

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA ELÉTRICA

DEPARTAMENTO DE COMUNICAÇÕES

MÉTODOS DE ESTIMAÇÃO DOS PARÂMETROS DOS MODELOS ARMA
PARA ANÁLISE ESPECTRAL

Por: Adrián Sotero De Witt Batista
Engenheiro Eletricista (UNICAMP - 1987)

Orientador: Prof. Dr. Amauri Lopes†
Professor MS4 do Departamento de Comunicações da
Faculdade de Engenharia Elétrica da UNICAMP

Dissertação submetida à Faculdade de Engenharia
Elétrica da UNICAMP como requisito parcial para
para obtenção do título de Mestre em Engenharia
Elétrica.

Campinas, 30 de junho de 1992.

Este exemplar corresponde à redação final da tese
defendida por Adrián Sotero de Witt
Batista ... lida pela Comissão

Julgadora em 30/06/92.

Amauri Lopes
Orientador

UNICAMP
BIBLIOTECA CENTRAL

AGRADECIMENTOS

A meus pais, minha avó e familiares pelo estímulo e carinho.

Ao Prof. Dr. Amauri Lopes por sua orientação e principalmente pelo imenso incentivo e amizade.

Aos professores Fabio Violaro e João Romano pela colaboração, e ao professor José Augusto pela valiosa ajuda ao andamento deste trabalho.

Aos amigos e colegas Ernesto, Paulo, Jozué, Nagle, Francisco, Leonardo, Coradine, Fernando, Aleardo e todos os outros pela ajuda e companheirismo.

Pela paciência e solicitude, a Celi, Marcia, Gisleine e Insley.

A Blake, Giba e família.

Ao pessoal da Turma, da Pô, Romeu! e da Buarque.

A mocada da graduação.

A todos que colaboraram direta ou indiretamente para a realização deste trabalho, seja através de discussões, críticas ou colocações pessoais.

A Universidade Estadual de Campinas pela oportunidade.

Ao CNPq, CPqD/TELEBRÁS e FAEP pelo apoio financeiro.

aos meus pais e irmãos,
saudade

RESUMO

Este trabalho está direcionado ao estudo das técnicas de Análise Espectral com base no modelo ARMA, utilizando os métodos de estimacão separada de seus parâmetros.

São desenvolvidos os aspectos teóricos e práticos da análise de mínimos quadrados das Equações Modificadas de Yule-Walker para a estimacão dos parâmetros auto-regressivos do modelo ARMA. O mesmo se dá em relação ao método de Durbin para a estimacão do modelo MA, visando sua aplicacão na estimacão dos parâmetros média-ajustável do modelo ARMA. Os resultados deste estudo são confrontados com aqueles resultados da aplicacão dos métodos clássicos na estimacão espectral ARMA e MA.

A avaliação do desempenho destes vários métodos é realizada através de simulações envolvendo sinais de testes gerados a partir de processos aleatórios conhecidos. Este conhecimento permitiu comparar as estimativas resultantes com os aspectos teóricos destes sinais. Também, utilizou-se varios tipos de processos de modo a cobrir uma ampla gama de possibilidades.

ÍNDICE

Capítulo 1 Introdução	1
1.1 A Análise Espectral	1
1.2 Objetivos da Tese	2
1.3 Organização da Dissertação	3
Capítulo 2 Conceitos Gerais	5
2.1 Introdução	5
2.2 Avaliação Espectral	5
2.3 Estimadores da Seqüência de Autocorrelação	7
2.4 Método Clássico Correlograma	13
2.5 Método Clássico Periodograma	16
2.6 Modelos Paramétricos	17
Capítulo 3 Modelos Paramétricos para a Análise Espectral	20
3.1 Introdução	20
3.2 Modelo Auto-regressivo Média-Ajustável de Ordem p e q, ARMA(p, q)	20
3.2.1 Relação entre os Parâmetros e a Seqüência de Autocorrelação de um Processo ARMA(p, q)	23
3.3 Modelo Auto-regressivo de Ordem p, AR(p)	25
3.3.1 Relação entre os Parâmetros e a Seqüência de Autocorrelação de um Processo AR(p)	27
3.4 Modelo Média-Ajustável de ordem q, MA(q)	29
3.4.1 Relação entre os Parâmetros e a Seqüência de Autocorrelação de um Processo MA(q)	30
3.5 Relação entre os modelos AR e MA	31
3.6 Estimadores Espectrais Paramétricos	33
Capítulo 4 Estimadores do Modelo Auto-Regressivo, Métodos com Base na Análise de Predição Linear	35
4.1 Introdução	35
4.2 Relação entre a Análise de Predição Linear e o Modelo Auto-regressivo	35

4.3 Métodos de Estimação AR Baseados na Predição	47
Linear Progressiva	38
4.4 Método Covariância Modificado	43
4.5 Seleção da Ordem do Modelo AR	45
Capítulo 5 Estimação Espectral Média-Ajustável	47
5.1 Introdução	47
5.2 Método de Durbin para a Estimação dos Parâmetros do Modelo MA	47
5.3 Método de Durbin: Análise Qualitativa	51
5.4 Método de Durbin: Análise Quantitativa	53
5.5 Estimativas Espectrais MA com Base nos Métodos Clássicos	71
5.6 Considerações Finais	81
Capítulo 6 Estimação Espectral Auto-Regressiva Média-Ajustável, ARMA	82
6.1 Introdução	82
6.2 Estimação Separada dos Parâmetros ARMA	83
6.3 Estimação do Numerador Espectral do Modelo ARMA	91
6.4 Seleção da Ordem do Modelo ARMA(p, q)	93
6.5 Simulações	94
6.5.1 Apresentação das Simulações	94
6.5.2 Estimação do Denominador Espectral ARMA com Base na Análise de Mínimos Quadrados das Equações Modificadas de Yule-Walker	98
6.5.3 Estimação do Numerador Espectral ARMA com Base no Método de Durbin	119
6.5.4 Estimação do Numerador Espectral ARMA com Base nos Métodos Correlograma e Periodograma	135
6.6 Conclusão	144
Capítulo 7 Conclusões	148
Referências	152

CAPÍTULO 1

INTRODUÇÃO

1.1 A Análise Espectral

A Análise Espectral é um conjunto de conceitos e métodos que visa caracterizar o conteúdo em freqüência de um sinal observado. Sua aplicação abrange todas as áreas da Engenharia Elétrica e das ciências em geral. Sua pesquisa tem produzido uma variedade de métodos de modo que se faz necessário a preparação de pessoal especializado nesta área, não só para a escolha adequada a cada aplicação como também para resolver novos problemas. Suas ferramentas matemáticas fundamentais são a Transformada de Fourier e os conceitos estatísticos. A primeira relaciona um sinal ou modelo deste com sua representação no domínio da freqüência, enquanto que a segunda torna-se necessária devido ao comportamento aleatório de uma grande variedade de sinais.

A Análise Espectral seria uma ciéncia exata se as características estatísticas do sinal observado pudessem ser exatamente determinadas. Entretanto, na prática dispomos, em geral, de pequenos intervalos do sinal, a partir dos quais não é possível determinar exatamente tais características. Esta é a razão pela qual é possível obter apenas uma estimativa do espectro de potênciia do sinal.

Existem diversos métodos para estabelecer tal estimativa, e podem ser divididos em duas categorias: Modernos e Clássicos.

1. Nos Métodos Modernos, também chamados de paramétricos, um modelo é utilizado na formulacão do problema de estimacão espectral. A base destes métodos é a idéia de que um sinal pode ser modelado pela resposta de um filtro linear causal cuja excitação é um ruído branco. O espectro de potênciia é, então, estimado em função dos parâmetros do filtro e da variância do ruído branco.

2. Nos Métodos Clássicos, ou não-paramétricos, nenhum modelo é utilizado na formulacão do problema de estimacão espectral.

Neles o espectro de potência é estimado diretamente do segmento do sinal observado (Método do Periodograma), ou então a partir da sua seqüência de autocorrelação (Método do Correlograma).

1.2 Objetivos da Tese

O objetivo desta tese é o estudo dos métodos de estimação dos parâmetros dos modelos ARMA para Análise Espectral. Tais modelos apresentam função de sistema racional composta por pólos e zeros, o que os torna adequados para a estimação de espectros de potência formados por picos estreitos e vales abruptos. Ao contrário, os modelos auto-regressivos (AR), composto apenas por pólos, e média-ajustável (MA), composto apenas por zeros, são específicos para a estimação de uma destas formas espectrais. Entretanto, a presença de relações não-lineares no modelo ARMA dificulta a estimação de seus parâmetros, que é realizada através de métodos iterativos de estimação simultânea ou, então, métodos sub-ótimos de estimação separada. Este trabalho está direcionado aos métodos de estimação separada.

O modelo MA é adequado para a estimação de espectros de potência com vales abruptos e também apresenta relações não-lineares que dificultam a obtenção direta de seus parâmetros. Embora o modelo MA não seja amplamente utilizado, as relações e os métodos de estimação do mesmo são parte importante dos métodos de estimação separada ARMA. Por este fato, a tese aborda o método de Durbin para a estimação MA, o qual é um método indireto de fácil implementação.

Ao longo da tese são ainda desenvolvidos tópicos tais como os métodos de estimação clássica, a conceituação e uso dos métodos modernos na Análise Espectral, bem como os métodos mais conhecidos para a estimação dos parâmetros do modelo AR. A motivação para tal é a geração de uma base para o estudo da estimação dos parâmetros do modelo ARMA.

1.3 Organização da Dissertação

No capítulo 2 são apresentados a problemática básica da Análise Espectral, os estimadores de autocorrelação utilizados ao longo da tese, os métodos de estimação clássica Correlograma e Periodograma e uma breve conceituação dos modelos paramétricos na Análise Espectral.

O capítulo 3 é dedicado às relações que caracterizam os modelos ARMA, AR e MA, à equivalência entre os modelos AR e MA, a ser utilizada no capítulo 5, bem como à aplicação prática destes modelos na estimativa da densidade espectral de potência de um sinal a partir dos dados disponíveis.

São apresentados no capítulo 4, alguns métodos para a obtenção dos parâmetros do modelo AR. Este modelo tem sido amplamente pesquisado e existe um número considerável de métodos para estimar seus parâmetros. Neste trabalho não será efetuado um estudo aprofundado do mesmo, mas serão apresentadas apenas suas características principais e os métodos mais conhecidos para a estimação de seus parâmetros, ou seja, aqueles baseados na teoria da predição linear: Autocorrelação, Covariância e Covariância Modificado.

O capítulo 5 é dedicado à estimação espectral MA. Nele é efetuado um estudo detalhado sobre o método de Durbin e sobre uma eventual substituição do modelo MA pelos métodos clássicos na estimação espectral MA. O método de Durbin explora a equivalência entre os modelos AR e MA e utiliza o método Autocorrelação para a obtenção do modelo AR. Neste trabalho é proposto e analisado o uso de outros métodos para a obtenção do modelo AR e as estimativas espetrais obtidas com este método são comparadas com aquelas fornecidas pelos métodos clássicos. Estes aspectos representam parte das contribuições deste trabalho.

O tema do capítulo 6 é a estimação espectral ARMA com base nos métodos de estimação separada. Aqui é utilizado a análise de mínimos quadrados das Equações Modificadas de Yule-Walker para a obtenção da parte auto-regressiva do modelo ARMA e o método de Durbin e os clássicos para a obtenção da parte média-ajustável. É efetuado um estudo detalhado das características do algoritmo de estimação da parte auto-regressiva, visando aumentar seu desempe-

nho, e uma nova análise comparativa entre os métodos apresentados no capítulo 5, agora dentro do contexto da estimação espectral ARMA. Este estudo e a análise comparativa completam o conjunto de contribuições proporcionado por esta tese.

Finalmente, o capítulo 7 resume as principais conclusões e contribuições atingidas.

Os estudos teóricos realizados nos capítulos 5 e 6 foram complementados com simulações baseadas em processos artificiais com espectros de potência conhecidos. Os algoritmos necessários às simulações foram implementados em rotinas de computador utilizando a linguagem C, compilador Turbo C 2.0 (Borland International, Inc)

CAPÍTULO 2

CONCEITOS GERAIS

2.1 Introdução

Neste capítulo é abordado de forma suscinta o problema da estimativa espectral a partir de um número finito de amostras de um processo aleatório e são apresentadas as idéias básicas associadas aos métodos clássicos e paramétricos da análise espectral. O objetivo é formar uma base comum aos próximos capítulos e nenhum esforço foi realizado na tentativa de aprofundar estes assuntos. Em conjunto com estes temas principais, são apresentados dois estimadores da seqüência de autocorrelação e analisadas suas propriedades.

