de Controle de Congestionamento Proposto	88
5.4.1	Avaliação de predição do algoritmo proposto Fuzzy-LMS-FBO	90
5.4.1.1	Predição da Série de Tráfego de Rede Waikato VIII-20111027- 213205-5	90
5.4.1.2	Predição da Série de Tráfego de Rede SNU20100315	93
5.4.2	Medidas de Desempenho Utilizadas para Avaliação do Controle de Fluxos	96
5.4.2.1	Controle de tráfego de rede utilizando as séries Waikato	96
5.4.2.2	Avaliação do Desempenho de Controle de Fluxos Utilizando as Séries de Tráfego SNU20100315 e SNU20100317	102
	Conclusão	107
	Referências	108
	Apêndices	114
	APÊNDICE A Variações dos Algoritmos Fuzzy Propostos	115

Anexos	120
ANEXO A Tráfego de Rede Waikato VIII 20110921-000000-0	121
ANEXO B Tráfego de Rede Waikato VIII 20111027-213205-5	123
ANEXO C Tráfego de Rede Waikato VIII 20111029-110001-1	125
ANEXO D Tráfego de Rede dec-pkt-2	127
ANEXO E Tráfego de Rede SNU20100315	129
ANEXO F Tráfego de Rede SNU20100317	131

Introdução

Na busca de uma descrição mais completa do tráfego de redes, modelos multifractais tem sido empregados (YU et al., 2013)(RONGCAI; SHUO, 2010). A modelagem multifractal generaliza os conceitos envolvidos com processos monofractais. Processos multifractais apresentam além de dependência de longo prazo, diferentes leis de escala, sendo dessa forma mais abrangentes. A dependência de longo prazo, presente nas séries de tráfego e que tem importante impacto no desempenho das redes (JUSAK; HARRIS, 2011), pode ser constatada pelo decaimento lento da função de autocorrelação dessas séries temporais.

Aplicações que exigem garantias de qualidade de serviço (QoS) têm sido cada vez mais encontradas na Internet, tais como voz sobre IP e vídeo conferência (DITZE; JAHNICH, 2005). Devido ao comportamento imprevisível e de rajadas dos fluxos em redes multimídia, congestionamentos podem ocorrer causando perdas de dados (bytes) e degradação dos parâmetros de QoS (*Quality of Service*) (HATANO; SHIGENO; OKADA, 2007). Desta forma, se faz necessário um mecanismo de controle de congestionamento eficiente para superar esses problemas e garantir a qualidade de serviço desejada.

A modelagem *fuzzy* tem sido bastante empregada em vários campos de pesquisa desde que a teoria *fuzzy* foi inicialmente desenvolvida (BEZDEK, 1993) (ROSS, 2009). O número de publicações assim como o número de aplicações na área apresenta um forte crescimento nas últimas décadas (ZHANG; PHILLIS; KOUIKOGLOU, 2005). A razão para estas pesquisas é que os modelos *fuzzy* possuem certas vantagens com relação a determinados sistemas sobre modelos lineares, como por exemplo, na descrição de processos reais desconhecidos, com características não-lineares e variantes no tempo, como o tráfego de redes (WANG et al., 2006).

Neste trabalho levamos em conta as características multifractais dos tráfegos de redes e da melhor descrição de sistemas não-lineares pela modelagem *fuzzy* para prever séries e favorecer aplicações para garantir parâmetros de QoS adequados. Focamos especificamente utilizando sistemas *fuzzy* e modelagem multifractal em alocação de banda adaptativa e controle de fluxos de tráfegos de rede.

Os capítulos estão organizados na seguinte forma:

- No capítulo 1, introduzimos os conceitos da análise multifractal. Apresentamos a equação da função de autocorrelação do modelo multifractal que será utilizada no decorrer dos capítulos. Descrevemos os modelos β MWM e β MWM Adaptativo. Apresentamos as séries de tráfego de rede utilizadas, assim como suas Funções de Escala e os seus Espectros Multifractais.

- No capítulo 2, apresentamos os conceitos da lógica *fuzzy* e deduzimos uma equação geral para a saída do sistema de inferência *fuzzy* o qual será de suma importância no capítulo 4.
- No capítulo 3, abordamos a teoria de filtros adaptativos, apresentando os algoritmos de Wiener-Hopf, LMS (*Least Mean Square*), Fuzzy LMS e Fuzzy RLS (*Recursive Least Square*).
- No capítulo 4, propomos um algoritmo *fuzzy* adaptativo que faz uso da equação de Wiener e da função de autocorrelação do modelo multifractal para atualizar seus parâmetros. Na sequência aplicamos o algoritmo proposto deste capítulo na predição e alocação de banda para tráfego de redes, apresentando os resultados da comparação com algoritmos clássicos da literatura.
- No capítulo 5, também propomos um algoritmo *fuzzy* que faz uso das Funções de Base Ortonormal para aumentar a precisão na predição de tráfego de redes com apoio da modelagem multifractal dos modelos β MWM e β MWM Adaptativo. Propomos também um esquema de tráfego de rede que faz uso de uma equação ótima de controle oriunda dos algoritmos *fuzzy*. Resultados de comparações com modelos existentes também são apresentados.
- No capítulo 6 concluímos este trabalho.

1 Modelagem Multifractal

Neste capítulo apresentamos a modelagem multifractal, o modelo β MWM e as séries de tráfego de rede consideradas. Função de Escala e Espectro de Legendre das séries também são apresentados.

1.1 Análise Multifractal

A descrição do comportamento local de medidas e funções em uma forma geométrica e estatística é de interesse da análise multifractal (PARK; WILLINGER, 2000). Na análise multifractal verifica-se o comportamento em escala de momentos estatísticos dos processos para estimar suas regularidades locais (FELDMANN; GILBERT; WILLINGER, 1998)(RIEDI et al., 1999). Através de ferramentas da análise multifractal algumas propriedades encontradas em processos reais podem ser verificadas. O tráfego de redes, por exemplo, ao ser considerado multifractal significa que possui uma estrutura de forte dependência inerente entre as amostras, com incidência de rajadas em várias escalas (RIEDI et al., 1999) (PARK; WILLINGER, 2000). Estas características podem degradar o desempenho de rede em relação a fluxos de tráfego Gaussianos e de curta-dependência.

Definição 1 *Um processo estocástico $X(t)$ é multifractal se satisfaz a equação:*

$$E(|X(t)|^q) = c(q)t^{\tau(q)+1} \quad (1.1)$$

onde $t \in T$ e $q \in Q$, T e Q são intervalos na reta real, $\tau(q)$ e $c(q)$ são funções com domínio Q . Normalmente, assume-se que T e Q tenham comprimentos positivos, e que $0 \in T$, $[0, 1] \subseteq Q$. A Definição 1 descreve a “multifractalidade” em termos de momentos estatísticos, onde $\tau(q)$ e $c(q)$ são conhecidos como a função de escala e o fator de momento de um processo multifractal, respectivamente. Caso $\tau(q)$ seja linear em relação a q o processo é dito ser monofractal, caso contrário, é dito multifractal (RIEDI et al., 1999)(DANG; MOLNAR; MARICZA, 2003)(VIEIRA; LING, 2006a).

1.2 Cascatas Multiplicativas

Uma cascata binomial é um método de se obter um processo multifractal que consiste de um procedimento iterativo no intervalo compacto $[0, 1]$. Sejam m_0 e m_1 (multiplicadores da cascata) dois números positivos cuja soma é 1. No estágio $k = 0$ da cascata, obtém-se a medida inicial μ_0 do processo com probabilidade uniforme em $[0, 1]$. No estágio $k = 1$, a medida μ_1 distribui massa utilizando a distribuição uniforme, sendo, m_0 no subintervalo

$[0, 1/2]$ e massa igual a m_1 em $[1/2, 1]$. Em $k = 2$, o intervalo $[0, 1/2]$ é subdividido em $[0, 1/4]$ e $[1/4, 1/2]$ e o mesmo acontece com o intervalo $[1/2, 1]$, obtendo (PARK; WILLINGER, 2000)(VIEIRA; LING, 2006b):

$$\begin{aligned}\mu_2[0, 1/4] &= m_0 m_0 & \mu_2[1/4, 1/2] &= m_0 m_1 \\ \mu_2[1/2, 3/4] &= m_1 m_1 & \mu_2[3/4, 1] &= m_1 m_1\end{aligned}\tag{1.2}$$

Considere o intervalo diádico $[t, t + 2^{-k}]$ onde $t = 0.\eta_1 \dots \eta_k = \sum_{i=1}^k \eta_i 2^{-i}$. Sejam ψ_0 e ψ_1 as frequências relativas de 0's e 1's no desenvolvimento da cascata. A medida μ no intervalo diádico é dado por:

$$\mu[t, t + 2^{-k}] = m_0^{k\psi_0} m_1^{k\psi_1}\tag{1.3}$$

Este processo preserva a cada estágio a massa dos intervalos diádicos por isso é chamado de cascata conservativa ou microcanônica. Em cada estágio da cascata os intervalos podem ser divididos em um número $b \geq 2$ de intervalos de tamanhos iguais. Para $b > 2$, o processo resultante é definido como cascata multinomial. Se os multiplicadores usados possuem um valor fixo para m_0 e $b = 2$, então a cascata multiplicativa é binomial determinística com função de escala: $\tau(q) = -\log_2(m_0^q + m_1^q) + 1$ (PARK; WILLINGER, 2000). Um exemplo de cascata binomial pode ser observado na Figura 1.




Figura 1 – Processo de construção de uma cascata multiplicativa.

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

$$\mu(\Delta t_k) = R(\eta_1)R(\eta_1, \eta_2) \dots R(\eta_1, \dots, \eta_k)\tag{1.4}$$

onde $R(\eta_1, \dots, \eta_i)$ é o multiplicador no estágio i da cascata. Uma vez que os multiplicadores $R(\eta_1, \dots, \eta_i)$ são i.i.d (independentes e identicamente distribuídos), pode-se demonstrar que a medida μ satisfaz a relação de escala (ZOU; ZHANG; WANG, 2008):

$$E(\mu(\Delta t_k)^q) = (E(R)^q)^k = \Delta t_k^{-\log_2 E(R^q)} \quad (1.5)$$

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

As séries de tráfego reais apresentam suas propriedades multifractais caracterizadas pela função de escala $\tau(q)$ e o fator de momento $c(q)$, conforme se pode observar na equação (1.1). Assim, um modelo multifractal deve capturar estas duas propriedades multifractais. Isto pode ser obtido pelo produto de uma cascata multiplicativa $\mu(\Delta t_k)$ e uma variável aleatória independente e identicamente distribuída (i.i.d) positiva Y em cada intervalo de tempo Δt_k (DANG; MOLNAR; MARICZA, 2002a). A variável Y é independente da medida da cascata $\mu(\Delta t_k)$, então a série obtida denotada por $X(\Delta t_k)$ satisfaz a seguinte equação:

$$\begin{aligned} E(X(\Delta t_k)^q) &= E(Y^q)E(\mu(\Delta t_k)^q) \\ &= E(Y^q)\Delta t_k^{\tau_0(q)} \end{aligned} \quad (1.6)$$

onde $\tau_0(q) = \tau(q) + 1$.

A partir disto, comparando (1.1) e (1.7) temos que as variáveis R e Y devem ser escolhidas de forma a atender as seguintes equações:

$$-\log_2(E(R^q)) = \tau_0(q) \quad (1.7)$$

$$E(Y^q) = c(q) \quad (1.8)$$

A função de escala pode ser precisamente modelada ao assumirmos que R é uma variável aleatória em $[0, 1]$ com distribuição beta simétrica $Beta(\alpha, \alpha)$ com $\alpha > 0$ (DANG; MOLNAR; MARICZA, 2002a):

$$\tau_0(q) = \log_2 \frac{\Gamma(\alpha)\Gamma(2\alpha + q)}{\Gamma(2\alpha)\Gamma(\alpha + q)} \quad (1.9)$$

onde $\Gamma(\cdot)$ corresponde a função Gama.

Considerando o modelo multifractal descrito em (DANG; MOLNAR; MARICZA, 2002b) representado pela multiplicação de uma variável aleatória Y por uma cascata multiplicativa multifractal, podemos descrever o processo de tráfego por 3 parâmetros (α, ρ, γ) , apresentando média μ e variância σ^2 dadas respectivamente por:

$$\mu = e^{\rho + \gamma^2/2} \quad (1.10)$$

e

$$\sigma^2 = e^{2\rho + 2\gamma^2} \left(\frac{\alpha + 1}{\alpha + 1/2} \right)^N - e^{2\rho + \gamma^2} \quad (1.11)$$

Em (DANG; MOLNAR; MARICZA, 2003) os autores mostram que os parâmetros α , σ e ρ para um processo multifractal podem ser atualizados adaptativamente.

1.3 Séries de Tráfego de Redes Consideradas Neste Trabalho

Neste trabalho são consideradas séries reais de tráfego de rede sem fio e séries de tráfego de redes com fio.

As séries de tráfego de redes com fio consideradas foram obtidas do *Network Reasearch Group WAND* do departamento de ciência de computação da *University of Waikato*. As séries de tráfegos escolhidas foram Waikato VIII 20110921-000000-0, 20111027-213205-5 e 20111029-110001-1 com coletas realizadas no período entre 7 de abril a 5 de novembro de 2011. A série de tráfego de rede dec-pkt-2 obtido da *Digital Equipamente Coorporation* também foi utilizado neste trabalho. A série dec-pkt-2 é uma série bastante conhecida na literatura nos trabalhos por exemplo, Dang, Molnar e Maricza (2003).

Foram utilizadas séries de tráfego de redes sem fio provenientes de coletas realizadas em um sistema de comunicação móvel WiMAX da *Seoul National University* (KIM et al., 2012). As séries da *Seoul National University* escolhidas foram SNU20100315 e SNU20100317 onde as coletas de dados foram realizadas respectivamente nos dias 15 e 17 de março de 2010.

Dados estatísticos, histogramas e outras informações das séries utilizadas neste trabalho podem ser encontrados nos anexos.

1.4 β MultiFractal Wavelet Model (β MWM)

O *Multifractal Wavelet Model* (MWM) é um modelo multifractal com grande destaque na modelagem de tráfego de redes (RIEDI et al., 1999)(RIBEIRO et al., 2000). Esse modelo é baseado em uma cascata multiplicativa no domínio *wavelet*. A transformada *wavelet* discreta é usada nesse modelo devido à sua capacidade de representação multiescala de sinais (VIEIRA; COSTA; SOUZA, 2013)(CHUI, 1992). O MWM apresenta mais de um modelo para os coeficientes *wavelet* e coeficientes de escala, gerados pela transformada *wavelet*. Uma dessas modelagens é o β MWM.

O processo de modelagem do β MWM consiste em obter a transformada discreta de *wavelet* de Haar para um número fixo de camadas J da cascata multiplicativa binomial (ROCHA; VIEIRA, 2009) para a série completa em uma única etapa. A partir dos coeficientes *wavelet* ($W_{j,i}$) e coeficientes de escala ($U_{j,i}$) gerados, para cada camada (escala) j , onde $0 \leq j \leq J - 1$, os parâmetros do MWM são estimados.

Para se compreender o modelo MWM, devemos apresentar alguns conceitos relacionados a transformada *wavelet*. A transformada *wavelet* discreta é usada para representação multiescala de sinais da seguinte forma:

$$f(t) = \sum_k U_{J_0,k} \phi_{J_0,k}(t) + \sum_{j=J_0}^{\infty} \sum_k W_{j,k} \psi_{j,k}(t) \quad (1.12)$$

onde $W_{j,k}$ e $U_{j,k}$ são respectivamente os coeficientes *wavelet* e de escala, dado por:

$$W_{j,k} = \int f(t)\psi_{j,k}(t)dt \quad (1.13)$$

$$U_{j,k} = \int f(t)\phi_{j,k}(t)dt \quad (1.14)$$




Figura 2 – Função escala $\phi_{j,k}(t)$ e *wavelet* de Haar $\psi_{j,k}(t)$.

A Figura 2 mostra a função escala $\phi_{j,k}(t)$ e a *wavelet* de Haar $\psi_{j,k}(t)$ utilizadas na representação multiescala do sinal. Pode-se demonstrar que os coeficientes de escala dado pela equação 1.14 podem ser recursivamente calculados utilizando a *wavelet* de Haar $\psi_{j,k}(t)$ através das seguintes equações:

$$U_{j,2k} = 2^{-1/2}(U_{j-1,k} + W_{j-1,k}) \quad (1.15)$$

$$U_{j,2k+1} = 2^{-1/2}(U_{j-1,k} - W_{j-1,k}) \quad (1.16)$$

Este processo recursivo é repetido até que se atinja a resolução desejada ou equivalentemente, até que se obtenha o número desejado de amostras, formando uma árvore binária de coeficientes de escala. A Figura 3 apresenta a árvore binária formada para obtenção dos coeficientes de escala representada pelas equações 1.15 e 1.16. No modelo MWM, a fim de assegurar a não-negatividade da série de tráfego sintético, determinadas condições devem ser impostas a seus coeficientes *wavelets* e de escala. Os coeficientes $U_{j,k}$ representam a média local do processo em escalas e deslocamentos de tempo diferentes. A condição $X(t) \geq 0, \forall t$, impõe que, $U_{j,2k+1} \geq 0, \forall j, k$. Impondo a condição $U_{j,k}, \forall j, k$, pode-se afirmar que $|W_{j,k}| \geq U_{j,k}, \forall j, k$. Os coeficientes *wavelets* são gerados a partir da equação:

$$W_{j,k} = U_{j,k}A_{j,k} \quad (1.17)$$

onde $A_{j,k}$ é uma variável aleatória cujo valor está em $[-1, 1]$. Além disso, supõe-se algumas condições para esta variável: os multiplicadores $A_{j,k}$ são independentes e identicamente distribuídos (i.i.d) dentro de cada escala, são também independentes de $U_{j,k}$ e simétricos em torno de zero. No caso particular do β MWM, os multiplicadores $A_{j,k}$ são modelados segundo

uma distribuição beta simétrica. A função densidade de probabilidade da distribuição beta simétrica é dada por:

$$f(x) = \frac{(1+x)^{p-1}(1-x)^{p-1}}{B(p,p)2^{2p-1}} \quad (1.18)$$




Figura 3 – Árvore Binária dos coeficientes de escala.

onde $B(\cdot)$ é a função beta e p é o parâmetro que determina a forma da distribuição. Os multiplicadores $A_{j,k}$ são escolhidos de forma a controlar as energias dos coeficientes *wavelets*. Assim, obtém-se as seguintes relações (RIEDI et al., 1999):

$$n_j = \frac{E(W_{j-1,k}^2)}{E(W_{j,k}^2)} = \frac{2p_j + 1}{p_{j-1} + 1} \quad (1.19)$$

$$(2p_0 + 1)E(W_{0,0}^2) = E(U_{0,0}^2) \quad (1.20)$$

O β MWM relaciona o decaimento de energia dos coeficientes *wavelets* n_j por camada j com os valores dos parâmetros p_j das distribuições beta simétrica, utilizadas para modelar os multiplicadores $A_{j,k}$. Os parâmetros p_j são estimados, recursivamente, por:

$$p_j = \frac{n_j}{2}(p_{j-1} + 1) - \frac{1}{2} \quad (1.21)$$

1.5 MultiFractal Wavelet Model Adaptativo (β MWM Adaptativo)

Em Goncalves, Vieira e Costa (2013), os autores apresentam uma variação do modelo β MWM, nomeado de β MWM adaptativo, o qual obtém os parâmetros do modelo β MWM adaptativamente utilizando uma parcela da série de tráfego utilizada em sua modelagem. Nesta seção descrevemos o algoritmo para estimação adaptativa dos parâmetros do β MWM apresentando em Goncalves, Vieira e Costa (2013).

1.5.1 Algoritmo para Estimação Adaptativa dos Parâmetros do β MWM

O algoritmo para Estimação Adaptativa dos Parâmetros do β MWM segue os seguintes passos (GONCALVES; VIEIRA; COSTA, 2013):

Inicialização: Inicializa-se o segundo momento dos coeficientes *wavelets* $E[W_{j,k}^2]$, média e variância dos coeficientes de escala $\mu_c(0) = 0$ e $\sigma_c^2 = 0$. Onde n representa o contador de janelas, sendo inicializado $n = 0$.

1º Passo: Realiza-se a transformada de Haar na janela de dados de tamanho 2^j , gerando 2^j coeficientes *wavelets* (nomeados de $\tilde{W}_{j,k}$) por camada j e um coeficiente de escala (nomeado de $\tilde{U}_{0,0}$) na camada $j = 0$.

2º Passo: Atualiza-se o segundo momento $E[W_{j,k}^2]$ dos coeficientes *wavelets* através da equação:

$$E[W_{j,k}^2](n+1) = E[W_{j,k}^2](n) \left(\frac{n}{n+1} \right) + \frac{\sum_{i=0}^{2^j-1} \tilde{W}_{j,k}^2}{(n+1)2^j} \quad (1.22)$$

3º Passo: As taxas de energias n_j são recalculadas pela equação 1.19 e os parâmetros p_j são recalculados segundo a equação 1.21.

4º Passo: As estatísticas dos coeficientes de escala são atualizados segundo as equações:

$$\mu_c(n+1) = \mu_c(n) \left(\frac{n}{n+1} \right) + \frac{\tilde{U}_{0,0}}{n+1} \quad (1.23)$$

$$\sigma_c^2(n+1) = \left(\sigma_c^2(n) + (\mu_c(n))^2 \right) \left(\frac{n}{n+1} \right) - (\mu_c(n+1))^2 + \frac{(\tilde{U}_{0,0})^2}{n+1} \quad (1.24)$$

5º Passo: Repetir os passos de 1 a 4 a cada nova janela de dados de tamanho 2^j amostras, incrementando o valor da variável n em 1. Na seção seguinte apresentamos a função de Autocorrelação para Processos Multifractais, o qual será bastante utilizada no decorrer deste trabalho.

A Tabela 1 mostra a Média, Variância e Parâmetro de Hurst para as séries de tráfego reais (seção 1.3) e das séries sintéticas geradas pelo modelo β MWM adaptativo. Nota-se que o modelo β MWM apresenta séries sintéticas com estatísticas próximas as das séries reais.

1.6 Função de Autocorrelação para Processos Multifractais

Pode-se constatar pela função de autocorrelação de um processo, a presença ou não de dependência de longo prazo entre as amostras (decaimento lento da função de autocorrelação). Além disso, a função de autocorrelação reflete a estatística de segunda ordem de uma série temporal. A partir das propriedades da modelagem multifractal

Tabela 1 – Média, Variância e parâmetro de Hurst das séries de tráfego reais e das séries sintéticas geradas pelo modelo β MWM Adaptativo.

Série	Média da Série Real	Média da Série Sintética	Variância da Série Real	Variância da Série Sintética	Parâmetro de Hurst
Waikato VIII 20110921-000000-0 512ms	2.5457×10^6	2.6776×10^6	4.8309×10^{11}	4.1013×10^{11}	0.8892
Waikato VIII 20111027-213205-5 512ms	2.3540×10^6	2.2518×10^6	5.0972×10^{11}	5.5881×10^{11}	0.8895
Waikato VIII 20111029-110001-1 10ms	9.5266×10^3	1.0549×10^4	1.3002×10^8	1.7537×10^8	0.8155
Waikato VIII 20111029-110001-1 100ms	1.1517×10^5	1.0008×10^5	4.1410×10^9	3.3405×10^9	0.8673
Waikato VIII 20111029-110001-1 512ms	5.1678×10^5	5.2435×10^5	1.6643×10^{11}	1.5299×10^{11}	0.9582
dec-pkt-2 512ms	1.8622×10^4	1.6899×10^4	2.8493×10^8	2.3751×10^8	0.7874
SNU20100315 512ms	2.4998×10^5	2.2241×10^5	2.9359×10^{10}	1.9459×10^{10}	0.9752
SNU20100317 512ms	2.5590×10^5	1.9036×10^5	2.8007×10^{10}	9.4285×10^9	0.9605

apresentada na seção anterior podemos obter a função de autocorrelação de um processo multifractal de forma analítica.

Corolário 1 *Seja o processo multifractal $X(n)$ discreto no tempo com parâmetros α , ρ e γ conforme as equações 1.10 e 1.11. A função de autocorrelação deste processo para os instantes de tempo n e k , é dada pela seguinte equação (VIEIRA; LING, 2006a):*

$$E[X(n), X(n+k)] = e^{2\rho+\sigma^2} \left(\frac{\alpha(\alpha+1)^{N-1}}{(\alpha+1/2)^N} k^{-\log_2(\frac{\alpha+1}{\alpha+1/2})} \right) \quad (1.25)$$

onde $N = \log_2(N_a)$ e N_a é quantidade de amostras do processo.

A Figura 4 mostra a comparação da função de autocorrelação do tráfego de rede real e do modelo multifractal representado pela equação 1.25 para o tráfego de rede Waikato VIII 20111029-110001-1 nas escalas de agregação de 10ms, 100ms e 512ms. Podemos observar que a função de autocorrelação multifractal apresenta um comportamento próximo do valor da autocorrelação real da série de tráfego utilizada.

A Figura 5 mostra a comparação da função de autocorrelação da série de tráfego de rede real e do modelo multifractal representado pela equação 1.25 para a série de tráfego





Figura 4 – Função de autocorrelação real e do modelo Multifractal para o tráfego de rede Waikato VIII 20111029-110001-1.




Figura 5 – Função de autocorrelação real e do modelo Multifractal para a série de tráfego de rede dec-pkt-2 agregada em 512ms.

de rede dec-pkt-2 agregada na escala de $512ms$. Nota-se um comportamento próximo das funções de autocorrelação da série real e do modelo multifractal, apresentando um distanciamento aparentemente maior comparado aos resultados obtidos para a série de tráfego de rede Waikato VIII 20111029-110001-1 da Figura 4.

