

NOVOS ALGORITMOS ADAPTATIVOS PARA IDENTIFICAÇÃO DE SISTEMAS
COM RESPOSTAS IMPULSIVAS ESPARSAS USANDO A TRANSFORMADA
WAVELET

Gerson Barboza

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE
FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM
ENGENHARIA ELÉTRICA.

Aprovada por:

Prof. Mariane Rembold Petraglia, Ph.D.

Prof. Sergio Lima Netto, Ph.D.

Prof. José Carlos Moreira Bermudez, Ph.D.

RIO DE JANEIRO, RJ - BRASIL

JUNHO DE 2007

BARBOZA, GERSON

Novos Algoritmos Adaptativos para
Identificação de Sistemas com Respostas
Impulsivas Esparsas Usando a Transformada
Wavelet [Rio de Janeiro] 2007

VI, 101 p. 29,7 cm (COPPE/UFRJ, M.Sc.,
Engenharia Elétrica, 2007)

Dissertação - Universidade Federal do
Rio de Janeiro, COPPE

1. Algoritmos Adaptativos
2. Transformada Wavelet

I. COPPE/UFRJ II. Título (série)

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

NOVOS ALGORITMOS ADAPTATIVOS PARA IDENTIFICAÇÃO DE SISTEMAS
COM RESPOSTAS IMPULSIVAS ESPARSAS USANDO A TRANSFORMADA
WAVELET

Gerson Barboza

Junho/2007

Orientadora: Mariane Rembold Petraglia

Programa: Engenharia Elétrica

Este trabalho apresenta novos algoritmos de filtragem adaptativa para identificação de sistemas com resposta impulsiva esparsa. Os algoritmos propostos utilizam uma estrutura composta de uma transformada wavelet e de filtros esparsos. Técnicas de ajuste do passo de adaptação proporcional aos valores dos coeficientes são empregadas para acelerar a convergência inicial do algoritmo adaptativo. Uma outra abordagem empregada utiliza a hierarquia temporal na relação entre as escalas da transformada wavelet, com o objetivo de reduzir o número de coeficientes a serem adaptados. Os desempenhos dos algoritmos propostos são comparados aos de algoritmos recentemente apresentados na literatura.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

NEW ADAPTIVE ALGORITHMS FOR THE IDENTIFICATION OF SYSTEMS
WITH SPARSE IMPULSE RESPONSES EMPLOYING WAVELET TRANSFORM

Gerson Barboza

June/2007

Advisor: Mariane Rembold Petraglia

Department: Electrical Engineering

This work presents new adaptive algorithms for the identification of systems with sparse impulse responses. The proposed algorithms employ a structure composed of a wavelet transform and sparse subfilters. Techniques of step-size normalization which is proportional to the coefficient values are employed in order to accelerate the initial convergence of the adaptation algorithm. Another approach also presented here applies time hierarchy among the scales of the wavelet transform to reduce the number of coefficients to be adapted. The behaviors of the proposed algorithms are compared to those of other algorithms recently proposed in the literature.

ÍNDICE

Folha de Rosto	i
Ficha Catalográfica	ii
Resumo (em Português)	iii
Abstract	iv
Índice	v
Capítulo 1 – Introdução	1
1.1. Introdução	1
1.2. Revisão Bibliográfica	4
1.3. Organização do Trabalho	6
Capítulo 2 – Estrutura Adaptativa Usando a Transformada Wavelet	8
2.1. Introdução	8
2.2. Visão Geral Sobre Filtros, Bancos de Filtros e Wavelets	9
2.2.1. Filtros	9
2.2.2. Bancos de Filtros	10
2.2.3. Wavelets	11
2.3. Modelagem Usando Wavelets	14
2.3.1. Formulação Analítica Para os Filtros Esparsos	15
2.3.2. Processo Adaptativo Para Obtenção dos Filtros Esparsos	17
2.4. Sistemas Esparsos e Modelos Utilizados	19
2.4.1. Modelos Recomendados Pela ITU-T G.168	20
2.4.1.1. Modelo 1	21
2.4.1.2. Modelo 2	22
2.4.1.3. Modelo 3	23
2.4.1.4. Modelo 4	24
2.4.1.5. Modelo 5	25
2.4.1.6. Modelo 6	26
2.4.1.7. Modelo 7	27
2.4.1.8. Modelo 8	28
2.5. Seleção das Wavelets	29

2.5.1. Análise dos Modelos dos Canais	31
2.5.2. Análise das Wavelets	37
2.6. Conclusões	42
Capítulo 3 – O Algoritmo Adaptativo com Redução dos Coeficientes para a Estrutura Wavelet	43
3.1. Introdução	43
3.2. O Algoritmo WB (<i>Wavelet-Based Algorithm</i>)	44
3.2.1. Algoritmos no Domínio da Transformada Usando Wavelets	46
3.2.2. Estrutura Hierárquica das Wavelets	48
3.2.3. Algoritmo de Seleção dos Coeficientes	49
3.2.4. Resumo do Algoritmo	54
3.3. O Algoritmo Proposto: ESWB (<i>Energy Sum Wavelet-Based</i>)	56
3.3.1. Algoritmo de Seleção de Coeficientes	56
3.3.2. Resumo do Algoritmo Proposto	60
3.4. Resultados Experimentais	61
3.4.1. Desempenho do Algoritmo ESWB com as Diferentes Wavelets	62
3.4.2. Comparação de Desempenho dos Algoritmos ESWB, WB e WPB	71
3.5. Conclusão	72
Capítulo 4 – Os Algoritmos WNLMS e WPNLMS	73
4.1. Introdução	73
4.2. Os Algoritmos NLMS e PNLMS	75
4.3. Algoritmos Propostos: WNLMS e WSPNLMS	77
4.4. Resultados Experimentais	79
4.4.1. Desempenho do Algoritmo WNLMS com Diferentes Wavelets	80
4.4.2. Desempenho do Algoritmo WPNLMS com Diferentes Wavelets	85
4.4.3. Comparação Entre os Algoritmos WNLMS e WPNLMS	90
4.5. Conclusões	94
Capítulo 5 – Conclusões	95
5.1. Conclusões Gerais	95
5.2. Sugestões de Trabalhos Futuros	97
Referências Bibliográficas	98

Capítulo 1

Introdução

1.1. Introdução

O avanço, nas últimas décadas, dos computadores digitais permitiu alavancar inúmeras áreas que, baseadas no poder das técnicas digitais, surgiram ou se modificaram para tentar compreender o mundo a partir do ponto de vista da computação digital. Da compreensão cada vez maior dos fenômenos físicos, surgem novas necessidades e possibilidades. Assim foi com a área de Processamento Digital de Sinais, que teve um grande avanço, melhorando a compreensão do mundo real e contribuindo de modo fundamental com muitas outras áreas, algumas das quais serão citadas no próximo parágrafo. Algumas das aplicações principais do Processamento Digital de Sinais são: processamento de sinais de áudio, compressão de áudio, processamento digital de imagem, compressão de vídeo, processamento de voz, reconhecimento de voz e equalização de canais.

Neste caminho de vertiginoso avanço tecnológico está também a área de filtragem adaptativa, cujas técnicas e teorias estão em rápido desenvolvimento. Muitos sinais encontrados na natureza não são estacionários, ou seja, suas estatísticas mudam ao longo do tempo. O filtro adaptativo tenta produzir, a partir de um sinal de entrada, um sinal de saída com propriedades desejadas, enquanto, simultaneamente, aprende o melhor modo de fazê-lo, sendo, portanto, a filtragem adaptativa um processo variante no tempo. Os filtros adaptativos vêm sendo aplicados em inúmeras áreas, tais como: controle de processos, telecomunicações, medicina, geologia, etc. As aplicações de filtragem adaptativa podem ser agrupadas em quatro principais categorias: identificação de sistemas, inversão de sistemas, cancelamento de interferências e predição de sinais.

Os filtros adaptativos que são baseados no algoritmo LMS [1]-[3] têm, em general, baixo custo computacional e implementações mais estáveis numericamente em comparação a outros algoritmos [4]. Entretanto, apresentam propriedades de convergência que em muitos casos se mostram sensíveis ao condicionamento da matriz de autocorrelação do sinal de entrada. Para mitigar esta sensibilidade, pode-se “branquear” o sinal de entrada. Um caminho para conseguir isto é transformando o vetor de sinal da entrada, usando uma determinada transformação, antes que o algoritmo do tipo LMS seja aplicado. Isto conduz ao que é conhecido geralmente como o algoritmo LMS no domínio da transformada [1],[3],[5],[6]. Dentre as muitas transformações propostas na literatura, a transformada wavelet discreta ortogonal é sabidamente capaz de descorrelacionar uma grande classe de sinais [7]-[9], além de apresentar um baixo custo computacional [10]. Em muitas situações é desejável reduzir tanto quanto possível a complexidade computacional dos algoritmos, enquanto que em outras é mais importante acelerar a convergência a despeito do tempo consumido. Este

trabalho prioriza estes dois objetivos, buscando algoritmos que sejam vantajosos quando aplicados em uma destas situações.

Dentro deste contexto de grandes avanços tecnológicos, a presente dissertação procura contribuir com dois trabalhos na área de identificação de sistemas, buscando desenvolver novos algoritmos adaptativos para a modelagem de sistemas com resposta impulsiva esparsa usando *wavelets*. Situações práticas em que modelos com respostas impulsivas esparsas podem ser empregados são bastante comuns, dentre as quais podemos citar o cancelamento de eco acústico em sistemas de viva-voz e vídeo-conferência, e o cancelamento de ecos em linhas telefônicas (devido ao descasamento de impedâncias entre os elementos da rede e o terminal de voz). De modo simples podemos dizer que o cancelamento de eco consiste na observação do sinal originalmente recebido e, quando ele reaparece (em geral com atraso e atenuação) no sinal transmitido, é “reconhecido” e subtraído do sinal em questão, ficando o sinal transmitido livre de ecos, conforme ilustrado na Fig. 1.1.

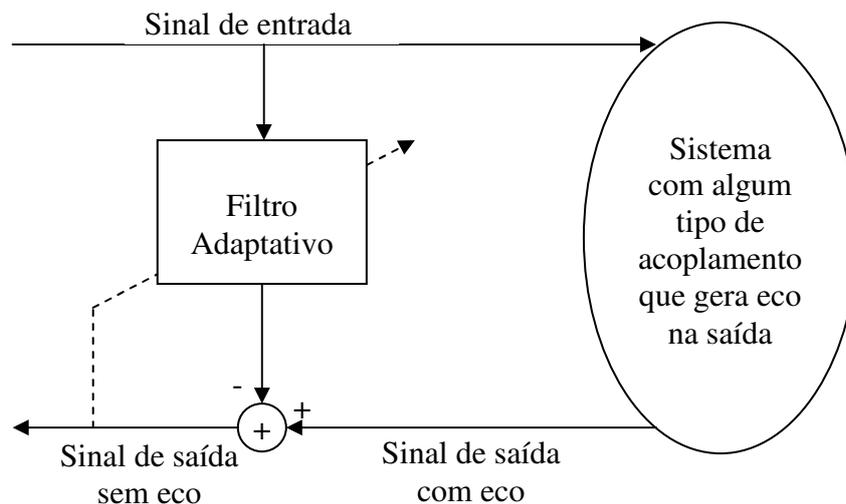


Fig. 1.1. Diagrama de uma arquitetura de cancelamento de eco acústico.

1.2. Revisão Bibliográfica

Desde que se percebeu que certas operações tornam-se mais simples e seus resultados ficam mais fáceis de serem analisados em domínios transformados, vários estudos em diferentes áreas com diversos tipos de transformação foram feitos. No caso específico da filtragem adaptativa isto também aconteceu, inicialmente explorando-se o fato de que usando a transformada de Fourier as operações de filtragem e correlação tornam-se mais simples [1]-[4].

Além disso, uma boa característica de várias transformadas empregadas em filtragem adaptativa é possibilitar a melhora da velocidade de convergência do algoritmo de adaptação [1]-[4],[11]. Neste enfoque, recentemente vários estudos têm investigado a utilização da transformada wavelet como uma alternativa para melhorar a convergência e reduzir a complexidade dos algoritmos de filtragem adaptativa [8],[12],[13].

Há várias maneiras de se utilizar as wavelets (e outras transformadas) nos algoritmos adaptativos para melhorar seu desempenho. Dentre as muitas técnicas possíveis serão citados alguns trabalhos que utilizam abordagens relevantes para os algoritmos desenvolvidos nesta dissertação.

Dentre os trabalhos apresentados na literatura cuja abordagem principal é a utilização da transformada wavelet para descorrelacionar o sinal de entrada, pode-se citar os algoritmos investigados em [11],[13],[14]. A idéia principal destes métodos é desenvolver algoritmos que utilizam, antes da adaptação, um bloco que “branqueia” o sinal, fornecendo ao algoritmo de adaptação um vetor de entrada com amostras descorrelacionadas, uma vez que os algoritmos convencionais, como o LMS e o NLMS [1]-[4], apresentam taxa de convergência elevada para sinais de entrada com

características de ruído branco. Este pré-processamento equivale a transformar a matriz de autocorrelação do sinal de entrada em uma matriz diagonal. No entanto, como isto na prática pode ser difícil, busca-se tornar esta matriz o mais próximo possível de uma matriz diagonal, ou seja, os elementos da matriz fora da diagonal principal terão valores muito pequenos comparados aos da diagonal principal. Foi testado, em [13], o desempenho do algoritmo adaptativo do tipo LMS que emprega a transformada wavelet com diferentes fatores de convergência. Em [11], o desempenho do algoritmo TDLMS (*Transform-Domain LMS*) empregando a transformada wavelet foi comparado ao do TDLMS com as transformadas DCT e WHT, apresentando o melhor resultado (convergência mais rápida) na equalização de canais variantes no tempo para sinais de entrada coloridos. Em [14], uma estrutura adaptativa composta de subfiltros esparsos e que utiliza uma transformada wavelet para decompor o sinal de entrada foi proposta, resultando em significantes ganhos no que tange à velocidade de convergência do algoritmo adaptativo em comparação ao LMS para sinais de entrada coloridos.

Um outro tipo de abordagem utilizando wavelets é aproveitar a hierarquia temporal na relação entre as escalas da transformada para reduzir o número de coeficientes adaptativos. Visando este objetivo, alguns algoritmos foram apresentados em [17]-[21] para identificação de sistemas com respostas impulsivas esparsas. Nestes trabalhos é escolhida uma escala como escala de controle, a qual terá todos os seus coeficientes adaptados. Os coeficientes de controle “suficientemente” diferentes de zero serão usados para definir quais coeficientes das outras escalas serão mantidos ativados para adaptação (os demais serão considerados nulos). Desta forma, consegue-se reduzir o número de coeficientes a adaptar em cada escala (exceto na de controle, na qual todos os coeficientes são adaptados).

No presente trabalho serão apresentados algoritmos que seguem as duas linhas de utilização das transformadas wavelets citadas acima. Serão também considerados algoritmos do tipo NLMS com passo de adaptação proporcional ao valor dos coeficientes [22], que resultam na aceleração da convergência inicial do algoritmo adaptativo em aplicações em que o sistema a ser modelado apresenta resposta ao impulso esparsa.

1.3. Organização do Trabalho

A seguir será feita uma descrição da organização desta dissertação.

No Capítulo 2 introduzem-se alguns conceitos básicos em processamento digital de sinais, e descreve-se a estrutura adaptativa, composta de uma transformada wavelet e filtros esparsos, que será adotada no desenvolvimento dos algoritmos adaptativos apresentados nos capítulos seguintes. São também descritos neste capítulo os modelos de canais de linhas telefônicas digitais utilizados nos testes dos algoritmos propostos, os quais apresentam respostas impulsivas esparsas. Uma análise da redução do número de coeficientes da estrutura investigada neste trabalho, quando esta é empregada na modelagem destes canais, é apresentada, considerando-se o emprego de diferentes funções wavelets.

O Capítulo 3 trata de algoritmos de redução de coeficientes, a partir da utilização da estrutura hierárquica temporal dos coeficientes das transformadas wavelets. Um novo algoritmo, que utiliza um critério de seleção dos coeficientes “significativos” a serem adaptados baseado na energia cumulativa percentual da resposta impulsiva em cada canal da transformada, é proposto. O algoritmo proposto é testado com os modelos de

canais esparsos apresentados no Capítulo 2 e seu desempenho é comparado ao de outros algoritmos que também utilizam a transformada wavelet.

O Capítulo 4 trata de algoritmos que utilizam a transformada wavelet, em conjunto com técnicas de adaptação baseadas em passos de adaptação proporcionais aos valores dos coeficientes, para melhorar a velocidade de convergência do algoritmo NLMS. Os algoritmos propostos são testados para os diferentes modelos de canais descritos no Capítulo 2 e para diferentes funções wavelet, e os seus desempenhos são comparados aos de algoritmos similares apresentados na literatura.

O Capítulo 5 apresenta as conclusões deste trabalho e descreve algumas idéias de continuação da pesquisa desenvolvida nesta dissertação.

Capítulo 2

Estrutura Adaptativa Usando a Transformada Wavelet

2.1. Introdução

Os filtros FIR (*Finite Impulse Response*) têm sido utilizados para modelar sistemas em aplicações tais como cancelamento de eco acústico [23] e equalização de canal. Em tais aplicações a abordagem tradicional usando algoritmos adaptativos FIR possui o problema da grande quantidade de operações exigida pelo algoritmo e/ou a lenta convergência, principalmente quando o espectro do sinal é muito colorido (ou seja, é grande a dispersão dos autovalores da matriz de autocorrelação do sinal de entrada). Nos últimos anos vários algoritmos foram propostos para resolver estes problemas. O conceito de filtragem adaptativa no domínio da frequência foi introduzido nos anos 70 [24]. O algoritmo LMS em domínios transformados [5], por exemplo, foi um dos primeiros algoritmos propostos que aplicava ao vetor de entrada uma transformação

antes de processá-lo, mas seu desempenho dependia da escolha correta da transformação empregada, necessitando, portanto, de informações adicionais sobre as estatísticas dos sinais.

Nesta linha os algoritmos usando bancos de filtros e wavelets têm gerado muito interesse e têm obtido bastante sucesso em várias aplicações.

2.2. Visão Geral Sobre Filtros, Bancos de Filtros e Wavelets

Para facilitar o entendimento do restante deste trabalho será feita aqui uma breve revisão sobre os principais conceitos referentes aos filtros, bancos de filtros e wavelets, que têm interesse do ponto de vista desta dissertação.

2.2.1. Filtros

Um filtro linear e invariante no tempo é completamente caracterizado pela sua resposta ao impulso $h(t)$. Uma vez que os filtros utilizados neste trabalho são digitais, suas respostas ao impulso estão definidas apenas em instantes de tempo múltiplos do período de amostragem T , ou seja, $h(t)$ para $t = nT$. O filtro digital age sobre uma seqüência de entrada $x(n)$, gerando uma seqüência de saída $y(n)$, a qual é a convolução de $x(n)$ e $h(n)$, ou seja:

$$y(n) = \sum_k h(k)x(n-k),$$

Os filtros implementados neste trabalho são do tipo FIR, sendo assim, o somatório acima contém um número finito de termos (por exemplo, $0 \leq k \leq M$, sendo M a ordem do filtro FIR).

2.2.2. Bancos de Filtros

Um banco de filtros é um conjunto de filtros usados para analisar ou sintetizar um sinal. Os filtros de um banco de análise separam o sinal de entrada em bandas de frequência de tal modo que estes novos sinais podem ser processados de forma mais eficiente do que o sinal original. Os filtros de um banco de síntese compõem um sinal de banda larga a partir de sinais de banda estreita. Uma aplicação típica de banco de filtros é em compressão de sinais, com o objetivo de facilitar a transmissão ou armazenamento desses sinais. Os sinais das diferentes subbandas são quantizados, e a qualquer momento estes sinais podem ser novamente recombinados pelo banco de síntese.

Em geral, não é necessário utilizar todas as amostras de saída dos filtros de análise. Normalmente as saídas destes filtros são sub-amostradas. Por exemplo, se tivermos um banco com dois filtros (um passa-baixas e um passa-altas) poderemos considerar somente as saídas para instantes pares. No caso de termos M filtros e considerarmos apenas as M -ésimas amostras de saída de cada filtro, dizemos que o sistema apresenta amostragem crítica, e teremos no total o mesmo número de amostras que o sinal original.

Uma característica chave dos bancos de filtros e que os faz interessantes é que as saídas de seus filtros com amostragem crítica podem conjuntamente possuir propriedades que seriam difíceis de serem extraídas de um único sinal.

2.2.3. Wavelets

Uma base de funções é um conjunto de funções linearmente independentes que é capaz de gerar todo o espaço de funções em que se está interessado. Se as funções $w_{jk}(t)$ formam uma base do espaço vetorial W e se uma função $f(t) \in W$, então existe um vetor de coeficientes b_{jk} tal que

$$f(t) = \sum_{j,k} b_{jk} w_{jk}(t) \quad (2.1)$$

Uma característica especial de uma base de wavelets é que todas as funções $w_{jk}(t)$ são construídas de uma única wavelet mãe $w(t)$. Esta wavelet mãe é uma pequena onda, normalmente começando em $t = 0$ e terminando em $t = N$.

Os índices j e k nas wavelets $w_{jk}(t)$ expressam respectivamente os níveis de compressão e deslocamento desta função em relação à wavelet mãe. Por exemplo, as wavelets deslocadas w_{0k} iniciam em $t = k$ e terminam em $t = k+N$, as wavelets comprimidas w_{j0} iniciam em $t = 0$ e terminam $t = N/2^j$. Ou seja, uma típica wavelet $w_{jk}(t)$ é comprimida 2^j vezes e deslocada k unidades de tempo para a direita. Sua fórmula geral é:

$$w_{jk}(t) = w(2^j t - k).$$

Uma propriedade importante que muitas wavelets possuem é a ortogonalidade, ou seja, duas wavelets $w_{jk}(t)$ são ortogonais se seu produto interno for zero:

$$\int_{-\infty}^{\infty} w_{jk}(t)w_{JK}(t)dt = 0, \quad \forall j \neq J, k \neq K$$

A ortogonalidade permite que se encontre com muita facilidade os coeficientes b_{JK} que fazem a decomposição de $f(t)$ na referida base. Multiplicando a equação (2.1) por $w_{JK}(t)$ e integrando obtém-se a relação:

$$\int_{-\infty}^{\infty} f(t)w_{JK}(t)dt = b_{JK} \int_{-\infty}^{\infty} (w_{JK}(t))^2 dt$$

a partir da qual se chega facilmente a b_{JK} .

A transformada wavelet discreta, utilizada para fazer a expansão em séries de sinais discretos no tempo, pode ser interpretada como um banco de filtros não-uniforme, os quais dividem o espectro de frequência do sinal analisado em bandas de oitavas [8],[9]. Neste trabalho será utilizada a transformada wavelet discreta implementada como um banco de filtros na estrutura em árvore, conforme mostrado na Fig. 2.1 para 3 níveis de decomposição.

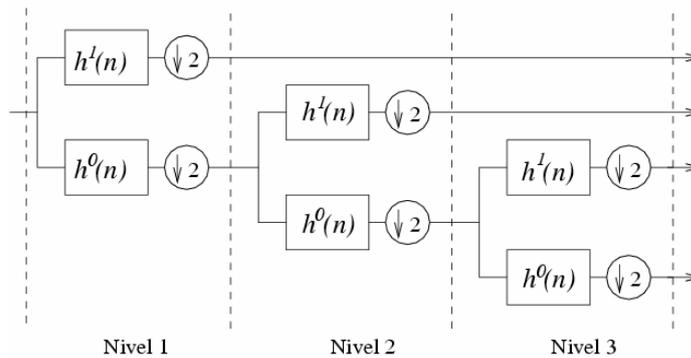


Figura 2.1. Estrutura em árvore para implementação da wavelet discreta.

O banco de filtros equivalente ao da Fig. 2.1 é mostrado na Fig. 2.2, onde os fatores de decimação para J níveis são dados por:

$$L_m = \begin{cases} 2^J & , m = 0 \\ 2^{J-m+1} & , m = 1, \dots, J \end{cases} \quad (2.2)$$

e os filtros equivalentes são relacionados aos filtros passa-baixas e passa-altas da Fig. 2.1 através das expressões:

$$H_m(z) = \begin{cases} \prod_{j=0}^J H^0(z^{2^j}) & , m = 0 \\ H^1(z^{2^{J-m}}) \prod_{j=0}^J H^0(z^{2^j}) & , m = 1, \dots, J \end{cases} \quad (2.3)$$

onde J é o número de níveis da decomposição, e $H^0(z)$ e $H^1(z)$ são as funções de transferência dos filtros $h^0(n)$ e $h^1(n)$.

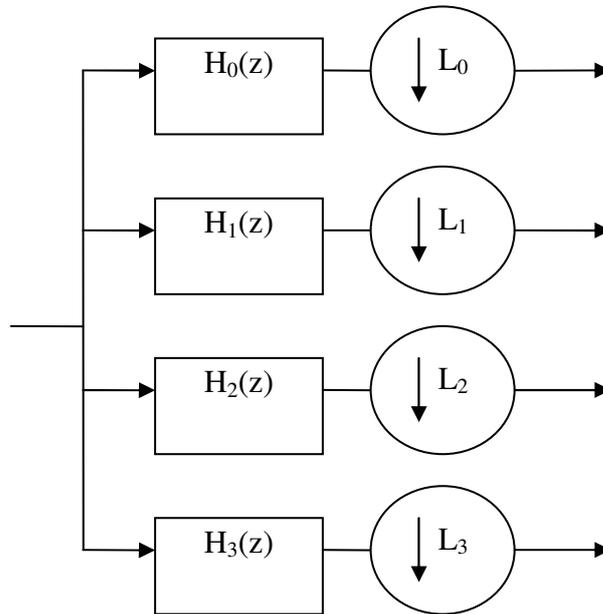


Figura 2.2. Banco de filtros equivalente à transformada wavelet discreta da com 3 níveis da Fig. 2.1.

2.3. Modelagem Usando Wavelets

Nesta seção será descrita a estrutura empregada nesta dissertação, que utiliza a transformada wavelet para decompor o sinal de entrada. Ao invés de reduzir a taxa de amostragem dos sinais nas subbandas do banco de filtros equivalente, mostrado na Fig. 2.2, utilizam-se filtros esparsos para processar estes sinais na mesma taxa do sinal de entrada, conforme ilustrado na Fig. 2.3.

A estrutura da Fig. 2.3 é capaz de modelar qualquer filtro FIR [25]. Os coeficientes do sistema a ser identificado podem ser modelados por um conjunto de filtros esparsos $G_m(z^{L_m})$, para $m = 0, 1, \dots, M-1$, os quais processam as saídas das transformadas wavelets. Os filtros esparsos são filtros FIR cujos coeficientes não-nulos são separados por L_m-1 zeros, onde L_m é o fator de esparsidade do m -ésimo subfiltro. Suas respostas em frequência se repetem L_m vezes sobre a faixa da frequência normalizada de 0 a 2π . O fator de esparsidade L_m corresponde ao fator de decimação da m -ésima banda do banco de filtros equivalente (Fig. 2.2).

Os coeficientes dos filtros esparsos podem ser obtidos por dois processos: analítico e adaptativo, descritos a seguir.