2.2 Avaliação Espectral

A densidade espectral de potência (DEP), $P_{xx}(f)$, de um processo aleatório discreto $x[n]$, é definida como a Transformada de Fourier de sua seqüência de autocorrelação estatística, $r_{xx}[m]$:

$$P_{xx}(f) = \sum_{m=-\infty}^{\infty} r_{xx}[m] \exp(-j2\pi mfT) \quad (2.1)$$

a qual é conhecida como relação de Wiener-Khintchine.

$P_{xx}(f)$ é periódica em freqüência com período $1/T$ Hz, e é assumido ser de faixa limitada em $\pm 1/2T$ Hz, onde T é o intervalo de amostragem do processo $x[n]$. O seu caráter de densidade de potência exige que $P_{xx}(f)$ seja uma função não-negativa.

A DEP é também definida, para processos ergódicos, como [1]:

$$P_{xx}(f) = \lim_{M \rightarrow \infty} E \left\{ \left| \frac{1}{2M+1} \sum_{n=-M}^{M} x[n] \exp(-j2\pi nfT) \right|^2 \right\} \quad (2.2)$$

onde "E" representa a operação de média estatística.

Ambas definições da DEP são equivalentes sob a hipótese de ergodicidade e ao longo deste trabalho assumimos que os processos aleatórios sob análise são discretos e ergódicos.

As duas definições da DEP não podem, em geral, ser utilizadas na prática, pois exigem o conhecimento da seqüência de autocorrelação ou então de todas as amostras do processo a ser analisado.

Em geral, dispomos apenas de um conjunto finito de amostras e é deste conjunto que devem ser obtidas ou estimadas as informações que o caracterizam. Por exemplo, seja $x[n]$ um processo discreto do qual dispomos de apenas N amostras no intervalo $0 \leq n \leq N-1$, denominadas $x_o[n]$. Este conjunto de amostras pode ser representado por:

$$x_o[n] = \begin{cases} x[n] & ; 0 \leq n \leq N-1 \\ 0 & ; \text{c.c} \end{cases} \quad (2.3)$$

ou ainda por:

$$x_o[n] = x[n] w[n] \quad (2.4)$$

onde $w[n]$ é uma janela retangular de amplitude unitária e comprimento N ,

$$w[n] = \begin{cases} 1 & ; 0 \leq n \leq N-1 \\ 0 & ; \text{c.c} \end{cases}$$

De acordo com a equação (2.4), o espectro de freqüências de $x_o[n]$ será:

$$X_o(f) = X(f) * W(f) \quad (2.5)$$

onde '*' denota a operação de convolução.

A equação (2.5) mostra que o espectro de freqüências $X_o(f)$ resulta da convolução entre o espectro desejado $X(f)$ e o da janela $w[n]$. Assim, enquanto dispomos de apenas um trecho finito de $x[n]$, poderemos obter somente uma aproximação de seu espectro de freqüências.

Os métodos de estimação do espectro de densidade de potência de processos aleatórios também estão sujeitos a esta limitação intrínseca ao conjunto finito de amostras, que se reflete numa redução na capacidade de discernir detalhes espectrais. Além desta li-

mitação na resolução espectral, existe o fenômeno da variância da estimativa, ou seja, conjuntos distintos de N amostras produzem estimativas distintas. Este efeito decorre da ausência da operação de mediação, estatística ou temporal, ao longo de todas as amostras do processo.

Nos métodos clássicos de análise espectral, baseados na Transformada de Fourier, procura-se estabelecer mecanismos de compromisso entre estes efeitos sem se dispor de meios eficazes para minorá-los. Nos métodos paramétricos são atingidos melhores resultados ao buscar a estimativa de um modelo para o processo sob análise.

Antes de passar para à discussão mais detalhada destes métodos, vamos estudar o problema da avaliação da seqüência de autocorrelação de um processo.

2.3 Estimadores da Seqüência de Autocorrelação, SAC

A média estatística mais freqüente nos métodos da análise espectral é a seqüência de autocorrelação, SAC, de um processo aleatório, a qual também está sujeita às limitações de se dispor de um conjunto finito de amostras.

A seqüência de autocorrelação de um processo aleatório $x[n]$ estacionário, é definida como:

$$r_{xx}[m] = E \left\{ x[n+m] x^*[n] \right\} = E \left\{ x[n] x^*[n-m] \right\} \quad (2.6)$$

onde "*" denota a operação de conjugado complexo.

Também, para processo ergódicos a SAC pode ser calculada através da seguinte média temporal [1], [2]:

$$r_{xx}[m] = \lim_{M \rightarrow \infty} \frac{1}{2M+1} \sum_{n=-M}^{M} x[n+m] x^*[n] \quad (2.7)$$

A SAC apresenta várias propriedades, entre as quais destacamos [1], [2], [3]:

$$r_{xx}[0] \geq |r_{xx}[m]| \quad (2.8)$$

$$r_{xx}[-m] = r_{xx}^*[m] \quad (2.9)$$

A definição dada pela equação (2.6) requer o conhecimento da função de densidade de probabilidade de segunda ordem do processo aleatório, enquanto que a definição (2.7) requer disponibilidade de todas as amostras do processo.

Entretanto, em geral, ambas informações não estão disponíveis nas situações práticas, o que nos obriga a fazer uso de estimativas da autocorrelação, obtidas das N amostras disponíveis do processo aleatório. A seguir vamos apresentar dois estimadores de autocorrelação que serão utilizados no decorrer deste trabalho.

1. Estimador Não-Polarizado de Autocorrelação:

Este estimador é a equação (2.7) adaptada a um conjunto finito de amostras, ou seja:

$$\hat{r}_{xx}[m] = \begin{cases} \frac{1}{N-m} \sum_{n=0}^{N-m-1} x[n+m] x^*[n] & ; 0 \leq m \leq N-1 \\ \hat{r}_{xx}^*[-m] & ; -(N-1) \leq m < 0 \\ 0 & ; |m| \geq N \end{cases} \quad (2.10)$$

Este estimador é não-polarizado, uma vez que a média de suas estimativas é igual a SAC teórica:

$$E \left\{ \hat{r}_{xx}[m] \right\} = \frac{1}{N-m} \sum_{n=0}^{N-m-1} E \left\{ x[n+m] x^*[n] \right\} = r_{xx}[m] ; 0 \leq m \leq N-1 \quad (2.11)$$

Observe que o valor médio das estimativas não-polarizadas é o produto da SAC teórica por uma janela retangular unitária, de comprimento $2N-1$, em torno de $m=0$.

A variância desta estimativa para um processo aleatório Gaussiano pode ser aproximada por:

$$\text{var} \left\{ \hat{r}_{xx}[m] \right\} \approx \frac{N}{(N-m)^2} \sum_{k=-\infty}^{\infty} \left(r_{xx}^2[m] + r_{xx}[k+m] r_{xx}[k-m] \right) \quad (2.12)$$

para $N \gg m$ [4]. Observamos que à medida que o valor m aumenta a variância também aumenta. Isto acontece pois, à medida que m se aproxima de $N-1$, diminui o número de produtos a serem somados para compor $\tilde{r}_{xx}[m]$, aumentando a incerteza ou o erro da estimativa. Por outro lado, quando N tende a infinito, a variância de $\tilde{r}_{xx}[m]$ tende a zero.

Dizemos que uma estimativa é consistente quando sua polarização e sua variância tendem a zero com o aumento do número N de amostras. Desta forma, $\tilde{r}_{xx}[m]$ é uma estimativa consistente da SAC.

2. Estimador Polarizado de Autocorrelação:

O estimador da equação (2.10) fornece estimativas não-polarizadas, cuja variância aumenta com o valor de m . Um estimador que contorna este problema, porém com a desvantagem de produzir estimativas polarizadas, é apresentado a seguir:

$$\tilde{r}_{xx}[m] = \begin{cases} \frac{1}{N} \sum_{n=0}^{N-m-1} x[n+m] x^*[n] & ; 0 \leq m \leq N-1 \\ \tilde{r}_{xx}^*[-m] & ; -(N-1) \leq m < 0 \\ 0 & ; |m| \geq N \end{cases} \quad (2.13)$$

A relação entre ambos estimadores é dada por:

$$\tilde{r}_{xx}[m] = \left(1 - \frac{|m|}{N}\right) \hat{r}_{xx}[m] \quad ; \quad 0 \leq |m| \leq N-1 \quad (2.14)$$

e a média das estimativas $\tilde{r}_{xx}[m]$, por:

$$E\{\tilde{r}_{xx}[m]\} = \left(1 - \frac{|m|}{N}\right) r_{xx}[m] \quad ; \quad |m| \leq N-1 \quad (2.15)$$

De modo que $\tilde{r}_{xx}[m]$ é uma estimativa polarizada da SAC para um número finito de amostras. Entretanto, se torna assintoticamente não-polarizada quando o número de amostras tende a infinito. As equações (2.14) e (2.15) mostram que o valor médio destas estimativas é o produto da SAC teórica por uma janela triangular, de comprimento $2N-1$, em torno do valor $m=0$.

Das equações (2.12) e (2.14), obtemos uma aproximação da va-

riância do estimador polarizado:

$$\text{var} \left\{ \tilde{r}_{xx}[m] \right\} \approx \frac{1}{N} \sum_{k=-\infty}^{\infty} \left(r_{xx}^2[m] + r_{xx}[k+m] r_{xx}[k-m] \right) \quad (2.16)$$

Observamos que a variância da estimativa não é influenciada pelo valor de m como acontece na estimativa não-polarizada. Também, esta variância tende a zero com o aumento do número de amostras. Assim, o estimador polarizado também fornece estimativas consistentes da SAC de um processo aletório.

Por fim, ambos estimadores satisfazem a propriedade de sequência conjugada simétrica da equação (2.9).

3. Característica de sequência positiva semidefinida das estimativas de autocorrelação.

O fato que a DEP é uma função não-negativa está intimamente relacionado com o fato de a SAC ser uma sequência positiva semidefinida [5]. Esta propriedade se refere à matriz Toeplitz Hermitiana, R_M , formada por elementos da SAC:

$$R_M = r_{xx}[i-j] ; \quad 0 \leq i, j \leq M-1$$

Tomando a forma quadrática associada a R_M :

$$a R_M a^H = \sum_{k=0}^{M-1} \sum_{j=0}^{M-1} a[k] a^*[j] r_{xx}[k-j]$$

onde " H " representa a operação de transposto conjugado, e a é um vetor linha $M \times 1$ qualquer, podemos escrever:

$$\begin{aligned} a R_M a^H &= \sum_{k=0}^{M-1} \sum_{j=0}^{M-1} a[k] a^*[j] E \left\{ x[n+k] x^*[n+j] \right\} \\ &= E \left\{ \left| \sum_{k=0}^{M-1} a[k] x[n+k] \right|^2 \right\} \geq 0 \end{aligned}$$

O fato deste produto ser não-negativo para todo vetor a de M elementos arbitrários caracteriza a matriz R_M como positiva semidefinida. Pode-se mostrar, [5], que esta propriedade da matriz R_M ,

válida para qualquer inteiro positivo M , está diretamente relacionada à não negatividade da DEP e motiva a denominação de $r_{xx}[m]$ como uma seqüência positiva semidefinida.

Portanto, é necessário que as seqüências de autocorrelação estimadas também sejam positivas semidefinidas, de forma a garantir que a Transformada de Fourier destas (que é uma estimativa possível para a DEP do processo aleatório) seja não-negativa.

Assim, vamos agora analisar as seqüências obtidas dos estimadores não-polarizado e polarizado de autocorrelação quanto ao seu caráter positivo semidefinido (ou não-negativo definido, NND). Uma abordagem mais ampla sobre as propriedades das seqüências e matrizes NND pode ser encontrada nos textos [5], [6], [7]. Apresentaremos aqui apenas aquelas características necessárias ao estudo em questão.

Definição 2.1: Uma seqüência é NND se e somente se sua Transformada de Fourier é uma função não-negativa.

