

PROJETO DE FILTROS DIGITAIS E SEPARAÇÃO DE FONTES USANDO FUZZY
ADAPTIVE SIMULATED ANNEALING

Hime Aguiar e Oliveira Junior

TESE 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 DOUTOR EM CIÊNCIAS
EM ENGENHARIA ELÉTRICA.

Aprovada por:

Prof. Antonio Petraglia, Ph.D.

Profa. Mariane Rembold Petraglia, Ph.D.

Profa. Maria Augusta Soares Machado, D.Sc.

Prof. Alexandre Pinto Alves da Silva, Ph.D.

Prof. Felipe Maia Galvão França, Ph.D.

Prof. Jacques Szczupak, Ph.D.

RIO DE JANEIRO, RJ – BRASIL

JUNHO DE 2008

OLIVEIRA JUNIOR, HIME AGUIAR E

Projeto de Filtros Digitais e Separação
de Fontes Usando Fuzzy Adaptive
Simulated Annealing [Rio de Janeiro]
2008

VII, 115 p. 29,7 cm (COPPE/UFRJ,
D.Sc., Engenharia Elétrica, 2008)

Tese – Universidade Federal do Rio
de Janeiro, COPPE

1. Filtros Digitais

I. COPPE/UFRJ II. Título (série)

AGRADECIMENTOS

Aos Professores Antonio e Mariane Petraglia, pela dedicação e apoio incondicionais, essenciais à conclusão desta tese.

Aos membros da banca examinadora, pela disponibilidade e precisão em seus pareceres.

À COPPE/UFRJ e funcionários do PEE, em particular Daniele e Mauricio, pela atenção e presteza na execução dos procedimentos administrativos.

Ao amigo Adão, pela permanente atenção e apoio incondicional durante décadas.

À Professora Maria Augusta, pelo permanente incentivo e incansável apoio.

E por último (mas não em último), agradeço à minha esposa, Deise, pela paciência e incentivo.

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

PROJETO DE FILTROS DIGITAIS E SEPARAÇÃO DE FONTES USANDO FUZZY
ADAPTIVE SIMULATED ANNEALING

Hime Aguiar e Oliveira Junior

Junho/2008

Orientadores: Antonio Petraglia

Mariane Rembold Petraglia

Programa: Engenharia Elétrica

Este trabalho visa propor um método de projeto de filtros digitais FIR com coeficientes reais e bancos de filtros QMF, utilizando técnicas de otimização global estocástica, em particular, aquela conhecida genericamente como *Simulated Annealing*. A abordagem utiliza amostras das respostas complexas consideradas ideais em pontos discretos do espectro digital pertinente para compor *training sets*, utilizados posteriormente na aproximação das referidas curvas por modelos paramétricos lineares e invariantes no tempo. Trata-se, em última análise, de problema de minimização global cuja solução é dada pelos parâmetros do sistema ótimo (com respeito ao quadrado de uma pseudonorma L_2 ponderada). Para a realização prática de tal minimização, é proposto o uso da implementação conhecida como *Fuzzy Adaptive Simulated Annealing*, ou Fuzzy ASA, abreviadamente. Em cada caso, é sintetizada função objetivo compatível com as diretrizes de projeto, cujo mínimo global determina a aproximação desejada. Ao final, abordagem baseada em minimização da informação mútua é estabelecida para casos de separação cega de sinais e análise de componentes independentes.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

DESIGN OF DIGITAL FILTERS AND SOURCE SEPARATION USING FUZZY
ADAPTIVE SIMULATED ANNEALING

Hime Aguiar e Oliveira Junior

June/2008

Advisors: Antonio Petraglia
Mariane Rembold Petraglia

Department: Electrical Engineering

This work proposes a design method directed to real coefficient FIR digital filters and QMF filter banks, using stochastic global optimization techniques, in particular, that one generically known as *Simulated Annealing*. The approach takes samples of complex responses considered ideal at discrete points along the corresponding digital spectrum, to compose training sets used afterwards to approximate the referred curves by means of linear and time-invariant parametric models. It is, after all, a global minimization problem, whose solution is given by the parameters of the optimal system (relative to a squared weighted L_2 norm). To the practical realization of such a minimization, it is used the implementation known as Fuzzy Adaptive Simulated Annealing, or Fuzzy ASA, for short. In each case, it is synthesized an objective function, compatible with design directives, whose global minimum determines the desired approximation. At last, a (mutual information) minimization based approach is established and applied to nonlinear blind source separation and independent component analysis problems.

ÍNDICE

1 Introdução	1
1.1 Estado da arte	4
1.2 Objetivos da pesquisa	6
2 Fundamentos teóricos	7
2.1 Lógica Fuzzy	7
2.2 Simulated Annealing	12
2.3 Considerações sobre o tipo de modelagem adotada	20
3 Projeto de filtros digitais FIR lineares e invariantes no tempo	23
3.1 Introdução	23
3.2 Implementação	24
3.3 Resultados	26
3.4 Conclusões – projeto de filtros digitais FIR	46
4 Projeto de bancos QMF	47
4.1 Introdução	47
4.2 Implementação	50
4.3 Resultados – comparação a projetos anteriores	51
4.4 Resultados – obtenção de relações numéricas biobjetivo	62
4.5 Conclusões – projeto de bancos QMF	77
5 Separação cega de misturas não-lineares e análise de componentes independentes	78
5.1 Introdução	78
5.2 Implementação	84
5.3 Resultados	85
5.4 Conclusões – separação cega de misturas não lineares	100
6 Conclusões e sugestões para pesquisa adicional	101

Referências bibliográficas	103
Anexo 1 - Código - equalizador senoidal de comprimento 61	108
Anexo 2 - Código - caso 64E (bancos QMF)	110
Anexo 3 - Código - sistema fuzzy SISO usado na separação de fontes	114

CAPÍTULO 1

INTRODUÇÃO

Ao longo das últimas décadas houve vários esforços bem sucedidos no sentido de construir métodos de síntese de filtros digitais que satisfizessem determinadas condições qualitativas de desempenho preestabelecidas. Em particular, podemos citar aqueles denominados de “por amostragem em frequência”, nos quais ocorre a coleta de valores da resposta em frequência desejada em um número finito de pontos, tipicamente igualmente espaçados e, a partir desses, obtêm-se os valores dos coeficientes de um filtro linear com resposta finita ao impulso que melhor aproxima a referida curva considerada ideal num certo sentido, bem definido em cada caso particular.

Em grande parte das situações, tais abordagens recorrem a resultados tanto da Álgebra Linear quanto do Cálculo Diferencial Local para obtenção do conjunto ótimo de parâmetros pela otimização de uma função-objetivo, a qual traduz o conjunto de exigências características do problema sob investigação. Infelizmente, os métodos de otimização baseados em gradientes apresentam uma característica em comum, a saber, a possibilidade de aprisionamento em pontos ótimos locais. Logo, se estivermos diante de funções de custo multimodais, poderá ocorrer a convergência a parâmetros correspondentes a filtros sub-ótimos, o que é indesejável. Como as funções em questão são predominantemente não-lineares, de domínio com elevado número de dimensões e com comportamento pouco favorável à classificação analítica no que se refere à obtenção dos respectivos conjuntos α e ω -limite (PALIS, 1978), o uso de métodos alternativos de otimização global certamente poderá ser algo decisivo no ataque aos problemas mais críticos. Lamentavelmente, constatamos que os métodos de otimização global não-convexa determinísticos, além de passíveis de aprisionamento em bacias de atração desinteressantes, podem ser bastante restritivos em termos de exigências analíticas com respeito à função de custo sob tratamento. Em vista disso, podemos formular o problema a ser resolvido: propor e utilizar método de projeto de filtros digitais FIR usando amostragem no domínio da frequência e otimização global estocástica, demonstrando sua eficácia e eficiência em casos de utilidade prática.

Para tanto, é fundamental levar em consideração numerosos trabalhos desenvolvidos no passado recente por meio de técnicas de Inteligência Computacional, como redes neurais artificiais (BHATTACHARYA, 1996, JOU, 2005, JOU, 2006), algoritmos evolucionários de inspiração biológica (genéticos e *particle swarm optimization*, em particular) (HUANG *et al.*, 2004, SCHNIER *et al.*, 2003), e que obtiveram resultados animadores, no que concerne aos índices de desempenho universalmente aceitos.

Mais uma vez, no entanto, e apesar de bem sucedidas em diversos casos de grande interesse, as abordagens utilizadas apresentam uma característica comum aos esforços anteriores, a saber, inexistência de garantia teórica geral para o alcance do ponto paramétrico globalmente minimizante, ou seja, o problema de projeto é transformado em um problema de otimização global (tipicamente minimização), mas o método de otimização usado para efetuar-la não possui garantia de convergência a ótimos globais (RAMSAY, 2005, ZABINSKY, 2003, PRONZATO *et al.*, 2000), seja esta garantia em probabilidade ou não. Esta característica é indesejável, e pode inviabilizar a solução de problemas relevantes, dado o elevado grau de incerteza quanto à proximidade da solução ótima teoricamente atingível.

Considerando esta realidade, nada mais conveniente que idealizar métodos implementáveis que possuam algum tipo de garantia de convergência, ao menos em probabilidade – esta é a proposta do presente trabalho, na síntese de métodos de projeto de filtros digitais, bancos QMF (*Quadrature Mirror Filter*) (VAIDYANATHAN, 1993) e separação de fontes por métodos não lineares.

Quanto às aplicações, os bancos QMF têm sido usados principalmente em diversas áreas de processamento digital de imagens e áudio, sendo particularmente importantes na decomposição de determinado sinal em um conjunto de componentes com espectros contidos em diferentes faixas de frequência (BOSE, 2004). Tal funcionalidade permite alcançar, por exemplo, significativa taxa de compressão de dados, seja para armazenamento ou transmissão - tal função é desempenhada pelo chamado banco de análise, que é o estágio inicial do banco QMF. De modo complementar, o banco de síntese (estágio final do banco QMF) permite recuperar a informação transmitida ou armazenada, recompondo os sinais decorrentes da etapa inicial e reintegrando uma aproximação do sinal original. Como cada tipo de sinal apresenta tipicamente a maior parte de sua energia em áreas relativamente bem

delimitadas do espectro digital, é possível consignar mais bits para as áreas mais importantes e reduzir o grau de quantização nas consideradas menos críticas, atingindo assim uma redução na representação final dos sinais a transmitir ou armazenar e, conseqüentemente, maior eficiência no processo global.

Os procedimentos de separação cega de sinais encontram aplicações nas mais diversas áreas, sendo as mais conhecidas as da Medicina, onde, por exemplo, é necessário obter eletrocardiogramas de fetos, que são “contaminados” pelos sinais cardíacos (de maior intensidade) de suas mães quando da realização dos exames, as da própria Engenharia, na eliminação de ruído ou separação de sons específicos de gravações com diversas fontes superpostas (o mesmo sendo válido para imagens superpostas) (ALMEIDA, 2006), as da Geologia, no tratamento de sinais sísmicos, as da Econometria, na análise da composição de séries históricas de índices ou cotações, com a finalidade de obter as causas fundamentais que levaram a determinado comportamento ou tendência.

1.1 Estado da arte

Existem atualmente diversos métodos bem sucedidos e definitivamente estabelecidos no que concerne a projeto de filtros digitais e suas associações mais complexas (BOSE, 2004, HAYKIN, 1996, OPPENHEIM *et al.*, 1999, GOH *et al.*, 1999, KIDAMBI, 1995, NGUYEN, 1993, PEI, 1992, CHEN, 1992). Apesar disso, trata-se de área com intensa atividade de pesquisa, visando obter métodos inovadores e abrangentes, capazes de solucionar os novos (e complexos) problemas da Engenharia contemporânea. Estabelecida a relevância do problema, é fato que existem presentemente diversos e crescentes esforços de pesquisa utilizando as chamadas técnicas evolucionárias, conforme referências anteriores, na síntese de métodos de projeto capazes de satisfazer vínculos (*constraints*) inviáveis para ataque com as técnicas convencionais supracitadas. Há iniciativas usando praticamente todos os tipos de abordagens até então conhecidas, em particular, redes neurais artificiais e algoritmos genéticos, havendo diversos casos de sucesso na superação de índices de desempenho obtidos por meio das técnicas convencionais. No entanto, há alguns inconvenientes associados a algumas dessas novas abordagens, a saber, elevado custo computacional, inexistência (na maioria dos casos) de prova teórica de convergência a ótimos globais em condições gerais e possibilidade de convergência a pontos paramétricos sub-ótimos. Consequentemente, há necessidade de pesquisa adicional no sentido de ampliar o conjunto de ferramentas disponíveis, superando as atuais limitações. Isso é válido em campos dos mais variados, como Econometria, Medicina, Geofísica, Astronomia, etc..

As tendências atuais de pesquisa no campo de separação cega de sinais, em particular, apresentam características coerentes com o exposto acima, ou seja, buscam obter métodos não necessariamente lineares para resolver problemas de natureza não linear. Isto pode ser explicado pelo fato que as misturas estritamente lineares foram tratadas com sucesso por técnicas analíticas bem estabelecidas da Estatística, Álgebra Linear e Cálculo. No entanto, diversos problemas práticos podem apresentar características de difícil tratamento quando atacados somente com aquelas ferramentas, levando o pesquisador a lançar mão de técnicas alternativas, sejam de inspiração biológica ou não, e de ajustamento a dados experimentais. Logo, existem inúmeras

publicações como (GÓRRIZ *et al.*, 2006) e (ALMEIDA, 2006), que utilizam algoritmos genéticos e redes neurais para separar misturas não lineares de modo não linear, e retratam bem a presente tendência de pesquisa nesta área. A contribuição apresentada nesta tese é coerente com esses esforços e utiliza técnicas não neurais para atingir os resultados desejados.

1.2 Objetivos da pesquisa

Logo, o objetivo da pesquisa é propor novos métodos de projeto de filtros digitais e separação cega de fontes, usando amostragem no domínio da frequência e otimização global estocástica para ajuste de diversos modelos paramétricos a *training sets* específicos, demonstrando sua eficácia e eficiência. Para tanto, será utilizada a técnica estocástica de otimização global conhecida como *Fuzzy ASA (Adaptive Simulated Annealing)* (INGBER, 2006, OLIVEIRA Jr, 2006), inspirada em idéias e resultados da Mecânica Estatística, cujos fundamentos foram estabelecidos por N. Metropolis e colegas na década de 1950 (METROPOLIS *et al.*, 1953, ROBERT *et al.*, 2004, HÄGGSTRÖM, 2002, BRÉMAUD, 1999). A presente pesquisa utilizará também resultados e conceitos da Lógica Fuzzy quando da construção da função de ponderação associada à de custo, sem citar técnicas de controle fuzzy encapsuladas no algoritmo numérico de minimização propriamente dito. Outro aspecto a ser ressaltado é a eliminação da exigência de diferenciabilidade (ou até continuidade) para as funções-objetivo sob processo de minimização, tendo em vista a generalidade adicional do método numérico utilizado. Os resultados aqui obtidos serão aplicados a diversos problemas na área de projeto de filtros digitais. Em particular, àqueles que envolvem procedimentos de otimização não-linear e/ou não-convexa, com ou sem vínculos, utilizando a implementação *Fuzzy ASA* para a fase de minimização global. Para demonstrar de modo inequívoco a utilidade das idéias aqui apresentadas, os resultados serão explicitados por meio de comparações entre os métodos recentes considerados mais adequados e aqueles obtidos pela presente abordagem. Isso será realizado pela síntese de filtros passa-baixa, passa-faixa, equalizadores, protótipos básicos de bancos QMF (VAIDYANATHAN, 1993) e separação cega de sinais, tendo em vista seu vasto espectro de aplicações em Engenharia e possibilidade de implementação eficiente. Houve diversas aplicações anteriores de otimização global ao projeto de bancos de filtros (WAH *et al.*, 1997), mas, devido à complexidade das funções-objetivo envolvidas, nem sempre o mínimo global pôde ser alcançado, levando a configurações sub-ótimas. Daí a relevância de realização de investigações adicionais, na tentativa de aperfeiçoar modelos promissores propostos previamente.

CAPÍTULO 2

FUNDAMENTOS TEÓRICOS

Este capítulo visa apresentar alguns dos pré-requisitos necessários ao entendimento do texto. Foram selecionados os resultados e definições fundamentais que, em conjunto com as referências, facilitam a leitura do trabalho.

2.1 Lógica Fuzzy

2.1.1 Considerações gerais

Embora seja sempre difícil definir conceitos fundamentais, podemos estabelecer que Lógica *Fuzzy* é um conjunto de métodos baseados no conceito de conjunto *fuzzy* e operações *fuzzy*, possibilitando a modelagem realista e flexível de sistemas. O aspecto mais notável dessa metodologia é a possibilidade de se capturar, em um modelo matemático, conceitos intuitivos como graus de satisfação, conforto, adequação, etc. Nada melhor do que um exemplo para ilustrar a idéia (OLIVEIRA Jr., 1999):

Suponhamos que em determinada cidade, a temperatura varie anualmente entre 15 e 42 graus Celsius. Ao questionarmos um grupo de habitantes sobre sua sensação térmica, escolhida entre as alternativas {FRIA, NEUTRA, QUENTE}, certamente todos concordarão que a de 15 graus é FRIA, 42 graus é QUENTE e a, digamos, 25 graus é NEUTRA. A pergunta crucial é:

Em que temperaturas a sensação FRIA se torna NEUTRA e esta se transforma em QUENTE?

Difícilmente haverá coincidência de opiniões, tendo em vista que os conceitos envolvidos são subjetivos e apresentam áreas "sombrias", nas quais não se consegue escolher entre duas alternativas mutuamente exclusivas simplesmente porque ambas estão parcialmente presentes (OLIVEIRA Jr., 1999). É importante ressaltar que, apesar do nome, não se trata de uma vertente da Lógica Matemática, nem uma nova Teoria de Conjuntos e muito menos

um paradigma conflitante com a Teoria das Probabilidades. Embora empregue os conceitos de inferência *fuzzy*, conjunto *fuzzy* e distribuição de possibilidades, a teoria é formulada por meio de conceitos da Teoria dos Conjuntos de Cantor e se mostra como importante ferramenta também no tratamento de sistemas estocásticos, aliada ao conhecimento já estabelecido nos modelos estatísticos. Devemos entender com clareza que o tipo de incerteza tratado pela Estatística difere daquele tratado pela Lógica *Fuzzy*. Apesar do elevado percentual de exemplos relacionados à área de Engenharia, nunca é demais reafirmar que o conceito de difusão (*fuzziness*) tem larga utilidade nas ciências sociais e médicas, onde a interação com conceitos até então não formalizados é grande.

Formalmente, um conjunto *fuzzy* F é definido como o conjunto de pares ordenados contendo o elemento e seu grau de pertinência no conjunto:

$$F = \{ (u, \mu_F(u)) / u \in U \} \quad (2.1)$$

onde U é o chamado universo de discurso e $\mu_F(u)$ a função de pertinência associada ao conjunto F , representada por:

$$\{ \mu_F(u) : u \in U \} \quad (2.2)$$

As funções de pertinência fazem o papel das curvas de possibilidades na teoria clássica da Lógica *Fuzzy*. Sendo os conjuntos *fuzzy* apropriados para representar noções vagas, freqüentemente encontradas no mundo real, como, por exemplo, alto, quente, frio, rápido, etc., é a função de pertinência que define as fronteiras desses conjuntos. A princípio, qualquer função com domínio U e imagem em $[0, 1]$ pode ser utilizada como função de pertinência. No entanto, as formas triangular, trapezoidal e gaussiana, mostradas nas Figuras 2.1 a 2.3, são as mais utilizadas. O eixo das abscissas corresponde às grandezas sob avaliação (temperatura, pressão, preço, etc.), e o das ordenadas mostra o grau de compatibilidade entre um valor particular e o conceito específico sob modelagem.

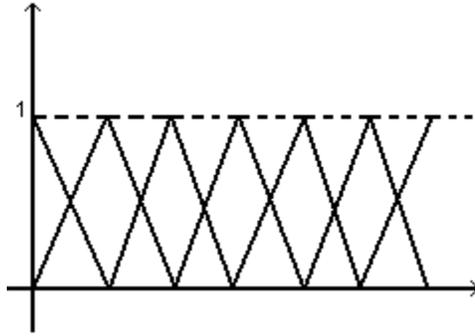


Figura 2.1 - Triangulares

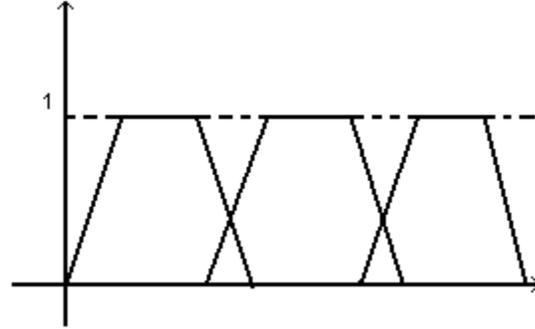


Figura 2.2 - Trapezoidais

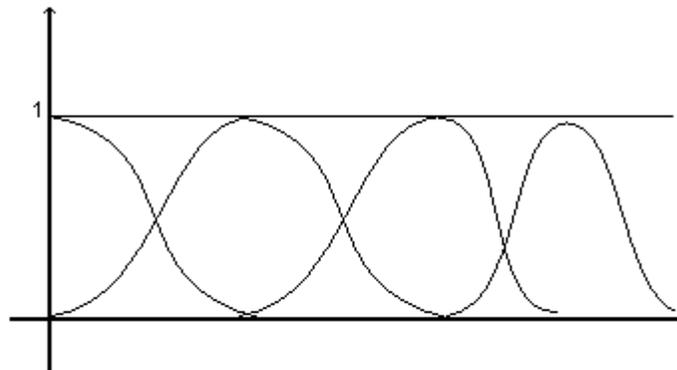


Figura 2.3 - Gaussianas

O conceito de conjunto *fuzzy* pode ser considerado uma generalização da noção de conjunto clássico (ABONYI, 2003, DRIANKOV, 1998, OLIVEIRA Jr., 1999, SOUZA, 2002, YAGER, 1994, ROSS, 1995, JAMSHIDI, 1997), sendo, num certo sentido, uma extensão da Teoria dos Conjuntos. Abaixo estão definidas as principais relações e operações entre conjuntos *fuzzy*.

2.1.2 União

A função de pertinência resultante da união de dois conjuntos *fuzzy* é o maior valor da pertinência aos dois conjuntos específicos e de cada um dos seus elementos. Em outras palavras, o que se quer para o grau de associação de um elemento, quando listado, na união de dois grupos *fuzzy*, é o valor máximo deste grau de associação quando dois grupos *fuzzy* formam uma união. Dados dois conjuntos *fuzzy* A e B, denomina-se conjunto *fuzzy* união de

A com B, ao conjunto *fuzzy* C definido como $C = A \cup B$, cuja função de pertinência é relacionada às funções de pertinência de A e B por:

$$\mu_C(x) = \max[\mu_A(x); \mu_B(x)] \quad (2.3)$$

A união de dois conjuntos *fuzzy* corresponde, na Álgebra Booleana, à operação OR, como mostrado na Figura 2.4.

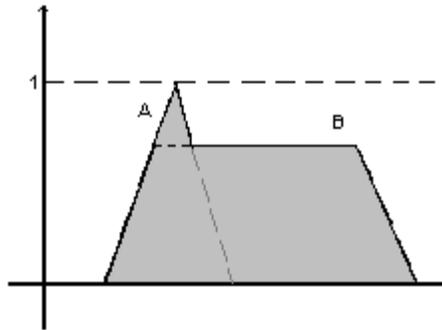


Figura. 2.4 - União entre conjuntos *fuzzy*.

2.1.3 Interseção

A interseção de dois conjuntos *fuzzy* caracteriza-se por ser a parte comum de ambos e, em consequência, é sempre menor que qualquer um dos conjuntos individuais. A função de pertinência resultante da interseção de dois conjuntos *fuzzy* é o menor valor da pertinência, aos dois conjuntos específicos e de cada um dos seus elementos. O grau de associação de um elemento na interseção de dois grupos *fuzzy* é o mínimo, ou o menor valor de seu grau de associação individualmente nos dois grupos que formam a interseção. Dados dois conjuntos *fuzzy* A e B, denomina-se conjunto *fuzzy* interseção de A com B, ao conjunto *fuzzy* C definido como $C = A \cap B$, cuja função de pertinência é relacionada às funções de pertinência de A e B por:

$$\mu_C(x) = \min[\mu_A(x); \mu_B(x)] \quad (2.4)$$

A interseção de dois conjuntos *fuzzy* corresponde, na Álgebra Booleana, à operação AND, como mostrado na Figura 2.5.

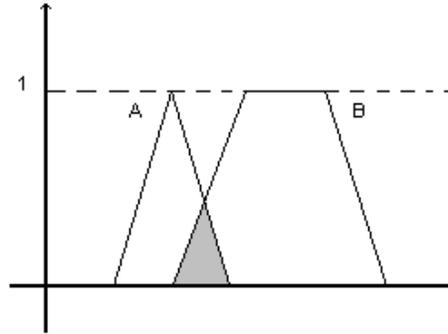


Figura. 2.5 - Interseção entre conjuntos *fuzzy*.

2.1.4 Complemento

Dado o conjunto *fuzzy* A, denomina-se complemento de A, o conjunto *fuzzy* C representado por \bar{A} e satisfazendo:

$$\mu_C(x) = 1 - \mu_A(x) \quad (2.5)$$

O complemento de um conjunto *fuzzy* corresponde, na Álgebra Booleana, à operação NOT.

2.1.5 Igualdade

Dados dois conjuntos *fuzzy* A e B sobre um universo de discurso X, com graus de pertinência de x iguais a $\mu_A(x)$ e $\mu_B(x)$ em A e B, respectivamente, dizemos que $A = B$, se $\mu_A(x) = \mu_B(x)$ para todo $x \in X$.

2.1.6 Inclusão

Dados dois conjuntos *fuzzy* A e B sobre um universo de discurso X, com graus de pertinência de x $\mu_A(x)$ e $\mu_B(x)$, respectivamente, dizemos que A está contido em B, e representamos por $A \subset B$, se $\mu_A(x) \leq \mu_B(x)$ para todo $x \in X$.

2.1.7 Suporte

O suporte de um conjunto *fuzzy* A , em um conjunto universo X , é o conjunto *crisp* que contém todos os elementos de X que possuem grau de pertinência diferente de zero em A .

$$\text{Suporte}(A) = \{ x \mid \mu_A(x) > 0 \} \quad (2.6)$$

2.1.8 Núcleo

O núcleo de um conjunto *fuzzy* A é o conjunto *crisp* de todos os pontos $x \in X$ tais que $\mu_A(x) = 1$.

$$\text{Núcleo}(A) = \{ x \mid \mu_A(x) = 1 \} \quad (2.7)$$

2.1.9 Normal

Um conjunto *fuzzy* A é dito normal se o seu núcleo não é vazio, ou seja, se há pelo menos um ponto $x \in X$ tal que $\mu_A(x) = 1$.

2.2 *Simulated Annealing*

2.2.1 Considerações gerais

O problema de otimização global de funções numéricas tem grande importância em várias áreas do conhecimento. Ele aparece em campos como Engenharia, Finanças, Gerenciamento, Medicina (CHERRUAULT, 2005), etc. Em casos práticos, a função a ser otimizada aparece como um índice de performance multivariável e está sujeita a certos vínculos, impostos por seu contexto. Quando a função-objetivo é “bem comportada”, existem vários métodos para se obter seus pontos extremos, satisfazendo aos referidos vínculos. Os problemas começam quando a dada função apresenta vários extremos locais, cada um deles possuindo sua própria bacia de atração, fazendo tipicamente o resultado final depender do ponto inicial, utilizado para “lançar” um dado algoritmo particular. Infelizmente, a maioria dos problemas práticos dá origem a funções-objetivo bastante complexas, sendo frequentemente não-lineares, descontínuas, multi-modais etc (BARHEN

et al., 1997). Para resolver tal classe de problemas, métodos não-determinísticos parecem ser uma boa alternativa, se não a única, em várias situações (VERDEGAY, 2003). Algoritmos genéticos e *Simulated Annealing* (abreviadamente SA) aparecem como abordagens bastante exploradas em otimização estocástica global. O problema neste caso está relacionado à velocidade de convergência e, no caso genético, garantia do alcance do extremo global, sob condições suficientemente gerais. Métodos puros de SA, por outro lado, possuem resultados que asseguram sua convergência a ótimos globais com probabilidade tendendo a 1, mas seu desempenho, em geral, não é satisfatório, em termos de eficiência computacional. *Annealing* (ou temperamento) é um termo de origem metalúrgica. Sua origem está relacionada ao fato de que podemos ajustar a grau de dureza e/ou flexibilidade de metais por meio de um processo de resfriamento controlado, no qual a peça em questão é aquecida a determinada temperatura e, então, resfriada segundo diversas escalas (de resfriamento), de acordo com o efeito final desejado. Se o objetivo é obter dureza e rigidez, a temperatura é diminuída abruptamente. Se, ao contrário, desejamos flexibilidade, a redução é feita lentamente, até a temperatura ambiente. Na atualidade, foram descobertas as razões de tal fenômeno: quando o material está muito aquecido, seus átomos constituintes vibram violentamente e sua orientação espacial é desordenada, de modo que, ao resfriá-los repentinamente, tendem a manter a configuração momentânea, ou seja, aleatória. No outro caso (resfriamento lento), há a tendência para o alinhamento em direções regulares e características de cada material, possibilitando a regularização do posicionamento atômico.

É claro que acima do zero absoluto sempre há movimento, mas ele diminui à medida que a temperatura cai. O ponto fundamental é que em cada patamar térmico existe a tendência de alinhamento em algum tipo de estrutura organizada. Ocorre que, em altas temperaturas, o movimento é muito intenso e de difícil percepção. Logo, com a diminuição do grau de movimento, o alinhamento se intensifica e, se o resfriamento for suficientemente lento, obteremos metais mais flexíveis e menos sujeitos à ruptura.

Esse mesmo princípio pode ser aplicado à otimização de funções (GARDINER, 2002, GILKS *et al.*, 1996, HOOS, 2005, NORRIS, 1999). No caso de minimização global de aplicações multimodais, podemos imaginar que, a partir de um ponto específico, geremos pontos aleatoriamente de acordo com determinada distribuição de probabilidades que favoreça a excursão rumo a regiões nas quais a função sob análise assumia valores numéricos menores. Isto corresponde a uma situação em que, inicialmente, permitimos a ocorrência de um “reconhecimento” do domínio funcional, propiciando a delimitação de

sub-regiões mais favoráveis, a partir das quais haverá um refinamento subsequente, convergindo a áreas com valores ainda menores, e assim por diante, até que estejamos em vizinhanças suficientemente próximas dos alvos finais. Para que isso efetivamente funcione, há resultados teóricos (BRÉMAUD, 1999, HASTINGS, 1970) que estabelecem condições suficientes para a convergência com probabilidade unitária a mínimos globais, baseados predominantemente na teoria das cadeias de Markov.

Embora não exista uma definição fundamental e básica, a partir da qual todos os métodos sejam realizados, todas as propostas formais de métodos baseados em SA têm como base as diretrizes de que pontos com menores valores funcionais sejam favorecidos e haja sempre probabilidade não nula de escape de mínimos locais, ou seja, ainda que a função a minimizar assuma valor superior em um ponto candidato, quando comparado ao estado atual, existe uma chance de transição, o que viabiliza a evasão de eventuais bacias de atração de mínimos intermediários. Em linhas gerais, poderíamos enunciar as seguintes diretrizes para a construção de algoritmos baseados em SA (MASTERS, 1993):

- Escolher a temperatura inicial tão pequena quanto possível, desde que grande o suficiente para o alcance do ótimo global;
- Escolher a temperatura final tão grande quanto possível, desde que pequena o bastante para alcançar a bacia de atração do ótimo global;
- Escolher a taxa de resfriamento de modo compatível com o número de iterações em cada temperatura, ou seja, não é adequado permanecer por muito tempo em cada patamar térmico se sua granularidade for insuficiente;
- Permitir a extensão do número de iterações em dado nível, caso o valor da função permaneça decaindo;
- Considerar a possibilidade de “customização” das funções de distribuição de probabilidades para cada tipo de problema. Embora as distribuições do tipo gaussiano sejam adequadas em muitos casos, existem situações nas quais uma de cauda longa (Cauchy, por exemplo) (CASELLA, 2001) melhorará substancialmente o resultado final.