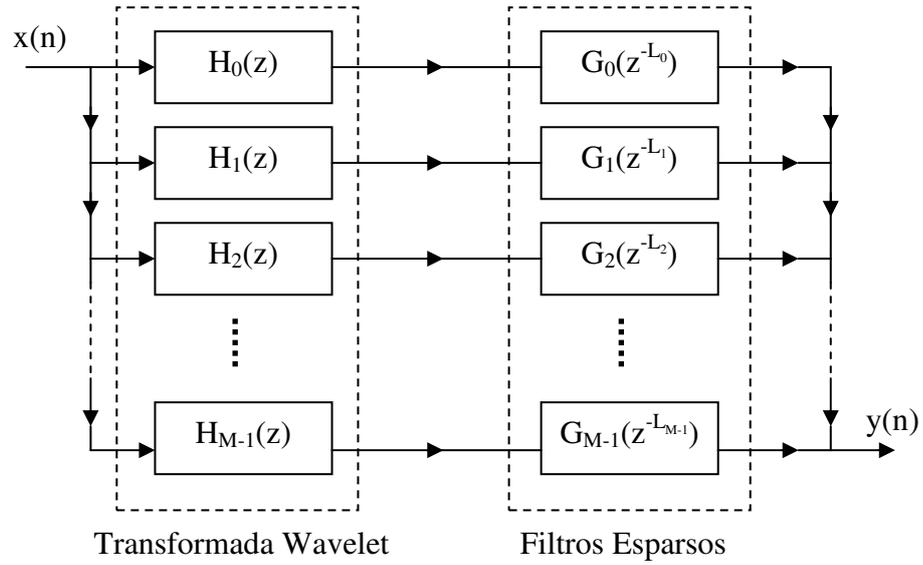


Figura 2.3. Estrutura composta pela transformada wavelet e por filtros esparsos para modelagem de sistemas FIR.

2.3.1. Formulação Analítica Para os Filtros Esparsos

A fim de explicar como calcular os coeficientes, será considerada inicialmente a estrutura da Fig. 2.3 com somente duas subbandas ($M = 2$). A função de transferência implementada por esta estrutura é dada por [25]:

$$R(z) = \begin{bmatrix} G_0(z^2) & G_1(z^2) \end{bmatrix} \mathbf{H}_p(z^2) \begin{bmatrix} 1 \\ z^{-1} \end{bmatrix} \quad (2.4)$$

onde $\mathbf{H}_p(z)$ é a matriz polifásica (de tamanho 2×2) do banco de filtros de análise equivalente.

A função de transferência $P(z)$ do sistema FIR a ser modelado pode ser escrita como:

$$P(z) = \begin{bmatrix} P_0(z^2) & P_1(z^2) \end{bmatrix} \begin{bmatrix} 1 \\ z^{-1} \end{bmatrix} \quad (2.5)$$

onde $P_0(z)$ e $P_1(z)$ são as componentes polifásicas tipo-1 de $P(z)$ [8].

Das equações (2.4) e (2.5) observamos que a estrutura da Fig. 2.3 com dois canais pode modelar exatamente o filtro FIR $P(z)$ quando:

$$\begin{bmatrix} G_0(z^2) & G_1(z^2) \end{bmatrix} \mathbf{H}_p(z^2) = \begin{bmatrix} P_0(z^2) & P_1(z^2) \end{bmatrix} \quad (2.6)$$

Tal igualdade não pode ser obtida, no caso geral, com filtros $G_0(z^2)$ e $G_1(z^2)$ FIR e causais. No entanto, se

$$\begin{bmatrix} G_0(z^2) & G_1(z^2) \end{bmatrix} = \begin{bmatrix} P_0(z^2) & P_1(z^2) \end{bmatrix} \mathbf{F}_p(z^2) \quad (2.7)$$

com a matriz $\mathbf{F}_p(z)$ sendo tal que

$$\mathbf{F}_p(z^2) \mathbf{H}_p(z^2) = z^{-\Delta} \mathbf{I} \quad (2.8)$$

a função de transferência da estrutura com dois canais será $P(z)z^{-\Delta}$. As matrizes $\mathbf{H}_p(z)$ e $\mathbf{F}_p(z)$ que satisfazem a equação (2.8) correspondem às matrizes polifásicas dos bancos de análise e síntese, respectivamente, de um sistema multitaxa com reconstrução perfeita [9].

Conseqüentemente, usando um banco de filtros de análise de um sistema multitaxa de reconstrução perfeita e subfiltros adaptativos de ordem suficiente (tal que a equação (2.7) possa ser satisfeita) na estrutura da Fig. 2.3, esta implementa exatamente qualquer filtro FIR $P(z)$, com a introdução de um atraso constante de Δ amostras no caminho do sinal.

O resultado encontrado para uma estrutura de duas bandas pode ser estendido para o caso multi-bandas, por aplicação da decomposição de duas bandas ao subfiltro $G_0(z^2)$ ou $G_1(z^2)$, e assim por diante. O número de coeficientes não-nulos de cada subfiltro $G_m(z^{L_m})$ da estrutura resultante será

$$K_m = \left\lceil \frac{N_P + N_{F_m}}{L_m} \right\rceil - 1, \quad (2.9)$$

onde N_P e N_{F_m} são os comprimentos do sistema desconhecido $P(z)$ e do filtro de síntese $F_m(z)$ da m -ésima banda, respectivamente, e $\lceil \cdot \rceil$ representa o menor número inteiro do parâmetro dado. A resposta impulsiva $r(n)$ da estrutura resultante pode ser obtida adicionando-se os resultados das convoluções das respostas ao impulso dos filtros de análise $h_m(n)$ e dos filtros esparsos $g_m(n)$, como a seguir:

$$r(n) = \sum_{m=0}^{M-1} h_m(n) * g_m(n). \quad (2.10)$$

2.3.2. Processo Adaptativo para Obtenção de Filtros Esparsos

O processo adaptativo é obtido usando a estrutura de identificação de sistema mostrada na Fig. 2.4. Nesta estrutura, os coeficientes dos subfiltros $G_m(z^{L_m})$ são adaptados de tal modo a modelar o sistema FIR “desconhecido”, designado aqui por $P(z)$. O sinal de entrada $x(n)$ passa através do filtro (sistema desconhecido) e é atrasado por Δ amostras, gerando a resposta desejada $d(n-\Delta)$, onde Δ é o atraso introduzido pelo modelo usando wavelet [25]. No ramo inferior da Fig. 2.4, o sinal $x(n)$ é decomposto por uma transformada wavelet discreta, implementada pelos filtros de análise $H_m(z)$ e

modificado pelos sub-filtros esparsos $G_m(z^{L_m})$, gerando o sinal de saída $y(n)$. O sinal de saída é comparado com a versão atrasada do sinal desejado para produzir o sinal de erro $e(n)$, o qual é então usado para adaptar os coeficientes dos subfiltros $G_m(z^{L_m})$.

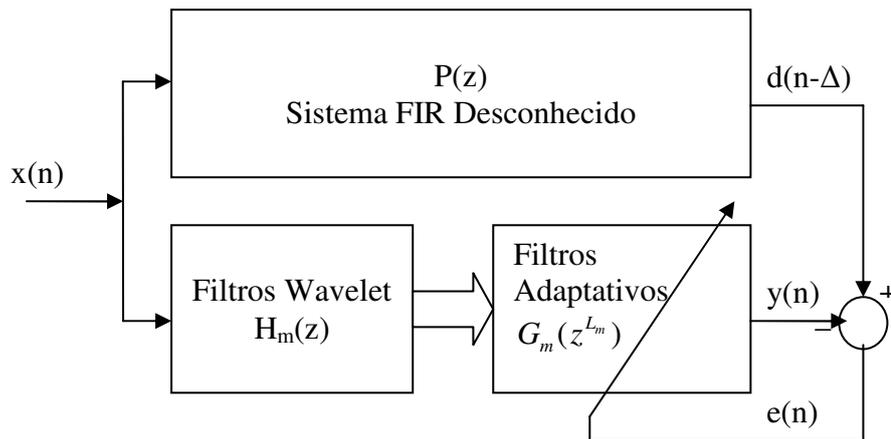


Figura 2.4. Estrutura adaptativa para identificação de sistemas.

Teoricamente qualquer sinal de entrada pode ser usado no sistema da Fig. 2.4 para obter os coeficientes do modelo. No entanto, algoritmos adaptativos simples, tais como o LMS [1]-[3], convergem mais rapidamente com um ruído branco na entrada do que com um ruído colorido.

Nesta dissertação, serão priorizadas as aplicações nas quais o sistema a ser identificado tem resposta impulsiva esparsa, ou seja, sua saída quando um impulso é aplicado na entrada possui uma grande quantidade de amostras iguais a zero. Conseqüentemente, após a convergência, muitos dos coeficientes dos subfiltros adaptativos serão nulos. Objetivando utilizar esta informação sobre o sistema para tornar a modelagem mais eficiente, foram empregadas duas estratégias diferentes no algoritmo de atualização dos filtros adaptativos utilizados na identificação do sistema. Uma das estratégias utiliza uma característica estrutural das wavelets para determinar

quais coeficientes devem ser atualizados, forçando-se então os outros coeficientes a serem nulos. A outra abordagem utiliza uma variante do algoritmo PNLMS [22], o qual é um algoritmo do tipo NLMS em que a taxa de atualização de cada coeficiente está relacionada ao percentual de energia representado por este coeficiente no total de energia da resposta ao impulso do filtro.

Após o processo de adaptação, os coeficientes de $G_m(z^{L_m})$ convergem para valores tais que a resposta impulsiva $r(n)$ da equação (2.10) se aproxime o melhor possível (segundo um determinado critério) de $p(n - \Delta)$, a resposta impulsiva de $P(z)$ atrasada. Nos próximos capítulos descreveremos em detalhes os algoritmos adaptativos desenvolvidos para a estrutura da Fig. 2.3.

2.4. Sistemas Esparsos e Modelos Utilizados

A presente dissertação trata da identificação de sistemas esparsos, os quais são sistemas em que um pequeno número de coeficientes da sua resposta impulsiva é considerado relevante. Deve-se observar aqui que a relevância citada é relativa e depende da métrica utilizada e das características do sistema em consideração e, portanto, a decisão de se um coeficiente é ou não relevante nem sempre é simples. Nesta seção, descreveremos os modelos de canais de linhas telefônicas digitais utilizados nas simulações apresentadas nesta dissertação.

2.4.1. Modelos de Canais Recomendados pelo ITU-T G.168

A *International Telecommunication Union* (ITU), em sua recomendação G.168 [26], faz, no apêndice D, uma série de sugestões sobre como analisar canais de comunicação objetivando o projeto de cancelamento de eco. Esta recomendação da ITU-T especifica as condições sob as quais estes modelos são aplicáveis e como utilizá-los. São apresentados 8 modelos de canais, os quais foram utilizados nos testes dos algoritmos desenvolvidos neste trabalho.

Para utilizar os modelos brutos fornecidos pela ITU foi necessário ajustar os dados fornecidos. O ajuste feito nas respostas ao impulso dos canais disponíveis na norma restringiu-se a:

- (a) adicionar várias amostras nulas antes de cada seqüência de dados (escolheu-se colocar 301 zeros), para simular o atraso principal do sistema;
- (b) adicionar amostras nulas no final da resposta ao impulso para fixar o tamanho do modelo (escolheu-se considerar no total 512 coeficientes);
- (c) normalizar as seqüências resultantes pelos seus valores máximos para que os coeficientes de cada modelo ficassem no intervalo $[-1; 1]$.

Deve-se observar que os ajustes descritos acima foram feitos para facilitar a comparação dos resultados obtidos neste trabalho com os resultados de alguns artigos referenciados nesta dissertação.

A partir destes três tratamentos feitos, obtivemos os modelos de canais mostrados a seguir.

2.4.1.1. Modelo 1

Na Fig. 2.5 é mostrada a resposta impulsiva do modelo bruto 1 recomendado pela G.168 [26]. Na Fig. 2.6 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

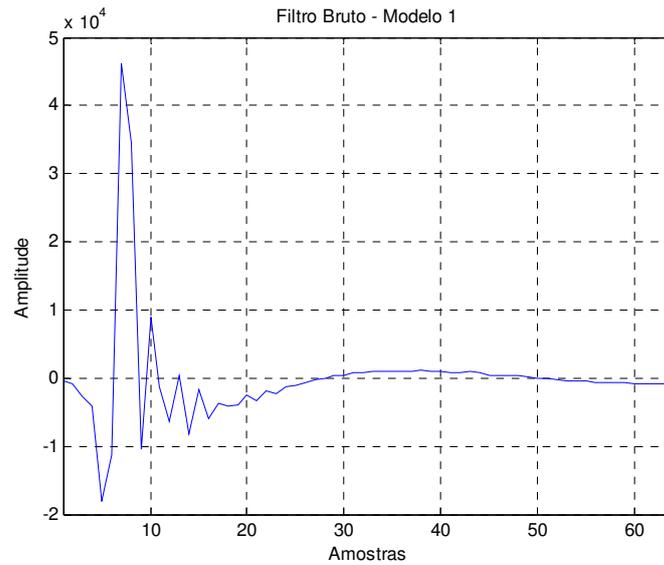


Figura 2.5. Modelo 1 bruto proposto pela recomendação ITU-T G.168.

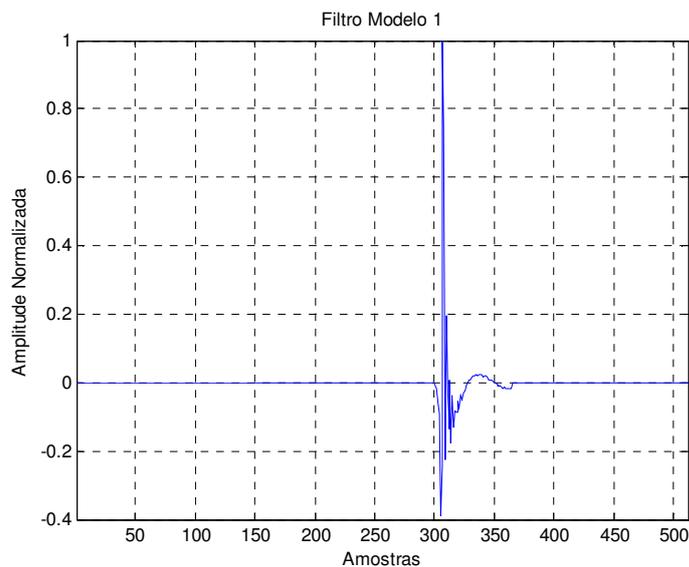


Figura 2.6. Modelo 1 tratado a partir do modelo proposto pela ITU-T G.168

2.4.1.2. Modelo 2

Na Fig. 2.7 é mostrado a resposta impulsiva do modelo bruto 2 recomendado pela G.168 [26]. Na Fig. 2.8 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

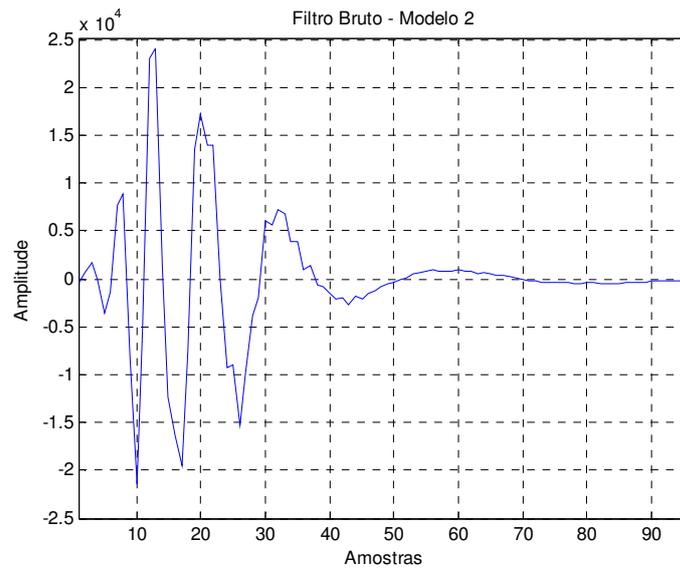


Figura 2.7. Modelo 2 bruto proposto pela recomendação ITU-T G.168.

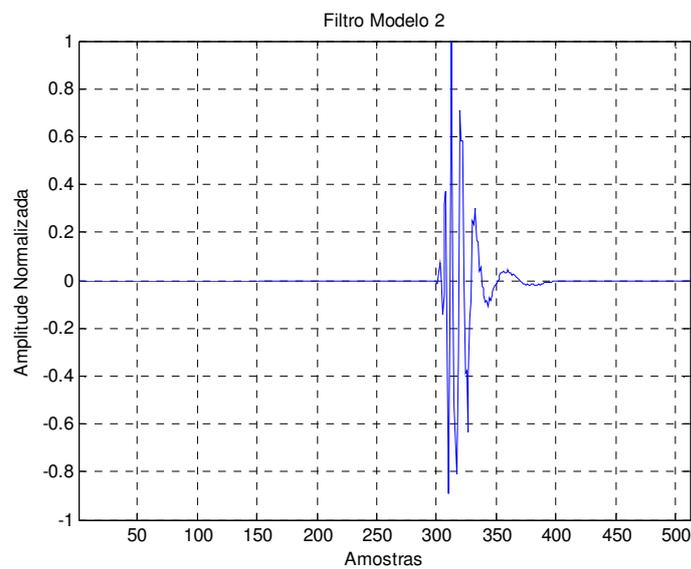


Figura 2.8. Modelo 2 tratado a partir do modelo proposto pela ITU-T G.168.

2.4.1.3. Modelo 3

Na Fig. 2.9 é mostrado a resposta impulsiva do modelo bruto 3 recomendado pela G.168 [26]. Na Fig. 2.10 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

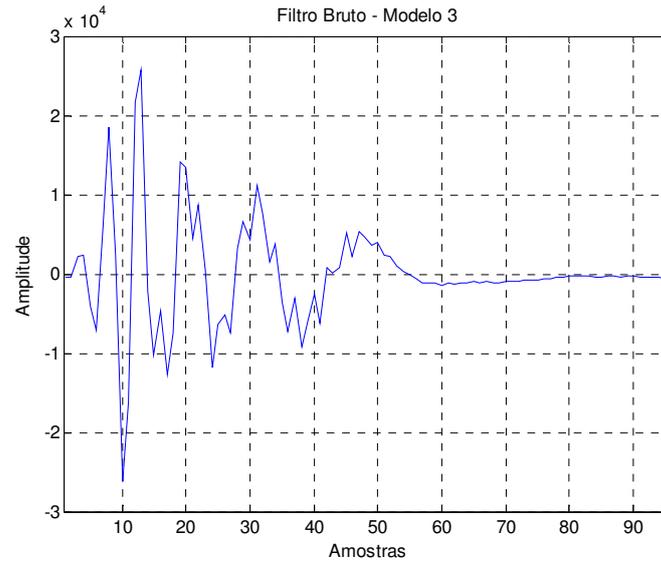


Figura 2.9. Modelo 3 bruto proposto pela recomendação ITU-T G.168.

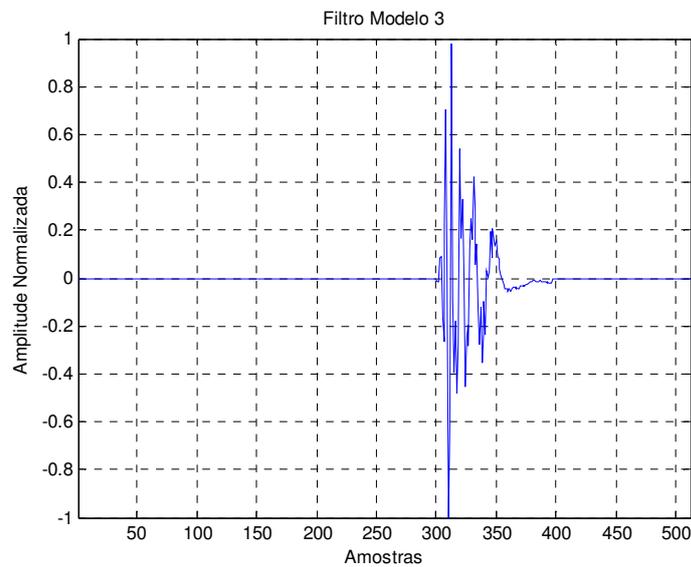


Figura 2.10. Modelo 3 tratado a partir do modelo proposto pela ITU-T G.168.

2.4.1.4. Modelo 4

Na Fig. 2.11 é mostrado a resposta impulsiva do modelo bruto 4 recomendado pela G.168 [26]. Na Fig. 2.12 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

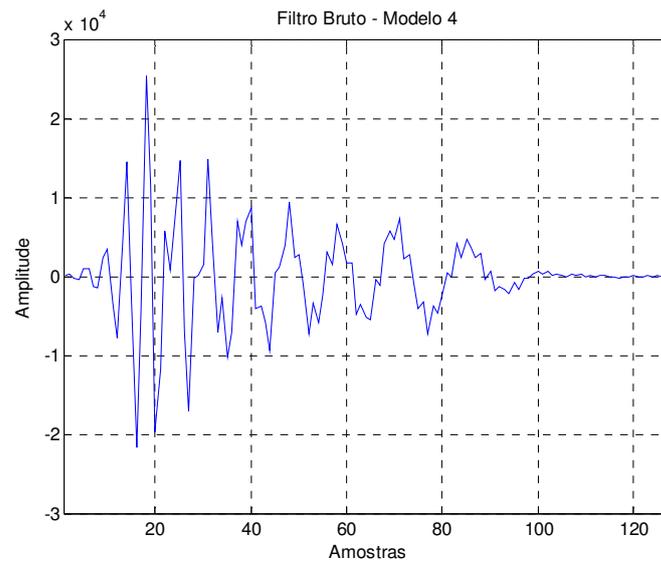


Figura 2.11. Modelo 4 bruto proposto pela recomendação ITU-T G.168.

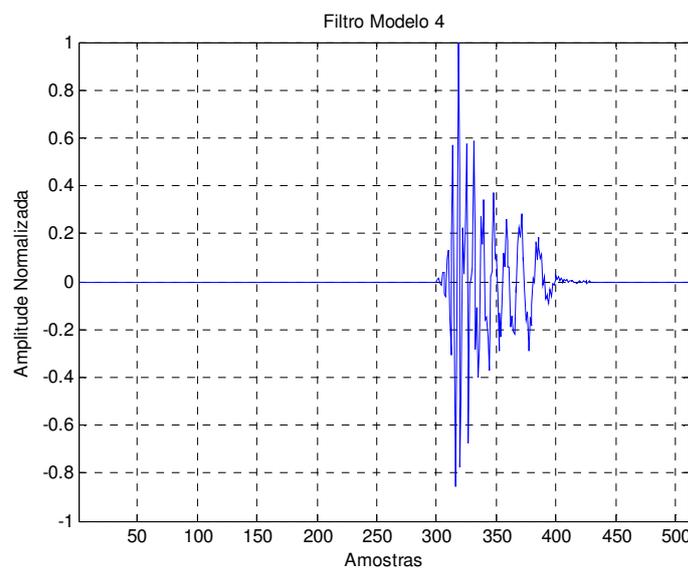


Figura 2.12. Modelo 4 tratado a partir do modelo proposto pela ITU-T G.168.

2.4.1.5. Modelo 5

Na Fig. 2.13 é mostrado a resposta impulsiva do modelo bruto 5 recomendado pela G.168 [26]. Na Fig. 2.14 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

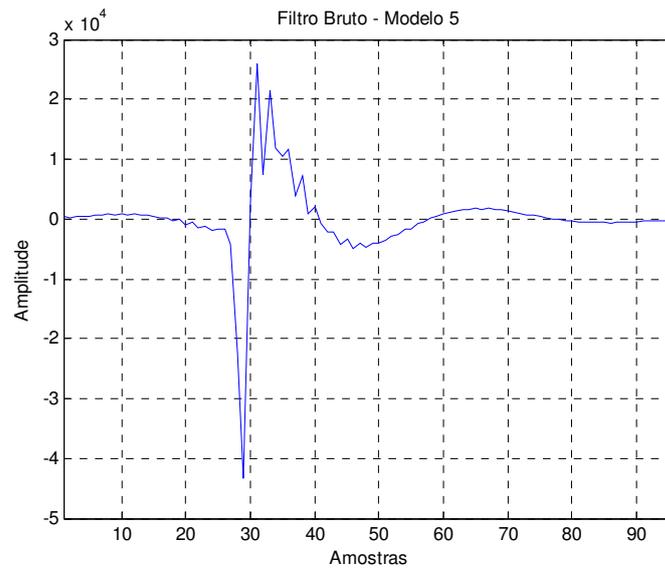


Figura 2.13. Modelo 5 bruto proposto pela recomendação ITU-T G.168.

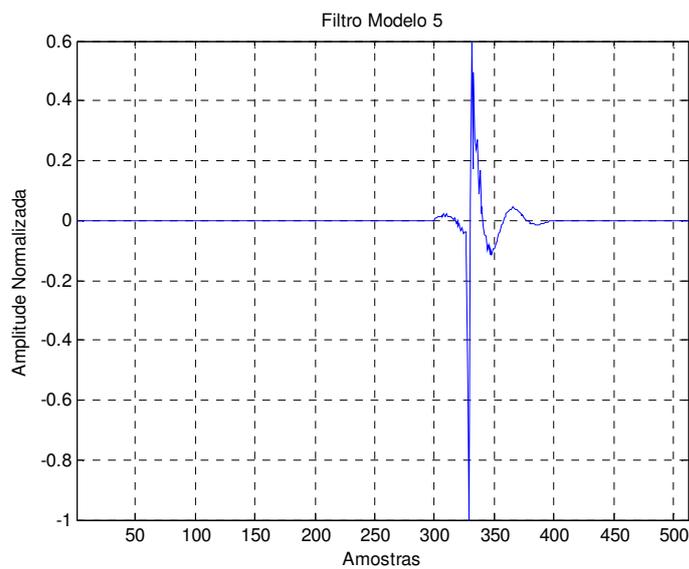


Figura 2.14. Modelo 5 tratado a partir do modelo proposto pela ITU-T G.168.

2.4.1.6. Modelo 6

Na Fig. 2.15 é mostrado a resposta impulsiva do modelo bruto 6 recomendado pela G.168 [26]. Na Fig. 2.16 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

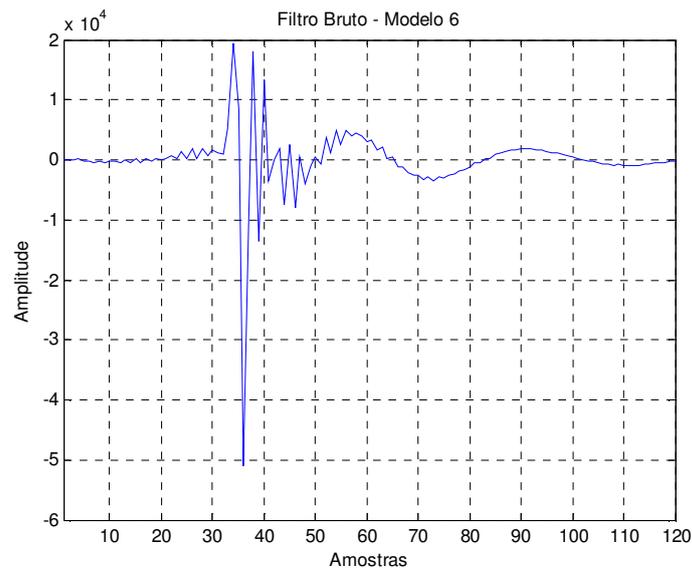


Figura 2.15. Modelo 6 bruto proposto pela recomendação ITU-T G.168.

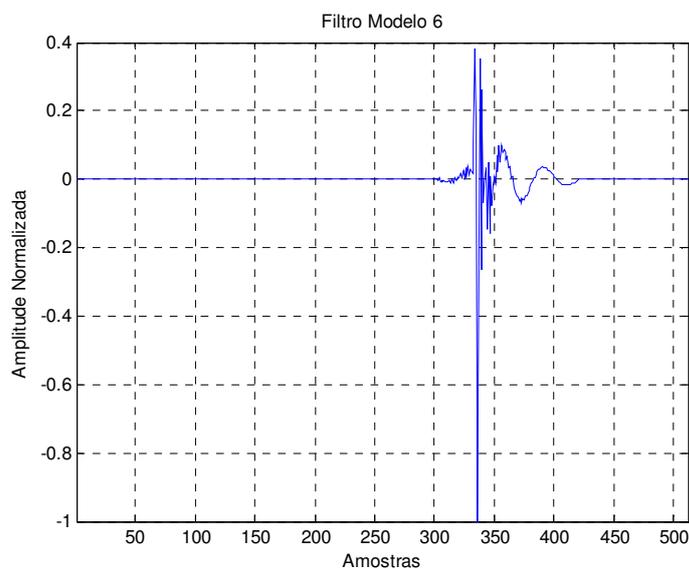


Figura 2.16. Modelo 6 tratado a partir do modelo proposto pela ITU-T G.168.