Propriedades: Uma seqüência NND satifaz as propriedades dadas pelas equações (2.8) e (2.9) (condições necessárias mas não suficientes).

Teorema 2.1: Dada uma seqüência $v[m]$ finita de comprimento $2N-1$, se existir uma seqüência $x[0], \dots, x[N-1]$, tal que:

$$v[m] = K x[m] * x^*[-m] ; 0 \leq m \leq N-1 \quad (2.17)$$

onde K é uma constante não-nula positiva, então $v[m]$ é NND.

Demostração:

Seja

$$v[m] = K x[m] * x^*[-m]$$

$$\begin{aligned} \mathcal{F}\{v[m]\} &= K \mathcal{F}\{x[m]\} \mathcal{F}\{x^*[-m]\} \\ V(f) &= K X(f) X^*(f) \\ &= K |X(f)|^2 \end{aligned}$$

como $K > 0$ e $|X(f)|^2 \geq 0$, $V(f)$ é uma função não-negativa e, portanto, $v[m]$ é uma seqüência NND, c.q.d.

Teorema 2.2: O produto de duas sequências NND é uma sequência NND.

Demostração:

Seja

$$c[m] = w[m] v[m]$$

onde $w[m]$ e $v[m]$ são NND,

$$\begin{aligned} \mathcal{F}\{c[m]\} &= \mathcal{F}\{w[m]\} * \mathcal{F}\{v[m]\} \\ C(f) &= W(f) * V(f) \end{aligned} \quad (2.18)$$

como $W(f) \geq 0$ e $V(f) \geq 0$ para todo valor de frequência, $C(f)$ é uma função não-negativa e, portanto, $c[m]$ é uma sequência NND, c.q.d.

Este teorema garante que o produto de duas sequências NND é NND. Por outro lado, como a expressão de convolução (2.18) implica numa soma de produtos, o produto de duas sequências pode não ser NND se uma delas não o for.

Aplicando estes conceitos nos estimadores de autocorrelação, temos:

-Para as sequências de estimativas não-polarizadas de autocorrelação:

Podemos escrever a equação (2.10) como:

$$\hat{r}_{xx}[m] = \frac{1}{N-m} \sum_{n=0}^{N-m-1} x[n+m] x^*[n] \quad ; \quad 0 \leq m \leq N-1$$

onde:

$$ww[m] = \frac{1}{N-m} \sum_{n=0}^{N-m-1} x[n+m] x^*[n] \quad ; \quad 0 \leq m \leq N-1$$

$$rr[m] = \sum_{n=0}^{N-m-1} x[n+m] x^*[n] \quad ; \quad 0 \leq m \leq N-1$$

Lembrando que:

$$rr[m] = \sum_{n=0}^{N-m-1} x[n+m] x^*[n] = x[m] * x^*[-m]$$

o Teorema 2.1 assegura que $rr[m]$ é uma sequência NND. Entretanto, a sequência $ww[m]$ não é NND, pois a propriedade (2.8) não é satisfeita, já que $ww[0] < ww[m]$. Portanto, não é garantido que o produto $ww[m] rr[m]$ seja NND.

Assim, o estimador não-polarizado pode fornecer estimativas de autocorrelação que não sejam positivas semidefinidas. Por exemplo, para a seqüência de amostras $x[0]=2.0$, $x[1]=2.1$ e $x[2]=1.0$, o estimador não-polarizado fornecerá $\hat{r}_{xx}[0]=3.137$, $\hat{r}_{xx}[1]=3.150$ e $\hat{r}_{xx}[2]=2.0$; como $\hat{r}_{xx}[0] < \hat{r}_{xx}[1]$ esta seqüência não é NND.

-Para as seqüências de estimativas polarizadas de autocorrelação:

A expressão (2.13) do estimador polarizado pode ser colocada na forma da equação (2.17) do Teorema 2.1 com $K=1/N$. Logo as estimativas polarizadas de autocorrelação são sempre NND.

O fato do estimador não-polarizado não garantir estimativas não-negativas para a DEP, faz com que o estimador polarizado seja o mais utilizado na prática. Unido a isto, nos métodos paramétricos de análise espectral é utilizada a inversa da matriz de estimativas de autocorrelação. Esta inversão só é possível se tais estimativas formam uma seqüência positiva definida [6], [7].

Nesta seção os símbolos $\hat{\cdot}$ e $\tilde{\cdot}$ foram utilizados para indicar as estimativas não-polarizadas e polarizadas da SAC, respectivamente. No decorrer deste trabalho o símbolo $\hat{\cdot}$, indicará as estimativas genéricas das grandezas de interesse. Quando, eventualmente, este símbolo indicar especificamente a estimativa não-polarizada, tal fato será explicitado.

Nos itens seguintes abordaremos os métodos clássicos da análise espectral e conceituaremos os métodos paramétricos. Este material tem por objetivo formar uma base para os próximos capítulos e não se propõe aprofundar nestes assuntos.

2.4 Método Clássico Correlograma

O Método Correlograma tem por base a equação (2.1), na qual a SAC desconhecida, é substituída por uma estimativa, $r_{xx}^{\hat{\cdot}}[m]$, de comprimento $2C+1$, obtida de N amostras do processo aleatório $x[n]$:

$$\hat{P}_{xx}(f) = \sum_{m=-C}^{C} r_{xx}^{\hat{\cdot}}[m] \exp(-j2\pi mfT) \quad (2.19)$$

onde C é feito bem menor que N-1 de forma a evitar a variância associada às estimativas de autocorrelação de índices elevados. Um valor máximo $C \cong N/10$ é sugerido em [8].

O Método Correlograma fornece estimativas polarizadas do espectro de potência desejado, $\hat{P}_{xx}(f)$, pois:

$$\begin{aligned} E\left\{\hat{P}_{xx}(f)\right\} &= \sum_{m=-C}^C E\left\{\hat{r}_{xx}[m]\right\} \exp(-j2\pi mfT) \\ &= \sum_{m=-\infty}^{\infty} d[m] r_{xx}[m] \exp(-j2\pi mfT) \end{aligned}$$

onde $d[m]$ é uma janela de comprimento $2C+1$, retangular unitária se $\hat{r}_{xx}[m]$ é o estimador não-polarizado, ou triangular truncada se $\hat{r}_{xx}[m]$ é o estimador polarizado. Portanto:

$$E\left\{\hat{P}_{xx}(f)\right\} = P_{xx}(f) * D(f) \quad (2.20)$$

Assim, o valor médio das estimativas produzidas pelo estimador espectral Correlograma, é a convolução entre o espectro de potência desejado $P_{xx}(f)$, e o espectro de freqüências, $D(f)$, da janela $d[m]$.

A figura 2.1 mostra o espectro de freqüências de uma janela retangular unitária e o de uma janela triangular. Estas figuras permitem prever que a operação de convolução deformará o espectro $P_{xx}(f)$. As eventuais raias de $P_{xx}(f)$, produzidas por componentes periódicas em $x[n]$, serão alargadas pelo lóbulo central de $D(f)$, enquanto que os lóbulos laterais provocarão dispersões que polarizarão as componentes de $P_{xx}(f)$ adjacentes. O alargamento espectral impõe limites na capacidade de observar raias próximas em freqüência, ou seja, provoca capacidade limitada de resolução. O espalhamento, por sua vez, leva à polarização da estimativa. Além destes fenômenos, componentes de baixa potência, próximas à componentes de alta potência serão completamente mascaradas.

As janelas, retangular ou triangular, estão implícitas nas estimativas da SAC, devido ao número finito de amostras disponí-

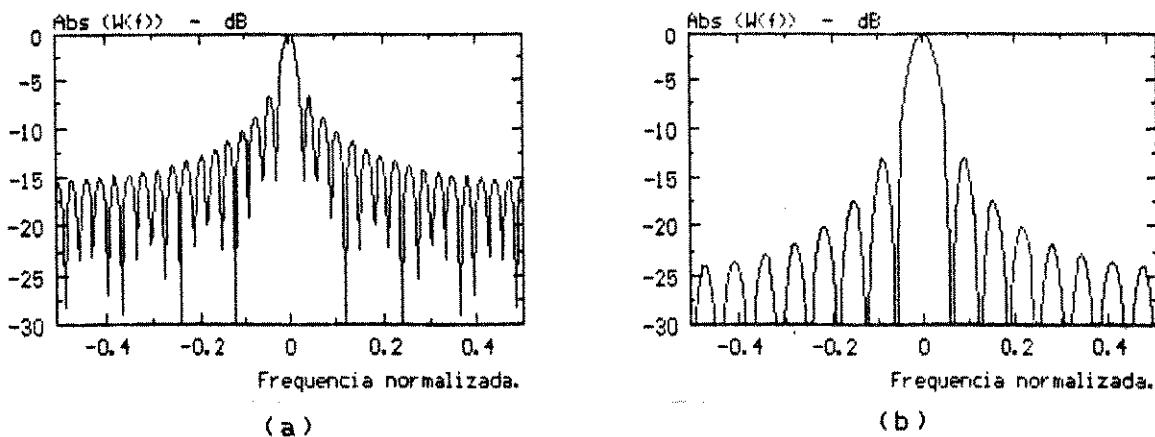


FIGURA 2.1 Espectro de Frequências de uma Janela (a) Retangular e (b) Triangular.

veis do processo aleatório sob análise. O aumento da variância das estimativas $\hat{r}_{xx}[m]$, à medida que m tende a $N-1$, também é consequência deste número finito. Seu efeito é controlado fazendo $C \ll N-1$, porém esta ação piora a resolução espectral, pois estreita a janela $w[m]$.

A tentativa de obter um compromisso entre o efeito da variância das estimativas de autocorrelação para $m \rightarrow N-1$ e a redução da resolução, leva à utilização de uma janela artificial $w[m]$:

$$\hat{P}_{xx}(f) = \sum_{m=-N+1}^{N-1} w[m] \hat{r}_{xx}[m] \exp(-j2\pi m f T)$$

onde $w[m]$ deve ter as seguintes características:

- a. $w[0] = 1$ para manter a potência média do sinal,
- b. $w[-m] = w[m]$, e
- c. $w[m] = 0$ para $|m| > C$.

onde C deve ser menor que $N-1$. Devido a estas propriedades a expressão anterior pode ser escrita como:

$$\hat{P}_{xx}(f) = \sum_{m=-C}^C w[m] \hat{r}_{xx}[m] \exp(-j2\pi m f T) \quad (2.21)$$

A equação (2.21) é a forma descrita por Blackman e Tukey, [8], para o estimador espectral Correlograma.

Para garantir que a estimativa espectral seja positiva, a janela $w[m]$ deve ser NND, tal como a estimativa de autocorrelação utilizada, motivo pelo qual é aconselhado o uso do estimador polarizado de autocorrelação.

2.5 Método Clássico Periodograma

O método Periodograma original tem por base o espectro do conjunto de N amostras do sinal, ou seja:

$$\hat{P}_{xx}(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x[n] \exp(-j2\pi n f T) \right|^2 \quad (2.22)$$

Este estimador apresenta variância excessiva, além de ser inconsistente, [1], devido à supressão das operações de média indicadas na seção 2.2. Novas versões deste método foram sugeridas visando corrigir estas deficiências. Dentre elas trataremos do método de Welch, por ser o mais empregado atualmente [1], [9].

No Periodograma de Welch o conjunto de N amostras é dividido em P segmentos, $x^{(p)}[n]$, com D amostras ($D \leq N-1$) cada um e é efetuado um deslocamento de S amostras entre segmentos adjacentes ($S \leq D$). Deste modo o número máximo de segmentos é a parte inteira de $1+(N-D)/S$. Sobre cada segmento é aplicada uma janela de ponderação $w[n]$, de forma que o p -ésimo segmento é dado por:

$$x^{(p)}[n] = w[n] x[n+pS] ; \quad 0 \leq p \leq P-1 \quad (2.23)$$

A Transformada de Fourier de cada segmento é:

$$X^{(p)}(f) = \sum_{n=0}^{D-1} x^{(p)}[n] \exp(-j2\pi n f T) \quad (2.24)$$

e o espectro de amostras:

$$\hat{P}_{xx}(f) = \frac{1}{D} |X^{(p)}(f)|^2 \quad (2.25)$$

Finalmente, o Periodograma de Welch é a média dos P espectros de amostras:

$$\hat{P}_{xx}(f) = \frac{1}{P} \sum_{p=0}^{P-1} P_{xx}^{(p)}(f) \quad (2.26)$$

O propósito da janela de ponderação é diminuir a polarização da estimativa e o efeito dos lóbulos laterais decorrentes da janela retangular, intrínseca ao número finito de amostras. A segmentação tem o propósito de reduzir a variância do estimador espectral, às custas de uma redução na resolução. A sobreposição entre segmentos tem por objetivo permitir um número significativo de segmentos sem uma redução drástica da resolução.