1.7 Função de Escala

Um processo multifractal definido pela equação 1.1 implica condição de estacionariedade para seus incrementos (DANG; MOLNAR; MARICZA, 2003). Portanto, a relação dada pela equação 1.26 apresentada abaixo, obtida a partir da equação 1.1, é válida para os momentos dos processos de incrementos, ou seja:

$$E[|Z^{(\Delta t)}|^q] = c(q)(\Delta t)^{\tau(q)+1} = c(q)(\Delta t)^{\tau_0(q)}, \quad q > 0 \quad (1.26)$$

onde $Z^{(\Delta t)}$ denota o processo de incremento na amostra de tempo Δt e $\tau_0(q) = \tau(q) + 1$. A equação 1.26 também é válida para $m = 1, 2, \dots$, sendo m o nível de agregação do processo de incrementos, podemos assim rescrever a equação 1.26 como se segue:

$$E[|Z^{(m\Delta t)}|^q] = c(q)(\Delta t)^{m\tau_0(q)}, \quad q > 0 \quad (1.27)$$

Assumindo Δt como tempo unitário, temos:

$$\log E[|Z^{(m)}|^q] = \tau_0(q) \log m + \log c(q) \quad (1.28)$$

Se a sequência de incrementos Z^m tem propriedade de escala (*scaling property*), então a curva que descreve os momentos $E[|Z^{(m)}|^q]$ em relação a m em um gráfico em escala logarítmica deverá ser uma linha reta, conforme 1.28. A inclinação desta linha reta fornece uma estimativa de $\tau_0(q)$ e o ponto de interceptação desta linha corresponde ao valor de $\log c(q)$. Uma vez estimados os valores de $\tau_0(q)$ para diferentes valores de q , uma curva de $\tau_0(q)$, ou $\tau(q)$, em função de q pode ser construída. Se a função de escala $\tau(q)$ em relação a q obter um comportamento linear diz-se que este é indício de que o processo seja monofractal (DANG; MOLNAR; MARICZA, 2003).

A Figura 6 mostra a Função de escala em relação a q para os tráfegos de rede dec-pkt-2 agregada em $512ms$ e Waikato VIII 20111029-110001-1 agregada em $10ms$, $100ms$ e $512ms$. Podemos observar que a série de tráfego de rede dec-pkt-2 apresentou uma relação linear entre $\tau(q)$ e q , o que é consistente com um comportamento monofractal. Em contraste a função de escala $\tau(q)$ mostra um comportamento não-linear para a série de tráfego de rede Waikato VIII 20111029-110001-1 nas três escalas de agregação consideradas, sugerindo uma estrutura multifractal para esta série de tráfego.




Figura 6 – Função de escala dos tráfegos de rede dec-pkt-2 agregada em 512ms e Waikato VIII 20111029-110001-1 agregada em 10ms, 100ms e 512ms.




Figura 7 – Função de escala da série de tráfego de rede SNU20100315 agregada em 100ms.

As Figura 7 e 8 mostram a Função de escala em relação a q para as séries de tráfego de rede SNU20100315 e Waikato VIII 20110921-000000-0 agregadas em 100ms e 512ms, respectivamente. Com ajuda da linha reta tracejada podemos visualizar um comportamento não linear de $\tau(q)$ em relação a q , sugerindo também uma estrutura multifractal para estas séries de tráfego consideradas.




Figura 8 – Função de escala da série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms.




Figura 9 – Função de escala da série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.

A Figura 9, assim como nos exemplos anteriores, mostra uma Função de escala não linear em relação a q para a série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.

1.8 Espectro Multifractal

O grau de singularidades locais de um processo estocástico pode ser quantificado por meio dos expoentes de Hölder pontuais correspondentes.

Seja α um número real estritamente positivo, K uma constante, e $X_0 \in R$. A função $f : R \rightarrow R$ é $C^\alpha(X_0)$ se existe um polinômio P_n , de grau $n < \alpha$, onde $C^\alpha(X_0)$

define o conjunto de funções f que são α vezes diferenciáveis, com derivadas contínuas, tal que:

$$|f(x) - P_n(x - x_0)| < K|x - x_0|^\alpha \quad (1.29)$$

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

$$h = \sup\{\alpha > 0 | f \in C^\alpha(x_0)\} \quad (1.30)$$

Esta caracterização da regularidade de uma função é amplamente utilizada em análise multifractal. Alguns trabalhos (SEURET; GILBERT, 2000)(VIEIRA; ROCHA; LEMOS, 2010) nos mostra que o expoente de Hölder pontual pode quantificar o grau da variação instantânea de um sinal de tráfego de redes. Mais precisamente, este expoente pode indicar o grau das rajadas de dados presentes neste sinal.

O espectro multifractal $f(\alpha)$ de um processo $X(t)$ pode ser visto como a transformada de Legendre de $\tau(q)$ pela relação:

$$f(\alpha) = \min_q \{q\alpha - \tau(q)\} \quad (1.31)$$

Em outras palavras, em contraste à outros modelos de tráfego, processos multifractais contêm uma multiplicidade de expoentes de Hölder locais dentro de qualquer intervalo finito (PARK; WILLINGER, 2000). Os expoentes de Hölder descrevem as características locais em escala de um processo em determinado ponto no tempo. O conceito de expoente de Hölder está relacionado com a singularidade local de um processo, ou seja, caracteriza a sua suavidade (quantidade de rajadas) em certo instante de tempo (RIBEIRO et al., 2005)(EHLERS, 2005). A distribuição destes expoentes pode ser representada por uma densidade normalizada chamada espectro multifractal. Em outras palavras, o espectro multifractal descreve a dimensão fractal do conjunto de instantes possuindo um dado expoente local (RIEDI et al., 1999).

Processos cujo espectro $f(\alpha)$ é definido para apenas um ponto, apresentando um único expoente de Hölder, são classificados como monofractais. Para processos multifractais, o espectro apresenta uma forma parabólica côncava, apresentando assim, múltiplos valores para os expoentes de Hölder (RIEDI et al., 1999)(VIEIRA; LING, 2008).




Figura 10 – Espectro Multifractal da série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 10ms, 100ms e 512ms.

Através da transformada de Legendre, o espectro multifractal para várias séries de tráfego foi calculado. As Figuras 10 e 11 apresentam os espectros multifractais para as séries reais de tráfego de redes Waikato VIII 20111029-110001-1 agregada em 10ms, 100ms e 512ms e dec-pkt-2 agregada em 512ms. Podemos observar uma forma côncava e uma multiplicidade de expoentes de Hölder, o que apresenta uma evidência da multifractalidade destas séries de tráfego (PAVLOV; ANISHCHENKO, 2007). O espectro multifractal da série sintética gerada a partir do modelo fBm para cada série de tráfego também são exibidos para comparação na Figura 11. Este modelo é conhecido por gerar tráfego sintético com autossimilaridade e tem sido usado para representar tráfego monofractal com dependência de longo prazo (NORROS,). O tráfego sintético fBm foi gerado com o mesmo valores de H das séries reais, ou seja, $H = 0.9752$ para a série de tráfego de rede SNU20100315. O espectro de Legendre apresentado na Figura 11 para a série real é mais largo que o espectro obtido a partir da série sintética gerada segundo o modelo fBm, denotando uma multiplicidade de expoentes de Hölder, o que é mais uma evidência de “multifractalidade” destas séries (PAVLOV; ANISHCHENKO, 2007).

As Figuras 12 e 13 mostram os espectros multifractais para as séries reais de tráfego de redes Waikato VIII 20110921-000000-0 e Waikato VIII 20111027-213205-5, respectivamente.




Figura 11 – Espectro Multifractal da série de tráfego de rede SNU20100315 agregada em 100ms e da série sintética do modelo fBm com $H = 0.9752$.




Figura 12 – Espectro Multifractal da série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms e da série sintética do modelo fBm com $H = 0.8892$.

As mesmas características das figuras 10 e 11 de formato côncavo e multiplicidade de expoentes de Hölder são encontradas nas Figuras 12 e 13, apresentando as mesmas evidências de multifractalidade. Os espectros multifractais das séries de tráfego reais também se apresentaram mais largos que os das séries sintéticas geradas segundo o modelo fBm.




Figura 13 – Espectro Multifractal da série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms e da série sintética do modelo fBm com $H = 0.8895$.

2 Lógica *Fuzzy*

A ideia de conjuntos *fuzzy* foi apresentada pela primeira vez nos anos 60 por Lofti Asker Zadeh, onde observou-se que a lógica tradicional (lógica *booleana*) não era suficiente para automatizar problemas relacionados à natureza industrial, biológica ou química (ROSS, 2009). Por volta do ano de 1974, Ebrahim Mandani controlou uma máquina à vapor com diferentes tipos de controladores utilizando a lógica *fuzzy* (MAMDANI; ASSILIAN, 1975).

A lógica *fuzzy* apresenta um melhor tratamento de imprecisões, ao contrário da lógica *booleana* que descreve a realidade utilizando os extremos, verdadeiro ou falso (ROSS, 2009). Outra vantagem da lógica *fuzzy* se refere ao uso de variáveis linguísticas, aproximando do pensamento natural do ser humano, que em certos casos pode facilitar a solução de problemas (LI; CHEN; HUANG, 2000). Neste capítulo introduzimos os conceitos e definições básicas da lógica *fuzzy*, obtendo uma expressão final chamada de FBF (*Fuzzy Basis Function*) que será de fundamental importância nos capítulos subsequentes.

2.1 Conceitos Básicos

Considere S , um conjunto não vazio, chamado de conjunto universo e constituído de todos elementos possíveis a um determinado contexto. Sendo s um subconjunto de S , indicamos se s é um elemento de S pela expressão:

$$s \in S \quad (2.1)$$

Caso s não seja um elemento de S , escrevemos:

$$s \notin S \quad (2.2)$$

Definição 2 *Função de Pertinência para conjuntos Crisp (Membership Function):* Seja A um conjunto em S , definimos assim a função de pertinência (lógica binária) pela equação:

$$\chi_A(x) = \begin{cases} 0 & \text{se } x \notin S \\ 1 & \text{se } x \in S \end{cases} \quad (2.3)$$

onde x pode ser qualquer elemento em S .

Definição 3 *Função de Pertinência para conjuntos Fuzzy (Membership Function):* Seja A um conjunto em S , definimos assim a função de pertinência (lógica fuzzy) pela equação:

$$\mu_A(x) \in [0, 1] \quad (2.4)$$

onde x pode ser qualquer elemento em S e μ_A pode assumir qualquer valor no intervalo $[0, 1]$.

A principal diferença entre a lógica comum (conjuntos *crisp*) e lógica *fuzzy* é quando nos referimos à função de pertinência, onde a lógica *crisp* assume apenas uma função de pertinência, enquanto podemos assumir várias funções para modelar a função de pertinência μ_A na lógica *fuzzy* (ROSS, 2009).

Definição 4 *Suporte: Seja A um conjunto fuzzy, definimos o suporte do conjunto A sendo o conjunto de todos os pontos crisp $u \in U$, tal que $\mu_A(u) > 0$.*

Definição 5 *Centro: Seja A um conjunto fuzzy, definimos o centro do conjunto A sendo o conjunto de todos os pontos crisp $u \in U$, tal que $\mu_A(u)$ atinja seu valor máximo.*

Definição 6 *Sejam A e B conjuntos fuzzy definidos no espaço U . A interseção $A \cap B$ também é um conjunto fuzzy no espaço U definindo para todo $u \in U$, representado pela equação:*

$$\mu_{A \cap B}(x) = \min[\mu_A(x), \mu_B(x)] \quad (2.5)$$

A união $A \cup B$ é um conjunto fuzzy no espaço U definindo para todo $u \in U$, representado pela equação:

$$\mu_{A \cup B}(x) = \max[\mu_A(x), \mu_B(x)] \quad (2.6)$$

O completo de A , dado por $\bar{A}$, é um conjunto no espaço U definindo para todo $u \in U$, representado pela equação:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (2.7)$$

Definição 7 *Sejam A e B conjuntos fuzzy definidos no espaço U . A interseção $A \cap B$ também é um conjunto fuzzy no espaço U definindo para todo $u \in U$, representado pela equação:*

$$\mu_{A \cap B}(x) = \mu_A(x) \mu_B(x) \quad (2.8)$$

A união $A \cup B$ é um conjunto fuzzy no espaço U definindo para todo $u \in U$, representado pela equação:

$$\mu_{A \cup B}(x) = \mu_A(x) + \mu_B(x) - \mu_{A(x) \cap B(x)} \quad (2.9)$$

As Definições 6 e 7 mostram duas escolhas diferentes para os operadores união e interseção. Baseado em diferentes interpretações variando de argumentações intuitivas até empíricas, ou até mesmo justificações axiomáticas, outros operadores são propostos na

literatura (WANG, 1994). A seguir definimos a *T-norm* e a *T-conorm*, duas representações para a união e interseção respectivamente.

Definição 8 A *T-norm* é uma função binária $T : [0, 1] \times [0, 1] \rightarrow [0, 1]$, monotônica, simétrica, associativa, sendo utilizada para implementar o operador lógico **AND** ou a interseção, definida por:

$$\begin{aligned}
 \min[x, y] & \quad \text{Intersecção fuzzy} \\
 xy & \quad \text{Produto algébrico} \\
 x \star y = \max[0, x + y - 1] & \quad \text{Produto limitado} \\
 & \quad x \text{ se } y = 1 \\
 & \quad y \text{ se } x = 1 \\
 & \quad 0 \text{ se } x, y = 1
 \end{aligned} \tag{2.10}$$

onde $\star$ é o símbolo utilizado para representar a *T-norm* e $x, y \in [0, 1]$.

Definição 9 A *T-conorm* é uma função binária $S : [0, 1] \times [0, 1] \rightarrow [0, 1]$, monotônica, simétrica, associativa, sendo utilizada para implementar o operador lógico **OR** ou a união, definida por:

$$\begin{aligned}
 \max[x, y] & \quad \text{União fuzzy} \\
 x + y - xy & \quad \text{Soma algébrica} \\
 x \dot{+} y = \min[0, x + y] & \quad \text{Soma limitada} \\
 & \quad x \text{ se } y = 0 \\
 & \quad y \text{ se } x = 0 \\
 & \quad 0 \text{ se } x, y > 0
 \end{aligned} \tag{2.11}$$

onde $\dot{+}$ é o símbolo utilizado para representar a *T-conorm* e $x, y \in [0, 1]$.

2.1.1 Princípio da Extensão

Definição 10 Seja U e V dois subconjuntos de S e f o mapeamento do conjunto U em V . Para um conjunto fuzzy $A \subset U$, o princípio da extensão define um conjunto fuzzy $B \subset V$, dado pela equação:

$$\mu_B(v) = \sup_{u \in f^{-1}(v)} [\mu_A(u)] \tag{2.12}$$

caso $f^{-1}(v)$ não seja vazio para algum $v \in V$, definimos $\mu_B(v) = 0$.

2.1.2 Relações Fuzzy

Relações são utilizadas no sentido de relacionamento, de modo que uma variável esteja relacionada a outra de alguma maneira, por exemplo, as expressões: x é menor que y , ou y é uma função de x (JANTZEN, 2007). São estabelecidos símbolos para vários tipos de relações, por exemplo, $x = y$, $x < y$. Definimos a seguir relação fuzzy.

Definição 11 *Relação Fuzzy: Seja S o conjunto universo e U e V subconjuntos de S . A relação fuzzy R é um conjunto fuzzy definido em $U \times V$, sendo $\mu_R(u, v)$ a função de pertinência de R , onde $u \in U$ e $v \in V$.*

Definição 12 *Relação Composta Fuzzy: Seja R e S relações fuzzy em $U \times V$ e $V \times W$, respectivamente. A relação composta fuzzy de R e S é uma relação fuzzy representada por $R \circ S$, dada pela equação:*

$$\mu_{R \circ S} = \sup_{v \in V} [\mu_R(u, v) \star \mu_S(v, w)] \quad (2.13)$$

onde $u \in U$ e $w \in W$. Na equação 2.13 é utilizado o símbolo $\star$, podendo ser qualquer operador na classe T-norm da definição 8.

2.1.3 Modus Ponens Generalizado e Modus Tollens Generalizado

Definição 13 *Sejam os conjuntos fuzzy A , A' , B e B' e as variáveis linguísticas x e y , definimos Modus Ponens Generalizado (GMP) como uma regra de inferência fuzzy, dado pelo seguinte procedimento:*

$$\text{Premissa 1: } x \text{ É } A' \quad (2.14)$$

$$\text{Premissa 2: } \text{SE } x \text{ É } A, \text{ ENTÃO } y \text{ É } B \quad (2.15)$$

$$\text{Consequência: } y \text{ É } B' \quad (2.16)$$

onde

Definição 14 *Sejam os conjuntos fuzzy A , A' , B e B' e as variáveis linguísticas x e y , definimos Modus Tollens Generalizado (GMT) como uma regra de inferência fuzzy, dado pelo seguinte procedimento:*

$$\text{Premissa 1: } y \text{ É } B' \quad (2.17)$$

$$\text{Premissa 2: } \text{SE } x \text{ É } A, \text{ ENTÃO } y \text{ É } B \quad (2.18)$$

$$\text{Consequência: } x \text{ É } A' \quad (2.19)$$

2.1.4 Implicações Fuzzy

Podemos entender implicação fuzzy como uma compreensão das regras SE-ENTÃO (WANG, 1994), onde a implicação $A \rightarrow B$ pode ser visualizada como a regra SE x é A , ENTÃO y é B , sendo $x \in U$ e $y \in V$ variáveis linguísticas. Definimos a seguir alguns modos de interpretar as implicações.

Definição 15 *Seja A um subconjunto de U e B um subconjunto de V . Uma implicação fuzzy, representada por $A \rightarrow B$, é um tipo especial de relação fuzzy em $U \times V$ dado pelas seguintes operações de pertinências:*

Conjunção Fuzzy:

$$\mu_{A \rightarrow B}(u, v) = \mu_A(u) \star \mu_B(v) \quad (2.20)$$

Disjunção Fuzzy:

$$\mu_{A \rightarrow B}(u, v) = \mu_A(u) \dot{+} \mu_B(v) \quad (2.21)$$

Implicação Material:

$$\mu_{A \rightarrow B}(u, v) = \mu_{\bar{A}}(u) \dot{+} \mu_B(v) \quad (2.22)$$

Calculo Proposicional:

$$\mu_{A \rightarrow B}(u, v) = \mu_{\bar{A}}(u) \dot{+} \mu_{A \star B}(v) \quad (2.23)$$

Generalização do modus pones:

$$\mu_{A \rightarrow B}(u, v) = \sup\{c \in [0, 1] \mid \mu_A(u) \star c \leq \mu_B(v)\} \quad (2.24)$$

Generalização do modus tollens:

$$\mu_{A \rightarrow B}(u, v) = \inf\{c \in [0, 1] \mid \mu_B(v) \dot{+} c \leq \mu_A(u)\} \quad (2.25)$$

2.1.5 Regras Fuzzy

Definição 16 *A base de regras fuzzy consiste no conjunto de regras fuzzy SE-ENTÃO, na seguinte forma:*

$$\begin{aligned} R^{(1)} : & \text{SE } x_1 \text{ é } F_1^1 \text{ E } \dots \text{ E } x_n \text{ é } F_n^1 \text{ ENTÃO } y \text{ é } G^1 \\ & \vdots \\ R^{(n)} : & \text{SE } x_1 \text{ é } F_1^l \text{ E } \dots \text{ E } x_n \text{ é } F_n^l \text{ ENTÃO } y \text{ é } G^l \end{aligned} \quad (2.26)$$

onde F_i^l e G_i^l são conjuntos fuzzy $U_i \subset R$ e $V \subset R$, respectivamente, e $\mathbf{x} = [x_1, \dots, x_n]^T$ é o vetor de entradas satisfazendo $\mathbf{x} \in U_i \times \dots \times U_n$. Sendo $y \in V$ e $l = 1, \dots, M$ o número de regras SE-ENTÃO da forma da equação 2.26.

As regras da Definição 16 podem ser obtidas através de duas maneiras (WANG, 1994): do conhecimento de especialistas humanos ou através de algoritmos de treinamento baseado na relação dos dados de entradas e respostas esperadas pelo sistema (respostas desejadas). Caso a obtenção das regras seja feita por especialistas humanos, se faz necessária a inicialização das funções de pertinências F_i^l e G_i^l também pelos especialistas. Caso a obtenção das regras seja feita por dados numéricos (algoritmos de treinamento), podemos especificar um dos modelos descritos na Seção 2.1.6.

2.1.6 Funções de Pertinência

Várias funções de pertinências são propostas na literatura (LILLY, 2010): Gaussiana, Triangular, Trapezoidal, Sigmóide entre outras. Neste trabalho, concentramos nosso estudo na função de pertinência Gaussiana.

Definição 17 Definimos a função de pertinência Gaussiana pela equação:

$$\mu_{F_i^l} = a_i^l \exp \left[- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right] \quad (2.27)$$

Na Figura 14 podemos observar a forma gráfica da função gaussiana, a qual é utilizada para formar a função de pertinência gaussiana, onde $a_i^l = \frac{1}{\sigma\sqrt{2\pi}}$.




Figura 14 – Função Gaussiana [Adaptado de Ross (2009)].

2.2 Sistema Fuzzy

Utilizando as definições básicas apresentadas anteriormente, podemos construir um sistema *fuzzy* que obtenha entradas *crisp*, que as interpreta e gera uma saída (resposta) *crisp*. A Figura 15 mostra a configuração básica desse sistema. Nota-se que $\mathbf{x}$ e y representam a entrada e saída do sistema respectivamente. O sistema apresenta múltiplas entradas (vetor) e apenas uma saída, sendo considerado MISO (*Multiple-Input-Single-Output*).

O sistema apresentado na Figura 15 apresenta os seguintes blocos:




Figura 15 – Sistema Fuzzy [Adaptado de Wang (1994)].

- Fuzzificador
- Defuzzificador
- Inferência *fuzzy*.
- Regras

Descrevemos nas próximas seções os blocos do sistema básico *fuzzy*.

2.2.1 Inferência *Fuzzy*

O bloco nomeado Inferência apresentado na Figura 15 é responsável em realizar um mapeamento *fuzzy* do conjunto $U = U_1 \times \dots \times U_n$ gerados pelo Fuzzificador em um conjunto $\in V$, apresentando uma resposta para o Defuzzificador. Nota-se que esse mapeamento é realizado baseado no conjunto de regras (bloco Regras da Figura 15) do sistema.

2.2.1.1 Interpretações de uma regra SE-ENTÃO

A regra *fuzzy* SE-ENTÃO é interpretada como uma implicação *fuzzy* $F_1^l \times \dots \times F_n^l \rightarrow G^l$ em $U \times V$ (WANG, 1994).

Definição 18 *Seja o conjunto fuzzy $A' \in U$ a entrada da inferência fuzzy. Logo, cada regra fuzzy SE-ENTÃO determina um conjunto fuzzy $B^l \in V$ utilizando a relação composta fuzzy 2.13, ou seja:*

$$\mu_{B^l}(y) = \sup_{\mathbf{x} \in U} [\mu_{F_1^l \times \dots \times F_n^l \rightarrow G^l} \star \mu_{A'}(\mathbf{x})] \quad (2.28)$$

Utilizando as seis interpretações da Definição 15 e fazendo $F_1^l \times \dots \times F_n^l = A$ e $G^l = B$, apresentamos a seguir as interpretações da regra SE-ENTÃO (equação 2.26) $A \rightarrow B$ mais comuns de acordo com (WANG, 1994).

Regra da operação *min* da implicação *fuzzy*:

$$\mu_{A \rightarrow B} = \min[\mu_A(\mathbf{x}), \mu_B(y)] \quad (2.29)$$

Regra da operação produto da implicação *fuzzy*:

$$\mu_{A \rightarrow B} = \mu_A(\mathbf{x})\mu_B(y) \quad (2.30)$$

Regra aritmética da implicação *fuzzy*:

$$\mu_{A \rightarrow B} = \min[1, 1 - \mu_A(\mathbf{x}) + \mu_B(y)] \quad (2.31)$$

Regra Max-Min da implicação *fuzzy*:

$$\mu_{A \rightarrow B} = \max[\min[\mu_A(\mathbf{x}), \mu_B(y)], 1 - \mu_A(\mathbf{x})] \quad (2.32)$$

Regra Booleana da implicação *fuzzy*:

$$\mu_{A \rightarrow B} = \max[1 - \mu_A(\mathbf{x}), \mu_B(y)] \quad (2.33)$$

Regra de Goguen da implicação *fuzzy*:

$$\mu_{A \rightarrow B} = \begin{cases} 1 & \text{se } \mu_A(\mathbf{x}) \leq \mu_B(y) \\ \frac{\mu_B(y)}{\mu_A(\mathbf{x})} & \text{se } \mu_A(\mathbf{x}) > \mu_B(y) \end{cases} \quad (2.34)$$

Nas equações 2.29-2.34, podemos definir $\mu_A(\mathbf{x}) = \mu_{F_1^l \times \dots \times F_n^l}(\mathbf{x})$ pela regra da operação *min*:

$$\mu_{F_1^l \times \dots \times F_n^l}(\mathbf{x}) = \min[\mu_{F_1^l}(x_1), \dots, \mu_{F_n^l}(x_n)] \quad (2.35)$$

ou pela equação da regra da operação do produto:

$$\mu_{F_1^l \times \dots \times F_n^l}(\mathbf{x}) = \mu_{F_1^l}(x_1) \dots \mu_{F_n^l}(x_n) \quad (2.36)$$

2.2.2 Fuzzificador

Fuzzificação é o processo para transformar quantidades *crisp* em quantidades *fuzzy* (ROSS, 2009, p. 94). A Figura 15 mostra o bloco do Fuzzificador onde é feita a Defuzzificação, realizando o mapeamento da entrada $\mathbf{x} = (x_1, \dots, x_n)^T \in U$ para conjuntos *fuzzy* pertencentes a U .

Apresentamos aqui as duas escolhas mais utilizadas na literatura (WANG, 1994):

Definição 19 *Fuzzificador Singleton*: Seja A' um conjunto fuzzy com suporte $\mathbf{x}$ definimos o Fuzzificador Singleton pela seguinte equação:

$$\mu_{A'} = \begin{cases} 1 & \text{se } \mathbf{x}' = \mathbf{x} \\ 0 & \text{se } \mathbf{x}' \neq \mathbf{x} \end{cases} \quad (2.37)$$

onde $\mathbf{x}' \in U$.

Definição 20 *Fuzzificador Gaussiano: Seja A' um conjunto fuzzy com suporte $\mathbf{x}$ definimos o Fuzzificador Gaussiano pela seguinte equação:*

$$\mu_{A'} = e^{\left[-\frac{(\mathbf{x}' - \mathbf{x})^T(\mathbf{x}' - \mathbf{x})}{\sigma^2}\right]} \quad (2.38)$$

onde $\mathbf{x}' \in U$, e σ é um parâmetro utilizado para caracterizar o formato de $\mu_{A'}$.