2.4.1.7. Modelo 7

Na Fig. 2.17 é mostrado a resposta impulsiva do modelo bruto 7 recomendado pela G.168 [26]. Na Fig. 2.18 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

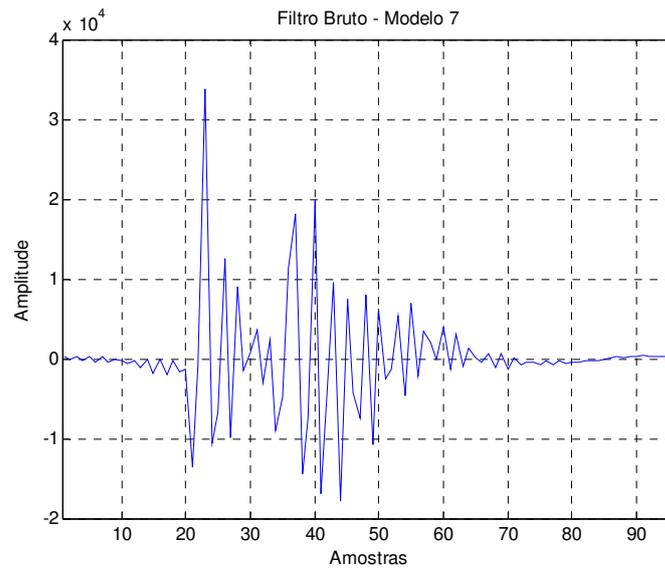


Figura 2.17. Modelo 7 bruto proposto pela recomendação ITU-T G.168.

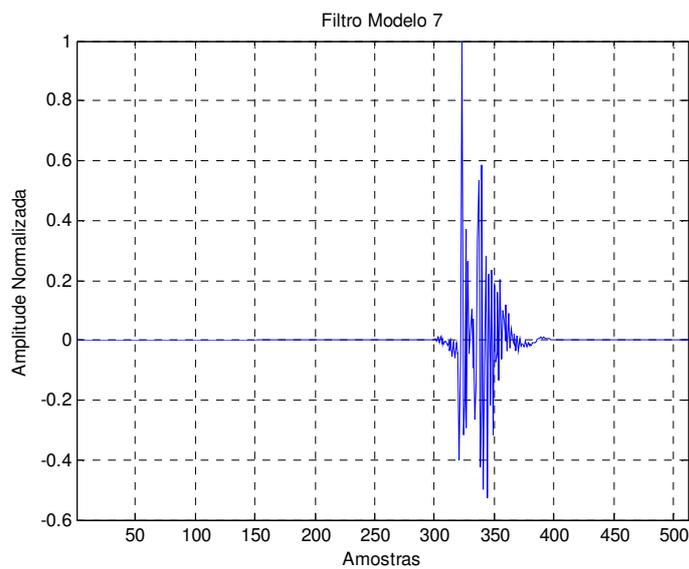


Figura 2.18. Modelo 7 tratado a partir do modelo proposto pela ITU-T G.168.

2.4.1.8. Modelo 8

Na Fig. 2.19 é mostrado a resposta impulsiva do modelo bruto 8 recomendado pela G.168 [26]. Na Fig. 2.20 tem-se a resposta impulsiva do modelo tratado para os propósitos desta dissertação.

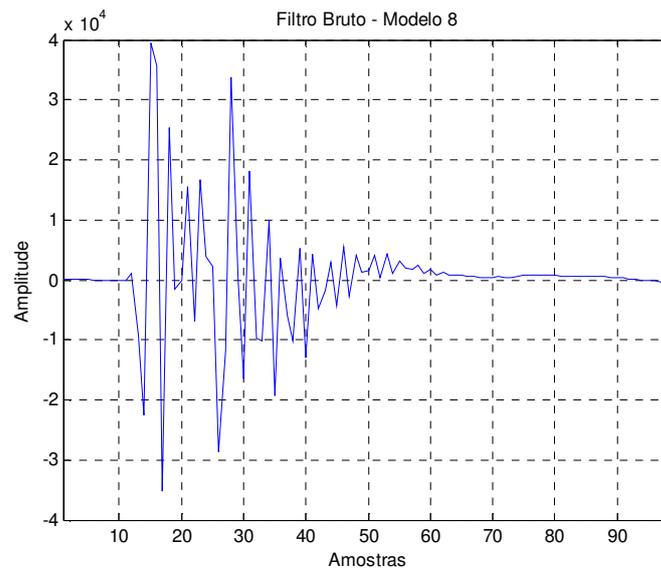


Figura 2.19. Modelo 8 bruto proposto pela recomendação ITU-T G.168.

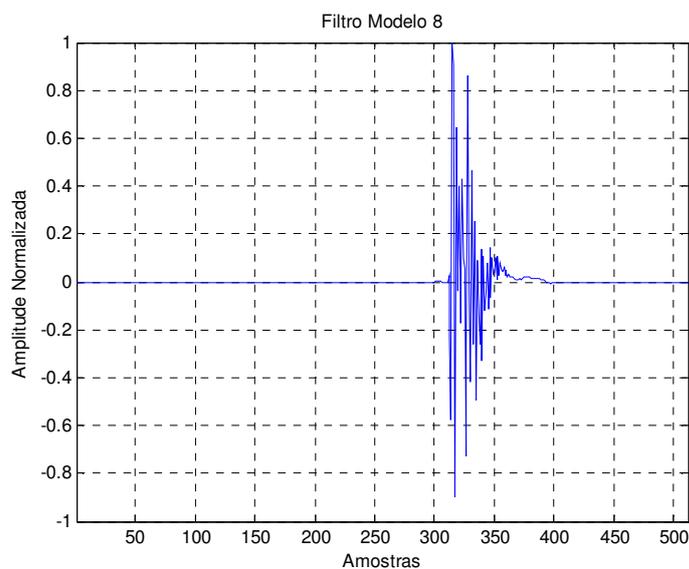


Figura 2.20. Modelo 8 tratado a partir do modelo proposto pela ITU-T G.168.

2.5. Seleção das Wavelets

Para testar e analisar o desempenho dos algoritmos de filtragem adaptativa desenvolvidos neste trabalho para a estrutura wavelet da Fig. 2.3, escolhemos, dentre as diversas wavelets disponíveis na literatura, o seguinte conjunto de funções, com seus respectivos coeficientes:

1. Biortogonal 2.4

$$h_0 = \{ 0 \quad 0,033146 \quad -0,066291 \quad -0,17678 \quad 0,41984 \quad 0,99437 \quad 0,41984 \\ -0,17678 \quad -0,066291 \quad 0,033146 \}$$

$$h_1 = \{ 0 \quad 0 \quad 0 \quad 0,35355 \quad -0,70711 \quad 0,35355 \quad 0 \quad 0 \quad 0 \}$$

2. Biortogonal 4.4

$$h_0 = \{ 0 \quad 0,037828 \quad -0,023849 \quad -0,11062 \quad 0,3774 \quad 0,8527 \quad 0,3774 \quad -0,11062 \\ -0,023849 \quad 0,037828 \}$$

$$h_1 = \{ 0 \quad -0,064539 \quad 0,040689 \quad 0,41809 \quad -0,78849 \quad 0,41809 \quad 0,040689 \\ -0,064539 \quad 0 \quad 0 \}$$

3. Biortogonal 5.5

$$h_0 = \{ 0 \quad 0 \quad 0,039687 \quad 0,0079481 \quad -0,054464 \quad 0,34561 \quad 0,73666 \quad 0,34561 \\ -0,054464 \quad 0,0079481 \quad 0,039687 \quad 0 \}$$

$$h_1 = \{ -0,013457 \quad -0,002695 \quad 0,13671 \quad -0,093505 \quad -0,4768 \quad 0,89951 \\ -0,4768 \quad -0,093505 \quad 0,13671 \quad -0,002695 \quad -0,013457 \quad 0 \}$$

4. Coiflet 4

$$h_0 = \{ -1,785e-006 \quad -3,2597e-006 \quad 3,123e-005 \quad 6,2339e-005 \quad -0,00025997 \\ -0,00058902 \quad 0,0012666 \quad 0,0037514 \quad -0,0056583 \quad -0,015212 \\ 0,025082 \quad 0,039334 \quad -0,09622 \quad -0,066627 \quad 0,43439 \quad 0,78224 \quad 0,41531 \\ -0,056077 \quad -0,081267 \quad 0,026682 \quad 0,016069 \quad -0,0073462 \\ -0,0016295 \quad 0,00089231 \}$$

$$h_1 = \{ -0,00089231 \quad -0,0016295 \quad 0,0073462 \quad 0,016069 \quad -0,026682 \\ -0,081267 \quad 0,056077 \quad 0,41531 \quad -0,78224 \quad 0,43439 \quad 0,066627 \\ -0,09622 \quad -0,039334 \quad 0,025082 \quad 0,015212 \quad -0,0056583 \quad -0,0037514 \\ 0,0012666 \quad 0,00058902 \quad -0,00025997 \quad -6,2339e-005 \quad 3,123e-005 \\ 3,2597e-006 \quad -1,785e-006 \}$$

5. Daubechies 1

$$h_0 = \{ 0,70711 \quad 0,70711 \}$$

$$h_1 = \{ -0,70711 \quad 0,70711 \}$$

6. Daubechies 4

$$h_0 = \{ -0,010597 \quad 0,032883 \quad 0,030841 \quad -0,18703 \quad -0,027984 \quad 0,63088 \\ 0,71485 \quad 0,23038 \}$$

$$h_1 = \{ -0,23038 \quad 0,71485 \quad -0,63088 \quad -0,027984 \quad 0,18703 \quad 0,030841 \\ -0,032883 \quad -0,010597 \}$$

Todas as funções acima apresentam comprimento reduzido (menor ou igual a 5) e, portanto, não introduzem atrasos muito grandes no sinal de saída. A wavelet

Daubechies 1 (ou Haar), além de ser muito simples (coeficientes +1 e -1), foi a função utilizada em algoritmos recentemente propostos [17],[27].

Um primeiro critério de avaliação das diferentes funções quando empregadas na estrutura da Fig. 2.3 foi a capacidade de redução no número de coeficientes do modelo, sem maiores considerações acerca do desempenho (convergência, MSE, etc.) do algoritmo adaptativo. Para alcançar este objetivo foi desenvolvido um método para, a partir de um critério baseado na energia da resposta ao impulso, encontrar o número de coeficientes “significativos” para cada wavelet.

2.5.1. Análise dos Modelos dos Canais

Para analisar os modelos propostos pela recomendação G.168 do ITU-T [26] que trata do cancelamento de eco em redes de telefonia digitais utilizaram-se algumas definições apresentadas a seguir, e que serão também empregadas no próximo capítulo.

Uma vez que esta análise necessitava de algum critério prático, utilizou-se um critério baseado na energia acumulada dos coeficientes. Primeiro definiu-se uma função normalizada (com valores entre 0 e 1) que expressa a energia acumulada no canal em função dos valores dos coeficientes, ou seja:

$$E(i) = \frac{\mathbf{w}_i^T \mathbf{w}_i}{\mathbf{w}^T \mathbf{w}} \quad (2.11)$$

onde \mathbf{w}_i representa o vetor composto das i primeiras entradas do vetor de coeficientes. O vetor \mathbf{w} representa todo o vetor de coeficientes. O sobrescrito T indica transposição do vetor.

Buscando selecionar os coeficientes “significativos” a partir de $E(i)$, define-se duas constantes, denominadas E_{Inf} e E_{Sup} as quais representam percentuais da energia normalizada que se permite descartar. No algoritmo utilizado nesta busca há uma relação entre estas constantes, de modo que basta definir uma para que a outra esteja automaticamente definida. Esta relação é dada por:

$$E_{Sup} = 1 - E_{Inf}. \quad (2.12)$$

Dentre todos os coeficientes à disposição está-se interessado nos coeficientes cujos índices pertençam ao seguinte conjunto:

$$\Omega = \{i \mid E_{Inf} < E(i) < E_{Sup}, \forall i \in \Delta\} \quad (2.13)$$

onde Δ , neste contexto, representa o conjunto dos índices dos coeficientes do canal analisado.

Os gráficos da energia acumulada, para cada um dos 8 modelos utilizados neste trabalho, são mostrados nas Figs. 2.21 a 2.28.

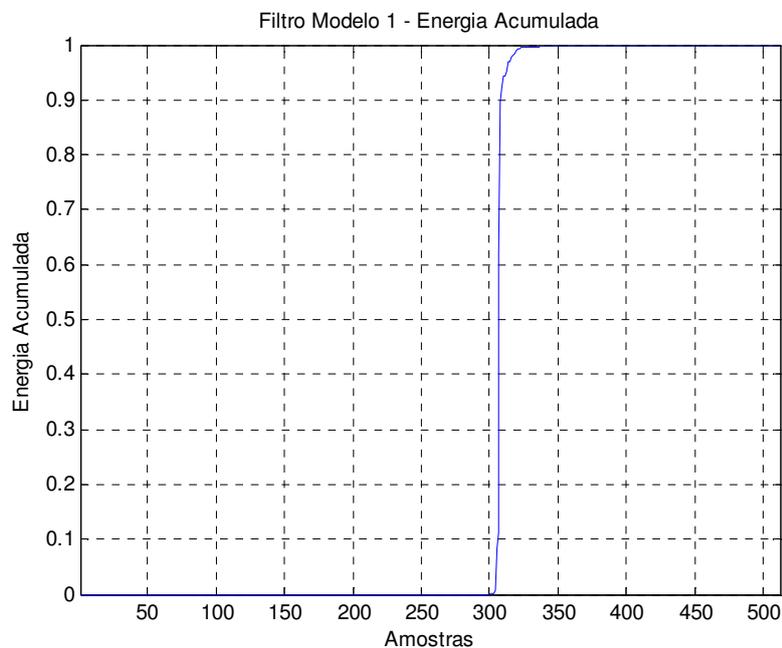


Figura 2.21. Gráfico de energia acumulada para o modelo 1.

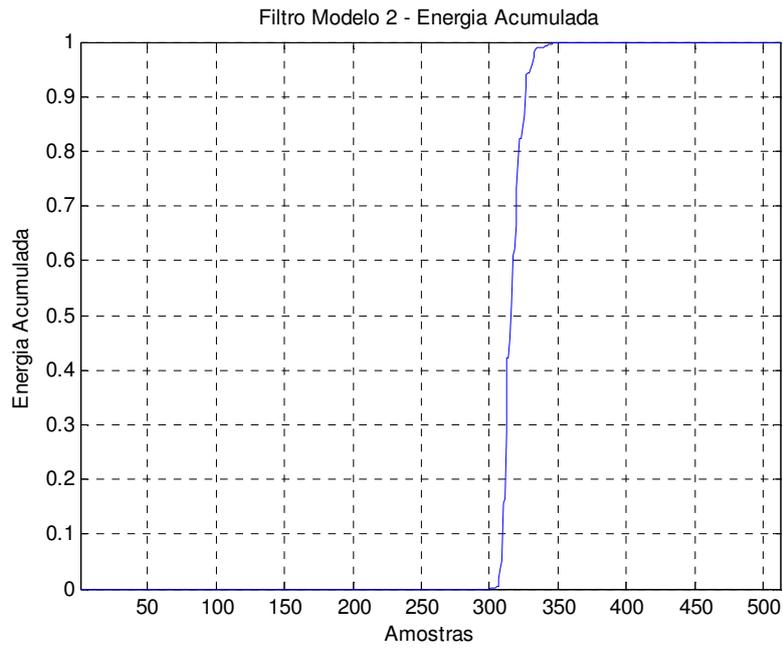


Figura 2.22. Gráfico de energia acumulada para o modelo 2.

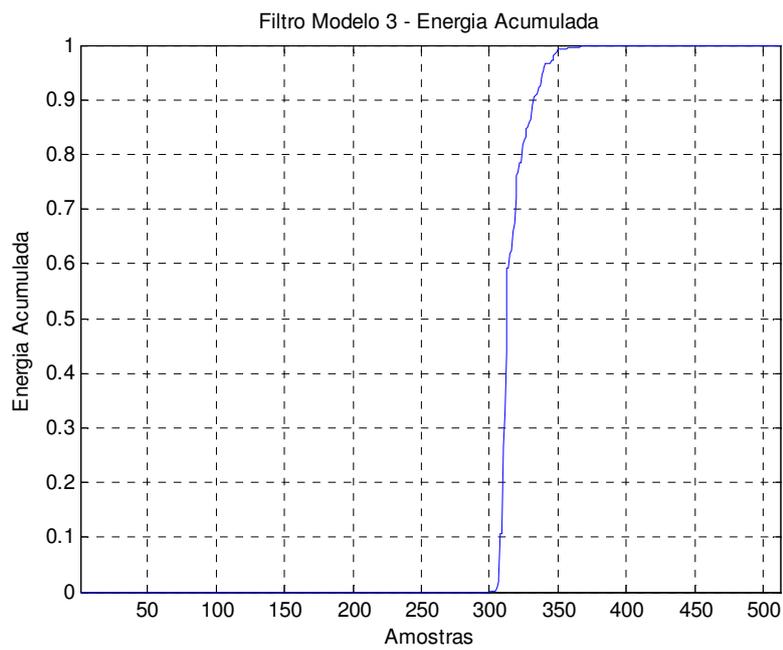


Figura 2.23. Gráfico de energia acumulada para o modelo 3.

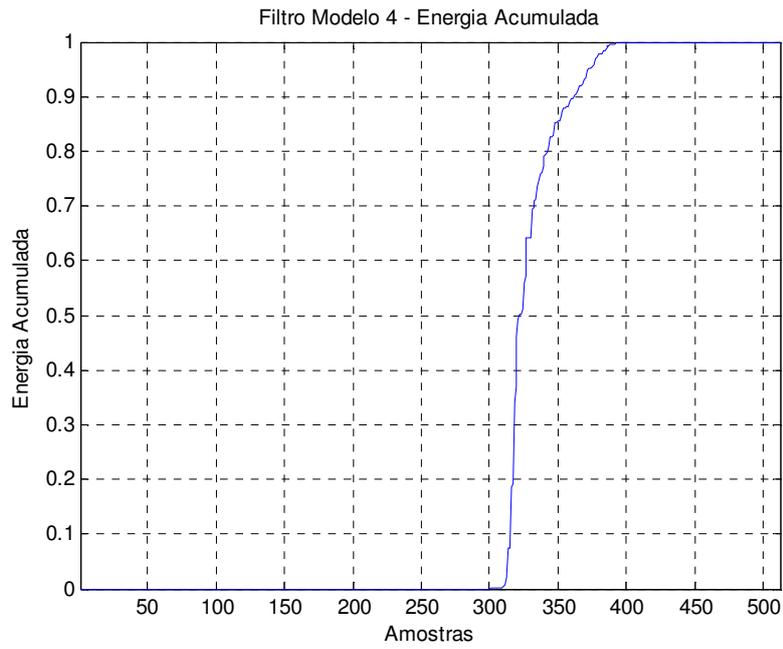


Figura 2.24. Gráfico de energia acumulada para o modelo 4.

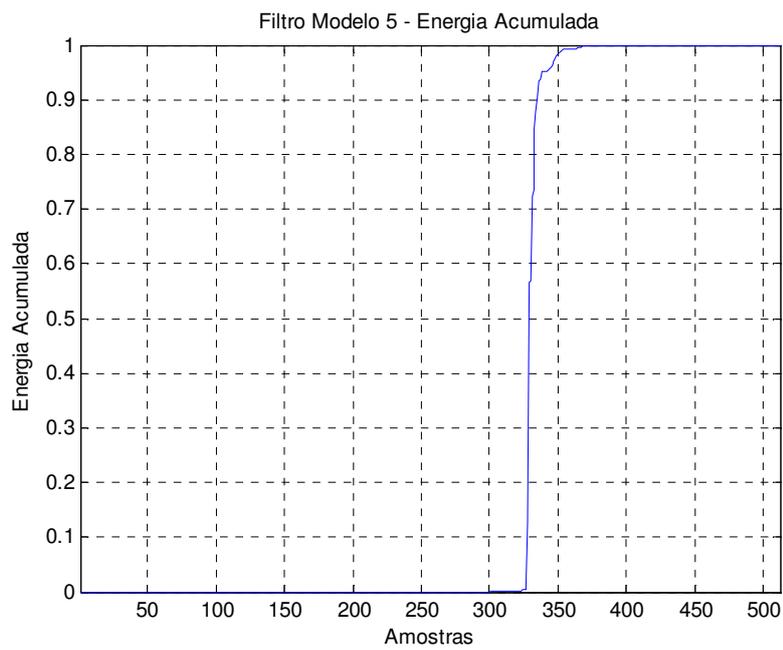


Figura 2.25. Gráfico de energia acumulada para o modelo 5.

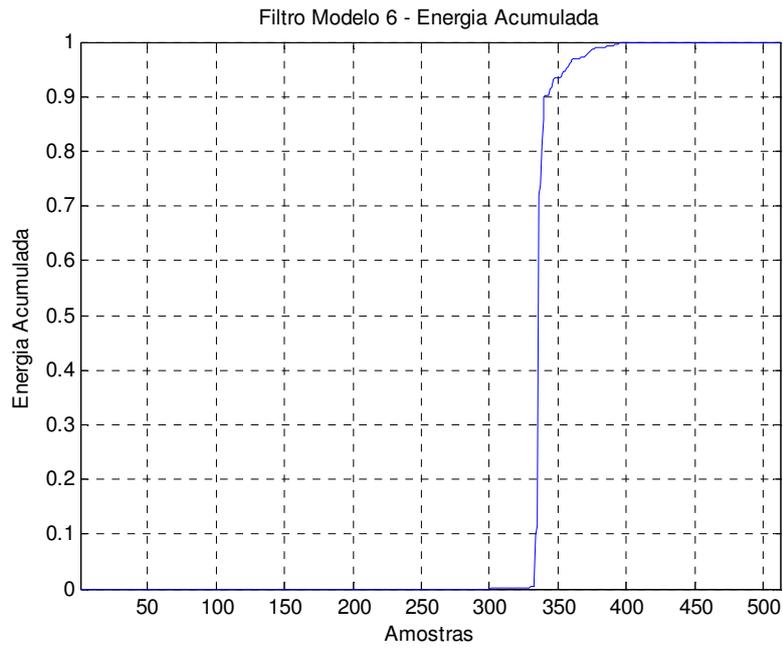


Figura 2.26. Gráfico de energia acumulada para o modelo 6.

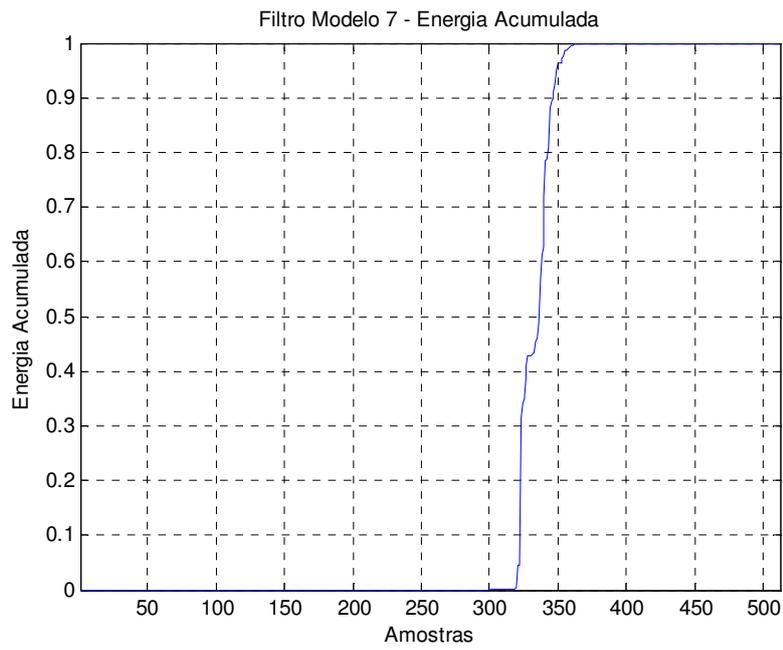


Figura 2.27. Gráfico de energia acumulada para o modelo 7.

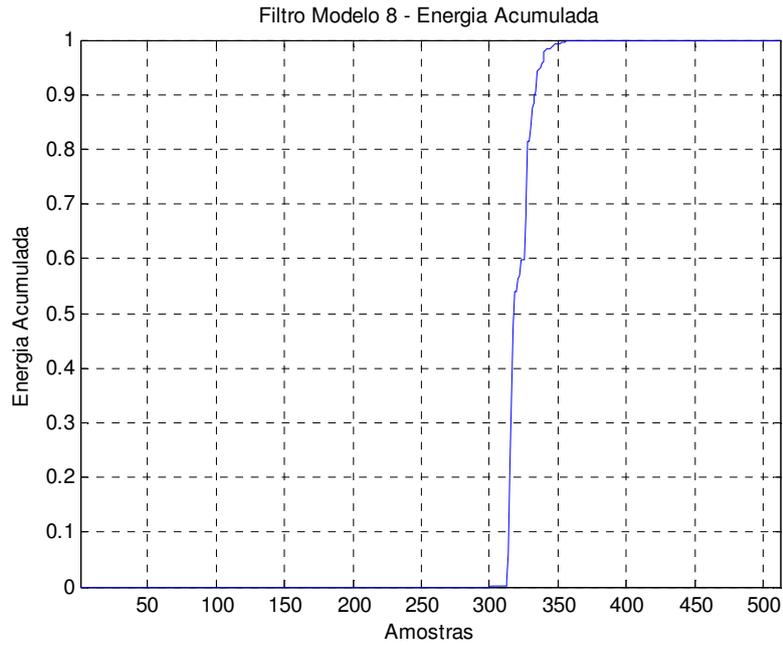


Figura 2.28. Gráfico de energia acumulada para o modelo 8.

A partir da definição deste critério, pode-se definir o limiar e analisar o número de coeficientes que devem ser selecionados para cada um dos canais. Esta informação está no gráfico da Fig. 2.29, o qual expressa para cada um dos 8 modelos, a quantidade de coeficientes selecionados usando-se $E_{inf} = 0,0001$ e, portanto, $E_{sup} = 0,9999$.

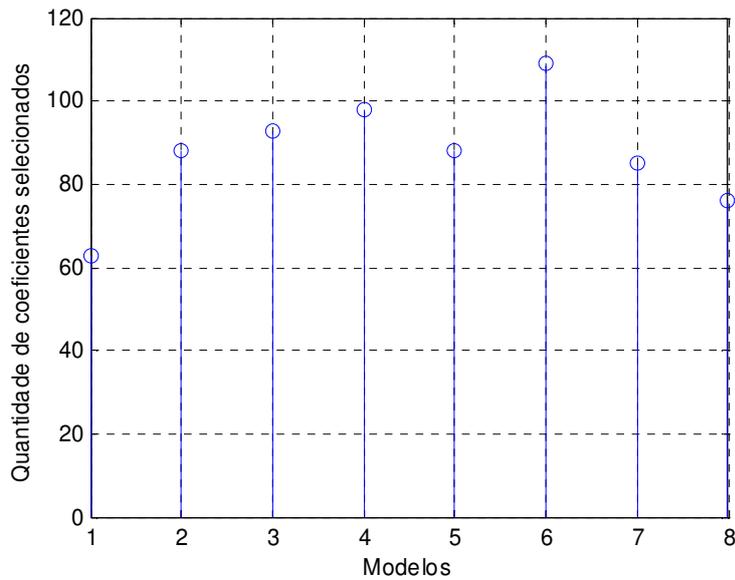


Figura 2.29. Número de coeficientes “significativos” para os 8 modelos.