Existe um compromisso entre resolução e variância na escolha destes parâmetros: um número pequeno de segmentos fornece estimativas de maior resolução, porém de variância elevada, enquanto que um aumento do número de segmentos reduz a variância das estimativas, porém também reduz a resolução.

Tem sido proposto, [9], o uso de 50% do número de amostras por segmento como o valor de sobreposição entre os mesmos.

Ambos métodos clássicos, Correlograma e Periodograma serão utilizados e comparados entre si no capítulo 5 para a estimativa espectral de dois processo MA, e novamente no capítulo 6, dentro do contexto da estimacão espectral ARMA.

2.6 Modelos Paramétricos

Os métodos paramétricos se baseiam no fato que o processo $x[n]$ sob análise pode ser modelado pela resposta de um filtro linear causal composto por pólos e zeros, cuja excitação é um ruído branco, $u[n]$, de média nula e variância P_u . A DEP de $x[n]$ é obtida da relação entre os espectros de potência dos processos de entrada e saída.

$$P_{xx}(f) = P_u |H(f)|^2 \quad (2.27)$$

onde $H(f)$ é a função de transferência do filtro. A forma mais geral para $H(f)$ é uma função racional composta por p pólos e q zeros:

$$H(f) = \frac{\sum_{k=0}^q b[k] \exp(-j2\pi kfT)}{1 + \sum_{k=1}^p a[k] \exp(-j2\pi kfT)} \quad (2.28)$$

É necessário, então, estimar os parâmetros de $H(f)$ a partir das amostras de $x[n]$, de forma tal que a excitação pelo ruído branco gere uma estimativa de $x[n]$ na saída, conforme ilustrado na figura 2.2.

Desta forma, a DEP do processo gerado constitui uma estimativa da DEP do processo $x[n]$, e é completamente determinada por um número finito de variáveis: os parâmetros do filtro e a variância do ruído branco.

Se fosse possível representar as propriedades estatísticas do processo $x[n]$ de forma fiel através do modelo, os problemas de variância e janelamento decorrentes do conjunto finito de amostras seriam totalmente superados. Porém, para um número finito de amostras, o modelo é também uma estimativa e o processo gerado na sua saída, somente uma aproximação. Contudo, em geral, são obtidos resultados superiores aos fornecidos pelos métodos clássicos, pois é possível fazer uso de técnicas de estimação que permitem explorar melhor as informações presentes nas amostras disponíveis.

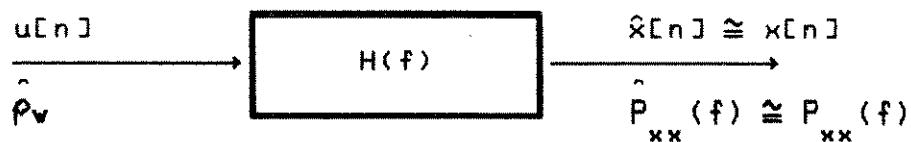


FIGURA 2.2 Aproximação de um Processo Aleatório $x[n]$ Através de um Modelo Racional

Os três tipos de modelos utilizados nos métodos paramétricos são definidos a partir da equação (2.28):

1. Modelo Auto-Regressivo Média-Ajustável de ordem p e q , ARMA(p, q). Neste modelo a função de transferência do filtro linear é a própria expressão (2.28).

2. Modelo Auto-Regressivo de ordem p , AR(p), com $q=0$ e $b[0]=1$. Para este modelo a equação (2.28) torna-se

$$H(f) = \frac{1}{1 + \sum_{k=1}^p a[k] \exp(-j2\pi k f T)} \quad (2.29)$$

neste caso o filtro apresenta somente p pólos.

3. Modelo Média-Ajustável de ordem q , MA(q), com $p=0$, a função de transferência é:

$$H(f) = \sum_{k=0}^q b[k] \exp(-j2\pi k f T) \quad (2.30)$$

e o filtro é composto por q zeros apenas.

A motivação para a explicitação destes modelos está ligada ao compromisso que existe entre o tipo de modelo a ser empregado e as características espectrais do processo a ser analisado. Os modelos compostos apenas por pólos são adequados à representação de espectros que apresentem picos, ao passo que aqueles compostos apenas por zeros são indicados para situações onde existem somente vales espectrais abruptos. Logo, os modelos com pólos e zeros são utilizados quando ambas características espectrais estão presentes.

Estes fatos tornam necessário um conhecimento prévio das características espectrais básicas do processo a ser analisado, de modo a permitir a exploração plena da potencialidade dos métodos paramétricos.

CAPÍTULO 3

MODELOS PARAMÉTRICOS PARA A ANÁLISE ESPECTRAL

3.1 Introdução

Neste capítulo são apresentadas as relações teóricas que caracterizam o processo gerado pelos modelos ARMA, AR e MA quando excitados por ruído branco. Estas relações são desenvolvidas tendo em vista a aplicação destes modelos na Análise Espectral. Em seguida são apresentadas as dificuldades de obtenção dos parâmetros dos modelos a partir das relações teóricas que envolvem a SAC do processo gerado e são abordadas as relações existentes entre os modelos AR e MA. Finalmente, é discutido o problema de aplicação destes conceitos teóricos na estimativa da DEP de um processo aleatório.

3.2 Modelo Auto-Regressivo Média-Ajustável De Ordem p E q, ARMA(p, q)

A função de sistema do filtro linear causal de um modelo ARMA(p, q) é composta por p pólos e q zeros:

$$H_{\text{ARMA}}(z) = \frac{B(z)}{A(z)} = \frac{\sum_{k=0}^q b[k] z^{-k}}{1 + \sum_{k=1}^p a[k] z^{-k}} \quad (3.1)$$

ou:

$$H_{\text{ARMA}}(z) = \frac{b[0] \prod_{k=1}^q \left[1 - \beta_k z^{-1} \right]}{\prod_{k=1}^p \left[1 - \rho_k z^{-1} \right]} \quad (3.2)$$

onde $A(z)$ é a Transformada de Z da seqüência de parâmetros $a[0], a[1], \dots, a[p]$, com $a[0]=1$, denominados parâmetros auto-regressivos.

vos, enquanto que $B(z)$ é a Transformada de Z da seqüência de parâmetros $b[0], \dots, b[q]$, denominados parâmetros média-ajustável, e p_k e z_k são as raízes dos polinômios $A(z)$ e $B(z)$, respectivamente.

Para garantir que filtro ARMA(p, q) seja causal e estável, os p pólos p_k devem estar no interior da circunferência de raio unitário (CRU) no plano Z [10]. A condição de estabilidade, $|p_k| < 1$ garante que o processo ARMA gerado seja estacionário [11].

A função de transferência associada é obtida da equação (3.1), substituindo z por $\exp(j2\pi fT)$:

$$H_{\text{ARMA}}(f) = \frac{B(f)}{A(f)} = \frac{\sum_{k=0}^q b[k] \exp(-j2\pi kfT)}{1 + \sum_{k=1}^p a[k] \exp(-j2\pi kfT)} \quad (3.3)$$

A equação (3.2) mostra que $b[0]$ pode ser considerado como um fator de ganho do filtro ARMA. Neste trabalho iremos empregar $b[0]=1$, e o ajuste da potência do processo $x[n]$, gerado pelo modelo, se dará através do valor da potência P_w do ruído branco de excitação.

Das equações (2.27) e (3.3) temos que a DEP do processo ARMA(p, q) é:

$$P_{\text{ARMA}}(f) = P_w \frac{|B(f)|^2}{|A(f)|^2} = P_w \frac{\left| 1 + \sum_{k=1}^q b[k] \exp(-j2\pi kfT) \right|^2}{\left| 1 + \sum_{k=1}^p a[k] \exp(-j2\pi kfT) \right|^2} \quad (3.4)$$

ou seja, a DEP do processo ARMA(p, q) é completamente definida pelos p parâmetros auto-regressivos, $a[k]$, os q parâmetros média-ajustável, $b[k]$, e pela variância, P_w , do ruído branco.

A figura 3.1 apresenta o espectro de densidade de potência de um processo ARMA (4, 4), onde podemos notar claramente as formas espectrais compostas por picos estreitos e vales abruptos, próprias de um processo ARMA. Os picos ocorrem nas freqüências dos pólos da equação (3.2) e se tornam tanto mais agudos quanto mais os pólos correspondentes se aproximem da CRU; de forma semelhante, os vales abruptos correspondem aos zeros e serão tanto mais abruptos quanto mais os zeros se aproximem da CRU.

A equação a diferenças, linear e com coeficientes constantes que define o processo $x[n]$ na saída do modelo pode ser obtida da aplicação da Transformada Z inversa na expressão (3.1):

$$x[n] = - \sum_{k=1}^p a[k] x[n-k] + \sum_{k=0}^q b[k] u[n-k] \quad (3.5)$$

A relação entre $x[n]$ e $u[n]$ também pode ser expressa por:

$$x[n] = \sum_{k=0}^{\infty} h[k] u[n-k] \quad (3.6)$$

onde $h[k]$ é a resposta impulsiva do filtro ARMA(p, q).

O modelo ARMA(p, q) é representado pelo fluxograma da figura 3.2.

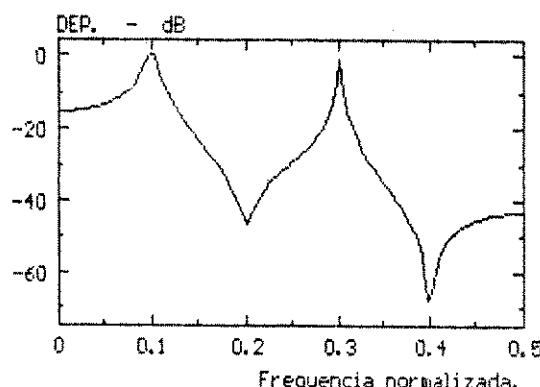


FIGURA 3.1 Espectro de Potência Típico de um Processo ARMA(4, 4).

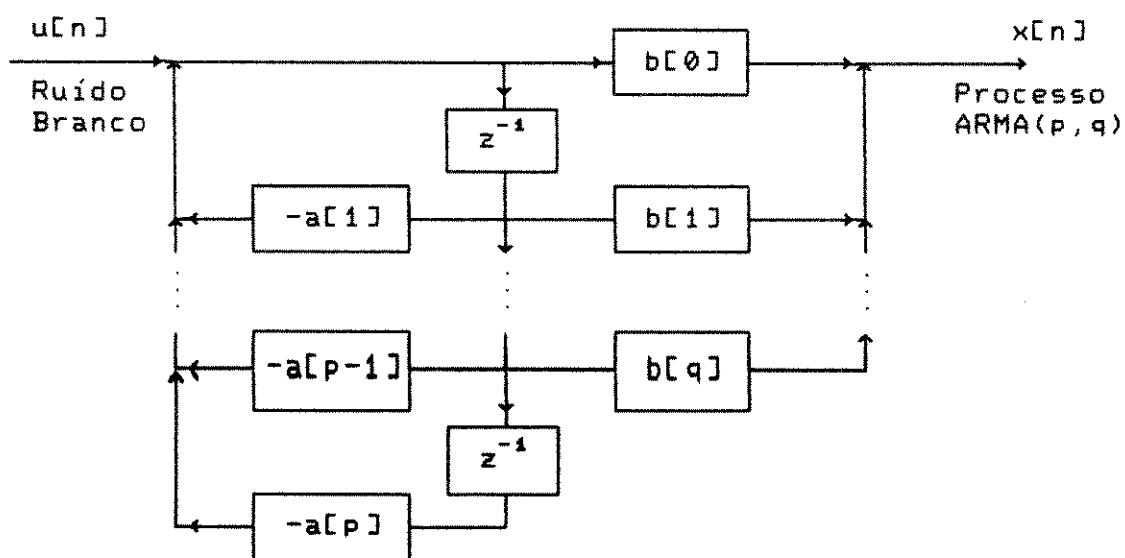


Figura 3.2 Modelo ARMA de Ordem p e q .