2.2.2 Fuzzy Adaptive Simulated Annealing

Apesar do tempo excessivo até a convergência apresentado por algumas realizações de *simulated annealing*, alguns pesquisadores conseguiram superar tais limitações, levando, por exemplo, a alternativas como ASA (*Adaptive Simulated Annealing*), que é um método de otimização global estocástica tipicamente eficaz. ASA é particularmente adequado a aplicações envolvendo sistemas neuro-*fuzzy* e treinamento de redes neurais artificiais, em virtude de seu excelente desempenho e relativa simplicidade. ASA possui uma implementação (na linguagem de programação C) que nos traz os benefícios de ser pública, parametrizável e bem mantida. Além disso, mostra-se como uma boa alternativa em relação aos algoritmos genéticos e inspirados em fenômenos biológicos, em geral, levando-se em conta os testes de desempenho já realizados (OLIVEIRA Jr., 2005), que demonstram sua boa qualidade. Infelizmente, todos os algoritmos estocásticos de otimização global conhecidos compartilham algumas características pouco desejáveis como, por exemplo, longos períodos de estagnação. Em implementações de SA, isto é devido ao chamado processo de *resfriamento*, cuja velocidade é limitada pelas características das funções de densidade de probabilidade (PDFs) usadas para a geração de novos pontos candidatos. Desta maneira, se escolhermos empregar o resfriamento de Boltzmann (BA), a “temperatura” é reduzida a uma taxa máxima correspondente a $T(k) = T(0) / \ln(k)$. No caso do resfriamento rápido (FA), a evolução da temperatura passa a $T(k) = T(0) / k$, se desejarmos assegurar convergência com probabilidade 1, resultando em uma evolução mais rápida do processo geral. O algoritmo ASA tem um esquema ainda mais eficiente, dado por:

$$T_i(k) = T_i(0)\exp(-C_i k^{1/D}) \quad (2.8)$$

onde os C_i são parâmetros definidos pelo usuário. Note que os subscritos indicam evolução independente de temperaturas para cada dimensão. Há também a possibilidade de utilizar o processo de *Simulated Quenching* (SQ) (INGBER, 2006), resultando em

$$T_i(k) = T_i(0)\exp(-C_i k^{Q_i/D}) \quad (2.9)$$

onde os Q_i são os parâmetros correspondentes ao processo de *quenching*. Se tais parâmetros forem maiores que 1, existirá ganho de velocidade, mas a convergência ao ótimo global não é mais assegurada. Tal procedimento poderia ser usado em casos de domínios com dimensões elevadas (> 100 , por exemplo) e recursos computacionais escassos. Apesar (ou por causa) de toda esta flexibilidade, há muitos ajustes a realizar, do ponto de vista do usuário. No que segue, descreveremos um método bem sucedido de aceleração aplicado ao sistema ASA, que, pela utilização de um controlador *fuzzy* Mamdani (OLIVEIRA Jr., 1999), ajusta dinamicamente parâmetros relacionados ao procedimento de *quenching*. Mostraremos que, pelo aumento da percepção de situações de estagnação ou fraco desempenho, é possível tomar ações corretivas e reduzir substancialmente (talvez eliminar) as tarefas de ajuste paramétrico manual. Tudo é feito sem alterar o código do sistema ASA (OLIVEIRA Jr., 2005). Algoritmos baseados em SA utilizam princípios idealizados por N. Metropolis e outros (METROPOLIS *et al.*, 1953), sendo conhecidos genericamente pelo rótulo de métodos de Monte Carlo. A abordagem usa três componentes fundamentais que têm grande impacto na implementação final:

- Uma densidade de probabilidade $g(\cdot)$, usada na geração de novos pontos candidatos.
- Uma densidade de probabilidade $a(\cdot)$, usada na aceitação/rejeição de novos pontos.
- Um esquema de redução de temperaturas $T(\cdot)$, que determina como as mesmas variarão durante a execução do algoritmo, ou seja, seu perfil dinâmico.

A estratégia básica é gerar um ponto inicial, escolhido de acordo com critérios convenientes, e ajustar a temperatura inicial de modo que o espaço de fase possa ser *suficientemente* explorado. A seguir, novos pontos são gerados de acordo com a PDF $g(\cdot)$ e probabilisticamente aceitos ou rejeitados, conforme determinar a PDF $a(\cdot)$. Se ocorrer a aceitação, o ponto candidato é elevado à condição de ponto básico vigente. Durante a execução do algoritmo as temperaturas são reduzidas, provocando a redução da probabilidade de aceitação de novos pontos posteriormente gerados apresentando valores da função-objetivo superiores àquele do ponto básico corrente (no caso de minimização de funções). Entretanto, existe uma probabilidade não nula de escolha de pontos situados *acima* deste último, tornando possível uma eventual “fuga” de mínimos locais. Como citado anteriormente, o algoritmo ASA é baseado no conceito de *simulated annealing*, possuindo um grande número de aspectos positivos. Dentre eles, podemos destacar:

- ♦ *Re-annealing* – trata-se do re-escalonamento dinâmico das temperaturas paramétricas, adaptando PDFs geradoras para cada dimensão de acordo com as sensibilidades exibidas em cada direção de busca. Em poucas palavras, se a função objetivo não apresenta variações significativas quando alteramos um dado parâmetro, pode ser proveitoso estender a amplitude do intervalo de busca naquela dimensão em particular, e vice-versa.
- ♦ Facilidades de *quenching* – a implementação do sistema ASA apresenta a possibilidade de ajuste (por parte do usuário) de vários parâmetros estruturais relacionados ao processo de *quenching*, o que poderá resultar em maior velocidade de convergência. Assim, é possível moldar a evolução das temperaturas paramétricas de modo amplo, fácil e limpo.
- ♦ Alto nível de parametrização – o sistema ASA foi codificado de tal modo que possamos alterar virtualmente qualquer subsistema sem esforço significativo. Sendo assim, é possível mudar o comportamento dos processos de geração/aceitação, critérios de conclusão, geração de pontos iniciais, nível de detalhe do arquivo de log, etc.

ASA foi projetado para encontrar mínimos globais pertencentes a um dado subconjunto compacto (limitado e fechado, na topologia usual) do espaço Euclidiano n-dimensional. Ele gera pontos, componente a componente, de acordo com:

$$\begin{aligned}
 x_{i+1} &= x_i + \Delta x_i, \\
 \text{com } \Delta x_i &= y_i (B_i - A_i), \\
 [A_i, B_i] &= \text{faixa de variação da } i\text{-ésima dimensão,} \\
 y_i \in [-1, 1] &\text{ é dado por} \\
 y_i &= \text{sgn}(u_i - 1/2) T_i [(1 + 1/T_i)^{|2u_i - 1|} - 1] \text{ onde} \\
 u_i \in [0, 1] &\text{ é gerado por meio da distribuição uniforme,} \\
 T_i &= \text{temperatura atual relativa à dimensão } i.
 \end{aligned}$$

A compacidade do espaço de busca (no sentido da Topologia Geral) não é uma severa limitação na prática, e, na falta de prévia informação sobre a possível localização de mínimos globais, basta escolher domínios hiper-retangulares suficientemente abrangentes

(OLIVEIRA Jr., 2005). Conforme citação anterior, o uso do mecanismo de *quenching* pode melhorar substancialmente a eficiência do processo de convergência, com a assunção do risco de alcance prematuro de mínimos não globais. Em certos casos, contudo, podemos simplesmente não ter alternativa, como é o caso de funções com domínios de elevado número de dimensões. Para resolver o problema, um controlador *fuzzy* foi projetado, a exemplo de iniciativas passadas relativas a outras metaheurísticas (LEE, 1993). A abordagem é simples: consideramos ASA como um sistema dinâmico MISO (*Multiple Input Single Output*) e “fechamos a malha”, pela amostragem da saída de ASA (valor corrente da função objetivo) e atuação em suas entradas (um subconjunto de parâmetros ajustáveis em *run-time*, relacionados ao processo de *quenching*) de acordo com uma *lei fuzzy* (algoritmo de controle), que nada mais faz do que emular o raciocínio humano sobre o processo subjacente. Assim, pelo uso de um controlador inteligente podemos acelerar e retardar a evolução das temperaturas, além de sermos capazes de tomar ações evasivas em caso de convergência prematura (OLIVEIRA Jr., 2005). Enfrentamos dois principais obstáculos para alcançar tal objetivo:

1. Como as saídas amostradas (valores da função objetivo) podem informar o estado atual do processo de minimização em andamento?
2. Como podemos alterar dinamicamente as entradas do sistema ASA de modo a eliminar situações indesejáveis, como permanência junto a mínimos não globais ou progresso insatisfatório?

A primeira questão foi resolvida graças ao conceito de função de sub-energia, usada no método TRUST (BARHEN *et al.*, 1997).

A função de sub-energia é dada por:

$$SE(x, x_0) = \log(1/[1+\exp(-(f(x)-f(x_0))-a)]) \quad (2.10)$$

onde a é uma constante real e x_0 é o ponto básico atual.

O ponto básico é o melhor ponto de mínimo encontrado até então. Logo, a função $SE()$ comporta-se qualitativamente como a original $f(.)$ quando o processo de busca “visita” pontos melhores do que o mínimo corrente e tende a se achatar em pontos piores.

Assim, é possível avaliar quando a busca está concentrada acima, nas imediações ou abaixo do ponto mínimo atual pela inspeção dos valores assumidos pela função de sub-energia. Tal processo de detecção resulta em conclusões aproximadas, tais como

A busca está *PRÓXIMA* do mínimo vigente.

ou

A busca está *MUITO DISTANTE* do mínimo vigente.

O que leva naturalmente a uma oportunidade de modelagem *fuzzy*.

A segunda questão acima está relacionada às partes conseqüentes da base de regras *fuzzy*, na qual temos que inserir ações corretivas para eventuais desvios em relação às diretrizes preestabelecidas para o processo de minimização. Isto foi feito pela variação dos graus de *quenching* para PDFs de geração e aceitação. A implementação usou fatores de *quenching* individuais para cada dimensão. A base de regras do controlador fuzzy contém asserções como

- ♦ SE AveSub está *PRÓXIMA* a zero ENTÃO aumente o nível de Quenching ;

- ♦ SE AveSub está *PRÓXIMA* ao mínimo corrente ENTÃO aumente o nível de Quenching;

- ♦ SE StdDevSub é *ZERO* ENTÃO decresça o nível de Quenching.

onde AveSub é uma variável lingüística correspondente à média abrupta (*crisp*) dos 100 últimos valores de sub-energia e StdDevSub é uma variável lingüística correspondente ao desvio-padrão abrupto (*crisp*) dos 100 últimos valores de sub-energia.

Tendo descrito a estrutura geral da abordagem adotada, indicamos a referência (OLIVEIRA Jr., 2005) para maiores detalhes relativos aos resultados obtidos através da otimização de algumas funções de difícil tratamento.

2.3 Considerações sobre o tipo de modelagem adotada

Esta seção se destina a explicitar e esclarecer o tipo genérico de modelagem usada para abordar o problema central da tese, dentre os três tipos possíveis (caixa branca, caixa cinza e caixa preta).

A obtenção de modelos matemáticos para sistemas complexos é essencial para que possamos entender, simular, explicar e prever seu comportamento em condições adequadas. Para tanto, temos reconhecidamente três tipos de (meta)abordagens disponíveis, a saber:

2.3.1 Caixa branca

É o mais conhecido e tradicional tipo de modelagem, no qual são usados resultados matemáticos bem estabelecidos para obtenção de modelos fechados que descrevem com precisão determinada (ou passível de determinação) o fenômeno real sob investigação. Normalmente assumem a forma de relações funcionais, envolvendo elementos de Álgebra, Análise Real e Funcional, Topologia, Geometria, etc. e são inequívocas, sem margem a interpretações subjetivas e, tipicamente, determinísticas, podendo, no entanto, envolver elementos probabilísticos, sem perder sua característica fundamental de independência direta em relação a dados experimentais.

2.3.2 Caixa preta

Aqui, os modelos são sintetizados com base somente em dados experimentais e modelos paramétricos reconhecidamente gerais para aproximar o sistema sob estudo, sem recurso a relações teóricas e/ou conhecimento não formal previamente acumulado. Logo, não há qualquer tipo de subsídio à tarefa de identificação a não ser a família parametrizada suficientemente flexível e geral para aproximação arbitrariamente precisa e algum tipo de processo ou método de aproximação, que possibilite a convergência ao

modelo final desejado. No caso de obtenção de filtros FIR com resposta complexa arbitrária, a família geral é representada pelo conjunto de todos os filtros lineares FIR de comprimento N , e a tarefa de identificação é obter um conjunto de N números reais (coeficientes) que determinem pelo menos um elemento específico (filtro FIR) com resposta suficientemente “próxima” à desejada. Os procedimentos típicos usados envolvem redes neurais artificiais, algoritmos genéticos, PSO (Particle Swarm Optimization), etc., e, como complemento, algum tipo de função objetivo, necessária ao direcionamento do processo global de aproximação. Sendo assim, tal função de custo mostra-se naturalmente como o ponto central de todo o problema, e sua obtenção tende a ser o obstáculo de mais difícil transposição.

2.3.3 Caixa cinza

Finalmente temos o modelo do tipo caixa cinza, que é uma combinação dos dois tipos anteriores e caracteriza-se por permitir a consideração tanto de conhecimento empírico acumulado, relações analíticas conhecidas e dados experimentais, quanto de famílias paramétricas que serão submetidas a procedimentos (tipicamente iterativos) de aproximação. Tal estratégia é sensata, uma vez que todas as informações acumuladas são aproveitadas e nunca temos conhecimento completo teórico dos sistemas físicos reais, existindo fatores desconhecidos que poderão ser revelados por métodos exploratórios complementares. Os procedimentos de modelagem permitirão que levemos em conta a opinião e intuição de especialistas, facilitando a descoberta de melhores modelos, obedecendo às restrições impostas pelo problema em questão. Em consequência, existe grande flexibilidade na utilização de cada tipo de informação, podendo o projetista optar por uma caixa “quase branca” ou “quase preta”, conforme use mais ou menos informações analíticas.

2.3.4 Abordagem modelar adotada

No presente trabalho, pode-se dizer que houve adoção do tipo “cinza escuro”, ou até mesmo “caixa preta”, conforme consideremos ou não as características ou resultados básicos definindo a função objetivo usada nos processos de otimização. O fato é que três componentes fundamentais figuraram em cada um dos casos, a saber: escolha de família paramétrica para o modelo procurado, definição de um *training set* no domínio da frequência e especificação de função objetivo adequada a cada tipo de problema, não havendo recurso a qualquer tipo de resultado analítico auxiliar nos procedimentos de obtenção dos parâmetros ótimos – uma vez definido cada alvo, os procedimentos aproximativos foram efetuados inteiramente pelo algoritmo de otimização global Fuzzy ASA . Por outro lado, é essencial que as características específicas de cada projeto estejam implícitas nas diversas funções, para que haja convergência ao sistema particular desejado.

CAPÍTULO 3

PROJETO DE FILTROS DIGITAIS FIR LINEARES E INVARIANTES NO TEMPO

3.1 Introdução

Dada uma função complexa ideal de resposta em frequência $H_d(\omega) = A(\omega)\exp(j\rho(\omega))$ (transformada de Fourier discreta no tempo), deseja-se obter os coeficientes reais $h(n)$, $n=0,\dots,N-1$ de um filtro digital LTI com resposta finita ao impulso e ordem $N-1$ (comprimento N), cuja resposta em frequência aproxime de modo ótimo a curva-modelo, por meio do seguinte algoritmo:

- Obter o *training set*, pelo cálculo do valor da função H_d nas frequências ω_i , $i=1,\dots,T$, com $\omega_i \in [0,\pi]$ e T igual à cardinalidade do conjunto de amostras. Note-se que não há quaisquer imposições geométricas sobre os valores de ω_i , como espaçamento uniforme, etc.;
- Construir a função-objetivo $S(h) = \sum W(i)(H_d(\omega_i) - H(\omega_i))^2$, onde $H(\cdot)$ é a função de transferência de um filtro LTI genérico de coeficientes reais $h(n)$ {Transformada de Fourier discreta no tempo}, $W(\cdot)$ é uma função real de ponderação, utilizada para condicionamento numérico, não sendo necessariamente diferenciável ou contínua, e $h = [h(0) h(1) \dots h(N-1)]$;
- Submeter a função $S(h)$ ao algoritmo de otimização global (no caso, Fuzzy ASA) e obter os parâmetros $h_o(n)$, $n=0,\dots,N-1$, que a minimizam. Tais valores determinarão o filtro ótimo, no sentido L_2 ponderado.

3.2 Implementação

Para realizar a estimação de parâmetros por meio da abordagem proposta, foi utilizado um programa extensível cuja estrutura consiste de um núcleo fixo, interface gráfica amigável e que permite a incorporação de *plug-ins* contendo o código das funções a otimizar. Como resultado final, são fornecidos os parâmetros correspondentes aos pontos ótimos pertencentes ao domínio das funções sob tratamento. A opção foi por usar uma “máquina de minimização global” geral. A idéia é extremamente simples: para investigar os parâmetros de um dado problema, dada a função-objetivo, basta construir um módulo de software (cuja estrutura será detalhada abaixo) contendo alguns poucos métodos com interfaces bem definidas. Dentre eles, um será responsável por avaliar a função-objetivo em pontos arbitrários do domínio e devolver o valor correspondente ao chamador. Tal tipo de arquitetura permite desacoplar o mecanismo de otimização propriamente dito dos cálculos particulares relativos a uma dada função numérica. Logo, após os procedimentos de ajuste iniciais, o núcleo central inicia um processo iterativo, chamando continuamente a função responsável pelo cálculo dos valores numéricos e simulando um processo estocástico que visita estados com “energias” cada vez menores e rumo à configuração que deverá conter algum ótimo global para o problema – é claro que as condições para convergência deverão ser cumpridas para que o resultado desejado seja atingido. Além disso, pode ser necessário ajustar alguns parâmetros para obtenção de melhor desempenho.

O programa central é codificado na linguagem C++ (STROUSTRUP, 1997), de modo a permitir seu fácil transporte a diversos sistemas operacionais, dentre eles vários “sabores” do sistema operacionais Unix (Linux, em particular). Para utilizá-lo, basta programar um módulo carregável dinamicamente que contenha, no mínimo, 3 rotinas específicas do problema em questão, a saber:

- Nome Da Função Objetivo

Devolve uma string contendo o nome da função-objetivo a ser investigada.

- Número De Parâmetros Da Função Objetivo

Devolve a dimensão linear do espaço no qual o domínio da função-objetivo está imerso.

- Função Objetivo Propriamente Dita

Devolve o valor da função, dados o ponto de cálculo e um ponteiro contendo informações de responsabilidade do usuário .

A título de ilustração, mostramos, no Anexo 1, o código-fonte de um módulo completo, correspondente a um dos casos de projeto de filtro FIR aqui tratados (equalizador). A partir deste ponto, é obviamente necessário compilar e “link-editar” o programa-fonte para criação do binário (shared object, DLL, etc.) que será carregado em *run-time* pelo programa principal, após as devidas configurações via interface gráfica . Os controles disponíveis na versão atual são relativos ao nome do arquivo que contem o código da biblioteca dinamicamente carregável (DLL), ao número de aceitações e gerações do algoritmo de otimização, à definição do domínio de otimização que restringe o espaço de estados do processo a ser simulado e ao tipo de algoritmo a ser utilizado durante a execução. Como instrumento complementar, uma janela mostra a evolução dos valores numéricos assumidos pelos pontos intermediários, na busca pelo extremo global. Para tornar o processo de desenvolvimento mais ágil, foram construídos utilitários que aceitam como entrada os relatórios gerados pelo programa de minimização (contendo os parâmetros estimados) e geram código Matlab com o objetivo de efetuar cálculos de verificação e apresentação gráfica dos resultados finais.

Apesar da generalidade do algoritmo central de otimização (Fuzzy ASA) e de sua expressiva invariância relativamente a situações particulares, cada problema de projeto exige a construção de função de custo bastante específica, refletindo rigorosamente as restrições características de cada tipo de filtro (ou sistema composto mais geral) – esse é o papel da função $S(\mathbf{h})$. A otimização global da função objetivo é realizada encarando os coeficientes do filtro, ou seus parâmetros específicos, como coordenadas de pontos pertencentes a \mathbb{R}^N , o espaço euclidiano N-dimensional, e permitindo que o aparato central evolua em seu espaço de fase – em outras palavras, podemos identificar \mathbb{R}^N com a classe de todos os filtros digitais FIR (ou sistemas parametrizados) teoricamente possíveis e a tarefa em questão é encontrar aquele(s) satisfazendo às condições de projeto – trata-se de uma espécie de isomorfismo, no sentido estritamente matemático.

Assim, o processo principal aciona repetidamente o módulo responsável pelo cálculo de $S(\mathbf{h})$ em diferentes pontos de \mathbb{R}^N (parâmetros do filtro candidato) e a

adequação de realizações particulares guia o mecanismo de otimização global. Cada ponto submetido (gerado por Fuzzy ASA e passado à função) corresponde a um filtro (ou sistema) candidato.

Levando em conta a estrutura dos algoritmos de SA, tudo o que importa para nortear sua evolução aos mínimos globais são os valores numéricos assumidos em diferentes pontos N-dimensionais – ou seja, estamos diante da chamada modelagem caixa preta e a busca é comandada por um processo estocástico cuja meta é alcançar estados de energia potencial mínima. É importante notar que esta abordagem foi adequada também para a solução de problemas multi-objetivo, encontrados nos projetos de bancos de filtros QMF, que serão descritos no capítulo 4, sendo suficiente encapsular todas as restrições em uma única função de custo.

Por razões práticas, a cadeia de Markov simulada evolui apenas em um subconjunto compacto de \mathbb{R}^N e foi necessário determinar sua forma e fronteiras. Novamente teremos que recorrer a informações específicas, escolhendo um hiper-retângulo simétrico em relação à origem e formado pelo produto cartesiano do intervalo fechado $[-1.5, 1.5]$, considerando o fato que coeficientes de filtros “interessantes” assumem valores ali contidos. Naturalmente, é possível utilizar outras regiões, dependendo das necessidades particulares. É importante ressaltar que o método proposto pode ser útil também em situações em que não tenhamos qualquer modelo matemático estabelecido, mas apenas dados experimentais, sejam eles no domínio da frequência ou do tempo – esta é uma boa característica da abordagem caixa preta. Em consequência, é também possível realizar modelagem não-linear sem expressivas alterações no esquema geral aqui descrito, principalmente no domínio do tempo.

3.3 Resultados

Em (JOU, 2006), é proposta (e concretizada) meta similar à aqui apresentada, utilizando redes neurais de Hopfield. Tendo em vista que o referido trabalho supera diversos resultados anteriormente estabelecidos pelas mais diferentes técnicas e apresenta índices de desempenho obtidos em significativo número de casos típicos, foi escolhido como base para validação da presente pesquisa, no que concerne à parte de projeto de filtros FIR. Naquela publicação, são apresentados exemplos de projeto de filtros FIR com coeficientes reais e a qualidade do resultado final é aferida, em geral,

por meio de dois índices específicos, a saber, erro máximo de atraso de grupo na banda de passagem e erro de aproximação complexo máximo nas bandas de passagem e rejeição. Em um dos seis casos apresentados, é realizada análise mais detalhada, pela apresentação de gráficos e parâmetros adicionais relevantes. Os filtros sob análise são os seguintes:

- 1 – Passa-baixas de comprimento 31, banda de passagem [0,0.06] e de rejeição [0.12,0.5] ;
- 2 – Passa-faixa de comprimento 31, banda de passagem [0.15,0.28] e rejeição [0,0.1] e [0.33,0.5] ;
- 3 – Diferenciador de comprimento 31 e atuação em todo o espectro digital ;
- 4 – Transformador de Hilbert de comprimento 31 ;
- 5 – Equalizador de fase passa-tudo *chirp* de comprimento 61 ;
- 6 – Equalizador de fase passa-tudo com atraso senoidal de comprimento 61.

Em todos os casos, o *training set* possui $L=10 \times N$ elementos, onde N é o comprimento do filtro. Os intervalos correspondem a frequências digitais normalizadas, mapeando $[0, \pi]$ em $[0, 0.5]$. No que segue, são apresentadas comparações quantitativas entre os resultados publicados em (JOU, 2006) e os resultantes de ensaios usando as técnicas aqui propostas. Trata-se de diversos tipos de filtros FIR, como citado anteriormente, e as respectivas especificações podem ser encontradas em (PEI, 1992) e (JOU, 2006). Nas tabelas apresentadas os coeficientes vão de $h(0)$ a $h(N-1)$, começando do topo da coluna esquerda ($h(0)$ a $h((N+1)/2)$) e o restante ($h(N+3)/2$ a $h(N-1)$) na coluna direita.

3.3.1 Filtro passa-baixas

Aqui, o objetivo é sintetizar um filtro de comprimento 31 com região de transição no intervalo [0.06, 0.12] (frequências normalizadas em [0, 0.5]), atraso de grupo constante (de valor 12) na faixa de passagem. No que segue, são apresentadas nas Figuras 3.1, 3.2 e 3.3 as curvas de amplitude, atraso de grupo e erro complexo, como subsídio na avaliação dos resultados obtidos. Logo após, são apresentadas as Tabelas 3.1 e 3.2 com os índices de desempenho e os coeficientes do filtro final, respectivamente.

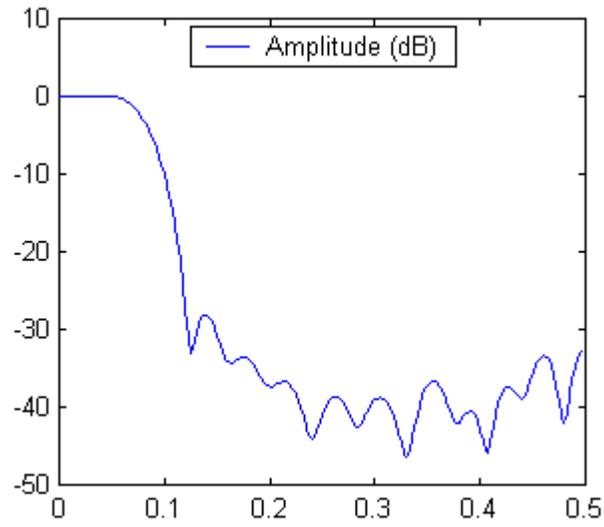


Figura.3.1 – Resposta em amplitude do filtro passa-baixas obtido com o método proposto

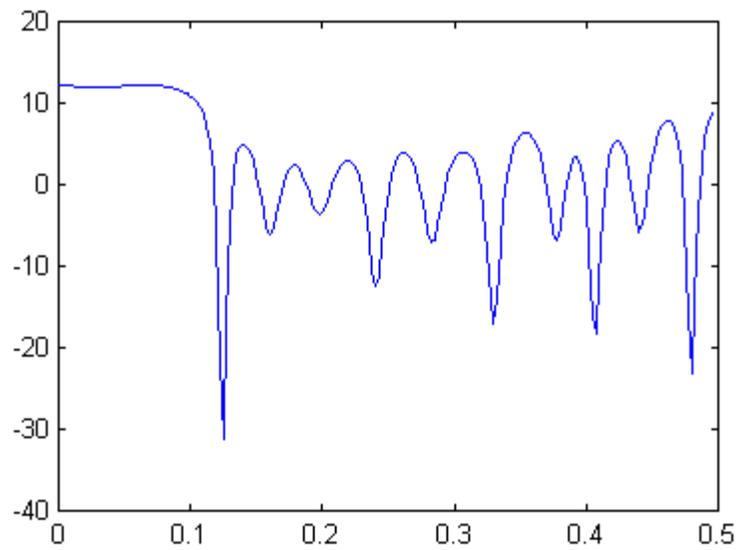


Figura 3.2. – Atraso de grupo do filtro passa-baixas obtido com o método proposto

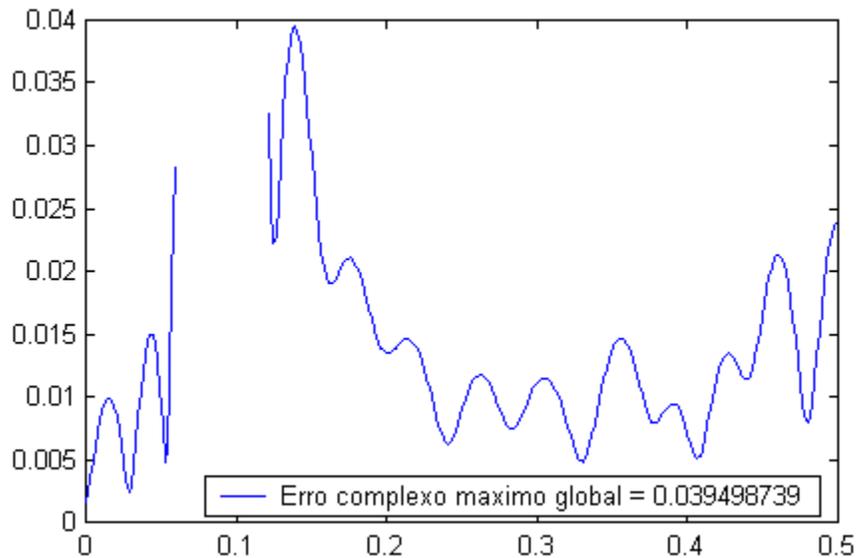


Figura.3.3 – Curva de erro complexo do filtro passa-baixas obtido com o método proposto

Tabela 3.1 - Comparação de índices de desempenho

Método	Erro complexo máximo (δ_p)	Erro de atraso de grupo (δ_τ)
Proposto	0.039498739	0.216474821
(JOU, 2006)	0.04133	0.7561

Pela Tabela 3.1, vemos que o método proposto superou a referência em ambos os índices, com drástica redução do erro de atraso de grupo (mais de 66 %), evidenciando sua superioridade em relação às abordagens anteriores.

Tabela 3.2 – Coeficientes do filtro passa-baixas obtido com o método proposto

1.349989443668622e-02	5.720072397381920e-02
1.980894802625944e-03	1.731486224171908e-02
-5.586728703016548e-03	-1.133800450532968e-02
-2.149367825236150e-02	-2.578683249690682e-02
-2.849856254089745e-02	-2.681317747558221e-02
-2.875172805751363e-02	-2.232509939706425e-02
-1.180218048197043e-02	-1.018067370656033e-02
1.612390728738528e-02	-6.853932545930690e-04
5.645380562705649e-02	5.403415522879101e-03
1.007362778396794e-01	5.589934132254323e-03
1.407489496234829e-01	6.710302512011429e-03
1.710290092402127e-01	2.812178594097918e-03
1.793598207596891e-01	3.331134697178051e-03
1.696267149856781e-01	3.824232834171439e-04
1.418343559260497e-01	8.731735682015346e-04
1.005843750379121e-01	

3.3.2 Filtro passa-faixa

Aqui, o objetivo é sintetizar um filtro de comprimento 31 com somente uma faixa de passagem em $[0.15, 0.28]$, duas de rejeição em $[0.0, 0.1]$ e $[0.33, 0.50]$, e atraso de grupo constante, igual a 12. Este exemplo será mais detalhado que os demais, para compatibilização com o tratamento dado pela publicação usada como padrão. No que segue, são apresentadas as curvas de amplitude e atraso de grupo. Logo após, são apresentadas as tabelas com índices de desempenho e coeficientes do filtro final.