A Figura 16 mostra a forma gráfica dos Fuzzificadores *Singleton* e Gaussiano.




Figura 16 – Fuzzificador *Singleton* e Gaussiano.

2.2.3 Defuzzificador

Defuzzificador é um processo para transformar quantidades *fuzzy* em quantidades *crisp*. Na Figura 15 visualizamos o bloco do Defuzzificador onde é feita a defuzzificação, realizando o mapeamento dos conjuntos *fuzzy* pertencentes ao conjunto V na saída do sistema em quantidades *crisp* $y \in V$.

Vários Defuzzificadores são propostos na literatura (ROSS, 2009, p. 99): Média dos máximos, Menor dos Máximos, Maior dos Máximos, Valor Médio da Área, Centro Médio entre outros. Neste trabalho aplicamos nos algoritmos de predição *fuzzy* o método de defuzzificação pelo Centro Médio.

Definição 21 *A defuzzificação por centro médio (centroide) é dado pela equação:*

$$y = \frac{\sum_{l=1}^M \bar{y}^l (\mu_{B'}(\bar{y}^l))}{\sum_{l=1}^M \mu_{B'}(\bar{y}^l)} \quad (2.39)$$

onde $\bar{y}^l$ é o centro do conjunto fuzzy G^l e representa o ponto em V , onde $\mu_{G^l}(y)$ alcança seu valor máximo. $\mu_{B'}$ é representado pela Equação 2.28.

A Figura 17 mostra a forma gráfica da defuzzificação pelo método do Centro Médio.

Utilizando inferência por regra do produto através da equação 2.30 e 2.36 e aplicando na implicação dada pela equação 2.28 obtemos a seguinte expressão:

$$\mu_{B'}(\bar{y}^l) = \sup_{\mathbf{x}' \in U} \left[\prod_{i=1}^n \mu_{F_i^l}(x'_i) \mu_{G^l}(\bar{y}^l) \mu_{A'}(\mathbf{x}') \right] \quad (2.40)$$




Figura 17 – Defuzzificação por Centro Médio (Centróide).

Se utilizarmos o fuzzificador *Singleton*, temos $\mu_{A'}(\mathbf{x}') = 1$ para $\mathbf{x}' = \mathbf{x}$, onde $\mathbf{x}$ representa a entrada *crisp* no sistema *fuzzy*, e $\mu_{A'} = 0$ para todos outros $\mathbf{x} \in U$. Podemos então simplificar a equação 2.40, resultando na expressão:

$$\mu_{B'}(\bar{y}^l) = \prod_{i=1}^n \mu_{F_i^l}(x_i) \quad (2.41)$$

onde $\mu_{G^l}(\bar{y}^{-l}) = 1$.

Substituindo a equação 2.41 na expressão 2.39 do defuzzificador por centro médio, chegamos na expressão final do sistema *fuzzy*, dada por:

$$f(\mathbf{x}) = \frac{\sum_{l=1}^M \bar{y}^l \left[\prod_{i=1}^n \mu_{F_i^l}(x_i) \right]}{\sum_{l=1}^M \left[\prod_{i=1}^n \mu_{F_i^l}(x_i) \right]} \quad (2.42)$$

Definição 22 Definimos a função chamada de expansão chamada *Fuzzy Basis Function (FBF)* como sendo a expressão de saída do sistema *fuzzy*, utilizando defuzzificação por centro médio, inferência pela regra do produto e função de pertinência gaussiana pela seguinte equação (WANG, 1994):

$$f(\mathbf{x}) = \frac{\sum_{l=1}^M \bar{y}^l \left[\prod_{i=1}^n a_i^l \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right]}{\sum_{l=1}^M \left[\prod_{i=1}^n a_i^l \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right]} \quad (2.43)$$

3 Filtros Adaptativos

Filtros adaptativos são usados em várias áreas de Engenharia Elétrica atualmente. Podemos definir filtragem como a operação cujo objetivo é processar um sinal visando manipular as informações contidas neste sinal (DINIZ, 2008). Algumas aplicações se mostram variantes no tempo, tornando difícil a utilização de filtros para descrever esses processos. Com esse intuito surgiu a filtragem adaptativa, a qual consegue descrever processos variantes no tempo (DINIZ, 2008). Os filtros adaptativos são utilizados em várias aplicações e situações. Podemos destacar 4 principais: Identificação de Sistemas, Cancelamento de Ruído, Equalização de Canais e Predição de Sinal (SCHILLING; HARRIS, 2011). Neste trabalho consideramos a aplicação de predição de sinal, que no nosso caso se torna prever intensidade de tráfego de rede.




Figura 18 – Predição utilizando filtro Adaptativo.

A Figura 18 mostra o diagrama de blocos para a aplicação de predição. A função do filtro adaptativo se torna encontrar uma função que relacione a entrada $\mathbf{x}(k)$ e saída $y(k)$, que representa o valor estimado da resposta desejada $d(k)$. Observamos que através do erro $e(k)$, podemos adaptar o filtro pelo algoritmo adaptativo, na tentativa de diminuir o erro e fazer uma predição mais precisa.

Neste capítulo descrevemos alguns algoritmos adaptativos apresentados na literatura: Filtro de Wiener, LMS (*Least Mean Square*), Fuzzy LMS e Fuzzy RLS (*Recursive Least Square*).

3.1 Filtro de Wiener

Considere o caso de predição dos valores desejados, dado pelo vetor $\mathbf{d}(k)$:

$$\mathbf{d}(k) = [d(0) \ d(1) \ d(2) \ \dots] \quad (3.1)$$

onde k representa o instante de tempo, $k = 0, 1, 2, \dots$

Descrevemos o filtro de Wiener pela Figura abaixo,




Figura 19 – Filtro Linear.

onde o vetor de entrada $\mathbf{x}(k)$ e o vetor de saída sendo $\mathbf{y}(k)$, são dados pelas seguintes equações:

$$\mathbf{x}(k) = [x_0(k) \ x_1(k) \ x_2(k) \ \dots \ x_N(k)] \quad (3.2)$$

$$\mathbf{y}(k) = [y_0(k) \ y_1(k) \ y_2(k) \ \dots \ y_N(k)] \quad (3.3)$$

Podemos verificar que a saída do filtro linear da Figura 19 dada em relação aos pesos $\mathbf{w}$ e pela entrada $\mathbf{x}$, pode ser representada por:

$$y(k) = \sum_{i=0}^N w_i(k) x_i(k) = \mathbf{w}^T(k) \mathbf{x}(k) \quad (3.4)$$

onde $\mathbf{w} = [w_0 \ \dots \ w_n]$.

Verifica-se também que o erro $e(k)$ é a diferença da resposta desejada (esperada) do filtro $d(k)$ pela saída obtida do filtro $y(k)$:

$$e(k) = d(k) - y(k) \quad (3.5)$$

Uma conceito utilizado em filtros adaptativos é o Erro Quadrático Médio (EQM), o qual representa a esperança do quadrado da diferença entre a resposta desejada e a saída do filtro obtido, matematicamente temos:

$$\xi(k) = E[e^2(k)] = E[(d(k) - y(k))^2] = \xi(k) = E[e^2(k)] = E[d(k)^2 - 2d(k)y(k) + y(k)^2] \quad (3.6)$$

Nota-se que quanto mais precisa a saída do filtro, menor a diferença entre a resposta desejada (erro) e conseqüentemente menor será a função custo $\xi(k)$.

Substituindo a equação 3.4 na equação 3.6, obtemos:

$$\begin{aligned} E[e^2(k)] &= \xi(k) \\ &= E[d(k)^2 - 2d(k)\mathbf{w}^T(k)\mathbf{x}(k) + \mathbf{w}^T(k)\mathbf{x}(k)\mathbf{x}^T(k)\mathbf{w}(k)] \\ &= E[d(k)^2] - 2E[d(k)\mathbf{w}^T(k)\mathbf{x}(k)] + E[\mathbf{w}^T(k)\mathbf{x}(k)\mathbf{x}^T(k)\mathbf{w}(k)] \end{aligned} \quad (3.7)$$

Considerando o operador E linear e o vetor $\mathbf{w}$ sendo constante, podemos simplificamos a equação 3.7:

$$\begin{aligned}\xi(k) &= E[d(k)^2] - 2\mathbf{w}^T(k)E[d(k)\mathbf{x}(k)] + \mathbf{w}^T(k)E[\mathbf{x}(k)\mathbf{x}^T(k)]\mathbf{w} \\ &= E[d(k)^2] - 2\mathbf{w}^T\mathbf{p} + \mathbf{w}^T\mathbf{R}\mathbf{w}\end{aligned}\quad (3.8)$$

onde $\mathbf{p} = E[d(k)\mathbf{x}(k)]$ é o vetor de correlação cruzada entre a resposta desejada e o vetor de entradas e $\mathbf{R} = E[\mathbf{x}(k)\mathbf{x}^T(k)]$ é matriz de autocorrelação das amostras de entradas.

Para encontrar o mínimo da função custo $\xi(k)$ precisamos encontrar o gradiente $\mathbf{g}_{\mathbf{w}}$ em relação a $\mathbf{w}$, sendo:

$$\begin{aligned}\mathbf{g}_{\mathbf{w}} &= \frac{\partial \xi}{\partial \mathbf{w}} = \left[\frac{\partial \xi}{\partial w_0} \quad \frac{\partial \xi}{\partial w_1} \quad \cdots \quad \frac{\partial \xi}{\partial w_N} \right]^T \\ &= -2\mathbf{p} + 2\mathbf{R}\mathbf{w} \\ &= 2(\mathbf{R}\mathbf{w} - \mathbf{p})\end{aligned}\quad (3.9)$$

Igualando a equação 3.9 a zero ($\mathbf{g}_{\mathbf{w}} = 0$) e isolando $\mathbf{w}$, encontramos o vetor dos coeficientes ótimos do filtro $\mathbf{w}_o$, conhecida como solução da equação de *Wiener-Hopf*:

$$\mathbf{R}\mathbf{w}_o = \mathbf{p} \quad (3.10)$$

$$\mathbf{w}_o = \mathbf{R}^{-1}\mathbf{p} \quad (3.11)$$

onde $\mathbf{R}^{-1}$ é a matriz inversa de $\mathbf{R}$, reescrevendo $\mathbf{R}$ e $\mathbf{p}$, temos:

$$\mathbf{R} = \begin{bmatrix} E[x_0(k)^2] & E[x_0(k)x_1(k)] & \cdots & E[x_0(k)x_N(k)] \\ E[x_1(k)x_0(k)] & E[x_1(k)^2] & \cdots & E[x_1(k)x_N(k)] \\ \vdots & \vdots & \ddots & \vdots \\ E[x_N(k)x_0(k)] & E[x_N(k)x_1(k)] & \cdots & E[x_N(k)^2] \end{bmatrix} \quad (3.12)$$

$$\mathbf{p} = \begin{bmatrix} E[d(k)x_0(k)] \\ E[d(k)x_1(k)] \\ \vdots \\ E[d(k)x_N(k)] \end{bmatrix} \quad (3.13)$$

Fazendo $d(k + \Delta - 1) = x(k + \Delta - 1)$, significa dizer que estamos tentando prever o sinal $\mathbf{x}(k)$, Δ passos a frente. Utilizando este princípio e rescrevendo a equação 3.11 na forma de somatório, obtemos:

$$\sum_{k=1}^N w_0(m)r_x(k-m) = r_{dx}(k) \quad (3.14)$$

onde $r_x(k - m)$ é correlação entre os valores nas entradas do filtro, descrita como:

$$r_x(k - m) = E[x(n - m)x(n - k)] \quad k, m = 1, 2, 3, \dots, N \quad (3.15)$$

e $r_{dx}(k)$ é a correlação cruzada entre as respostas desejada $x(n + \Delta - 1)$ e as entradas do filtro, descrita como:

$$r_{dx}(k) = E[x(n + \Delta - 1)x(n - k)] \quad k = 1, 2, 3, \dots, N \quad (3.16)$$

3.2 Algoritmo de Otimização do Gradiente-Descendente

O método do Gradiente-Descendente é um algoritmo de primeira ordem utilizado para minimizar funções, tentando encontrar um mínimo local utilizando apenas informações do gradiente da função a ser minimizada (GULER, 2010).

Definição 23 *Seja U um conjunto não vazio de $\mathbb{R}^n$ e $f : U \rightarrow \mathbb{R}$ uma função com derivada parcial contínua $\partial f / \partial w_i$, com $i = 0, \dots, n$. Definimos o método do Gradiente-Descendente pela equação:*

$$w_{k+1} = w_k + \gamma \frac{\partial f}{\partial w_i} \quad (3.17)$$

onde γ é a taxa de aprendizado com valor pequeno. Escrevendo na forma vetorial e com o gradiente, temos:

$$\mathbf{w}(k + 1) = \mathbf{w}(k) + \gamma \mathbf{g}_{\mathbf{w}}(k) \quad (3.18)$$

3.3 Algoritmo de Otimização Levenberg-Marquardt

O algoritmo Levenberg-Marquardt objetiva prover solução para o problema da minimização por mínimos quadrados não-linear (GILL; MURRAY; WRIGHT, 1982). Seja o vetor x que representa os parâmetros desconhecidos tal que:

$$z(j) = h(j, x) + r(j) \quad , j = 1, \dots, k \quad (3.19)$$

onde $h(j)$ é a função medida e $r(j)$ corresponde ao erro, ou resíduo. A função a ser minimizada tem a forma:

$$f(x) = \frac{1}{2} \sum_{j=1}^m r_j^2(x) \quad (3.20)$$

Escrevendo em forma matricial o vetor de erro $\mathbf{r}(x) = (r_1(x), r_2(x), \dots, r_m(x))$, pode-se representar f como $f(x) = \frac{1}{2} \|\mathbf{r}(x)\|^2$. As derivadas de f podem ser escritas usando a matriz Jacobiana J de r definida como $J(x) = \frac{\partial r_j}{\partial x_i}$, $1 \leq j \leq m$ e $1 \leq i \leq n$. O mínimo da função f é encontrado fazendo o gradiente de f igual a zero, $\nabla f(x) = 0$.

O gradiente da função $f(x)$ assim como a Hessiana ($\nabla^2 f(x)$) podem ser dados em função da Jacobiana de $r_j(x)$:

$$\nabla f(x) = \sum_{j=1}^m r_j(x) \nabla r_j(x) = J(x)^T r(x) \quad (3.21)$$

$$\nabla^2 f(x) = J(x)^T r(x) + \sum_{j=1}^m r_j(x) \nabla r_j(x) \quad (3.22)$$

Pode-se demonstrar que a matriz Hessiana é aproximada por $\nabla^2 f(x) = J(x)^T J(x)$ pra resíduos pequenos. Levenberg propôs uma combinação entre métodos de gradiente descendente e de Newton para resolver a equação $\nabla f(x) = 0$, o qual pode ser dado pela seguinte equação de atualização:

$$\alpha_{i+1} = \alpha_i - (H + \eta \text{diag}(H))^{-1} \nabla \Phi(\alpha_i) \quad (3.23)$$

onde H é a matriz Hessiana avaliada em x_i .

3.4 Mínimos Quadrados Médios (LMS - *Least Mean Square*)

A equação 3.11 obtida na seção 3.2 não apresenta um bom resultado já que na prática não conseguimos obter o valor de $\mathbf{R}$ e $\mathbf{p}$ (DINIZ, 2008, p. 36). Caso boas estimativas $\hat{\mathbf{R}}$ e $\hat{\mathbf{p}}$ estejam disponíveis podemos aplicar o algoritmo Gradiente-descendente para encontrar uma solução (mínimo local) para a equação 3.11, como se segue:

$$\begin{aligned} \mathbf{w}(k+1) &= \mathbf{w}(k) + \mu \hat{\mathbf{g}}_{\mathbf{w}}(k) \\ &= \mathbf{w}(k) + 2\mu(\hat{\mathbf{p}}(k) - \hat{\mathbf{R}}(k)\mathbf{w}(k)) \end{aligned} \quad (3.24)$$

Uma boa solução é estimar o gradiente empregando as estimativas instantâneas para $\mathbf{R}$ e $\mathbf{p}$ como se segue:

$$\hat{\mathbf{R}} = \mathbf{x}(k)\mathbf{x}^T(k) \quad (3.25)$$

$$\hat{\mathbf{p}} = d(k)\mathbf{x}^T(k) \quad (3.26)$$

Substituindo as equações 3.25 e 3.26 na equação 3.24:

$$\begin{aligned} \hat{\mathbf{g}}_{\mathbf{w}} &= -2d(k)\mathbf{x}(k) + 2\mathbf{x}(k)\mathbf{x}^T(k)\mathbf{w}(k) \\ &= 2\mathbf{x}(k)(-d(k) + \mathbf{x}^T(k)\mathbf{w}(k)) \\ &= 2\mathbf{x}(k)(-d(k) + y(k)) \end{aligned} \quad (3.27)$$

Substituindo a equação 3.5 na equação 3.27 obtemos:

$$\hat{\mathbf{g}}_w = -2e(k)\mathbf{x}(k) \quad (3.28)$$

O algoritmo gerado baseado na estimativa do gradiente da equação 3.28 é conhecido como *Least Mean Square* (LMS), tendo como equação adaptativa:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + 2\gamma e(k)\mathbf{x}(k) \quad (3.29)$$

3.5 Algoritmo *Fuzzy LMS*

Considere o vetor de entrada $[x(k)]$ com $x(k) \in U \equiv [C_1^-, C_1^+] \times [C_2^-, C_2^+] \dots [C_n^-, C_n^+] \subset R^n$ onde U representa o espaço das amostras de entrada do filtro e R o espaço do vetor de saída $[d(k)]$, sendo $k = 0, 1, 2, \dots$ o instante de tempo.

O problema se torna encontrar um filtro adaptativo $f_k : U \subset R^n \rightarrow R$ tal que a seguinte equação:

$$L = \frac{1}{2} E[(d(k) - f_k(x(k)))^2] \quad (3.30)$$

seja minimizada.

O projeto do filtro adaptativo LMS Fuzzy descrito por (WANG, 1994), segue os seguintes passos:

- **Passo 1:** Defina M conjuntos *fuzzy* F_i^l para cada intervalo $[C_i^-, C_i^+]$ do espaço de entrada U , com sua função de pertinência sendo:

$$\mu_{F_i^l} = \exp \left[-\frac{1}{2} \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right] \quad (3.31)$$

- **Passo 2:** Construa um conjunto de regra SE-ENTÃO da seguinte forma:

$$R^l = \begin{cases} \text{Se } x_1 \text{ é } F_1^l \text{ e } \dots \text{ e } x_n \text{ é } F_n^l \\ \text{Então } d \text{ é } G^l \end{cases} \quad (3.32)$$

onde $x = (x_1, \dots, x_n)^T \in U$, $d \in R$ e F^l definida no passo 1, com sua função de pertinência $\mu_{F_i^l}$.

- **Passo 3:** Construa o filtro adaptativo, que é equivalente a expansão de *fuzzy basis function* (FBF) (WANG, 1994), representado pela equação:

$$f_k(x) = \frac{\sum_{l=1}^M \theta^l (\prod_{i=1}^n \mu_{F_i^l}(x_i))}{\sum_{l=1}^M (\prod_{i=1}^n \mu_{F_i^l}(x_i))} \quad (3.33)$$

- **Passo 4:** Utilizando o algoritmo definido em (KUO; LEE; TIAN, 2013), atualize os parâmetros θ^l , $\bar{x}_i^l$ e σ_i^l .

3.5.1 Algoritmo Adaptativo LMS para Treinamento dos Parâmetros do Modelo *Fuzzy*

Utilizando o método do Gradiente-descendente (3.2), necessitamos encontrar a derivada da equação 3.30 para utilizarmos como uma aproximação para o gradiente do método.

Rescrevendo $f_k(x(k))$, temos:

$$f = f_k(x(k)) = \frac{a}{b} \quad (3.34)$$

onde a é dado por:

$$a = \sum_{l=1}^M \theta^l z^l \quad (3.35)$$

e

$$b = \sum_{l=1}^M z^l \quad (3.36)$$

onde z^l é dado por:

$$z^l = \prod_{i=1}^n a_i^l \exp \left(- \left(\frac{x_i^l - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \quad (3.37)$$

Derivando a equação 3.30 em relação a $\bar{x}_i^l$, observamos que apenas f é dependente de z_i^l , sendo z^l dependente de $\bar{x}_i^l$. Utilizando a regra da cadeia, temos:

$$\frac{\partial L}{\partial \bar{x}_i^l} = \frac{\partial L}{\partial z^l} \frac{\partial z^l}{\partial \bar{x}_i^l} \quad (3.38)$$

Derivando L em relação a z^l , obtemos:

$$\frac{\partial L}{\partial z^l} = (d - f) \frac{(\theta^l - f)}{b} \quad (3.39)$$

Derivando z^l em relação a $\bar{x}_i^l$, obtemos:

$$\begin{aligned} \frac{\partial z^l}{\partial \bar{x}_i^l} &= \frac{\partial}{\partial \bar{x}_i^l} \left[\exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right] \prod_{k=1; k \neq i}^n a_k^l \exp \left(- \left(\frac{x_k^l - \bar{x}_k^l}{\sigma_k^l} \right)^2 \right) \\ \frac{\partial z^l}{\partial \bar{x}_i^l} &= \left[2 \frac{(x_i - \bar{x}_i^l)}{(\sigma_i^l)^2} \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right] \prod_{k=1; k \neq i}^n a_k^l \exp \left(- \left(\frac{x_k^l - \bar{x}_k^l}{\sigma_k^l} \right)^2 \right) \end{aligned} \quad (3.40)$$

Simplificando a equação 3.40, obtemos a equação:

$$\frac{\partial z^l}{\partial \bar{x}_i^l} = 2 \frac{(x_i - \bar{x}_i^l)}{(\sigma_i^l)^2} \prod_{i=1}^n a_i^l \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \quad (3.41)$$

Substituindo a equação 3.37 na equação 3.41, obtemos a forma final para a derivada de z^l em relação a $\bar{x}_i^l$:

$$\frac{\partial z^l}{\partial \bar{x}_i^l} = 2 \frac{(x_i - \bar{x}_i^l)}{(\sigma_i^l)^2} z^l \quad (3.42)$$

Substituindo as equações 3.42 e 3.39 na equação 3.38, encontramos a derivada final de L em relação a $\bar{x}_i^l$ como se segue:

$$\frac{\partial L}{\partial \bar{x}_i^l} = (d - f) \frac{(\theta^l - f)}{b} 2z^l \frac{(x_i - \bar{x}_i^l)}{(\sigma_i^l)^2} \quad (3.43)$$

Repetindo o mesmo procedimento para σ_i^l e θ^l , encontramos as respectivas equações:

$$\frac{\partial L}{\partial \sigma_i^l} = (d - f) \frac{(\theta^l - f)}{b} z^l \frac{(x_i - \bar{x}_i^l)^2}{(\sigma_i^l)^3} \quad (3.44)$$

$$\frac{\partial L}{\partial \theta^l} = (d - f)(\theta^l - f) \frac{z^l}{b} \quad (3.45)$$

O algoritmo adaptativo para treinamento do modelo *fuzzy* consiste em utilizar as equações obtidas anteriormente e utilizá-las no método Gradiente-descendente através das seguintes equações:

$$\theta^l(k) = \theta^l(k-1) - \gamma \frac{\partial L}{\partial \theta^l} \quad (3.46)$$

$$\bar{x}_i^l(k) = \bar{x}_i^l(k-1) - \gamma \frac{\partial L}{\partial \bar{x}_i^l} \quad (3.47)$$

$$\sigma_i^l(k) = \sigma_i^l(k-1) - \gamma \frac{\partial L}{\partial \sigma_i^l} \quad (3.48)$$

Com as equações 3.46, 3.47 e 3.48 adaptativas, definimos a execução do algoritmo Fuzzy LMS pelos passos seguintes:

Passo 1: Inicialize os parâmetros $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ aleatoriamente.

Passo 2: Atualize os parâmetros do modelo utilizando as equações 3.46, 3.47 e 3.48, representadas em sua forma estendida:

$$\theta^l(k) = \theta^l(k-1) + \gamma [d(k) - f_k] \frac{z^l(k-1)}{b(k-1)} \quad (3.49)$$

$$\bar{x}_i^l(k) = \bar{x}_i^l(k-1) + \gamma [d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{x_i(k) - \bar{x}_i^l(k-1)}{(\sigma_i^l(k-1))^2} \quad (3.50)$$

$$\sigma_i^l(k) = \sigma_i^l(k-1) + \gamma [d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{(x_i(k) - \bar{x}_i^l(k-1))^2}{(\sigma_i^l(k-1))^3} \quad (3.51)$$

onde

$$z^l(k-1) = \prod_{i=1}^n \exp \left[-\frac{1}{2} \left(\frac{x_i(k) - \bar{x}_i^l(k-1)}{\sigma_i^l(k-1)} \right)^2 \right] \quad (3.52)$$

e

$$b(k-1) = \sum_{l=1}^M z^l(k-1) \quad (3.53)$$

para $l = 1, 2, \dots, M$, $i = 1, 2, \dots, n$ e γ sendo a taxa de aprendizagem $0 < \gamma < 1$.

Passo 3: Realize novamente o passo 2, fazendo $k = k + 1$ até o instante desejado.

3.6 Algoritmo *Fuzzy RLS*

Considere um vetor de entrada $[x(k)]$ satisfazendo a seguinte equação:

$$x(k) \in U \equiv [C_1^-, C_1^+] x [C_2^-, C_2^+] \dots [C_n^-, C_n^+] \subset R^n \quad (3.54)$$

onde U representa o espaço de entrada do filtro e R o espaço do vetor de saída $d[(k)]$, com $k = 0, 1, 2, \dots$ sendo o instante de tempo.

O problema se torna encontrar um filtro adaptativo $f_k : U \subset R^n \rightarrow R$ tal que a seguinte equação:

$$J(k) = \sum_{i=0}^k \lambda^{k-i} [d(i) - f_k(x(i))]^2 \quad (3.55)$$

seja minimizada, onde $\lambda \in (0, 1]$ representa o fator de esquecimento.

Dado os valores de tempo $k = 0, 1, 2, \dots$ com as respectivas amostras $x(k)$ e $d(k)$, desejamos encontrar um filtro $f_{k-1} : U \rightarrow R$ tal que $f_{k-1}[d(k-1), \dots, d(k-n)]$ seja uma ótima predição para $d(k)$. Fazendo $x(k) = [y(k-1), \dots, y(k-n)]^T$ e $d(k) = y(k)$ podemos observar que o objetivo se torna minimizar a mesma função custo $J(k)$.