Deve-se observar que a quantidade de coeficientes explicitada na Fig. 2.29 é uma quantidade ideal que serve apenas para fins de análise e observação, uma vez que na situação em que eles foram calculados os filtros já eram conhecidos. Numa situação real, em que é necessário selecionar um número de coeficientes que permita a convergência (ou seja, coeficientes de valores relevantes não podem ser acidentalmente excluídos do grupo que será adaptado), as quantidades de coeficientes selecionados certamente serão maiores do que estas.

2.5.2. Análise das wavelets

Nesta análise, buscou-se avaliar a capacidade da wavelet em concentrar a energia da resposta impulsiva dos modelos esparsos em poucos coeficientes, pois deste modo seria possível desenvolver um algoritmo capaz de trabalhar com um número pequeno de coeficientes.

Para realizar esta análise foi desenvolvido um algoritmo em que todos os coeficientes são adaptados. Após o algoritmo ter alcançado a convergência, usa-se o critério de energia explicado na Seção 2.5.1 para encontrar o número de coeficientes significativamente diferentes de zero. Nesta análise usou-se $E_{Inf} = 0,0001$ e $E_{Sup} = 0,9999$, o que significa que se está descartando 0,02% da energia total contida em cada canal. Para cada um dos modelos da ITU-T G.168 obtiveram-se os dados contidos nas Tabelas 2.1 a 2.8, a seguir:

Tabela 2.1. Número de coeficientes “significativos” da estrutura wavelet para o modelo 1 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	9	10	11	9	9	11
1	11	11	10	9	9	6
2	18	17	17	7	17	19
3	11	12	24	25	16	12
Total	49	50	62	50	51	48

Tabela 2.2. Número de coeficientes “significativos” da estrutura wavelet para o modelo 2 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	13	14	13	13	11	13
1	7	7	8	13	5	7
2	10	10	14	13	8	10
3	32	32	30	27	34	42
Total	62	63	65	66	58	72

Tabela 2.3. Número de coeficientes “significativos” da estrutura wavelet para o modelo 3 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	13	13	14	13	13	13
1	14	13	12	13	11	10
2	14	13	22	14	10	8
3	35	34	31	26	49	38
Total	76	73	79	66	83	69

Tabela 2.4. Número de coeficientes “significativos” da estrutura wavelet para o modelo 4 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	16	15	15	15	16	15
1	14	13	11	12	11	12
2	24	23	20	25	21	19
3	53	54	43	48	53	53
Total	107	105	103	100	101	99

Tabela 2.5. Número de coeficientes “significativos” da estrutura wavelet para o modelo 5 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	13	12	12	13	12	12
1	7	7	7	13	7	6
2	6	7	4	15	5	7
3	20	20	31	24	30	24
Total	46	46	54	65	54	49

Tabela 2.6. Número de coeficientes “significativos” da estrutura wavelet para o modelo 6 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	15	15	14	15	15	15
1	15	14	10	15	9	11
2	9	8	7	19	7	6
3	32	37	31	32	31	32
Total	71	74	62	81	62	64

Tabela 2.7. Número de coeficientes “significativos” da estrutura wavelet para o modelo 7 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	13	13	13	12	11	12
1	14	14	13	12	11	13
2	12	10	10	18	8	9
3	33	36	37	36	37	36
Total	72	73	73	78	67	70

Tabela 2.8. Número de coeficientes “significativos” da estrutura wavelet para o modelo 8 da ITU-T G.168.

Canais	Bior2.4	Bior4.4	Bior5.5	Db1	Db4	Coif4
0	11	13	13	12	12	13
1	11	11	13	11	14	13
2	9	9	8	12	8	8
3	25	25	26	25	25	24
Total	56	58	60	60	59	58

Comparando os resultados das Tabelas 2.1 a 2.8 com os da Fig. 2.29, pode-se observar que a estrutura que emprega a transformada wavelet é capaz de compactar em um número reduzido de coeficientes a informação contida nas respostas impulsivas esparsas para todos os modelos, exceto para o modelo 4. Em alguns casos, como no modelo 6, a redução é significativa (em torno de 40%).

Pode-se também observar, analisando as tabelas acima, que não há uma única transformada wavelet (dentre as wavelets testadas) que resulte no menor número de coeficientes para todos os modelos.

2.6. Conclusões

Neste capítulo, após uma breve apresentação dos conceitos básicos de filtragem, bancos de filtros e transformada wavelet, apresentamos uma estrutura para modelagem de sistemas FIR composta de uma transformada wavelet e de filtros esparsos, a qual será utilizada nos algoritmos propostos nos próximos capítulos. Introduzimos os sistemas esparsos que serão utilizados nas simulações dos algoritmos propostos, os quais foram obtidos da recomendação “*ITU recommendation G.168: Digital Network Echo Cancellers*”. A capacidade de modelagem destes sistemas pela estrutura wavelet com um número reduzido de coeficientes foi verificada através da utilização de um critério de seleção dos coeficientes “significativos” baseado na distribuição da energia das respostas ao impulso dos sistemas. A partir dos resultados obtidos para os modelos e wavelets considerados, concluiu-se que não há uma wavelet “ótima” para todos os modelos, mas que em geral a estrutura wavelet é capaz de modelar os sistemas esparsos com uma redução significativa no número de coeficientes.

Capítulo 3

Algoritmo Adaptativo com Redução dos Coeficientes para a Estrutura Wavelet

3.1. Introdução

As técnicas de identificação de sistemas baseadas em filtros adaptativos são amplamente usadas em inúmeras aplicações. Identificação de sistemas adaptativos para respostas de eco tem sido um tópico de grande interesse na indústria de telecomunicações e nas comunidades de pesquisa que a suportam [28]. Dois desafios técnicos bem conhecidos que devem ser enfrentados no projeto de canceladores de eco são (i) a longa duração do caminho da resposta do eco desconhecido, o que normalmente requer milhares de coeficientes adaptativos para que essa resposta seja

precisamente modelada; (ii) o comportamento altamente não estacionário da resposta do eco, particularmente em seus últimos coeficientes.

A motivação para utilização de algoritmos de redução de coeficientes pode ser explicada pela alta carga computacional dos algoritmos adaptativos com milhares de coeficientes. A avaliação de um algoritmo adaptativo que usa redução de coeficientes, normalmente envolve uma solução de compromisso entre a complexidade computacional do algoritmo e seu desempenho. Além disso, algoritmos que utilizam a redução de coeficientes tipicamente sofrem de um peso computacional extra, pois necessitam determinar quais coeficientes devem ser adaptados em cada iteração (ou conjunto de iterações) e alguns desses algoritmos utilizam uma ordenação para facilitar a tomada desta decisão.

Na próxima seção será descrito em detalhes o algoritmo baseado na wavelet (WB – *Wavelet Based Algorithm*) proposto por Ho e Blunt em [17], o qual será utilizado como ponto de partida para o desenvolvimento do algoritmo proposto na Seção 3.3.

3.2. O Algoritmo WB (*Wavelet-Based Algorithm*)

Em [17] foi desenvolvido um algoritmo que utiliza a transformada wavelet visando a redução do número de coeficientes que são atualizados quando se empregam filtros adaptativos para a identificação de sistemas esparsos. Como descrito neste trabalho, a localização no tempo das regiões não-nulas das respostas impulsivas requer alta resolução temporal, enquanto que uma boa decorrelação da entrada requer uma alta resolução espectral. Para alcançar este objetivo é proposto um método para a

identificação de sistemas esparsos no domínio da wavelet. Além da vantagem quanto à resolução tempo-frequência da transformada wavelet em relação a outras transformadas, o algoritmo WB se beneficia da estrutura hierárquica temporal entre escalas da wavelet, de tal modo que ao determinar os coeficientes que estão em uma determinada escala cuja faixa no domínio do tempo se sobrepõe às regiões não-nulas da resposta impulsiva, pode-se descobrir os coeficientes em todas as outras escalas correspondentes a estas mesmas regiões não-nulas. Conseqüentemente, somente os coeficientes do sistema desconhecido correspondentes a estas regiões necessitam ser adaptados. A esta característica é adicionado o fato de que a boa localização espectral das wavelets provê, até certo ponto, a decorrelação de entradas coloridas. A combinação destas características incrementa a velocidade de convergência e reduz a complexidade computacional do algoritmo adaptativo.

Uma limitação do algoritmo WB é que o seu desempenho é satisfatório para respostas impulsivas esparsas ricas em conteúdo espectral, ou seja, com respostas em frequência com magnitude aproximadamente plana. Isto ocorre porque é necessário que uma certa quantidade de energia espectral da resposta impulsiva esteja presente em cada banda passante dos filtros equivalentes da wavelet (ver Seção 2.2). Apesar deste tipo de resposta impulsiva ser bastante comum na prática, nem sempre acontece nas aplicações de cancelamento de eco acústico, como observado em [29], [31].

A seguir serão apresentados detalhes do algoritmo proposto em [17], que serão também utilizados no desenvolvimento do algoritmo proposto na Seção 3.3.

3.2.1. Algoritmos no Domínio da Transformada Usando Wavelets

As wavelets possuem a propriedade atrativa da boa localização dentro dos domínios temporal e espectral. É bem sabido que a propriedade espectral da localização permite uma decorrelação maior de uma entrada colorida e, portanto, permite uma rápida convergência para algoritmos adaptativos.

A decomposição wavelet de um sinal ou da resposta ao impulso de um sistema em escalas binárias é realizada com o uso de um filtro passa-baixas e de um filtro passa-altas, denotados nesta seção por g e h , respectivamente [8]. Repetindo um processo de convolução e de sub-amostragem, pode-se decompor um sinal em diferentes níveis de resolução temporal/espectral. Um fator importante que governa a habilidade da localização temporal/espectral é o comprimento dos dois filtros. Filtros mais longos produzirão uma maior resolução espectral e uma menor resolução temporal. Mais especificamente, um filtro mais longo resultará numa melhor divisão em frequência, mas fornecerá menos informação sobre a posição exata das regiões não-nulas da resposta impulsiva.

Utilizando a formulação matricial apresentada em [17], a estimativa da saída do sistema pode ser escrita como

$$\hat{y}(k) = \mathbf{w}^T(k)\mathbf{x}(k) \quad (3.1)$$

onde $\mathbf{w}(k)$ é o vetor de coeficientes do filtro adaptativo e $\mathbf{x}(k) = [x(k) \ x(k-1) \ \dots \ x(k-N+1)]^T$ é o vetor de amostras da entrada, ambos de comprimento N (igual ao comprimento total da resposta ao impulso a ser modelada). Pode-se reescrever (3.1) como

$$\hat{y}(k) = \mathbf{w}^T(k) \mathbf{Q}^T \mathbf{R} \mathbf{x}(k) \quad (3.2)$$

onde \mathbf{Q} e \mathbf{R} são matrizes relacionadas às wavelets utilizadas no algoritmo [17]. Cada linha destas matrizes contém a wavelet em uma determinada escala e translação. Deve-se notar que \mathbf{Q} e \mathbf{R} são tais que $\mathbf{Q}^T \mathbf{R} = \mathbf{I}$, onde \mathbf{I} é matriz identidade. Então (3.2) torna-se

$$\hat{y}(k) = \mathbf{b}^T(k) \mathbf{z}(k) \quad (3.3)$$

onde $\mathbf{b}(k) = \mathbf{Q} \mathbf{w}(k)$ pode ser visto como o vetor de coeficientes do filtro decomposto pela wavelet e $\mathbf{z}(k) = \mathbf{R} \mathbf{x}(k)$ pode ser interpretado como o vetor das entradas decompostas.

Para wavelets ortogonais, tem-se $\mathbf{Q} = \mathbf{R}$ e os filtros passa-baixas e passa-bandas usados para gerar a matriz wavelet seguem de um conjunto explícito de regras tais que h é a versão passa-altas de g [8]. A melhoria na velocidade da convergência é controlada pelo equilíbrio entre a habilidade de descorrelação e o número de coeficientes para adaptar, ambos os quais são função dos comprimentos dos filtros que implementam a wavelet.

Além das wavelets ortogonais, podem-se utilizar as wavelets biortogonais, em que não haverá igualdade entre as matrizes wavelet \mathbf{Q} e \mathbf{R} , uma vez que a restrição na relação entre g e h é relaxada [8]. Isto permite mais graus de liberdade para escolher as wavelets e pode, conseqüentemente, conduzir a maiores ganhos no desempenho do algoritmo.

3.2.2. Estrutura Hierárquica das Wavelets

Será explicado a seguir o uso da propriedade de localização no tempo das wavelets para a identificação de sistemas esparsos. A decomposição wavelet em uma determinada escala pode identificar regiões não-nulas de uma resposta impulsiva esparsa em uma resolução temporal aproximadamente igual à duração da wavelet nesta escala. Além disso, a estrutura hierárquica regular de sua decomposição permite a identificação fácil dos coeficientes das wavelets em todas as outras escalas cujas extensões temporais também se sobrepõem às regiões não-nulas. Esta propriedade pode ser explorada na modelagem de sistemas esparsos, adaptando todos os coeficientes associados a uma escala de controle a_δ , determinando quais destes coeficientes diferem significativamente de zero, e então ativando, para a adaptação, os coeficientes em todas as outras escalas cujas extensões das wavelets correspondentes caíam nas mesmas regiões da resposta impulsiva que os coeficientes não-nulos detectados na escala a_δ . Os coeficientes do filtro associados com as wavelets na escala a_δ são chamados de coeficientes de controle. Os coeficientes que correspondem a níveis mais elevados e mais baixos da escala são denotados como coeficientes “pais” e “filhos”, respectivamente.

A ativação de coeficientes pais e filhos para a adaptação pode ser bastante simplificada ao se arranjar as wavelets dentro de **Q** e **R** corretamente. Para este fim, as wavelets são ordenadas das escalas maiores para as menores como mostrado na Fig. 3.1. Além disso, as wavelets em cada linha da matriz wavelet são vistas como tendo uma região central e duas regiões estendidas. As regiões centrais em uma certa escala **a** não se sobrepõem. As regiões estendidas correspondem ao restante do comprimento da wavelet distribuído igualmente em ambos os lados da região central como mostrado na

Fig. 3.1. Ao arranjar as wavelets desta maneira, o processo de seleção dos coeficientes pais e filhos pode ser executado de forma mais simples [17].

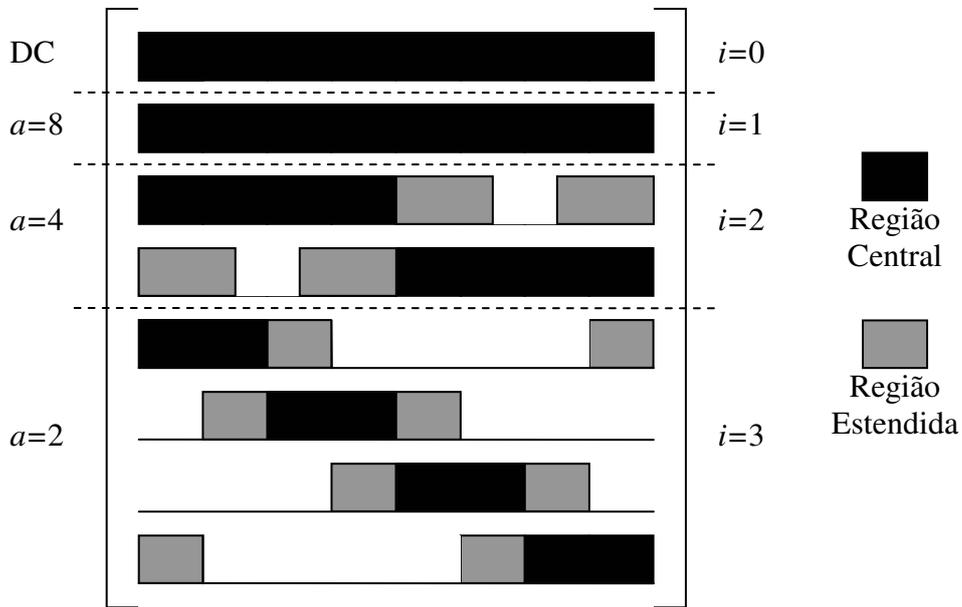


Figura 3.1. Ilustração do algoritmo de ativação dos coeficientes da estrutura wavelet na forma matricial para $N=8$ e $M=3$.

A seguir está descrito o algoritmo de seleção de coeficientes utilizado em [17].

3.2.3. Algoritmo de Seleção de Coeficientes

Para simplificar a análise, foi associado a cada nível binário da escala \mathbf{a} um índice de escala i tal que $a = 2^{(M-i+1)}$ para $1 \leq i \leq M$, onde $2^M=N$ é o comprimento total do filtro. O nível DC na transformada wavelet é associado ao índice de escala $i=0$. A explicação acima é ilustrada na Fig. 3.1 para três níveis de escala.

Atribui-se aos $N=2^M$ coeficientes, em $\mathbf{b}(k)$, índices que vão de 0 a 2^M-1 , com cada coeficiente correspondendo a uma única wavelet na matriz \mathbf{Q} . Os coeficientes do

filtro decomposto são agrupados em conjuntos de acordo com o nível da escala correspondente da wavelet. A cada índice de escala i , para $1 \leq i \leq M$, estão associados os coeficientes de índices na faixa 2^{i-1} até 2^i-1 , inclusive. Será denotado δ , o índice da escala de controle. Os índices de escala $i < \delta$, são associados aos coeficientes pais enquanto os índices de escala $i > \delta$ estão associados aos coeficientes filhos. O conjunto dos índices dos coeficientes de controle é representado por Δ . O conjunto de índices de todos os coeficientes pais ativos para a adaptação é representado por P . Similarmente, o conjunto dos índices dos coeficientes filhos ativos é representado por C . A operação do algoritmo WB pode ser resumida da seguinte forma:

REPETIR

Adapta coeficientes de controle

Adapta coeficientes pais e filhos ativos

SE fim do intervalo de adaptação encontrado ENTÃO

PARA cada coeficiente de controle maior que um valor mínimo

Ativa seus coeficientes pais e filhos

FIM PARA

FIM SE

FIM REPETIR

A estrutura do algoritmo proposto é descrita na Fig. 3.2. $\mathbf{z}_\Delta(k)$, $\mathbf{z}_C(k)$ e $\mathbf{z}_P(k)$ são vetores de amostras da entrada decompostas pela wavelet para o vetor de coeficientes de controle $\mathbf{b}_\Delta(k)$, o vetor de coeficientes filhos ativos $\mathbf{b}_C(k)$ e o vetor de coeficientes pais ativos $\mathbf{b}_P(k)$, respectivamente. $\hat{y}(k)$ é a saída estimada do sistema, $y(k)$ é a resposta real do sistema e $e(k)$ é o erro.

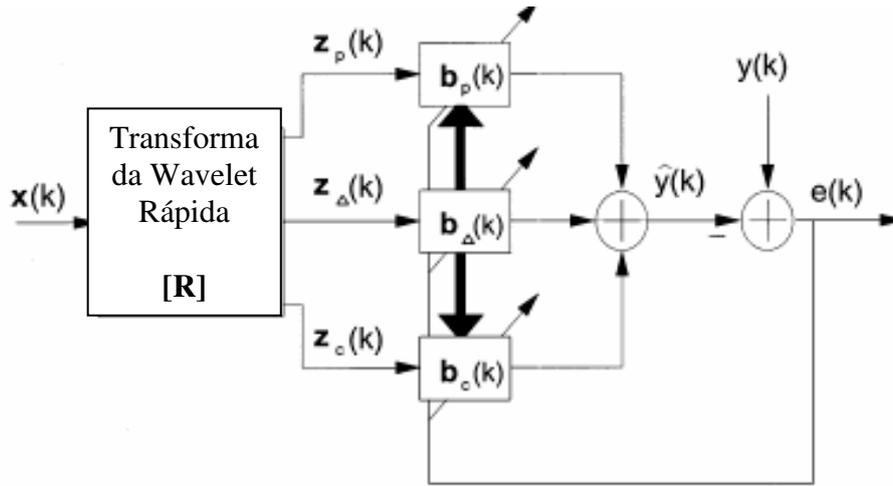


Figura 3.2. Diagrama de blocos do algoritmo WB [17].

A estimativa da saída do sistema descrito na Fig. 3.2 pode ser expressa por:

$$\hat{y}(k) = \mathbf{b}_{\Delta}^T(k) \mathbf{z}_{\Delta}(k) + \mathbf{b}_c^T(k) \mathbf{z}_c(k) + \mathbf{b}_p^T(k) \mathbf{z}_p(k) \quad (3.4)$$

A atualização dos coeficientes de controle é dada por:

$$\mathbf{b}_{\Delta}(k+1) = \mathbf{b}_{\Delta}(k) + 2\hat{\mu}e(k)\hat{\lambda}_{\delta}^{-2}\mathbf{z}_{\Delta}(k), \quad (3.5)$$

onde $\hat{\lambda}_{\delta}^{-2}$ é o inverso da potência de entrada estimada para o índice de escala δ ;

$\hat{\mu} = \mu_0 / \hat{N}$, μ_0 é uma constante pré-estabelecida e \hat{N} é o número total de coeficientes sendo adaptados no momento. Deve-se observar que todos os coeficientes de controle são adaptados.

Para os coeficientes pais e filhos, as equações de atualização são:

$$\mathbf{b}_c(k+1) = \mathbf{b}_c(k) + 2\hat{\mu}e(k)\hat{\Lambda}_c^{-2}\mathbf{z}_c(k), \quad (3.6)$$

$$\mathbf{b}_p(k+1) = \mathbf{b}_p(k) + 2\hat{\mu}e(k)\hat{\Lambda}_p^{-2}\mathbf{z}_p(k), \quad (3.7)$$

onde $\hat{\Lambda}_c^2$ e $\hat{\Lambda}_p^2$ são matrizes diagonais cujos elementos são as potências estimadas das entradas em diferentes níveis de escala correspondente aos coeficientes pais e filhos ativos, respectivamente.

Deve ser dado um período apropriado de tempo para adaptação dos coeficientes de controle, o qual será denotado como intervalo de adaptação T_{AI} (*Time of Adaptation Interval*). T_{AI} pode ser escolhido proporcional à constante de convergência [1]. No fim de cada intervalo da adaptação, o algoritmo determina quais coeficientes de controle são significativamente diferentes de zero. Cada coeficiente de controle é modelado como uma variável aleatória de distribuição gaussiana [15]. Uma vez que o valor verdadeiro do coeficiente não é conhecido, foi usado o critério de Neyman-Pearson [16] para a detecção. Para uma dada probabilidade de falso alarme, a detecção de coeficientes não-nulos de controle é conseguida comparando sua magnitude com um nível limiar. Este limiar, chamado de Φ é calculado ao fim de cada intervalo de adaptação como [19]:

$$\Phi = \beta_{fa} \sqrt{\frac{\hat{\mu}_{\xi}^{\hat{\xi}}(k)}{\hat{\lambda}_{\delta}^2(k)}} \quad (3.8)$$

onde $\hat{\xi}(k)$ é a estimativa atual do erro médio quadrático e $\hat{\lambda}_{\delta}^2(k)$ é a atual potência estimada do sinal no índice de escala δ , os quais podem ser obtidos através da média exponencial de $e(k)$ e o primeiro elemento de $\mathbf{z}_{\Delta}(k)$, respectivamente. O parâmetro β_{fa} está relacionado à probabilidade de falso alarme P_{fa} definida pelo usuário de acordo com a variância de distribuição gaussiana unitária padrão e $\frac{\hat{\mu}_{\xi}^{\hat{\xi}}(k)}{\hat{\lambda}_{\delta}^2(k)}$ é a estimativa da variância dos coeficientes adaptativos [1]. Os índices de coeficientes de controle detectados são colocados no conjunto de índices de coeficientes Ω .

A probabilidade da detecção depende de quão grandes são as médias dos coeficientes de controle em comparação aos seus desvios padrões. Os desvios padrões são proporcionais ao tamanho do passo do algoritmo. Diminuir o tamanho do passo pode, conseqüentemente, aumentar a probabilidade da detecção, ao custo de uma maior demora na convergência.

Uma vez que os coeficientes de controle não-nulos foram determinados, os coeficientes pais e filhos apropriados podem ser ativados. Cada coeficiente de controle não-zero detectado com índice $\omega \in \Omega$ ativará os coeficientes filhos com índices na faixa:

$$C_{\omega,i} = \left[2^{(i-\delta)} \omega : 2^{(i-\delta)} (\omega+1) - 1 \right] \quad (3.9)$$

para $\delta+1 \leq i \leq M$. Este processo de seleção ativa coeficientes filhos onde as regiões centrais das correspondentes wavelets se sobrepõem temporariamente com as regiões centrais das wavelets identificadas pelos coeficientes de controle não-nulos detectados. É considerada somente a sobreposição das regiões centrais a fim eliminar a ativação desnecessária de filhos. Isto é possível porque todas as regiões centrais das wavelets, em um único nível de escala, juntas sobrepõem toda a duração da resposta impulsiva no domínio do tempo.

Para determinar os coeficientes pais que precisam ser ativados levam-se em conta as regiões estendidas. Inicialmente determinam-se os coeficientes pais que estarão sempre ativados devido ao fato de que suas wavelets cobrem, no mínimo, quase toda a extensão da resposta impulsiva. Estes coeficientes têm o índice de escala $i = 0, 1, \dots, r$ onde $r = \lceil \log_2(\max(L_g, L_h)) \rceil$, e L_g e L_h são, respectivamente, os comprimentos dos filtros passa-baixas e passa-altas que geraram a wavelet [8]. O número total de pais nesta escala é 2^r .

A determinação dos restantes dos coeficientes pais que devem ser ativados é um pouco mais complexa e necessita fundamentalmente de duas quantidades. A primeira é a duração da wavelet no índice de escala i :

$$l_i = \left(2^{(M-i)} - 1 \right) L_g + 2^{(M-i)} L_h - \left(2^{(M-i+1)} - 2 \right), i > r \quad (3.10)$$

onde $2^M = N$ é o comprimento total do filtro. A segunda quantidade necessária é o deslocamento temporal entre duas wavelets sucessivas dentro do mesmo índice de escala i :

$$k_i = 2^{(M-i+1)}. \quad (3.11)$$

Então, para cada $\omega \in \Omega$, o restante dos coeficientes pais que necessitam ser ativados são aqueles cujos índices estão no conjunto

$$P_\omega = \{j : [\rho_{\omega,i} - \eta_i] \leq j \leq [\rho_{\omega,i} + \eta_i], i = r+1, \dots, \delta-1\} \quad (3.12)$$

onde $\rho_{\omega,i} = \lfloor \omega / 2^{\delta-i} \rfloor$ e $\eta_i = \lceil (l_i - k_i) / (2k_i) \rceil$. O valor $\rho_{\omega,i}$ é o índice do coeficiente do pai no índice de escala i cuja região central da wavelet correspondente se sobrepõe temporariamente à região não-nula identificada pelo coeficiente de controle não-zero detectado de índice ω . O valor η_i é o número de sucessivas regiões centrais no índice de escala i que se sobrepõem com a região estendida de um lado de uma wavelet no mesmo índice de escala.

3.2.4. Resumo do Algoritmo

O algoritmo a seguir utiliza as definições dadas anteriormente no texto.