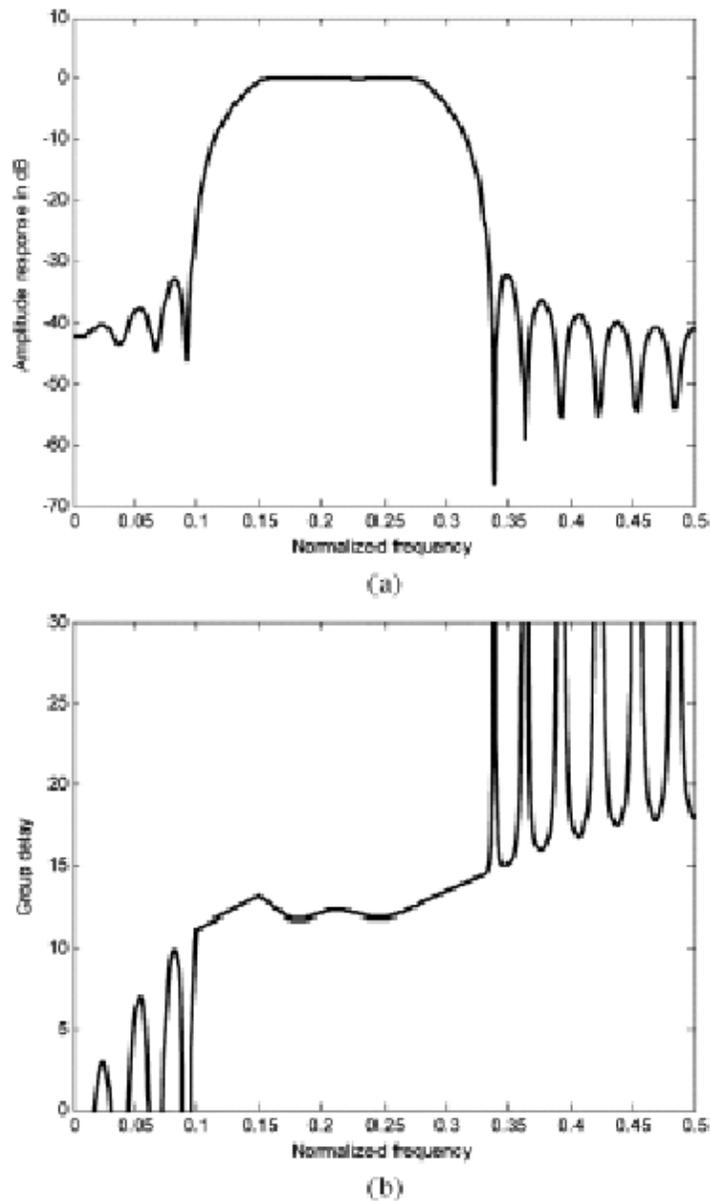


Figura 3.4 – Resposta de amplitude (em dB) (a) e gráfico do atraso de grupo (b) obtidas em (JOU, 2006)

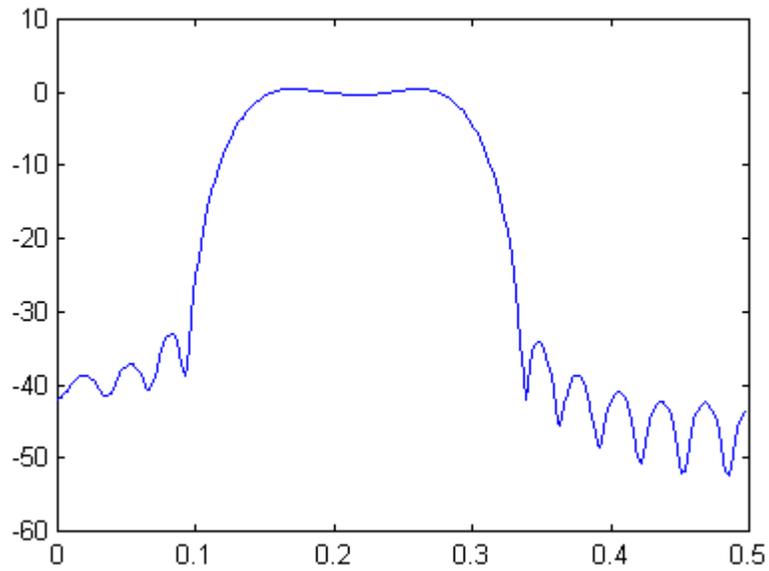


Figura 3.5 – Resposta de amplitude (em dB) do filtro passa-faixa com o método proposto

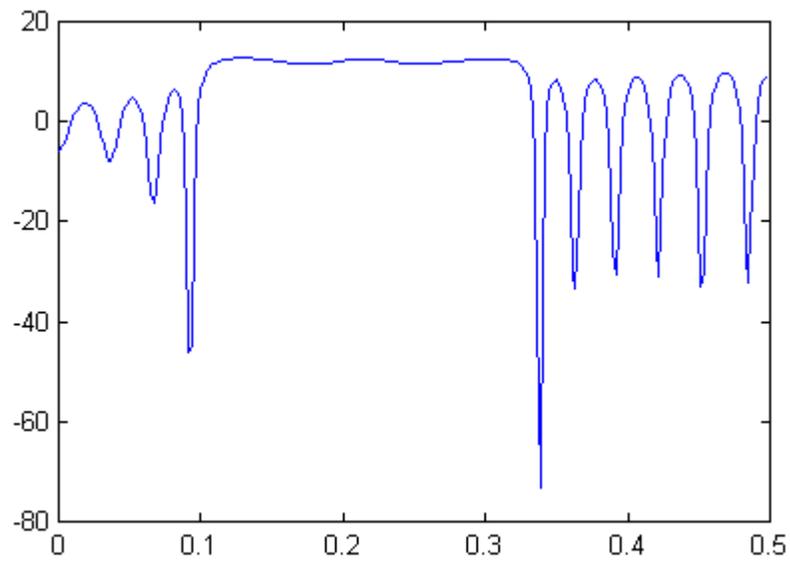


Figura 3.6 – Curva de atraso de grupo do filtro passa-faixa com o método proposto

Tabela 3.3 - Comparação de índices de desempenho especiais

Grandeza	(JOU, 2006)	Proposto
Erro no limite esquerdo da banda de passagem	0.0627	0.0575
Erro no limite direito da banda de passagem	0.0587	0.0524
Erro no primeiro lobo esquerdo	0.0239	0.0224
Erro no primeiro lobo direito	0.0223	0.0196
Módulo do erro complexo máximo	0.06266	0.06089
Erro máximo de atraso de grupo na banda de passagem	0.7561	0.5489
Valor mínimo do atraso de grupo na banda de passagem	11.68	11.4656
Valor máximo do atraso de grupo na banda de passagem	13.08	12.5489
Amplitude da excursão do atraso de grupo na banda de passagem	1.40	1.0833

Tabela 3.4 - Comparação de índices de desempenho

Método	Erro complexo máximo (δ_p)	Erro de atraso de grupo (δ_τ)
Proposto	6.089e-02	0.5489
(JOU, 2006)	6.266e-02	1.080

O training set possui 310 (=10x31) elementos na pesquisa descrita em (JOU, 2006) e 100 elementos no presente trabalho, o que representa uma redução substancial no esforço computacional e tem importante impacto no desempenho geral do algoritmo. Pelas Tabelas 3.3 e 3.4, vemos que o método proposto superou a referência em todos os índices. Fica comprovada a eficácia da nova abordagem em mais este projeto, considerando que alguns índices de desempenho foram superados drasticamente, como no caso do erro de atraso de grupo.

Tabela 3.5 – Coeficientes do filtro passa-faixa obtido com o método proposto

-0.001837914476369	0.073708129357635
0.009935750560736	0.031666242086951
-0.019251362346424	0.006345985585397
-0.049861827100943	0.055649617634259
0.010528920995195	0.011587428546593
0.055915070756933	-0.044244284103041
0.006393823781558	-0.015580084869688
0.032228526486936	0.001475111214787
0.073932276963528	-0.011019340846704
-0.124760866532111	0.005664410859877
-0.257499929241588	0.018058207255140
0.074193478705421	0.002728094197810
0.361484282182677	-0.003688819770780
0.074213670077878	-0.000193237176018
-0.258049931324484	-0.002536687445088
-0.125161532135573	

3.3.3 Diferenciador de comprimento 31 e atuação em todo o espectro digital [0, 0.5]

Aqui, o objetivo é sintetizar um diferenciador *full-band* de comprimento 31 e atraso de grupo constante (de valor 11.5). No que segue, são apresentadas nas Figuras 3.7 a 3.10, as curvas de amplitude, atraso de grupo, erro complexo e erro de atraso de grupo, respectivamente, como subsídio na avaliação dos resultados obtidos. Logo após, são apresentados nas Tabelas 3.6 e 3.7 os índices de desempenho do método proposto e do método apresentado em (JOU, 2006) e os coeficientes do filtro final.

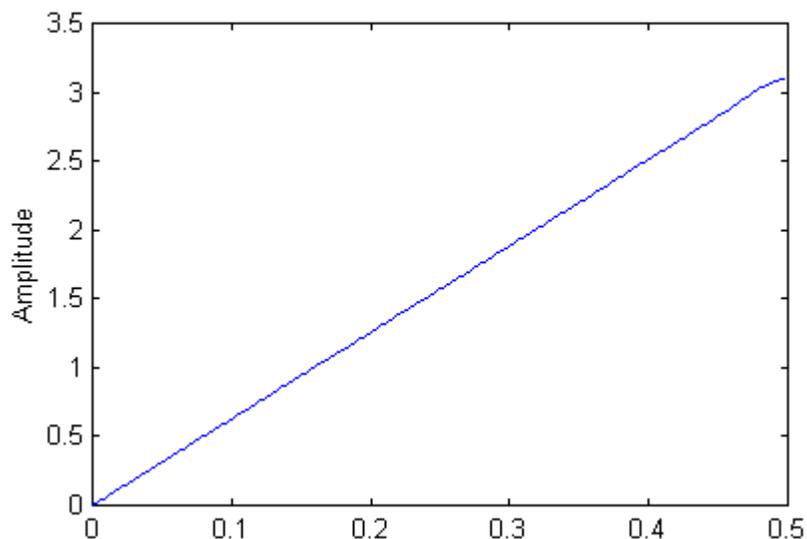


Figura 3.7 – Resposta em amplitude (escala linear) do diferenciador obtido com o método proposto

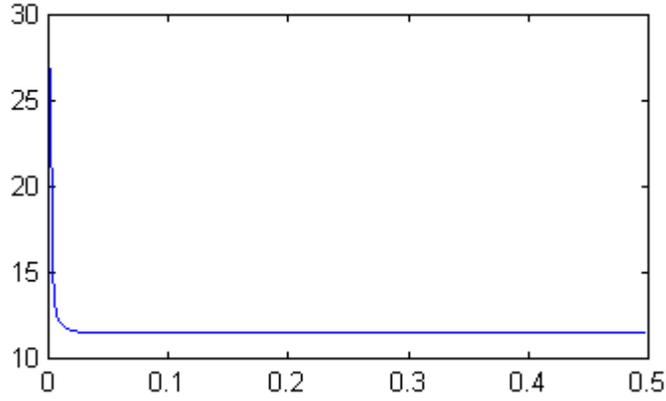


Figura 3.8 – Atraso de grupo do diferenciador obtido com o método proposto

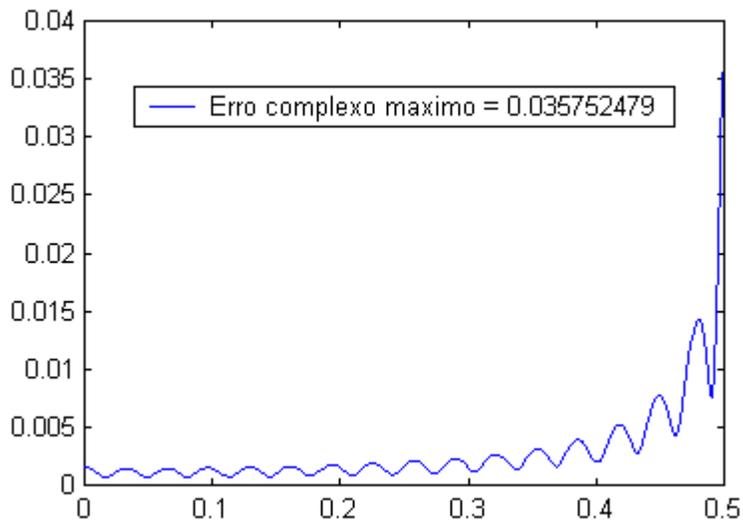


Figura 3.9 – Curva de erro complexo do diferenciador obtido com o método proposto

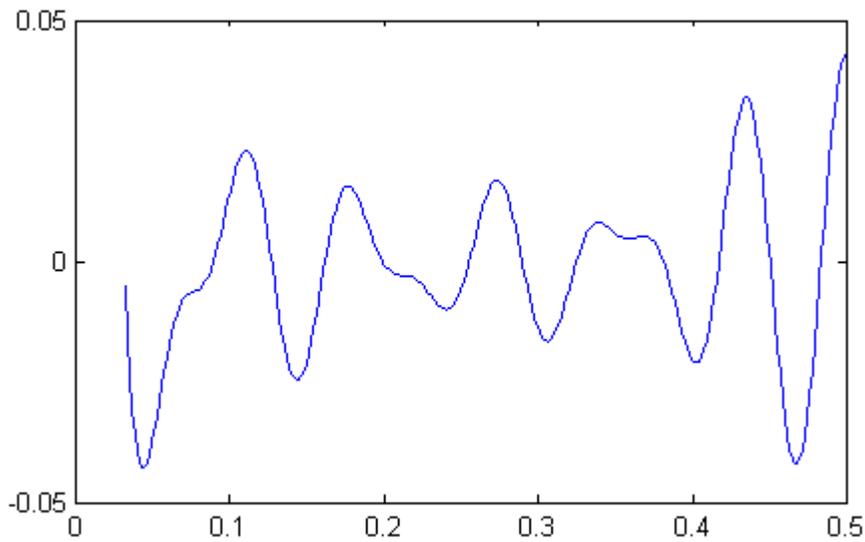


Figura 3.10 – Curva de erro de atraso de grupo do diferenciador obtido com o método proposto

Tabela 3.6 - Comparação de índices de desempenho

Método	Erro complexo máximo (δ_p)	Erro de atraso de grupo (δ_τ)
Proposto	0.035752479	0.043378279
(JOU, 2006)	0.0387	0.04700

Tabela 3.7 – Coeficientes do diferenciador obtido com o método proposto

-2.300695395772896e-03	-1.561274268229096e-02
2.773171551021691e-03	1.040863544384022e-02
-3.420882040419089e-03	-7.427712974026234e-03
4.291598790758755e-03	5.544843999880523e-03
-5.552589252469246e-03	-4.299426108708702e-03
7.419957266044321e-03	3.412983243645453e-03
-1.041631368849310e-02	-2.780919525223281e-03
1.560500766975468e-02	2.292883608353818e-03
-2.587822362156436e-02	-1.930865782449006e-03
5.081483266452708e-02	1.632616263143591e-03
-1.413647916390944e-01	-1.407717926708983e-03
1.273125477969229e+00	1.210970240702396e-03
-1.273133264999064e+00	-1.062956203743569e-03
1.413570777234438e-01	9.253631871798264e-04
-5.082331990768506e-02	-8.240982630120161e-04
2.587046097726104e-02	

Pela Tabela 3.6, vemos que o método proposto superou a referência em ambos os índices, oferecendo redução de aproximadamente 10% nos módulos do erro complexo máximo e do erro de atraso de grupo. Mais uma vez, sua eficácia foi comprovada.

3.3.4 Transformador de Hilbert de comprimento 31

Aqui, o objetivo é sintetizar um transformador de Hilbert de banda larga com comprimento 31, $\omega_L=0.05$ (frequência de corte inferior normalizada), $\omega_H=0.5$ (frequência de corte superior normalizada) e atraso de grupo igual a 11.5 . No que segue, são apresentadas, nas Figuras 3.11 a 3.16, as curvas de amplitude, atraso de grupo, erro complexo e detalhes das duas primeiras, para melhor avaliação dos resultados. Logo após, são apresentados nas Tabelas 3.8 e 3.9 os índices de desempenho do método proposto e do método apresentado em (JOU, 2006) e coeficientes do filtro final.

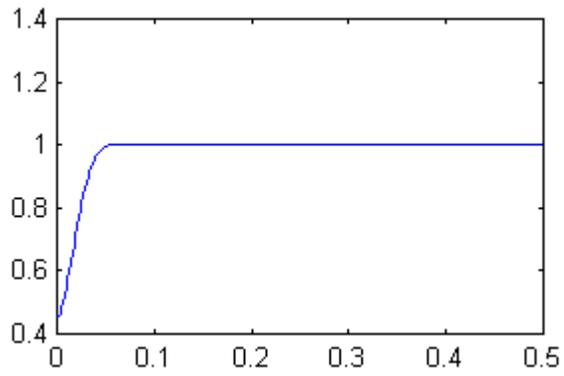


Figura 3.11 – Resposta em amplitude do transformador de Hilbert obtido com o método proposto

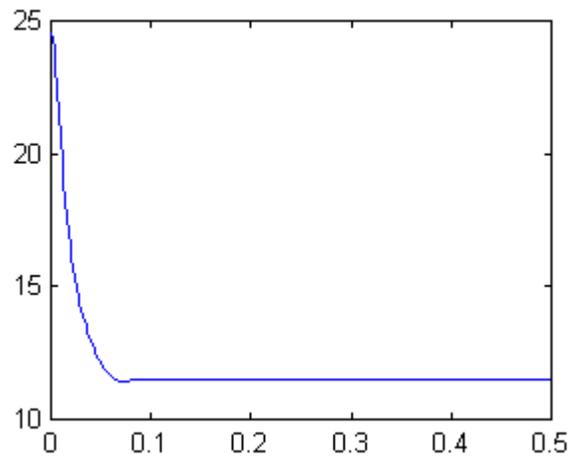


Figura 3.12 – Atraso de grupo do transformador de Hilbert obtido com o método proposto

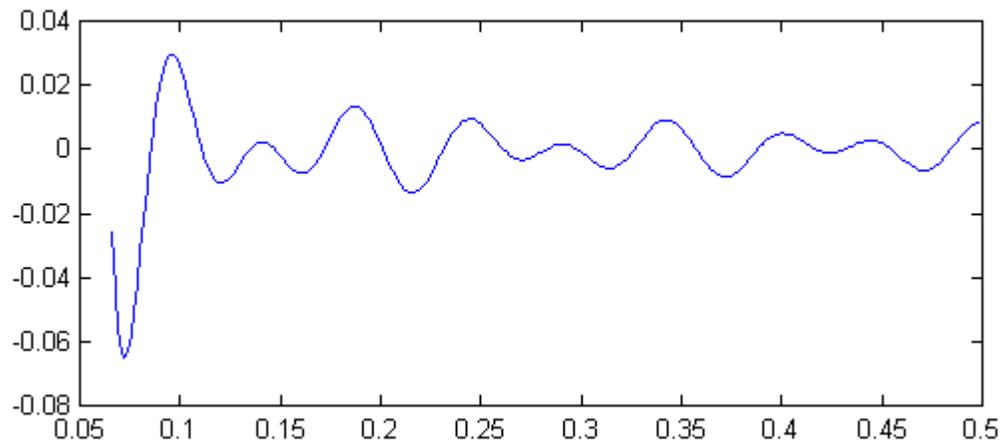


Figura 3.13 – Curva de erro de atraso de grupo do transformador de Hilbert obtido com o método proposto

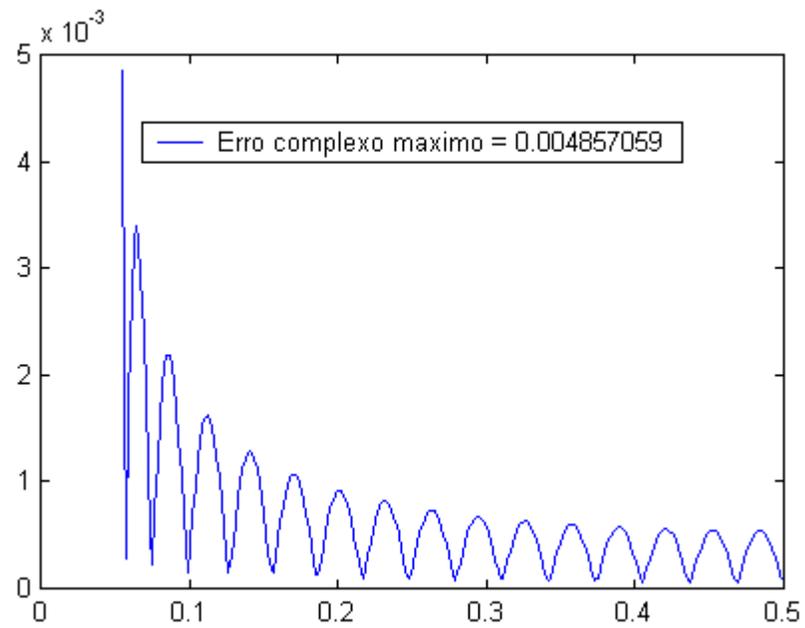


Figura 3.14 – Curva de erro complexo do transformador de Hilbert obtido com o método proposto

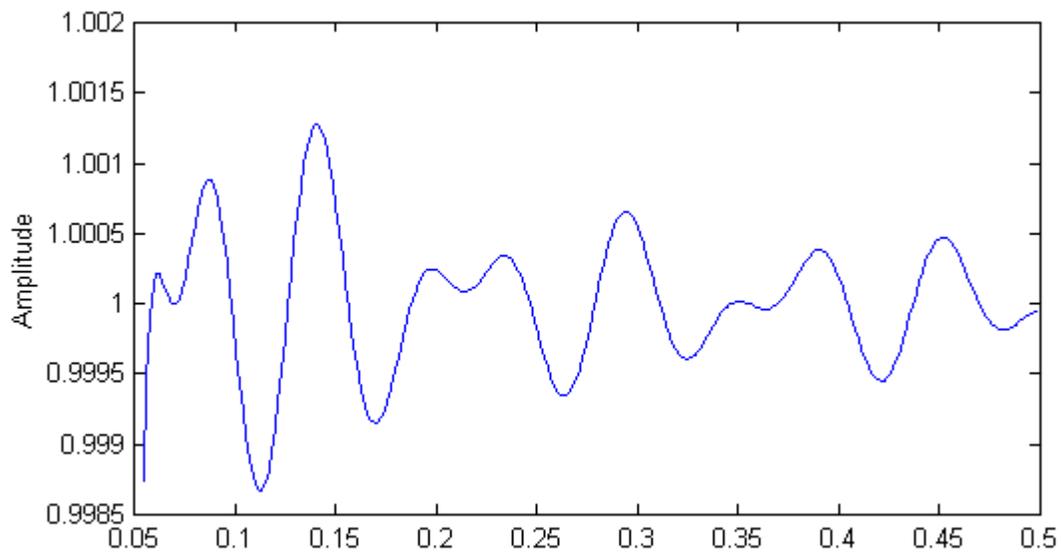


Figura 3.15 – Zoom da resposta em amplitude (escala linear) do transformador de Hilbert obtido com o método proposto

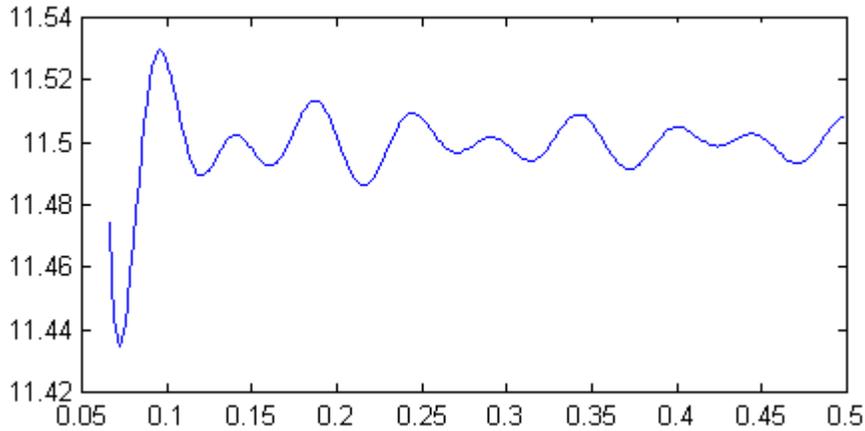


Figura 3.16 – Zoom da curva de atraso de grupo do transformador de Hilbert obtido com o método proposto

Tabela 3.8 - Comparação de índices de desempenho

Método	Erro complexo máximo (δ_p)	Erro de atraso de grupo (δ_τ)
Proposto	0.004857059	0.065050112
(JOU, 2006)	0.01050	0.07560

Pela Tabela 3.8, vemos que o método proposto superou a referência em ambos os índices, com expressiva redução do erro complexo máximo (superior a 50%) e razoável melhora do erro de atraso de grupo (superior a 10%).

Tabela 3.9 – Coeficientes do transformador de Hilbert obtido com o método proposto

-1.067498402126269e-03	8.088234899873083e-02
-2.292876910821742e-03	6.443986102801079e-02
-4.205474523564142e-03	5.200523688763421e-02
-7.067728770631233e-03	4.207804646689279e-02
-1.124070199496255e-02	3.390073951622692e-02
-1.727424020748538e-02	2.705186589338856e-02
-2.605776712608001e-02	2.128647013965200e-02
-3.921742220559379e-02	1.644387319876482e-02
-6.017734383381798e-02	1.241476971640638e-02
-9.777335594167726e-02	9.108423876203203e-03
-1.843389043046776e-01	6.447583616208436e-03
-6.108838520361685e-01	4.359358816587151e-03
6.598137962219037e-01	2.771492663960441e-03
2.324983196950823e-01	1.608869923657880e-03
1.444211798341833e-01	8.035104048487328e-04
1.046318500977753e-01	

3.3.5 Equalizador de fase passa-tudo *chirp* de comprimento 61

Este caso lida com equalizadores de fase *chirp* digitais com a seguinte especificação:

Fase

$$\Phi(\omega) = -M \omega - (8/\pi)(\omega - \pi/2)^2, \quad (3.1)$$

onde $M=(N-1)/2$, N = comprimento do filtro e ω varia em $[0,\pi]$.

Conseqüente atraso de grupo

$$\tau(\omega) = M + (16/\pi)(\omega - \pi/2) \quad (3.2)$$

O atraso aumenta linearmente com a frequência e a resposta de fase é simétrica em torno de $\omega = \pi/2$. Nas Figuras 3.17 a 3.20, são apresentadas as curvas de amplitude, atraso de grupo, erro de atraso de grupo e erro complexo, como subsídio na avaliação dos resultados obtidos. Nas Tabelas 3.10 e 3.11, são apresentados os índices de desempenho do método proposto e do método apresentado em (JOU, 2006) e os coeficientes do filtro final.

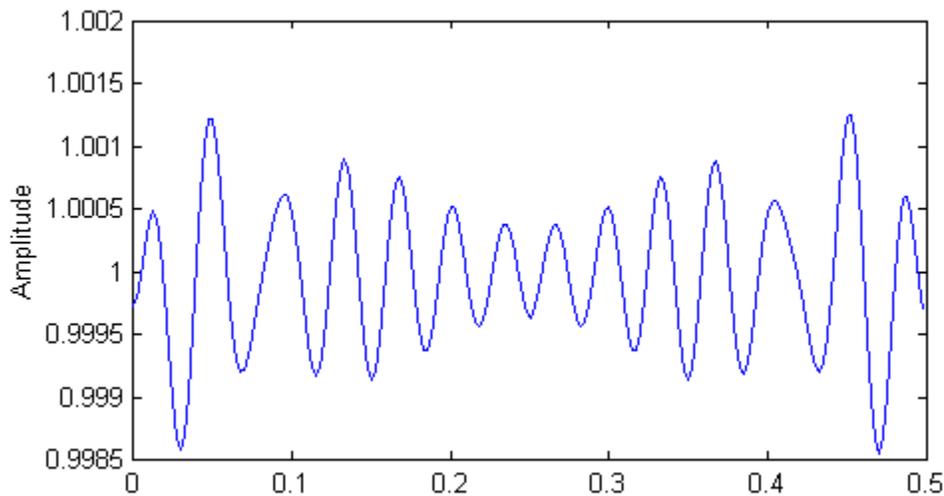


Figura 3.17 – Resposta em amplitude do equalizador obtido com o método proposto

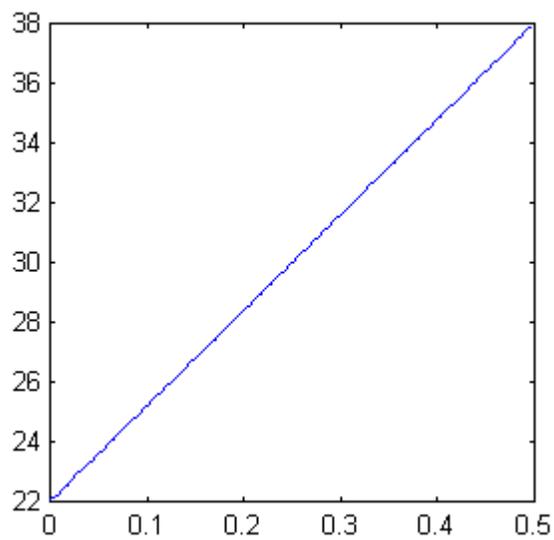


Figura 3.18 – Atraso de grupo do equalizador obtido com o método proposto

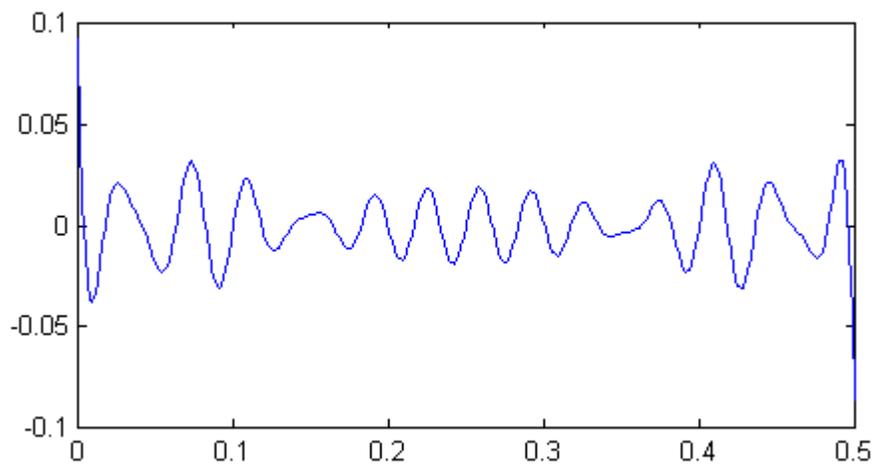


Figura 3.19 – Curva de erro de atraso de grupo do equalizador obtido com o método proposto

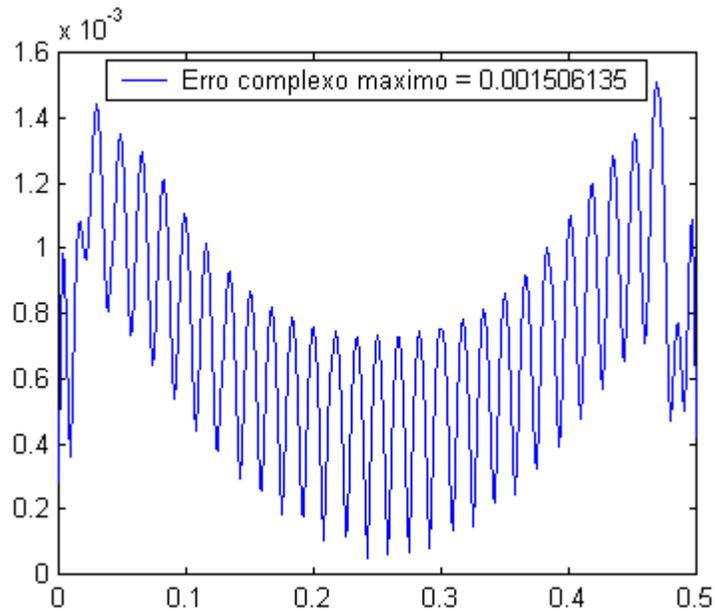


Figura 3.20 – Curva de erro complexo do equalizador obtido com o método proposto

Tabela 3.10 - Comparação de índices de desempenho

Método	Erro complexo máximo (δ_p)	Erro de atraso de grupo (δ_τ)
Proposto	0.001506135	0.091932242
(JOU, 2006)	0.001775	0.09231

Pela Tabela 3.10, vemos que o método proposto superou a referência em ambos os índices de desempenho. Pode-se notar, pela Figura 3.19, que o erro de atraso de grupo apresentou valores bastante reduzidos e inferiores a 0.05 em quase todo o espectro digital.