Defina m_i conjuntos *fuzzy* rotulados como F_i^{ji} ($i = 1, 2, \dots, n$ $ji = 1, 2, \dots, m_i$), satisfazendo ao respectivo intervalo $[C_i^-, C_i^+]$ do espaço de entrada U , tal que a função $\mu_{F_i^{ji}}$ obedeça ao intervalo $[C_i^-, C_i^+]$, fazendo $x_i \in [C_i^-, C_i^+]$ em que exista pelo menos um $\mu_{F_i^{ji}}$ diferente de zero.

Podemos construir um conjunto de regras *fuzzy* IF-THEN da seguinte forma:

$$R^{(j^1, \dots, j^n)} : \text{Se } x_1 \text{ é } F_1^{j^1} \text{ e } \dots \text{ e } x_n \text{ é } F_n^{j^n}, \text{ entao } d \text{ é } G^{(j^1, \dots, j^n)} \quad (3.56)$$

Utilizando defuzzificação através do centro médio e inferência por produto, obtemos para o filtro f_k a seguinte equação:

$$f_k(x) = \frac{\sum_{j^1=1}^{m_1} \dots \sum_{j^n=1}^{m_n} \theta^{(j^1, \dots, j^n)} (\mu_{F_1^{j^1}}(x_1) \dots \mu_{F_n^{j^n}}(x_n))}{\sum_{j^1=1}^{m_1} \dots \sum_{j^n=1}^{m_n} (\mu_{F_1^{j^1}}(x_1) \dots \mu_{F_n^{j^n}}(x_n))} \quad (3.57)$$

onde $\theta^{(j^1, \dots, j^n)} \in R$ representa o ponto ao qual a função $\mu_{G^{(j^1, \dots, j^n)}}$ atinge seu valor máximo.

Definindo θ pela seguinte equação

$$\begin{aligned} \theta = & (\theta^{(1,1,\dots,1)}(x), \dots, \theta^{(m_1,1,\dots,1)}(x); \\ & \theta^{(1,2,1,\dots,1)}(x), \dots, \theta^{(m_1,2,1,\dots,1)}(x), \dots; \\ & \theta^{(1,m_2,1,\dots,1)}(x), \dots, \theta^{(m_1,m_2,1,\dots,1)}(x), \dots; \\ & \theta^{(1,m_2,\dots,m_n)}(x), \dots, \theta^{(m_1,m_2,\dots,m_n)}(x))^T \end{aligned} \quad (3.58)$$

Definimos as funções de base *fuzzy* (*fuzzy basis function*) $p^{(j^1, \dots, j^n)}(x)$ como:

$$p^{(j^1, \dots, j^n)}(x) = \frac{\mu_{F_1}^{j^1}(x_1) \dots \mu_{F_n}^{j^n}(x_n)}{\sum_{j^1=1}^{m_1} \dots \sum_{j^n=1}^{m_n} (\mu_{F_1}^{j^1}(x_1) \dots \mu_{F_n}^{j^n}(x_n))} \quad (3.59)$$

$$\begin{aligned} p(x) = & (p^{(1,1,\dots,1)}(x), \dots, p^{(m_1,1,\dots,1)}(x); \\ & p^{(1,2,1,\dots,1)}(x), \dots, p^{(m_1,2,1,\dots,1)}(x), \dots; \\ & p^{(1,m_2,1,\dots,1)}(x), \dots, p^{(m_1,m_2,1,\dots,1)}(x), \dots; \\ & p^{(1,m_2,\dots,m_n)}(x), \dots, p^{(m_1,m_2,\dots,m_n)}(x))^T \end{aligned} \quad (3.60)$$

onde $p(x)$ é escrito na mesma forma que 3.59.

Utilizando as equações 3.59 e 3.59 para reescrever a equação 3.57, obtemos a seguinte função:

$$f_k(x) = p^T(x)\theta \quad (3.61)$$

3.6.1 Atualização do parâmetro θ no Algoritmo Fuzzy RLS

Observando a equação 3.61 notamos que f_x é linear nos parâmetros, podendo assim empregar o algoritmo *Fast-RLS* (DINIZ, 2008) para atualizar o parâmetro θ .

Inicialize $\theta(0)$ de acordo com 3.59 e $P(0) = \sigma I$, onde σ é um pequeno valor positivo e I uma matriz identidade.

A cada iteração do algoritmo pode-se adaptar os parâmetros de acordo com as seguintes equações:

$$\phi(k) = p(x(k)) \quad (3.62)$$

$$P(k) = \frac{1}{\lambda} [P(k-1) - P(k-1)\phi(k)(\lambda + \phi^T(k)P(k-1)\phi(k))^{-1} \phi^T(k) P(k-1)] \quad (3.63)$$

$$K(k) = P(k-1)\phi(k)[\lambda + \phi^T(k)P(k-1)\phi(k)]^{-1} \quad (3.64)$$

$$\theta(k) = \theta(k-1) + K(k)(d(k) - \phi^T(k)\theta(k-1)) \quad (3.65)$$

onde λ é o fator de esquecimento definido pela equação 3.55 do custo a ser minimizado.

4 Esquema de Alocação de Banda Utilizando Preditor Fuzzy Adaptativo de Tráfego de Redes Baseado na Função de Autocorrelação de um Modelo Multifractal

A modelagem *fuzzy* tem sido bastante empregada em vários campos de pesquisa desde que a teoria *fuzzy* foi inicialmente desenvolvida (BEZDEK, 1993) (ROSS, 2009). A razão para estas pesquisas é que os modelos *fuzzy* possuem certas vantagens com relação a determinados sistemas sobre modelos lineares, como por exemplo, na descrição de processos reais desconhecidos, com características não-lineares e variantes no tempo, como o tráfego de redes (CHEN; PENG; WANG, 2000). Entre os modelos *fuzzy* propostos, particularmente o modelo nebuloso descrito em (KIM et al., 1997) é capaz de descrever um sistema desconhecido usando um pequeno número de regras nebulosas como o faz o modelo de Takagi e Sugeno (TAKAGI; SUGENO, 1985) e é de fácil implementação como o modelo de Sugeno e Yasukawa (SUGENO; YASUKAWA, 1993). Porém, estes trabalhos não apresentam algoritmos adaptativos de treinamento para os modelos *fuzzy*, ou seja, para modelagem de uma série temporal são necessárias todas as amostras da série em questão. Algoritmos adaptativos são mais adequados para aplicações multimídia em tempo real nas redes atuais devido ao processamento mais rápido das informações (LIU; HSU, 2006). Tendo em vista isso, apresentamos um novo modelo *fuzzy* capaz de prever eficientemente o tráfego de redes através da função de autocorrelação do modelo multifractal à medida que dados de tráfego de entrada vão sendo disponibilizados.

Apresentamos neste capítulo o algoritmo proposto de predição adaptativo *fuzzy* utilizando a função de autocorrelação da modelagem multifractal. Aplicamos também o algoritmo proposto em um esquema de alocação de banda adaptativa para fluxo de tráfego de rede.

4.1 Algoritmo Fuzzy LMS com Autocorrelação Multifractal

A predição da taxa futura dos fluxos de tráfego, quando devidamente aplicada a mecanismos de controle, pode vir a proporcionar ganhos de desempenho e consequentemente oferecer melhora de eficiência na utilização dos recursos da rede de comunicações.

A constatação da autossimilaridade no tráfego de diferentes ambientes de rede (PARK; WILLINGER, 2000) despertou o interesse dos pesquisadores em saber como esta

característica poderia ser utilizada na predição de tráfego. Em seguida, foi apresentado (GRIPENBERG; NORROS, 1996) um preditor ótimo em tempo contínuo para o fBm (movimento Browniano fracionário). Neste mesmo trabalho, os autores também mostram que a presença da autossimilaridade não torna mais precisos os resultados da predição, e sim, apenas faz com que seja possível a realização de predição em diferentes escalas temporais.

Para a predição de processos discretos são necessários preditores em tempo discreto. Hirchoren e Arantes (1998) apresentam um preditor linear em tempo discreto para o ruído gaussiano fracionário, onde usam o preditor de Wiener, e reafirmam através de resultados teóricos e simulados as constatações apresentadas por Gripenberg e Norros (1996).

Como se pode perceber nas equações de *Wiener-Hopf* apenas o valor quadrático médio dos valores presentes nas entradas, a correlação entre estes valores, e a correlação cruzada entre o valor desejado e os valores nas entradas do filtro são necessários para a obtenção dos coeficientes. Ou seja, a obtenção dos coeficientes ótimos do filtro de *Wiener* requer apenas o conhecimento das estatísticas de primeira e segunda ordem do sinal de interesse.

Souza e Vieira (2012) utilizaram um modelo multifractal para o tráfego de redes que possui combinação de uma cascata multiplicativa com um processo independente lognormal, onde a seguinte equação,

$$E[X(n), X(n+k)] = e^{2\rho+\sigma^2} \left(\frac{\alpha(\alpha+1)^{N-1}}{(\alpha+1/2)^N} k^{-\log_2(\frac{\alpha+1}{\alpha+1/2})} \right)$$

da função de autocorrelação do modelo multifractal, foi inserida no algoritmo de *Wiener* para calcular os coeficientes do filtro, dado pela seguinte equação:

$$\sum_{k=1}^N w_0(m) E[x(n-m)x(n-k)] = E[x(n+\Delta-1)x(n-k)] \quad k = 1, 2, 3, \dots, N \quad (4.1)$$

Ao utilizar a função de autocorrelação do modelo multifractal, (SOUZA; VIEIRA, 2012) obteve-se EQM's (Erro Quadrático Médio) menores em comparação aos algoritmos clássicos da literatura.

A abordagem de predição proposta neste trabalho, a qual chamaremos de Fuzzy LMS com Autocorrelação Multifractal, consiste em aproveitar o modelo descrito por Souza e Vieira (2012) e introduzir a modelagem *fuzzy* com o objetivo de melhorar a descrição não-linear do tráfego de rede a ser predito, substituindo a seguinte equação:

$$\theta^l(k) = \theta^l(k-1) + \gamma[d(k) - f_k] \frac{z^l(k-1)}{b(k-1)}$$

de adaptação do parâmetro θ pela equação dos coeficientes do filtro dado em relação a função de autocorrelação multifractal descrito por Souza e Vieira (2012).

Definimos o algoritmo Fuzzy LMS com Autocorrelação Multifractal pelos seguintes passos:

- **Passo 1:** Execute o algoritmo de Levenberg-Marquardt para calcular o parâmetro α multifractal adaptativamente descrito na seção 3.3.
- **Passo 2:** Calcule a função de autocorrelação multifractal através do valor do parâmetro α multifractal, utilizando a seguinte equação:

$$E[X(n), X(n+k)] = e^{2\rho+\sigma^2} \left(\frac{\alpha(\alpha+1)^{N-1}}{(\alpha+1/2)^N} k^{-\log_2(\frac{\alpha+1}{\alpha+1/2})} \right)$$

- **Passo 3:** Calcule os pesos ótimos do filtro de Wiener utilizando a função de autocorrelação multifractal, através da seguinte equação:

$$\sum_{k=1}^N w_0(m) E[x(n-m)x(n-k)] = E[x(n+\Delta-1)x(n-k)] \quad k = 1, 2, 3, \dots, N$$

- **Passo 4:** Substitua o parâmetro θ do modelo Fuzzy LMS pelos pesos ótimos do filtro de Wiener.
- **Passo 5:** Realize a adaptação dos parâmetros $\bar{x}_i^l$ e σ_i^l do modelo Fuzzy LMS.

$$\bar{x}_i^l(k) = \bar{x}_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{x_i(k) - \bar{x}_i^l(k-1)}{(\sigma_i^l(k-1))^2}$$

$$\sigma_i^l(k) = \sigma_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{(x_i(k) - \bar{x}_i^l(k-1))^2}{(\sigma_i^l(k-1))^3}$$

- **Passo 6:** A cada iteração realize os passos 1 até o 5 novamente, até que sejam realizadas todas iterações.

A Figura 20 mostra os passos de execução do algoritmo Fuzzy LMS com Autocorrelação Multifractal através de um fluxograma.

4.1.1 Avaliação dos Preditores

Na presente seção, apresentamos avaliações comparativas entre o desempenho do preditor proposto e o desempenho de outros três diferentes preditores, quando aplicados a traços de tráfego TCP/IP e Ethernet. Os outros preditores levados em consideração foram: o LMS (*Least Mean Square*) (TOREYIN et al., 2006) (HAYKIN, 1989), o Fuzzy RLS (*Recursive Least Square*) (WANG, 1994) e o Fuzzy LMS (WANG, 1994) (LEE, 1996).

As séries de tráfego de rede foram obtidas do WAND Network Research Group (ver seção 1.3) da Waikato University no período de 7 de Abril a 5 de Novembro (WITS, 2014) e Digital Equipment Corporation (DEC) (DEC, 1995)(PAXSON; FLOYD, 1995). As




Figura 20 – Fluxograma do algoritmo Fuzzy LMS com Autocorrelação Multifractal.

séries de tráfego de rede escolhidos para este capítulo são: Waikato VIII 20111029-110001-1 agregadas em 10ms, 100ms e 512ms e dec-pkt-2 agregada em 512ms. Nota-se que as séries de tráfego de rede possuem indícios de características fractais conforme nas seções 1.7 e 1.8.

Os algoritmos foram executados em um computador Notebook Positivo SIM 5160 com processador Intel Pentium T4500 de 2.3GHZ, 1MB de memória cache e com uma memória RAM de capacidade 4GB (INTEL, 2014).

Utilizamos inicialmente o conceito de erro quadrático médio (EQM) na análise de desempenho de predição. Avaliamos o preditor proposto utilizando duas medidas relativas de erro. Conhecidos como erros quadráticos médios normalizados (EQMN), a primeira medida consiste em normalizar o EQM em relação à variância da série predita, enquanto a segunda medida consiste em normalizar o EQM em relação ao erro quadrático médio do preditor ótimo para o processo passeio aleatório (*random walk*) (PAPOULIS, 1984). As definições dos EQMN's são dadas a seguir.

Definição 24 *Seja o processo X , onde $\hat{x}$ é a predição do valor desejado x , defini-se o erro quadrático médio como:*

$$EQM = E[(\hat{x} - x)^2] \quad (4.2)$$

Definição 25 Seja σ_x^2 a variância do processo X , dada por $\sigma_x^2 = E[(\mu - x)^2]$ onde μ é a média do processo, define-se o erro quadrático médio normalizado do tipo 1 como:

$$EQMN1 = \frac{EQM}{\sigma_x^2} = \frac{E[(\hat{x} - x)^2]}{E[(\mu - x)^2]} \quad (4.3)$$

Definição 26 Seja $\hat{x}_{pa}$ o valor predito da amostra do processo X , cujo valor é o mesmo da amostra imediatamente anterior do processo. Define-se o erro quadrático médio normalizado do tipo 2 como:

$$EQMN2 = \frac{EQM}{\sigma_x^2} = \frac{E[(\hat{x} - x)^2]}{E[(\hat{x}_{pa} - x)^2]} \quad (4.4)$$

De acordo com as definições anteriores, um preditor que apresente um valor de $EQMN1$ igual ou inferior a 1 possuirá desempenho igual ou superior a um preditor que apenas estime o valor futuro como sendo igual à média do processo. Para um $EQMN2$ próximo a 1, teremos que o preditor analisado apresentará desempenho próximo ao de um preditor que estime o valor futuro como sendo igual ao valor imediatamente anterior.

Os parâmetros $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ dos algoritmos Fuzzy (Fuzzy LMS, Fuzzy RLS e Fuzzy LMS com Autocorrelação Multifractal) foram inicializados aleatoriamente no intervalo $[-0.5, 0.5]$, $[-2, 2]$, $[0.1, 0.3]$, respectivamente (WANG, 1994). As taxas de aprendizagem γ dos algoritmos Fuzzy LMS, e Fuzzy LMS com Autocorrelação Multifractal foram inicializados $\alpha = 0.05$, enquanto os parâmetros σ e λ do algoritmo Fuzzy RLS foram inicializados como sendo 0.96 e 0.01, respectivamente. Os valores escolhidos para esses parâmetros estão de acordo com Wang (1994). O número de regras *fuzzy* foi considerado como $M = 48$ para todos os algoritmos *fuzzy*.

Tabela 2 – Erros Quadrático Médio para a série de tráfego de Waikato VIII 20111029-110001-1 agregada em 10ms.

Ordem n	EQM	EQMN1	EQMN2
13	0.0073	0.4874	0.3358
12	0.0068	0.4446	0.3039
11	0.0075	0.4972	0.3426
10	0.0076	0.5036	0.3469
9	0.0086	0.5707	0.3932

Tabela 3 – Erros Quadrático Médio para a série de tráfego de Waikato VIII 20111029-110001-1 agregada em 100ms.

Ordem n	EQM	EQMN1	EQMN2
13	0.0086	0.3344	0.2767
12	0.0082	0.3222	0.2727
11	0.0091	0.3551	0.2939
10	0.0103	0.3989	0.3302
9	0.0111	0.4297	0.3556

Tabela 4 – Erros Quadrático Médio para a série de tráfego de Waikato VIII 20111029-110001-1 agregada em 512ms.

Ordem n	EQM	EQMN1	EQMN2
13	0.0026	0.1273	0.2734
12	0.0025	0.1228	0.2578
11	0.0026	0.1280	0.2749
10	0.0033	0.1613	0.3466
9	0.0041	0.2022	0.4343

A ordem n dos algoritmos foi escolhida de forma a obter os menores valores de Erro Quadrático Médio possíveis. Nota-se que quanto maior a ordem dos algoritmos, maior a complexidade e maior é o tempo de execução dos algoritmos (FARHANG-BOROUJENY, 1999). As Tabelas 2, 3 e 4 mostram os erros de predição do algoritmo Fuzzy LMS com Autocorrelação Multifractal para $n = 9, 10, 11, 12, 13$, utilizando a série de tráfego Waikato VIII 20111029-110001-1 agregada em 10ms, 100ms e 512ms. Nota-se que os algoritmos conseguiram obter os menores valores de EQM para ordem $n = 12$. Escolhemos assim a ordem $n = 12$, para a simulação (seção 4.1.1.1) de predição utilizando a série Waikato VIII 20111029-110001-1 nas três escalas de agregação.

Tabela 5 – Erros Quadrático Médio para a série de tráfego de rede dec-pkt-2 agregada em 512ms.

Ordem n	EQM	EQMN1	EQMN2
13	0.0057	0.3429	0.4224
12	0.0055	0.3291	0.4055
11	0.0065	0.3914	0.4823
10	0.0072	0.4249	0.5297
9	0.0082	0.4932	0.6077

A Tabela 5 mostra os Erros Quadráticos Médios para a série de tráfego de rede dec-pkt-2 agregada em 512ms para $n = 9, 10, 11, 12, 13$, utilizando o algoritmo Fuzzy LMS com Autocorrelação Multifractal. Nota-se que assim como nos exemplos anteriores, o algoritmo obteve o menor valor de EQM para $n = 12$. Escolhemos então o valor $n = 12$, na simulação de predição da série de tráfego dec-pkt-2 (4.1.1.2).

4.1.1.1 Resultado para a Série de Tráfego de rede Waikato VIII 20111029-110001-1

Nesta seção apresentamos os resultados de predição para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada nas seguintes escalas 10ms, 100ms e 512ms.

A Figura 21 mostra a evolução de α em relação ao tempo (iterações) utilizando o algoritmo Levenberg-Marquardt para a série de tráfego de rede Waikato VIII 20111029-110001-1.




Figura 21 – Algoritmo Levenberg-Marquardt para atualização de α para a série de tráfego de rede Waikato VIII 20111029-110001-1.

A Figura 22 mostra a evolução do Erro Quadrático Médio para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 10ms. Podemos observar que os algoritmos obtiveram resultados semelhantes para os valores iniciais da série. O algoritmo LMS foi o que apresentou o maior valor de EQM em comparação aos demais. Nota-se que o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou menores EQM a partir aproximadamente do passo 300.

A Tabela 6 mostra os EQM's e Tempo Computacional para o fluxo de rede Waikato VIII 20111029-110001-1 agregada em 10ms. Assim como na Figura 22 notamos que o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou melhores resultados em termos de EQM em relação aos demais algoritmos apresentados.

Os algoritmos na simulação da série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 10ms apresentaram erros quadráticos médios EQMN1 menores do que 1 para os algoritmos Fuzzy LMS com Autocorrelação Multifractal, Fuzzy LMS e




Figura 22 – Mean Square Error para a série de tráfego Waikato VIII 20111029-110001-1 agregada em 10ms e com $n = 12$ para todos algoritmos.

Tabela 6 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 10ms e com $n = 12$ para todos algoritmos.

Algoritmo	EQM	EQMN1	EQMN2	Tempo Médio(s)	Tempo Total(s)
Fuzzy LMS com Autocorrelação Multifractal	0.0068	0.4446	0.3039	0.0100	12.0433
Fuzzy LMS	0.0139	0.8999	0.6151	4.8037×10^{-4}	0.6240
Fuzzy RLS	0.0138	0.8962	0.6126	3.0023×10^{-4}	0.390
LMS($\gamma = 0.07$)	0.0157	1.0218	0.6984	3.6028×10^{-5}	0.0468

Fuzzy RLS. Esse resultado reforça que esses algoritmos conseguiriam obter uma predição melhor caso fosse estimado o valor futuro igual à média. Nota-se que o algoritmo LMS não apresentou semelhante característica neste caso específico (para este tráfego de rede). Em relação ao erro quadrático médio EQMN2, observamos que todos os algoritmos obtiveram valores inferiores a 1, apresentando melhor predição caso fosse estimado o valor futuro como sendo igual ao valor imediatamente anterior. Destaca-se o algoritmo Fuzzy LMS com Autocorrelação Multifractal que apresentaram ambos EQMN1 e EQMN2 inferiores aos demais algoritmos utilizados nas simulações.

Na Tabela 6 podemos visualizar o tempo computacional médio das iterações dos algoritmos e o tempo computacional total. Os resultados mostram que o algoritmo LMS apresentou o menor tempo computacional com uma média de 3.6028×10^{-5} segundos, seguido pelos algoritmos Fuzzy RLS e Fuzzy LMS respectivamente. O algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou o maior tempo computacional em relação

aos demais algoritmos utilizados, obtendo um tempo computacional médio de 10ms.




Figura 23 – Mean Square Error para a série de tráfego Waikato VIII 20111029-110001-1 agregada em 100ms e com $n = 12$ para todos algoritmos.

A Figura 23 mostra a evolução do Erro Quadrático Médio para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 100ms. A Figura 23 apresenta um EQM maior para o algoritmo Fuzzy RLS em comparação aos demais. Nota-se que aproximadamente a partir do passo 600, podemos observar um EQM menor para o algoritmo Fuzzy LMS com Autocorrelação Multifractal.

Tabela 7 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 100ms e com $n = 12$ para todos algoritmos.

Algoritmo	EQM	EQMN1	EQMN2	Tempo Médio(s)	Tempo Total(s)
Fuzzy LMS com Autocorrelação Multifractal	0.0082	0.3222	0.2727	0.0083	10.0153
Fuzzy LMS	0.0146	0.5756	0.4872	2.1756×10^{-4}	0.2652
Fuzzy RLS	0.0215	0.8480	0.7178	1.9196×10^{-4}	0.2340
LMS($\gamma = 0.08$)	0.0122	0.4820	0.4080	2.5595×10^{-5}	0.0312

A Tabela 7 mostra os EQM's e Tempo Computacional para o fluxo de rede Waikato VIII 20111029-110001-1 agregada em 100ms e reforça os resultados apresentados pela Figura 23, apresentando Erros Quadrático Médio menores para o algoritmo proposto Fuzzy LMS com Autocorrelação Multifractal. Nota-se que todos os algoritmos avaliados apresentaram valores de EQMN1's e EQMN2's inferiores a 1. Destaca-se o algoritmo LMS

que apresentou melhores resultados de EQM's em relação aos algoritmos Fuzzy LMS e Fuzzy RLS, diferentemente do exemplos para a série de tráfego agregada em 10ms.

O tempo computacional apresentado na Tabela 7 mostra a superioridade do algoritmo LMS em relação aos demais quando nos referimos a tempo de execução, apresentando um valor de tempo médio de execução de 2.5595×10^{-5} . O algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou o maior tempo computacional em relação aos demais algoritmos utilizados, obtendo um tempo computacional médio de 0.0083.




Figura 24 – Mean Square Error para a série de tráfego Waikato VIII 20111029-110001-1 agregada em 512ms e com $n = 12$ para todos algoritmos.

A Figura 24 mostra a evolução do Erro Quadrático Médio para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 512ms. Destaca-se o algoritmo proposto Fuzzy LMS com Autocorrelação Multifractal que apresentou Erros Quadrático Médio inferiores aos demais algoritmos em quase todos os passos de execução da simulação. Note-se uma decaimento maior do EQM para o algoritmo Fuzzy RLS aproximadamente a partir do passo 200, onde podemos observar um valor de EQM inferior em relação aos algoritmos Fuzzy LMS e LMS aproximadamente a partir do passo 800.

A Tabela 8 mostra os EQM's e Tempo Computacional para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 512ms. Assim como na Figura 24 notamos que o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou melhores resultados em termos de EQM em relação aos demais algoritmos apresentados.

Os algoritmos na simulação da série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 512ms apresentaram erros quadráticos médios EQMN1 menores do que 1 para todos os algoritmos. Esse resultado reforça que esses algoritmos conseguiram obter uma predição melhor caso fosse estimado o valor futuro igual a média. Em relação

Tabela 8 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 512ms e com $n = 12$ para todos algoritmos.

Algoritmo	EQM	EQMN1	EQMN2	Tempo Médio(s)	Tempo Total(s)
Fuzzy LMS com Autocorrelação Multifractal	0.0025	0.1228	0.2578	0.0083	10.0153
Fuzzy LMS	0.0067	0.3289	0.6906	2.1756×10^{-4}	0.2652
Fuzzy RLS	0.0039	0.1931	0.4054	1.9196×10^{-4}	0.2340
LMS($\gamma = 0.06$)	0.0053	0.2603	0.5466	2.5595×10^{-5}	0.0312

ao erro quadrático médio EQMN2, observamos que todos os algoritmos obtiveram valores inferiores a 1, apresentando melhor predição caso fosse estimado o valor futuro como sendo igual ao valor imediatamente anterior. Destaca-se o algoritmo Fuzzy LMS com Autocorrelação Multifractal que apresentou ambos EQMN1 e EQMN2 inferiores aos demais algoritmos utilizados nas simulações.