REPETIR

$$\mathbf{x}(k) = [x(k) \quad x(k-1) \quad \dots \quad x(k-N+1)]^T$$

$$[\mathbf{z}_p(k) \quad \mathbf{z}_\Delta(k) \quad \mathbf{z}_c(k)] = \mathbf{R}(\mathbf{x}(k))$$

$$\mathbf{b}_\Delta(k+1) = \mathbf{b}_\Delta(k) + 2\hat{\mu}e(k)\hat{\lambda}_\delta^{-2}\mathbf{z}_\Delta(k)$$

$$\mathbf{b}_c(k+1) = \mathbf{b}_c(k) + 2\hat{\mu}e(k)\hat{\Lambda}_c^{-2}\mathbf{z}_c(k)$$

$$\mathbf{b}_p(k+1) = \mathbf{b}_p(k) + 2\hat{\mu}e(k)\hat{\Lambda}_p^{-2}\mathbf{z}_p(k)$$

$$\hat{y}(k) = \mathbf{b}_\Delta^T(k)\mathbf{z}_\Delta(k) + \mathbf{b}_C^T(k)\mathbf{z}_C(k) + \mathbf{b}_P^T(k)\mathbf{z}_P(k)$$

SE fim do intervalo de adaptação

$$\text{PARA cada coeficiente de magnitude maior que } \Phi = \beta_{fa} \sqrt{\frac{\hat{\mu}\hat{\xi}(k)}{\hat{\lambda}_\delta^2(k)}}$$

Lembrando que $\omega \in \Omega$ é o índice do coeficiente selecionado

$$C_{\omega,i} = \left[2^{(i-\delta)} \omega : 2^{(i-\delta)} (\omega+1) - 1 \right]$$

$$r = \left\lceil \log_2(\max(L_g, L_h)) \right\rceil$$

$$l_i = \left(2^{(M-i)} - 1 \right) L_g + 2^{(M-i)} L_h - \left(2^{(M-i+1)} - 2 \right), i > r$$

$$k_i = 2^{(M-i+1)}.$$

$$\rho_{\omega,i} = \left\lfloor \omega / 2^{\delta-i} \right\rfloor$$

$$\eta_i = \left\lceil (l_i - k_i) / (2k_i) \right\rceil$$

$$P_\omega = \left\{ j : \left\lfloor \rho_{\omega,i} - \eta_i \right\rfloor \leq j \leq \left\lfloor \rho_{\omega,i} + \eta_i \right\rfloor, i = r+1, \dots, \delta-1 \right\}$$

FIM PARA

FIM SE

FIM REPETIR

3.3. O Algoritmo Proposto: ESWB (*Energy Sum Wavelet-Based*)

O algoritmo proposto nesta dissertação, denotado por ESWB, é semelhante e inspirado na linha de raciocínio do algoritmo WB descrito na Seção 3.2. No método proposto procura-se aproveitar a estrutura hierárquica entre escalas característica das wavelets para desenvolver um algoritmo que difere do anterior pelo modo de selecionar os coeficientes de controle que terão seus filhos ativados. Outra diferença do algoritmo ESWB é na estrutura de decomposição e filtragem do sinal de entrada, sendo adotada a estrutura apresentada na Seção 2.3. Com esta estrutura, a seleção dos coeficientes pais e filhos a serem ativados é mais simples, não sendo necessário analisar as regiões estendidas.

3.3.1. Algoritmo de Seleção de Coeficientes

Como já foi mencionado, uma das diferenças do algoritmo ESWB em relação ao algoritmo WB é quanto ao critério utilizado para selecionar os coeficientes de controle que são considerados suficientemente diferentes de zero.

O critério adotado se baseia na energia dos coeficientes do canal de controle. A idéia deste critério é encontrar a região dos coeficientes do canal de controle que concentram a quase totalidade da energia deste canal.

Como descrito na Seção 2.5, para aplicar este critério, cria-se uma função energia normalizada definida como

$$E_{\delta}(i) = \frac{\mathbf{w}_{\delta,i}^T \mathbf{w}_{\delta,i}}{\mathbf{w}_{\delta}^T \mathbf{w}_{\delta}} \quad (3.13)$$

onde $\mathbf{w}_{\delta,i}$ representa o vetor composto das i primeiras entradas do vetor de coeficientes no índice de escala δ (deve-se lembrar que o δ especifica o índice de escala dos coeficientes de controle). O vetor \mathbf{w}_{δ} representa todo o vetor de coeficientes no índice de escala δ .

Analisando uma curva típica de $E_{\delta}(i)$, ilustrada na Fig. 3.3, observa-se que na faixa de valores de i correspondente aos coeficientes que têm relevância o gráfico apresenta uma inclinação acentuada. Uma vez que o tipo de sistema em que estamos interessados é esparso e os coeficientes de interesse estão localizados numa mesma região, o gráfico de $E_{\delta}(i)$ terá essencialmente três regiões distintas: uma região onde o gráfico é horizontal ou praticamente horizontal (o que significa que estes coeficientes têm energia zero ou quase zero); uma segunda região em que a função energia acumulada cresce rapidamente (que corresponde a faixa de coeficientes que têm energia relevante para o sistema); e uma terceira região em que o gráfico volta a ser horizontal ou quase horizontal com valores muito próximos a $E_{\delta}(i) = 1$ (indicando que os coeficientes voltaram a ter energia nula ou quase nula). No exemplo da Fig. 3.3 a região que vai de $i = 1$ até $i = 70$ corresponde a $E_{\delta}(i) = 0$; a região que vai de $i = 71$ a $i = 75$ tem $E_{\delta}(i)$ variando linearmente até o valor máximo de 1; a região após $i = 75$ tem $E_{\delta}(i) = 1$. Claramente percebe-se que estamos interessados nos coeficientes da segunda região e que, portanto, podemos encontrar um método para selecionar estes coeficientes.

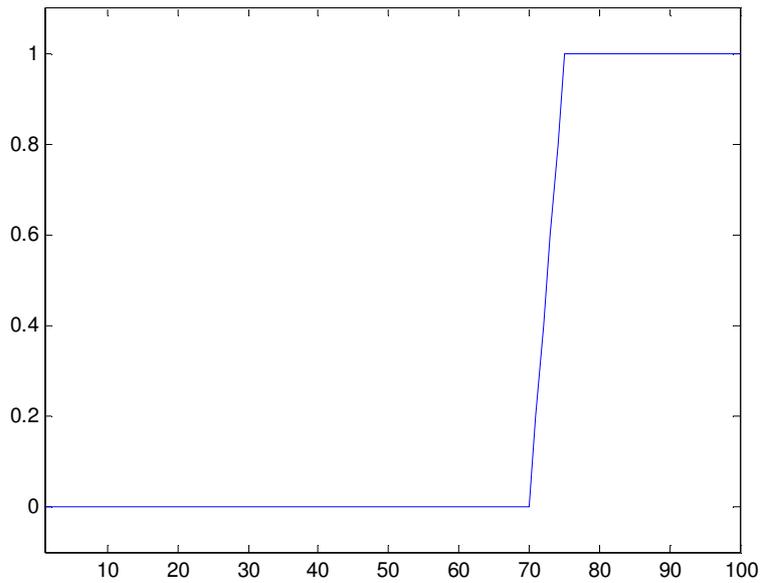


Figura 3.3. Gráfico típico de $E_{\delta}(i)$.

Buscando selecionar os coeficientes na segunda região do gráfico de $E_{\delta}(i)$, utilizam-se duas constantes, como descrito na Seção 2.5, denominadas E_{Inf} e E_{Sup} , as quais representam percentuais da energia normalizada que se pode descartar.

Com este critério determinam-se, dentre todos os coeficientes de controle, quais serão considerados suficientemente diferentes de zero (e, portanto, terão seus pais e filhos ativados), ou seja, consideram-se ativos os coeficientes que tiverem seus índices dentro do seguinte conjunto:

$$\Omega = \{i \mid E_{Inf} < E_{\delta}(i) < E_{Sup}, \forall i \in \Delta\} \quad (3.14)$$

onde Δ representa o conjunto dos índices dos coeficientes de controle.

Na implementação prática do critério descrito acima, aplicou-se um limiar aos coeficientes para evitar que o ruído de adaptação dos coeficientes (devido ao ruído da estimativa do gradiente, o qual é proporcional ao passo) seja acumulado no cálculo da função energia acumulada. O limiar adotado foi igual a 1% do valor máximo dos coeficientes de cada canal.

Após determinar os coeficientes significativos do canal de controle, selecionamos os coeficientes filhos usando o seguinte mapeamento entre os coeficientes do canal de controle significativos $\Omega_\delta = [\omega_{Inf} : \omega_{Sup}]$ e os coeficientes do i-ésimo canal:

$$\Omega_i = \left[(L_i/L_\delta)\omega_{Inf} + \Delta_i : (L_i/L_\delta)\omega_{Sup} + \Delta_i \right]$$

onde $\Delta_i = (N_{H_\delta} - N_{H_i})/L_i$ é o atraso do i-ésimo canal em relação ao canal de controle δ dividido pelo fator de esparsidade L_i do subfiltro correspondente, sendo N_{H_i} e N_{H_δ} os comprimentos dos filtros de análise equivalentes dos canais i e δ , respectivamente. Na implementação prática do mapeamento acima, considerou-se, para selecionar os coeficientes filhos, um coeficiente a mais no início da faixa selecionada do canal de controle (ou seja, utilizou-se $\hat{\omega}_{Inf} = \omega_{Inf} - 1$) e um a mais no final da faixa selecionada (ou seja, $\hat{\omega}_{Sup} = \omega_{Sup} + 1$), para evitar que houvesse perda de informação quando as componentes da resposta ao impulso do filtro esparsa modelado tiverem uma pequena defasagem temporal. Com isto, conseguiu-se melhorar consideravelmente o desempenho do algoritmo proposto.

Após selecionar os coeficientes pais e filhos ativos, estes foram adaptados usando equações de atualizações semelhantes às equações (3.6) e (3.7).

3.3.2. Resumo do Algoritmo Proposto

O algoritmo a seguir utiliza as definições dadas anteriormente no texto.

REPETIR

$$\mathbf{x}(k) = [x(k) \quad x(k-1) \quad \dots \quad x(k-N+1)]^T$$

$$[\mathbf{z}_p(k) \quad \mathbf{z}_\Delta(k) \quad \mathbf{z}_c(k)] = \mathbf{h}_m(k) * \mathbf{x}(k)$$

$$\mathbf{b}_\Delta(k+1) = \mathbf{b}_\Delta(k) + 2\hat{\mu}e(k)\hat{\Lambda}_\delta^{-2}\mathbf{z}_\Delta(k)$$

$$\mathbf{b}_c(k+1) = \mathbf{b}_c(k) + 2\hat{\mu}e(k)\hat{\Lambda}_c^{-2}\mathbf{z}_c(k)$$

$$\mathbf{b}_p(k+1) = \mathbf{b}_p(k) + 2\hat{\mu}e(k)\hat{\Lambda}_p^{-2}\mathbf{z}_p(k)$$

$$\hat{y}(k) = \mathbf{b}_\Delta^T(k)\mathbf{z}_\Delta(k) + \mathbf{b}_c^T(k)\mathbf{z}_c(k) + \mathbf{b}_p^T(k)\mathbf{z}_p(k)$$

SE fim do intervalo de adaptação

PARA cada coeficiente cujo índice estiver no conjunto

$$\Omega = \{i \mid E_{inf} < E_\delta(i) < E_{sup}, \forall i \in \Delta\}, \text{ onde } E_\delta(i) = \frac{\mathbf{w}_{\delta,i}^T \mathbf{w}_{\delta,i}}{\mathbf{w}_\delta^T \mathbf{w}_\delta}$$

Então determinam-se os coeficientes pais e filhos usando a

seguinte relação:

$$\Omega_i = \left[(L_i/L_\delta)\hat{\omega}_{inf} + \Delta_i : (L_i/L_\delta)\hat{\omega}_{sup} + \Delta_i \right], \text{ onde}$$

$$\Delta_i = (N_{H_\delta} - N_{H_i})/L_i,$$

FIM PARA

FIM SE

FIM REPETIR

3.4. Resultados Experimentais

Para analisar o desempenho do algoritmo proposto foram utilizados os modelos sugeridos pela ITU em sua recomendação G.168 sobre cancelamento de eco em linhas telefônicas digitais descritos na Seção 2.3.. As wavelets utilizadas foram as Biortogonais 2.4, 4.4 e 5.5, Daubechies 1 e 4, e Coiflet 4, conforme discutido na Seção 2.4, com 3 níveis de decomposição (ou seja, $M = 4$ canais). Escolhemos o canal de frequências mais baixas ($\delta=0$), cujo fator de esparsidade é $L_\delta= 8$, como canal de controle. Esta escolha foi feita baseada nos resultados de testes preliminares, que indicaram ser este o melhor canal de controle para os sistemas e sinais de entrada considerados.

Foi utilizado como sinal de entrada um ruído colorido originado da passagem de um ruído branco gaussiano pelo filtro:

$$H(z) = \frac{0,25\sqrt{3}}{1-1,5z^{-1} + z^{-2} - 0,25z^{-3}} \quad (3.15)$$

cujo resultado é um sinal aleatório com espectro semelhante ao da voz humana [21].

A seguir serão mostrados os desempenhos dos algoritmos ESWB e WB para os diferentes modelos de canais.

3.4.1. Desempenho do algoritmo ESWB com as diferentes wavelets

As Figs. 3.4 a 3.19 mostram a evolução do MSE e do número de coeficientes adaptados no algoritmo ESWB para os 8 modelos. Dos gráficos do erro médio quadrático, podemos concluir que o algoritmo ESWB com a wavelet Daubechies 1 apresentou a convergência mais lenta para todos os modelos, o que já era esperado devido à simplicidade (e conseqüente baixa seletividade em frequência) desta transformada. As wavelets Biortogonais 2.4 e 4.4 convergiram para MSEs menores que -50 dB em todas as simulações. A wavelet Biortogonal 5.5 obteve o melhor desempenho para os modelos 4 a 8, mas resultou num MSE em torno de -38 dB para o modelo 2. As wavelets Coiflet 4 e Daubechies 4 tiveram desempenho inferior às Biortogonais para todos os modelos.

Quanto ao número de coeficientes, o algoritmo ESWB com a wavelet Daubechies 1 foi o que resultou no menor número de coeficientes após o estágio inicial de seleção dos coeficientes ativos. A wavelet Coiflet 4 foi a que apresentou, em geral, o maior número de coeficientes. Podemos também verificar que em relação à redução do número de coeficientes, as wavelets Daubechies foram mais eficientes do que as demais, ao custo de um aumento no MSE.

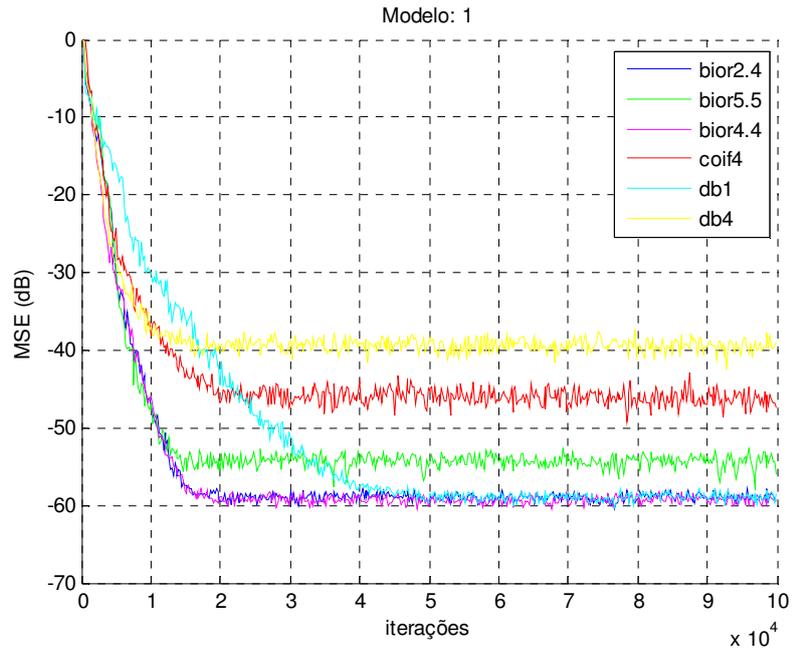


Figura 3.4. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 1.

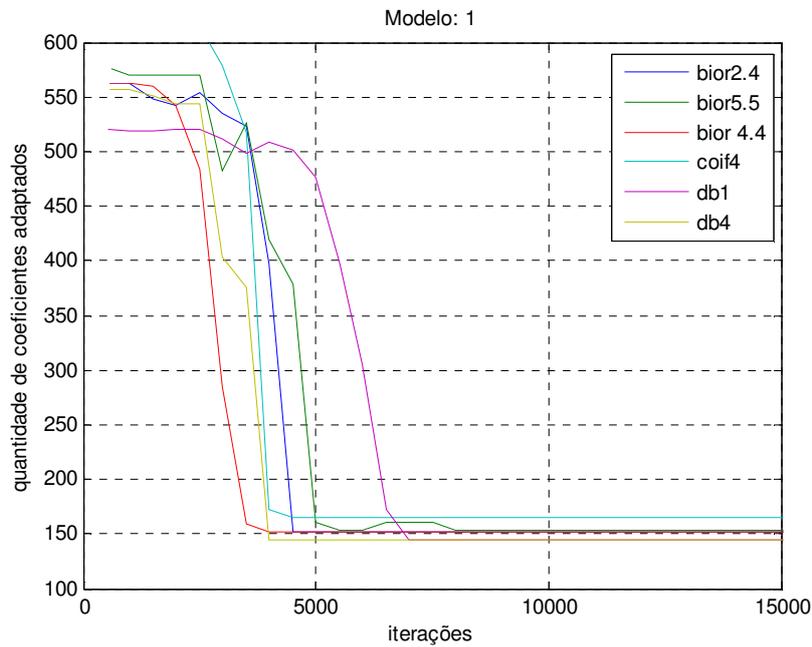


Figura 3.5. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 1.

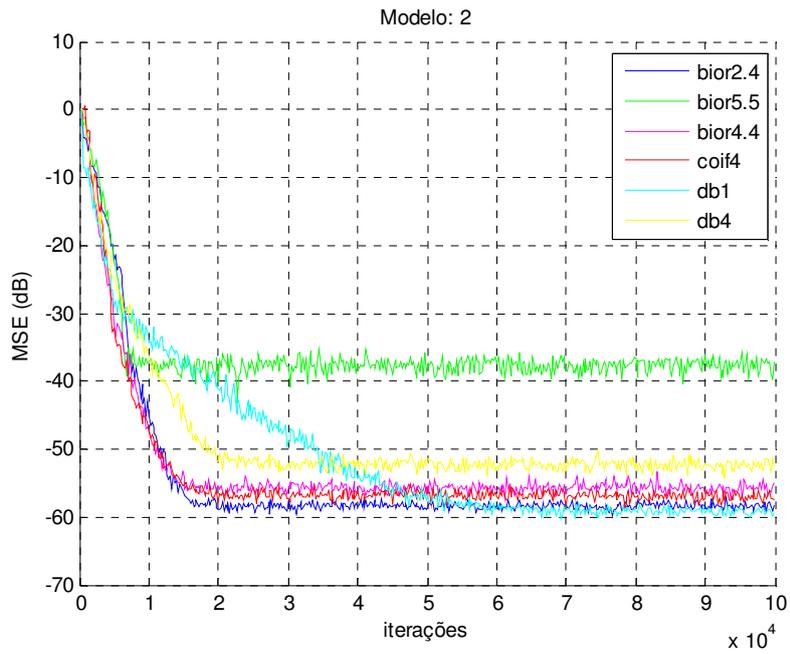


Figura 3.6. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 2.

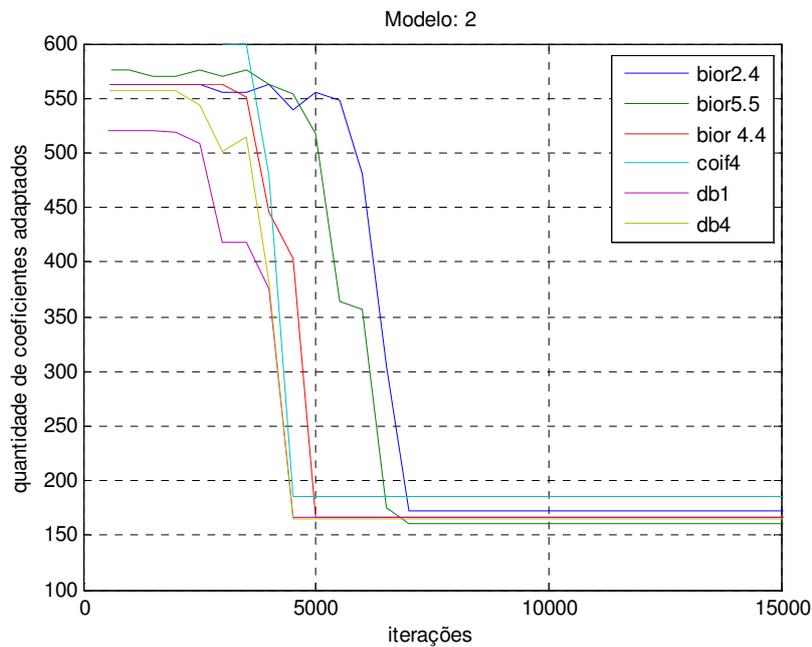


Figura 3.7. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 2.

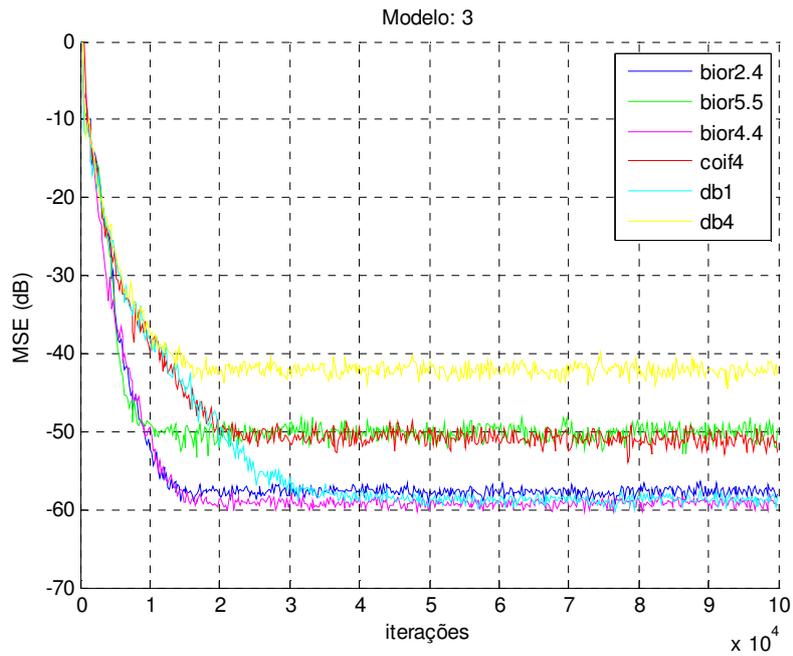


Figura 3.8. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 3.

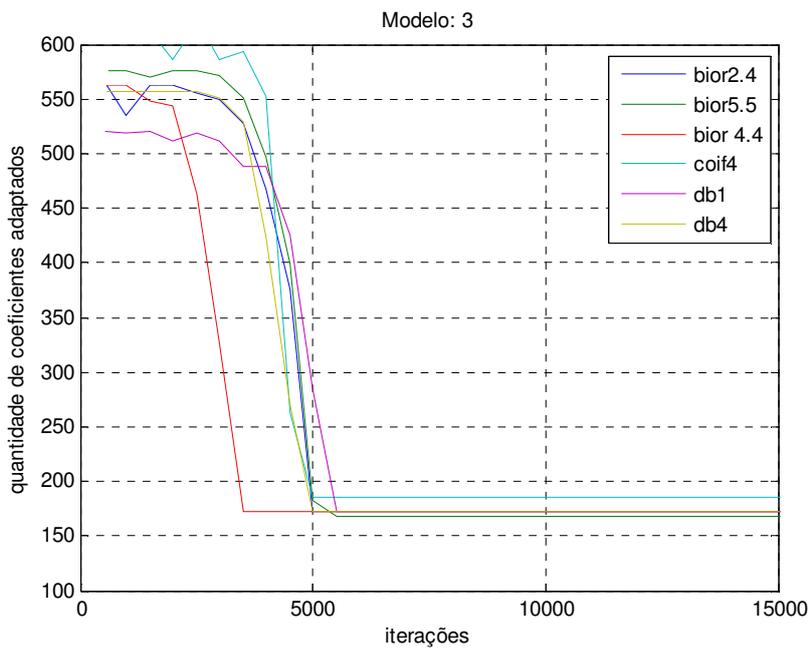


Figura 3.9. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 3.

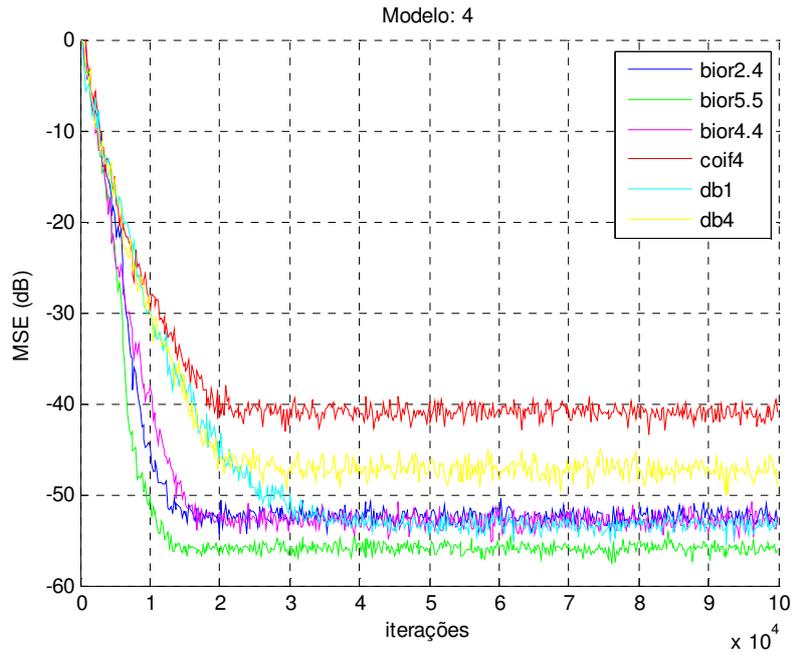


Figura 3.10. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 4.

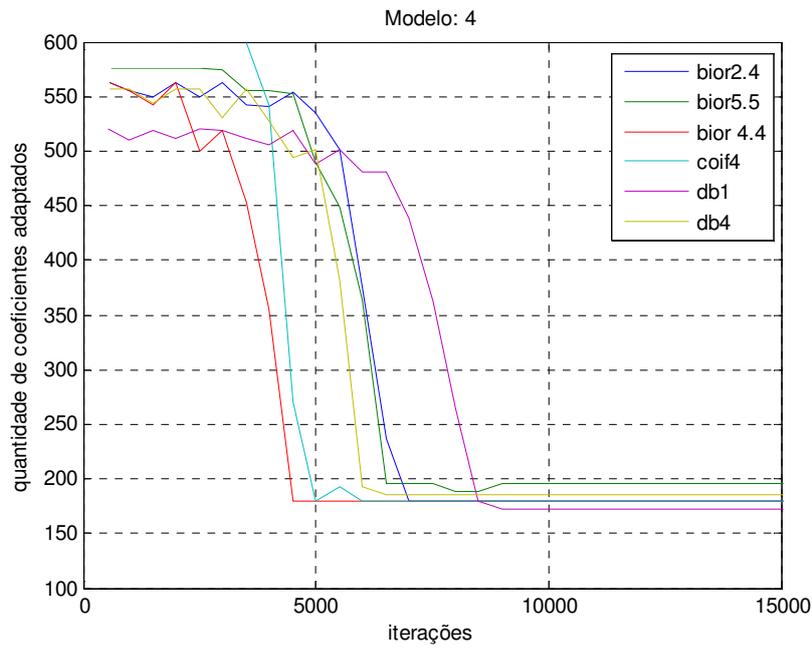


Figura 3.11. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 4.