Tabela 3.11 – Coeficientes do equalizador de fase chirp obtido com o método proposto

3.313303520252225e-04	2.263760989433543e-01
5.672304775414883e-04	-3.344638468033943e-01
2.714731935017642e-04	4.310167412013595e-02
4.560376596938199e-04	2.336363083192074e-01
2.772313609273251e-04	-3.270092164590118e-01
4.470385749213093e-04	2.826364245184882e-01
3.579940248035949e-04	-1.994568420390955e-01
5.533844741341641e-04	1.245963964461532e-01
5.312504886530475e-04	-7.462365778283912e-02
7.985525603602873e-04	4.312267197468608e-02
8.535101033166874e-04	-2.578300461464391e-02
1.267682102620685e-03	1.522197481350891e-02
1.479432086681568e-03	-9.792692220278145e-03
2.209201203986525e-03	6.090362812034013e-03
2.824605013853976e-03	-4.320116494697702e-03
4.327872884014264e-03	2.811325188826758e-03
6.104585480364666e-03	-2.195261273374173e-03
9.793566661477144e-03	1.467863338444998e-03
1.523632496965955e-02	-1.248672272694228e-03
2.577676077175936e-02	8.443172484880232e-04
4.313630623540846e-02	-7.757844969020960e-04
7.461056812398334e-02	5.248517801194346e-04
1.246084745646782e-01	-5.280635002244193e-04
1.994376322352981e-01	3.541130838678464e-04
2.826462289355945e-01	-4.199778831353898e-04
3.269850343847225e-01	2.742590079785664e-04
2.336432140733921e-01	-4.278663732370898e-04
-4.312938353072857e-02	2.656370141286883e-04
-3.344602822975485e-01	-5.392912892221758e-04
-2.264056247966048e-01	3.165779613651861e-04
2.441238502851920e-01	

3.3.6 Equalizador de fase passa-tudo com atraso senoidal de comprimento 61

Este caso trata do projeto de filtro passa-tudo com ganho unitário e resposta em fase dada por

$$\Phi(\omega) = -M \omega - 2 \pi \cos(\omega) \quad (3.3)$$

onde $M=(N-1)/2$, N = comprimento do filtro e ω varia em $[0,\pi]$.

Em conseqüência, o atraso de grupo é dado por $\tau(\omega) = M - 2 \pi \sin(\omega)$.

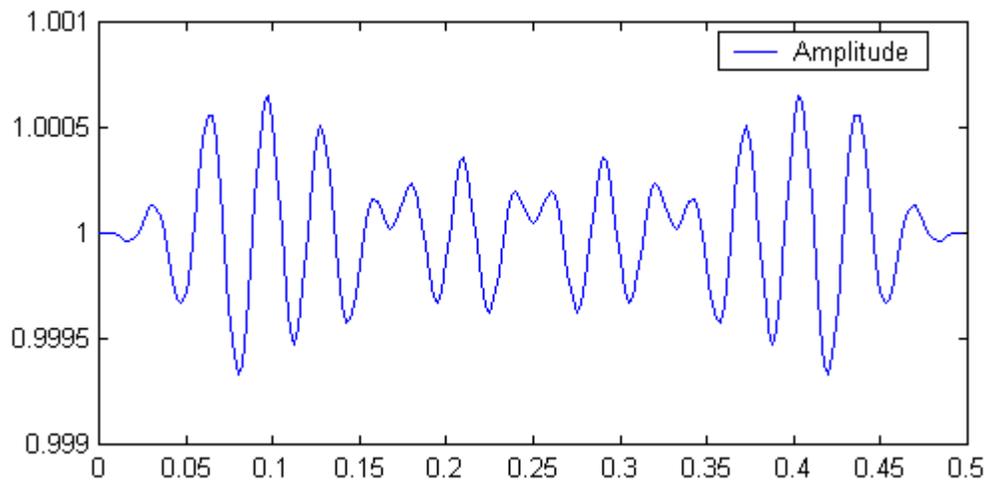


Figura 3.21 – Resposta em amplitude (escala linear) do equalizador obtido com o método proposto

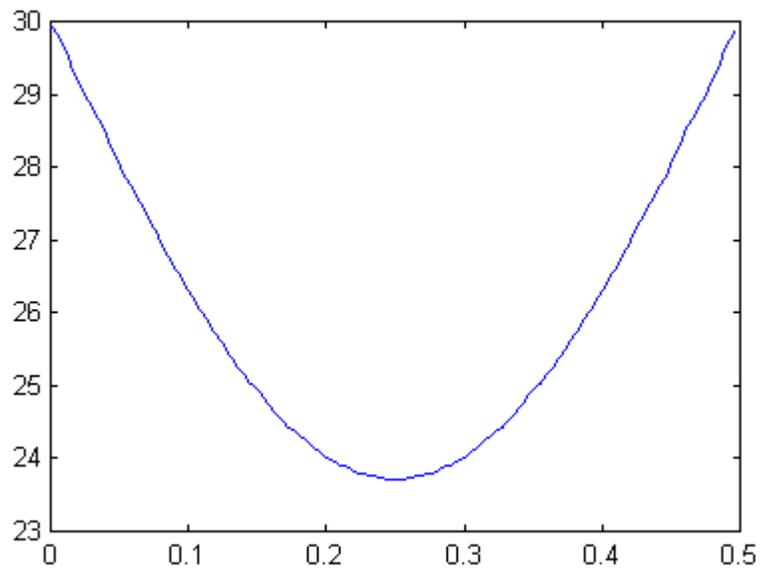


Figura 3.22 – Atraso de grupo do equalizador obtido com o método proposto

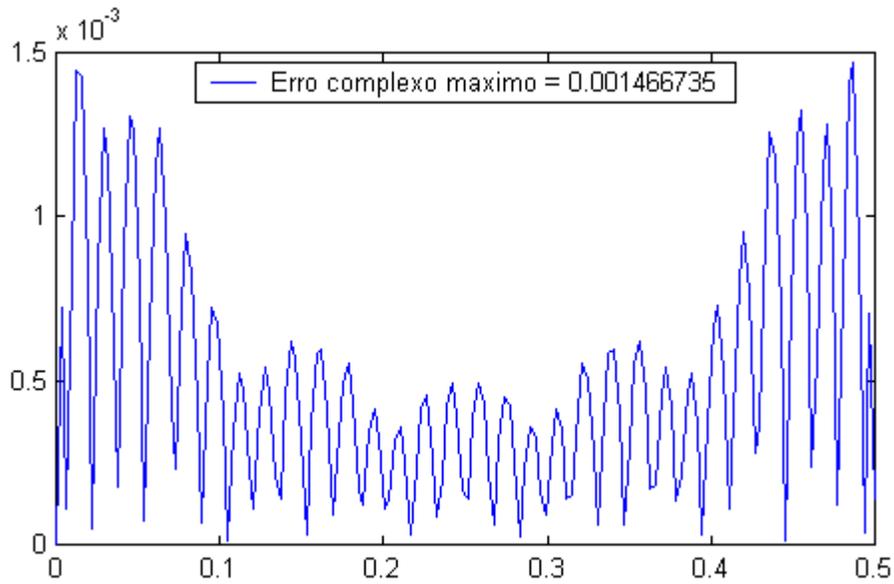


Figura 3.23 – Curva de erro complexo do equalizador obtido com o método proposto

Tabela 3.12 - Comparação de índices de desempenho

Método	Erro complexo máximo (δ_p)	Erro de atraso de grupo (δ_τ)
Proposto	0.001466735	0.088732403
(JOU, 2006)	0.001588	0.09830

Pela Tabela 3.12, vemos que o método proposto superou a referência em ambos os índices, reduzindo em aproximadamente 10% os valores dos erros apresentados em (JOU, 2006) e evidenciando, uma vez mais, sua eficácia.

Tabela 3.13 – Coeficientes do equalizador obtido com o método proposto

-4.203805455009930e-04	0.00000
0.00000	8.523424042303883e-02
-3.685652615134307e-04	0.00000
0.00000	3.359228009317205e-02
-3.502164230926212e-04	0.00000
0.00000	1.454205724613560e-02
-3.666319672442465e-04	0.00000
0.00000	7.094900560162374e-03
-4.066932095494393e-04	0.00000
0.00000	3.842872804071504e-03
-4.685477427932168e-04	0.00000
0.00000	2.289897391547230e-03
-7.014383800246077e-04	0.00000
0.00000	1.463033805840513e-03
-9.896010677664139e-04	0.00000
0.00000	9.926360012364303e-04
-1.570226138650236e-03	0.00000
0.00000	7.018642536107877e-04
-5.275019359728725e-04	0.00000
0.00000	4.714267850738611e-04
-2.412287634084593e-02	0.00000
0.00000	4.106181303323064e-04
1.395102919207290e-01	0.00000
0.00000	3.732036513588636e-04
-5.699249973981046e-01	0.00000
0.00000	3.512385395700095e-04
5.977756217915143e-01	0.00000
0.00000	3.672223488506539e-04
4.905200826608643e-01	0.00000
0.00000	4.066262600110443e-04
2.202753879678499e-01	

3.4 – Conclusões – projeto de filtros digitais FIR

Neste capítulo foi proposta uma técnica baseada em algoritmos de otimização global não linear estocástica cujo objetivo é ajustar a resposta de filtros digitais FIR lineares e invariantes no tempo a funções complexas de resposta em frequência $H_d(\omega) = A(\omega)\exp(j\phi(\omega))$ (transformada de Fourier discreta no tempo) arbitrárias. O objetivo final é obter os coeficientes reais $h(n)$, $n=0,\dots,N-1$ do filtro digital FIR LTI e ordem $N-1$ (comprimento N), cuja resposta em frequência aproxime com erro mínimo a curva modelo.

Para esse fim, foram sintetizadas funções objetivo que retratam as várias condições de contorno características de cada tipo de filtro (foram examinados seis tipos de dispositivos) e procedeu-se à sua minimização, tendo como variáveis os parâmetros dos filtros propriamente ditos. Em cada um dos casos, foram feitas comparações com os respectivos resultados apresentados em (JOU, 2006), para aferição da eficácia da nova abordagem aqui proposta. Em cada um deles, o método aqui proposto superou os publicados em (JOU, 2006), demonstrando sua utilidade e proporcionando mais uma alternativa ao projeto de filtros FIR com resposta complexa arbitrária.

CAPÍTULO 4

PROJETO DE BANCOS QMF

4.1 Introdução

Em atividades práticas de processamento de sinais, há freqüente interesse em separar a informação contida em diferentes faixas de freqüência. Por exemplo, para estimar o conteúdo de alta freqüência de uma imagem, a fim de localizar suas bordas, ou filtrar ruído de alta freqüência em sinais de áudio, objetivando melhorar sua qualidade.

Em tais situações, necessitamos de informação em todas as regiões do espectro de freqüências, de modo a determinar a importância de cada uma delas, no que se refere à quantidade de informação. Logo, é fácil perceber a necessidade de filtragem em diversas bandas, decompondo o sinal original para fins de análise, transmissão ou armazenamento, e sua posterior recomposição. Esta operação pode ser realizada de modo eficiente utilizando bancos de filtros. No que segue, descreveremos sucintamente a estrutura dos bancos QMF (Quadrature Mirror Filter), que possuem estrutura extremamente simples e, ao mesmo tempo, são eficazes em grande parte das aplicações reais, especialmente quando associados em certos tipos de configurações.

Consideremos o diagrama de um banco QMF de 2 canais mostrado na Figura 4.1, onde os filtros H_0 e H_1 integram o banco de análise, e F_0 e F_1 o de síntese.

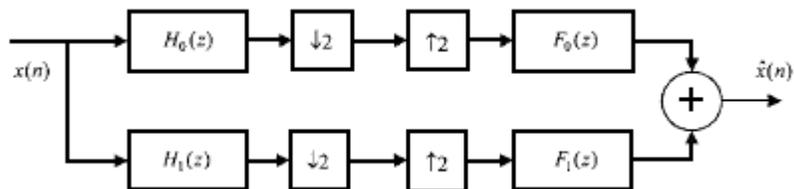


Figura 4.1 – Banco de filtros de 2 canais.

A expressão do sinal reconstruído é

$$\hat{X}(z) = T(z)X(z) + A(z)X(-z) \quad (4.1)$$

onde $T(z)$ e $A(z)$ representam a função de transferência de todo o conjunto (ou função de distorção) e função de *aliasing*, respectivamente, sendo expressas por

$$T(z) = \frac{1}{2} [H_0(z)F_0(z) + H_1(z)F_1(z)] \quad (4.2)$$

$$A(z) = \frac{1}{2} [H_0(-z)F_0(z) + H_1(-z)F_1(z)] \quad (4.3)$$

Para efetuar reconstrução perfeita, o sistema não pode apresentar *aliasing*, nem distorção de fase ou amplitude. Para eliminar o primeiro efeito, fazemos $A(z)=0$. Para isso, podemos impor

$$F_0(z) = H_1(-z) \text{ e } F_1(z) = -H_0(-z) \quad (4.4)$$

Consequentemente, a função de distorção torna-se

$$T(z) = \frac{1}{2} [H_0(z)H_1(-z) - H_0(-z)H_1(z)] \quad (4.5)$$

Mas, como o filtro passa-altas complementar tem a restrição $H_1(z)=H_0(-z)$, a função de distorção vem a ser

$$T(z) = \frac{1}{2} [H_0^2(z) - H_0^2(-z)] \quad (4.6)$$

que é completamente determinada pelo filtro-protótipo $H_0(z)$, do banco de análise.

Infelizmente, as condições para reconstrução perfeita são demasiadamente restritivas, levando à adoção da chamada reconstrução quase perfeita, a qual é efetuada por meio de filtros-protótipo FIR com fase linear. Usando as expressões anteriores e expressando o filtro-protótipo H_0 no domínio da frequência como

$$H_0(\omega) = e^{-j\omega N/2} R(\omega) \text{ e } |H_0(\omega)| = |R(\omega)| \quad (4.7)$$

obtemos a seguinte expressão da função de transferência global

$$\begin{aligned}
T(\omega) &= \frac{1}{2} [H_0^2(\omega) - H_0^2(\omega - \pi)] \\
&= \frac{1}{2} e^{-j\omega N} [|H_0(\omega)|^2 - (-1)^N |H_0(\omega - \pi)|^2]
\end{aligned} \tag{4.8}$$

Para evitar o caso de distorção indesejável ($T(\omega) = 0$ em $\omega = \pi/2$), precisamos que N (ordem do filtro H_0) seja ímpar, o que implica em

$$T(\omega) = \frac{1}{2} e^{-j\omega N} [|H_0(\omega)|^2 + |H_0(\omega - \pi)|^2] \tag{4.9}$$

Resultando em um sistema global com fase linear e, conseqüentemente, na eliminação da distorção de fase. Logo, resta apenas tratar da minimização da distorção de amplitude, o que é equivalente a impor que o módulo de $T(\omega)$ seja próximo da unidade, ou seja, quanto mais “plana” for a expressão $|H_0(\omega)|^2 + |H_0(\omega - \pi)|^2$, melhor será a reconstrução. Se $|H_0(\omega)|^2 + |H_0(\omega - \pi)|^2 = 1$, para todo ω em $[0, \pi]$, a reconstrução será perfeita, caso contrário, o sinal reconstruído terá amplitude distorcida pelo termo $|H_0(\omega)|^2 + |H_0(\omega - \pi)|^2$, desconsiderando o fator $1/2$. Em conclusão, é necessário sintetizar filtros-protótipo satisfazendo, com a maior precisão possível, a condição acima. Nesse contexto, podemos enunciar:

“Dados um inteiro N (ordem do filtro), o valor de atenuação mínima na faixa de rejeição e o erro de reconstrução máximo, obter os coeficientes reais $h_0(n)$, $n=0, \dots, N$, de um filtro-protótipo (aqui denominado H_0) com resposta finita ao impulso e comprimento $N+1$, cuja resposta em frequência realize de modo ótimo um banco de filtros com reconstrução quase perfeita, e respeitando as condições de projeto, por meio do seguinte algoritmo:

- Determinar as abscissas do *training set*, usado no processo de ajustamento, que são valores de frequências ω_i , $i=1, \dots, T$, com $\omega_i \in [0, \pi]$ e T igual à cardinalidade do conjunto em questão. Note-se que não há quaisquer imposições geométricas sobre os valores de ω_i , como espaçamento uniforme, etc.;

- Construir a função-objetivo

$$\begin{aligned}
S(h) &= \alpha \sum \{ (1 - |H(\omega_i)|)^2 : \omega_i \in I_P \} + (1 - \alpha) \sum W(i) (1 - |H(\omega_i)|^2 - |H(\omega_i - \pi)|^2)^2 : \omega_i \in [0, \pi] \} \\
&\quad + \alpha \sum \{ |H(\omega_i)|^2 : \omega_i \in I_R \}
\end{aligned} \tag{4.10}$$

onde $H(\cdot)$ representa o ganho de um filtro LTI com fase linear de coeficientes reais $\{h(n) : n=0, \dots, N\}$, $W(\cdot)$ é uma função real de ponderação, utilizada para condicionamento numérico, não sendo necessariamente diferenciável ou contínua, I_P a faixa de passagem, I_R a faixa de rejeição e α o parâmetro de ponderação, que também sofrerá treinamento e está restrito ao intervalo $[0,1]$;

- Submeter a função $S(h)$ ao algoritmo de otimização global (no caso, Fuzzy ASA) e obter os parâmetros $h_0(n)$, $n=0, \dots, N$, que a minimizam. Tais valores determinarão o filtro ótimo H_0 , no sentido L_2 ponderado.”

4.2 Implementação

Nesta seção são expostos alguns detalhes específicos da função objetivo usada para o projeto de bancos de filtros QMF. Por se tratar de método uniforme, poder-se-á notar que a estrutura fundamental do código é similar àquela usada em projetos de filtros FIR anteriormente apresentada. Para ilustração, apresentamos o código usado para o caso 64E no Anexo 2. A seguir, serão fornecidos os detalhes relevantes.

O ajuste de nível de atenuação na faixa de rejeição é realizado por meio de uma constante (ERRO_STOPBAND) que permite, pela penalização realizada por parcela de diferença quadrática, variações controladas do ganho do filtro-protótipo na referida banda. A ponderação da curva de erro é, mais uma vez, materializada através de um sistema de inferência fuzzy, que, após período de estabilização numérica, é ativado e visa equalizar os valores dos erros individuais em cada ponto de treinamento, com vistas a reduzir o valor máximo do erro de reconstrução. Esta última meta possui reforço adicional pela introdução de parcela diretamente proporcional ao referido valor, na função objetivo.

Outro aspecto notável consiste na ponderação adicional dos picos de amplitude de erro na faixa de rejeição dos filtros-protótipo., como encontrado no cálculo do valor da função objetivo. Para complementar a exposição, o código-fonte correspondente ao sistema fuzzy SISO é mostrado no Anexo 3.

Pela análise do código, é possível ver que foram usadas funções de pertinência de entrada triangulares e, as de saída, são concentradas em valores *crisp* (os chamados *singletons*), conferindo grande eficiência à implementação do esquema de ponderação sem prejuízo da meta final proposta, a saber, uniformizar os valores da curva de erro de

reconstrução, reduzindo seu máximo valor final. Tal método apresenta vantagens substanciais sobre os tradicionais que implementam WLS, tendo-se em conta que a função de ponderação é construída em função da curva de erro real (em *run time*) e adaptativa em relação às várias instâncias de execução do programa, ao contrário da situação usual, em que preestabelecemos uma função específica de ponderação, com expressão analítica fixa durante as diversas encarnações dos processos de ajustamento.

4.3 Resultados – comparação a projetos anteriores

Em (JOHNSTON, 1980) é proposto um método de projeto de bancos de filtros QMF de dois canais utilizando o método de otimização global de Hooke e Jeeves. Tendo em vista que o referido trabalho estabelece diversos resultados usados como padrão de comparação desde sua publicação, apresentando índices de desempenho e coeficientes dos respectivos filtros-protótipo obtidos em significativo número de casos, foi escolhido como base para validação da presente pesquisa, no que concerne à parte de projeto de bancos de filtros QMF¹. Naquela publicação, são apresentados exemplos de projeto em 16 casos e a qualidade do resultado final é aferida por meio de dois índices específicos, a saber, erro máximo de reconstrução em todo o espectro digital (sistema global) e atenuação mínima na faixa de rejeição (filtro-protótipo). Em cada um dos 16 casos apresentados, a frequência correspondente à borda esquerda da faixa de rejeição também é registrada. Para maiores detalhes, sugerimos consulta à citada referência. No que segue, são apresentadas comparações quantitativas entre os resultados publicados em (JOHNSTON, 1980) e os resultantes de ensaios usando as técnicas aqui propostas.

Trata-se de 16 casos de projetos de bancos QMF usando filtros-protótipo FIR, como citado anteriormente, identificados por rótulos correspondentes ao comprimento de cada um dos filtros-protótipo e respectivas faixas de transição entre regiões de aceitação e rejeição. A normalização de frequências foi realizada por meio do mapeamento de $[0, \pi]$ em $[0, 0.5]$. A frequência digital tabulada se refere à borda esquerda da região de rejeição do filtro-protótipo (H_0). Devido às diferenças entre os ambientes computacionais empregados, alguns índices aqui obtidos através dos coeficientes originais não coincidem com os publicados em (JOHNSTON, 1980).

¹ Tendo em vista a simetria dos filtros-protótipo, os coeficientes apresentados a seguir correspondem aos de mais alta ordem, ou seja, $h_0(N/2)$, $h_0(N/2+1)$, ..., $h_0(N-1)$, como no artigo-referência (JOHNSTON, 1980). A precedência de apresentação é de cima para baixo e da esquerda para a direita.

A seguir, são apresentados os resultados obtidos com o método proposto e o método apresentado em (JOHNSTON, 1980) para os diversos projetos tabelados naquela referência.

4.3.1 – Caso 8A

Tabela 4.1 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.4032	0.0589	31.5
Proposto	0.4041	0.0548	31.8

Pela Tabela 4.1, vemos que o método proposto superou ligeiramente o método apresentado em (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima.

Tabela 4.2 - Coeficientes de H0

0.48988269753247798420	-0.07010354788578677942
0.06923655211205788362	0.00939984185343245571

4.3.2 – Caso 12A

Tabela 4.3 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3948	0.0218	47.65
Proposto	0.3986	0.0207	47.94

Pela Tabela 4.3, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima em proporções comparáveis às do caso 8A.

Tabela 4.4 - Coeficientes de H0

0.48463485567623498800	-0.00280872751867102194
0.08779618478501262368	0.01872572171973541089
-0.08404400555387199490	-0.00379518606584659888

4.3.3 – Caso 12B

Tabela 4.5 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3598	0.0419	33.93
Proposto	0.3652	0.0382	34.22

Pela Tabela 4.5, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima.

Tabela 4.6 - Coeficientes de H0

0.48175299196261017760	-0.00823071675494712121
0.09546726424517852638	0.02682991093572200878
-0.08864950429393055054	-0.00607355467328253573

4.3.4 – Caso 16A

Tabela 4.7 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3937	0.0102	61.15
Proposto	0.392	0.0101	61.45

Pela Tabela 4.7, vemos que o método proposto superou ligeiramente os resultados em (JOHNSTON, 1980) na atenuação mínima, sendo quase equivalente relativamente ao erro máximo de reconstrução perfeita.

Tabela 4.8 - Coeficientes de H0

0.48062197289031510780	0.02866626795731365071
0.09881354645512654966	-0.00255571335953835117
-0.09094789120424093265	-0.00556812726470243529
-0.01045935231077855035	0.00120466466822635493

4.3.5 – Caso 16B

Tabela 4.9 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3548	0.0204	44.17
Proposto	0.359	0.0168	44.40

Pela Tabela 4.9, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima, sendo que o primeiro índice apresentou redução percentual elevada.

Tabela 4.10 - Coeficientes de H0

0.47789913387758931050	0.03522022746050455788
0.10544890317870160570	-0.00208292232734708701
-0.09435695137471539207	-0.00941695331918894658
-0.01573886409898207078	0.00259728124807571004

4.3.6 – Caso 16C

Tabela 4.11 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3209	0.072	29.15
Proposto	0.3265	0.0472	29.60

Pela Tabela 4.11, vemos que o método proposto superou o apresentado em (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima, sendo que, similarmente ao caso 16B, o primeiro índice sofreu significativa redução percentual.

Tabela 4.12 - Coeficientes de H0

0.47434076191645602180	0.04417599264661019320
0.11284573572788270110	0.00161887127855804298
-0.09570358482374140274	-0.01878846898842989957
-0.02572471380288963994	0.00595762364364376372

4.3.7 – Caso 24B

Tabela 4.13 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3523	0.0082	64
Proposto	0.3516	0.0083	65.36

Pela Tabela 4.13, vemos que o método proposto superou (JOHNSTON, 1980) na atenuação mínima em mais de 1 dB, apresentando erro de reconstrução ligeiramente maior (0.0001 dB).

Tabela 4.14 - Coeficientes de H0

0.47280857298164108420	-0.01964133240310612927
0.11662880501472309980	0.00133499558766741609
-0.09842159974493858154	0.00694456310658351627
-0.02628753705233543084	-0.00146515319985175501
0.04478695025183365708	-0.00156577158269016704
0.00428570564753469330	0.00047284494703503908

4.3.8– Caso 24C

Tabela 4.15 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3145	0.0208	40.08
Proposto	0.3175	0.0204	40.63

Pela Tabela 4.15, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima.

Tabela 4.16 - Coeficientes de H0

0.46919846685943777940	-0.02678444878400671955
0.12331638840123949900	-0.00085643676454487199
-0.09911774449481480787	0.01332774782860669978
-0.03442855741591736157	-0.00203820655637978717
0.05037591574020496704	-0.00520335961559248439
0.00987087722783431751	0.00223895039401898885

4.3.9 – Caso 24D

Tabela 4.17 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.2977	0.0712	29.73
Proposto	0.2998	0.0659	30.12

Pela Tabela 4.17, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima, aumentando novamente as diferenças percentuais entre os dois métodos de projeto.

Tabela 4.18 - Coeficientes de H0

0.46725983317705721560	-0.03125605281052561829
0.12597147110623319040	-0.00473409404959940217
-0.09653772322033325748	0.01956748585723129888
-0.04195167098617755968	-0.00201663484156254600
0.05430596670883722221	-0.01024174557189061994
0.01447369051037301034	0.00405292655407780457

4.3.10 – Caso 32C

Tabela 4.19 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3125	0.0117	52.1
Proposto	0.3112	0.00978	53.21

Pela Tabela 4.19, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima, mantendo a tendência de distanciamento entre os valores relativos aos dois métodos de projeto.

Tabela 4.20 - Coeficientes de H0

0.46602967258469002460	0.01866047831955652131
0.12916417078790820570	0.00021366960417138029
-0.09974004329424750181	-0.01012314892701110004
-0.04008240657446013322	0.00131636450764002809
0.05324249633364880330	0.00477954837487992463
0.01527505415139075034	-0.00134930260191149193
-0.03177838709715365834	-0.00184745017816564092
-0.00472587468769490333	0.00085026340257787021

4.3.11 – Caso 32D

Tabela 4.21 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.2943	0.0269	36.71
Proposto	0.2938	0.021	37.02

Pela Tabela 4.21, vemos que o método proposto superou (JOHNSTON, 1980) em ambos os índices, sendo que a melhora no erro de reconstrução foi em proporções bem superiores à da atenuação mínima na faixa de rejeição do filtro protótipo.

Tabela 4.22 - Coeficientes de H0

0.46349167242485578290	0.02310227228032029831
0.13287405029498919330	0.00231183757307628496
-0.09911053524743927701	-0.01449330398063677916
-0.04501568977870024774	0.00065160587191754661
0.05486380997738282694	0.00851311139902802966
0.01967561129926724897	-0.00202999736507510596
-0.03490756853871539167	-0.00449240475048415591
-0.00848779634515862275	0.00262010601774176691

4.3.12 – Caso 48C

Tabela 4.23 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.3118	0.0038	67.76
Proposto	0.3118	0.0034	67.78

Pela Tabela 4.23, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima, apresentando, no entanto, índices praticamente equivalentes, sob o ponto de vista quantitativo.

Tabela 4.24 - Coeficientes de H0

0.464233161301977	0.007839959389688
0.132077133972771	-0.000755459312199
-0.099383714189300	-0.004213115981962
-0.043594082565172	0.000786436800442
0.054326972343525	0.002036273431762
0.018812212255909	-0.000522882963108
-0.034087244709552	-0.000853110739706
-0.007800574320083	0.000244100398751
0.021736159954701	0.000301906414188
0.002463596812045	-0.000054569930927
-0.013439754876376	-0.000091110502065
-0.000058506487280	-0.000012631113299

4.3.13 – Caso 48D

Tabela 4.25 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.292	0.0109	52.14
Proposto	0.292	0.0104	53

Pela Tabela 4.25, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima, com melhor percentual nesta última.

Tabela 4.26 - Coeficientes de H0

0.46129914913154940200	0.01275374047356920941
0.13643457703397279810	0.00050719945295512106
-0.09817787143292898422	-0.00853493390997154926
-0.04912783518748756878	0.00048366738701647487
0.05541063582089286732	0.00545932951569948113
0.02431891662111113073	-0.00091201059912770761
-0.03695293908817900291	-0.00321784126248055415
-0.01276734888290547917	0.00088549953494317872
0.02599295163358028918	0.00173296408539346403
0.00628934785052842529	-0.00071126262731359305
-0.01836826767130882859	-0.00079452212527335948
-0.00269003610393312711	0.00044978917049139382

4.3.14 – Caso 48E

Tabela 4.27 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.2743	0.0733	30.62
Proposto	0.2741	0.0656	30.86

Pela Tabela 4.27, vemos que o método proposto superou (JOHNSTON, 1980) em ambos os índices, apresentando significativa redução percentual no erro de reconstrução.

Tabela 4.28 - Coeficientes de H0

0.45881763833298688790	0.01822169371503128132
0.13902503979485050790	0.00322694399446039198
-0.09554363829585098278	-0.01326150953809494999
-0.05455217159961440326	-0.00170311845759523990
0.05483669116531741938	0.01032357548581193038
0.03020001789319049987	0.00043611392106262761
-0.03814450762418088170	-0.00807854378831778311
-0.01872180398741931859	0.00078358686810965942
0.02895273429912760890	0.00590402807333622291
0.01132727665573986069	-0.00179974349073170497
-0.02229438377076927921	-0.00418886115920606619
-0.00684830776905344038	0.00301425554280964616

4.3.15 – Caso 64D

Tabela 4.29 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.2916	0.006083	65.77
Proposto	0.2929	0.00559	69.36

Pela Tabela 4.29, vemos que o método proposto superou (JOHNSTON, 1980) tanto no erro de reconstrução quanto na atenuação mínima, tendo o primeiro índice atingido a maior redução percentual.

Tabela 4.30 - Coeficientes de H0

0.46008730291226107580	0.00742882516063705228
0.13821374493096211240	-0.00024035861472627710
-0.09773037860974502500	-0.00504178765645179293
-0.05100971069891063747	0.00055373630684200697
0.05542873847731764198	0.00328833578485722899
0.02649100066236061146	-0.00061746389989043556
-0.03763379323850356284	-0.00203284526373207191
-0.01491337277712886066	0.00052601244584105143
0.02718102133244891874	0.00117881680072751496
0.00833477953828384334	-0.00039516978877574400
-0.01996997500352120855	-0.00062415931588957502
-0.00437160747054936034	0.00024000880065357509
0.01463841151905906010	0.00029527101251745799
0.00193992325242783891	-0.00012674244103998790
-0.01055304506418498073	-0.00011173462038395570
-0.00052733612270267614	0.00003844250044087019

4.3.16 – Caso 64E

Tabela 4.31 – Comparação de índices de desempenho

Método	Frequência normalizada	Erro de reconstrução máximo (dB)	Atenuação mínima (dB)
(JOHNSTON, 1980)	0.2729	0.4094	31.82
Proposto	0.2702	0.0934	36

Pela Tabela 4.31, vemos que o método proposto superou (JOHNSTON, 1980) em ambos os índices, sendo que o erro de reconstrução foi reduzido em aproximadamente 77%, enquanto a atenuação mínima apresentou aumento de aproximadamente 13%.