Os tempos computacionais apresentados na Tabela 8 representando a série de tráfego Waikato VIII 20111029-110001-1 agregada em 512ms, apresenta similaridades com os resultados apresentados nas Tabelas 22 e 23, representando o mesma série de tráfego nas agregações 10ms e 100ms, respectivamente. Essas similaridades mostram um tempo computacional menor para o algoritmo LMS, seguido dos algoritmos Fuzzy RLS e Fuzzy LMS. O maior tempo computacional nos três casos (10ms, 100ms e 512ms) foi obtido pelo algoritmo proposto Fuzzy LMS com Autocorrelação Multifractal.

Comparando a execução do algoritmo Fuzzy LMS com Autocorrelação Multifractal para as três escalas de agregação (10ms, 100ms e 512ms), observamos uma predição mais precisa para a escala de agregação 512ms, apresentando um EQM igual a 0.0025 enquanto as escalas de agregação 10ms e 100ms apresentaram EQM respectivamente iguais a 0.0068 e 0.0082.

A Figura 25 compara os valores preditos e os valores reais (desejados) do algoritmo Fuzzy LMS com Autocorrelação Multifractal para a série de tráfego de rede Waikato VIII 20111029-110001-1 através de um gráfico quantil-quantil conhecido como QQplot (ROLLS; MICHAILIDIS; HERNÁNDEZ-CAMPOS, 2005). A reta representada pela cor vermelha mostra a curva ideal de predição, indicando uma melhor precisão para valores que se encontram mais próximos da reta. Nota-se que, para a série de tráfego agregada em 10ms, encontramos uma região linear aproximadamente entre 0.1 e 0.3, indicando uma predição adequada para esse intervalo. Ao observamos valores acima e abaixo desse intervalo, encontramos um afastamento da reta ideal, indicando que não houve uma boa predição. Para a escala de agregação 100ms notamos um intervalo linear sobre a reta ideal aproximadamente entre 0.1 e 0.4. Considerando a escala de agregação em 512ms




Figura 25 – QQ-plot para a predição da série de tráfego de rede Waikato VIII 20111029-110001-1 utilizando o algoritmo Fuzzy LMS com Autocorrelação Multifractal com $n = 12$.

encontramos uma linearidade em quase todo o intervalo de valores preditos, indicando valores mais próximos do ideal.

4.1.1.2 Resultado para a Série de Tráfego de rede dec-pkt-2 agregada em 512ms

Nesta seção apresentamos os resultados de predição para a série de tráfego de rede dec-pkt-2 agregada na escalas de 512ms.

A Figura 26 mostra a evolução de α em relação ao tempo (iterações) utilizando o algoritmo Levenberg-Marquardt para a série de tráfego de rede dec-pkt-2 agregada em 512ms.

A Figura 27 mostra a evolução do Erro Quadrático Médio para a série de tráfego de dec-pkt-2 agregada em 512ms. Observamos que o algoritmo LMS apresentou EQM superior em relação aos demais algoritmos em quase toda extensão dos passos de execução.




Figura 26 – Algoritmo Levenberg-Marquardt para atualização de α para a série de tráfego de rede dec-pkt-2 agregada em 512ms.

Observamos também menores EQM para os algoritmos Fuzzy LMS e Fuzzy RLS aproximadamente até o passo 400, onde a partir de um certo momento o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresenta melhores resultados de Erro quadrático médio em comparação aos demais algoritmos.




Figura 27 – Mean Square Error para a série de tráfego dec-pkt-2 agregada em 512ms e com $n = 12$ para todos algoritmos.

A Tabela 9 mostra os EQM's e Tempo Computacional para a série de tráfego de rede dec-pkt-2 agregada em 512ms. Os resultados assim como a Figura 27, apresenta menores valores de EQM para o algoritmo proposto Fuzzy LMS com Autocorrelação Multifractal, com valor igual a 0.0055. O algoritmo LMS apresentou o maior valor de EQM em comparação aos demais. Nota-se que todos algoritmos apresentaram EQMN1's e EQMN2's com valor inferior a 1, com destaque para o algoritmo proposto que apresentou os menores valores para ambos erros quadráticos normalizados.

Tabela 9 – Erros Quadrático Médio e Tempo Computacional para a a série de tráfego de rede dec-pkt-2 agregada em 512ms e com $n = 12$ para todos algoritmos.

Algoritmo	EQM	EQMN1	EQMN2	Tempo Médio(s)	Tempo Total(s)
Fuzzy LMS com Autocorrelação Multifractal	0.0055	0.3291	0.4055	0.0083	10.0153
Fuzzy LMS	0.0087	0.5212	0.6422	2.1756^{-4}	0.2652
Fuzzy LMS	0.0078	0.4663	0.5745	1.9196^{-4}	0.2340
LMS($\gamma = 0.06$)	0.0100	0.6011	0.7407	2.1756×10^{-4}	0.2652

A Figura 28 compara os valores preditos e os valores reais (desejados) do algoritmo Fuzzy LMS com Autocorrelação Multifractal para a série de tráfego de rede dec-pkt-2 agregada em 512ms. Podemos observar que encontramos uma certa região linear próxima da reta ideal de predição, aproximadamente entre o intervalo $[0.1, 0.3]$. Observamos também um distanciamento maior nas extremidades, indicando um predição menos precisa para esses valores.




Figura 28 – QQ-plot para a predição da série de tráfego de rede dec-pkt-2 agregada em 512ms e com $n = 12$ para todos algoritmos.

4.2 Esquema de Alocação de Banda Utilizando Predição Fuzzy

Algumas propostas de alocação de banda para fluxos de tráfego baseadas em predição realizadas por redes neurais e *fuzzy* merecem atenção pois mostram que o controle preventivo de tráfego pode ser bastante eficiente, uma vez que o mesmo tenta reduzir o congestionamento antes que este aconteça e se adapta bem às variações bruscas da série de tráfego de redes (OUYANG; YANG; LIAN, 2006) (AQUINO; BARRIA, 2006).

Os esquemas de alocação de banda para fluxos de tráfego de redes podem se beneficiar de algoritmos de predição da taxa de tráfego de modo a antecipar as ações para alocação de recursos e controle de congestionamento (TRAN; ZIEGLER, 2005). Neste sentido, o passo de predição pode ser ajustado de forma a possibilitar que a rede tenha tempo para obtenção e alocação dos recursos necessários. Precisamente nesta seção, propomos um esquema de alocação dinâmica de banda que considera como entrada as predições realizadas pelo modelo *fuzzy* proposto.

Seja $A(\tau, t)$ um processo a tempo discreto correspondente a série de tráfego acumulado (neste caso, número de *bytes*) no intervalo de tempo (τ, t) e que chega ao servidor para ser transmitido. Para satisfazer um limite de retardo d_{req} , qualquer pacote (ou dados) deve ser transmitido até o instante de tempo $t + d_{req}$. A banda ε , ou seja, a taxa necessária, portanto, para atender a esse critério e para se ter perda nula de tráfego, deve obedecer à seguinte relação:

$$\varepsilon * (t - \tau + d_{req}) \geq A(\tau, t) + b_{t-1} \quad \forall \quad t \geq \tau \quad (4.5)$$

onde b_{t-1} corresponde ao número de *bytes* não escoados pela rede no instante anterior. Note que a relação acima deve ser satisfeita para todo $t \geq 0$ e $\tau \geq 0$ onde $t \geq \tau$. Um

meio de se obter um algoritmo eficiente de estimação de banda é estimar a série de tráfego $A(\tau, t)$ através de seu valor predito $A_p(\tau, t)$, ou seja, prever a taxa com a qual o fluxo será injetado no enlace, de modo que este respeite o limite de retardo estipulado.

O seguinte procedimento para mapear o valor predito da intensidade de tráfego com a banda requerida foi utilizado: Seja ΔBW a quantia de banda finita e C a máxima banda disponível. Determina-se o intervalo de banda $[(k)\Delta BW, (k+1)\Delta BW](k \geq 0)$, no qual o valor predito da taxa P_{t+1} se encontra e usa-se o valor superior do intervalo $(k+1)\Delta BW$ ou a máxima banda disponível C , no caso de $C < (k+1)\Delta BW$ como banda requerida no instante $t+1$. Ou seja, a banda BW_{t+1} , no instante $t+1$, de acordo com a equação (4.5), é dada por:

$$BW_{t+1} = \min \left\{ \left\langle \frac{(P_{t+1} + b_t)/(t + d_{req})}{\Delta BW} \right\rangle \Delta BW, C \right\} \quad (4.6)$$

onde o operador $\langle x \rangle$ representa o maior número inteiro mais próximo de x .

Como a banda requerida (equação 4.6) é o valor superior do intervalo onde se encontra o valor da taxa predito, tem-se uma provisão de banda menos sensível às pequenas variações das predições, dentro dos intervalos de tamanho ΔBW . Ao se aumentar o intervalo de banda, evita-se uma frequente realocação de banda, reduzindo o custo de sinalização envolvido. Portanto, o valor de ΔBW influencia no custo de sinalização do esquema de alocação de banda.

4.2.1 Avaliação do Desempenho de Alocação de Banda

Esta seção apresenta as medidas de desempenho utilizadas para avaliar o esquema de provisão de banda proposto, assim como os resultados de desempenho obtidos para o mesmo. Seja z_t o valor observado de taxa de tráfego e BW_t a banda fornecida no instante de tempo t . As seguintes medidas de desempenho podem ser definidas:

Definição 27 *Utilização Média(u): A utilização média mede a fração de banda usada para servir o fluxo de dados observados no período de tempo T , calculada por:*

$$u = \frac{1}{T} \sum_{t=1}^T \min \left\{ \frac{z_t}{BW_t}, 1 \right\} \quad (4.7)$$

Definição 28 *Taxa de perda (TP): A taxa de perda mede a quantidade de bytes perdidos devido à alocação de banda menor do que a necessária, dada por:*

$$TP = \frac{1}{T} \sum_{t=1}^T \max \left\{ \frac{(z_t - BW_t) - B}{z_t}, 0 \right\} \quad (4.8)$$

Inicialmente avaliaremos o esquema de alocação de banda para o caso em que o *buffer* $B = 0$.

4.2.2 Desempenho da Alocação de Banda para a Série de Tráfego de Rede Waikato VIII 20111029-110001-1

A Figura 29 apresenta o resultado da taxa de perda em relação a ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada em 10ms, 100ms e 512ms. Os resultados para a agregação em 10ms mostram taxa de perda constante para todos algoritmos a partir de um certo valor de ΔB . Observamos as menores taxa de perda para o algoritmo Fuzzy LMS com Autocorrelação Multifractal nos valores de ΔB próximos a zero. Os algoritmos apresentaram curvas semelhantes para a escala de agregação em 10ms, enquanto o algoritmo LMS apresentou as maiores taxas de perda para valores de ΔB aproximadamente menores do que 0.2, chegando a obter uma taxa de perda perto de 30% na região próxima a 0 para ΔB .




Figura 29 – Taxa de perda dada em relação a ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1.

Os resultados para a escala de agregação 100ms mostrados na Figura 29 apresentam taxa de perda inferiores também para o algoritmo Fuzzy LMS com Autocorrelação Multifractal considerando valores menores de ΔB . Nota-se que algoritmo Fuzzy LMS

obteve taxa de perdas inferiores aos algoritmos Fuzzy RLS e LMS para valores pequenos de ΔB e valores superiores aos demais algoritmos a partir de um certo valor de ΔB .




Figura 30 – Taxa de Perda dada em relação ao tamanho do *buffer* para a série de tráfego de rede Waikato VIII 20111029-110001-1.

A Figura 30 mostra a taxa de perda dada em relação ao tamanho do *buffer* para a série de tráfego de rede Waikato VIII 110001-1. Observamos que a taxa de perda para todos os algoritmos converge para um certo valor quando aumentamos o tamanho do *buffer*, indicando que quanto maior o tamanho do *buffer* mais conseguimos armazenar as amostras da série de tráfego, chegando em uma situação em que não exista mais perdas.

Os resultados para a escala de agregação 10ms mostrado na Figura 30 mostram que taxas de perdas menores foram obtidos pelo algoritmo Fuzzy LMS com Autocorrelação Multifractal para valores aproximadamente menores do que 4×10^4 para o tamanho do *buffer* em relação aos outros algoritmos. Observamos um comportamento similar para os algoritmos Fuzzy LMS e Fuzzy RLS, enquanto o algoritmo LMS apresenta valores superiores de taxa de perda quando reduzimos o tamanho do *buffer*, chegando a valores perto de 20% de perda para um tamanho do *buffer* próximo a 0.

Para a escala de agregação em $100ms$ e $512ms$ mostrados na Figura 30, foram obtidos menores taxa de perda para o algoritmo proposto em ambas escalas de agregação, quando consideramos valores pequenos do tamanho do *buffer*.




Figura 31 – Utilização Média em relação a ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1.

A Figura 31 mostra a utilização Média em relação a ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1 agregada nas escalas $10ms$, $100ms$ e $512ms$. Nota-se que os algoritmos apresentam valores próximos a partir de um certo valor de ΔB .

Os resultados mostrados na Figura 31 para o algoritmo LMS nas três escalas de agregação $10ms$, $100ms$ e $512ms$ indicam taxas de utilização superiores aos demais algoritmos para valores pequeno de ΔB .

Os algoritmos *fuzzy* apresentaram comportamento similares nas escalas de agregação $10ms$, $100ms$ e $512ms$ para a série de tráfego de rede Waikato VIII 20111029-110001-1 ao observarmos a Figura 31. Podemos notar que os algoritmos apresentaram similares taxas de utilização com diferentes taxas de perdas apresentadas anteriormente nas Figuras

29 e 30, com destaque do algoritmo Fuzzy LMS com Autocorrelação Multifractal que apresentou menores taxa de perda em relação aos demais algoritmos apresentados.




Figura 32 – Tamanho médio da fila no *buffer* em relação à ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1.

A Figura 32 mostra o tamanho média da fila no *buffer* em relação à ΔB para a série de tráfego de rede Waikato VIII 20111029-110001-1 nas escalas de agregação 10ms, 100ms e 512ms. Observamos valores próximos para os algoritmos a partir de um certo valor de ΔB nas escalas 10ms e 100ms, enquanto para a escala 512ms não foi constatada essa mesma característica.

O algoritmo proposto Fuzzy LMS com Autocorrelação Multifractal apresentou, na Figura 32, valores inferiores de tamanho médio da fila em relação aos outros algoritmos considerando valores pequenos de ΔB , nas três escalas de agregação.

4.2.3 Desempenho de Alocação de Banda para a Série de Tráfego de Rede dec-pkt-2 512ms

A Figura 33 mostra os resultados para taxa de perda obtida em relação ao tamanho do *buffer* para a série de tráfego de rede dec-pkt-2 agregada em 512ms. O algoritmo Fuzzy LMS com Autocorrelação Multifractal obteve as menores taxas de perda quando observamos valores de tamanho do *buffer* aproximadamente inferiores a 4×10^4 , obtendo valores de perda próximos a 2%. O algoritmo LMS apresentou as maiores taxas de perda quando reduzimos o tamanho do *buffer*, apresentando valores de taxa de perda aproximadamente no intervalo [14%, 16%]. Nota-se um comportamento similar dos algoritmos Fuzzy LMS e Fuzzy RLS, apresentando valores próximos de taxa de perda.




Figura 33 – Taxa de Perda obtida em relação ao tamanho do *buffer* para a série de tráfego de rede dec-pkt-2 agregada em 512ms.

A Figura 34 apresenta os resultados da taxa de perda obtida em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms. Observamos os menores valores de taxa de perda para o algoritmo proposto para todos os valores de ΔB , apresentando taxas de perda perto de 4% para ΔB próximo de 0. As maiores taxas de perdas foram obtidas pelo algoritmo LMS, obtendo valores perto de 20%, enquanto visualizamos menores taxas de perdas para o algoritmo Fuzzy RLS em relação ao algoritmo Fuzzy LMS, apesar do comportamento similar das curvas de ambos.




Figura 34 – Taxa de perda obtida em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms.




Figura 35 – Utilização Média do enlace dada em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms.

A Figura 35 mostra a Utilização Média do enlace dada em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms. Observamos que os algoritmos apresentaram resultados semelhantes de taxa de utilização, obtendo a mesma característica dos resultados para a série de tráfego de rede Waikato VIII 20111029-110001-1 onde se conseguiu menores taxas de perda para o algoritmo Fuzzy LMS com Autocorrelação Multifractal a uma taxa de utilização similar.




Figura 36 – Tamanho média da fila no *buffer* em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms.

A Figura 36 apresenta os resultados para o tamanho médio da fila no *buffer* em relação a ΔB para a série de tráfego de rede dec-pkt-2 agregada em 512ms. Nota-se um resultado semelhante para o algoritmo Fuzzy LMS com Autocorrelação Multifractal ao obtido pelo tráfego Waikato VIII 20111029-110001-1 na Figura 32, onde o algoritmo proposto de sobressaiu apresentando um tamanho médio da fila no *buffer* inferior aos demais algoritmos utilizados na comparação.

5 Controle de Fluxos de Tráfego Utilizando Sistema *Fuzzy* com Base Ortonormal

Duas estratégias distintas de controle e gerenciamento de congestionamento são comumente encontradas na literatura: recuperação e prevenção (DURRESI; SRIDHARAN; JAIN, 2006). A primeira tem como objetivo atuar na rede após a ocorrência de congestionamento para resolver tal problema. A segunda trata de detectar possíveis condições que levem a situações de congestionamentos e de executar procedimentos para impedir suas ocorrências. Esta estratégia de prevenção, que se baseia em antecipar situações de congestionamento, normalmente inclui modelos para análise do comportamento do tráfego, sendo este frequentemente complexo e não-linear (LEE; FAPOJUWO, 2005).

A solução adotada neste trabalho está relacionada com a aplicação da modelagem *fuzzy* visando a predição do comportamento de fila no *buffer* e o controle da taxa de entrada dos fluxos de tráfego. Neste tipo de abordagem, um fator importante para o sucesso do controle de congestionamento é a aplicação de uma modelagem de tráfego adequada. Quanto mais precisa for a estimativa do comportamento dos fluxos da rede, mais apropriado será o serviço oferecido ao usuário. Por outro lado, se o modelo não for capaz de representar precisamente o tráfego real, o desempenho real da rede pode ser subestimado ou superestimado. Assim, um modelo de tráfego eficiente deve capturar fielmente as características do tráfego de redes. Muitos estudos mostram que modelos *fuzzy* possuem vantagens sobre os modelos lineares em descrever o comportamento não-linear e variante no tempo de processos reais desconhecidos, como é o caso dos fluxos de tráfego de redes (OUYANG; LEE; LEE, 2005). De fato, a modelagem *fuzzy* é capaz de representar um sistema complexo não-linear através da combinação de vários modelos locais lineares invariantes no tempo (CHEN; LIU; TONG, 2007).

Várias técnicas de controle de congestionamento em redes de computadores têm sido propostas na literatura (WANG et al., 2007; DURRESI; SRIDHARAN; JAIN, 2006). Dentre as propostas de controle de congestionamento utilizando lógica nebulosa, algumas utilizam modelos *fuzzy* sem adaptação dos parâmetros como em (HU; PETR, 2000) e outras são baseadas em protocolos ou tecnologias de rede específicos. No primeiro caso, muitos dos esquemas não são suficientemente precisos em prever o comportamento variante do tráfego gerado por aplicações em tempo real devido à não adaptação de seus parâmetros. Por exemplo, em (HU; PETR, 2000), os autores propõem um algoritmo de controle preditivo das taxas dos fluxos de tráfego. Entretanto, nesta abordagem as funções de pertinência que caracterizam as entradas do preditor nebuloso são fixas, ou seja, tais funções não se ajustam à medida que novas entradas de dados são disponibilizadas. No segundo caso,

podemos encontrar propostas de esquemas de controle que são dedicados aos protocolos de redes ATM (*Asynchronous Transfer Mode*) ou baseados nos mecanismos de controle de congestionamento do protocolo TCP/IP (Transmission Control Protocol/Internet Protocol), como em (WANG et al., 2007). Entre as propostas de controle de congestionamento que não dependem de mecanismos específicos de rede, destacamos o método de Realimentação Binária (CHEN; LIU; SAMALAM, 1996) e o método de Controle Proporcional (HABIB; SAADAWI, 1992). Tais métodos podem ser utilizados para controle de aplicações de tempo real e são também eficazes para outros problemas de controle (KARNIK; KUMAR, 2005). Assim, usaremos estes métodos nas análises comparativas deste trabalho.

5.1 Descrição do Sistema de Controle de Congestionamento

Nessa seção, detalhamos o sistema de controle de congestionamento implementado. Este sistema de controle visa prever adaptativamente o comportamento da fila no *buffer* e, a partir dos parâmetros do modelo de previsão de tráfego, controlar a taxa da fonte de tal forma que o tamanho da fila no *buffer* seja igual ou inferior ao nível de referência desejado.




Figura 37 – Modelo do Sistema de Controle de Congestionamento.

A estrutura básica do sistema de controle de congestionamento considerado é mostrada na Figura 37, na qual estão identificados todos os elementos do sistema:

- Fluxo de tráfego controlável $\mu(k)$;
- Fluxo de tráfego não-controlável $\nu(k)$;
- *Buffer*;
- Atraso de realimentação (*round-trip time*) d ;
- Tamanho da fila no *buffer* $b(k)$ no instante k ;

- Capacidade η do enlace de saída do sistema;
- Nível desejado para o tamanho da fila no *buffer* b^r ;

O tráfego que chega ao *buffer* vem de duas classes distintas. Uma está relacionada ao tráfego controlável $\mu(k)$ que adapta sua taxa às condições da rede, chamado de tráfego TBD (Taxa de Bits Disponível). A taxa de transmissão do tráfego TBD é regulada pelo controlador *fuzzy* adaptativo proposto implementado no *switch*. A outra classe é a do tráfego não-controlável $v(k)$, no qual se enquadram os serviços do tipo TBC (Taxa de Bits Constante) e TBV (Taxa de Bits Variável). Essa classe de tráfego é sensível ao atraso e tem maior prioridade de uso do enlace. Deste modo, as fontes controláveis podem usufruir apenas a banda restante não usada pelas fontes não-controláveis.

Os serviços de taxa de bits variável (TBV) e constante (TBC) são apropriados para um grande número de aplicações (LEE; VECIANA, 2000; CHEN; LIU; SAMALAM, 1996). O serviço TBV, cujos fluxos possuem características de rajadas aleatórias, oferece conexões para aplicações de vídeo e áudio em tempo real e não-real com largura de banda variável. Os pacotes desse tipo de serviço são transmitidos a taxas arbitrárias e entregues com atraso e Taxa de Perda de Bytes (TPB) limitados de acordo com os valores requeridos pela aplicação. O serviço TBC pode ser considerado um caso especial do serviço TBV, onde a taxa de pico é igual à taxa média de serviço. Esses tipos de serviços são usados para aplicações em tempo-real com largura de banda fixa, tais como, em redes chaveadas por circuitos (Exemplo: canal de voz de 64Kbyte/seg). Os pacotes do serviço TBC são gerados em intervalos periódicos regulares e entregues com atrasos estritamente limitados.

Os serviços de taxa de bits disponível (TBD) são utilizados em uma classe mais estreita de aplicações que podem se adaptar à banda disponível e tolerar atrasos. Essas conexões TBD em geral compartilham a banda do enlace com os tráfegos de TBV e TBC, quando houver parte não usada. Das características citadas para o tráfego TBD, podemos perceber que esse serviço não é apropriado para aplicações sensíveis a atrasos.

Dado que a fonte TBD ajusta sua taxa de transmissão periodicamente de acordo com a banda disponível no momento, o desempenho da rede será fortemente afetado pela eficiência do mecanismo de ajuste de taxa. Para atingir um nível adequado de eficiência, a fonte é informada das últimas condições da rede, normalmente através de um canal de realimentação com atraso. O atraso de realimentação juntamente com o atraso de transmissão direta é chamado de *round-trip time* (representado pelo atraso d na Figura 37). Este atraso causa diferenças entre a taxa da fonte TBD e a banda disponível, o que exige a presença de *buffers* na rede para acomodar o tráfego TBD durante os intervalos de tempo em que a taxa da fonte excede a taxa disponível no enlace.

O esquema de controle de tráfego proposto tem como objetivo levar em consideração o atraso de *round-trip* d prevendo o comportamento da ocupação do *buffer* a fim de evitar

ocorrência de congestionamento. Para isto, desenvolvemos um algoritmo adaptativo de predição de d passos a frente do tamanho da fila no *buffer* $b(k+d)$ baseado nas informações passadas e atuais da taxa da fonte controlável $\mu(s)_{s \leq k}$ e do tamanho da fila no *buffer* $b(s)_{s \leq k}$. Além disso, para manter o tamanho da fila no *buffer* abaixo do nível desejado b^τ e minimizar a sua variância, aplicamos a taxa ótima de controle proposta $\mu^o(k)$ para regular a taxa da fonte controlável. Deste modo, é possível confinar a taxa de perda de bytes dentro dos níveis estabelecidos no contrato de tráfego.

Devido aos diversos tipos de serviços e aplicações, tais como, dados, voz e vídeo sendo multiplexados nos nós das redes, a dinâmica da ocupação do *buffer* é um processo complexo e não-linear. Esta ocupação expressa pelo tamanho de fila no *buffer* do sistema da Figura 37 pode ser descrita através da equação de Lindley (JACOBSON, 1995):

$$b(k+1) = \min\{\max[b(k) + (\mu(k-d) + \nu(k) - \eta) \times T, 0], B_{max}\}, \quad (5.1)$$

onde B_{max} é a capacidade máxima do *buffer*.

5.2 Funções de Base Ortonormal

A Base de Laguerre é usada em muitos contextos de identificação e controle de sistemas não-lineares. Neste trabalho, adotamos a Base de Laguerre porque é completamente parametrizada por apenas um polo, o polo de Laguerre. O conjunto das funções de transferência associadas com essa base é dada pela seguinte equação:

$$\Phi_{mag,j} = \sqrt{1-p^2} \frac{q^{-1}(q^{-1}-p)^{j-1}}{(1-pq)^j} \quad (5.2)$$

onde $p \in \{P : -1 < p < 1\}$ é o polo das Funções de Laguerre (Base de Laguerre) e q^{-j} é o operador de deslocamento. Nota-se que fazendo $p = 0$ na equação 5.2, obtemos $\Phi_{mag,j}(q^{-1}) = q^{-1}$. Portanto $\Phi_{mag,j}(q^{-1}) = q^{-1}$ é um caso especial da Base de Laguerre.