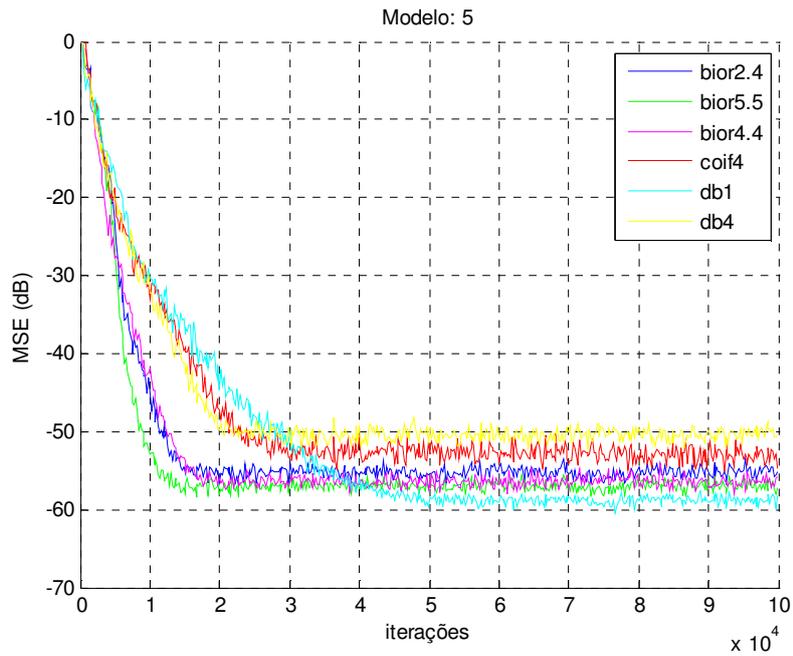


Figura 3.12. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 5.

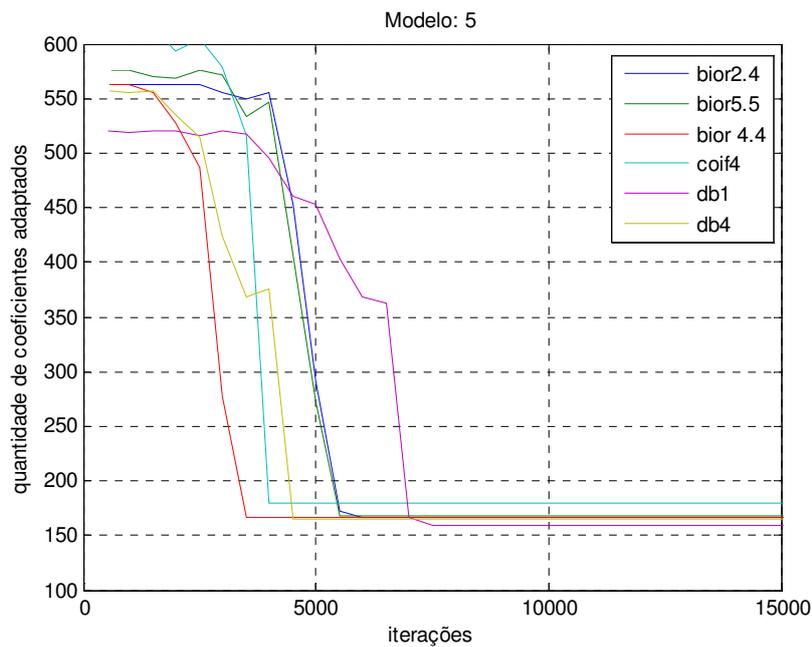


Figura 3.13. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 5.

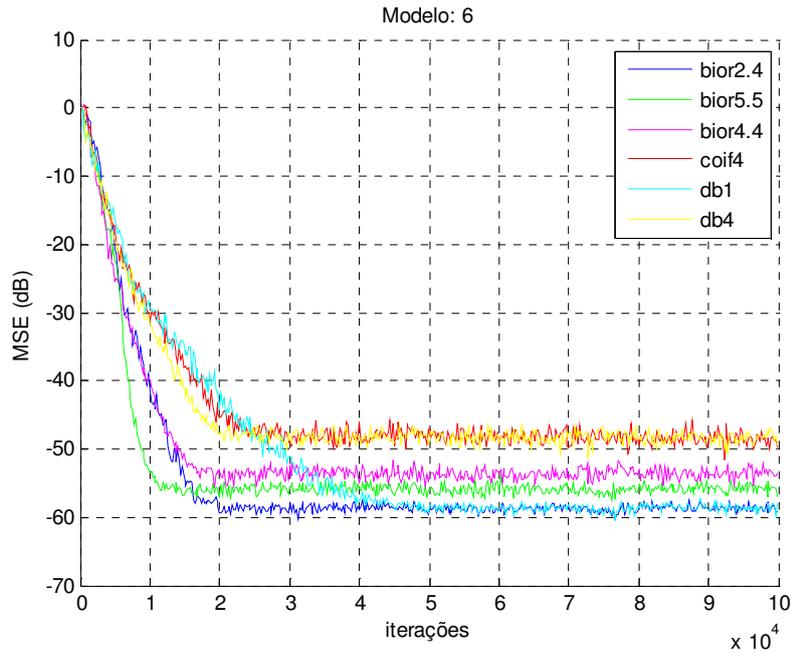


Figura 3.14. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 6.

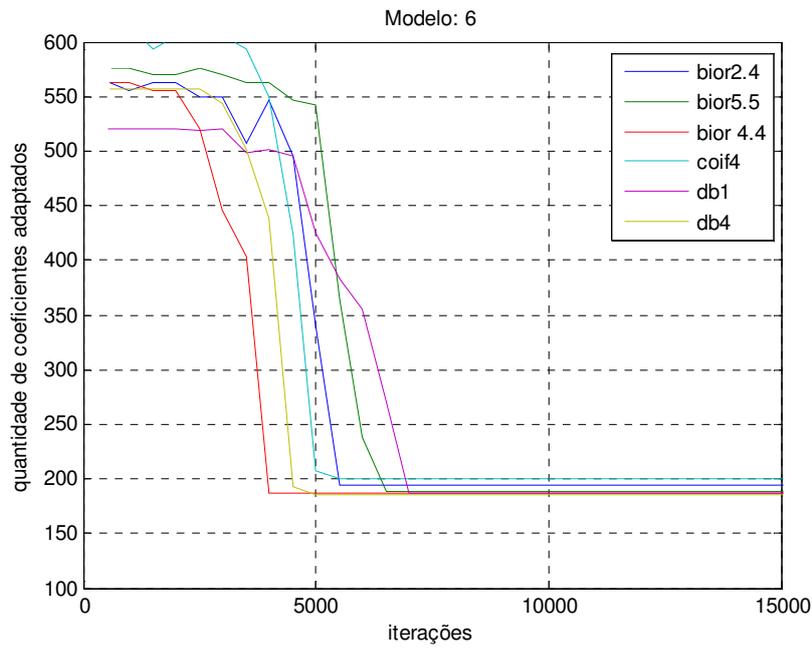


Figura 3.15. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 6.

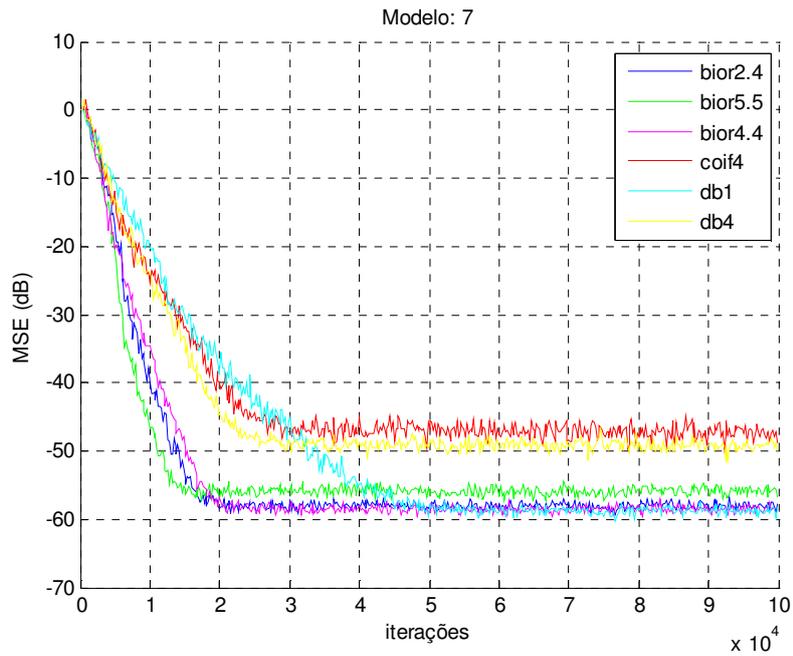


Figura 3.16. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 7.

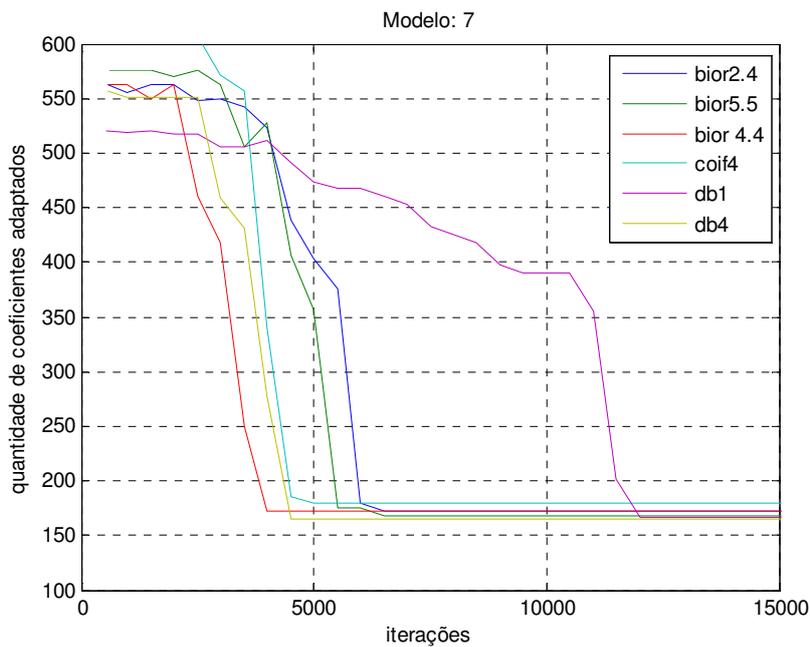


Figura 3.17. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 7.

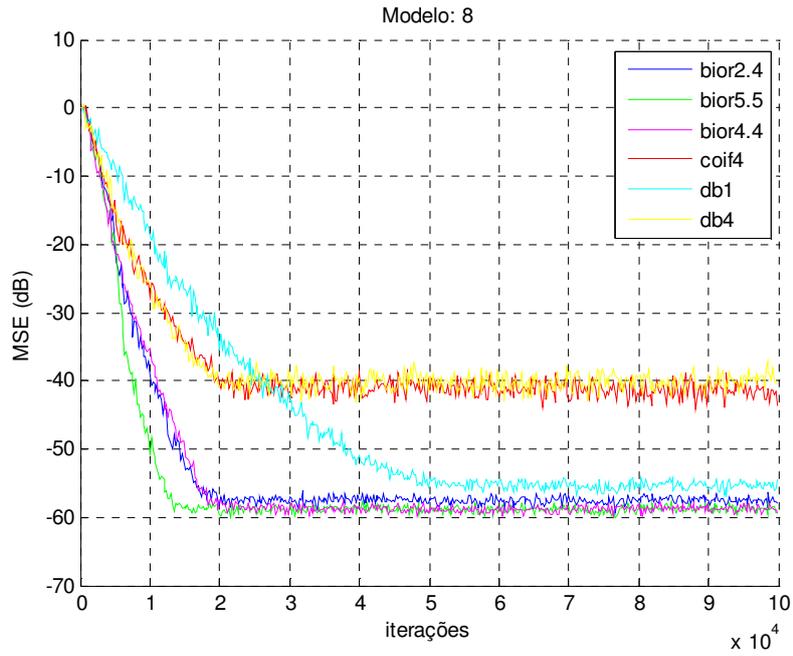


Figura 3.18. Evolução do MSE do algoritmo ESWB com diferentes wavelets para o modelo 8.

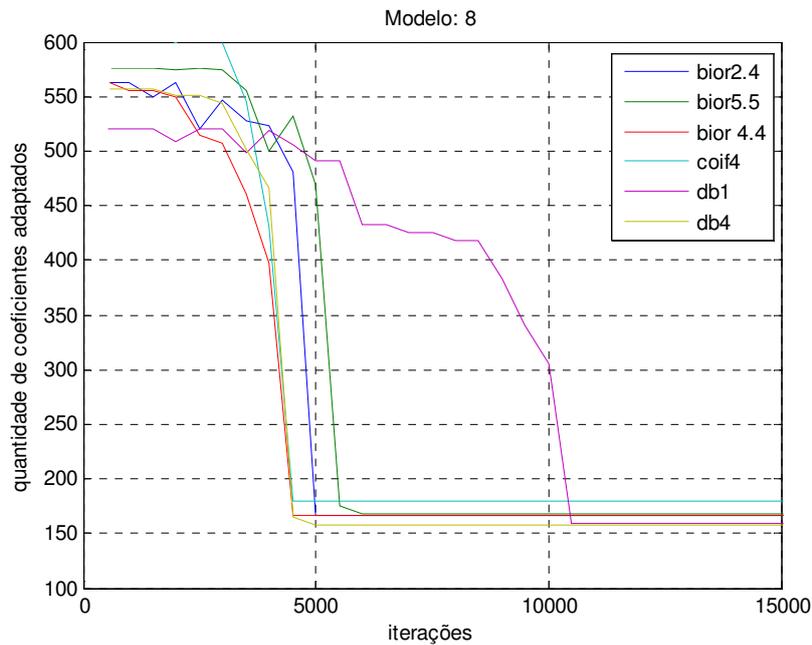


Figura 3.19. Evolução do número de coeficientes do algoritmo ESWB com diferentes wavelets para o modelo 8.

3.4.2. Comparação de desempenhos dos algoritmos ESWB, WB e WPB

Comparando os resultados obtidos com o algoritmo ESWB (mostrados na seção anterior) e com o algoritmo WB proposto em [18],[19] (mostrados na Fig. 8 da referência [27]), verifica-se uma maior robustez do algoritmo proposto, o qual não apresenta os problemas de convergência do algoritmo WB relatados em [27] e [29]. Observa-se também que a velocidade de convergência do algoritmo proposto utilizando wavelets com melhor seletividade do que a Haar (ou Daubechies 1) é significativamente maior do que as do algoritmo WB e do algoritmo WPB (*Wavelet-Packet-Based algorithm*) proposto em [27] e [29], que utilizaram a wavelet Haar. O número de coeficientes requerido pelo algoritmo proposto é, em média, maior do que os obtidos pelos algoritmos WB e WPB,. No entanto, o MSE em regime permanente obtido com o algoritmo proposto foi, em geral, menor do que os MSEs resultantes dos algoritmos WB e WPB. Por exemplo, para o modelo 1, os números de coeficientes adaptados nos algoritmos ESWB, WB e WPB foram em torno de 160, 130 e 100, respectivamente, de acordo com a Fig. 3.5 da seção anterior e com a Fig. 5 da referência [27]. Já os MSEs resultantes foram aproximadamente -60 dB, -48 dB e -50 dB para os algoritmos ESWB, WB e WPB, respectivamente, todos com a wavelet Haar.

3.5. Conclusões

Neste capítulo foi apresentado um algoritmo que utiliza a transformada wavelet para reduzir o número de coeficientes adaptativos e, deste modo, diminuir a complexidade do algoritmo, o que é bastante útil em situações onde uma resposta ao impulso longa e esparsa está sendo modelada. Neste sentido este algoritmo obteve bastante êxito. Para alcançar este objetivo a propriedade de boa localização temporal da transformada wavelet foi utilizada, a qual permite identificar a resposta ao impulso apenas nas regiões em que suas amostras são diferentes de zero, sem introduzir degradação significativa no desempenho do algoritmo. A propriedade de boa localização espectral, a qual provê uma decorrelação parcial do sinal de entrada, foi também utilizada, acelerando assim a velocidade de convergência do algoritmo adaptativo. Comparando os resultados das simulações realizadas neste trabalho com os apresentados em [27], observou-se que o algoritmo ESWB proposto teve um bom desempenho, no que tange à velocidade de convergência e ao erro médio quadrático em regime permanente, em geral superior aos dos algoritmos WB e WPB, mas com uma redução menor no número de coeficientes. O algoritmo proposto não apresentou os problemas de convergência do WB relatados em [27] e [29] nas simulações realizadas. Este melhor desempenho deve-se ao critério de seleção dos coeficientes ativos (baseado na energia da resposta impulsiva no canal de controle) e ao mapeamento da região da resposta do canal de controle com energia significativa em regiões nos demais canais (ao invés do mapeamento de cada coeficiente em pais e filhos).

Capítulo 4

Os Algoritmos WNLMS e WPNLMS

4.1. Introdução

Alguns dos algoritmos clássicos mais usados, tais como o NLMS (*Normalized Least Mean Square*) ou o RLS [1]-[3] (*Recursive Least Squares*), não levam em conta a esparsidade da resposta impulsiva característica de sistemas que aparecem em várias aplicações, tais como no cancelamento de ecos acústicos e em linhas digitais. É fácil perceber que há margem para melhoria do desempenho dos algoritmos convencionais, se o sistema a ser identificado tiver resposta impulsiva esparsa.

Uma das primeiras tentativas de explorar esta característica foi feita por Duttweiler em [22] no contexto de cancelamento de eco acústico envolvendo um transformador híbrido em conjunto com um atraso de rede variável, onde a resposta ao impulso era claramente esparsa. Neste trabalho foi proposto o algoritmo PNLMS (*Proportionate NLMS*), que possui uma convergência inicial acelerada e é capaz de rastrear mudanças no sistema desconhecido muito mais rapidamente que o algoritmo

NLMS quando a resposta ao impulso que se deseja identificar é esparsa. A idéia básica que norteia o PNLMS é utilizar diferentes passos de atualização para os diferentes coeficientes baseados em suas magnitudes [22],[30].

No entanto, o PNLMS tem um problema, em que após a convergência inicial rápida (coeficientes grandes), os coeficientes restantes adaptam mais lentamente que no NLMS. Alguns algoritmos foram propostos para solucionar ou, pelo menos, minimizar este problema, como o algoritmo PNLMS++ [30], o qual nada mais é do que a alternância entre o PNLMS e o NLMS.

Apesar das melhorias obtidas, uma característica importante destes algoritmos permanece: eles têm desempenho satisfatório quando o sinal de entrada se assemelha a um ruído branco, mas quando o sinal de entrada é um ruído colorido a velocidade da convergência cai drasticamente. Este tipo de sinal de entrada é comum em várias aplicações, e, por exemplo, quando o sinal de entrada é a voz humana estes algoritmos apresentam baixa velocidade de convergência.

A linha adotada neste trabalho para solucionar este problema foi a inclusão de uma transformação, utilizando wavelet, sobre o sinal de entrada, deste modo dando ao algoritmo adaptativo um sinal mais fácil de ser tratado. Uma das vantagens desta abordagem é a de que sempre que surgir um algoritmo adaptativo melhor para ruído branco, ele pode ser utilizado como algoritmo “pós-wavelet”.

Neste trabalho investigamos dois novos algoritmos baseados na transformada wavelet (um inspirado no NLMS e outro no PNLMS) e observamos seus desempenhos com diferentes wavelets, comparando-os com os desempenhos dos algoritmos que não utilizam a wavelet.

4.2. Os Algoritmos NLMS e PNLMS

O algoritmo NLMS é uma melhoria do algoritmo LMS, pois uma vez que a atualização do algoritmo é diretamente proporcional ao vetor de entrada $\mathbf{x}(k)$, ocorre que quando algum elemento de $\mathbf{x}(k)$ é grande, o ajuste feito pelo algoritmo no coeficiente correspondente também é grande. Devido a este fato, o algoritmo LMS sofre de um problema de amplificação de ruído do gradiente. Para solucionar este problema, o NLMS (*Normalized LMS*) aplica uma normalização (no sentido da norma-2 euclidiana do vetor $\mathbf{x}(k)$) no ajuste do vetor de coeficientes [1]-[3].

Um resumo do algoritmo NLMS é dado na Tabela 4.1.

Tabela 4.1. Algoritmo NLMS

$$\begin{aligned}\mathbf{x}(k) &= [x(k) \quad x(k-1) \quad \dots \quad x(k-L+1)]^T \\ \hat{y}(k) &= \mathbf{x}^T(k) \hat{\mathbf{w}}(k) \\ e(k) &= d(k) - \hat{y}(k) \\ \hat{\mathbf{w}}(k+1) &= \hat{\mathbf{w}}(k) + \frac{\beta \mathbf{x}(k) e(k)}{\mathbf{x}^T(k) \mathbf{x}(k) + \delta}\end{aligned}$$

Na Tabela 4.1 deve-se observar que $x(k)$ é o sinal de entrada que excita o sistema desconhecido e $\hat{\mathbf{w}}(k)$ é o vetor dos coeficientes do filtro adaptativo. Além disso, seja $y(k)$ a saída do sistema desconhecido e $v(k)$ a medida do ruído. A observação ou sinal desejado $d(k)$ é a soma de $y(k)$ e $v(k)$. $\hat{y}(k)$ é a saída estimada (saída do filtro adaptativo). O sinal do erro $e(k)$ entre a saída do filtro adaptativo $\hat{y}(k)$ e $d(k)$ é o que controla o algoritmo adaptativo. β é o passo do algoritmo e δ um número positivo pequeno usado para se evitar divisão por zero (ou um *overflow* no algoritmo computacional).

Um dos algoritmos desenvolvidos neste capítulo é inspirado numa ligeira variação do PNLMS (*Proportionate Normalized Least Mean Square*), por isto será feita uma breve introdução deste algoritmo para em seguida explicarmos o algoritmo proposto.

Em comparação com o NLMS clássico [1]-[4], o PNLMS tem convergência inicial extremamente rápida e boa performance de rastreamento quando o caminho do eco é esparso. A principal idéia do PNLMS [22] é assumir diferentes passos de atualização para diferentes coeficientes baseado em suas magnitudes. Magnitudes maiores dos coeficientes corresponderão a passos maiores, magnitudes menores a passos menores.

No entanto o PNLMS possui algumas desvantagens. Após uma convergência inicial rápida sobre os coeficientes grandes, os coeficientes pequenos restantes adaptam a uma taxa mais lenta que o NLMS. Isto ocorre porque apesar de restarem apenas coeficientes pequenos, o erro continua grande e o desempenho do algoritmo fica degradado. O algoritmo PNLMS++ [30] melhora a convergência do PNLMS, mas não soluciona o problema, uma vez que o que ele faz é simplesmente alternar entre o PNLMS e o NLMS.

O algoritmo de PNLMS é especificado na Tabela 4.2 [22], onde L é o comprimento do filtro adaptativo, β é o passo, e δ é um número positivo pequeno usado para se evitar divisão por zero (ou um *overflow* no algoritmo computacional). A constante δ_p é importante quando todos os coeficientes são nulos (por exemplo, no início da adaptação). Note que $\sum_{l=1}^L g_l(k) = L$, e que o valor de $g_l(k)$ é dependente da estimativa atual dos coeficientes, exceto no começo, quando cuidados especiais devem ser tomados com coeficientes aproximadamente zero ou coeficientes extremamente pequenos.

Tabela 4.2. Algoritmo PNLMS

$$\begin{aligned}
 \mathbf{x}(k) &= [x(k) \quad x(k-1) \quad \dots \quad x(k-L+1)]^T \\
 \hat{y}(k) &= \mathbf{x}^T(k) \hat{\mathbf{w}}(k) \\
 e(k) &= d(k) - \hat{y}(k) \\
 \gamma_{\min}(k+1) &= \rho \max \{ \delta_p, |\hat{w}_1(k)|, \dots, |\hat{w}_L(k)| \} \\
 \gamma_l(k+1) &= \max \{ \gamma_{\min}(k+1), |\hat{w}_l(k)| \} \\
 g_l(k+1) &= \frac{\gamma_l(k+1)}{\frac{1}{L} \sum_{i=1}^L \gamma_i(k+1)}, \quad 1 \leq l \leq L \\
 \Gamma(k+1) &= \text{diag} \{ g_1(k+1), \dots, g_L(k+1) \} \\
 \hat{\mathbf{w}}(k+1) &= \hat{\mathbf{w}}(k) + \frac{\beta \Gamma(k+1) \mathbf{x}(k) e(k)}{\mathbf{x}^T(k) \Gamma(k+1) \mathbf{x}(k) + \delta}
 \end{aligned}$$

4.3. Algoritmos Propostos: WNLMS e WPNLMS

A idéia de ambos os algoritmos é incrementar o desempenho do NLMS e o do PNLMS usando a transformada wavelet de acordo com a estrutura descrita no Capítulo 2 e mostrada na Fig. 2.3.

Deve-se observar nesta estrutura que não se tem o sinal $x(k)$ entrando diretamente no filtro adaptativo, mas, ao invés disto, tem-se o sinal de entrada passando por um banco de filtros ($H_m(z)$), que implementa a wavelet desejada, e as saídas destes bancos de filtro entram nos respectivos filtros adaptativos ($G_m(z^{L_m})$).

Sendo $h_i(k)$ a resposta impulsiva do filtro $H_i(z)$, e definindo Φ_k um operador que executa a decimação do parâmetro por um fator k , tem-se que as entradas dos filtros adaptativos serão $\mathbf{z}_i(k) = \Phi_k[\mathbf{h}_{L_i}(k) * \mathbf{x}(k)]$, para $i = 0, 1, \dots, M-1$. A partir destas

definições e sendo $\hat{\mathbf{w}}_i(k)$ o vetor contendo os coeficientes dos filtros esparsos $G_i(z^{L_i})$, pode-se propor o algoritmo WNLMS como na Tabela 4.4 a seguir.

Tabela 4.4. Algoritmo WNLMS

$$\begin{aligned} \mathbf{x}(k) &= [x(k) \quad x(k-1) \quad \dots \quad x(k-L+1)]^T \\ \mathbf{z}_i(k) &= \Phi_{L_i}[\mathbf{h}_i(k) * \mathbf{x}(k)], \quad i = 0, 1, \dots, M-1 \\ \hat{y}_i(k) &= \mathbf{z}_i^T(k) \hat{\mathbf{w}}_i(k), \quad i = 0, 1, \dots, M-1 \\ \hat{y}(k) &= \sum_{i=0}^{M-1} \hat{y}_i(k) \\ e(k) &= d(k-\Delta) - \hat{y}(k) \\ \hat{\mathbf{w}}_i(k+1) &= \hat{\mathbf{w}}_i(k) + \frac{\beta \mathbf{z}_i(k) e(k)}{\mathbf{z}_i^T(k) \mathbf{z}_i(k) + \delta}, \quad i = 0, 1, \dots, M-1 \end{aligned}$$

Utilizando as mesmas definições acima e lembrando que K_i é o número de coeficientes não nulos do i -ésimo subfiltro, pode-se propor o algoritmo WPNLMS como o resumido na Tabela 4.5. Notar que $\sum_{l=1}^{K_i} g_{i,l}(k) = k_i$.