Tabela 4.32 - Coeficientes de H0

0.45699572221643258720	0.01293622077948389931
0.14172368487931960580	0.00309959854585316287
-0.09480937387440528663	-0.01059459012770181015
-0.05679849817757474245	-0.00176025664957258905
0.05461216132779957156	0.00900413746301989212
0.03247574263224806829	0.00054739657496057255
-0.03804070831008696252	-0.00665602729528567191
-0.02105343597453004922	-0.00023207698251215760
0.02918154081521175114	0.00552947330244266642
0.01450008288279499950	-0.00025410775966300839
-0.02348415127507414921	-0.00447832868470271917
-0.01010671743635076919	0.00065386928410721015
0.01895592331652911147	0.00375951878371278900
0.00683869745874772592	-0.00116524963914932996
-0.01538081232095262971	-0.00327428825063227295
-0.00484038699370878660	0.00150437105365809902

4.4 Resultados – obtenção de relações numéricas biobjetivo

Como citado na seção anterior, em (JOHNSTON, 1980) é proposto um método de projeto de bancos de filtros QMF utilizando o método de otimização global de Hooke e Jeeves. Naquela pesquisa, são apresentados exemplos de projeto em 16 casos e a qualidade do resultado final é aferida por meio de dois índices específicos, a saber, erro máximo de reconstrução em todo o espectro digital (sistema global) e atenuação mínima na faixa de rejeição (filtro-protótipo). Em cada um dos casos apresentados, os resultados finais consistem de estimativas pontuais de parâmetros do filtro-protótipo H_0 e respectivos índices de desempenho, considerados ótimos ou quase ótimos, sem considerações adicionais a respeito do comportamento global do problema multiobjetivo naturalmente configurado. Dado a importância de funções que explicitem, ainda que experimentalmente, a relação de dependência entre os dois índices acima (que apresentam uma relação de compromisso), foram construídas curvas que realizam exatamente esse objetivo – em cada situação relevante, apresentar estimativas da relação entre a atenuação mínima na faixa de rejeição de um dado filtro-protótipo e o P.R.E. obtível naquela configuração. A apresentação é feita pelo agrupamento das curvas obtidas, tanto por comprimento de filtros protótipo (8, 12, 16, 24, 32, 48, 64) quanto por larguras de faixas de transição especificadas (A, B, C, D, E), através de figuras com os erros de reconstrução perfeita (PRE) em função da atenuação na faixa de rejeição do filtro protótipo, com indicações dos pontos atingidos usando os coeficientes mostrados em (JOHNSTON, 1980).

Outro aspecto digno de nota é que aproximações de segmentos das chamadas frentes de Pareto (SCHNIER *et al.*, 2003) estão contidas e podem ser visualizadas em cada curva individual. Tais curvas representam conjuntos de parâmetros tais que ao alterarmos um de seus componentes para valor considerado melhor para a aplicação sob estudo, provocaremos a piora de um ou mais dos demais elementos, configurando assim uma relação de compromisso tipicamente complexa e de difícil tratamento quantitativo.

4.4.1 – Comprimento 8

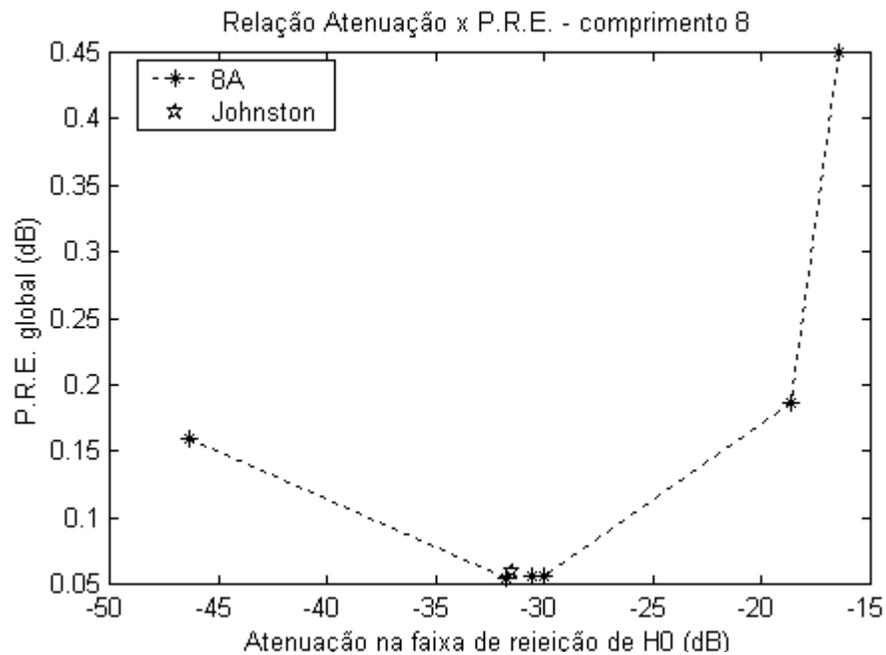


Figura 4.2 – Compromisso entre atenuação e P.R.E. – 8 coeficientes

Na Figura 4.2 pode-se observar a solução de (JOHNSTON, 1980) acima do segmento da aproximação da curva de Pareto (à esquerda do ponto indicado) obtida pelo presente método. Esta tendência se confirmará ao longo de todos os ensaios e reafirma a consistência da abordagem aqui adotada, sendo importante observar que os pontos correspondentes a projetos apresentados em (JOHNSTON, 1980) estão tipicamente próximos dos extremos à direita da referida curva.

4.4.2 – Comprimento 12

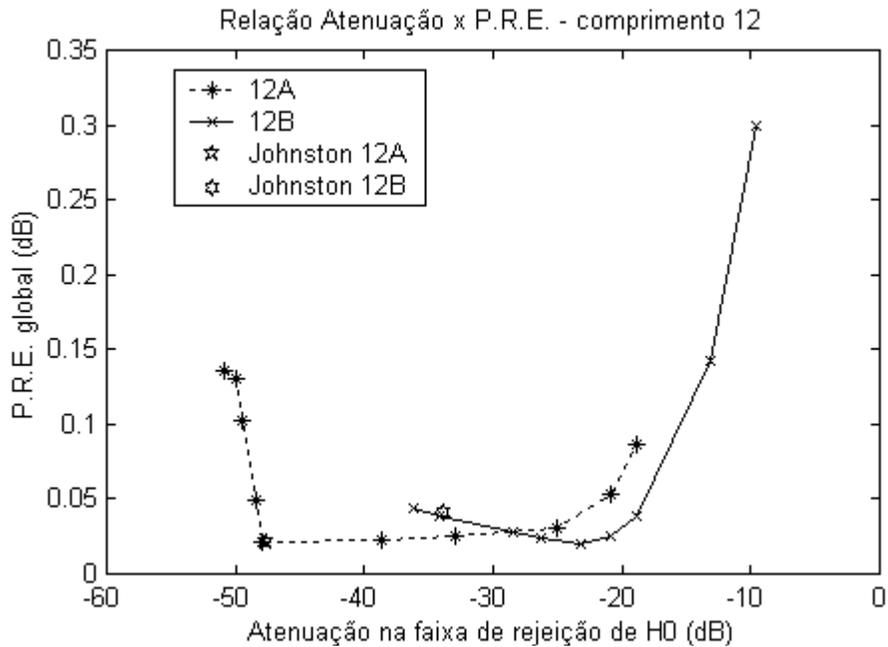


Figura 4.3 – Compromisso entre atenuação e P.R.E. – 12 coeficientes

Na Figura 4.3 podemos observar uma vez mais as soluções de (JOHNSTON, 1980) posicionadas sobre os respectivos segmentos das aproximações das curvas de Pareto obtidas pelo presente método. No caso 12A, é possível ver que o ponto correspondente ao respectivo projeto em (JOHNSTON, 1980) está posicionado na fronteira entre a curva de Pareto (à esquerda) e o segmento que poderíamos chamar de curva de pontos (ou projetos) degenerados (à direita), tendo em vista que, à medida que a atenuação diminui (situação desfavorável), os valores do erro de reconstrução perfeita aumentam (situação igualmente desfavorável).

4.4.3 – Comprimento 16

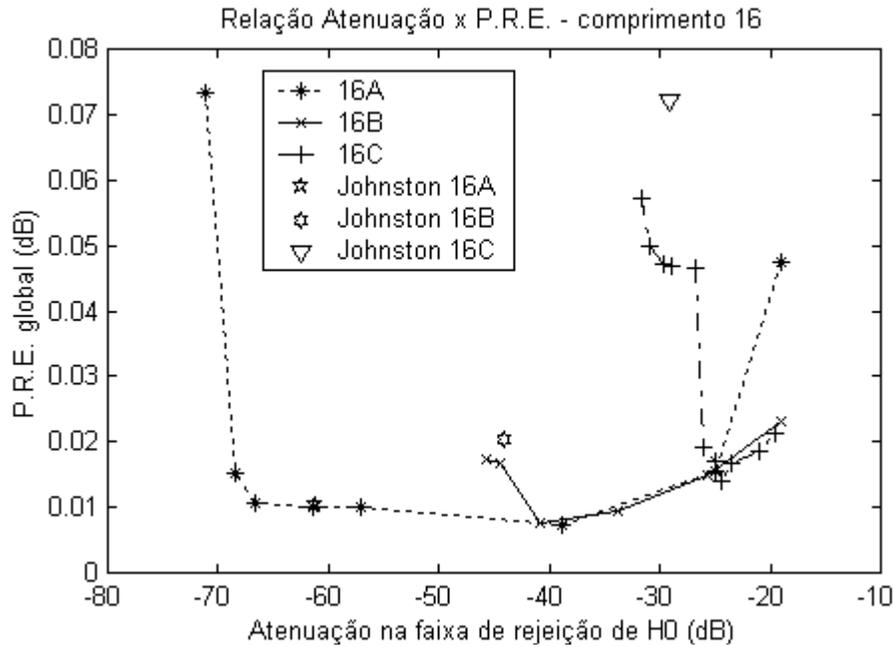


Figura 4.4 – Compromisso entre atenuação e P.R.E. – 16 coeficientes

Na Figura 4.4 podemos observar as soluções de (JOHNSTON, 1980) posicionadas sobre os respectivos segmentos das aproximações das curvas de Pareto obtidas pelo presente método. Nos casos 16B e 16C o afastamento é acentuado, evidenciando as vantagens do método apresentado. Em cada uma das curvas podemos delimitar facilmente as duas regiões mencionadas anteriormente, que correspondem à aproximação do conjunto de pontos da curva de Pareto (à esquerda) e a grupos de pontos degenerados (sem possibilidade de compromisso), apresentando índices de desempenho cada vez piores (à direita), ou seja, a diminuição da atenuação provoca o aumento do erro de reconstrução perfeita. Neste conjunto de resultados é possível observar que os pontos originais apresentados em (JOHNSTON, 1980) estão posicionados ligeiramente à esquerda da fronteira entre as duas regiões e existem, nos três casos, extensas vizinhanças de casos de projeto superiores aos da referência (JOHNSTON, 1980).

4.4.4 – Comprimento 24

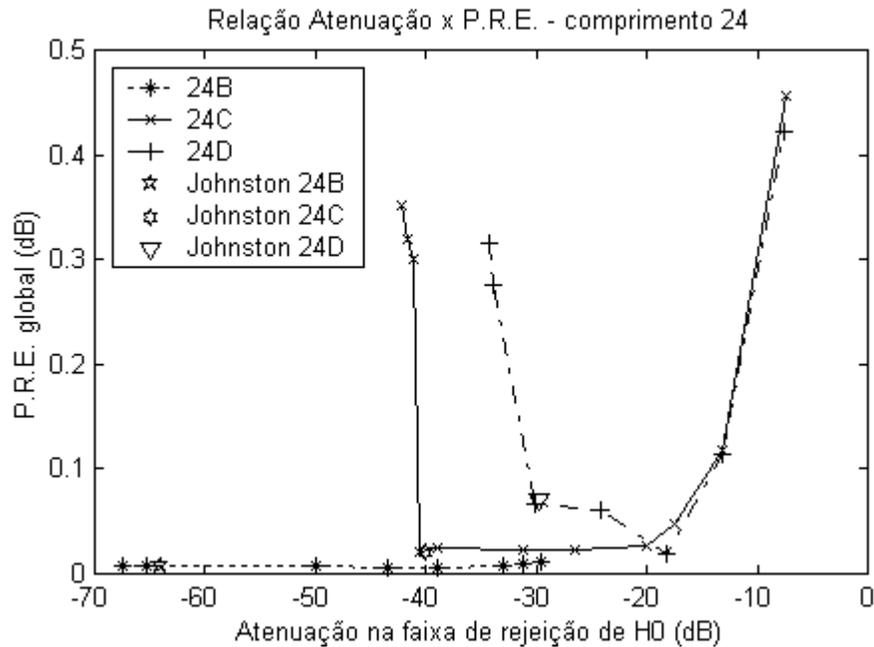


Figura 4.5 – Compromisso entre atenuação e P.R.E. – 24 coeficientes

Na Figura 4.5 podemos observar as soluções de (JOHNSTON, 1980) posicionadas sobre os respectivos segmentos das aproximações das curvas de Pareto obtidas pelo presente método. No caso 24B, observa-se, à esquerda, segmentos representativos de soluções significativamente melhores do que as de (JOHNSTON, 1980), quanto à atenuação na faixa de rejeição. Como mencionado anteriormente, observamos que em cada uma das curvas é possível delimitar duas regiões, que correspondem à aproximação da curva de Pareto (à esquerda) e a grupos de pontos degenerados, apresentando índices de desempenho cada vez piores (à direita). No caso 24C, o projeto apresentado em (JOHNSTON, 1980) está praticamente coincidente com o melhor projeto possível, a partir do qual o erro de reconstrução perfeita é sempre crescente, não importando qual valor da atenuação seja adotado. O gráfico correspondente ao caso 24D apresenta comportamento similar no caso de redução da atenuação, embora seja possível reduzir ainda mais o erro de reconstrução perfeita em um reduzido trecho, caso em que será necessário piorar discretamente a atenuação na faixa de rejeição do filtro protótipo.

4.4.5 – Comprimento 32

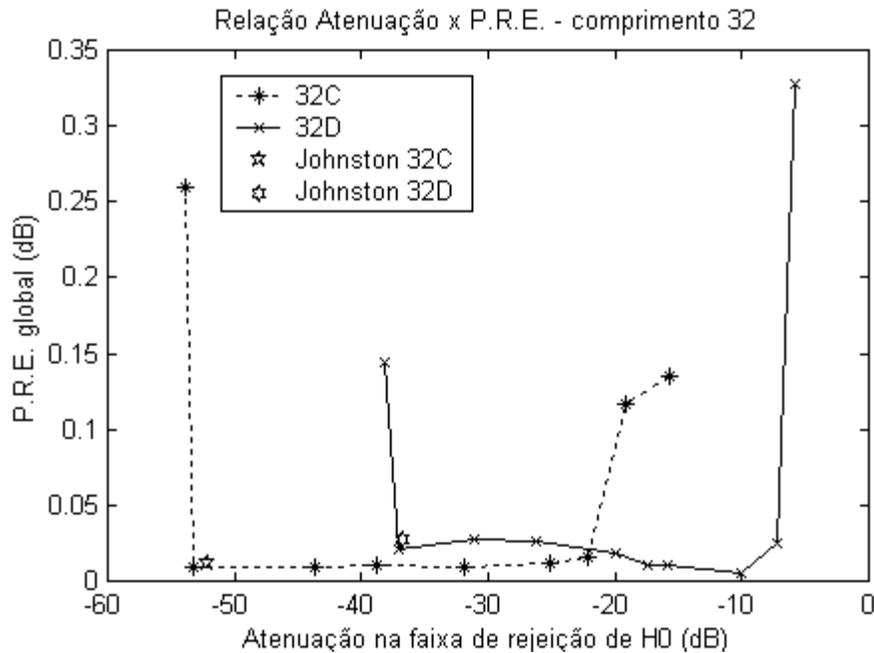


Figura 4.6 – Compromisso entre atenuação e P.R.E. – 32 coeficientes

Na Figura 4.6 podemos observar as soluções de (JOHNSTON, 1980) posicionadas sobre os respectivos segmentos das aproximações das curvas de Pareto obtidas pelo presente método. No caso 32C, observa-se, à esquerda, um pequeno segmento representativo de soluções melhores do que as de (JOHNSTON, 1980), quanto à atenuação na faixa de rejeição do filtro protótipo. Observa-se ainda no extremo esquerdo da curva correspondente ao caso 32C que, a partir de certo valor da atenuação na faixa de rejeição do filtro protótipo, o valor do erro de reconstrução perfeita piora de modo acelerado quando ocorrem pequenos aumentos da atenuação. No caso 32D, é possível notar situação similar, existindo uma pequena vizinhança à esquerda do ponto correspondente ao projeto mostrado em (JOHNSTON, 1980) na qual ocorrem diversas possibilidades de projeto superiores. Repetindo o comportamento do caso anterior, existe um limiar de valor de atenuação na faixa de rejeição do filtro protótipo a partir do qual o erro de reconstrução perfeita cresce de modo acentuado para pequenas melhoras da referida atenuação. Em ambos os casos ocorre o mesmo comportamento no extremo direito das respectivas curvas, a saber, o relaxamento da atenuação provoca aumento no erro de reconstrução perfeita, o que é inconveniente nos casos reais.

4.4.6 – Comprimento 48

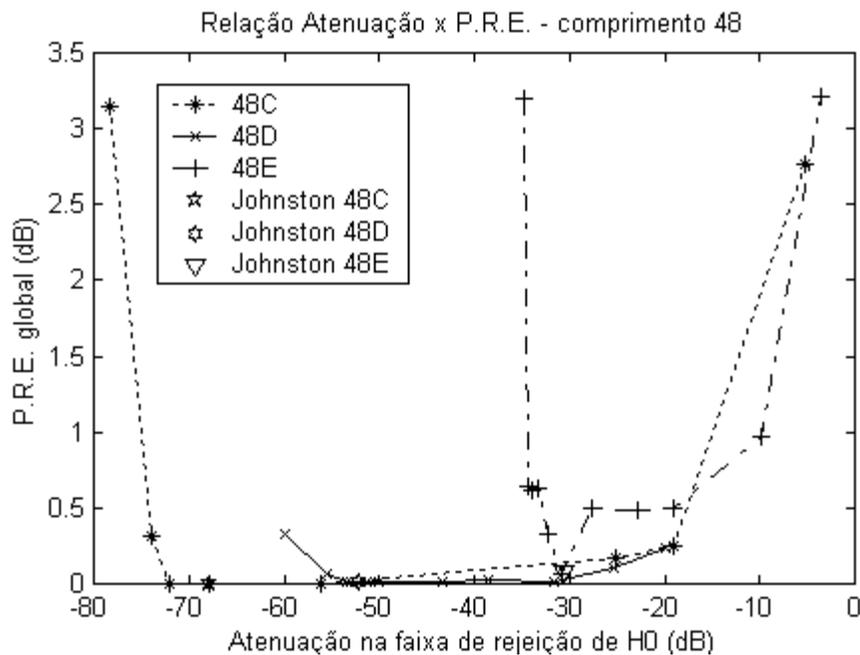


Figura 4.7 – Compromisso entre atenuação e P.R.E. – 48 coeficientes

Na Figura 4.7 podemos observar as soluções de (JOHNSTON, 1980) posicionadas sobre os respectivos segmentos das aproximações das curvas de Pareto obtidas pelo presente método. Nos casos 48C e 48D, observa-se, à esquerda, segmentos representativos de soluções significativamente melhores do que as de (JOHNSTON, 1980), quanto à atenuação na faixa de rejeição. Em ambos os gráficos nota-se que a partir de certo limiar da atenuação na faixa de rejeição do filtro protótipo o erro de reconstrução perfeita cresce em uma taxa elevada quando aumentamos a referida atenuação (valores absolutos em dB), o que não é conveniente. Outra similaridade apresentada nos dois casos (48C e 48D) é que ao centro de cada gráfico é possível ver regiões nas quais o erro de reconstrução se mantém constante, quando a atenuação varia em determinado intervalo. O caso 48E se caracteriza pela inexistência de tal região de erro de reconstrução constante, sendo que o ponto correspondente ao projeto apresentado em (JOHNSTON, 1980) delimita claramente as duas sub-regiões.

4.4.7 – Comprimento 64

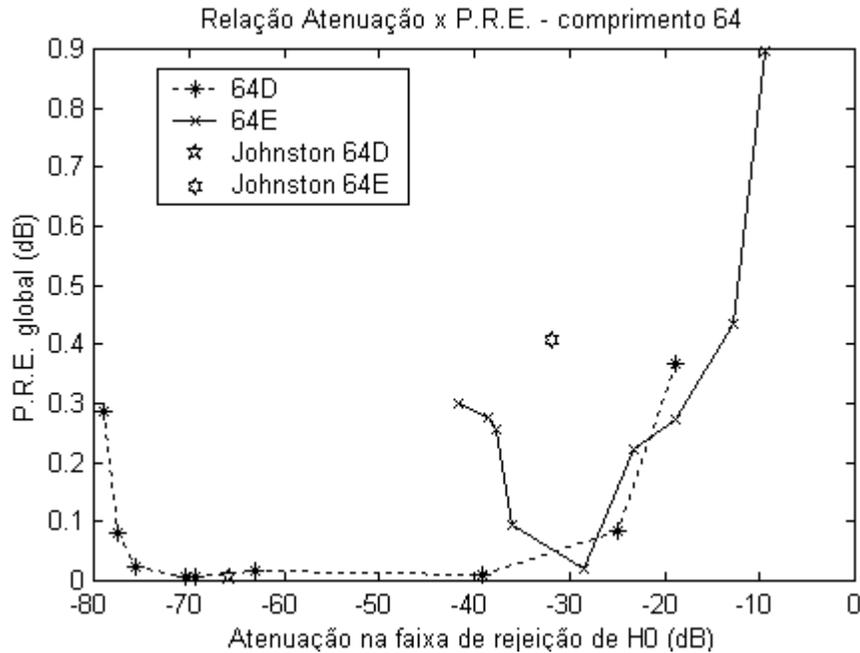


Figura 4.8 – Compromisso entre atenuação e P.R.E. – 64 coeficientes

Na Figura 4.8 podemos observar as soluções de (JOHNSTON, 1980) posicionadas sobre os respectivos segmentos das aproximações das curvas de Pareto obtidas pelo presente método. No caso 64D, observa-se, à esquerda, um segmento representativo de soluções significativamente melhores do que a apresentada em (JOHNSTON, 1980), quanto à atenuação na faixa de rejeição e ao erro de reconstrução, sendo que no extremo esquerdo da curva ocorre o fenômeno usual de elevado crescimento do erro de reconstrução perfeita para pequenas variações da atenuação na faixa de rejeição do filtro protótipo. Ao centro, é possível localizar uma região praticamente plana, insensível à variação da atenuação e, conseqüentemente, desinteressante do ponto de vista da qualidade de projetos. A configuração do gráfico correspondente ao caso 64E mostra que o ponto correspondente ao projeto apresentado em (JOHNSTON, 1980) pode ser significativamente melhorado, tendo em vista a sua distância à curva obtida pelo método proposto e o segmento posicionado no extremo esquerdo, composto de pontos mais vantajosos. Assim como em outros casos, o gráfico não apresenta região plana.

4.4.8 – Faixa A

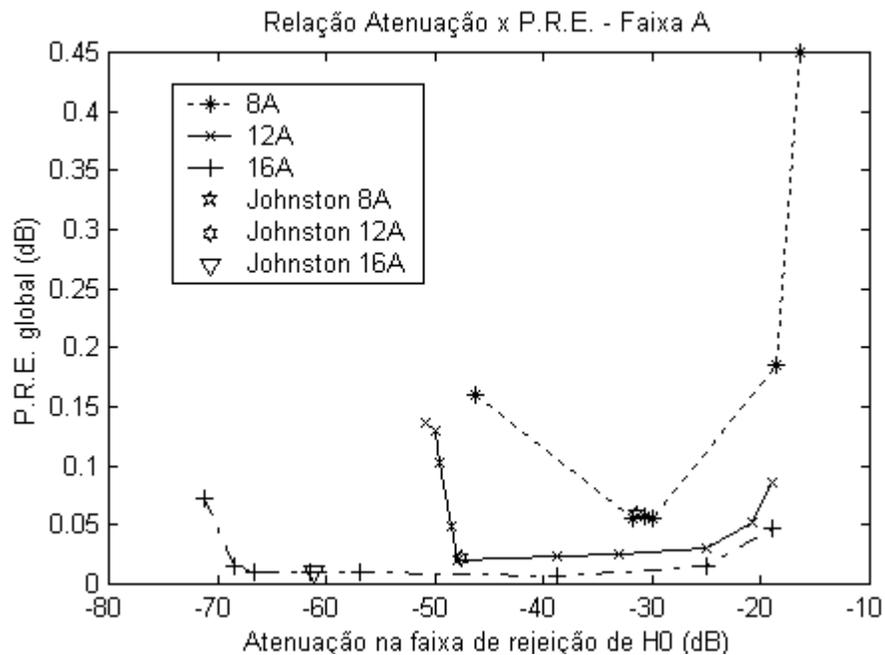


Figura 4.9 – Compromisso entre atenuação e P.R.E. – faixa A

Na Figura 4.9 são apresentados os gráficos correspondentes aos casos 8A, 12A e 16A. Na curva correspondente ao filtro de comprimento 8 é notória a ausência de área aproximadamente plana, estando o ponto relativo ao respectivo projeto apresentado em (JOHNSTON, 1980) posicionado de modo quase ótimo, no sentido de que ainda pequenas variações ao longo da curva resulta em piora em pelo menos um dos índices de desempenho adotados. Na curva correspondente ao caso 12A a situação é diferente, com o aparecimento de uma região central de baixa inclinação e pouca sensibilidade à variação da atenuação na faixa de rejeição do filtro protótipo. O ponto correspondente ao projeto apresentado em (JOHNSTON, 1980) aparece em posição próxima à ótima, e a observação do gráfico revela que existe uma pequena região com possibilidade de melhor desempenho. Na curva correspondente ao caso 16A a região quase plana central é ampliada e apresenta sensibilidade quase nula à variação da atenuação na faixa de rejeição do filtro protótipo, sendo que o ponto correspondente ao respectivo projeto publicado em (JOHNSTON, 1980) aparece relativamente distante do que pode ser considerado ótimo. Com base em tal observação, é possível obter diversas configurações de projeto com melhores valores de atenuação na faixa de rejeição e praticamente o mesmo erro de reconstrução perfeita.

4.4.9 – Faixa B

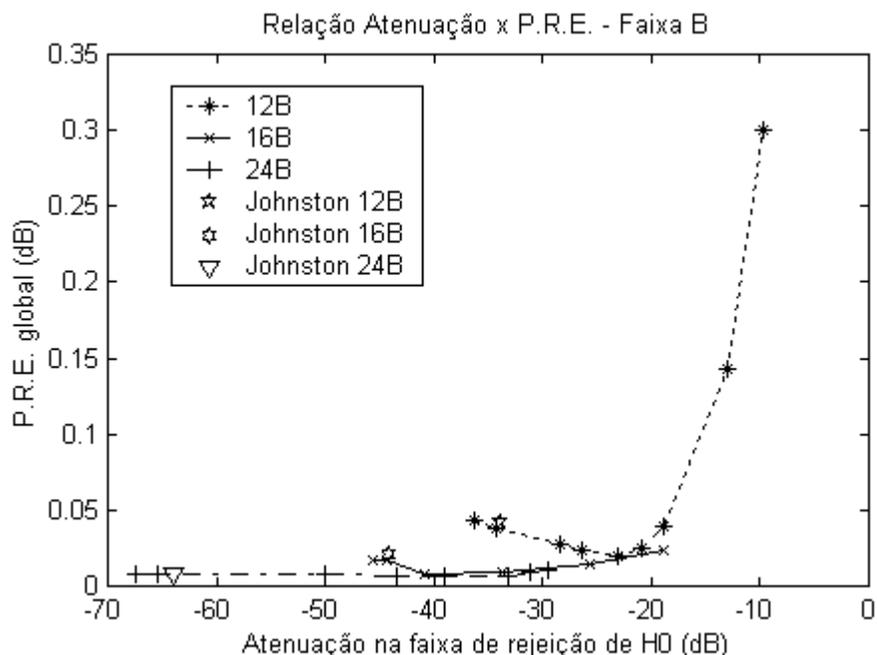


Figura 4.10 – Compromisso entre atenuação e P.R.E. – faixa B

Na Figura 4.10 são apresentadas as curvas relativas aos casos 12B, 16B e 24B superpostas. Similarmente ao caso da faixa A, existe a tendência de aparecimento e ampliação de uma faixa central aproximadamente plana, à medida que os comprimentos dos filtros protótipos aumenta. No caso 12B o ponto correspondente ao projeto apresentado em (JOHNSTON, 1980) aparece um pouco acima da aproximação da curva de Pareto, evidenciando a existência de projetos mais adequados. Aqui não ocorre o aparecimento de regiões insensíveis à variação da atenuação na faixa de rejeição do filtro protótipo. Na curva correspondente ao caso 16B surge um segmento intermediário com baixa sensibilidade à variação da atenuação, e o ponto correspondente ao projeto em (JOHNSTON, 1980) está posicionado acima do extremo esquerdo da aproximação obtida, indicando reduzida região com melhor desempenho em ambos os índices adotados. No caso do filtro protótipo de comprimento 24 (24B), a região de baixa sensibilidade à variação da atenuação na faixa de rejeição é ainda mais extensa e, levando em consideração a posição do ponto correspondente ao projeto mostrado em (JOHNSTON, 1980), indica possibilidade de obtenção de diversos casos de projeto com praticamente o mesmo erro de reconstrução perfeita, porém com maior atenuação na faixa de rejeição do filtro protótipo, o que é desejável.