A saída do modelo entrada-saída, pode ser escrita como:

$$y(k) = H(l_1(k), \dots, l_n(k)) \quad (5.3)$$

onde $l_j(k) = \Phi_{mag,j}(q^{-1})u(k)$ é a j -ésima Função de Laguerre no instante de tempo k , n é a quantidade de funções base, $u(k)$ é o sinal de entrada e H é um operador não linear. Note que a operação de não linearidade do operador H pode ser obtida por uma modelagem *fuzzy*.

As funções de Laguerre $l_j(k)$ são recursivas e podem ser obtidas através da formulação de uma equação de estado, como se segue:

$$\mathbf{l}(k+1) = A\mathbf{l}(k) + b\mathbf{u}(k) \quad (5.4)$$

$$y(k) = H(\mathbf{l}(k)) \quad (5.5)$$

onde $\mathbf{l} = [l_1(k) \dots l_n(k)]^T$. A matriz A e o vetor b dependem da ordem n do modelo e do valor do polo p , como se segue:

$$A = \begin{pmatrix} p & 0 & \dots & 0 \\ 1-p^2 & p & \dots & 0 \\ (-p)(1-p) & 1-p^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ (-p)^{n-2}(1-p) & (-p)^{n-3}(1-p) & \dots & p \end{pmatrix} \quad (5.6)$$

$$b = \sqrt{(1-p^2)} [1 \ (-p) \ (-p)^2 \ \dots \ (-p)^{n-1}]^T \quad (5.7)$$

5.2.1 Modelo do Polo Obtido a Partir da Função de Autocorrelação de Processos Multifractais

O polo usado para calcular as Funções de Base Ortonormal, pode ser obtido pela seguinte expressão (VIEIRA; ROCHA, 2011):

$$p = -\frac{1}{2^{\log_2(\frac{\alpha+1}{\alpha+1/2})}} \quad (5.8)$$

onde podemos estimar o valor de p adaptativamente através do valor de α .

5.2.2 Algoritmo preditivo Fuzzy-LMS-FBO com alfa adaptativo

Nesta seção é proposta uma equação para o cálculo de α através do parâmetro n_j gerado no modelo β MWM adaptativo (seção 1.4), o qual será utilizado no cálculo do polo p de Laguerre utilizado nas Funções de Base Ortonormal, dado na equação 5.8.

Proposição 1 *Dado o parâmetro n_j gerado adaptativamente no modelo β MWM Adaptativo proposto em Goncalves, Vieira e Costa (2013). Podemos calcular o parâmetro α através da seguinte equação:*

$$\alpha = \frac{n_j - 1}{2 - n_j} \quad (5.9)$$

Prova: Utilizando a equação descrita em Goncalves, Vieira e Costa (2013), podemos calcular H através da seguinte equação:

$$n_j = 2^{2H-1} \quad (5.10)$$

Utilizando a equação descrita em Dang, Molnar e Maricza (2002a), dada por:

$$H = 1 - \frac{\log_2 \left(\frac{\alpha+1}{\alpha+0.5} \right)}{2} \quad (5.11)$$

Substituindo 5.11 em 5.10 e isolando α , chegamos na equação 5.9, como queríamos demonstrar.

A proposta deste capítulo é de incluir o algoritmo Fuzzy LMS (seção 3.5) para modelar a função não-linear H (equação 5.3) no modelo de Funções de Base Ortonormal. O primeiro algoritmo proposto é Fuzzy-LMS-FBO com Alfa Fixo, obtendo o polo pelo modelo βMWM (RIEDI et al., 1999). O segundo sendo o Fuzzy LMS-FBO com Alfa Adaptativo obtido através do modelo βMWM Adaptativo (GONCALVES; VIEIRA; COSTA, 2013), utilizando a equação 5.9.

Definimos o algoritmo Fuzzy-LMS-FBO com Alfa Adaptativo pelos seguintes passos:

- **Passo 1:** Execute o algoritmo βMWM adaptativo para calcular o parâmetro α multifractal adaptativamente.
- **Passo 2:** Calcule o polo de Laguerre através do valor do parâmetro α multifractal.

$$p = -\frac{1}{2^{\log_2 \left(\frac{\alpha+1}{\alpha+1/2} \right)}}$$

- **Passo 3:** Calcule a Matriz A e o vetor b para o cálculo das funções de Laguerre.

$$A = \begin{pmatrix} p & 0 & \dots & 0 \\ 1-p^2 & p & \dots & 0 \\ (-p)(1-p) & 1-p^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ (-p)^{n-2}(1-p) & (-p)^{n-3}(1-p) & \dots & p \end{pmatrix}$$

$$b = \sqrt{(1-p^2)} [1 \quad (-p) \quad (-p)^2 \quad \dots \quad (-p)^{n-1}]^T$$

- **Passo 4:** Calcule as funções de Laguerre $l(k)$ através de A e b .

$$\mathbf{l}(k+1) = A\mathbf{l}(k) + b\mathbf{u}(k)$$

- **Passo 5:** Execute o algoritmo de adaptação dos parâmetros $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ do modelo Fuzzy LMS tendo como entrada as funções de Laguerre $l(k)$.

$$\theta^l(k) = \theta^l(k-1) + \gamma[d(k) - f_k] \frac{z^l(k-1)}{b(k-1)}$$

$$\bar{x}_i^l(k) = \bar{x}_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{x_i(k) - \bar{x}_i^l(k-1)}{(\sigma_i^l(k-1))^2}$$

$$\sigma_i^l(k) = \sigma_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{(x_i(k) - \bar{x}_i^l(k-1))^2}{(\sigma_i^l(k-1))^3}$$

- **Passo 6:** A cada iteração realize os passos 1 até o 5 novamente, até que sejam realizadas todas iterações.

O algoritmo Fuzzy-LMS-FBO com Alfa Fixo é definido pelos seguintes passos:

- **Passo 1:** Execute o algoritmo β MWM para calcular o parâmetro α multifractal.
- **Passo 2:** Calcule o polo de Laguerre através do valor do parâmetro α multifractal.

$$p = -\frac{1}{2^{\log_2\left(\frac{\alpha+1}{\alpha+1/2}\right)}}$$

- **Passo 3:** Calcule a Matriz A e o vetor b para o cálculo das funções de Laguerre.

$$A = \begin{pmatrix} p & 0 & \dots & 0 \\ 1-p^2 & p & \dots & 0 \\ (-p)(1-p) & 1-p^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ (-p)^{n-2}(1-p) & (-p)^{n-3}(1-p) & \dots & p \end{pmatrix}$$

$$b = \sqrt{(1-p^2)} [1 \quad (-p) \quad (-p)^2 \quad \dots \quad (-p)^{n-1}]^T$$

- **Passo 4:** Calcule as funções de Laguerre $l(k)$ através de A e b .

$$\mathbf{l}(k+1) = A\mathbf{l}(k) + b\mathbf{u}(k)$$

- **Passo 5:** Execute o algoritmo de adaptação dos parâmetros $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ do modelo Fuzzy LMS tendo como entrada as funções de Laguerre $l(k)$.

$$\theta^l(k) = \theta^l(k-1) + \gamma[d(k) - f_k] \frac{z^l(k-1)}{b(k-1)}$$

$$\bar{x}_i^l(k) = \bar{x}_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{x_i(k) - \bar{x}_i^l(k-1)}{(\sigma_i^l(k-1))^2}$$

$$\sigma_i^l(k) = \sigma_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{(x_i(k) - \bar{x}_i^l(k-1))^2}{(\sigma_i^l(k-1))^3}$$

- **Passo 6:** A cada iteração realize os passos 2 até o 5 novamente, até que sejam realizadas todas iterações.

A Figura 38 mostra os passos de execução do algoritmo Fuzzy-LMS-FBO com Alfa Adaptativo através de um fluxograma.




Figura 38 – Fluxograma do algoritmo Fuzzy-LMS-FBO com alfa adaptativo.

Destacamos que o algoritmo Fuzzy-LMS-FBO com Alfa Fixo, diferentemente do algoritmo Fuzzy-LMS-FBO com Alfa Adaptativo, necessita de todas as amostras do tráfego de rede para obter o parâmetro α multifractal, o que na prática pode se tornar inviável.

Na Figura 39 podemos observar os parâmetros do modelo obtido pelos modelos β MWM fixo e adaptativo de (GONCALVES; VIEIRA; COSTA, 2013) para a série de tráfego de rede Waikato VIII-20111027-213205-5, agregada em 512ms. Na Figura 39(a) observa-se a evolução do parâmetro n_j (equação 5.10) da última camada, o qual é utilizado para calcular o parâmetro α do modelo multifractal através da equação 5.9. Na Figura 39(b) podemos visualizar a variação do parâmetro α através do tempo (iterações).

Utilizando a equação 5.11, podemos estimar o valor do expoente de Hölder no instante de tempo, dado o α do modelo multifractal. Na Figura 39(c) visualizamos o




Figura 39 – Função de Höder, parâmetros n_j e α para o tráfego de rede WaikatoVIII-20111027-213205-5.

resultado obtido dos expoentes de Hölder para a série de tráfego de rede Waikato VIII-20111027-213205-5 agregada em 512ms.

Na Figura 40 podemos observar os parâmetros n_j , α e expoente de Hölder do modelo β MWM fixo e adaptativo (GONCALVES; VIEIRA; COSTA, 2013) para a série de tráfego de rede SNU20100315, agregada em 100ms. A Figura 40(a) apresenta a evolução do parâmetro n_j da última camada. Na Figura 40(b) pode-se visualizar a variação do parâmetro α através do tempo (iterações), enquanto na Figura 40(c) visualizamos a estimativa obtida da Função de Hölder.

5.3 Cálculo da Taxa Ótima de Controle de Fluxos

Nesta seção, como parte do esquema de controle de congestionamento adaptativo proposto, apresentamos uma expressão para o cálculo da taxa ótima de controle para regular a taxa $\mu(k)$ da fonte controlável a partir da minimização da função custo J abaixo:




Figura 40 – Função de Hölder, parâmetros n_j e α para a série de tráfego de rede SNU20100315.

$$J(k+d) = E \left[\frac{1}{2} (b(k+d) - b^\tau)^2 + \frac{\lambda}{2} \mu^2(k) \right], \quad (5.12)$$

onde λ é o fator de ponderação e $E[\cdot]$ denota a esperança matemática. Na equação (5.12), a função custo J leva em consideração o erro de ajuste do tamanho da fila no *buffer*, isto é, considera a diferença entre o valor do tamanho da fila no *buffer* d passos à frente e o nível desejado para o tamanho da fila no *buffer* b^τ . Os erros de modelagem (imprecisão do modelo), mesmo sendo pequenos, podem causar oscilações no tamanho de fila do *buffer* $b(k)$ de tal forma a ultrapassar o nível de referência b^τ . Devido a este fato, introduzimos na equação (5.12) o parâmetro de projeto λ para limitar o valor de $\mu^2(k)$, evitando situações como essa.

Proposição 2 Definimos a taxa ótima de controle μ^0 pela seguinte equação:

$$\mu^o = \frac{1}{\lambda} [b^\tau - f_x] \frac{\theta^l(k-1) - f_k}{b(k-1)} \times a^l(k-1) \frac{\mu(k) - \bar{\mu}^l(k-1)}{(\sigma^l(k-1))^2} \quad (5.13)$$

Prova: A taxa de controle ótima é dada em função do valor do tamanho da fila no buffer d passos à frente. Uma estimativa do tamanho da fila $b(k)$ no buffer d passos à frente é fornecida pela saída do preditor fuzzy proposto quando aplicado à predição de amostras deste processo pela equação 3.57, sendo:

$$f_k = b(k + d) \quad (5.14)$$

Derivando a equação 5.12 em função de μ , obtemos:

$$\frac{\partial J}{\partial \mu} = [b(k + d) - b^*] \frac{\partial b(k + d)}{\partial \mu} + \lambda \mu = 0 \quad (5.15)$$

Em (WANG, 1994, p. 31) encontramos a derivada $(\partial b(k + d)/\partial \mu)$, dada pela equação:

$$\frac{\partial b(k + d)}{\partial \mu} = \frac{\partial f_x}{\partial \mu} = \frac{\theta^l(k - 1) - f_k}{b(k - 1)} a^l(k - 1) \frac{\mu(k) - \bar{\mu}^l(k - 1)}{(\sigma^l(k - 1))^2} \quad (5.16)$$

Substituindo a equação 5.16 em 5.15 e isolando μ chegamos ao valor da taxa ótima de controle μ^0 , como queríamos demonstrar.

5.4 Avaliação do Esquema de Controle de Congestionamento Proposto

O esquema de controle de congestionamento proposto é constituído de um módulo de predição adaptativa de tráfego representado pelo algoritmo de predição *fuzzy* proposto e um módulo relativo ao cálculo da taxa ótima para os fluxos. Os parâmetros obtidos na predição do tamanho de fila no *buffer* são usados para calcular a taxa da fonte de tal forma que o tamanho da fila no *buffer* se aproxime do nível desejado e a sua variância se torne mínima. O esquema de controle de fluxos proposto é inserido no bloco “Controle de Fluxo Nebuloso Preditivo Adaptativo” da Figura 37.

Nessa seção, avaliamos o esquema de controle de congestionamento proposto e o comparamos a outros métodos de controle de congestionamento. Inicialmente, apresentamos os métodos de controle e as medidas de desempenho utilizados na comparação. Em seguida, validamos o esquema de controle de congestionamento proposto através de simulações. Para validação do esquema de controle proposto no primeiro cenário considerou-se uma rede composta pelas fontes controláveis e não-controláveis utilizando respectivamente os tráfegos de rede *Waikato VIII-20111027-213205-5* (WITS, 2014) e *Waikato VIII-20110921-000000-0* (WITS, 2014) obtidos em 2011 pelo *Computer Science Department* da *University of Waikato*, agregadas na escala de 512ms. No segundo cenário foi considerado uma rede composta pelas fontes controláveis e não-controláveis utilizando respectivamente os tráfegos de rede *SNU20100315* (KIM et al., 2012) e *SNU20100317* (KIM et al., 2012) obtidos em 2010 na rede sem fio WiMAX da *Seoul National University*, agregadas na escala de 100ms.

Os métodos utilizados na comparação de desempenho do esquema de controle de congestionamento proposto são: método de Realimentação Binária (RAMAKRISHNAN; JAIN, 1990) e método de Controle Proporcional (HABIB; SAADAWI, 1992). Tais métodos foram escolhidos por serem bastante utilizados na literatura (KARNIK; KUMAR, 2005) e por possuírem características semelhantes ao método proposto, isto é, esses métodos analisam o comportamento do tamanho da fila no *buffer* e estimam uma nova taxa para as fontes controláveis a partir de condições pré-estabelecidas, sendo também independentes de protocolos específicos de rede. Além disso, assim como no esquema de controle proposto, nestes métodos de controle, um valor limitante para o tamanho da fila no *buffer* pode ser estabelecido.

No método de Realimentação Binária (*Binary Feedback*) a taxa da fonte de tráfego é controlada através do monitoramento do tamanho da fila no *buffer* (CHEN; LIU; SAMALAM, 1996; KARNIK; KUMAR, 2005). Dois limiares são configurados: T_l e T_h . Quando o tamanho da fila no *buffer* excede T_h , o congestionamento é detectado e a taxa da fonte é reduzida por um fator de 0.98. Por outro lado, quando o tamanho da fila no *buffer* se torna menor do que T_l , considera-se que não há mais congestionamento e a taxa da fonte é incrementada por um fator correspondente a 1% da capacidade do enlace de saída do nó. Caso contrário, a taxa da fonte permanece inalterada.

Nas simulações, os dois limiares T_l e T_h são configurados como $0.95b^\tau$ e $1.05b^\tau$, respectivamente, onde b^τ é o nível desejado para o tamanho da fila no *buffer*.

Controle de Congestionamento Proporcional (*Proportional Congestion Control*) - Esse método de controle de congestionamento monitora o tamanho da fila no *buffer* e usa esse valor para regular a taxa da fonte controlável através de uma variável de controle $c(k)$ (HABIB; SAADAWI, 1992).

Seja b^τ o valor de referência de controle do tamanho da fila no *buffer* em um enlace. O sinal de controle da taxa de tráfego $c(k)$ é gerado através do seguinte algoritmo de controle de congestionamento:

$$c(k) = \begin{cases} 1.002 & \text{se } b(k) < 0.998b^\tau \\ 1.002 - \frac{b(k) - 0.998b^\tau}{b^\tau} & \text{se } 0.998b^\tau < b(k) < 1.002b^\tau \\ 0.998 & \text{se } b(k) > 1.002b^\tau \end{cases} \quad (5.17)$$

onde 0.998 pode ser visto como um limiar inferior e 1.002 como um limiar superior para o sinal de controle. O sinal de controle da taxa $c(k)$ é inversamente proporcional a ocupação do *buffer* quando $0.998b^\tau < b(k) < 1.002b^\tau$. Quando $b(k)$ é maior do que b^τ , o sinal de controle $c(k)$ é enviado para fonte para que esta diminua sua taxa. A situação inversa também ocorre, ou seja, quando $b(k)$ é menor do que b^τ , o sinal de controle $c(k)$ é enviado para que a fonte aumente sua taxa. Sendo $\mu(k)$ a taxa da fonte controlável no instante k , então a taxa da fonte para o instante seguinte será dada por $\mu(k+1) = c(k)\mu(k)$.

5.4.1 Avaliação de predição do algoritmo proposto Fuzzy-LMS-FBO

5.4.1.1 Predição da Série de Tráfego de Rede Waikato VIII-20111027-213205-5

Os algoritmos foram inicializados de tal forma que conseguissem o melhor resultado possível de predição. Os parâmetros de aprendizagem α foram igualmente inicializados para todos algoritmos, com valor igual a 0.08. Os valores de $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ dos modelos Fuzzy foram inicializados como sendo, respectivamente, $[-0.5, 0.5]$, $[-2, 2]$, $[0.1, 0.3]$, enquanto o número de regras de regras *fuzzy* foi inicializado como $M = 48$ para todos os algoritmos.

A ordem n dos algoritmos foi escolhida de forma a obter os menores valores de Erro Quadrático Médio possíveis. Nota-se que quanto maior a ordem dos algoritmos, maior a complexidade e maior é o tempo de execução dos algoritmos (FARHANG-BOROUJENY, 1999). A Tabela 10 mostra os erros de predição do algoritmo Fuzzy LMS-FBO com alfa adaptativo para $n = 9, 10, 11, 12, 13$, utilizando a série de tráfego Waikato VIII 20111027-213205-5 agregada 100ms. Nota-se que o algoritmo Fuzzy LMS-FBO com alfa adaptativo obteve o menor valor de EQM para ordem $n = 12$. Escolhemos assim a ordem $n = 12$, para a simulação de predição utilizando a série Waikato VIII 20111027-213205-5.

Tabela 10 – Erros Quadrático Médios para a série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.

Ordem n	EQM	EQMN1	EQMN2
13	0.0019	0.1863	0.4436
12	0.0017	0.1593	0.4055
11	0.0017	0.1591	0.4823
10	0.0035	0.3381	0.8053
9	0.0035	0.3406	0.8111
8	0.0036	0.3412	0.8126

A Figura 41 mostra a evolução do erro quadrático médio de predição do tráfego de rede Waikato VIII-20111027-213205-5. A Figura 41(a) mostra o EQM para os 600 primeiros passos de iteração, a Figura 41(b) mostra também o EQM para as 17000 primeiras amostras enquanto a Figura 41(c) mostra o EQM para as 3000 últimas amostras do tráfego considerado. Na Figura 41(a) podemos visualizar maiores valores de erro quadrático médio para o algoritmo Fuzzy LMS em todo o intervalo de iterações considerado na figura. Os algoritmos Fuzzy-LMS-FBO com alfa adaptativo e alfa fixo mostraram valores próximos a partir aproximadamente do passo 100, enquanto o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou EQM maiores do que o algoritmos Fuzzy-LMS-FBO's em quase todo o intervalo considerado.

Observando a Figura 41(c) notamos uma melhor precisão de predição em termos de EQM para o algoritmo Fuzzy LMS-FBO com alfa adaptativo, seguido pelos algoritmos Fuzzy LMS-FBO com alfa fixo, Fuzzy LMS com Autocorrelação Multifractal e Fuzzy LMS nos 3000 últimos passos de iteração.




Figura 41 – Erro quadrático médio de predição para o tráfego de rede Waikato VIII-20111027-213205-5.

A Tabela 11 apresenta os EQM's e Tempo Computacional para a série de tráfego de rede Waikato VIII-20111027-213205-5 agregada em $512ms$. O algoritmo Fuzzy-LMS-FBO com alfa adaptativo se destacou dos demais, apresentando o menor EQM de valor igual a 0.0017. O algoritmo Fuzzy-LMS-FBO com alfa fixo apresentou menor EQM, de valor 0.0038, em relação aos algoritmos Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal.

Os algoritmos utilizados na simulação apresentaram valores de EQMN1 (ver Tabela 11) inferiores a 1, reforçando que esses algoritmos conseguiram obter uma predição melhor caso fosse estimado o valor futuro igual a média. Destaca-se o algoritmo Fuzzy-LMS-FBO com alfa adaptativo que apresentou o menor valor de EQMN1.

Na Tabela 11 podemos visualizar que o algoritmo Algoritmo Fuzzy-LMS-FBO com alfa adaptativo apresentou o menor valor de EQMN2, conseguindo obter um valor de 0.3794. Os algoritmos Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal obtiveram respectivamente os valores 1.2352 e 1.0959 para o EQMN2, os quais são superiores a 1,

Tabela 11 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede Waikato VIII-20111027-213205-5 agregada em $512ms$ e com $n = 12$ para todos algoritmos.

Algoritmo	EQM	EQMN1	EQMN2	Tempo Médio(s)	Tempo Total(s)
Algoritmo Fuzzy-LMS-FBO com alfa adaptativo	0.0017	0.1593	0.3794	9.6482×10^{-4}	16.7233
Algoritmo Fuzzy-LMS-FBO com alfa fixo	0.0038	0.3638	0.8664	5.7331×10^{-4}	9.9373
Fuzzy LMS	0.0054	0.5186	1.2352	1.9981×10^{-4}	3.4632
Fuzzy LMS com Auto-correlação Multifractal	0.0048	0.4616	1.0959	0.0082	139.4000

indicando que esses algoritmos não conseguiram melhor predição caso fosse estimado o valor futuro como sendo igual ao valor imediatamente anterior para a série de tráfego de rede Waikato VIII-20111027-213205-5 ($512ms$) considerado.

Os tempos computacionais apresentados na Tabela 11 mostram que o algoritmo Fuzzy LMS apresentou o menor tempo médio de valor 1.9981×10^{-4} segundos, com um tempo total de execução de 16.7233 segundos. O algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou o pior resultado em termos de tempo computacional, terminando sua execução em 139.4 segundos. O algoritmo Fuzzy-LMS-FBO com alfa adaptativo apresentou um tempo computacional médio de 9.6482×10^{-4} segundos, enquanto o algoritmo Fuzzy-LMS-FBO com alfa fixo apresentou um tempo computacional de 5.7331×10^{-4} segundos. Nota-se que apesar do algoritmo Fuzzy-LMS-FBO com alfa fixo obter um tempo computacional menor em relação ao algoritmo Fuzzy-LMS-FBO com alfa adaptativo, destacamos sua inviabilidade devido ao conhecimento prévio da série para o cálculo do parâmetro multifractal α .

Tabela 12 – Tempo Computacional de execução em relação ao algoritmo Fuzzy LMS para a série de tráfego de rede Waikato VIII-20111027-213205-5 agregada em $512ms$, com $n = 12$ para todos algoritmos.

Algoritmo	Tempo Total em relação ao Fuzzy LMS
Algoritmo Fuzzy-LMS-FBO com alfa adaptativo	4.8288
Algoritmo Fuzzy-LMS-FBO com alfa fixo	2.8693
Fuzzy LMS	1
Fuzzy LMS com Auto-correlação Multifractal	40.2517

A Tabela 12 mostra o tempo computacional em relação ao algoritmo Fuzzy LMS na predição da série de tráfego de rede Waikato VIII-20111027-213205-5. Nota-se que o algoritmo Fuzzy-LMS-FBO com alfa adaptativo apresentou um tempo de execução 4.8288 vezes maior em relação ao algoritmo Fuzzy LMS que apresentou o menor tempo computacional. A Tabela 12 é importante ao comparamos o desempenho do algoritmo Fuzzy LMS com Autocorrelação Multifractal em relação aos algoritmos Fuzzy-LMS-FBO's, apresentando um tempo computacional de ordem 40 vezes maior em relação ao Fuzzy LMS.




Figura 42 – Gráfico QQ-plot para a predição da série de tráfego de rede Waikato VIII-20111027-213205-5.

A Figura 42 mostra o gráfico Quantil-Quantil (ROLLS; MICHAELIDIS; HERNÁNDEZ-CAMPOS, 2005) para a predição da série de tráfego de rede Waikato VIII-20111027-213205-5, utilizando os algoritmos Fuzzy-LMS-FBO com alfa adaptativo (Figura (a)) e Fuzzy-LMS-FBO com alfa fixo (Figura (b)). Nota-se uma certa linearidade das amostras para ambos algoritmos, destacando-se um afastamento da reta linear nas extremidades do intervalo considerado para o valor predito.

5.4.1.2 Predição da Série de Tráfego de Rede SNU20100315

Na simulação de predição para a série de tráfego de rede SNU20100315 agregada em 100ms, os parâmetros de aprendizagem α foram igualmente inicializados para todos algoritmos, com valor igual a 0.08. Os valores de $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ dos modelos *fuzzy* foram inicializados como sendo, respectivamente, $[-0.5, 0.5]$, $[-2, 2]$, $[0.1, 0.3]$, enquanto o número de regras *fuzzy* foi inicializado como $M = 48$ para todos os algoritmos.

A Tabela 13 mostra os Erros Quadráticos Médios para a série de tráfego de rede SNU20100315 agregada em 100ms para $n = 10, 11, 12, 13, 14$, utilizando o algoritmo Fuzzy LMS-FBO com alfa adaptativo. Nota-se que o algoritmo obteve o menor valor de EQM

para $n = 13$. Escolhemos assim o valor $n = 13$, na simulação de predição da série de tráfego SNU20100315.