Tabela 4.5. Algoritmo WPNLMS

$$\begin{aligned}
 \mathbf{x}(k) &= [x(k) \quad x(k-1) \quad \dots \quad x(k-L+1)]^T \\
 \mathbf{z}_i(k) &= \Phi_{L_i}(\mathbf{h}_i(k) * \mathbf{x}(k)), i = 0, 1, \dots, M-1 \\
 \hat{y}_i(k) &= \mathbf{z}_i^T(k) \hat{\mathbf{w}}_i(k), \quad i = 0, 1, \dots, M-1 \\
 \hat{y}(k) &= \sum_{i=0}^{M-1} \hat{y}_i(k) \\
 e(k) &= d(k-\Delta) - \hat{y}(k) \\
 \gamma_{\min,i}(k+1) &= \rho \max \{ \delta_p, |\hat{w}_{i,1}(k)|, \dots, |\hat{w}_{i,K_i}(k)| \} \\
 \gamma_{i,l}(k+1) &= \max \{ \gamma_{\min,i}(k+1), |\hat{w}_{i,l}(k)| \} \\
 g_{i,l}(k+1) &= \frac{\gamma_{i,l}(k+1)}{\frac{1}{K_i} \sum_{j=1}^{K_i} \gamma_{i,j}(k+1)}, \quad 1 \leq l \leq K_i \\
 \Gamma_i(k+1) &= \text{diag} \{ g_{i,1}(k+1), \dots, g_{i,K_i}(k+1) \} \\
 \hat{\mathbf{w}}_i(k+1) &= \hat{\mathbf{w}}_i(k) + \frac{\beta \Gamma_i(k+1) \mathbf{z}_i(k) e(k)}{\mathbf{z}_i^T(k) \Gamma_i(k+1) \mathbf{z}_i(k) + \delta}, \quad i = 0, 1, \dots, M-1
 \end{aligned}$$

4.4. Resultados Experimentais

Para demonstrar experimentalmente a eficácia dos algoritmos investigados neste capítulo realizamos um conjunto de simulações utilizando os modelos da ITU-T G.168 descritos no Capítulo 2. Nas simulações utilizamos o mesmo sinal de entrada das simulações do Capítulo 3, obtido passando-se um ruído branco gaussiano de média zero e variância unitária pelo filtro com a seguinte função de transferência:

$$H(z) = \frac{0,25\sqrt{3}}{1 - 1,5z^{-1} + z^{-2} - 0,25z^{-3}} \quad (4.1)$$

cujo resultado é um sinal aleatório com espectro semelhante ao da voz humana. Para o passo fixo dos algoritmos utilizou-se o valor $\beta = 0,2$. Para os parâmetro ρ , δ e δ_p usou-se o valor 0,01. Os valores dos parâmetros acima foram os mesmos utilizados em [22],[30],[31]. Além disso, adicionou-se um ruído branco gaussiano de potência -60 dB ao sinal desejado. Nos algoritmos WNLMS e WPNLMS foram empregadas as wavelets Biortogonais 2.4, 4.4 e 5.5, Daubechies 1 e 4, e Coiflet 4, conforme discutido no Capítulo 2, usando 3 níveis de decomposição.

A seguir serão mostrados os desempenhos dos algoritmos NLMS, PNLMS, WNLMS e WPNLMS para os 8 modelos da recomendação ITU-T G.168.

4.4.1. Desempenho do algoritmo WNLMS com diferentes wavelets

As Figs. 4.1 a 4.8 mostram a evolução do erro médio quadrático (em dB) do algoritmo WNLMS com as diversas wavelets para cada um dos 8 modelos. Destas figuras podemos observar que o algoritmo WNLMS apresenta velocidade de convergência significativamente mais rápida do que a do algoritmo NLMS com todas as wavelets testadas. Já o algoritmo PNLMS apresenta uma convergência inicial mais rápida do que o WNLMS, mas esta torna-se bem mais lenta para um MSE entre -10 e -20 dB.

Comparando o desempenho do algoritmo WNLMS com as diferentes wavelets, observa-se que a wavelet Daubechies 1 apresenta a pior taxa de convergência para todos os modelos, o que já era esperado devido a simplicidade (e conseqüente baixa

seletividade) desta transformada. As wavelets Biortogonais 4.4 e 5.5 foram as que apresentaram a melhor velocidade de convergência para todos os modelos. A wavelet Coiflet 4 teve desempenho inferior aos das demais wavelets, exceto ao da Daubechies 1, para todos os modelos.

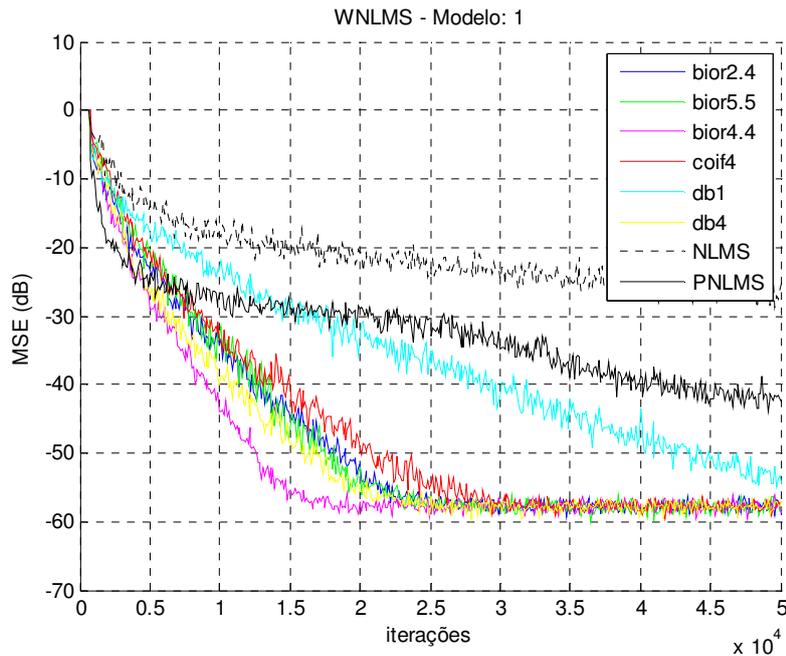


Figura 4.1. Desempenho do algoritmo WNLMS para o modelo 1.

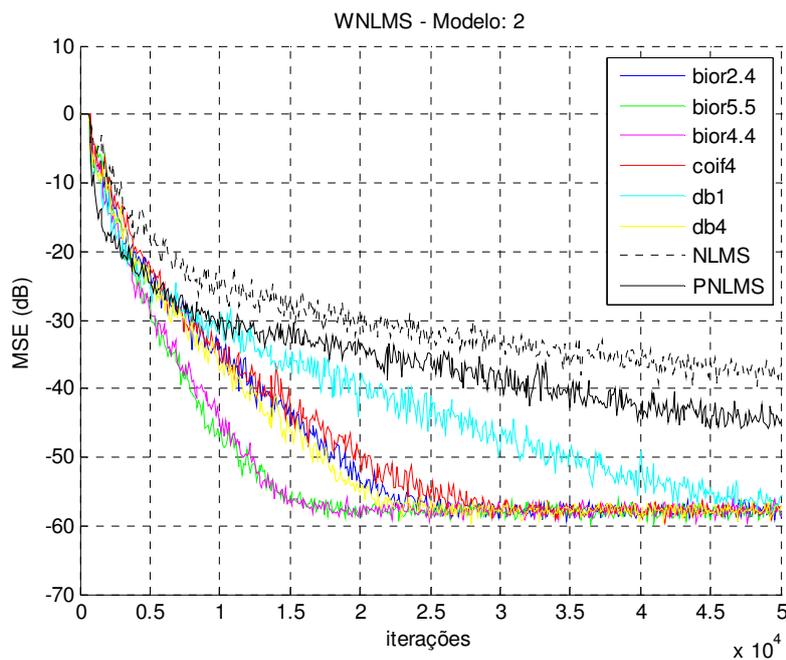


Figura 4.2. Desempenho do algoritmo WNLMS para o modelo 2.

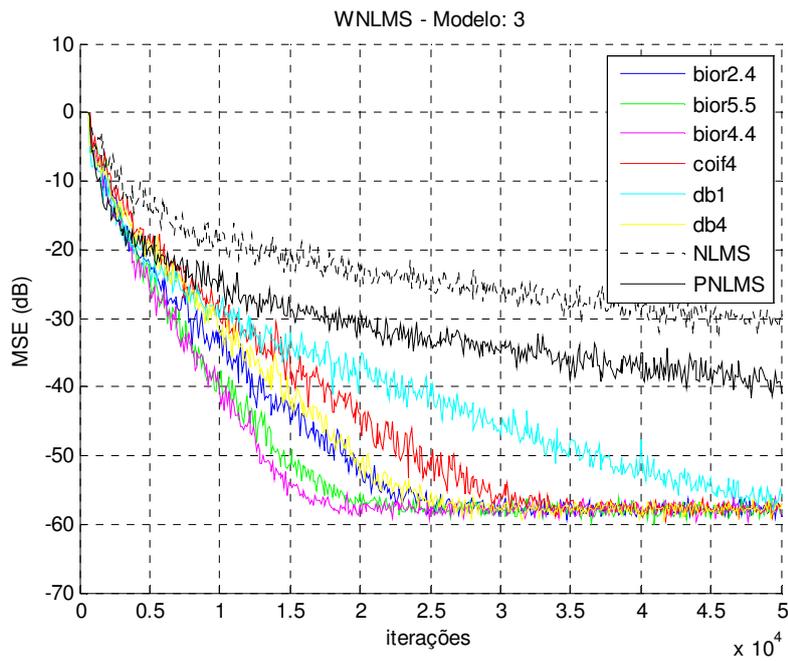


Figura 4.3. Desempenho do algoritmo WNLMS para o modelo 3.

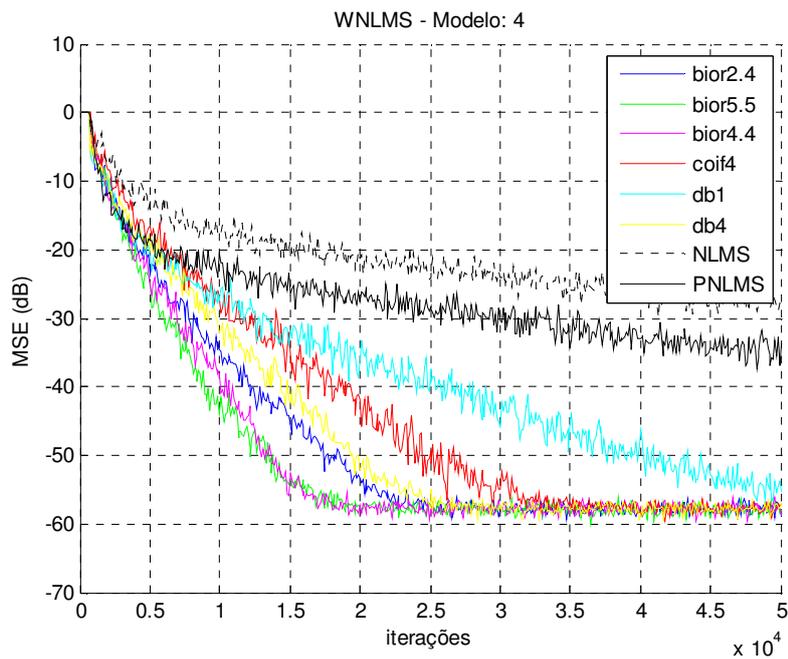


Figura 4.4. Desempenho do algoritmo WNLMS para o modelo 4.

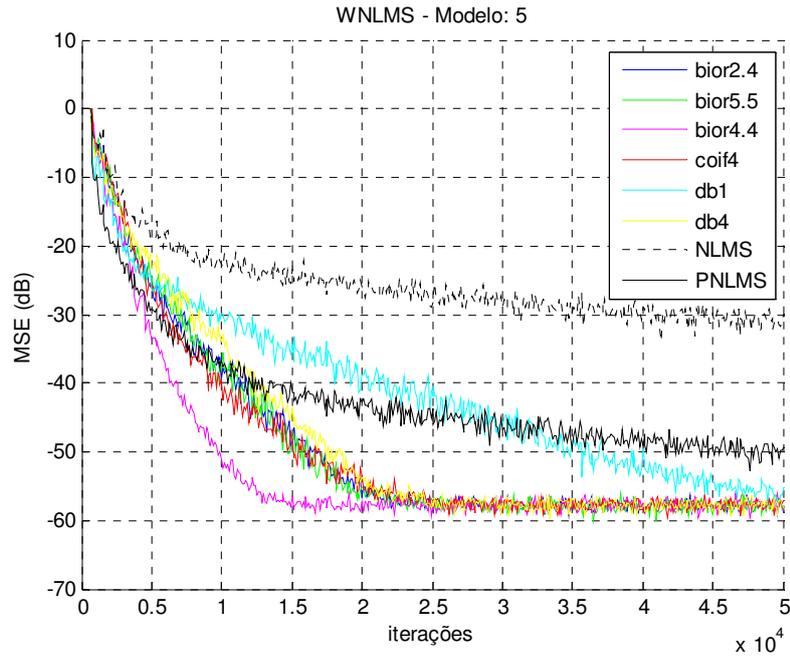


Figura 4.5. Desempenho do algoritmo WNLMS para o modelo 5.

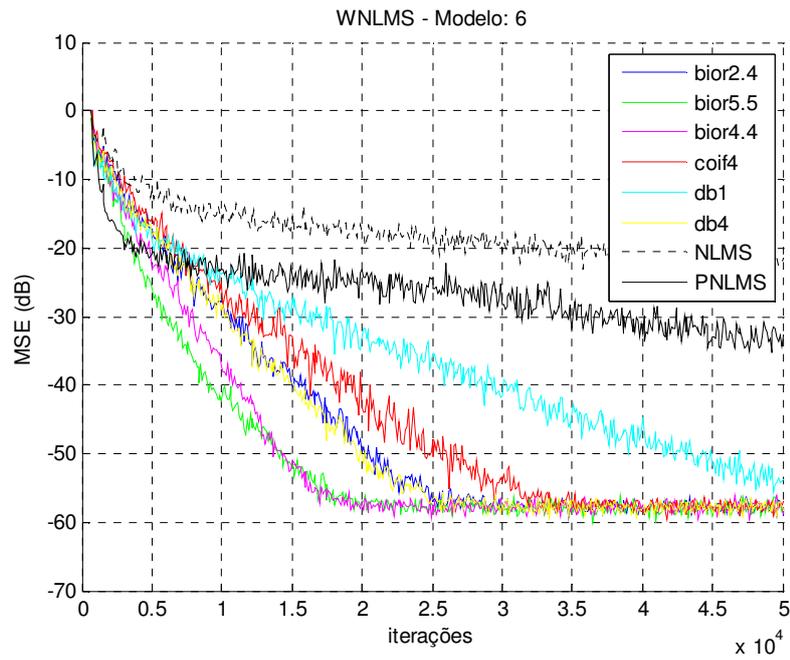


Figura 4.6. Desempenho do algoritmo WNLMS para o modelo 6.

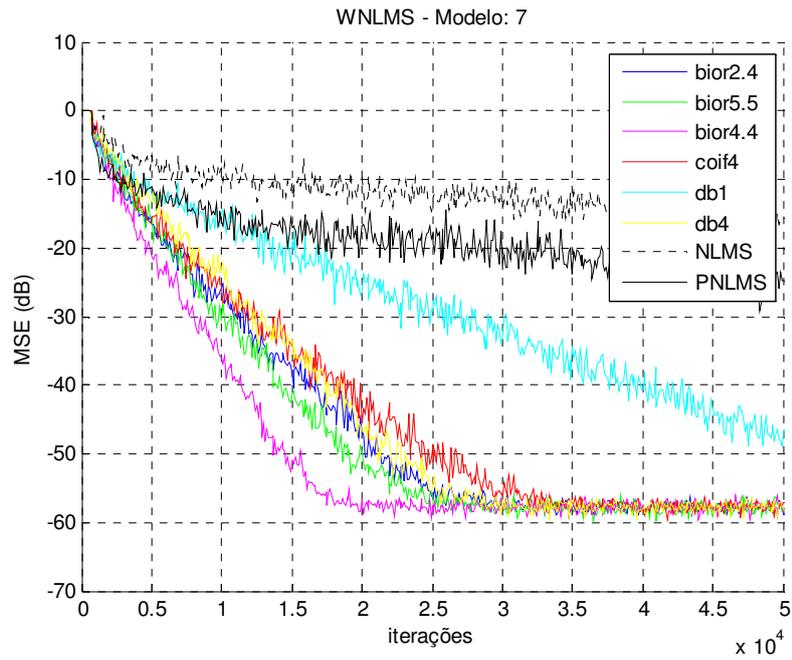


Figura 4.7. Desempenho do algoritmo WNLMS para o modelo 7.

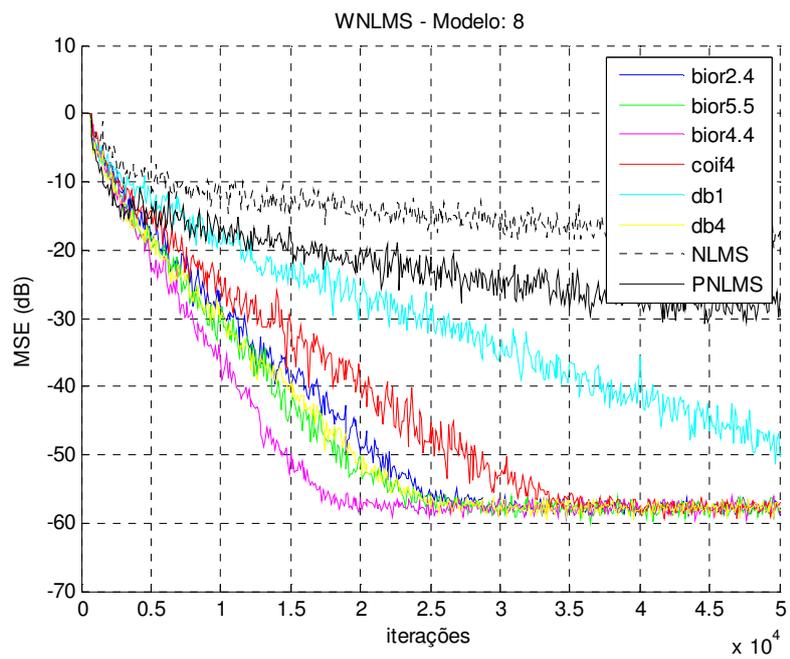


Figura 4.8. Desempenho do algoritmo WNLMS para o modelo 8.

4.4.2. Desempenho do algoritmo WPNLMS com diferentes wavelets

As Figs. 4.9 a 4.16 mostram a evolução do erro médio quadrático (em dB) do algoritmo WPNLMS com as diversas wavelets para os 8 modelos. Destas figuras podemos observar que o algoritmo WPNLMS apresenta velocidade de convergência significativamente mais rápida do que as dos algoritmos NLMS e PNLMS com todas as wavelets testadas. A degradação da velocidade de convergência observada no algoritmo PNLMS não ocorre no algoritmo WPNLMS. Principalmente para os modelos 3, 4, 6, 7 e 8, para os quais a convergência do algoritmo PNLMS era significativamente degradada a partir de -10 dB, o uso do algoritmo WPNLMS acelera muito a velocidade da adaptação. Mesmo para os outros modelos, consegue-se atingir um MSE bem menor em um número reduzido de iterações.

Comparando o desempenho do algoritmo WPNLMS com as diferentes wavelets, observa-se que apesar da transformada Daubechies 1 continuar tendo o pior desempenho, a sua convergência foi significativamente acelerada em relação a do algoritmo WNLMS com esta mesma transformada. O desempenho do algoritmo WPNLMS com as demais wavelets, inclusive com a Coiflet 4, não variou muito para todos os modelos, mostrando a baixa sensibilidade deste algoritmo à função wavelet utilizada.

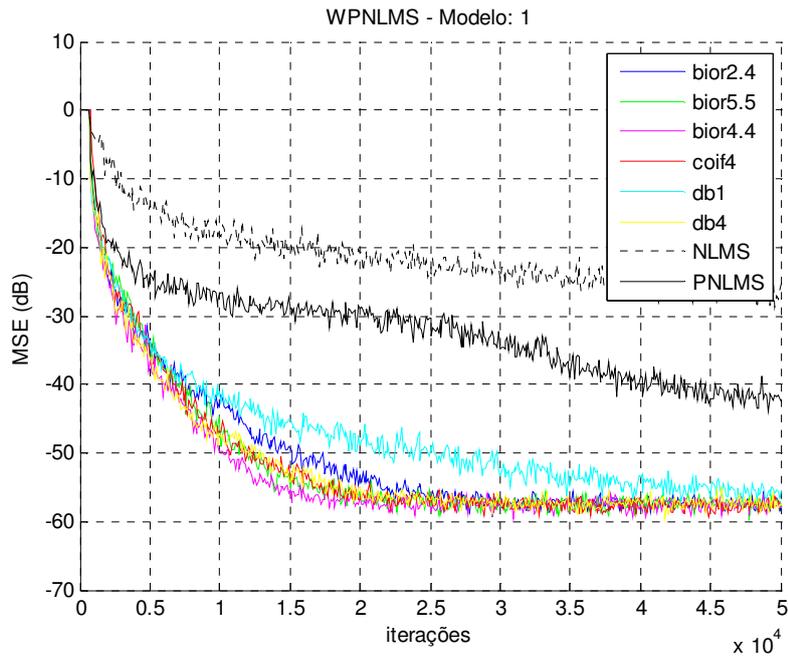


Figura 4.9. Desempenho do algoritmo WPNLMS para o modelo 1.

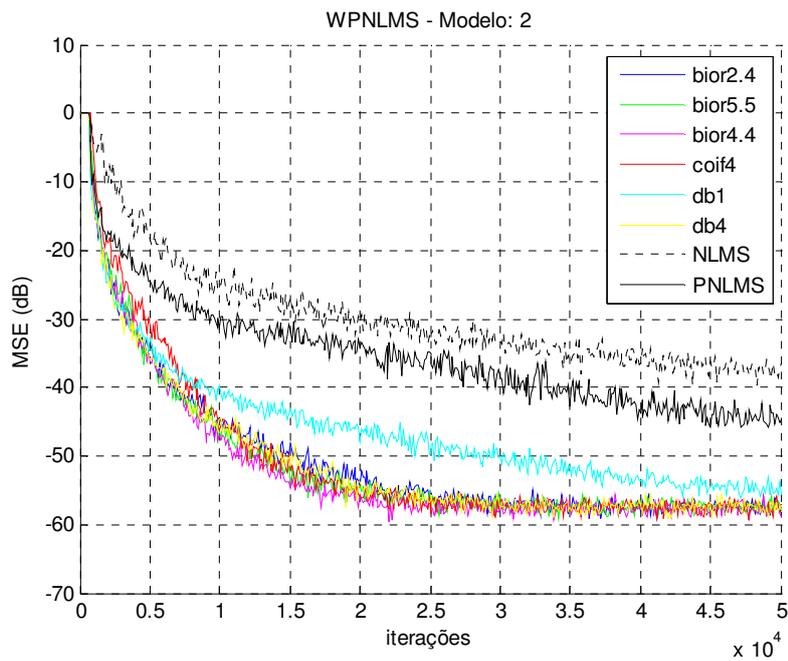


Figura 4.10. Desempenho do algoritmo WPNLMS para o modelo 2.

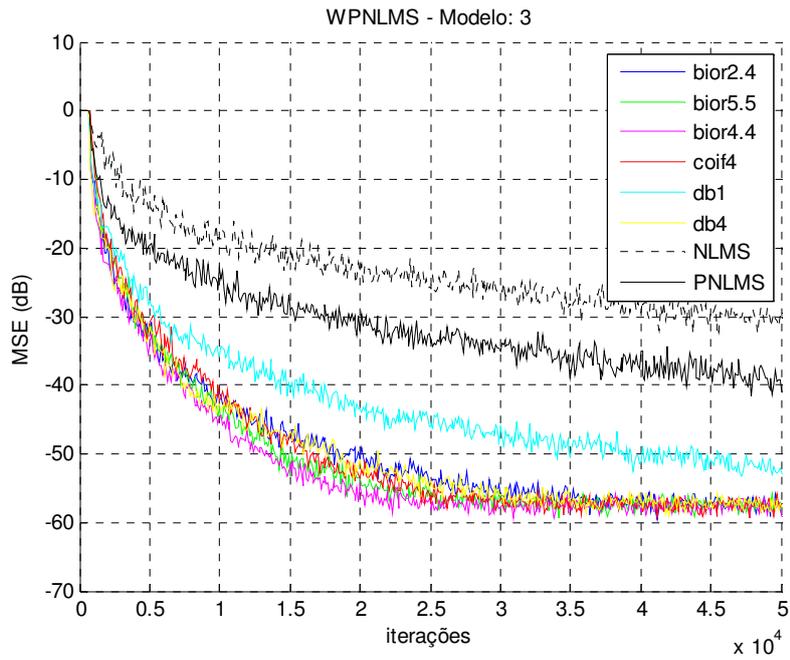


Figura 4.11. Desempenho do algoritmo WPNLMS para o modelo 3.

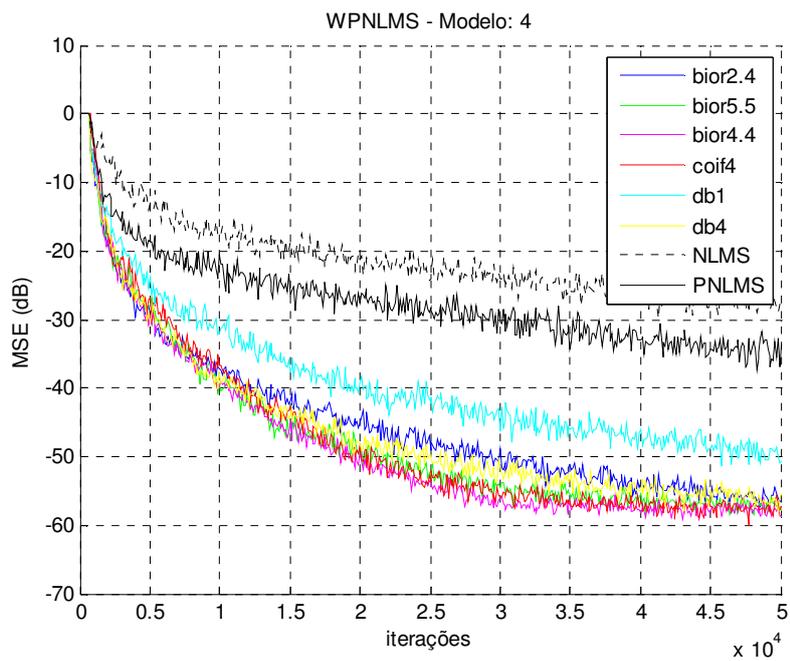


Figura 4.12. Desempenho do algoritmo WPNLMS para o modelo 4.

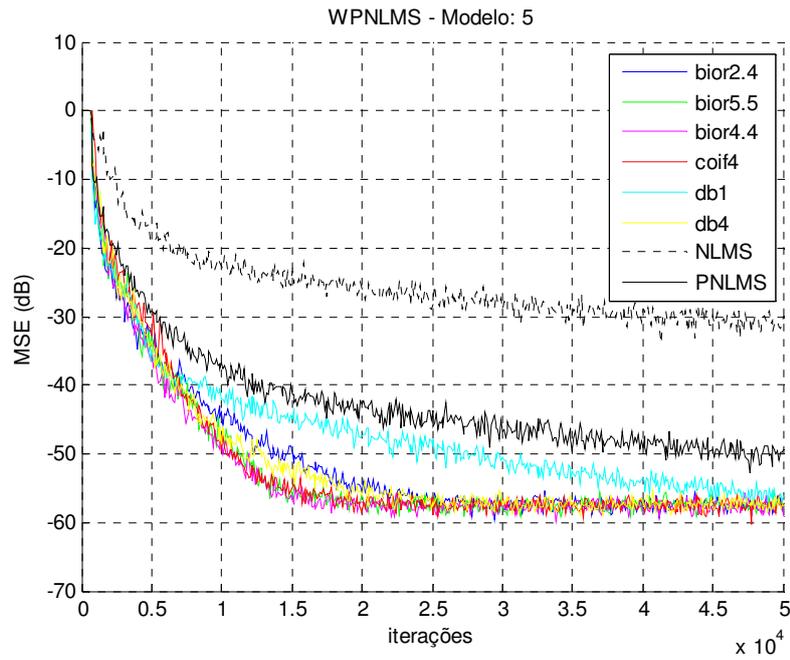


Figura 4.13. Desempenho do algoritmo WPNLMS para o modelo 5.