4.4.10 – Faixa C

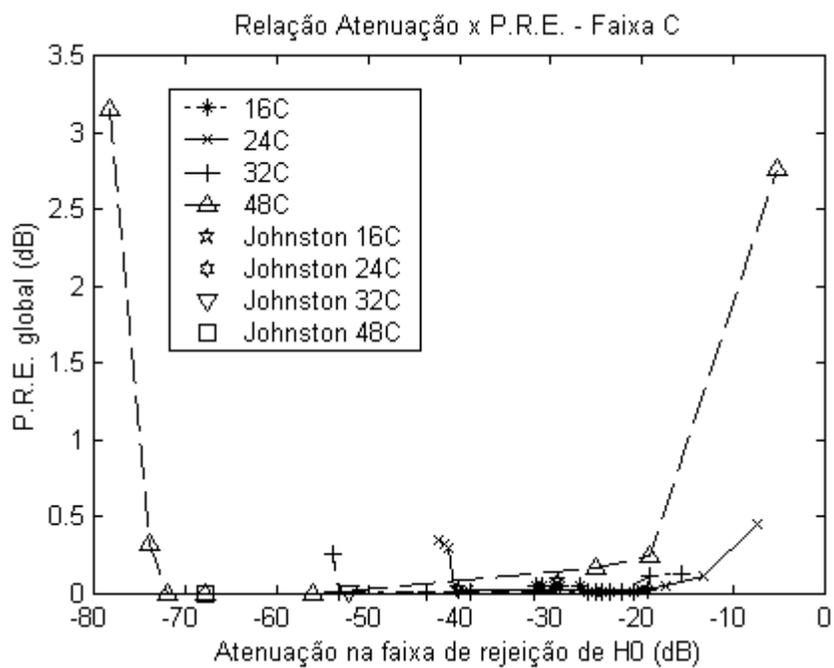


Figura 4.11 – Compromisso entre atenuação e P.R.E. – faixa C

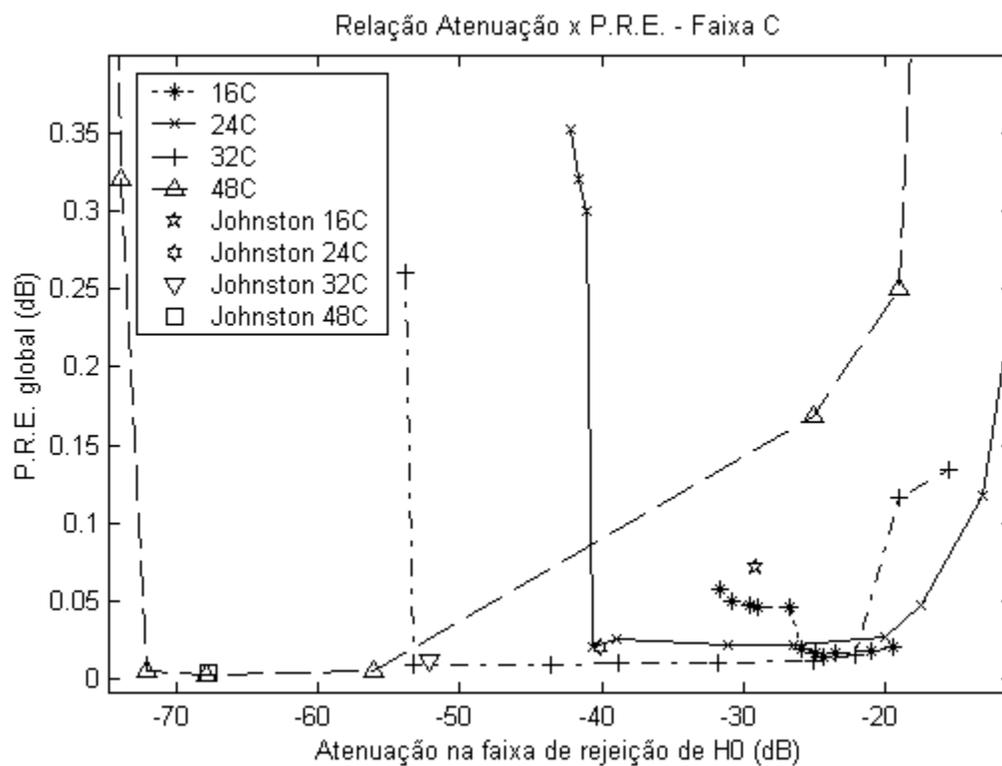


Figura 4.12 – Compromisso entre atenuação e P.R.E. – zoom das curvas da faixa C

Nas Figuras 4.11 e 4.12 são apresentados os quatro casos correspondentes à faixa de transição C definida em (JOHNSTON, 1980), a saber, 16C, 24C, 32C e 48C. Inicialmente, podemos notar que à medida que o comprimento do filtro protótipo aumenta, melhores projetos podem ser obtidos, conforme intuitivamente esperado. No caso 16C os gráficos apresentam reduzida região de relativa insensibilidade à variação da atenuação na faixa de rejeição, ao centro da respectiva curva, ao passo que o ponto correspondente ao projeto apresentado em (JOHNSTON, 1980) está bem acima de seu extremo esquerdo, de onde podemos concluir que há uma região significativamente favorável à obtenção de melhores casos de projeto. No caso 24C, o ponto correspondente ao projeto apresentado em (JOHNSTON, 1980) está muito próximo ao que pode ser considerado ótimo, deixando pouca margem a aperfeiçoamento. A região central quase plana foi expandida e as laterais apresentam grande inclinação. No caso 32C novamente ocorre a expansão da região de insensibilidade à variação da atenuação na faixa de rejeição, e o ponto correspondente ao projeto publicado em (JOHNSTON, 1980) está posicionado de modo quase ótimo. Em consequência, existe uma pequena margem para aperfeiçoamento se houver deslocamento ao longo da respectiva curva na direção de melhor atenuação, à esquerda, obtendo-se simultaneamente menor erro de reconstrução perfeita. Finalmente, o gráfico correspondente ao caso 48C mostra claramente uma razoável margem para escolha de melhores filtros H_0 no extremo esquerdo da região de baixa sensibilidade à atenuação na faixa de rejeição, sendo possível melhorar o projeto apresentado em (JOHNSTON, 1980) em aproximadamente 5 dB relativamente à atenuação sem alteração significativa no erro de reconstrução perfeita.

4.4.11 – Faixa D

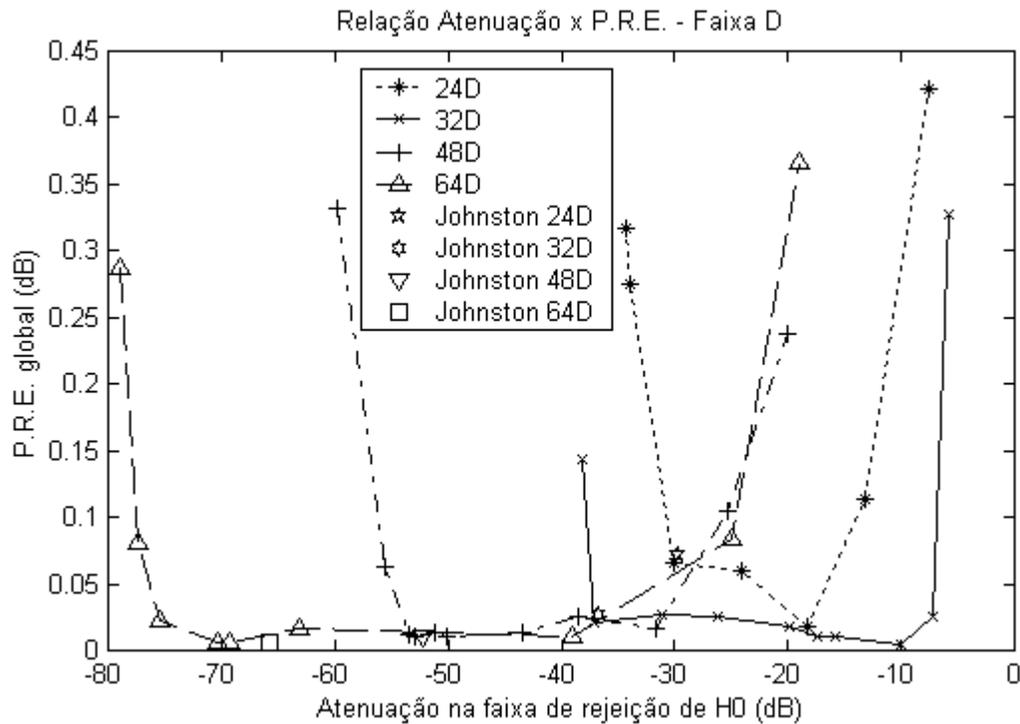


Figura 4.13 – Compromisso entre atenuação e P.R.E. – faixa D

Na Figura 4.13 podemos observar quatro gráficos correspondentes aos casos 24D, 32D, 38D e 64D tratados em (JOHNSTON, 1980), com superposição dos pontos representativos dos projetos lá propostos. É possível, mais uma vez, extrair algumas conclusões pela observação detalhada das curvas de compromisso. O gráfico correspondente ao caso 24D não apresenta qualquer região aproximadamente plana, indicando que mesmo pequenas excursões ao longo de sua extensão alterarão significativamente ambos os índices de desempenho. O ponto correspondente ao projeto apresentado em (JOHNSTON, 1980) está posicionado de modo quase ótimo, proporcionando reduzidas possibilidades de aperfeiçoamento. Embora haja margem para redução no erro de reconstrução perfeita, isto se daria com substancial degradação da atenuação na faixa de rejeição do filtro protótipo, o que pode ser inaceitável. A curva relativa ao caso 32D mostra o aparecimento da região central com menor sensibilidade à variação da atenuação na faixa de rejeição, estando o ponto correspondente ao projeto estabelecido em (JOHNSTON, 1980) posicionado em seu extremo esquerdo, e

praticamente superposto ao que pode ser considerado o melhor caso de compromisso. Dessa observação é possível concluir que há reduzida região para aperfeiçoamento daquele projeto. No caso 48D ocorre um aparente deslocamento à esquerda da curva anteriormente descrita (caso 32D), e o ponto correspondente ao projeto em (JOHNSTON, 1980) aparece no extremo esquerdo da região central de baixa sensibilidade à variação da atenuação na faixa de rejeição do filtro protótipo. Existe, no entanto, um pequeno trecho com possibilidade de obtenção de melhores valores de atenuação sem degradação do erro de reconstrução perfeita. O caso 64D apresenta uma extensa região de baixa sensibilidade à variação da atenuação na faixa de rejeição e maiores possibilidades de aprimoramento do projeto proposto em (JOHNSTON, 1980), que é indicado no gráfico, próximo a seu extremo esquerdo inferior. Existe uma região correspondente a projetos com melhores valores de atenuação e erros de reconstrução ligeiramente inferiores, imediatamente à esquerda do ponto correspondente ao projeto proposto em (JOHNSTON, 1980), reforçando a utilidade das curvas biobjetivo aqui apresentadas. Nota-se, pela Figura 4.13, que é possível melhorar o projeto original em até 4 dB, sem prejuízo do erro de reconstrução perfeita.

4.4.12 – Faixa E

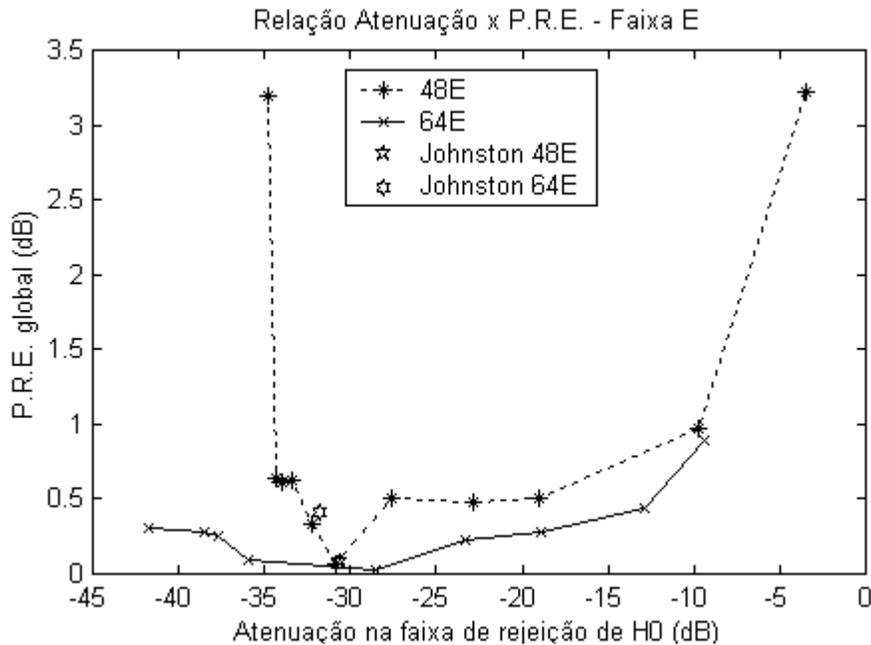


Figura 4.14 – Compromisso entre atenuação e P.R.E. – faixa E

Na Figura 4.14 são apresentadas duas curvas de compromisso correspondentes aos casos 48E e 64E, como estabelecido em (JOHNSTON, 1980), e os pontos relativos aos projetos propostos naquela referência. Reforçando as configurações encontradas em casos anteriores, observamos dois tipos de situações: no caso 48E, a parte inferior da curva não apresenta região de baixa sensibilidade à variação da atenuação na faixa de rejeição e o ponto correspondente ao projeto proposto em (JOHNSTON, 1980) encontra-se em situação quase ótima, havendo poucas possibilidades de aperfeiçoamento substancial. A situação no caso 64E é diferente, pois é claro o aparecimento de uma região de baixa sensibilidade à atenuação e com erros de reconstrução próximos do mínimo alcançado em todo o gráfico. Como o ponto publicado em (JOHNSTON, 1980) está bem acima da respectiva curva (com erro de reconstrução perfeita várias vezes superior ao mínimo geral), conclui-se que existe larga margem para aprimoramento naquele caso, como pode ser visto no extremo esquerdo inferior da Figura 4.14, dada a grande extensão da curva de compromisso com índices mais vantajosos, principalmente em termos de erro de reconstrução perfeita.

4.5 – Conclusões - projeto de bancos QMF

Neste capítulo foram aplicadas técnicas baseadas em otimização global estocástica não linear ao problema de projeto de bancos QMF.

O estudo adotou como base de comparação os resultados publicados em (JOHNSTON, 1980), utilizado tradicionalmente para tal tipo de avaliação desde sua publicação. Foram obtidos tanto resultados pontuais como globais, no sentido de que uma vez sintetizada uma função objetivo que contivesse todos os vínculos do problema, esta foi minimizada globalmente através do algoritmo Fuzzy ASA através da adaptação dos parâmetros do filtro protótipo associado ao banco QMF, tendo sido obtidos não só projetos a ser comparados com aqueles publicados em (JOHNSTON, 1980) isoladamente, mas também curvas retratando o compromisso entre os dois índices de desempenho adotados para avaliação de resultados, a saber, erro de reconstrução perfeita e atenuação na faixa de rejeição do filtro protótipo H_0 . Embora os resultados pontuais tenham por si sós demonstrado a eficácia do novo método, a obtenção das curvas é importante por oferecer um panorama do comportamento dos possíveis projetos que obedeçam às condições de contorno, quando variamos os valores de um dos índices de desempenho. Concluimos que o objetivo da pesquisa foi alcançado.

CAPÍTULO 5

SEPARAÇÃO CEGA DE MISTURAS NÃO-LINEARES E ANÁLISE DE COMPONENTES INDEPENDENTES

5.1 Introdução

Em muitas aplicações da Medicina (eletrocardiograma, eletroencefalograma), Acústica (filtragem de ruído), Economia (Econometria), Defesa (sistemas de radar/sonar), etc. (TAN, 2001), diversos sinais são recebidos e processados por sensores que os condicionam e transmitem a estágios posteriores, para algum tipo de tratamento e utilização subseqüentes. Pela própria estrutura física de tais componentes, os sinais originais sofrem algum tipo de distorção, que, via de regra, deve ser revertida, sob pena de comprometer a funcionalidade de todo o aparato. Em alguns casos, é possível modelar tal fenômeno como sendo resultado de uma mistura linear, ou seja, os sinais originais teriam sido processados por um sistema linear invariante no tempo, representado por uma matriz inversível. Tal premissa resume o problema à busca da matriz que, composta à primeira, devolva as leituras reais. Assumindo a hipótese que os sinais originais são estatisticamente independentes, tal tarefa foi resolvida de modo satisfatório por inúmeros pesquisadores, usando métodos dos mais diversos (ALMEIDA, 2006). Ocorre que nem sempre a premissa da linearidade convive satisfatoriamente com a realidade dos dispositivos físicos, e tem que ser descartada, sob pena de fracasso na implementação de funcionalidades específicas - daí a necessidade de criação de métodos de separação de misturas não lineares, que mantêm estreita relação com a análise de componentes independentes.

Embora haja inúmeros resultados relativos à análise de componentes independentes de misturas lineares (obtidas através de transformação linear de dois ou mais sinais), a correspondência com respeito às misturas não lineares é desigual, ou seja, ainda há poucos resultados efetivos no tocante à separação de sinais componentes de misturas obtidas através de operadores não-lineares. Dentre os mais destacados métodos para tal fim, encontramos MISEP (ALMEIDA, 2006), que estende INFOMAX (BELL, 1995), este último com escopo restrito ao caso de misturas lineares de sinais estatisticamente independentes. A abordagem MISEP amplia o alcance do modelo

INFOMAX em duas direções, a saber, é capaz de separar misturas não-lineares e usa não-linearidades adaptativas nas saídas. Tendo em vista que tais componentes são estreitamente relacionadas às distribuições de probabilidade dos vetores resultantes da análise final, a flexibilidade extra obtida permite tratar um maior espectro de casos. A seguir, será apresentada uma breve descrição do problema sob tratamento e da contribuição aqui proposta para ataque ao problema de separação cega de misturas não-lineares e análise de componentes independentes. Ao final, serão evidenciadas, através de ensaios específicos, as vantagens do presente algoritmo.

O problema sob análise consiste em, dados vetores observados ($\mathbf{o}=[o_1, o_2]$), obtidos de leituras de sensores não-lineares (misturadores) e cujos sinais originais ($\mathbf{s}=[s_1, s_2]$) foram gerados segundo distribuições desconhecidas, obter a transformação $\mathbf{y} = \mathbf{F}(\mathbf{o}) = [y_1, y_2]$ que estime os vetores originais (\mathbf{s}) sem conhecimento prévio de características específicas, tanto dos sensores como dos sinais sob medição, admitindo-se apenas que os sinais originais são estatisticamente independentes entre si e a não-linearidade inserida nos medidores é uma função inversível, pelo menos no domínio operacional do aparato. A Figura 5.1 ilustra sinteticamente o contexto.

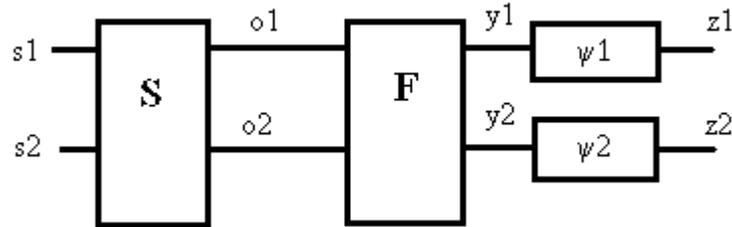


Figura 5.1 – Diagrama do aparato global de separação

Tanto a abordagem INFOMAX quanto a MISEP objetivam minimizar a informação mútua dos componentes da variável aleatória \mathbf{y} , definida pela fórmula

$$I(\mathbf{y}) = \sum_i H(y_i) - H(\mathbf{y}) \quad (5.1)$$

onde $H(\mathbf{y})$, a entropia diferencial de Shannon (ALMEIDA, 2006), é definida por

$$H(\mathbf{y}) = -\int p(\tilde{\mathbf{y}}) \log p(\tilde{\mathbf{y}}) d\tilde{\mathbf{y}} \quad (5.2)$$

sendo p a função densidade de probabilidade da variável aleatória em questão e o logaritmo aqui adotado o neperiano, embora seja possível adotar outras bases, como a decimal.

A informação mútua $I(\mathbf{y})$ é não-negativa, sendo nula apenas quando as componentes do vetor \mathbf{y} são estatisticamente independentes, e considerada uma boa medida da independência entre os y_i para uso em análise de componentes independentes (ALMEIDA, 2006). Assim, o presente trabalho utilizará o mesmo índice na solução do problema proposto, embora sua estimação seja realizada de modo completamente diverso dos demais.

Os métodos MISEP e INFOMAX utilizam abordagens neurais, com treinamento baseado em gradientes, com o segundo restrito somente a misturas lineares. Em consequência, ambos são suscetíveis a aprisionamento em mínimos locais da função sob minimização (informação mútua), e cujo estimador será determinado no que segue. Daí surge uma oportunidade para aprimoramento, se for possível sintetizar aprendizado com garantia teórica de alcance do ótimo global do referido índice de desempenho.

Propõe-se aqui realizar \mathbf{F} por meio de um sistema de inferência fuzzy MIMO (*Multiple Input Multiple Output*) do tipo Takagi-Sugeno-Kang, que possui propriedades aproximativas em condições teóricas bastante gerais (ABONYI, 2003) e equivalentes a ANNs típicas, ψ_1 e ψ_2 por meio da composição de sigmóides com polinômios não-decrescentes e aprendizado por reforço usando Fuzzy ASA, que possui garantia teórica de convergência a ótimos globais sob condições pouco restritivas e compatíveis com o problema em questão, a saber, minimizar a informação mútua entre as componentes de \mathbf{y} . Desse modo, e considerando igual número de sinais e sensores, \mathbf{F} será realizado por um sistema MIMO TSK, que pode apresentar adaptabilidade tanto nas partes antecedentes como conseqüentes, por meio de seus parâmetros característicos, tendo sido os exemplos construídos de modo a adaptar somente os coeficientes das partes conseqüentes e em dimensão 2, para melhor inteligibilidade das comparações com resultados anteriores.

Como citado anteriormente, a função objetivo para minimização é a informação mútua $I(\mathbf{y})$ e busca-se uma expressão computacionalmente adequada para atingir tal meta. Supondo-se que cada uma das funções no estágio de saída é a CDF (*Cumulative Distribution Function*) dos y_i , é fácil ver que os z_i serão uniformemente distribuídos no intervalo $[0,1]$, resultando em $H(z_i)=0$, e chegando à seguinte expressão para $I(\mathbf{z})$

$$I(\mathbf{z}) = \sum_i H(z_i) - H(\mathbf{z}) = -H(\mathbf{z}) \quad (5.3)$$

Além disso, cada z_i é relacionado a y_i por meio de uma função inversível (bijetora), resultando em $I(\mathbf{y})=I(\mathbf{z})$. Em conseqüência, obtemos

$$I(\mathbf{y}) = -H(\mathbf{z}) \quad (5.4)$$

Concluimos que, ao maximizar a entropia de saída $H(\mathbf{z})$, estaremos minimizando a informação mútua $I(\mathbf{y})$, que é o efeito final desejado. Logo, o presente método buscará maximizar $H(\mathbf{z})$, tendendo simultaneamente para a configuração em que as funções ψ_i coincidam com as CDFs das saídas y_i . A expressão parametrizada para cada ψ_i é

$$\psi_i(x)=\text{sig}(a+bx+cx^3+dx^5+ex^7) \quad (5.5)$$

onde

$$\text{sig}(x)=1/(1+e^{-x}), a, b, c, d, e \geq 0 \quad (5.6)$$

Por serem não decrescentes, assumirem valores não negativos e restritos ao intervalo $[0,1]$, são adequadas à representação de distribuições acumuladas. O grau 7 para o polinômio se mostrou adequado e suficiente em todos os casos experimentais, não havendo inconveniente algum em elevá-lo, a não ser o correspondente aumento de complexidade computacional, principalmente na fase de treinamento.

Ao contrário do método INFOMAX, tais funções serão ajustadas durante o treinamento global e, diferentemente de MISEP, o treinamento não será realizado por métodos neurais. Como as ψ_i têm papel acessório, ao final do treinamento o estágio de saída será descartado, sendo utilizado somente o sistema \mathbf{F} .

Para efetivar a otimização propriamente dita é necessário dispor de algum tipo de expressão relacionando as leituras (\mathbf{o}) e a entropia $H(\mathbf{z})$, considerando que o

ajustamento deve ser realizado a partir dos dados experimentais disponíveis. Isso é realizado pela observação da seguinte expressão

$$H(\mathbf{z}) = H(\mathbf{o}) + \langle \log |\det \mathbf{J}| \rangle \quad (5.7)$$

na qual \mathbf{J} é o jacobiano da transformação composta por \mathbf{F} e o estágio de saída, e o operador $\langle \rangle$ denota valor esperado. Como a entropia $H(\mathbf{o})$ é independente dos parâmetros sob ajuste, pode ser ignorada para efeitos de otimização, restando a segunda parcela, que é aproximada pela média amostral calculada por meio de cada um dos elementos do *training set* (valores observados) e cuja expressão é

$$\langle \log(|\det \mathbf{J}|) \rangle \cong \frac{1}{K} \sum_{k=1}^K \log(|\det \mathbf{J}^k|) = E, \quad (5.8)$$

$$\mathbf{J} = [\partial z_i / \partial o_j]$$

onde $\det \mathbf{J}^k$ denota o valor do jacobiano em um ponto genérico do *training set* e K é o número de elementos daquele conjunto. Esta é a função usada no processo de ajustamento, dependendo dos valores \mathbf{J}^k e parâmetros sob adaptação. Dessa forma, quando o processo de minimização evolui, o sistema \mathbf{F} e as funções ψ_i tendem a assumir configurações favoráveis à recuperação do vetor aleatório original (\mathbf{s}), apresentado aos sensores de entrada.

Tratando especificamente dos exemplos, teremos 64 parâmetros a estimar, com 54 correspondentes ao sistema TSK e 10 às funções auxiliares, tendo em vista que a realização lança mão de sistema MIMO com 2 entradas e 2 saídas, subdivisão exaustiva (*grid*) e fixa do domínio de entrada (normalizado em $[0,1] \times [0,1]$), apresentando 9 regras com 3 parâmetros conseqüentes cada, usados da forma $y = p_{i0} + p_{i1}x_1 + p_{i2}x_2$, resultando em $9 \times 3 \times 2 = 54$ elementos a determinar. Quanto às ψ_i , são compostas de sigmóides padrão compostas com polinômios de grau 7 e coeficientes não negativos nos termos de grau ímpar, a menos do termo constante, com supressão dos de grau par, o que resulta em 5 parâmetros para cada uma delas – como a dimensão de saída é 2, resulta o total de $2 \times 5 = 10$ coeficientes. Assim, o vetor apresentado ao algoritmo Fuzzy ASA será composto pela concatenação de 27 números reais correspondentes ao primeiro sistema TSK, 27 do segundo, 5 da primeira função (ψ_1) e 5 da segunda função (ψ_2).

Quanto à decomposição do domínio de entrada normalizado, foram utilizadas 3 funções de pertinência materializadas em termos fuzzy (ABONYI, 2003) correspondentes aos conceitos de alto, médio e baixo, que demonstraram ser eficazes na aproximação das funções inversas encontradas.

Tendo em vista o fato que a análise de componentes independentes por métodos não lineares pode não apresentar um único resultado sem restrições adicionais à minimização da informação mútua, seja no modelo assumido ou nas condições de contorno, foram realizados testes adicionais utilizando o chamado modelo pós não linear (PNL), que consiste em assumir que a mistura é composta de operação linear seguida de aplicação de não linearidade em cada dimensão. Logo, o diagrama da Figura 5.1 assumiria a forma mostrada na Figura 5.2

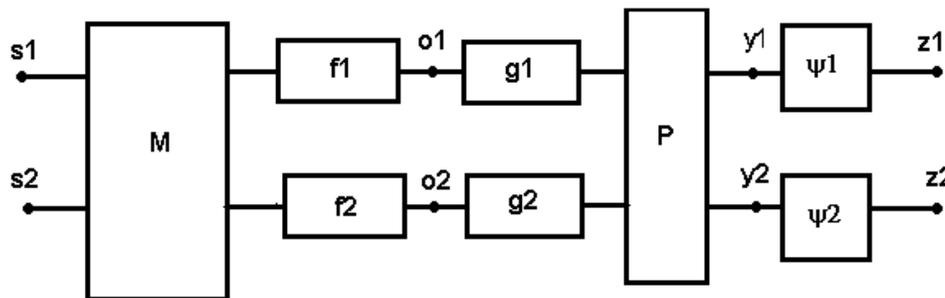


Figura 5.2 – Modelo PNL

Sendo assim, foi assumida a condição que a não linearidade genérica da mistura original consiste de multiplicação por uma matriz (\mathbf{M}) seguida pela aplicação unidimensional de operadores não lineares ($f1$ e $f2$), o que é compatível com as situações encontradas na prática (GÓRRIZ *et al.*, 2006). Para realizar a separação, é empregada a configuração inversa, ou seja, aplicação de operadores não lineares ($g1$ e $g2$) seguida de multiplicação pela matriz (\mathbf{P}), cujos parâmetros deverão ser determinados.

Na presente pesquisa, $g1$ e $g2$ são sistemas Takagi-Sugeno-Kang SISO (*Single Input Single Output*) com domínio de entrada normalizado no intervalo $[-1,1]$ e granularidade dada por termos *fuzzy* denominados BAIXO, MÉDIO e ALTO, fixos. Na parte conseqüente, encontramos as expressões usuais parametrizadas pelos coeficientes das expressões afins. Similarmente ao primeiro caso, o ajuste será realizado em tais

coeficientes, mantendo as expressões antecedentes fixas, com 3 regras para cada sistema de inferência. As funções ψ_1 e ψ_2 , como antes, correspondem às CDFs das saídas y_i , e seu tratamento será exatamente o mesmo.

5.2 Implementação

No caso específico do modelo PNL aqui tratado, teremos 26 parâmetros a estimar, com 12 correspondentes aos sistemas TSK, 10 às funções auxiliares ψ_i e 4 à matriz P, tendo em vista que a realização lança mão de 2 sistemas SISO, subdivisão exaustiva (*grid*) e fixa do domínio de entrada (normalizado em [-1,1]), apresentando, cada um, 3 regras com 2 parâmetros conseqüentes cada e usados na forma $y=p_{i0}+p_{i1}x$, resultando em $3 \times 2 \times 2 = 12$ elementos a determinar. Quanto às ψ_i , são compostas de sigmóides padrão compostas com polinômios de grau 7 e coeficientes não negativos nos termos de grau ímpar, a menos do termo constante, com supressão dos de grau par, o que resulta em 5 parâmetros para cada uma delas – como o número de saídas é 2, temos o total de $2 \times 5 = 10$ coeficientes. Assim, o vetor apresentado ao algoritmo Fuzzy ASA será composto pela concatenação de 12 números reais correspondentes aos sistemas TSK, 5 da primeira função (ψ_1), 5 da segunda função (ψ_2) e, finalmente, 4 relativos aos elementos da matriz P. De modo similar aos problemas anteriores, a informação mútua é minimizada por meio de aproximações obtidas através do cálculo do determinante Jacobiano em pontos do *training set*, como descrito anteriormente. Todas as operações específicas são encapsuladas em um único módulo, que é ativado repetidamente pelo núcleo principal em sua trajetória rumo à configuração desejada.

5.3 Resultados

A partir desse ponto serão apresentados alguns resultados usados na validação da presente proposta e demonstrativos de sua eficácia, e, em cada caso, será feita a comparação com o respectivo resultado obtido através do método MISEP.

5.3.1 – Exemplo 1 – separação por sistema TSK MIMO

Neste caso os pontos originais foram gerados através de distribuições de Laplace e uniforme unidimensionais, de modo a gerar sinais estatisticamente independentes, em conformidade com as premissas do problema, como mostrado na Figura 5.3. Para tanto, as coordenadas de cada dimensão foram geradas e condicionadas separadamente tendendo a uma distribuição conjunta em forma de cruz, indicativa da condição desejada. Em seguida, foi aplicada a não linearidade expressa por ($o_1 = s_1 + 4s_2^2$, $o_2 = s_2 + 4s_1^2$), produzindo o *training set* a ser usado no processo de análise propriamente dito, como pode ser visto na Figura 5.4.