Tabela 13 – Erros Quadrático Médio para a série de tráfego de rede SNU20100315 agregada em 100ms.

Ordem n	EQM	EQMN1	EQMN2
14	0.0057	0.0652	0.3944
13	0.0057	0.0651	0.3937
12	0.0057	0.0658	0.3977
11	0.0058	0.0663	0.4011
10	0.0059	0.0674	0.4075

A Figura 43 mostra a evolução do erro quadrático médio para a predição da série de tráfego de rede SNU20100315 agregada em 100ms. Pode-se notar que os algoritmos Fuzzy-LMS-FBO's apresentaram menores EQM em relação ao algoritmo Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal em quase toda simulação para a série SNU20100315. Nota-se maiores valores de EQM para o algoritmo Fuzzy LMS.




Figura 43 – Erro quadrático médio de predição para a série de tráfego de rede SNU20100315.

A Tabela 14 apresenta os erros quadrático médio e tempo computacional para a série de tráfego de rede SNU20100315 agregada em 100ms. Os resultados na Tabela 14 mostra que o algoritmo Fuzzy-LMS-FBO com alfa adaptativo apresentou o menor EQM com valor de 0.0057, seguido pelo algoritmo Fuzzy-LMS-FBO com alfa fixo apresentando um valor de 0.0061. O algoritmo Fuzzy LMS apresentou o maior valor de EQM dentre todos os algoritmos, com valor igual a 0.0071.

Tabela 14 – Erros Quadrático Médio e Tempo Computacional para a tráfego de rede SNU20100315 agregada em 100ms, com $n = 13$ para todos algoritmos.

Algoritmo	EQM	EQMN1	EQMN2	Tempo Médio(s)	Tempo Total(s)
Algoritmo Fuzzy-LMS-FBO com alfa adaptativo	0.0057	0.0651	0.3937	0.0010	1.4820
Algoritmo Fuzzy-LMS-FBO com alfa fixo	0.0061	0.0700	0.4231	6.2190×10^{-4}	0.9204
Fuzzy LMS	0.0071	0.0816	0.4938	3.4784×10^{-4}	0.5148
Fuzzy LMS com Auto-correlação Multifractal	0.0068	0.0798	0.4594	0.0162	23.9150

Os resultados apresentados pela Tabela 14 mostram que todos algoritmos obtiveram EQMN1 com valor inferior a 1 para a série de tráfego de rede considerado (SNU20100315), indicado uma melhor predição caso fosse estimado o valor futuro igual à média. Destacando-se o algoritmo Fuzzy-LMS-FBO com alfa adaptativo com valor de EQMN1 igual a 0.0651. Em relação ao erro normalizado EQMN2, podemos observar que todos os algoritmos também conseguiram obter valor inferior a 1 com destaque do algoritmo Fuzzy-LMS-FBO com alfa adaptativo, que apresentou o menor valor.

Os tempos computacionais (Tabela 14) mostram que o algoritmo Fuzzy LMS apresentou uma maior eficiência quando nos referimos a tempo total de execução, realizando a predição da série em 0.5148 segundos. O algoritmo Fuzzy LMS com Autocorrelação Multifractal obteve o maior tempo computacional com um valor de 23.9150 segundos de tempo total, enquanto os algoritmos Fuzzy-LMS-FBO com alfa fixo e alfa adaptativo apresentaram tempos total de execução respectivamente 0.9204 e 1.4820 segundos.




Figura 44 – QQ-plot para a predição do tráfego de rede SNU20100315 para o algoritmo Fuzzy-LMS-FBO com alfa adaptativo.

A Figura 44 mostra o gráfico Quantil-Quantil para a predição do tráfego de rede SNU20100315 do algoritmo Fuzzy-LMS-FBO com alfa adaptativo. Nota-se uma linearidade na curva em quase todo intervalo de valores preditos, apresentando um distanciamento da reta ideal aproximadamente entre o intervalo $[0.1, 0.4]$ e $[0.9, 1]$ para valores preditos.

5.4.2 Medidas de Desempenho Utilizadas para Avaliação do Controle de Fluxos

A avaliação do desempenho do esquema de controle de congestionamento proposto se baseia nas seguintes medidas de desempenho: TPB (Taxa de Perda de Bytes), Utilização do enlace e a Vazão da Taxa Controlável.

A TPB é a razão entre o número de bytes perdidos e o número total de bytes transmitidos durante o período de transmissão de dados. Ou seja,

$$TPB(\%) = \frac{\text{No de Bytes Perdidos}}{\text{No Total de Bytes Transmitidos}} \times 100\% \quad (5.18)$$

A utilização do enlace é a proporção da capacidade do enlace que é utilizada na transmissão dos fluxos de tráfego. É dada pela seguinte equação:

$$\text{Utilização}(\%) = \frac{\text{No de Bytes Transmitidos}}{\text{Capacidade do Enlace}} \times 100\% \quad (5.19)$$

A vazão do tráfego controlável é a quantidade de dados [*bytes*], oriundo das fontes controláveis, que são transmitidos com sucesso em um determinado período de tempo.

$$\text{Vazão}(\text{bytes/seg}) = \frac{\text{No de Bytes Transmitidos}}{\text{Tempo Total de Observação}} \quad (5.20)$$

5.4.2.1 Controle de tráfego de rede utilizando as séries Waikato

A simulação do controle de tráfego de rede utilizando as séries Waikato VIII-20111027-213205-5 e Waikato VIII 20110921-000000-0 foi executada com um *buffer* apresentando tamanho igual a $B_{max} = 9 \times 10^6$ *bytes* para o sistema apresentado na seção 5.1. O valor desejado do tamanho da fila no *buffer* b^r foi escolhido como sendo igual a $b^r = 0.3B_{max}\%$, com um valor igual a $b^r = 2.7 \times 10^6$ *bytes*. A capacidade η do canal foi inicializada igual a $\eta = 9 \times 10^6$ *bytes/segundos*.

Os parâmetros de aprendizagem α , a quantidade de regras *fuzzy* M , juntamente com os valores de $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ dos modelos Fuzzy foram inicializados da mesma forma como no exemplo da simulação na seção 5.4.1.1.




Figura 45 – Tamanho da fila no *buffer* para a série de tráfego Waikato VIII-20111027-213205-5 sem controle, método binário e o método proporcional.

A Figura 45 mostra o tamanho da fila no *buffer* em função do tempo para os métodos binário, proporcional e para o caso sem uso de controle (sem controle). Nota-se que o método binário apresentou um comportamento de ocupação da fila no *buffer* visualmente menor comparado ao método proporcional e para o caso sem controle.




Figura 46 – Tamanho da fila no *buffer* para a série de tráfego Waikato VIII-20111027-213205-5 e Waikato VIII 20110921-000000-0 utilizando algoritmo Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal.

A Figura 46 mostra o tamanho da fila no *buffer* em função do tempo para os algo-

ritmos Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal. Podemos observar que o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou um comportamento de ocupação da fila no *buffer* visualmente maior para os primeiros passos de iteração.




Figura 47 – Tamanho da fila no *buffer* para a série de tráfego Waikato VIII-20111027-213205-5 e Waikato VIII 20110921-000000-0 utilizando os algoritmos Fuzzy-LMS-FBO's.

Os resultados obtidos na simulação do controle de fluxos para os algoritmos Fuzzy-LMS-OBS's podem ser observados na Figura 47. Nota-se um comportamento de fila com menor preenchimento do buffer em relação as figuras 45 e 47.




Figura 48 – Tráfego controlável depois da aplicação do controle fuzzy adaptativo.

Na Figura 48 visualizamos o tráfego controlável $\mu(k)$ em função do tempo (iterações k) para os todos os algoritmos Fuzzy utilizados na simulação. Nota-se que o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou os maiores valores de intensidade tráfego(bytes), obtendo valores próximos a 9×10^6 bytes.




Figura 49 – Comparação do tráfego controlável antes e depois do controle fuzzy adaptativo.

A Figura 49 mostra a comparação da série de tráfego de rede Waikato VIII-20111027-213205-5 antes e depois da aplicação do controle de fluxos para os algoritmos *fuzzy* utilizados na simulação.

A Tabela 15 mostra a Média e a Variância do tamanho da fila no *buffer* para os algoritmos *fuzzy*, os métodos utilizados para comparação e o tráfego Sem Controle. Observa-se que o método Proporcional apresentou uma média do tamanho da fila no *buffer* superior aos demais, seguido pelo tráfego Sem Controle. Os algoritmos Fuzzy-LMS-FBO's apresentaram uma média do tamanho da fila no *buffer* menor em comparação aos outros métodos, com destaque para o Fuzzy LMS que apresentou a menor média. Nota-se

que o método proporcional apresentou média superior aos algoritmos Fuzzy LMS com Autocorrelação Multifractal e Fuzzy-LMS-FBO com alfa fixo.

Tabela 15 – Média e Variância da Fila no *Buffer*

	Média	Variância
Sem Controle	5.4970×10^6	1.5193×10^{13}
Binário	6.9963×10^4	3.6784×10^{11}
Proporcional	7.7294×10^6	3.5294×10^{12}
Fuzzy LMS-FBO com Alfa Adaptativo	6.7741×10^4	2.2428×10^{11}
Fuzzy LMS-FBO com Alfa Fixo	8.4620×10^4	2.6472×10^{11}
Fuzzy LMS	5.7077×10^4	2.3588×10^{11}
Fuzzy LMS com Autocorrelação Multifractal	1.6141×10^5	5.2452×10^{11}

Tabela 16 – Perda, Utilização e Vazão do *Buffer*

	Perda (%)	Utilização (%)	Vazão (bytes)
Sem Controle	10.2361	96.1328	8.6520×10^6
Binário	0.0580	61.8052	5.5625×10^6
Proporcional	6.8252	99.9911	8.9992×10^6
Fuzzy LMS-FBO com Alfa Adaptativo	0.0153	64.5069	5.3248×10^6
Fuzzy LMS-FBO com Alfa Fixo	0.0160	59.1650	5.8056×10^6
Fuzzy LMS	0.0177	62.7637	5.6487×10^6
Fuzzy LMS com Autocorrelação Multifractal	0.0212	56.8070	5.1126×10^6

As medidas de desempenho utilizadas para avaliação do controle de fluxos podem ser encontradas na Tabela 16. Nota-se que os algoritmos *fuzzy* obtiveram uma Taxa de Perda próximas a 0%, enquanto o método Binário obteve uma Taxa de Perda um pouco superior de valor 0,0508%. Nota-se que o algoritmo Fuzzy LMS-FBO com alfa fixo obteve a menor taxa de perda, com um valor de 0.0160%.

O algoritmo Fuzzy LMS com Autocorrelação Multifractal obteve a maior taxa de perda em comparação aos demais algoritmos *fuzzy* no controle de fluxo para os tráfegos Waikato na Tabela 16, ainda na Tabela 16 podemos observar que o algoritmo Fuzzy LMS com Autocorrelação Multifractal obteve a menor taxa de utilização do enlace e o menor valor de Vazão.

Os resultados apresentados na Tabela 16 mostram que o algoritmo Fuzzy LMS-FBO com alfa adaptativo obteve a menor taxa de perda em relação aos demais algoritmos. Nota-se que o algoritmo Fuzzy LMS-FBO com alfa adaptativo conseguiu obter a menor taxa de perda apresentando uma vazão superior ao algoritmo Fuzzy LMS com Autocorrelação Multifractal enquanto o algoritmo Fuzzy LMS-FBO com alfa fixo obteve taxa de utilização inferior em relação aos algoritmos Fuzzy LMS-FBO com alfa adaptativo e Fuzzy LMS.

5.4.2.2 Avaliação do Desempenho de Controle de Fluxos Utilizando as Séries de Tráfego SNU20100315 e SNU20100317

A simulação do controle de tráfego de rede utilizando as séries SNU20100315 e SNU20100317 foi executada com um *buffer* apresentando tamanho igual a $B_{max} = 1 \times 10^5$ bytes. O valor desejado do tamanho da fila no *buffer* b^r foi escolhido como sendo igual a $b^r = 0.3B_{max}\%$, com um valor igual a $b^r = 3 \times 10^4$ bytes. A capacidade η do canal foi inicializada igual a $\eta = 9 \times 10^5$ bytes/segundos.

Os parâmetros de aprendizagem α , a quantidade de regras Fuzzy M , juntamente com os valores de $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ dos modelos Fuzzy foram inicializados da mesma forma como no exemplo da simulação na seção 5.4.1.1.




Figura 50 – Tamanho da fila no *buffer* para as séries de tráfego SNU20100315 e SNU20100317 sem controle, método binário e o método proporcional.

A Figura 50 mostra o tamanho da fila no *buffer* em função do tempo para os métodos binário, proporcional e para o caso sem uso de controle (sem controle) utilizando as séries de tráfego SNU20100315 e SNU20100317. Podemos observar que o tamanho da fila do *buffer* para o método proporcional apresentou um comportamento aproximadamente no limiar (valor máximo do *buffer* $B_{max} = 1 \times 10^5$) em quase toda execução da simulação do

controle de fluxos, enquanto o método binário apresentou um comportamento de tamanho de fila no *buffer* visualmente inferior ao método proporcional.




Figura 51 – Tamanho da fila no *buffer* para as séries de tráfego SNU20100315 e SNU20100317 utilizando os algoritmos Fuzzy-LMS-FBO's.

A Figura 51 mostra o tamanho da fila no *buffer* em função do tempo para os algoritmos Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal utilizando as séries de tráfego SNU20100315 e SNU20100317. Nota-se que o comportamento de fila preenchido apresentado na figura 50 não foi visualizado na figura 51.




Figura 52 – Tamanho da fila no *buffer* para as séries de tráfego SNU20100315 e SNU20100317 utilizando algoritmo Fuzzy LMS e Fuzzy LMS com Autocorrelação Multifractal.

A Figura 52 mostra o tamanho da fila no *buffer* em função do tempo para os

algoritmos Fuzzy-LMS-FBO com alfa adaptativo e alfa fixo utilizando as séries de tráfego SNU20100315 e SNU20100317.




Figura 53 – Tráfego controlável depois da aplicação do controle *fuzzy* adaptativo utilizando a série de tráfego de rede SNU20100315.

Na Figura 53 visualizamos o tráfego controlável $\mu(k)$ em função tempo (iterações k) para os todos os algoritmos Fuzzy utilizados na simulação. Nota-se que o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou os maiores valores de tráfego, obtendo valores acima de 4×10^4 bytes.




Figura 54 – Comparação do tráfego controlável antes e depois do controle fuzzy adaptativo utilizando o tráfego de rede SNU20100315.

A Figura 54 mostra a comparação da série de tráfego de rede SNU20100315, agregada em $100ms$, antes e depois da aplicação do controle de fluxos para os algoritmos *fuzzy* utilizados na simulação.

A Tabela 17 mostra a Média e a Variância do tamanho da fila no *buffer* para os algoritmos *fuzzy*, os métodos utilizados para comparação e o tráfego Sem Controle. Observa-se que o método Proporcional apresentou uma média do tamanho da fila no *buffer* superior aos demais, seguido pelo tráfego Sem Controle. Os algoritmos Fuzzy-LMS-FBO's

apresentaram uma média do tamanho da fila no *buffer* menor em comparação aos outros métodos, com destaque para o Fuzzy-LMS-FBO com alfa fixo que apresentou a menor média. Nota-se que o método binário apresentou média superior aos algoritmos *fuzzy*.

Tabela 17 – Média e Variância da Fila no *Buffer*

	Média	Variância
Sem Controle	6.6110×10^4	2.2263×10^9
Binário	8.7734×10^3	5.6950×10^8
Proporcional	9.9822×10^4	1.2987×10^7
Fuzzy LMS-FBO com Alfa Adaptativo	2.2336×10^3	1.1010×10^8
Fuzzy LMS-FBO com Alfa Fixo	1.5783×10^3	7.1747×10^7
Fuzzy LMS	3.0690×10^3	1.6352×10^8
Fuzzy LMS com Auto-correlação Multifractal	2.3157×10^3	1.2087×10^8

Tabela 18 – Perda, Utilização e Vazão do *Buffer*

	Perda (%)	Utilização (%)	Vazão (bytes)
Sem Controle	51.6728	72.9901	6.5691×10^5
Binário	0.7223	62.2850	5.6057×10^5
Proporcional	99.8901	99.3987	8.9905×10^5
Fuzzy LMS-FBO com Alfa Adaptativo	0.0016	57.8889	5.2100×10^5
Fuzzy LMS-FBO com Alfa Fixo	0.0012	56.8454	5.1161×10^5
Fuzzy LMS	0.0266	59.2872	5.3358×10^5
Fuzzy LMS com Auto-correlação Multifractal	0.0070	57.2757	5.1548×10^5

As medidas de desempenho utilizadas para avaliação do controle de fluxos podem ser encontradas na Tabela 18. Nota-se que os algoritmos *fuzzy* obtiveram uma Taxa de Perda próximas a 0%, enquanto o método Binário obteve uma Taxa de Perda um pouco superior de 0,7223%. Nota-se que o algoritmo Fuzzy LMS-FBO com alfa fixo obteve a menor taxa de perda, com um valor de 0.0012%, apresentando também os menores valores de Utilização e Vazão.

O algoritmo Fuzzy-LMS-FBO com alfa adaptativo apresentou a segunda menor taxa de perda na Tabela 18 em relação aos demais algoritmos, enquanto o algoritmo Fuzzy LMS com Autocorrelação Multifractal apresentou uma Vazão menor em comparação ao algoritmo Fuzzy-LMS-FBO com alfa adaptativo apesar de não obter uma menor taxa de perda.

Conclusão

Neste trabalho apresentamos uma modificação do modelo Fuzzy LMS onde se inclui valores da função de autocorrelação do modelo multifractal, para atualização do parâmetro θ do modelo *fuzzy* através da equação de *Wiener-Hopf*. Os resultados se mostraram favoráveis em termos de predição, apresentando menores erros quadráticos médios em comparação com outros algoritmos da literatura (Fuzzy LMS, LMS e Fuzzy RLS). O algoritmo de predição proposto Fuzzy LMS com Autocorrelação Multifractal também foi empregado em um esquema de provisão de banda, o qual também se mostrou favorável em relação a outros preditores, apresentando taxa de perda, tamanho médio da fila e utilização menores.

Os resultados obtidos nas simulações do controle de fluxos mostraram que os algoritmos *fuzzy* propostos apresentam melhores resultados em termos de Média e Variância do tamanho da fila no *buffer* em relação aos métodos Binário, Proporcional, Fuzzy LMS e ao tráfego Sem Controle. Os algoritmos propostos Fuzzy-LMS-FBO's, o Fuzzy LMS e o Fuzzy LMS com Autocorrelação Multifractal, resultaram em Taxas de Perdas próximos a 0% para o sistema de congestionamento proposto com as séries de tráfego de rede utilizadas neste trabalho. Destacando também uma redução na Utilização e Vazão.

Os tempo computacionais obtidos, para os algoritmos *fuzzy* propostos, revelaram um valor superior em relação aos algoritmos LMS, Fuzzy LMS e Fuzzy RLS, sendo não crítico e aplicável em aplicações com tempo real, devido ao fato desse acréscimo de tempo não ser superior ao atraso de realimentação (tempo necessário a execução da próxima iteração) do controle de fluxos.

Os resultados obtidos mostram que a alocação de recursos de rede, no nosso caso específico, alocação de banda e controle de fluxos de tráfego de rede pode se usufruir de uma predição mais precisa do tráfego de rede, podendo ser ofertado uma melhor qualidade de serviços (QoS).

Como trabalhos futuros, sugerimos as seguintes propostas:

- Aplicar os algoritmos de predição em outros esquemas de alocação de banda mais complexos e mais realistas.
- Ampliação do sistema de congestionamento *fuzzy* para atender mais de 2 tipos de fluxos de tráfego de redes.

Referências

- AQUINO, V. A.; BARRIA, J. A. Multiresolution fir neural-network-based learning algorithm applied to network traffic prediction. *IEEE Transactions on Systems*, v. 36, n. 2, p. 208–220, 2006. Citado na página 69.
- BEZDEK, J. Fuzzy models What are they, and why? *Fuzzy Systems, IEEE Transactions on*, v. 1, n. 1, p. 1–6, 1993. ISSN 1063-6706. Citado 2 vezes nas páginas 17 e 55.
- CHEN, B.; LIU, X.; TONG, S. Adaptive Fuzzy Output Tracking Control of MIMO Nonlinear Uncertain Systems. *Fuzzy Systems, IEEE Transactions on*, v. 15, n. 2, p. 287–300, April 2007. Citado na página 78.
- CHEN, B.-S.; PENG, S.-C.; WANG, K.-C. Traffic modeling, prediction, and congestion control for high-speed networks: a fuzzy ar approach. *Fuzzy Systems, IEEE Transactions on*, v. 8, n. 5, p. 491–508, 2000. Citado na página 55.
- CHEN, T. M.; LIU, S. S.; SAMALAM, V. K. The Available Bit Rate Service for Data in ATM Networks. *Comm. Mag.*, v. 34, n. 5, p. 56–58, 63–71, maio 1996. Citado 3 vezes nas páginas 79, 80 e 89.
- CHUI, C. K. *An Introduction to Wavelets*. San Diego, CA, USA: Academic Press Professional, Inc., 1992. ISBN 0-12-174584-8. Citado na página 22.
- DANG, T. D.; MOLNAR, S.; MARICZA, I. Capturing the complete characteristics of multifractal network traffic. *GLOBECOM*, Taipei, Taiwan, Novembro 2002. Citado 2 vezes nas páginas 21 e 83.
- DANG, T. D.; MOLNAR, S.; MARICZA, I. Capturing the Complete Multifractal Characteristics of Network Traffic. In: *In Proc., GLOBECOM 2002*. [S.l.: s.n.], 2002. Citado na página 21.
- DANG, T. D.; MOLNAR, S.; MARICZA, I. Queuing performance estimation for general multifractal traffic. *Int. J. Commun. Syst.*, v. 16, n. 2, p. 117–136, 2003. Citado 4 vezes nas páginas 19, 21, 22 e 28.
- DEC. *Digital Equipament Corporation Traces*. 1995. Disponível em: <<http://ita.ee.lbl.gov/html/contrib/DEC-PKT.html>>. Citado 2 vezes nas páginas 57 e 127.
- DINIZ, P. S. R. *Adaptive Filtering: Algorithms and Practical Implementation*. [S.l.]: Springer, 2008. Citado 3 vezes nas páginas 45, 49 e 54.
- DITZE, M.; JAHNICH, I. Towards end-to-end QoS in service oriented architectures. In: *Industrial Informatics, 2005. INDIN '05. 2005 3rd IEEE International Conference on*. [S.l.: s.n.], 2005. p. 92–97. Citado na página 17.
- DURRESI, A.; SRIDHARAN, M.; JAIN, R. Congestion control using adaptive multilevel early congestion notification. *International Journal of High performance and Networking*, v. 4, n. 5, 2006. Citado na página 78.
- EHLERS, R. S. [S.l.]: Departamento de Estatísticas UFPR, 2005. Citado na página 31.

- FARHANG-BOROUJENY, B. *Adaptive Filters: Theory and Applications*. [S.l.]: John Wiley & Sons, 1999. Citado 2 vezes nas páginas 60 e 90.
- FELDMANN, A.; GILBERT, A. C.; WILLINGER, W. Data networks as cascades: investigating the multifractal nature of Internet WAN traffic. *SIGCOMM Comput. Commun. Rev.*, ACM, New York, NY, USA, v. 28, n. 4, p. 42–55, 1998. Citado na página 19.
- GILL, P. E.; MURRAY, W.; WRIGHT, M. H. *Practical Optimization*. [S.l.]: Emerald Group Publishing Limited, 1982. Citado na página 48.
- GONCALVES, B. H. P.; VIEIRA, F. H. T.; COSTA, V. H. T. Modelagem Multifractal BMWM Adaptiva para Tráfego de Redes de Computadores. In: *X Encontro Anual de Computação - EnAComp 2013*. [S.l.: s.n.], 2013. p. 383–390. Citado 6 vezes nas páginas 24, 25, 82, 83, 85 e 86.
- GRIPENBERG, G.; NORROS, I. On the prediction of fractional brownian motion. *Journal of Applied Probability*, v. 33, p. 400–410, 1996. Citado na página 56.
- GULER, O. *Foundations of Optimization (Graduate Texts in Mathematics, Vol. 258)*. [S.l.]: Springer, 2010. Citado na página 48.
- HABIB, I. W.; SAADAWI, T. N. Access flow control algorithms in broadband networks. *Computer Communications*, v. 15, n. 5, p. 326–332, 1992. Citado 2 vezes nas páginas 79 e 89.
- HATANO, T.; SHIGENO, H.; OKADA, K. TCP-friendly Congestion Control for HighSpeed Network. In: *Applications and the Internet, 2007. SAINT 2007. International Symposium on*. [S.l.: s.n.], 2007. p. 10–10. Citado na página 17.
- HAYKIN, S. S. *Modern filters*. [S.l.]: Macmillan New York, 1989. Citado na página 57.
- HIRCHOREN, G.; ARANTES, D. Predictors for the discrete time fractional gaussian processes. In: *Telecommunications Symposium, 1998. ITS '98 Proceedings. SBT/IEEE International*. [S.l.: s.n.], 1998. p. 49–53 vol.1. Citado na página 56.
- HU, Q.; PETR, D. A predictive self-tuning fuzzy-logic feedback rate controller. *Networking, IEEE/ACM Transactions on*, v. 8, n. 6, p. 697–709, Dec 2000. Citado na página 78.
- INTEL. *Intel Pentium Processor T4500*. 2014. Disponível em: <http://ark.intel.com/PT-BR/products/42925/Intel-Pentium-Processor-T4500-1M-Cache-2_30-GHz-800-MHz-FSBf>. Citado na página 58.
- JACOBSON, V. Congestion Avoidance and Control. *SIGCOMM Comput. Commun. Rev.*, v. 25, n. 1, p. 157–187, jan. 1995. ISSN 0146-4833. Citado na página 81.
- JANTZEN, J. *Foundations of Fuzzy Control*. [S.l.]: John Wiley & Sons, 2007. Citado na página 38.
- JUSAK, J.; HARRIS, R. Study of UDP-based Internet traffic: Long-range dependence characteristics. In: *Australasian Telecommunication Networks and Applications Conference (ATNAC), 2011*. [S.l.: s.n.], 2011. p. 1–7. ISSN Pending. Citado na página 17.