3.2.1 Relação entre os Parâmetros e a SAC de um Processo ARMA(p, q)

Esta relação é bastante importante no contexto da aplicação deste modelo para a análise espectral, pois será a base dos métodos de estimação dos parâmetros ARMA a partir das amostras de um sinal. Ela pode ser obtida reescrevendo a expressão (3.4) da seguinte forma:

$$P_{\text{ARMA}}(z) = \rho_w \frac{B(z)}{A(z)} H^*(z)$$

ou

$$P_{\text{ARMA}}(z) A(z) = \rho_w B(z) H^*(z) \quad (3.7)$$

Calculando a Transforma Z inversa:

$$r_{xx}[m] * [\delta[m] + a[m]] = \rho_w b[m] * h^*[-m] \quad (3.8)$$

onde $a[m] = \{a[1], \dots, a[p]\}$ e $b[m] = \{1, b[1], \dots, b[q]\}$ e $\delta[m]$ é a seqüência impulso unitário:

$$\delta[m] = \begin{cases} 1 & ; m=0 \\ 0 & ; m \neq 0 \end{cases}$$

Explicitando a convolução, temos:

$$r_{xx}[m] = - \sum_{k=1}^p a[k] r_{xx}[m-k] + \rho_w \sum_{k=0}^q b[k] h^*[k-m] \quad (3.9)$$

mas $h[n]=0$ para $n<0$. Logo:

$$r_{xx}[m] = - \sum_{k=1}^p a[k] r_{xx}[m-k] \quad ; \quad m>q \quad (3.10a)$$

$$r_{xx}[m] = - \sum_{k=1}^p a[k] r_{xx}[m-k] + \rho_w \sum_{k=m}^q b[k] h^*[k-m]; \quad 0 \leq m \leq q \quad (3.10b)$$

$$r_{xx}^*[-m] \quad ; \quad m \leq 0 \quad (3.10c)$$

Podemos observar que a relação entre os parâmetros auto-regressivos do processo ARMA(p, q) e sua SAC é linear para $|m| > q$, enquanto que os parâmetros média-ajustável estão convoluidos com os coeficientes da resposta impulsiva $h[n]$, resultando numa relação não-linear com a SAC.

Também, a SAC de um processo ARMA(p, q) não tem um limite definido, o que significa que as amostras do processo são todas correlacionadas entre si, independente do intervalo que as separa. Isto é consequência da presença de pólos no modelo e quanto mais próximos à CRU estes se encontram, maior é a sobreposição entre respostas impulsivas do filtro ARMA excitadas em instantes distintos, resultando numa maior correlação entre as amostras correspondentes.

A figura 3.2 permite inferir que os conjuntos de amostras do ruído branco $\{u[n-q], \dots, u[n]\}$ e $\{u[n-q+m], \dots, u[n+m]\}$ formam a componente média-ajustável de $x[n]$ e de $x[n+m]$, respectivamente. Estes dois conjuntos são compostos por amostras totalmente distintas quando $|m| > q$. Logo, as componentes média-ajustável correspondentes são incorrelatas entre si para $|m| > q$. Este é o motivo pelo qual os parâmetros $b[k]$ participam da definição da SAC somente para $|m| \leq q$. Isto não significa que a componente média-ajustável do processo ARMA não influencie a SAC para $|m| > q$, pois a autocorrelação deste processo é uma sequência regressiva em si mesma, conforme as equações (3.10a) e (3.10b).

A estimacão de um modelo ARMA para representar a DEP de um sinal parte de estimativas da SAC obtidas das amostras disponíveis, e faz uso das relações expressas na equação (3.10) para avaliar os parâmetros do modelo. Vamos analisar esta tarefa supondo, por enquanto, que a SAC é perfeitamente conhecida.

A não-linearidade destas relações, decorrente da convolução entre os parâmetros $b[k]$ e a resposta impulsiva do filtro ARMA, não permite obter simultaneamente os parâmetros do modelo através de algoritmos de fácil implementação. Para esta finalidade são utilizadas técnicas iterativas de elevada complexidade, [2], [11].

Entretanto, a linearidade observada para $|m| > q$ permite que os parâmetros auto-regressivos sejam calculados separadamente dos média-ajustável, através de um sistema de p equações formado com

base na expressão (3.10a). Por exemplo, do seguinte sistema de equações lineares, com $r_{xx}[m]$ no intervalo $q+1 \leq m \leq q+p$:

$$\begin{bmatrix} r_{xx}[q] & r_{xx}[q-1] & \dots & r_{xx}[q-p+1] \\ r_{xx}[q+1] & r_{xx}[q] & \dots & r_{xx}[q-p+2] \\ \vdots & \vdots & \ddots & \vdots \\ r_{xx}[q+p-1] & r_{xx}[q+p-2] & \dots & r_{xx}[q] \end{bmatrix} \begin{bmatrix} a[1] \\ a[2] \\ \vdots \\ a[p] \end{bmatrix} = - \begin{bmatrix} r_{xx}[q+1] \\ r_{xx}[q+2] \\ \vdots \\ r_{xx}[q+p] \end{bmatrix} \quad (3.11)$$

Este sistema é denominado Equações Normais ARMA de Yule-Walker ou Equações Modificadas de Yule-Walker. A matriz de autocorrelações é Toeplitz, o que facilita a solução do sistema através de um algoritmo de eliminação Gaussiana [1], [2].

Contudo, ainda que os parâmetros auto-regressivos sejam conhecidos, não é possível calcular com a mesma facilidade os média-ajustável devido à não-linearidade da relação de convolução. Torna-se necessário utilizar de certos algoritmos indiretos, conhecidos como métodos de estimação separada dos parâmetros do modelo ARMA, os quais serão estudados no capítulo 6. O estudo das características deste métodos é o objetivo central deste trabalho. Seu desenvolvimento requer os conceitos a serem desenvolvidos no restante deste capítulo, bem como nos capítulos 4 e 5.

3.3 MODELO AUTO-REGRESSIVO DE ORDEM p, AR(p)

O modelo AR(p) é um caso particular do modelo ARMA(p, q), onde os zeros são eliminados, restando apenas os pólos. A função de sistema do filtro AR(p) pode ser obtida da expressão (3.1) fazendo $q=0$ e $b[0]=1$, ou seja:

$$H_{AR}(z) = \frac{1}{A(z)} = \frac{1}{1 + \sum_{k=1}^p a[k] z^{-k}} \quad (3.12)$$

Os p pólos devem estar dentro da CRU para que o filtro seja estável e o processo gerado, estacionário.

Desta forma, a equação a diferenças linear associada será:

$$x[n] = - \sum_{k=1}^p a[k] x[n-k] + u[n] \quad (3.13)$$

onde os parâmetros $a[k]$ e o processo $u[n]$ são definidos como na seção anterior. O modelo AR(p) é representado no fluxograma da figura 3.3.

Particularizando a expressão (3.4), obtemos a DEP do processo AR(p):

$$P_{AR}(f) = \frac{P_w}{|A(f)|^2} = \frac{P_w}{\left| 1 + \sum_{n=1}^p a[n] \exp(-j2\pi n f T) \right|^2} \quad (3.14)$$

A figura 3.4 mostra o espectro de potência de um processo AR(4), onde observamos os picos estreitos, que correspondem aos pólos do filtro AR, e a ausência de vales abruptos em decorrência da ausência de zeros. Tal como no caso do modelo ARMA, os picos serão tanto mais agudos quanto mais próximos à CRU se encontrarem os pólos correspondentes. Logo, o modelo AR é adequado para a análise de processos com estas características espectrais.

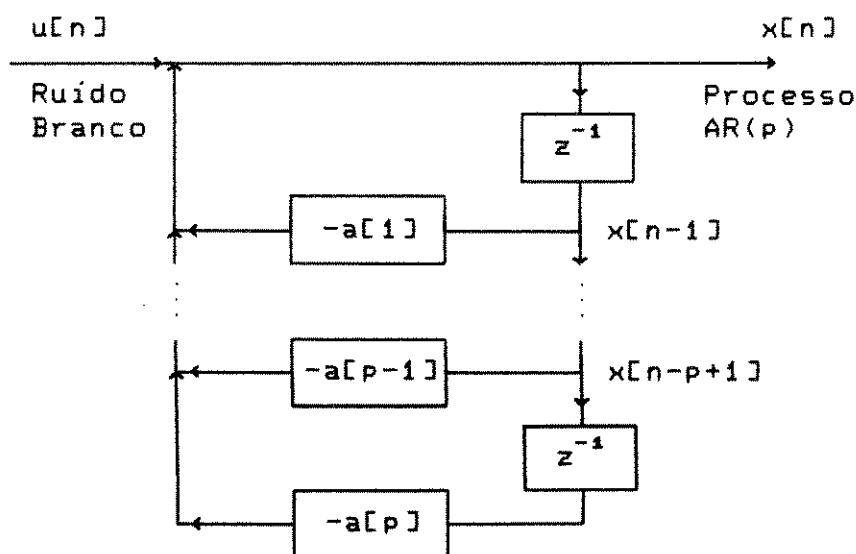


Figura 3.3 Modelo AR De Ordem p .

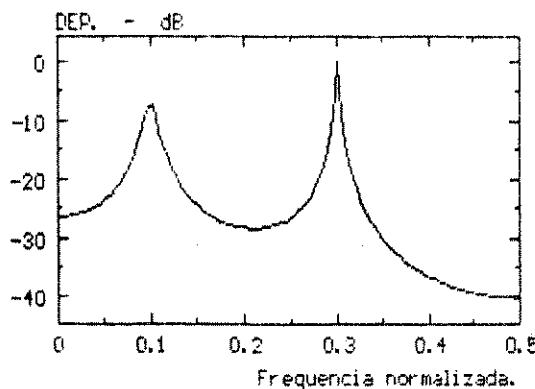


FIGURA 3.4 Espectro de Potência Típico de um Processo AR(4).

3.3.1 Relação entre os Parâmetros e a SAC de um Processo AR(p)

Fazendo $q=0$ nas equações (3.10), obtemos a relação entre os parâmetros de um processo AR(p) e sua SAC:

$$r_{xx}[m] = \begin{cases} - \sum_{k=1}^p a[k] r_{xx}[m-k] + P_w \delta[m] & ; m \geq 0 \\ r_{xx}^*[-m] & ; m < 0 \end{cases} \quad (3.15a)$$

$$(3.15b)$$

onde $\delta[m]$ é a seqüência impulso unitário, já definida.

A presença de P_w para $m=0$ decorre do fato de $b[0]=1$, o que faz com que $h[0]=1$.

O anulamento dos coeficientes $b[k]$ eliminou a presença da operação de convolução, presente na equação (3.10b), tornando linear a relação entre a SAC e os parâmetros $a[k]$. Este fato simplificará significativamente a tarefa de estimativa do modelo AR, como será discutido mais adiante.

Observamos ainda, que a SAC do processo AR(p), do mesmo modo que no caso ARMA, não tem um comprimento definido. Logo, aqui também as amostras do processo gerado são todas correlacionadas entre si, independente do intervalo que as separe. Este fato pode ser intuído de forma alternativa a partir da equação (3.13), a qual mostra que $x[n]$ depende das amostras passadas.

A estimação dos parâmetros de um modelo AR, supondo que a SAC seja conhecida, pode ser realizada através do seguinte sistema de $p+1$ equações lineares, obtido da equação (3.15) para $0 \leq m \leq p$:

$$\begin{bmatrix} r_{xx}[0] & r_{xx}^*[1] & \dots & r_{xx}^*[p] \\ r_{xx}[1] & r_{xx}[0] & \dots & r_{xx}^*[p-1] \\ \vdots & \vdots & \ddots & \vdots \\ r_{xx}[p] & r_{xx}^*[p-1] & \dots & r_{xx}^*[0] \end{bmatrix} \begin{bmatrix} 1 \\ a[1] \\ \vdots \\ a[p] \end{bmatrix} = \begin{bmatrix} \rho_v \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (3.16)$$

Este sistema, denominado de Equações Normais AR de Yule-Walker, em homenagem aos pioneiros dos modelos de regressão, mostra que para obter a variância do ruído branco e os parâmetros do processo AR(p), basta conhecer sua SAC no intervalo $0 \leq m \leq p$. Paralelamente, uma vez obtidos estes parâmetros, os valores de $r_{xx}[m]$ para $|m| > p$ podem ser obtidos recursivamente através da equação (3.15a), lembrando que $r_{xx}[-m] = r_{xx}^*[m]$:

A matriz de correlações do sistema de equações (3.16) é Toeplitz e Hermetiana, o que permite a solução deste sistema através do algoritmo de Levinson-Durbin. Este é um algoritmo eficiente de fácil implementação, e fornece os parâmetros do modelo AR de forma recursiva [1], [2].