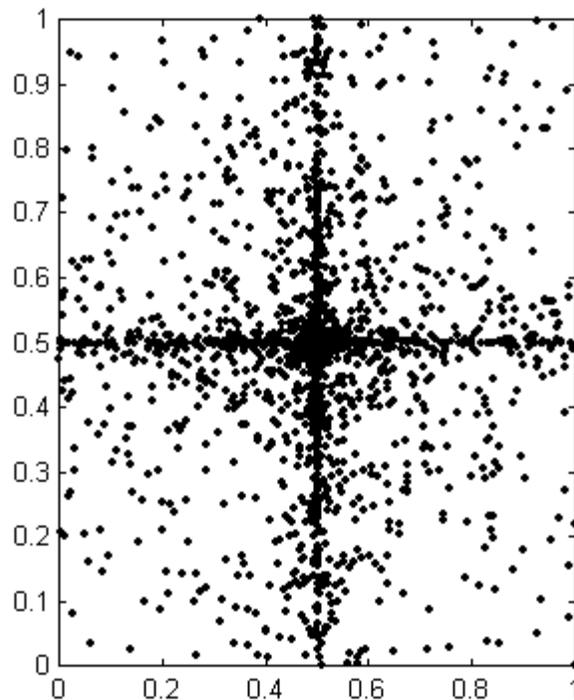


Figura 5.3 – Distribuição conjunta dos sinais originais

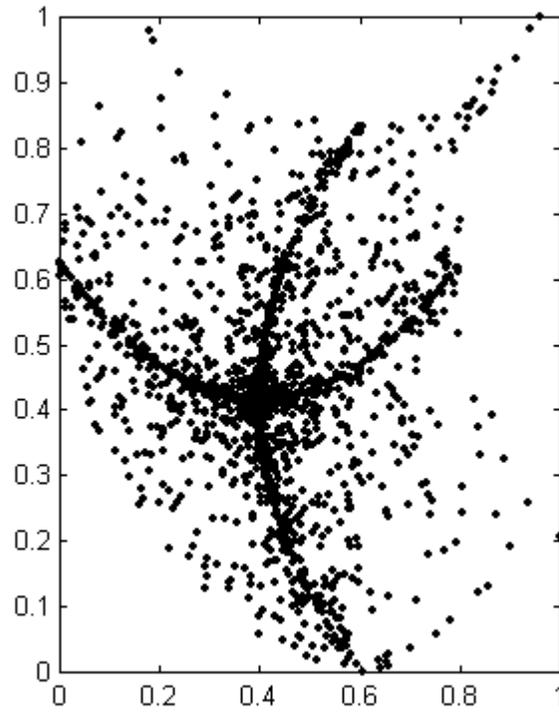


Figura 5.4 – Distribuição conjunta dos sinais transformados

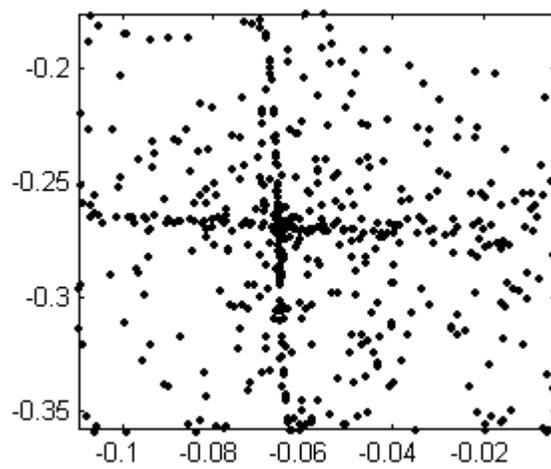


Figura 5.5 – Distribuição conjunta dos sinais recuperados pelo método proposto

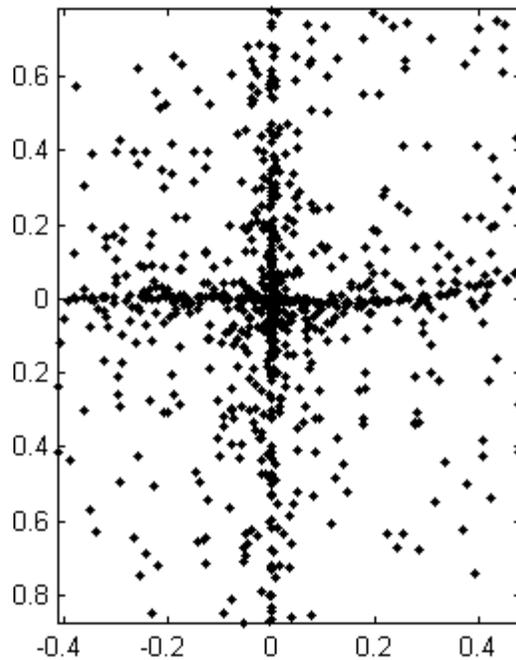


Figura 5.6 – Distribuição conjunta dos sinais recuperados pelo método MISEP

Note-se que, assim como no caso linear, admite-se tanto permutação quanto mudança de escala nos sinais recuperados.

Os resultados obtidos pelos dois métodos são mostrados na Figuras 5.5 e 5.6, por meio da distribuições conjuntas dos sinais resultantes, e demonstram graficamente a eficácia de ambos neste caso particular, a menos de algumas peculiaridades, como distorção não-linear nas regiões periféricas.

É possível notar que as distribuições conjuntas obtidas pelos dois métodos indicam a independência estatística dos sinais resultantes da separação, tendo em vista a predominância de pontos agrupados ao longo de eixos aproximadamente horizontais e verticais.

5.3.2 – Exemplo 2 – separação por sistema TSK MIMO

Neste caso os pontos originais foram gerados através de distribuições de Laplace e uniforme unidimensionais, de modo a gerar sinais estatisticamente independentes, em conformidade com as premissas do problema, como mostrado na Figura 5.7a. Para tanto, as coordenadas de cada dimensão foram geradas e condicionadas separadamente, tendendo a uma distribuição conjunta em forma de coluna vertical, indicativa da condição desejada. Em seguida, foi aplicada a não linearidade expressa por $(o_1 = s_1 + 4s_2^2, o_2 = s_2 + 4s_1^2)$, produzindo o *training set* a ser usado no processo de análise propriamente dito, que é representado na Figura 5.7b.

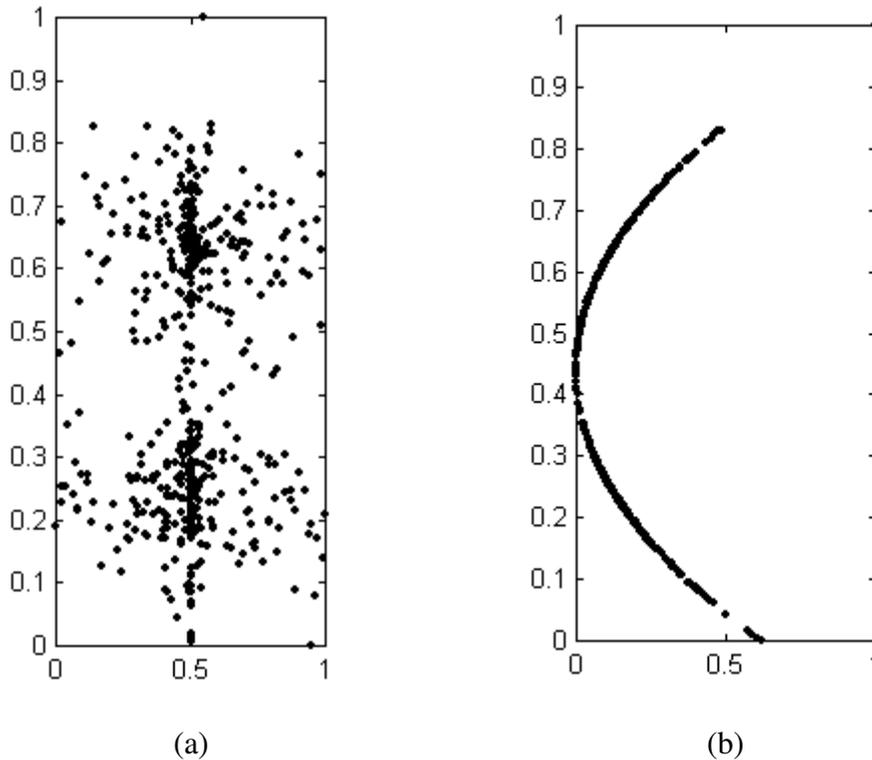


Figura 5.7 – Distribuição conjunta dos sinais (a) originais e (b) medidos

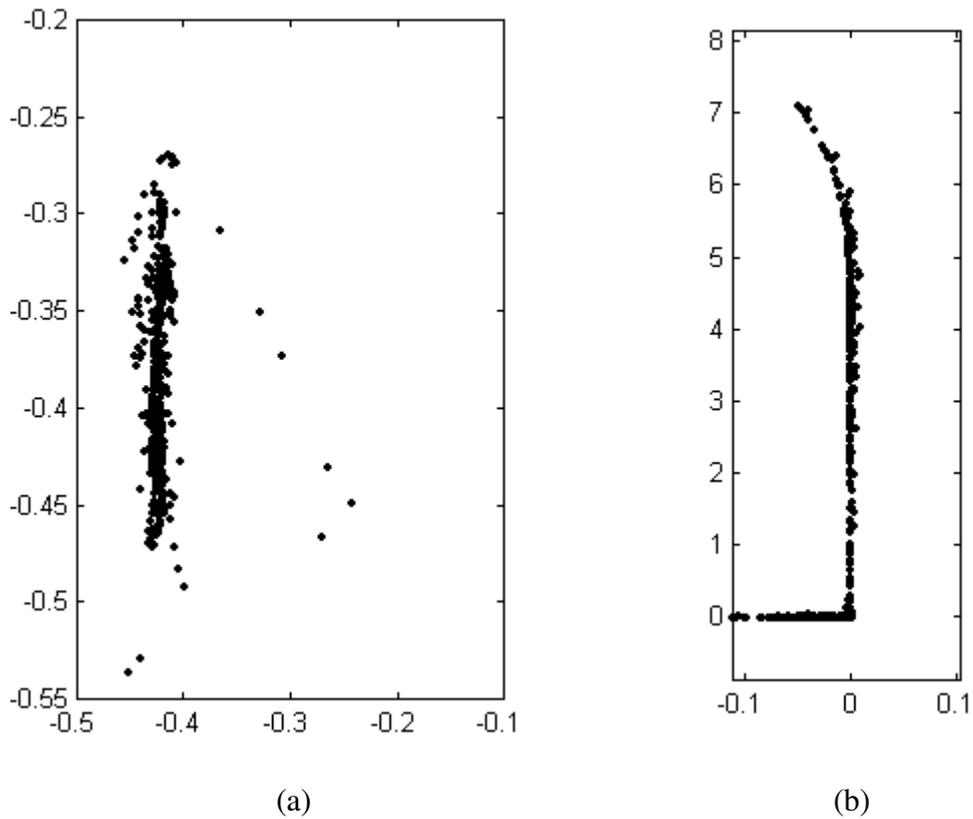
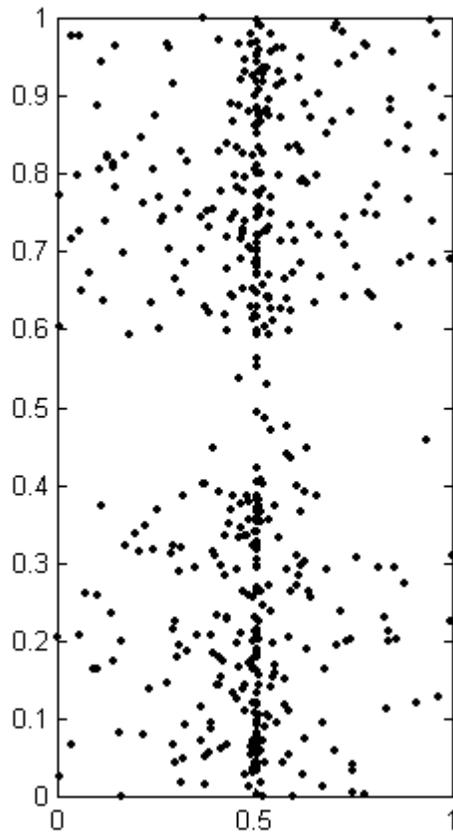


Figura 5.8 – Distribuições recuperadas (a) método proposto e (b) MISEP

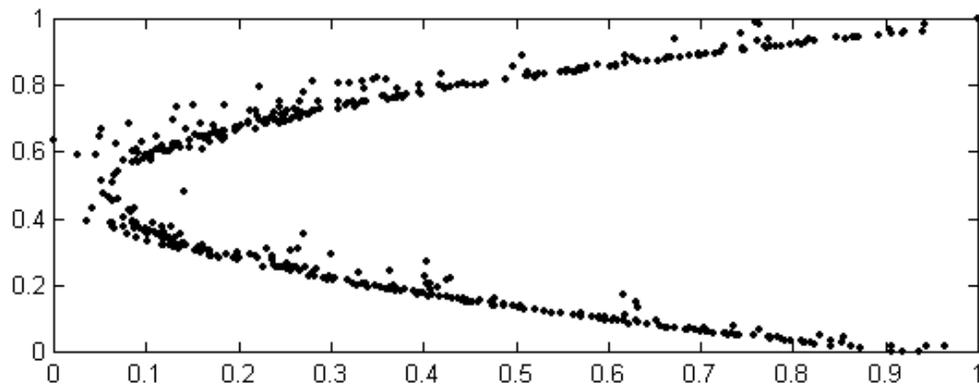
Pode-se ver na Figura 5.8b um exemplo de falha do método MISEP na recuperação da configuração original dos sinais, tendo em vista principalmente o segmento horizontal inferior. Na Figura 5.8a, vemos o resultado da recuperação bem sucedida pelo método proposto. Pode-se ver que a distribuição conjunta obtida pelo método proposto indica a independência estatística dos sinais resultantes da separação, tendo em vista a predominância (agrupamento) de pontos na proximidade de um segmento vertical, como a apresentada pelos sinais originais, diferentemente da configuração mostrada na Figura 5.8b, correspondente ao método MISEP.

5.3.3 – Exemplo 3 – separação por sistema TSK MIMO

Neste outro caso os pontos originais foram gerados através de distribuições uniformes unidimensionais, customizadas de modo a gerar sinais estatisticamente independentes, em conformidade com as premissas do problema. Para tanto, as coordenadas de cada dimensão foram condicionadas separadamente tendendo a uma distribuição conjunta em forma de coluna vertical segmentada, indicativa da condição desejada, como mostra a Figura 5.9a. Em seguida, foi aplicada a não linearidade expressa por ($o_1 = s_1 + 4s_2^2$, $o_2 = s_2 + 4s_1^2$), produzindo o *training set* a ser usado no processo de análise propriamente dito, representado na Figura 5.9b.

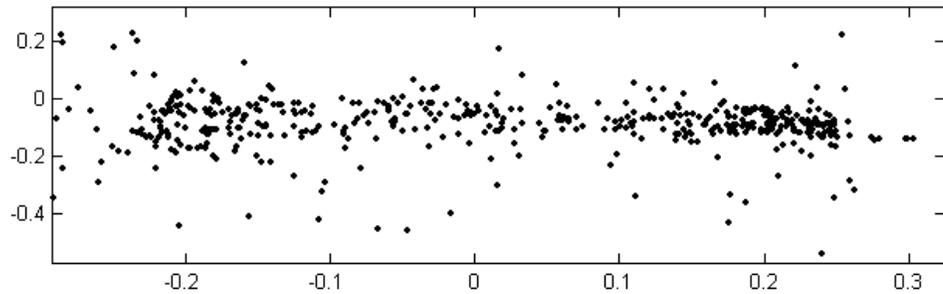


(a)

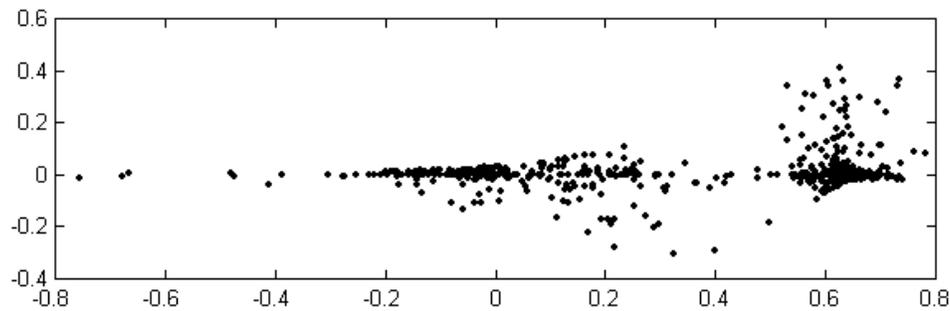


(b)

Figura 5.9 – Distribuição conjunta (a) sinais originais e (b) medidos



(a)



(b)

Figura 5.10 – Sinais recuperados (a) método proposto e (b) MISEP

É notório que houve permutação na ordem dos sinais recuperados, mostrados nas Figuras 5.10a e 5.10b, além da usual mudança de escala, tendo em vista que os eixos principais estão na posição horizontal, ao contrário da configuração original (Figura 5.9a). Observa-se mais uma vez que a distribuição conjunta obtida pelo método proposto sinaliza a independência estatística dos sinais resultantes da separação, levando em conta a existência do agrupamento de pontos na direção horizontal, o mesmo não ocorrendo no diagrama correspondente aos sinais separados pelo método MISEP (Figura 5.10b), particularmente em seu extremo direito.

5.3.4 – Exemplo 4 – separação por sistema TSK MIMO

Neste outro caso os pontos originais foram gerados através de distribuições de Laplace unidimensionais, customizadas de modo a gerar sinais estatisticamente independentes, em conformidade com as premissas do problema (Figura 5.11a). Para tanto, as coordenadas de cada dimensão foram condicionadas separadamente tendendo a uma distribuição conjunta em forma de coluna vertical segmentada, indicativa da condição desejada. Em seguida, foi aplicada a transformação linear expressa por $(o_1 = s_1 + 4s_2, o_2 = s_2 + s_1)$ sucedida pela distorção da segunda coordenada através da função $\tanh(0.4x)$, produzindo o *training set* a ser usado no processo de análise propriamente dito, que está representado na Figura 5.11b.

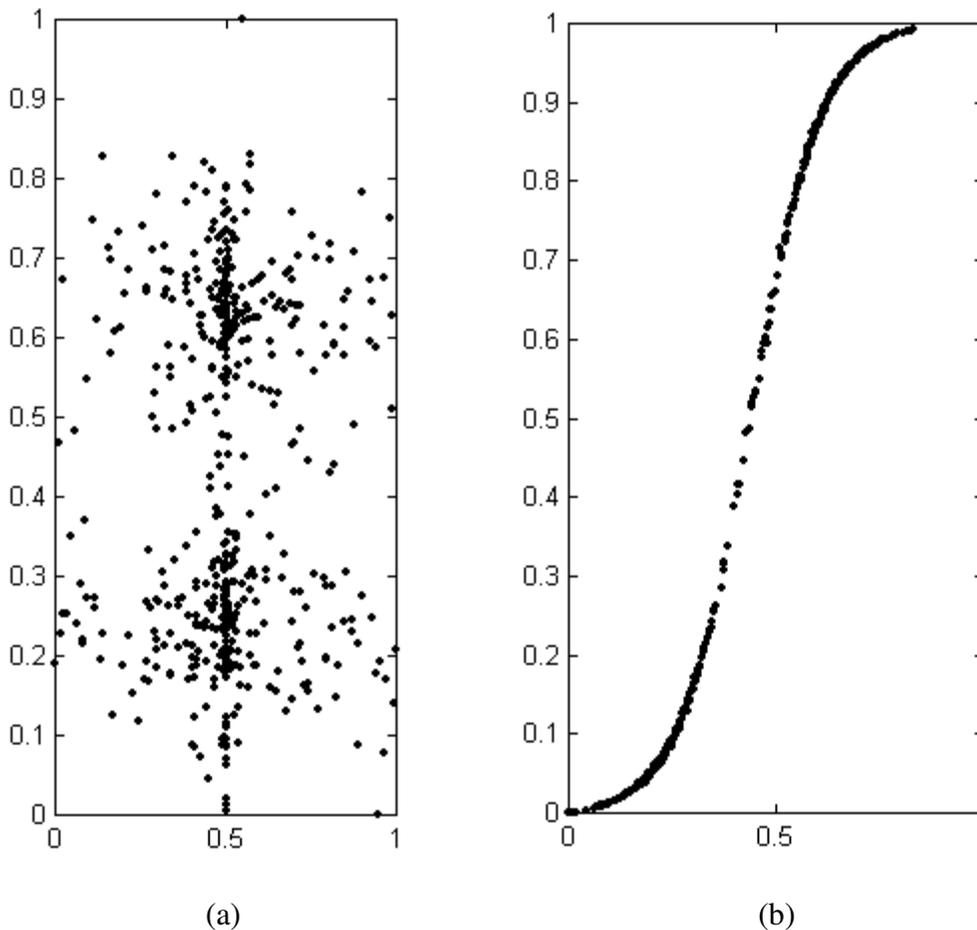


Figura 5.11 – Distribuição conjunta (a) sinais originais e (b) medidos

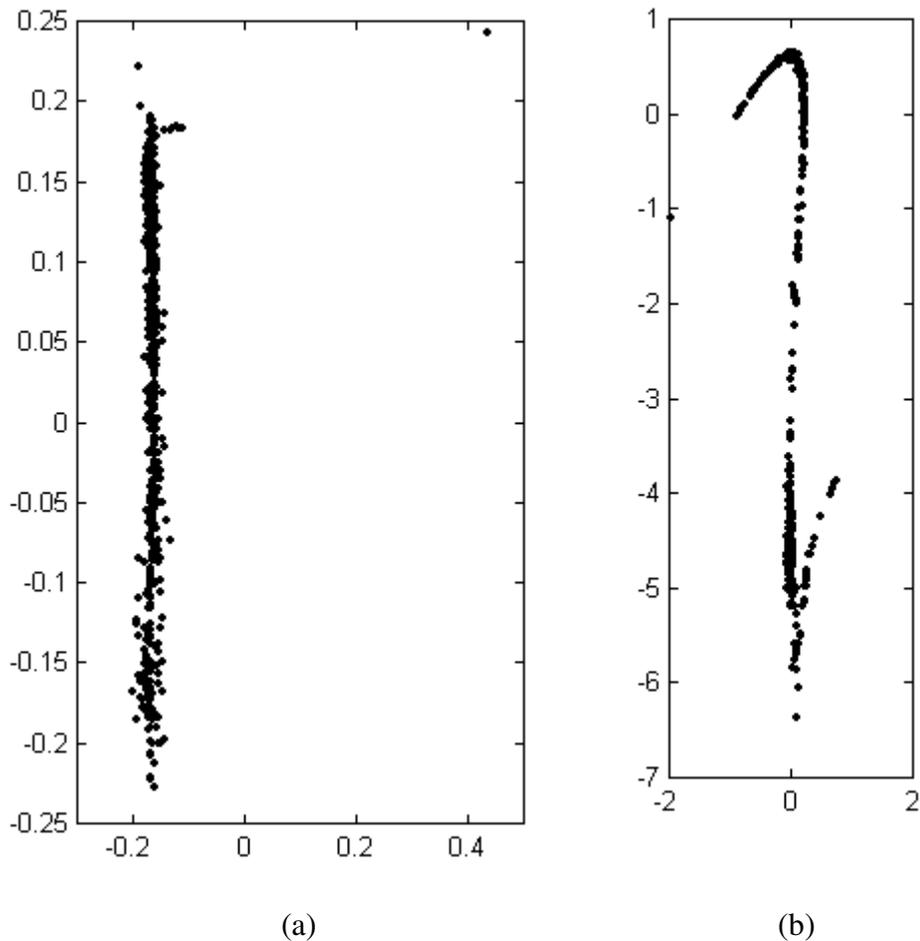


Figura 5.12 – Sinais recuperados (a) método proposto e (b) MISEP

Pode-se ver aqui um exemplo de falha do método MISEP na recuperação da configuração original dos sinais (Figura 5.12b), quando comparado ao resultado obtido pelo método proposto (Figura 5.12a), tendo em vista, particularmente, as partes superior e inferior da configuração resultante. Neste exemplo a distribuição conjunta obtida pelo método proposto aponta para a independência estatística dos sinais resultantes da separação, considerando o agrupamento de pontos na direção vertical, em contraste ao mostrado no diagrama correspondente aos sinais separados pelo método MISEP (Figura 5.12b), particularmente em seus extremos.

5.3.5 – Exemplo 5 – mistura por modelo PNL

Neste exemplo os sinais originais (Figura 5.13) foram obtidos pela digitalização de sons reais e misturados através de transformação linear sucedida de distorção pelas funções $\tanh(x)$ e $\tanh(0.5x)$, produzindo o *training set* de 1000 elementos a ser usado no processo de análise propriamente dito, representado por meio das Figuras 5.15 e 5.16. Pela distribuição conjunta dos sinais não distorcidos, como ilustrado na Figura 5.14, é possível constatar que apresentam alto grau de independência estatística, em conformidade com as premissas do problema.