- KARNIK, A.; KUMAR, A. Performance of TCP Congestion Control with Explicit Rate Feedback. *IEEE/ACM Trans. Netw.*, IEEE Press, v. 13, n. 1, p. 108–120, fev. 2005. ISSN 1063-6692. Citado 2 vezes nas páginas 79 e 89.
- KIM, E. et al. A new approach to fuzzy modeling. *Fuzzy Systems, IEEE Transactions on*, v. 5, n. 3, p. 328–337, Aug 1997. Citado na página 55.
- KIM, S. et al. *Dataset of BitTorrent traffic on Korea Telecom's mobile WiMAX network*. 2012. Disponível em: <<http://crawdad.cs.dartmouth.edu/snu/bittorrent/>>. Citado 4 vezes nas páginas 22, 88, 129 e 131.
- KUO, S. M.; LEE, B. H.; TIAN, W. *Real-Time Digital Signal Processing: Fundamentals, Implementations and Applications*. [S.l.]: John Wiley & Sons, 2013. Citado na página 50.
- LEE, I. W. C.; FAPOJUWO, A. O. Stochastic Processes for Computer Network Traffic Modeling. *Comput. Commun.*, Elsevier Science Publishers B. V., v. 29, n. 1, p. 1–23, dez. 2005. ISSN 0140-3664. Citado na página 78.
- LEE, K. Y. Complex fuzzy adaptive filter with LMS algorithm. *Signal Processing, IEEE Transactions on*, v. 44, n. 2, p. 424–427, 1996. ISSN 1053-587X. Citado na página 57.
- LEE, T.-J.; VECIANA, G. de. Model and performance evaluation for multiservice network link supporting ABR and CBR services. *Communications Letters, IEEE*, v. 4, n. 11, p. 375–377, Nov 2000. Citado na página 80.
- LI, H.; CHEN, C. P.; HUANG, H.-P. *Fuzzy Neural Intelligent Systems: Mathematical Foundation and the Applications in Engineering*. [S.l.]: CRC Press, 2000. Citado na página 35.
- LILLY, J. H. *Fuzzy control and identification*. [S.l.]: John Wiley & Sons, 2010. Citado na página 40.
- LIU, H.-H.; HSU, P.-L. Design and simulation of adaptive fuzzy control on the traffic network. In: *SICE-ICASE, 2006. International Joint Conference*. [S.l.: s.n.], 2006. p. 4961–4966. Citado na página 55.
- MAMDANI, E.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, v. 7, n. 1, p. 1 – 13, 1975. Citado na página 35.
- NORROS, I. A storage model with self-similar input. *Queueing Systems*. Citado na página 32.
- OUYANG, C.-S.; LEE, W.-J.; LEE, S.-J. A TSK-type neurofuzzy network approach to system modeling problems. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, v. 35, n. 4, p. 751–767, Aug 2005. Citado na página 78.
- OUYANG, Y. C.; YANG, C. W.; LIAN, W. S. Neural networks based variable bit rate traffic prediction for traffic control using multiple leaky bucket. *Journal of High Speed Networks*, v. 15, n. 2, p. 11–122, 2006. Citado na página 69.
- PAPOULIS, A. *Probability, Random Variables, and Stochastic Processes*. [S.l.]: Mc-Graw Hill, 1984. Citado na página 58.

- PARK, K.; WILLINGER, W. *Self-similar Network Traffic and Performance Evaluation*. New York: John Wiley and Sons, 2000. Citado 4 vezes nas páginas 19, 20, 31 e 55.
- PAVLOV, A. N.; ANISHCHENKO, V. S. Multifractal analysis of complex signals. *Physics-Uspekhi*, v. 50, n. 8, p. 819, 2007. Citado na página 32.
- PAXSON, V.; FLOYD, S. Wide area traffic: the failure of poisson modeling. *Networking, IEEE/ACM Transactions on*, v. 3, n. 3, p. 226–244, Jun 1995. Citado na página 57.
- RAMAKRISHNAN, K. K.; JAIN, R. A Binary Feedback Scheme for Congestion Avoidance in Computer Networks. *ACM Trans. Comput. Syst.*, v. 8, n. 2, p. 158–181, maio 1990. ISSN 0734-2071. Citado na página 89.
- RIBEIRO, V. J. et al. Multiscale queuing analysis of long-range-dependent network traffic. In: *Proc. IEEE INFOCOM*. [S.l.: s.n.], 2000. p. 1026–1035. Citado na página 22.
- RIBEIRO, V. J. et al. Small-time scaling behavior of internet backbone traffic. *Computer Networks: The International Journal of Computer and Telecommunications Networking*, Elsevier North-Holland, Inc., v. 48, n. 3, p. 315–334, 2005. Citado na página 31.
- RIEDI, R. H. et al. A multifractal wavelet model with application to network traffic. *Information Theory, IEEE Transactions on*, v. 45, n. 3, p. 992–1018, Apr 1999. Citado 5 vezes nas páginas 19, 22, 24, 31 e 83.
- ROCHA, F. G. C.; VIEIRA, F. H. T. Modelagem de tráfego de vídeo mpeg-4 utilizando cascata multifractal com distribui cao autorregressiva dos multiplicadores. In: *The 8th International Information and Telecommunication Technologies Symposium*. [S.l.: s.n.], 2009. Citado na página 22.
- ROLLS, D. A.; MICHAILIDIS, G.; HERNÁNDEZ-CAMPOS, F. Queueing analysis of network traffic: Methodology and visualization tools. *Comput. Netw.*, v. 48, n. 3, p. 447–473, jun. 2005. ISSN 1389-1286. Citado 2 vezes nas páginas 65 e 93.
- RONGCAI, Z.; SHUO, Z. Network traffic generation: A combination of stochastic and self-similar. In: *Advanced Computer Control (ICACC), 2010 2nd International Conference on*. [S.l.: s.n.], 2010. v. 2, p. 171–175. Citado na página 17.
- ROSS, T. J. *Fuzzy logic with engineering applications*. [S.l.]: John Wiley & Sons, 2009. Citado 8 vezes nas páginas 6, 17, 35, 36, 40, 42, 43 e 55.
- SCHILLING, R.; HARRIS, S. *Fundamentals of digital signal processing using MATLAB*. [S.l.]: Cengage Learning, 2011. Citado na página 45.
- SEURET, S.; GILBERT, A. Pointwise hölder exponent estimation in data network traffic. *ITC Specialist Semina*, 2000. Citado na página 31.
- SOUZA, B. V. L.; VIEIRA, F. H. T. Algoritmo de predição de tráfego de rede baseado na função autocorrelação de um modelo multifractal. In: *XXXIV Congresso Nacional de Matemática Aplicada e Computacional*. Águas de Lidóias, SP: [s.n.], 2012. Citado na página 56.
- SUGENO, M.; YASUKAWA, T. A fuzzy-logic-based approach to qualitative modeling. *Fuzzy Systems, IEEE Transactions on*, v. 1, n. 1, p. 7–, Feb 1993. Citado na página 55.

- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-15, n. 1, p. 116–132, Jan 1985. Citado na página 55.
- TOREYIN, B. et al. Lms based adaptive prediction for scalable video coding. In: *Acoustics, Speech and Signal Processing, 2006. ICASSP 2006 Proceedings. 2006 IEEE International Conference on*. [S.l.: s.n.], 2006. v. 2, p. II–II. Citado na página 57.
- TRAN, H. T.; ZIEGLER, T. Adaptive bandwidth provisioning with explicit respect to qos requirements. *Computer Communications*, v. 28, p. 1862–1876, 2005. Citado na página 69.
- VIEIRA, F.; ROCHA, F. An adaptive fuzzy model using orthonormal basis functions based on multifractal characteristics applied to network traffic control. *Neurocomputing*, v. 74, n. 11, p. 1894–1907, 2011. Citado na página 82.
- VIEIRA, F. H. T.; COSTA, V. H. T.; SOUZA, B. V. L. Neural network based approaches for network traffic prediction. *Artificial Intelligence, Evolutionary Computing and Metaheuristics*, v. 427, p. 657–684, 2013. Citado na página 22.
- VIEIRA, F. H. T.; LING, L. L. Modelagem fuzzy utilizando funções de base ortonormais aplicada à predição adaptativa de tráfego de redes. *Learning and Nonlinear Models. Rev. Socied. Brasileira de Redes Neurais (SBRN)*, v. 4, n. 2, p. 93–111, 2006. Citado 2 vezes nas páginas 19 e 26.
- VIEIRA, F. H. T.; LING, L. L. Performance bounds for a cascade based multifractal traffic model with generalized multiplier distributions. *Journal of Communication and Information Systems*, v. 21, p. 165–175, 2006. Citado na página 20.
- VIEIRA, F. H. T.; LING, L. L. Modelagem de tráfego de redes utilizando cascata multifractal generalizada. *Revista de Informática Teórica e aplicada*, v. 15, n. 2, 2008. Citado na página 31.
- VIEIRA, F. H. T.; ROCHA, F. G. C.; LEMOS, R. P. An algorithm for adaptive prediction of local singularities of network traffic flows. 2010. Citado na página 31.
- WANG, C. et al. LRED: A Robust and Responsive AQM Algorithm Using Packet Loss Ratio Measurement. *Parallel and Distributed Systems, IEEE Transactions on*, v. 18, n. 1, p. 29–43, Jan 2007. Citado 2 vezes nas páginas 78 e 79.
- WANG, L.-X. *Adaptive Fuzzy Systems and Control: Design and Stability Analysis*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1994. ISBN 0-13-099631-9. Citado 11 vezes nas páginas 6, 37, 39, 40, 41, 42, 44, 50, 57, 59 e 88.
- WANG, Z.-x. et al. Research on fuzzy neural network algorithms for nonlinear network traffic predicting. In: *Optoelectronics Letters*. [S.l.: s.n.], 2006. p. 373–375. ISSN Pending. Citado na página 17.
- WITS. *WITS: Waikato Internet Traffic Storage from University of Waikato*. 2014. Disponível em: <<http://wand.net.nz/wits/waikato/8/>>. Citado 2 vezes nas páginas 57 e 88.
- YU, Y. et al. Traffic prediction in 3G mobile networks based on multifractal exploration. *Tsinghua Science and Technology*, v. 18, n. 4, p. 398–405, 2013. Citado na página 17.

ZHANG, R.; PHILLIS, Y. A.; KOUIKOGLOU, V. S. *Fuzzy Control of Queuing Systems*. [S.l.]: Springer, 2005. Citado na página 17.

ZOU, D.; ZHANG, X.; WANG, W. Multi-service traffic models of heterogeneous wireless communication networks. *Proc. of the 7th World Congress on Intelligent Control and Automation*, p. 495–498, 2008. Citado na página 21.

Apêndices

APÊNDICE A – Variações dos Algoritmos Fuzzy Propostos

Nas seções anteriores apresentamos dois algoritmos propostos, o primeiro faz uso do Algoritmo de Levenberg–Marquardt para calcular adaptativamente o alfa multifractal, sendo empregado no Algoritmo Fuzzy LMS Autocorrelação Multifractal (Fuzzy LMS-AM), enquanto o segundo algoritmo proposto faz uso do modelo β MWM Adaptativo. Nesta seção apresentamos duas variações dos algoritmos Fuzzy LMS Autocorrelação Multifractal e Fuzzy LMS-FBO com alfa adaptativo.

O primeiro algoritmo proposto, nomeado Fuzzy LMS Autocorrelação Multifractal β MWM (Fuzzy LMS-AM β MWM), faz uso do modelo β MWM Adaptativo para atualizar o parâmetro α da equação da função de Autocorrelação Multifractal. Substituímos assim, o parâmetro θ pelos pesos ótimos do filtro de Wiener, do mesmo modo empregado no algoritmo Fuzzy LMS Autocorrelação Multifractal.

Definimos o algoritmo Fuzzy LMS Autocorrelação Multifractal β MWM pelos seguintes passos:

- **Passo 1:** Execute o algoritmo β MWM adaptativo para calcular o parâmetro α multifractal adaptativamente.
- **Passo 2:** Calcule a função de autocorrelação multifractal através do valor do parâmetro α multifractal, utilizando a seguinte equação:

$$E[X(n), X(n+k)] = e^{2\rho+\sigma^2} \left(\frac{\alpha(\alpha+1)^{N-1}}{(\alpha+1/2)^N} k^{-\log_2(\frac{\alpha+1}{\alpha+1/2})} \right)$$

- **Passo 3:** Calcule os pesos ótimos do filtro de Wiener utilizando a função de autocorrelação multifractal, através da seguinte equação:

$$\sum_{k=1}^N w_0(m) E[x(n-m)x(n-k)] = E[x(n+\Delta-1)x(n-k)] \quad k = 1, 2, 3, \dots, N$$

- **Passo 4:** Substitua o parâmetro θ do modelo Fuzzy LMS pelos pesos ótimos do filtro de Wiener.
- **Passo 5:** Realize a adaptação dos parâmetros $\bar{x}_i^l$ e σ_i^l do modelo Fuzzy LMS.

$$\begin{aligned} \bar{x}_i^l(k) &= \bar{x}_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{x_i(k) - \bar{x}_i^l(k-1)}{(\sigma_i^l(k-1))^2} \\ \sigma_i^l(k) &= \sigma_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{(x_i(k) - \bar{x}_i^l(k-1))^2}{(\sigma_i^l(k-1))^3} \end{aligned}$$




Figura 55 – Fluxograma do algoritmo Fuzzy LMS Autocorrelação Multifractal β MWM.

- **Passo 6:** A cada iteração realize os passos 1 até o 5 novamente, até que sejam realizadas todas iterações.

A Figura 55 mostra os passos de execução do algoritmo Fuzzy LMS Autocorrelação Multifractal β MWM através de um fluxograma.

O segundo algoritmo proposto, nomeado Fuzzy LMS-FBO Levenberg–Marquardt utiliza o algoritmo Levenberg-Marquardt para atualizar o parâmetro α adaptativamente e o polo através de α pela seguinte equação:

$$p = -\frac{1}{2^{\log_2\left(\frac{\alpha+1}{\alpha+1/2}\right)}}$$

Na sequência calculamos a matriz A e b utilizados no cálculo das Funções de Laguerre $l(k)$ e aplicamos no modelo Fuzzy LMS, do mesmo modo empregado no algoritmo Fuzzy LMS-FBO com alfa adaptativo.

Definimos o algoritmo Fuzzy LMS-FBO Levenberg–Marquardt pelos seguintes passos:

- **Passo 1:** Execute o algoritmo Levenberg-Marquardt para calcular o parâmetro α multifractal adaptativamente.
- **Passo 2:** Calcule o polo de Laguerre através do valor do parâmetro α multifractal.

$$p = -\frac{1}{2^{\log_2\left(\frac{\alpha+1}{\alpha+1/2}\right)}}$$

- **Passo 3:** Calcule a Matriz A e o vetor b para o cálculo das funções de Laguerre.

$$A = \begin{pmatrix} p & 0 & \dots & 0 \\ 1 - p^2 & p & \dots & 0 \\ (-p)(1 - p) & 1 - p^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ (-p)^{n-2}(1 - p) & (-p)^{n-3}(1 - p) & \dots & p \end{pmatrix}$$

$$b = \sqrt{(1 - p^2)} [1 \quad (-p) \quad (-p)^2 \quad \dots \quad (-p)^{n-1}]^T$$

- **Passo 4:** Calcule as funções de Laguerre $l(k)$ através de A e b .

$$\mathbf{l}(k+1) = A\mathbf{l}(k) + b\mathbf{u}(k)$$

- **Passo 5:** Execute o algoritmo de adaptação dos parâmetros $\theta^l(0)$, $\bar{x}_i^l(0)$ e $\sigma_i^l(0)$ do modelo Fuzzy LMS tendo como entrada as funções de Laguerre $l(k)$.

$$\theta^l(k) = \theta^l(k-1) + \gamma[d(k) - f_k] \frac{z^l(k-1)}{b(k-1)}$$

$$\bar{x}_i^l(k) = \bar{x}_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{x_i(k) - \bar{x}_i^l(k-1)}{(\sigma_i^l(k-1))^2}$$

$$\sigma_i^l(k) = \sigma_i^l(k-1) + \gamma[d(k) - f_k] \frac{\theta^l(k-1) - f_k}{b(k-1)} z^l(k-1) \frac{(x_i(k) - \bar{x}_i^l(k-1))^2}{(\sigma_i^l(k-1))^3}$$

- **Passo 6:** A cada iteração realize os passos 1 até o 5 novamente, até que sejam realizadas todas iterações.

A Figura 56 mostra os passos de execução do algoritmo Fuzzy-LMS-FBO com Alfa Adaptativo através de um fluxograma.




Figura 56 – Fluxograma do algoritmo Fuzzy-LMS-FBO Levenberg–Marquardt.




Figura 57 – Erro Quadrático Médio de predição para a série de tráfego de rede SNU20100315 agregada em 100ms.

A Figura 57(a) e (b) mostra o Erro Quadrático Médio de predição dos algoritmos propostos para a série de tráfego de rede SNU20100315 agregada em 100ms. Nota-se que o algoritmo Fuzzy-LMS-FBO com Alfa Adaptativo obteve os menores erros quadrático médio em comparação aos demais algoritmos, enquanto o algoritmo Fuzzy LMS-AM β MWM obteve os maiores EQM's.

Tabela 19 – Erros Quadrático Médio e Tempo Computacional para a série de tráfego de rede SNU20100315 agregada em 100ms, com $n = 12$ para todos algoritmos.

Algoritmo	EQM	EQMN1	EQMN2	Tempo Médio(s)	Tempo Total(s)
Algoritmo Fuzzy-LMS-FBO com alfa adaptativo	0.0057	0.0658	0.3977	0.0010	1.4820
Fuzzy LMS Autocorrelação Multifractal	0.0078	0.0918	0.5284	0.0162	23.9150
Fuzzy LMS-AM β MWM	0.0696	0.8166	4.6987	0.0067	9.9360
Fuzzy LMS-FBO Levenberg-Marquardt	0.0095	0.1082	0.6545	0.0131	19.4229

A Tabela 19 mostra o desempenho dos algoritmos propostos em termos de erros quadrático médio e tempo computacionais para a série tráfego de rede SNU20100315 agregada em 100ms. O algoritmo Algoritmo Fuzzy-LMS-FBO com alfa adaptativo apresentou os menores EQM, EQMN1 e EQMN2 em comparação aos demais algoritmos, diferentemente do algoritmo Fuzzy LMS-AM β MWM que apresentou os maiores EQM, EQMN1 e EQMN2.

Destaca-se o algoritmo Fuzzy LMS-AM β MWM que apresentou EQMN2 superior a 1, indicando que há uma melhor predição caso fosse estimado o valor futuro como sendo igual ao valor imediatamente anterior.

Na Tabela 19 são apresentados os tempos computacionais dos algoritmos propostos. Destaca-se o algoritmo Fuzzy-LMS-FBO com alfa adaptativo que obteve os menores tempos computacionais em comparação aos demais.

Os algoritmos Fuzzy LMS Autocorrelação Multifractal e Fuzzy LMS-FBO Levenberg–Marquardt, que fazem o uso do algoritmo Levenberg–Marquardt, apresentaram os maiores tempos computacionais em comparação aos demais enquanto os algoritmos Fuzzy-LMS-FBO com alfa adaptativo e Fuzzy LMS Autocorrelação Multifractal β MWM, que fazem uso do algoritmo β MWM adaptativo, apresentaram os menores tempos computacionais, destacando o algoritmo Fuzzy-LMS-FBO que não utiliza a função de autocorrelação multifractal.

Anexos

ANEXO A – Tráfego de Rede Waikato VIII 20110921-000000-0

O tráfego de rede Waikato VIII 20110921-000000-0 foi obtido do *Network Reasearch Group WAND* do Departamento de Ciência de Computação da *University of Waikato* foi coletada no dia 21 de setembro de 2011.




Figura 58 – Série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms.

A Figura 58 mostra a série de tráfego Waikato VIII 20110921-000000-0 em função do tempo na escala de agregação de 512ms.

Tabela 20 – Dados Estatísticos da série de tráfego de rede Waikato VIII 20110921-000000-0.

Média	Variância	Expoente de Hurst	Valor Máximo	Valor Mínimo
2.5457×10^6	4.8309×10^{11}	0.8892	6870167	444828

A Tabela 20 mostra a média, a variância e o expoente de Hurst, o valor máximo e o valor mínimo da série de tráfego de rede Waikato VIII 20110921-000000-0.




Figura 59 – Histograma da série de tráfego de rede Waikato VIII 20110921-000000-0 agregada em 512ms.

A Figura 59 mostra o histograma e a aproximação da função de distribuição lognormal para a série de tráfego de rede Waikato VIII 20110921-000000-0.

ANEXO B – Tráfego de Rede Waikato VIII 20111027-213205-5

O tráfego de rede Waikato VIII 20111027-213205-5 foi obtido do *Network Research Group WAND* do departamento de ciência de computação da *University of Waikato* foi coletada no dia 27 de outubro de 2011.




Figura 60 – Série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.

A Figura 60 mostra a série de tráfego Waikato VIII 20111027-213205-5 em função do tempo na escala de agregação de 512ms.

Tabela 21 – Dados Estatísticos da série de tráfego de rede Waikato VIII 20111027-213205-5.

Média	Variância	Expoente de Hurst	Valor Máximo	Valor Mínimo
2.3540×10^6	5.0972×10^{11}	0.8895	6993460	484334

A Tabela 21 mostra a média, a variância e o expoente de Hurst, o valor máximo e o valor mínimo da série de tráfego de rede Waikato VIII 20110921-000000-0.




Figura 61 – Histograma da série de tráfego de rede Waikato VIII 20111027-213205-5 agregada em 512ms.

A Figura 61 mostra o histograma e a aproximação da função de distribuição lognormal para a série de tráfego de rede Waikato VIII 20111027-213205-5.

ANEXO C – Tráfego de Rede Waikato VIII 20111029-110001-1

O tráfego de rede Waikato VIII 20111029-110001-1 foi obtido do *Network Reasearch Group WAND* do departamento de ciência de computação da *University of Waikato* foi coletada no dia 29 de outubro de 2011.




Figura 62 – Tráfego de rede Waikato VIII 20111029-110001-1.

A Figura 62 mostra a série de tráfego Waikato VIII 20111029-110001-1 em função do tempo nas escalas de agregação de $10ms$, $100ms$ e $512ms$.

Tabela 22 – Dados Estatísticos da série de tráfego de rede Waikato VIII 20111029-110001-1.

Agregação	Média	Variância	Expoente de Hurst	Valor Máximo	Valor Mínimo
10ms	9.8541×10^3	1.3621×10^8	0.8155	107591	60
100ms	1.1420×10^5	4.0652×10^9	0.8673	894209	4484
512ms	$5.1678e \times 10^5$	1.6643×10^{11}	0.9582	6989977	12826

A Tabela 22 mostra a média, a variância e o expoente de Hurst, o valor máximo e o valor mínimo da série de tráfego de rede Waikato VIII 20111029-110001-1.




Figura 63 – Histograma da série de tráfego de rede Waikato VIII 20111029-110001-1.

A Figura 63 mostra o histograma e a aproximação da função de distribuição lognormal para a série de tráfego de rede Waikato VIII 20111029-110001-1.

ANEXO D – Tráfego de Rede dec-pkt-2

O tráfego de rede dec-pkt-2 contém uma hora de tráfego obtido entre a *Digital Equipment Coporation* e o resto do mundo, sendo coletada no dia 9 de março de 1995 (DEC, 1995).




Figura 64 – Série de tráfego de rede dec-pkt-2 agregada em 512ms.

A Figura 64 mostra a série de tráfego dec-pkt-2 em função do tempo na escala de agregação de 512ms.

Tabela 23 – Dados Estatísticos da série de tráfego de rede dec-pkt-2.

Média	Variância	Expoente de Hurst	Valor Máximo	Valor Mínimo
1.8622×10^4	2.8493×10^8	0.7874	172913	98

A Tabela 22 mostra a média, a variância o e expoente de Hurst, o valor máximo e o valor mínimo da série de tráfego de rede Waikato dec-pkt-2.




Figura 65 – Histograma da série de tráfego de rede dec-pkt-2 agregada em 512ms.

A Figura 65 mostra o histograma e a aproximação da função de distribuição lognormal para a série de tráfego de rede dec-pkt-2.

ANEXO E – Tráfego de Rede SNU20100315

O tráfego de rede SNU20100315 representa a série de tráfego obtido em 2010 na rede sem fio WiMAX da *Seoul National University* (KIM et al., 2012), sendo coletada no dia 15 de março de 2010.




Figura 66 – Série de tráfego de rede SNU20100315 agregada em 100ms.

A Figura 66 mostra a série de tráfego SNU20100315 em função do tempo na escala de agregação de 100ms.

Tabela 24 – Dados Estatísticos da série de tráfego de rede SNU20100315 agregada em 100ms.

Média	Variância	Expoente de Hurst	Valor Máximo	Valor Mínimo
2.5590×10^5	2.8007×10^{10}	0.9752	565192	0

A Tabela 24 mostra a média, a variância o e expoente de Hurst, o valor máximo e o valor mínimo da série de tráfego de rede SNU20100315.




Figura 67 – Histograma da série de tráfego de rede SNU20100315 agregada em 100ms.

A Figura 67 mostra o histograma para a série de tráfego de rede SNU20100315.

ANEXO F – Tráfego de Rede SNU20100317

A série de tráfego de rede SNU20100317 representa o tráfego obtido em 2010 na rede sem fio WiMAX da *Seoul National University* (KIM et al., 2012), sendo coletada no dia 17 de março de 2010.




Figura 68 – Série de tráfego de rede SNU20100317 agregada em 100ms.

A Figura 66 mostra a série de tráfego SNU20100317 em função do tempo na escala de agregação de 100ms.

Tabela 25 – Dados Estatísticos da série de tráfego de rede dec-pkt-2.

Média	Variância	Expoente de Hurst	Valor Máximo	Valor Mínimo
2.4998×10^5	2.9359×10^{10}	0.9605	540222	0

A Tabela 25 mostra a média, a variância e o expoente de Hurst, o valor máximo e o valor mínimo da série de tráfego de rede SNU20100317.




Figura 69 – Histograma da série de tráfego de rede SNU20100317 agregada em 100ms.

A Figura 69 mostra o histograma para a série de tráfego de rede SNU20100317.