Nas situações práticas onde se pretende aplicar o modelo AR para estimação da DEP de um processo $x[n]$, não dispomos dos valores da SAC para estimar os parâmetros do modelo. Entretanto, é possível substituir $r_{xx}[m]$ por estimativas da mesma obtidas a partir das amostras disponíveis do processo. A matriz de correlações formada por tais estimativas, continua a satisfazer as condições acima e o algoritmo de Levinson-Durbin poderá ser utilizado, desde que a matriz apresente inversa.

Em função destas características, o modelo AR tem sido amplamente estudado e aplicado.

3.4 MODELO MÉDIA-AJUSTÁVEL DE ORDEM q , MA(q)

O modelo MA(q) é o outro caso particular do modelo ARMA(p, q) onde os pólos são eliminados. Assim, fazendo $p=0$ na expressão (3.1), obtemos a função de sistema do filtro MA(q):

$$H_{MA}(z) = B(z) = 1 + \sum_{k=1}^q b[k] z^{-k} \quad (3.17)$$

O fato do filtro MA(q) apresentar apenas zeros faz com que a resposta impulsiva seja de comprimento finito. Portanto, o filtro é sempre estável e o processo MA(q) gerado é sempre estacionário. Se os q zeros se situarem no interior da CRU, o filtro apresentará fase mínima.

A equação a diferenças linear que define um processo MA(q) é dada por:

$$x[n] = u[n] + \sum_{k=1}^q b[k] u[n-k] \quad (3.18)$$

onde os parâmetros média-ajustável, $b[k]$, são os coeficientes da resposta impulsiva do filtro MA(q). O modelo MA(q) é representado no fluxograma da figura 3.5.

Paralelamente, a DEP de um processo MA(q) é dada por:

$$P_{MA}(f) = P_w |B(f)|^2 = P_w \left| 1 + \sum_{k=1}^q b[k] \exp(-j2\pi k f T) \right|^2 \quad (3.19)$$

Na figura 3.6 é mostrado o espectro de potência de um processo MA(4), onde as formas espectrais predominantes são os vales abruptos, correspondentes aos zeros do filtro. Logo, o modelo MA é adequado para processos com esta característica espectral.

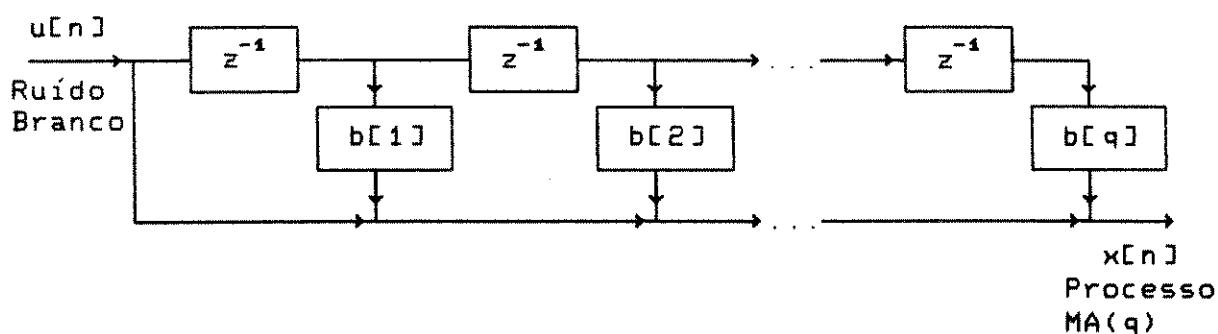


Figura 3.5 Modelo MA de Ordem q.

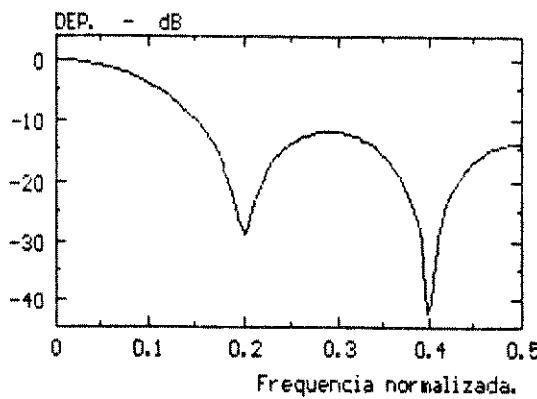


FIGURA 3.6 Espectro de Potência Típico de um Processo MA(4).

3.4.1 Relação entre os Parâmetros e a SAC de um Processo MA(q)

Fazendo $p=0$ na expressão 3.10 e lembrando que $h[k] = b[k]$, obtemos:

$$r_{xx}[m] = \begin{cases} 0 & ; m > q \\ P_v \sum_{k=m}^q b[k] b^*[k-m] & ; 0 \leq m \leq q \\ r_{xx}^*[-m] & ; m < 0 \end{cases} \quad (3.20)$$

na qual persiste a relação não-linear entre a SAC e os q parâmetros do processo MA(q).

Podemos constatar da expressão (3.20) que a SAC de um processo MA(q), é nula para $|m| > q$. Isto significa que amostras do processo separadas por um intervalo $|m| > q$ são incorrelatas. De fato, a equação (3.18) permite inferir que as amostras do ruído branco que formam $x[n]$ são totalmente distintas daquelas que compõem $x[n+m]$ para $|m| > q$. Portanto, $x[n]$ e $x[n+m]$ são incorrelatas entre si, para $|m| > q$.

A presença da relação não linear entre a SAC e os coeficientes $b[k]$ tornam difícil a tarefa de estimação destes coeficientes a partir de $r_{xx}[m]$. Existem duas técnicas propostas:

1. Técnicas iterativas de grande complexidade que não possuem garantia de convergência [11].

2. Técnicas de fatoração espectral que também apresentam alto grau de dificuldade, mas garantem uma solução satisfatória [5].

Entretanto, os parâmetros de um modelo $MA(q)$, também podem ser encontrados de forma indireta, através da relação existente entre os parâmetros de um modelo AR de ordem infinita e os do $MA(q)$, apresentada na seção a seguir, e que é explorada de forma ampla no capítulo 5 como parte do método de Durbin para a estimacão de parâmetros média-ajustável.

Em virtude da dificuldade de obtenção de seus parâmetros e de sua qualidade como estimador espectral, o modelo $MA(q)$ tem sido pouco estudado e utilizado. Entretanto, sua participação nos métodos de estimacão separada dos parâmetros do modelo $ARMA(p, q)$ é bastante importante, e motivou o estudo detalhado de suas características no capítulo 5.

3.5 RELAÇÃO ENTRE OS MODELOS AR E MA

Existem relações envolvendo os três modelos as quais permitem expressar um determinado modelo em função de outro. Assim um processo $ARMA(p, q)$ ou $MA(q)$ pode ser representado através de um modelo AR de ordem infinita, enquanto que um processo $ARMA(p, q)$ ou $AR(p)$, através de um MA de ordem infinita.

A importância destas relações reside em que, na prática podemos selecionar qualquer dos três modelos e ainda obter uma boa aproximação de um dado processo aleatório, desde que uma ordem suficientemente elevada seja utilizada. Ou ainda, podemos estimar os parâmetros de um modelo a partir das amostras do processo aleatório e, a partir desses, estimar os parâmetros de outro modelo [1].

Trataremos especificamente da relação entre os parâmetros dos modelos $AR(\infty)$ e $MA(q)$, que é a base do método de Durbin para estimacão dos parâmetros MA, apresentado no capítulo 5. As relações entre os outros modelos podem ser encontradas seguindo procedimento análogo [12].

Seja:

$$A(z) = \sum_{n=0}^{\infty} a[n] z^{-n} \quad (3.21)$$

o polinômio do denominador da função de sistema de um modelo AR(∞), onde $a[n] = 0$ para $n < 0$ e $a[0] = 1$, e

$$B(z) = 1 + \sum_{n=1}^q b[n] z^{-n} \quad (3.22)$$

o polinômio associado a um modelo MA(q).

Encontramos a equivalência entre os parâmetros $a[n]$ e $b[n]$, igualando a função do sistema $B(z)$ ao inverso de $A(z)$:

$$B(z) = \frac{1}{A(z)} \quad (3.23)$$

de onde resulta:

$$A(z) B(z) = 1 \quad (3.24)$$

Aplicando a Transformada Z inversa nesta expressão obtemos a relação desejada:

$$a[n] + \sum_{k=1}^q b[k] a[n-k] = \delta[n] \quad (3.25)$$

onde $\delta[n]$ é a seqüência impulso unitário, já definida.

Dados os parâmetros $a[n]$ podemos calcular os parâmetros do modelo MA(q) formando um conjunto de q equações lineares a partir da expressão (3.25) para $1 \leq n \leq q$.

Embora, na prática, não seja possível estimar um modelo AR(∞), este pode ser aproximado por um de ordem muito elevada ($p \gg q$). Isto permite contornar as dificuldades de estimar os parâmetros do modelo MA(q), aproveitando a facilidade de obtenção dos parâmetros dos modelos auto-regressivos: estimamos inicialmente, a partir das amostras disponíveis do processo, os parâmetros de um modelo AR de ordem suficientemente elevada (AR longo) e, utilizando as relações desta seção, obtemos as estimativas dos parâmetros do MA(q).

3.6 Estimadores Espectrais Paramétricos

O objetivo aqui é apresentar algumas considerações sobre a utilização das relações teóricas dos modelos paramétricos nas situações práticas onde se pretende a análise espectral de um processo aleatório $x[n]$ qualquer.

A princípio, é necessário estimar os parâmetros do modelo a ser utilizado, seja ARMA, AR ou MA, a partir do conjunto finito de amostras disponível, e substitui-las na equação correspondente da DEP, (3.4), (3.14) ou (3.19), para obter a estimativa espectral.

Entretanto, devemos antes selecionar o modelo a ser utilizado em função das características espectrais do processo $x[n]$. Estas não são, em geral, conhecidas e devem ser inferidas do conjunto de amostras disponível, o que pode ser efetuado através do método Periodograma.

Escolher o modelo adequado às características espectrais do processo é bastante importante. Se, por exemplo, for utilizado um modelo MA para estimar um espectro de potência com somente picos estreitos, então a ordem do modelo deverá ser bastante elevada para que a estimativa resultante seja de boa qualidade. A opção por um modelo AR permitiria a utilização de uma ordem muito menor, e a qualidade da estimativa resultante seria superior. Além disto, o esforço necessário para estimar os parâmetros seria consideravelmente menor.

Por outro lado, uma vez selecionado o modelo correto, a ordem do mesmo deve ser tal que evite a presença de formas espectrais falsas ou o mascaramento de detalhes importantes na estimativa do espectro de potência. Por exemplo, no caso de processos com picos espectrais estreitos, uma ordem auto-regressiva elevada poderá provocar a formação de picos espúrios, enquanto que uma ordem insuficiente fornecerá espectros de baixa resolução onde os picos espectrais não serão explicitados adequadamente.

Existem diversos critérios para a seleção da ordem. Dentre eles, o Critério de Informação de Akaike para os modelos AR, MA e ARMA será apresentado nos capítulos a seguir.

Em geral, a estratégia adotada para estimar os parâmetros do modelo selecionado consiste em obter inicialmente uma estimativa

da SAC a partir das amostras disponíveis do processo $x[n]$. Esta, então, é substituída na relação correspondente entre a SAC e os parâmetros do modelo, equação (3.10), (3.16) ou (3.20). É desta nova relação aproximada que são obtidas as estimativas dos parâmetros. Entretanto, o fato de trabalharmos com uma SAC estimada gera imprecisões, mesmo quando $x[n]$ é um processo obtido através do modelo racional selecionado.

O uso dos estimadores espectrais paramétricos fornecem estimativas de melhor qualidade que os estimadores espectrais clássicos, particularmente quando é necessário grande resolução e se dispõe de seqüências de amostras de comprimento pequeno.