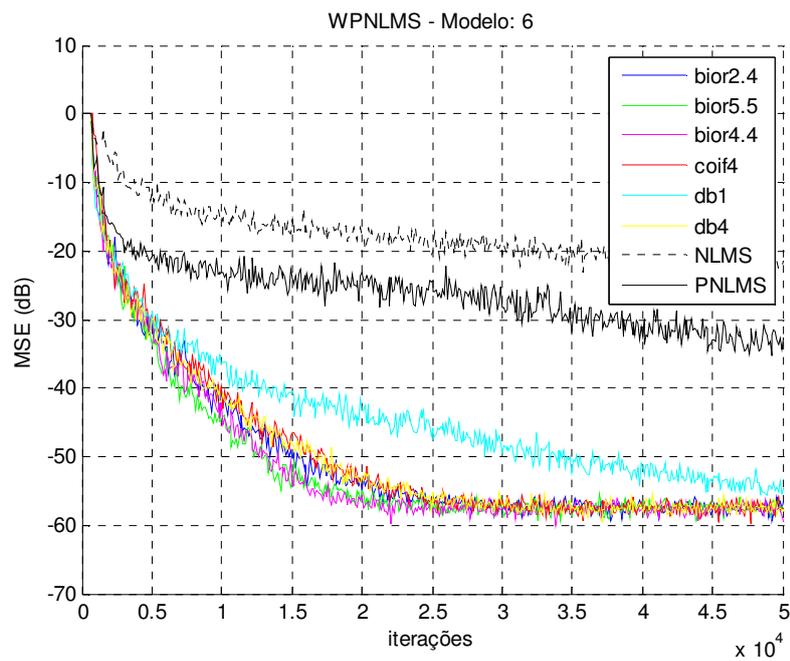


Figura 4.14. Desempenho do algoritmo WPNLMS para o modelo 6.

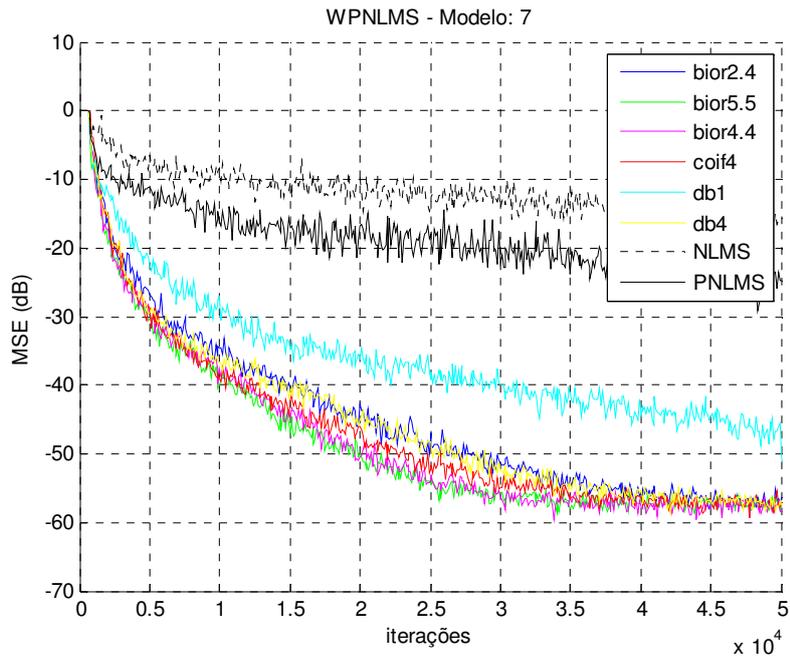


Figura 4.15. Desempenho do algoritmo WPNLMS para o modelo 7.

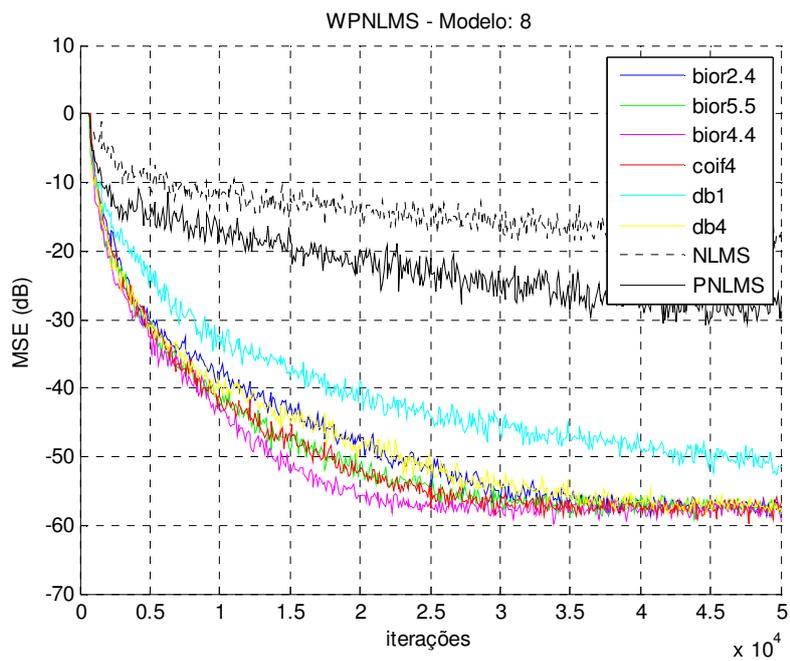


Figura 4.16. Desempenho do algoritmo WPNLMS para o modelo 8.

4.4.3. Comparação entre os algoritmos WNLMS e WPNLMS

Para comparar os desempenhos dos algoritmos WNLMS e WPNLMS foram geradas as Figs. 4.17 a 4.22 com as evoluções dos erros médios quadráticos destes algoritmos para o modelo 1 empregando cada uma das wavelets selecionadas. Incluímos também os MSEs dos algoritmos NLMS e PNLMS nestes gráficos. Para os demais modelos, os desempenhos comparativos foram semelhantes. Destas figuras, observa-se que a convergência foi significativamente acelerada em relação ao algoritmo WNLMS, principalmente nas iterações iniciais. O desempenho do algoritmo WPNLMS é significativamente melhor do que o do WNLMS principalmente para as wavelets Daubechies 1 e Coiflet 4.

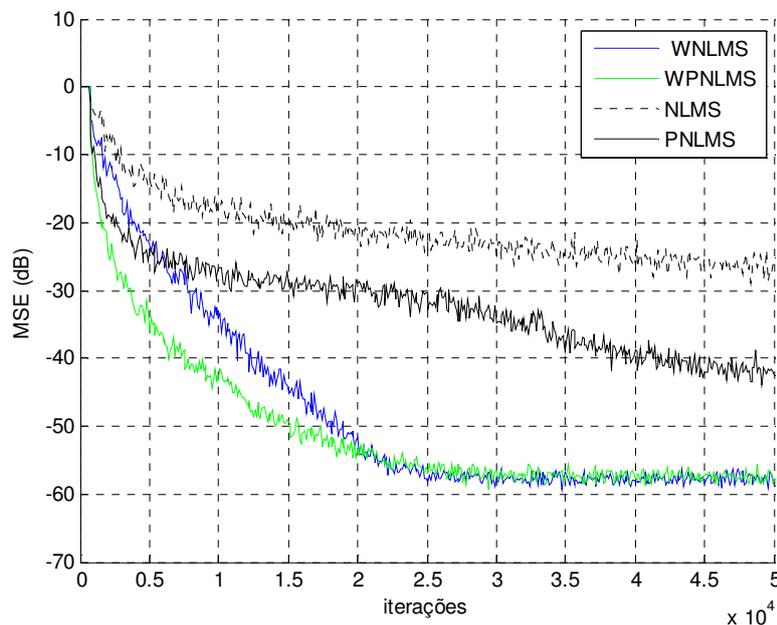


Figura 4.17. Comparação entre o desempenho do WPNLMS e da WNLMS com a wavelet Biortogonal 2.4 para o modelo 1.

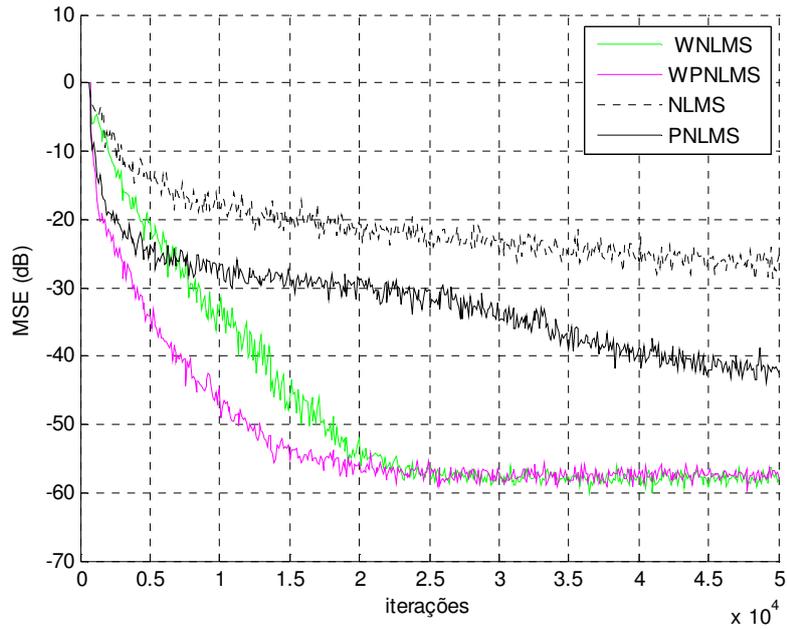


Figura 4.18. Comparação entre o desempenho do WPNLMS e da WNLMS com a wavelet Biortogonal 5.5 para o modelo 1.

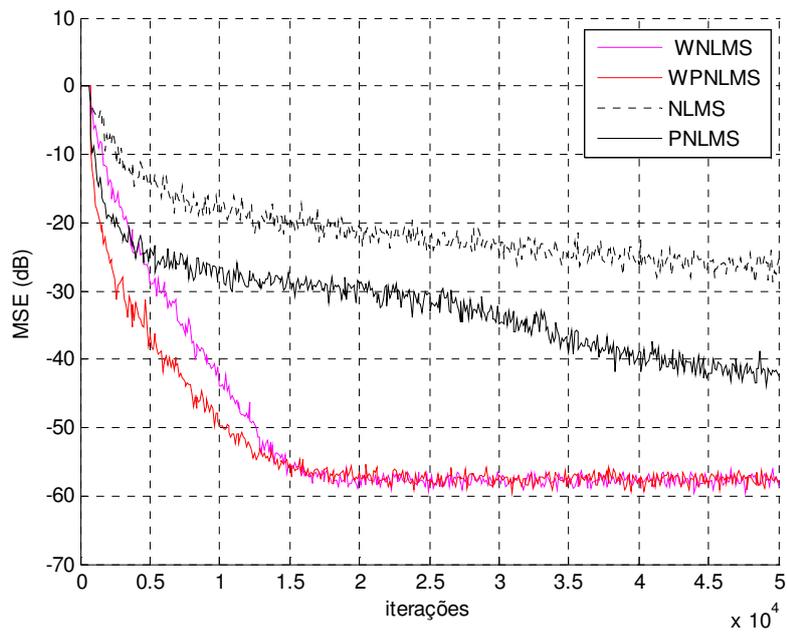


Figura 4.19. Comparação entre o desempenho do WPNLMS e da WNLMS com a wavelet Biortogonal 4.4 para o modelo 1.

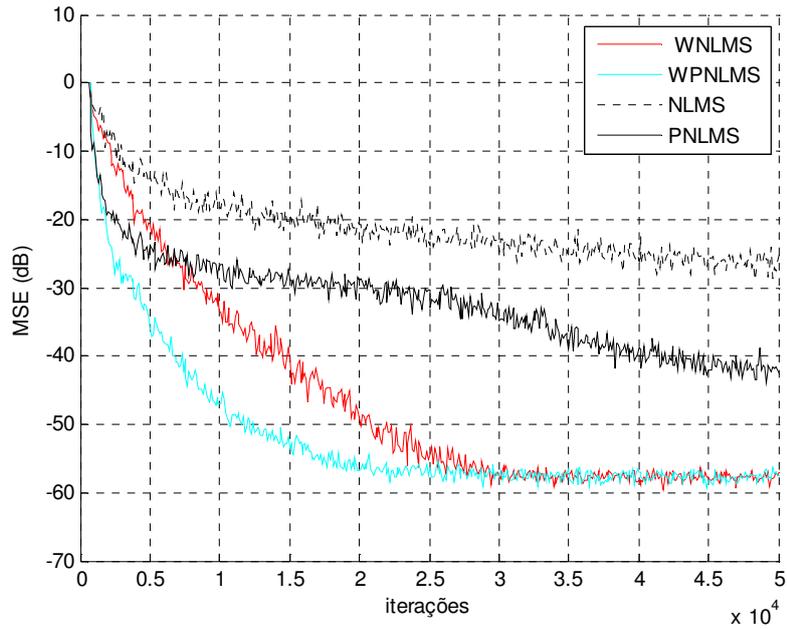


Figura 4.20. Comparação entre o desempenho do WPNLMS e da WNLMS com a wavelet Coiflet 4 para o modelo 1.

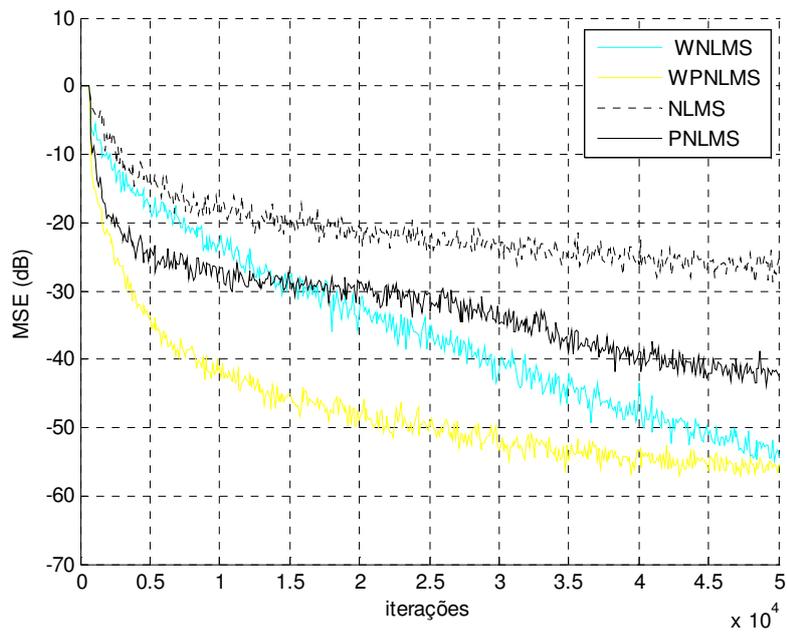


Figura 4.21. Comparação entre o desempenho do WPNLMS e da WNLMS com a wavelet Daubechies 1 para o modelo 1.

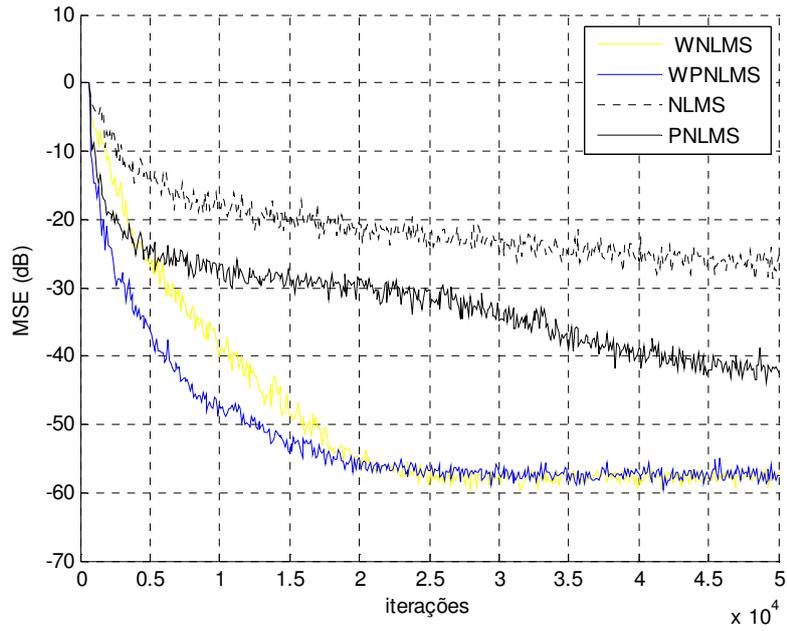


Figura 4.22. Comparação entre o desempenho do WPNLMS e da WNLMS com a wavelet Daubechies 4 para o modelo 1.

4.5. Conclusões

Neste capítulo foram apresentados novos algoritmos adaptativos que utilizam a transformada wavelet a fim de melhorar a convergência quando o sistema a ser modelado é esparso e a entrada é um ruído colorido. Nas simulações, onde foi utilizado um sinal de entrada com características semelhantes à voz humana, os algoritmos propostos obtiveram excelentes resultados, acelerando significativamente a velocidade de convergência em relação às suas versões que não utilizam a transformada wavelet. Nestes algoritmos, assim como no algoritmo do Capítulo 3, a propriedade de boa localização espectral das wavelets foi fundamental, pois deste modo foi possível descorrelacionar parcialmente a entrada de modo a acelerar a convergência.

Apesar de inicialmente este trabalho ter desenvolvido um algoritmo inspirado no PNLMS [22] (o qual foi chamado de WPNLMS), verificou-se ao longo dos testes que a melhoria feita no algoritmo PNLMS poderia também ser feita diretamente no algoritmo NLMS, o qual deu origem ao algoritmo chamado de WNLMS. Foi visto que na comparação entre os algoritmos NLMS, PNLMS, WNLMS e WPNLMS, o WPNLMS obtém os melhores resultados nos exemplos aqui incluídos no que tange à velocidade de convergência. No entanto, observa-se que o poder da estrutura com wavelets é tal que o WNLMS consegue convergir mais rápido que algoritmos publicados recentemente na literatura, como é o caso do PNLMS.

Capítulo 5

Conclusões

5.1. Conclusões gerais

Neste trabalho foram apresentados novos algoritmos de filtragem adaptativa para identificação de sistemas com respostas impulsivas esparsas. Os algoritmos propostos nesta dissertação fazem uso da propriedade da boa resolução tempo x frequência da transformada wavelet para acelerar a convergência de adaptação e reduzir a complexidade computacional dos algoritmos convencionais.

No Capítulo 2 foi apresentada a estrutura adaptativa utilizada nos algoritmos desenvolvidos neste trabalho, composta de uma transformada wavelet e de filtros adaptativos esparsos, e foi investigada a sua capacidade de compactação da informação “significativa” das respostas impulsivas de modelos de canais de linhas telefônicas descritos na Recomendação ITU-T G.168 [26] para diferentes wavelets.

No Capítulo 3 foi apresentado um algoritmo que utiliza a estrutura wavelet e a hierarquia temporal dos coeficientes nas diferentes escalas da transformada para fazer a

seleção de um número reduzido de coeficientes a serem adaptados e, deste modo, diminuir a complexidade do algoritmo, o que é bastante útil na identificação de sistemas com respostas impulsivas esparsas. Para alcançar este objetivo a propriedade de localização temporal é utilizada para identificar na resposta impulsiva as regiões em que esta é diferente de zero. A boa localização espectral da wavelet, a qual provê uma decorrelação parcial do sinal de entrada, é também explorada, resultando em um algoritmo com convergência acelerada, denominado de ESWB. Nas simulações realizadas neste trabalho, o algoritmo proposto apresentou um desempenho, no que tange à velocidade de convergência e ao erro médio quadrático em regime permanente, superior ao dos algoritmos WB e WPB propostos em [17] e [27], com uma redução menor no número de coeficientes. Observou-se também que o algoritmo ESWB não apresentou os problemas de convergência do algoritmo WB, relatadas em [27].

No Capítulo 4 foram apresentados dois novos métodos que utilizam a estrutura wavelet descrita no Capítulo 2 e algoritmos do tipo NLMS e PNLMS, a fim de melhorar a taxa de convergência quando usados na identificação de sistemas esparsos, sem buscar reduzir o número de coeficientes. Os algoritmos resultantes, chamados de WNLMS e WPNLMS, obtiveram excelentes resultados, acelerando significativamente a velocidade de convergência das suas versões sem a transformada wavelet. Em particular, o algoritmo WPNLMS, que utiliza um passo de adaptação proporcional ao valor de cada coeficiente, mostrou-se especialmente apropriado para a identificação de sistemas com respostas impulsivas esparsas, devido à sua rápida convergência.

5.2. Sugestões de trabalhos futuros

Em relação ao algoritmo que visa à redução do número de coeficientes apresentado no Capítulo 3, alguns tópicos a serem investigados são a extensão do método para respostas impulsivas esparsas contidas em mais de uma região e a seleção do canal da transformada mais adequado para ser usada como canal de controle. Na primeira linha de pesquisa, sugerimos a modificação do critério de seleção dos coeficientes, incorporando a este uma análise da energia de blocos de coeficientes para fazer uma pré-seleção das regiões de interesse. Na segunda linha de pesquisa, sugerimos a incorporação da idéia de seleção da melhor decomposição wavelet (ou pacote wavelet) para uma dada aplicação descrita em [27], buscando otimizar a seleção dos coeficientes. Uma análise teórica do desempenho do algoritmo para diferentes características dos sistemas esparsos e do sinal de entrada também seria interessante.

Em relação ao algoritmo com passo de adaptação proporcional ao valor do coeficiente adaptado descrito no Capítulo 4, podem-se utilizar outros algoritmos propostos na literatura, como o IPNLMS [31], em conjunto com a estrutura wavelet. Acreditamos que outros algoritmos estão por vir que aproveitarão o poder que esta ferramenta, a transformada wavelet, pode acrescentar aos algoritmos adaptativos.

Referências Bibliográficas

- [1] HAYKIN, S., *Adaptive Filter Theory*, Prentice Hall, 2002.
- [2] SAYED, A. H., *Fundamentals of Adaptive Filtering*, John Wiley & Sons Inc., 2003.
- [3] FARHANG-BOROJENY, B., *Adaptive Filters*, Willey, 1998.
- [4] WIDROW, B., STEARNS, S. D., *Adaptive Signal Processing*, Prentice-Hall, 1985.
- [5] NARAYAN, S. S., PETERSON, A. M., NARASIMHA, M. J. “Transform Domain LMS Algorithm”, *IEEE Transactions on Acoustic, Speech, and Signal Processing*, vol. 31, pp. 609-614, 1983.
- [6] LEE, J. C., UN, C. K., “Performance of Transform-Domain LMS Adaptive Digital Filters,” *IEEE Transactions of Acoustic, Speech, and Signal Processing*, vol. ASSP-34, pp. 499-510, Jun. 1986.
- [7] TEWFIK, A. H., KIM, M., “Fast Positive Definite Linear System Solvers,” *IEEE Transactions on Acoustic, Speech, and Signal Processing*, vol. ASSP-42, pp. 572-585, Mar. 1994.
- [8] STRANG, G., NGUYEN, T., *Wavelets and Filter Banks*, Wesley Cambridge Press, 1997.
- [9] VAIDYANATHAN, P. P., *Multirate Systems and Filter Banks*, Prentice-Hall, 1993.
- [10] ATTALLAH, S., “The Wavelet Transform-Domain LMS Algorithm: a More Practical Approach,” *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, vol. 47, n. 3, Mar. 2000.

- [11] OGUNFUNMI, T., DANG, L., “Performance Analysis of Wavelet Transform-Based Adaptive Filtering.”, In: *Twenty-Eighth Asilomar Conference on Signals, Systems and Computers*, vol. 1, pp. 288–292, 1994.
- [12] ANANDAKUMAR, K., KASSAM, S. A., “Adaptive Filter Based on Wavelet Decomposition,” In: *IEEE - SP International Symposium on Time-Frequency and Time-Scale Analysis*, pp. 260–263, 1994.
- [13] ERDOL, N., BASBUG, F., “Wavelet Transform Based Adaptive Filters: Analysis and New Results,” *IEEE Transactions on Signal Processing*, vol. 44, n. 9, pp. 2163–2171, Sep. 1996.
- [14] PETRAGLIA, M. R., TORRES, J. C. B., “Performance Analysis of Adaptive Filter Structure Employing Wavelet and Sparse Subfilters,” *IEE Proceedings - Vision, Image and Signal Processing*, vol. 149, n. 2, pp. 115–119, 2002.
- [15] BERSHAD, N. J., QU, L. Z., “On the Probability Density Function of the LMS Adaptive Filter Weights,” *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 37, pp. 43–56, Jan. 1989.
- [16] MOON, T. K., STIRLING, W. C., *Mathematical Methods and Algorithms for Signal Processing*, Prentice-Hall, 2000.
- [17] HO, K.C., BLUNT, S. D., “Adaptive Sparse System Identification Using Wavelets”, *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, vol. 49, pp. 656–667, Oct. 2002.
- [18] BLUNT, S. D., HO, K. C., “Novel Sparse Adaptive Algorithm in the Haar Transform Domain”, In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol. 1, pp. 452–455, May 2000.

- [19] BLUNT, S. D., HO, K. C., “A Novel Sparse Adaptive Algorithm Using Wavelets”, In: *IEEE International Symposium on Circuits and Systems*, vol. 3, pp. III-37 – III-40, May 2002.
- [20] HO, K. C., BLUNT, S. D., “Enhanced Adaptive Sparse Algorithms Using the Haar Wavelet”, In: *IEEE International Symposium on Circuits and Systems*, vol. 3, pp. III-45 – III-48, May 2002.
- [21] HO, K. C., BLUNT, S. D., “Rapid Identification of a Sparse Impulse Response Using an Adaptive Algorithm in the Haar Domain”, *IEEE Transactions on Signal Processing*, vol. 51, n. 3, pp. 628–638, Mar. 2003.
- [22] DUTTWEILER, D. L., “Proportionate Normalized Least-Mean-Squares Adaptation in Echo Cancellers”, *IEEE Transactions on Speech and Audio Processing*, vol. 8, n. 5, pp. 508–518, Sep. 2000.
- [23] BREINING, C., et al., “Acoustic echo control”, *IEEE Signal Processing Magazine*, n. 4, pp. 42-69, 1999.
- [24] DENTINO, M., McCOOL, J., WIDROW, B., “Adaptive Filtering in the Frequency Domain”, *Proceedings of the IEEE*, vol. 66, pp. 1658-1659, Dec. 1978.
- [25] TORRES, J. C. B., PETRAGLIA, M. R., “Performance Analysis of an Adaptive Filter Employing Wavelets and Sparse Subfilters”, In: *European Signal Processing Conference*, vol. 2, pp. 997-1001, Sep. 2000.
- [26] ITU-T Recommendation G.168, International Telecommunication Union, 2004.
- [27] NOSKOSKI, O. A., BERMUDEZ, J. C. M., “Wavelet-Packet-Based Adaptive Algorithm for Sparse Impulse Response Identification”, In: *IEEE International Conference on Acoustics, Speech and Signal Processing*, vol. 3, pp. 1321-1324, Apr. 2007.

- [28] HÄNSLER, E., SCHMIDT, G., *Acoustic Echo and Noise Control: A Practical Approach*, Wiley, 2004.
- [29] NOSKOSKI, O. A., *Um Novo Algoritmo Adaptativo Usando Pacote Wavelet na Identificação de Sistemas com Resposta Esparsa ao Impulso*. Projeto de Tese de D. Sc., UFSC, Florianópolis, SC, Brasil, 2006.
- [30] GAY, S. L., “An Efficient, Fast Converging Adaptive Filter for Network Echo Cancellation,” In: *Thirty-Second Asilomar Conference on Signals, Systems and Computers*, pp. 394–398, Nov. 1998.
- [31] BENESTY, J., GAY, S. L., “An Improved PNLMS Algorithm,” In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, pp. 1881-1884, May 2002.