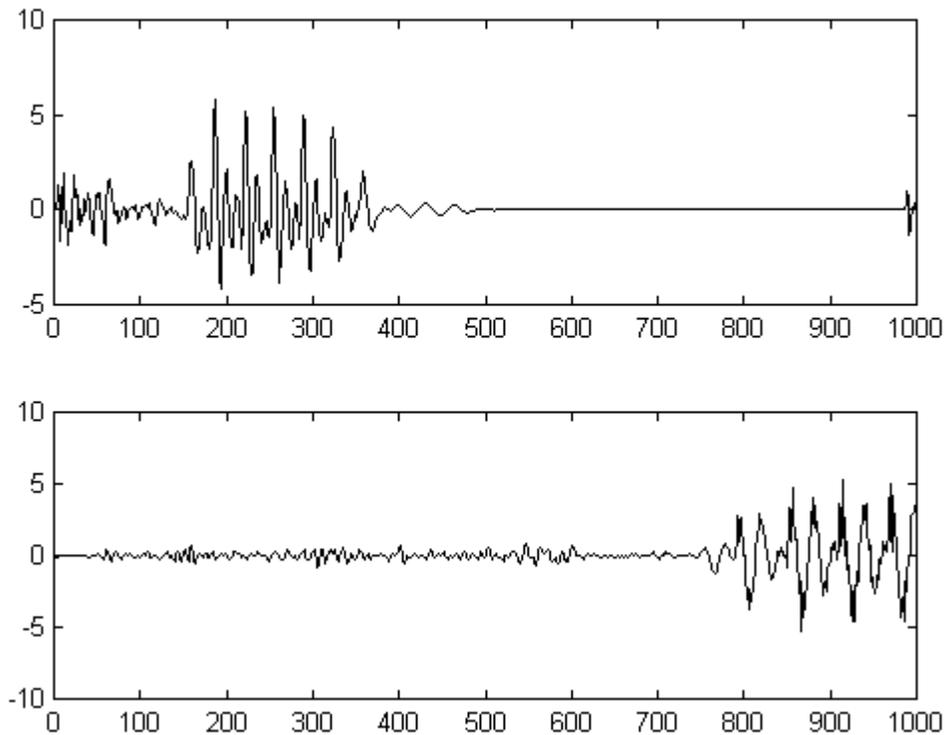


Figura 5.13 – Sinais originais

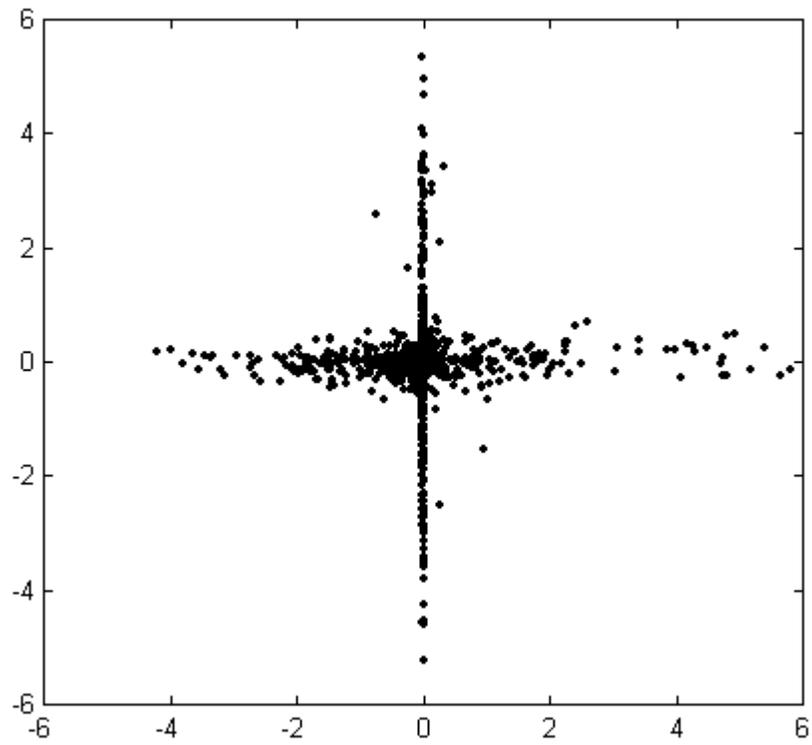


Figura 5.14 – Distribuição conjunta dos sinais originais

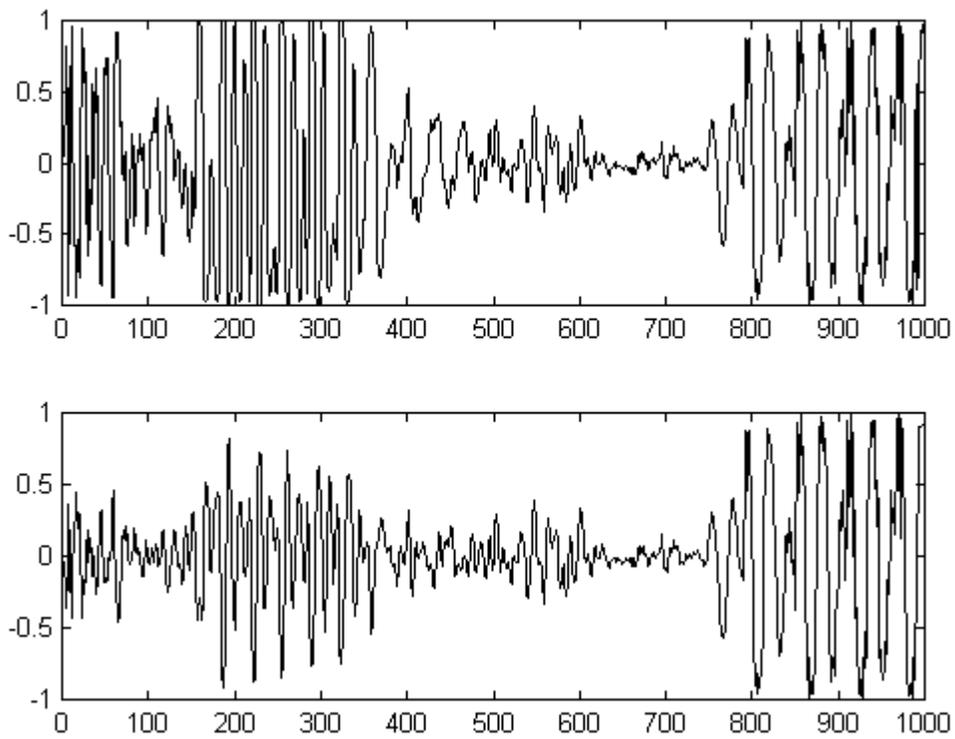


Figura 5.15 – Misturas utilizadas para treinamento

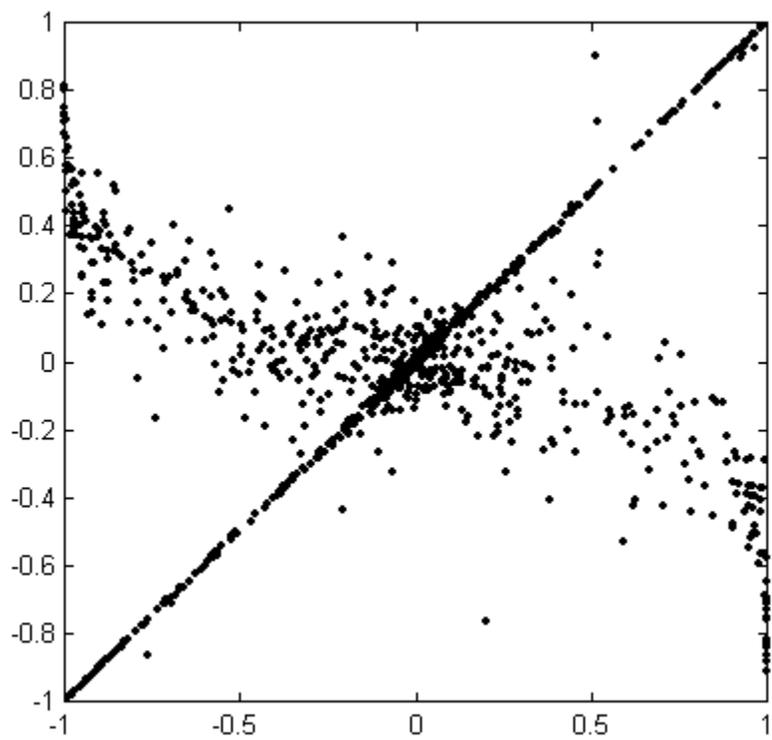


Figura 5.16 – Distribuição conjunta dos sinais misturados

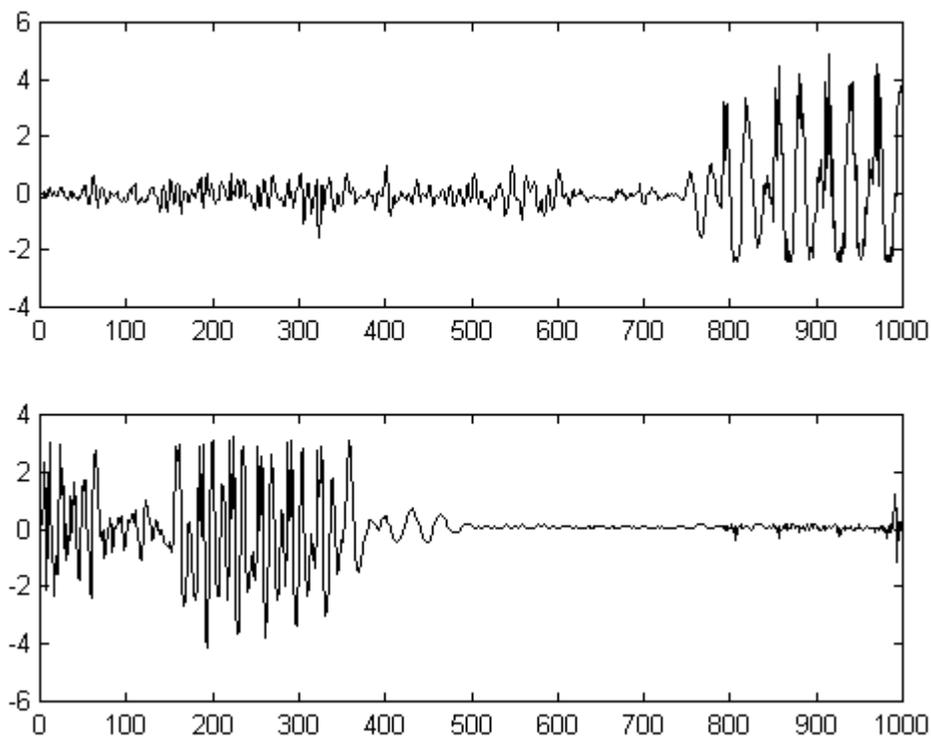


Figura 5.17 – Sinais recuperados pelo método proposto

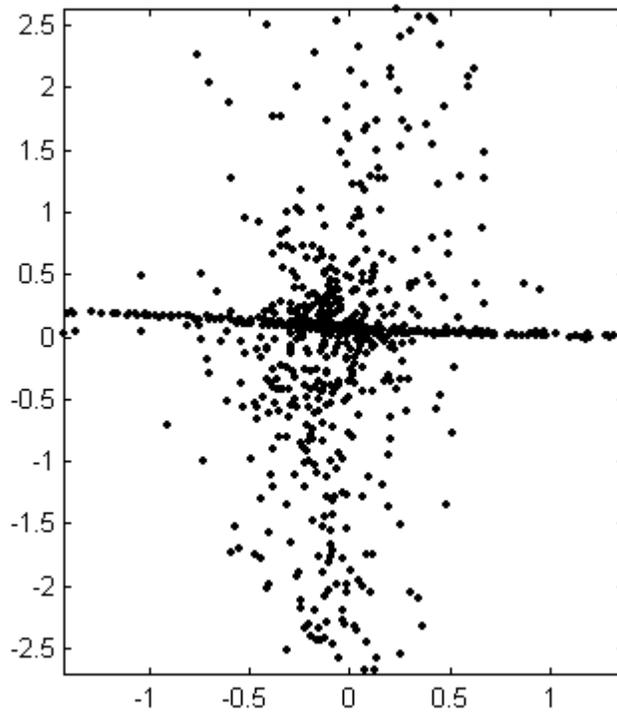


Figura 5.18 – Distribuição conjunta dos sinais recuperados pelo método proposto

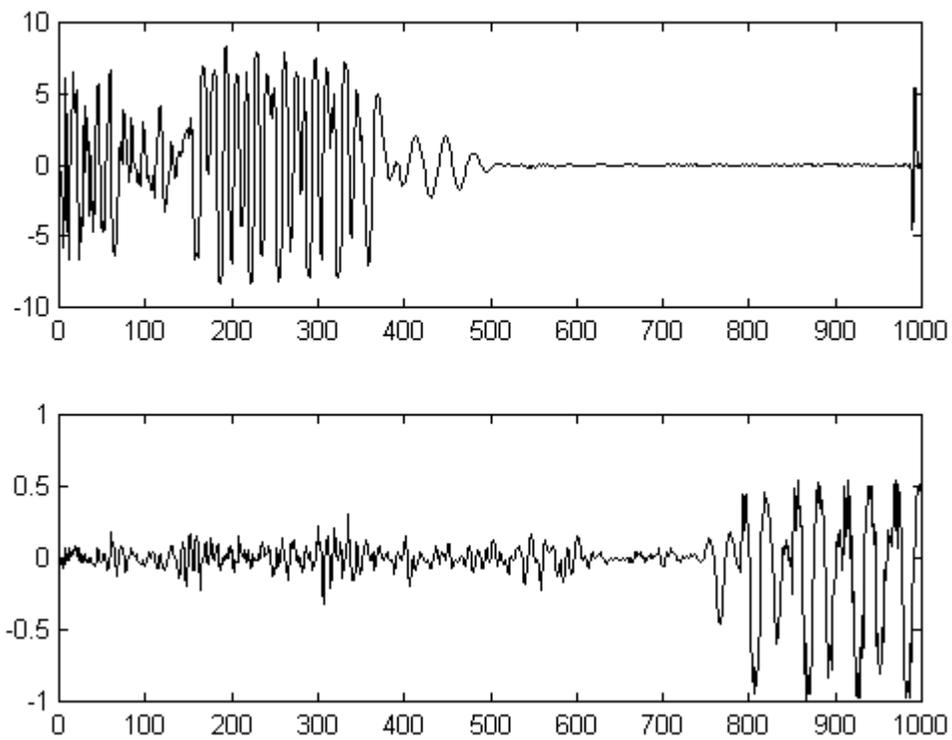


Figura 5.19 – Sinais recuperados pelo método MISEP

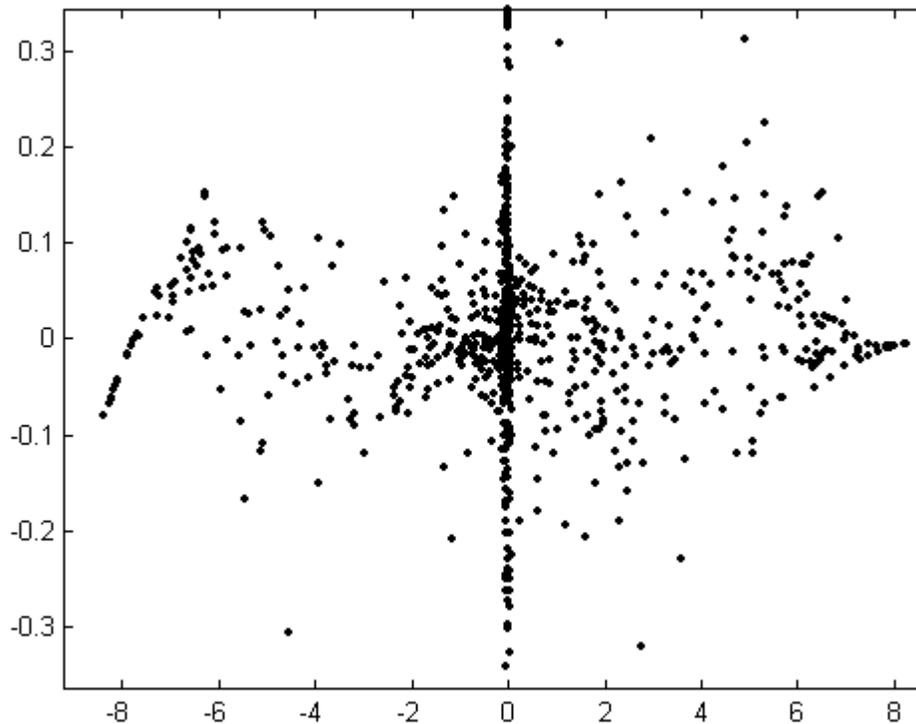


Figura 5.20 – Distribuição conjunta dos sinais recuperados pelo método MISEP

Para maior precisão na avaliação dos resultados, foi utilizado o índice conhecido como *crosstalk* residual e definido pela expressão $E[(\mathbf{y}-\mathbf{s})^2]$, sendo \mathbf{y} o sinal recuperado e \mathbf{s} o original, ambos condicionados de modo a apresentar variância unitária. Levando em conta que quanto menor o valor do índice escolhido, melhor a qualidade da recuperação, resta computá-lo usando os sinais obtidos pelas duas abordagens e comparar os valores numéricos obtidos. Os valores alcançados pelo método aqui apresentado são -7.7314 dB (ou 0.41061) para o primeiro sinal e -20.8643 dB (ou 0.090528) para o segundo sinal, enquanto que para o MISEP são 23.3090 dB (ou 14.6369) e -4.1943 dB (ou 0.6169), respectivamente, levando à conclusão que o algoritmo proposto superou o MISEP neste exemplo. Observa-se, através das Figuras 5.17 e 5.18, que houve inversão de ordem dos sinais em um dos casos de separação, situação compatível com as condições impostas à solução do problema, ou seja, são permitidas tanto permutações quanto mudanças de escala. O método MISEP preservou a ordem das entradas, conforme mostrado nas Figuras 5.19 e 5.20.

5.4 – Conclusões – separação cega de misturas não lineares

Neste capítulo foram apresentados os resultados da aplicação do algoritmo Fuzzy ASA à separação de misturas não lineares através de sistemas também não lineares, cuja finalidade é inverter o efeito de distorções causadas por dispositivos de aquisição de dados reais e recuperar os componentes não diretamente observáveis que deram origem a um conjunto de sinais observáveis. As hipóteses assumidas são compatíveis com as situações encontradas na prática (fontes estatisticamente independentes e não linearidades inversíveis), não limitando a utilidade dos resultados encontrados.

Foram abordados dois tipos de problemas de separação de fontes (mistura não linear genérica e mistura pós não linear - PNL), e os dois modelos paramétricos adotados para sua solução usaram sistemas fuzzy do tipo Takagi-Sugeno-Kang associados a polinômios para obtenção do comportamento desejado. Para tanto, foi sintetizada uma aproximação computacional adequada do índice conhecido como informação mútua entre sinais aleatórios e utilizado o algoritmo Fuzzy ASA para efetuar sua minimização global, tendo como variáveis os parâmetros que determinam os vários dispositivos presentes no aparato de separação. É pertinente observar que, particularmente no caso de recuperação de sinais individuais misturados através do modelo PNL, é possível realizar separação paralela de trechos dos sinais fontes, o que pode acelerar significativamente o processo global. Os resultados obtidos foram satisfatórios e, quando comparados aos obtidos com o método MISEP (ALMEIDA, 2006), demonstraram desempenho superior em diversos casos.

CAPÍTULO 6

CONCLUSÕES E SUGESTÕES PARA PESQUISA ADICIONAL

Tendo em vista os resultados obtidos, pode-se concluir que os métodos propostos na presente pesquisa são eficazes quando aplicados a projeto de filtros lineares FIR com coeficientes reais, bancos de filtros QMF (pela obtenção do respectivo filtro protótipo) e separação de fontes, apresentando índices de desempenho superiores e/ou comparáveis aos estabelecidos até a presente data. Além disso, são passíveis de aplicação à modelagem de sistemas digitais mais gerais e com características analíticas complexas, de difícil tratamento pelos métodos convencionais universalmente aceitos. Sendo assim, é necessário usá-los em casos adicionais relevantes e concluir sobre o escopo de sua utilidade prática. Assim, será possível estender ainda mais a utilidade desta ferramenta de fácil encapsulamento em programas voltados ao projeto automático de filtros e apto ao ataque de problemas de difícil tratamento analítico em forma fechada. Outro produto importante do presente trabalho foi a obtenção das curvas de compromisso relacionando erro de reconstrução perfeita e atenuação na faixa de rejeição do filtro protótipo em bancos QMF, que proporcionam uma visão abrangente das possibilidades de aprimoramento em projetos específicos.

É claro que, no futuro, o mesmo tipo de abordagem poderá ser aplicada com a substituição do algoritmo de otimização global presentemente utilizado por outro, demonstrando a versatilidade e modularidade do método aqui proposto. Esse procedimento será vantajoso se o suposto substituto for eficaz, considerando que a fase de ajustamento é crucial para o sucesso na resolução de problemas.

Resultados igualmente promissores foram alcançados quando o algoritmo Fuzzy ASA foi aplicado à separação cega de sinais e análise de componentes independentes, como coadjuvante na síntese de sistemas não lineares capazes de inverter distorções introduzidas por sensores acoplados de modo também não linear. Em particular, o método mostrou-se eficaz quando utilizado na separação de misturas pós não lineares (PNL), superando a abordagem MISEP, proposta em (ALMEIDA, 2006). Além disso, é adequado para implementação em ambientes multiprocessados, ou seja, é possível segmentar um dado

problema de separação, executar simultaneamente diversos ajustamentos e, ao final, justapor os resultados obtidos. Cabe salientar que, embora a informação mútua seja uma grandeza adequada para utilização na separação cega de sinais e análise de componentes independentes, certos problemas com misturas não lineares podem possuir mais de uma solução quando a usamos como única meta, criando a necessidade de aplicação da chamada regularização, que consiste tipicamente da imposição de vínculos adicionais ao problema, de modo que ocorra a convergência a uma solução adequada. Tal tópico é presentemente alvo de intensa pesquisa e pode ser uma ferramenta importante em alguns casos, se agregada futuramente aos métodos aqui apresentados.

O êxito alcançado em todos os tipos de problemas aqui tratados pode ser estendido a outros modelos paramétricos, com restrições ou não, de modo que o potencial da abordagem apresentada seja investigado e estimado de modo ainda mais abrangente. Talvez a maior contribuição oferecida em todo o trabalho seja a apresentação de um método geral de modelagem que, embora levando em conta os aspectos específicos e particulares de um dado problema, viabiliza a obtenção de sistemas satisfatórios a partir de dados amostrais, dispensando processos de modelagem convencionais (do tipo caixa branca). Tal característica é coerente com as numerosas linhas de investigação atuais, que utilizam cada vez mais esses tipos de estratégia. É claro que tal caminho não teria sido possível sem a eficácia do algoritmo Fuzzy ASA, usado exhaustivamente na solução de todos os problemas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABONYI, J., 2003, **Fuzzy Model Identification for Control**. Boston, Birkhäuser.
- ALMEIDA, L. B., 2006, **Nonlinear Source Separation**. Morgan & Claypool Publishers.
- BARHEN, J., PROTOPODESCU, V., REISTER. D., 1997, “TRUST - A Deterministic Algorithm for Global Optimization”, **Science**, v. 276 (May), pp. 1094-1097.
- BELL, A., SEJNOWSKI, T., 1995, ”An information-maximization approach to blind separation and blind deconvolution”, **Neural Computation**, v. 7, pp.1129-1159.
- BHATTACHARYA, D. ; ANTONIOU, A., 1996, “Real-Time Design of FIR Filters by Feedback Neural Networks”, **IEEE Signal Processing Letters**, v. 3, n. 5 (May), pp. 158-161.
- BOSE, T., 2004, **Digital Signal and Image Processing**. New York, John Wiley & Sons.
- BRÉMAUD, P., 1999, **Markov Chains – Gibbs Fields, Monte Carlo Simulation and Queues**. New York, Springer-Verlag.
- CASELLA, G., BERGER, R.L., 2001, **Statistical Inference**. 2 ed. New York, Duxbury Press.
- CHEN, C.K., LEE, J.H., 1992, “Design of Quadrature Mirror Filters with Linear Phase in the Frequency Domain”, **IEEE Trans. on Circuits and Systems II**, v. 39, n. 9 (Sep), pp.593-605.
- CHERRUAULT, Y., MORA, G., 2005, **Optimisation Globale – Theorie des Courbes α -denses**. Paris, Ed. Economica.
- DRIANKOV, D., PALM, R., 1998, **Advances in Fuzzy Control**. New York, Physica-Verlag.

GARDINER, C.W., 2002, **Handbook of Stochastic Methods**. 2 ed. Berlin, Springer-Verlag.

GILKS, W.R., RICHARDSON, S., SPIEGELHALTER, D.J., 1996, **Markov Chain Monte Carlo in Practice**. 1 ed. Boca Raton, Chapman & Hall/CRC.

GOH, C.K., LIM, Y.C., NG., C.S., 1999, "Improved Weighted Least Squares Algorithm for the Design of Quadrature Mirror Filters", **IEEE Trans. on Signal Processing**, v. 47, n. 7 (Jul), pp. 1866-1877.

GÓRRIZ, J.M., PUNTONET, C.G., ROJAS, F. *et al.*, 2006, "Optimizing Blind Source Separation with Guided Genetic Algorithms", **Neurocomputing**, v. 69, pp. 1442-1457.

HÄGGSTRÖM, O., 2002, **Finite Markov Chains and Algorithmic Applications**. 1 ed. Cambridge, Cambridge University Press.

HASTINGS, W.K., 1970, "Monte Carlo Sampling Methods using Markov Chains and their Applications", **Biometrika**, v. 55, pp. 97-109.

HAYKIN, S., 1996, **Adaptive Filter Theory**. 3 ed. Upper Saddle River, Prentice-Hall.

HOOS, H.H., STÜTZLE, T., 2005, **Stochastic Local Search – Foundations and Applications**. 1 ed. San Francisco, Morgan Kaufmann Publishers.

HUANG, W.P., ZHOU, L.F., QIAN, J.X., 2004, "FIR Filter Design: Frequency Sampling Filters by Particle Swarm Optimization Algorithm". In: **Proceedings of the Third International Conference On Machine Learning and Cybernetics**, pp.2322-2327, Shangai, Aug.

INGBER, L., "Simulated Annealing: Practice versus Theory", Disponível em: <http://www.ingber.com/asa93_sapvt.pdf>. Acesso em: 13 jun. 2006.

JAMSHIDI, M., 1997, **Applications of Fuzzy Logic – Towards High Machine Intelligence Quotient Systems**. 1 ed. New Jersey, Prentice-Hall PTR.

JOHNSTON, J.D., 1980, "A Filter Family Designed for Use in Quadrature Mirror Filters Banks". In: **Proc. IEEE Intern. Conf. Acoustics, Speech and Signal Processing**, pp. 291-294, Denver, Apr.

JOU, Y., 2005, “Least-Squares Design of Digital Differentiators Using Neural Networks with Closed-Form Derivations”, **IEEE Signal Processing Letters**, v. 12, n. 11 (Nov), pp. 760-763.

JOU, Y., 2006, “Design of Real FIR Filters With Arbitrary Magnitude and Phase Specifications Using a Neural-Based Approach”, **IEEE Transactions on Circuits and Systems-II:Express Briefs**, v. 53, n 10 (Oct), pp. 1068-1072.

KIDAMBI, S.S., RAMACHANDRAN, R.P., 1995, “Design of Nonrecursive Filters Satisfying Arbitrary Magnitude and Phase Specifications Using a Least-Squares Approach”, **IEEE Transactions on Circuits and Systems-II: Analog and Digital Signal Processing**, v. 42, n. 11 (Nov), pp. 711-716.

LEE M. A., TAKAGI H., 1993, “Dynamic Control of Genetic Algorithms using Fuzzy Logic Techniques”. In: **Proceedings of the 5th Int’l Conference on Genetic Algorithms (ICGA’ 93)**, pp.76-83, Urbana Champaign, Jul.

MASTERS, T., 1993, **Advanced Algorithms for Neural Networks – A C++ Sourcebook**. 1 ed. New York, John Wiley & Sons.

METROPOLIS, N., ROSENBLUTH, A.W., ROSENBLUTH, M.N. *et al.*, 1953, ”Equation of state calculations by fast computing machines”, **J. Chemical Physics**, v. 21, n. 6, pp. 1087-1092.

NEWMAN, M.E.J., BARKEMA, G.T., 1999, **Monte Carlo Methods in Statistical Physics**. 1 ed. New York, Oxford University Press.

NGUYEN, T., 1993, “The Design of Arbitrary FIR Digital Filters Using the Eigenfilter Method”, **IEEE Transactions on Signal Processing**, v. 41, n. 3 (Mar), pp. 1128-1139.

NORRIS, J., 1999, **Markov Chains**. 1 ed. Cambridge, Cambridge University Press.

OLIVEIRA Jr., H.A. “Fuzzy Control of Stochastic Global Optimization Algorithms and Very Fast Simulated Reannealing”. Disponível em: < http://www.optimization-online.org/DB_FILE/2003/11/779.pdf>. Acesso em: 13 jun. 2006.

- OLIVEIRA Jr., H.A., 1999, **Lógica Difusa – Aspectos Práticos e Aplicações**. 1 ed. Rio de Janeiro, Editora Interciência.
- OPPENHEIM, A.V., SCHAFER, R.W., BUCK, J.R., 1999, **Discrete-time Signal Processing**. 2 ed. New Jersey, Prentice-Hall.
- PALIS JR., J., DE MELO, W., 1978, **Introdução aos Sistemas Dinâmicos**. 1 ed. Rio de Janeiro, IMPA.
- PEI, S.C., SHYU, J.J., 1992, “Eigen-Approach for Designing FIR Filters and All-Pass Phase Equalizers with Prescribed Magnitude and Phase Response”, **IEEE Transactions on Circuits and Systems-II: Analog and Digital Signal Processing**, v. 39, n. 3 (Mar), pp. 137-146.
- PRONZATO, L., WYNN, H.P., ZHIGLJAVSKY, A.A., 2000, **Dynamical Search – Applications of Dynamical Systems in Search and Optimization**. 1 ed. Boca Raton, Chapman & Hall/CRC.
- RAMSAY, J. O., SILVERMAN, B.W., 2005, **Functional Data Analysis**. 2 ed. New York, Springer-Verlag.
- ROBERT, C. P., CASELLA, G., 2004, **Monte Carlo Statistical Methods**. 2 ed. New York, Springer-Verlag.
- ROSENBLATT, M., 1971, **Markov Processes. Structure and Asymptotic Behavior**. 1 ed. Berlin, Springer-Verlag.
- ROSS, T., 1995, **Fuzzy Logic with Engineering Applications**. 1 ed. New York, McGraw-Hill.
- SCHNIER, T., YAO, X., LIU, P., 2004, “Digital Filter Design Using Multiple Pareto Fronts”, **Soft Computing**, v. 8, pp.332-343.
- SOUZA, J. M. C., KAYMAK, U., 2002, **Fuzzy Decision Making in Modeling and Control**. 1 ed. Singapura, World Scientific.
- STROUSTRUP, B., 1997, **The C++ Programming Language**. 3. ed. Reading, Addison-Wesley.

TAN, Y., WANG, J., 2001, “Nonlinear Blind Source Separation Using Higher Order Statistics and a Genetic Algorithm”, **IEEE Transactions on Evolutionary Computation**, v. 5, n. 6 (Dec), pp. 600-612.

VAIDYANATHAN, P.P., 1993, **Multirate Systems and Filter Banks**. 1 ed. Englewood Cliffs, Prentice-Hall.

VERDEGAY, J.L., 2003, **Fuzzy Sets Based Heuristics for Optimization**. 1 ed. Berlin, Springer Verlag.

WAH, B.W., SHANG, Y., WANG, T. *et al.*, 1997, “Global Optimization of QMF Filter Bank Design using NOVEL”. In: **IEEE Int. Conf. On Acoustics, Speech, and Signal Processing**, pp.2081-2084, Munich, Apr.

YAGER, R.R., FILEV, D.P., 1994, **Essentials of Fuzzy Modeling and Control**. 1 ed. New York, John Wiley & Sons.

ZABINSKY, Z.B., 2003, **Stochastic Adaptive Search for Global Optimization**. 1 ed. Boston, Kluwer Academic Publishers.

ANEXO 1

```
#include <windows.h>
#include <stdio.h>
#include <math.h>

#define PI    M_PI
/// Ordem do filtro FIR
#define M 60
#define NOMAXIMODEENTRADAS 10000
#define TAMANHO_TS    100

double Frequencias[NOMAXIMODEENTRADAS];
double RespostaIdeal[NOMAXIMODEENTRADAS];
double RespostaIdealFASE[NOMAXIMODEENTRADAS];

char NomeComUnderscore[] = "_FIR";
double PesoFuzzy( double frequencia );

double ErroFiltro(double *h,int indice_no_TS,int Ordem)
{
double H_real = 0, H_imag=0, Hd_real, Hd_imag, y, omega, FASEATUAL;
int i;

omega = Frequencias[indice_no_TS];
FASEATUAL = RespostaIdealFASE[indice_no_TS];

    for (i=0 ; i <= Ordem ; i++)
    {
        H_real += h[i]*cos(omega*i); H_imag += h[i]*sin(omega*i) ;
    }

    H_imag = -H_imag;
    Hd_real = RespostaIdeal[indice_no_TS]*cos(FASEATUAL);
    Hd_imag = RespostaIdeal[indice_no_TS]*sin(FASEATUAL);

    y = (Hd_real-H_real)*(Hd_real-H_real)+(Hd_imag-H_imag)*(Hd_imag-H_imag) ;

return y;
}

BOOL DllMain(HINSTANCE hInst,DWORD dwReason,LPVOID Reservado)
{
int i;
double aux;
```

```

switch (dwReason)
{
case DLL_PROCESS_ATTACH:

for (i=0;i<=TAMANHO_TS;i++)
{
    Frequencias[i] = ((double) i / (double) TAMANHO_TS)*PI ;
    RespostaIdeal[i] = 1.0;
    RespostaIdealFASE[i] = -30*Frequencias[i] - 2*PI*cos(Frequencias[i]) ;
}

break;

case DLL_PROCESS_DETACH: break;
case DLL_THREAD_ATTACH: break;
case DLL_THREAD_DETACH: break;
}
return TRUE;
}
extern "C" double __declspec(dllexport) FIR
(
    int nodedimensoes, // No de elementos no vetor abaixo
    double *h, // Vetor
    void *Custom // Informacao especifica do usuario
)
{
double aux, dife;
double erro = 0 ;

for ( int i=0 ; i <= TAMANHO_TS ; i++ )
{
    dife = ErroFiltro(h,i,nodedimensoes-1);
    dife = dife*PesoFuzzy(Frequencias[i]);
    erro += dife;
}
return erro ;
}

extern "C" char * __declspec(dllexport) NomeDaFuncaoObjetivo(void)
{
return (char *) NomeComUnderscore;
}

extern "C" unsigned int __declspec(dllexport) NumeroDeParametrosDaFO(void)
{
return ( M + 1 ) ;
}

```

ANEXO 2

```
#include <windows.h>
#include <stdio.h>
#include <stdlib.h>
#include <math.h>

#define PI    M_PI

// Comprimento do filtro prototipo com fase linear ( TIPO II )
#define COMPRIMENTO  64

/// Ordem do filtro FIR
#define M (COMPRIMENTO-1)

#define AVALIACOES_PARA_PONDERACAO    1100000L

static double ErroMaximo = -1.0;

double PesoFuzzy( int indice );
double FIS(double);

#define OMEGA_C    (0.5*PI)
#define DELTA_W    (0.015*2*PI)
#define ERRO_STOPBAND 0.005
#define NOMAXIMODEENTRADAS 10000
#define TAMANHO_TS    135

double ERROS[TAMANHO_TS+1];
double ERROS_AUX[TAMANHO_TS+1];

char NomeComUnderscore[] = "_FIRQMF";

double AmplitudeFIR(double *parametros, double omega, int COMPRIsobre2);

double Frequencias[NOMAXIMODEENTRADAS];
double RespostaIdeal[NOMAXIMODEENTRADAS];

BOOL DllMain(HINSTANCE hInst,DWORD dwReason,LPVOID Reservado)
{
    int i;
    double aux;

    switch (dwReason)
    {
```

```

case DLL_PROCESS_ATTACH:
case DLL_THREAD_ATTACH:

        ErroMaximo = -1.0;

for (i=0;i<=TAMANHO_TS;i++)
        Frequencias[i] = ((double) i / (double) TAMANHO_TS)*PI ;

        break;

case DLL_PROCESS_DETACH: break;

case DLL_THREAD_DETACH: break;
}

return TRUE;

}

extern "C" double __declspec(dllexport) FIRQMF(
        int nodedimensoes, // No de elementos no vetor abaixo
        double *h, // Vetor
        void *Custom // Informacao especifica do usuario
        )
{
double aux1,aux2, aux3, dife;
double erro ;
double Parcela1, Parcela2, Parcela3;
double ALPHA;
double Maximo = -1000;
double H0_ANTES_ANTERIOR, H0_ANTERIOR, H0_ATUAL= -1.0;

static long Avaliacoes = 0;

Avaliacoes++ ;

        Parcela1 = Parcela2 = Parcela3 = 0;

        ALPHA = h[nodedimensoes-1];

for ( int i=0 ; i < TAMANHO_TS ; i++ )
{
        aux1 = AmplitudeFIR(h,Frequencias[i],nodedimensoes-1);
        aux2 = AmplitudeFIR(h,Frequencias[i]-PI,nodedimensoes-1);

```

```

H0_ANTES_ANTERIOR = H0_ANTERIOR;
H0_ANTERIOR = H0_ATUAL ;
H0_ATUAL = fabs(aux1) ;

if ( fabs(Frequencias[i]-OMEGA_C) >= DELTA_W )
{
    if (Frequencias[i] >= OMEGA_C)
        Parcela1 += (aux1-ERRO_STOPBAND)*(aux1-ERRO_STOPBAND)* \
            (( ( H0_ATUAL < H0_ANTERIOR ) && \
              ( H0_ANTES_ANTERIOR < H0_ANTERIOR ) && \
              (( H0_ANTERIOR + H0_ATUAL)/2.0 > ERRO_STOPBAND ) ) ? 10.0 : 1.0) ;
        else Parcela3 += (aux1-1.0)*(aux1-1.0) ;
}

aux3 = 1.0-aux1*aux1-aux2*aux2 ; dife = aux3*aux3 ;

if ( Avaliacoes == AVALIACOES_PARA_PONDERACAO )
    { ERROS_AUX[i] = dife; ErroMaximo = -1.0 ; }

    if (Maximo < dife) Maximo = dife ;

Parcela2 += dife*( Avaliacoes <= AVALIACOES_PARA_PONDERACAO ) ? 1.0 :
PesoFuzzy(i) ;

}

erro = (1-ALPHA)*Parcela1 + ALPHA*Parcela2 + (1-ALPHA)*Parcela3 +
10000*ALPHA*Maximo ;

return erro ;
}

extern "C" char * __declspec(dllexport) NomeDaFuncaoObjetivo(void)
{
    return (char *) NomeComUnderscore;
}

extern "C" unsigned int __declspec(dllexport) NumeroDeParametrosDaFO(void)
{
    return COMPRIMENTO/2 + 1 ;
}

```

```

double AmplitudeFIR(double *h, double omega, int COMPRI sobre2)
{
// 1o parametro = vetor entregue por ASA ( Primeiros <COMPRI sobre2> elementos )
// 2o parametro = frequencia digital entre 0 e PI
// 3o parametro = COMPRIMENTO/2 (Comprimento do filtro/2)

double y = 0 ;
int i;

for (i=1 ; i <= COMPRI sobre2 ; i++)
    y += 2*h[COMPRI sobre2-i]*cos(omega*(i-0.5)) ;

return y ;

}

double PesoFuzzy( int indice )
{

int i;
double aux;

if (ErroMaximo < 0)
{
for (i=0;i<=TAMANHO_TS;i++)
    if (ERROS_AUX[i] > ErroMaximo) ErroMaximo = ERROS_AUX[i];

for (i=0;i<=TAMANHO_TS;i++)
    ERROS[i] = ERROS_AUX[i]/ErroMaximo;

    ErroMaximo = 0;
}

    aux = FIS(ERROS[indice]);

return aux ;

}

```

ANEXO 3

```
#define VALORMB 0.02
#define VALORB 0.1
#define VALORM 0.4
#define VALORA 0.9
#define VALORMA 1.0
```

```
double MuitoBaixo(double x)
{
    if (x<=0) return 1;
    if (x>=0.25) return 0;

    return 1-4*x;
}
```

```
double Baixo(double x)
{
    if (x<=0 || x>= .5) return 0;
    if (x <= 0.25) return 4*x;

    return 2-4*x;
}
```

```
double Medio(double x)
{
    if (x<=0.25 || x>= .75) return 0;
    if (x <= .5) return -1+4*x;

    return 3-4*x;
}
```

```
double Alto(double x)
{
    if (x<=.5 || x>=1) return 0;
    if (x <= .75) return -2+4*x;

    return 4*(1-x);
}
```

```
double MuitoAlto(double x)
{
    if (x<=.75) return 0;
    if (x<=1) return -3+4*x;

    return 1;
}
```

```
double FIS(double x)
{
    return MuitoBaixo(x)*VALORMB+Baixo(x)*VALORB+ Medio(x)*VALORM + \
        Alto(x)*VALORA + MuitoAlto(x)*VALORMA ;
}
```