Alguns métodos para obter os parâmetros dos modelos paramétricos a partir de uma estimativa da SAC serão objeto dos próximos capítulos.

CAPÍTULO 4

ESTIMADORES DO MODELO AUTO-REGRESSIVO, MÉTODOS COM BASE NA ANÁLISE DE PREDIÇÃO LINEAR

4.1 Introdução

No capítulo anterior foi delineado o método de estimacão dos parâmetros do modelo AR baseado na matriz de autocorrelações dos dados e no algoritmo de Levinson-Durbin. Entretanto, tal método apresenta resultados satisfatórios apenas nas situações onde o número de amostras disponíveis é bem maior que a ordem do modelo AR desejado.

O objetivo deste capítulo é apresentar métodos baseados na Teoria de Predição Linear, em particular o método Covariância e Covariância Modificado, que oferecem melhor resolução espectral às custas de um maior esforço computacional. A abordagem destes métodos aqui visa apenas criar um suporte para sua aplicação nos métodos de estimacão MA e ARMA dos capítulos seguintes.

4.2. Relação entre a Análise de Predição Linear e o Modelo Auto-Regressivo

Existe uma relação estreita entre a análise de predição linear e a modelagem auto-regressiva. Tal relação tem sido amplamente explorada para a obtenção dos parâmetros do modelo AR, e é apresentada a seguir.

Abordaremos primeiro a predição linear progressiva de um processo $x[n]$. Usamos o termo progressiva como o equivalente à palavra inglesa "forward" e denotamos as variáveis envolvidas com o sub-índice f . De forma semelhante, utilizaremos o termo regressivo em substituição a "backward" e mantemos o sub-índice b , para a predição linear regressiva.

Seja $\hat{x}_f[n]$ a previsão linear progressiva da amostra $x[n]$, em termos das p amostras anteriores $x[n-1], \dots, x[n-p]$, isto é:

$$\hat{x}_f[n] = - \sum_{k=1}^p a_f[k] x[n-k] \quad (4.1)$$

Onde $a_f[1], \dots, a_f[p]$ são os coeficientes da previsão linear progressiva.

O erro de previsão da amostra $x[n]$ é definido como:

$$\begin{aligned} e_f[n] &= x[n] - \hat{x}_f[n] \\ &= x[n] + \sum_{k=1}^p a_f[k] x[n-k] \end{aligned} \quad (4.2)$$

e sua potência média P_f como:

$$P_f = E \{ |e_f[n]|^2 \} \quad (4.3)$$

A equação (4.2) é a equação a diferenças lineares que descreve o filtro de erro de previsão progressiva de ordem p mostrado na figura 4.1, onde $x[n]$ é o processo de excitação deste filtro e $e_f[n]$ seu processo residual.

Sabe-se que os p coeficientes $a_f[k]$, que minimizam a potência do erro de previsão são obtidos solucionando-se o seguinte sistema de equações [1], [2], [6]:

$$\begin{bmatrix} r_{xx}[0] & r_{xx}^*[1] & \dots & r_{xx}^*[p] \\ r_{xx}[1] & r_{xx}[0] & \dots & r_{xx}^*[p-1] \\ \vdots & \vdots & \ddots & \vdots \\ r_{xx}[p] & r_{xx}^*[p-1] & \dots & r_{xx}^*[0] \end{bmatrix} \begin{bmatrix} 1 \\ a_f[1] \\ \vdots \\ a_f[p] \end{bmatrix} = - \begin{bmatrix} P_f \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (4.4)$$

onde $r_{xx}[m]$ é a SAC teórica do processo $x[n]$.

Este sistema tem estrutura idêntica às Equações Normais AR de Yule-Walker, equação (3.16). Também, a equação (4.2) é similar a expressão (3.13) que define um modelo AR(p).

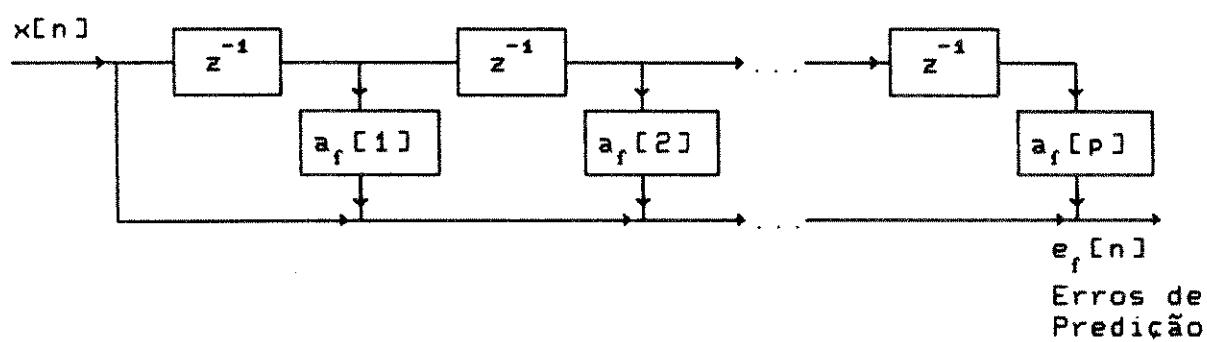


Figura 4.1 Filtro de Erro de Predição Progressiva de Ordem p .

Desta forma, se o processo $x[n]$ foi gerado por um filtro AR(p), então a seqüência de erros de predição é o ruído branco $u[n]$ da equação (3.13), os coeficientes da predição linear progressiva são os parâmetros auto-regressivos ($a_f[k] = a[k]$) e o filtro de erro de predição (que é o inverso do filtro AR(p)) é um filtro branqueador.

De forma semelhante, seja $\hat{x}_b[n]$ a predição linear regressiva da amostra $x[n]$, em função das p amostras futuras $x[n+1], \dots, x[n+p]$:

$$\hat{x}_b[n] = - \sum_{k=1}^p a_b^*[k] x[n+k] \quad (4.5)$$

onde $a_b[1], \dots, a_b[p]$ são os coeficientes da predição linear regressiva de ordem p .

O erro $e_b[n]$ desta predição é dado pela equação a seguir:

$$\begin{aligned} e_b[n] &= x[n] - \hat{x}_b[n] \\ &= x[n] + \sum_{k=1}^p a_b^*[k] x[n+k] \end{aligned} \quad (4.6)$$

e a potência a ser minimizada:

$$P_b = E \left\{ |e_b[n]|^2 \right\} \quad (4.7)$$

Os coeficientes $a_b[k]$ que minimizam P_b são obtidos através do seguinte sistema:

$$\begin{bmatrix} r_{xx}[0] & r_{xx}^*[1] & \dots & r_{xx}^*[p] \\ \vdots & \vdots & \ddots & \vdots \\ r_{xx}[p-1] & r_{xx}[p-2] & \dots & r_{xx}^*[1] \\ r_{xx}[p] & r_{xx}[p-1] & \dots & r_{xx}[0] \end{bmatrix} \begin{bmatrix} a_b[p] \\ \vdots \\ a_b[1] \\ 1 \end{bmatrix} = - \begin{bmatrix} 0 \\ \vdots \\ 0 \\ p_b \end{bmatrix} \quad (4.8)$$

Onde a matriz de autocorrelações é a mesma da equação (4.4). Estas semelhanças permitem demonstrar que as soluções das equações matriciais (4.4) e (4.8) apresentam as seguintes propriedades [1], [2], [6]:

$$a_b[k] = a_f^*[k] \quad 1 \leq k \leq p \quad (4.9)$$

$$\rho_b = \rho_f$$

Também, ambas predições lineares contêm a mesma informação estatística do processo $x[n]$. Assim, se o filtro de erro de predição progressiva é um filtro branqueador de um processo AR(p), então o filtro de erro de predição regressiva pode ser considerado como o filtro branqueador de uma realização anti-causal do mesmo processo.

4.3 Métodos de Estimação AR Baseados na Predição Linear Progressiva

Seja a seqüência de amostras $x[0], \dots, x[N-1]$, de um processo $x[n]$ no qual se deseja efetuar uma modelagem AR(p). De acordo com a teoria da seção anterior, a técnica de predição linear permitiria obter os parâmetros deste modelo. Entretanto não conhecemos a SAC de $x[n]$ e não podemos montar a equação (4.4). Torna-se então necessário definir outro critério de otimização que leve em conta o número finito de amostras disponíveis.

A estratégia mais empregada nesta situação é a minimização da soma dos erros quadráticos de predição das amostras disponíveis, a qual é geralmente denominada critério dos mínimos quadrados. Ví-sando explicitar tal critério, vamos considerar os erros de predição:

$$e_f[n] = x[n] - \hat{x}_f[n] = x[n] + \sum_{k=1}^p a_f[k] x[n-k] \quad (4.10)$$

definidos no intervalo $0 \leq n \leq N-1+p$, considerando $x[n]=0$ para $n < 0$ e $n \geq N$.

Os $N+p$ erros de predição representados pela equação (4.10), podem ser expressos na forma matricial:

$$\begin{bmatrix} e_f[0] \\ \vdots \\ e_f[p] \\ \vdots \\ e_f[N-1] \\ \vdots \\ e_f[N-1+p] \end{bmatrix} = \begin{bmatrix} x[0] & \dots & 0 \\ \vdots & \ddots & \vdots \\ x[p] & \dots & x[0] \\ \vdots & & \vdots \\ x[N-1] & \dots & x[N-1-p] \\ \vdots & & \vdots \\ 0 & \dots & x[N-1] \end{bmatrix} \begin{bmatrix} 1 \\ a_f[1] \\ \vdots \\ a_f[p] \end{bmatrix} \quad (4.11)$$

onde a matriz de amostras de ordem $(N+p) \times (p+1)$, denominada X , é uma matriz retangular Toeplitz. Seus elementos nas extremidades superior direita e inferior esquerda são nulos devido a que $x[n]=0$ para $n < 0$ e $n \geq N$.

Os coeficientes da predição linear são encontrados minimizando a potência do erro de predição:

$$P_f = \sum_n |e_f[n]|^2 \quad (4.12)$$

onde os limites da soma não foram especificados de propósito, já que sua seleção determina os critérios distintos para a determinação de tais coeficientes. Dentre estes, estudaremos:

1. Método Autocorrelação.
2. Método Covariância.

Método Autocorrelação

Neste método são selecionados todos os $N+p$ termos do erro de predição associados à matriz de amostras X , de modo que a relação

entre os erros previsão, $e_f[n]$, e os coeficientes $a_f[k]$, é a própria equação (4.11):

$$e_f = X \begin{bmatrix} 1 \\ a_f \end{bmatrix} \quad (4.13)$$

onde:

$$\begin{aligned} e_f &= [e_f[0], \dots, e_f[N-1+p]]^T \\ a_f &= [a_f[1], \dots, a_f[p]]^T \end{aligned} \quad (4.14)$$

onde " T " denota a operação de transposição.

Assim, o objetivo é encontrar o conjunto de coeficientes que minimizam ρ_f , dado por:

$$\rho_f = \sum_{n=0}^{N-1+p} |e_f[n]|^2 \quad (4.15)$$

Pode-se mostrar que este conjunto ótimo é obtido pela solução da equação (1):

$$X^H X \begin{bmatrix} 1 \\ a_f \end{bmatrix} = \begin{bmatrix} \rho_f \\ 0_p \end{bmatrix} \quad (4.16)$$

onde 0_p é um vetor de p elementos nulos.

O produto $R = X^H X$ é uma matriz quadrada de ordem $(p+1)$, Hermitiana, cujos elementos, $rr[i,j]$, são:

$$\begin{aligned} rr[i,j] &= \sum_{n=0}^{N-1+p} x^*[n-i] x[n-j] = \sum_{n=0}^{N-1-(i-j)} x[n+i-j] x^*[n] \\ rr[i,j] &= rr^*[j,i] \end{aligned} \quad (4.17)$$

para $0 \leq i-j \leq p$. Como $rr[i,j]$ depende apenas de diferença $(i-j)$, a matriz R é também Toeplitz. Se cada termo $rr[i,j]$ é dividido pelo número de amostras, N , então estes termos serão iguais as estimativas polarizada da autocorrelação: $r_{xx}[i-j] = rr[i,j]/N$. Se ρ_f é também dividido por N , então as equações normais (4.16) serão

idênticas as equações de Yule-Walker (3.16), com a SAC teórica substituída pelas estimativas polarizadas de autocorrelação do processo $x[n]$.

A matriz R , além de ser Toeplitz e Hermitiana, é também positiva definida, o que garante que a sequência $\{1, a_1[1], \dots, a_p[p]\}$, solução da equação (4.16), será de fase mínima [2]. Logo, o filtro de erro de predição associado também o será. Isto garante que o modelo AR(p) (cuja função de sistema é a inversa do filtro de erro de predição) apresentará todos seus pólos no interior da CRU e será, portanto, estável.

Estas características da matriz R permite a solução da equação matricial (4.16) através do algoritmo de Levinson-Durbin, o qual apresenta um número pequeno de operações proporcional a p^2 , em contraste com o método de eliminação Gaussiana (algoritmo de Cholesky) onde o número de operações é proporcional a p^3 [1].

Os elementos nulos na matriz de amostras X estão associados aos registradores de conteúdo nulo no filtro de erro de predição linear; o que implica que os erros de predição na saída do filtro serão maiores que aqueles obtidos quando o filtro está "cheio", ou seja, quando todos seus registradores apresentam conteúdo não-nulo. Isto acarreta estimativas espectrais AR com resolução pobre, principalmente quando o número de amostras é pequeno. Nesta situação a qualidade das estimativas obtidas é bastante semelhante à daquelas fornecidas pelo método Periodograma [1].

Este fato motivou a avaliação de outros métodos onde os erros correspondentes à situação em que o filtro não está completamente "cheio" são desenfatizados ou abandonados. Dentre estes, destaca-se o método Covariância.

Método da Covariância

Aqui são selecionados apenas os $N-p$ termos do erro de predição $e_1[p], \dots, e_{N-1}[N-1]$, associados aos elementos não-nulos da matriz X . Isto significa que não é colocada nenhuma hipótese sobre as amostras fora do intervalo $0 \leq n \leq N-1$.

Os elementos não-nulos da matriz X utilizados formam a matriz T , Toeplitz, de ordem $(N-p) \times (p+1)$:

$$T = \begin{bmatrix} x[p] & \dots & x[0] \\ & \vdots & \\ x[N-1] & \dots & x[N-1-p] \end{bmatrix} \quad (4.18)$$

A relação entre os erros de predição e os coeficientes $a_f[k]$ é:

$$e_f = T \begin{bmatrix} 1 \\ a_f \end{bmatrix} \quad (4.19)$$

onde o vetor a_f é definido como na equação (4.14), e

$$e_f = [e_f[p], \dots, e_f[N-1]]^T \quad (4.20)$$

Assim, a potência média do erro de predição a ser minimizada é:

$$\rho_{cv} = \frac{1}{N-p} \sum_{n=p}^{N-1} |e_f[n]|^2 \quad (4.21)$$

e as equações normais que a minimizam são:

$$T^H T \begin{bmatrix} 1 \\ a_f \end{bmatrix} = \begin{bmatrix} \rho_{cv} \\ 0_p \end{bmatrix} \quad (4.22)$$

O produto $R = T^H T$ é uma matriz Hermitiana quadrada de ordem $(p+1)$. Também é uma matriz não-Toeplitz, já que seus elementos:

$$rr[i,j] = \frac{1}{N-p} \sum_{n=p}^{N-1} x^*[n-i] x[n-j] ; \quad 0 \leq i, j \leq p \quad (4.23)$$

não podem ser expressos em termos da diferença $(i-j)$.

Em função disto, o sistema de equações normais (4.22) é resolvido através do algoritmo de Cholesky, resultando em um esforço computacional maior que o método Autocorrelação.

A matriz R é, em geral, positiva definida, o que significa que não se pode garantir que os coeficientes de predição encontrados formem uma seqüência de fase-mínima [2]. Logo o modelo AR(p) correspondente poderá ser instável. Para a aplicação em análise espectral, esta instabilidade não é problemática.

Uma condição necessária, mas não suficiente, para que a matriz R seja não singular é [1]:

$$p \leq \frac{N}{2} \quad (4.24)$$

o que condiciona a escolha da ordem do modelo AR(p).

Uma vez que a matriz de amostras T está associada ao filtro de erro de predição "cheio", cada amostra $x[n]$ no intervalo $p \leq n \leq N-1$ é prevista unicamente em termos das amostras disponíveis, e, portanto, os erros de predição tendem a ser pequenos. Como resultado o uso do método Covariância fornece estimativas espectrais AR com resolução significativamente melhor que o método anterior, particularmente quando o número de amostras disponíveis é pequeno.

4.4 Método Covariância Modificado

Na seção 4.2, foi mencionado que as predições lineares progressivas e regressivas contêm a mesma informação estatística do processo $x[n]$. Entretanto, o mesmo não se verifica quando dispomos de um conjunto finito de amostras para calcular os filtros ótimos. Neste caso os preditores progressivos e regressivos ótimos segundo o critério dos mínimos quadrados fornecerão resultados distintos [1]. Este fato sugere a combinação de ambas predições para gerar mais pontos de erros e obter, como resultado, melhores estimativas dos parâmetros do modelo AR(p).

Desta forma o erro de predição regressiva, $e_b[n]$, equação (4.6), pode ser expresso como:

$$e_b[n] = x[n-p] + \sum_{k=1}^p a_b^*[k] x[n-p+k] \quad (4.25)$$

onde agora é utilizada a notação $n-p$, em lugar de n , para que $e_f[n]$ e $e_b[n]$ sejam funções do mesmo conjunto de amostras ($x[n]$, $x[n-1], \dots, x[n-p]$).

A estratégia adotada para o cálculo dos coeficientes é a minimização da soma dos erros quadráticos da previsão progressiva e regressiva:

$$\rho_{\text{CVM}} = \frac{1}{2(N-p)} \left[\sum_{n=p}^{N-1} |e_f[n]|^2 + \sum_{n=p}^{N-1} |e_b[n]|^2 \right] \quad (4.26)$$

sujeita à condição que $a_f[k] = a_b^*[k]$ para $1 \leq k \leq p$. Aqui também são utilizados apenas os erros correspondentes a filtros cheios, o que justifica os extremos no somatório da equação (4.26).

A minimização de ρ_{CVM} nas condições acima leva ao seguinte sistema de equações:

$$R \begin{bmatrix} 1 \\ a_f \end{bmatrix} = \begin{bmatrix} 2\rho_{\text{CVM}} \\ 0_p \end{bmatrix} \quad (4.27)$$

onde R é dado por,

$$R = T^H T + J T^H T^* J \quad (4.28)$$

T é a matriz do item anterior e J é a matriz de reflexão quadrada de ordem $(p+1)$:

$$J = \begin{bmatrix} 0 & \dots & 0 & 1 \\ 0 & \dots & 1 & 0 \\ \vdots & \ddots & \vdots & \vdots \\ 1 & \dots & 0 & 0 \end{bmatrix} \quad (4.29)$$

R é uma matriz quadrada de ordem $(p+1)$, não-Toeplitz, Hermitiana cujos elementos são, [2]:

$$rr[i,j] = \frac{1}{2(N-p)} \left[\sum_{n=p}^{N-1} x^*[n-i] x[n-j] + \sum_{n=0}^{N-1-p} x[n+i] x^*[n+j] \right] \quad (4.30)$$

A seqüência de estimativas de parâmetros auto-regressivos obtidas através deste método pode não ser de fase mínima. A matriz R é, em geral, positiva definida e a ordem auto-regressiva a ser escolhida deve obedecer a

$$p \leq \frac{2N}{3} \quad (4.31)$$

a qual é a condição necessária mas não suficiente para que R seja não singular [1].

Tal como no método anterior, o Covariância Modificado requer um número de operações proporcional a p^3 , para a solução das equações normais (4.27) através do algoritmo de Cholesky.

Este método é altamente indicado para situações onde se necessita de grande resolução e de dispõe de um número reduzido de amostras. Seu desempenho é superior ao do método Covariância, porém o esforço computacional também é maior.

O método Covariância Modificado tem sido amplamente estudado dentro do contexto de detecção de senoides em ruído branco. E é observado que para esta finalidade seu melhor desempenho é atingido quando a ordem do modelamento AR é [13], [14]:

$$p = \frac{N}{3} \quad (4.32)$$

4.5 Seleção da Ordem do Modelo AR

Sabemos que a seleção da ordem do modelo AR representa um compromisso entre o aumento da resolução e a diminuição da variância do espectro de potência estimado.

Como não se sabe previamente qual é a melhor ordem a ser utilizada diversos critérios de seleção da ordem tem sido propostos

[1], [2]. Dentre eles apresentamos o Critério de Informação Akaike, CIA.

O CIA determina a ordem do modelo minimizando uma função de informação teórica. Para processos AR de características estatísticas Gaussianas, este critério estabelece que a ordem p adequada é aquela que minimiza [1]:

$$CIA[p] = N \ln(P_w) + 2p \quad (4.33)$$

onde

N é o número de amostras disponíveis

\ln é a função logaritmo natural

P_w é a estimativa da variância do ruído branco, e

p é a ordem a ser selecionada.

Uma forma de testar se a ordem p selecionada é a mais adequada é verificar se os resíduos produzidos pelo filtro branqueador de ordem p associado, quando alimentado pelo processo sob análise, se aproximam de um processo tipo ruído branco; ou seja, se o espectro de potência dos resíduos é aproximadamente constante. Este espectro pode ser estimado através do método Correlograma ou o Periodograma.

CAPÍTULO 5

ESTIMAÇÃO ESPECTRAL MÉDIA-AJUSTAVÉL

5.1 Introdução

Como foi observado no capítulo 3, o uso do estimador espectral MA é adequado para a análise de processos cuja DEP é formada por picos de faixa larga, vales abruptos ou ambos. Por outro lado, uma vez que este modelo é composto apenas por zeros, seu uso não é aconselhado quando se deseja estimativas espectrais de alta resolução. Também a relação de convolução (3.20) dificulta a estimação de seus parâmetros em função da SAC estimada do processo sob análise.

Embora estas desvantagens, as técnicas de estimação MA fazem parte importante dos métodos de estimação separada dos parâmetros do modelo ARMA, apresentados no capítulo a seguir.

É em função deste fato que estudamos aqui o método de Durbin para a estimação dos parâmetros do modelo MA(q), bem como a comparação entre este e os métodos clássicos, Correlograma e Periodograma, na estimativa espectral de processos MA.

Analisamos com riqueza de detalhes, o uso do método de Durbin para a estimativa espectral de dois processos MA(4) onde são apresentadas novas idéias que permitiram alcançar melhor desempenho. Em seguida, as estimativas obtidas são comparadas com as fornecidas pelos estimadores clássicos.

5.2 Método de Durbin para a Estimação dos Parâmetros do Modelo MA

Como descrito no capítulo 3, este método é uma alternativa para contornar as dificuldades da estimação dos parâmetros do modelo MA(q). É um algoritmo indireto, de fácil implementação e que utiliza relações lineares.

A base do método de Durbin é equação (3.25) da relação entre o modelo AR(∞) e o modelo MA(q):

$$a[n] + \sum_{k=1}^q b[k] a[n-k] = d[n] \quad 0 \leq n \leq \infty \quad (5.1)$$

Dado que não é possível estimar um modelo AR com ordem infinita, este é substituído por um modelo AR(L) de ordem suficientemente elevada ($L > q$), o qual é geralmente denominado AR longo. As estimativas de seus coeficientes são obtidas do conjunto de amostras disponíveis do processo $x[n]$, através de algum método de estimação dos parâmetros do modelo AR, como, por exemplo, os apresentados no capítulo anterior.

A ordem L deve ser a maior possível, pois quanto maior o seu valor, melhor será a aproximação entre o processo AR(L) e o MA(q) desejado. A fim de compreender este fato, vamos retomar a equação (3.23) que estabelece o critério de equivalência entre os modelos e analisar a relação entre as respostas impulsivas dos filtros associados. Especificamente, vamos inverter a relação (3.23) e calcular a resposta impulsiva de $1/B(z)$, em função dos q zeros, α_k do polinômio $B(z)$. Por questão de simplicidade, consideraremos somente zeros simples. Assim:

$$\begin{aligned} A(z) = \frac{1}{B(z)} &= \frac{1}{1+b[1] z^{-1} + \dots + b[q] z^{-q}} \\ &= \frac{1}{\prod_{k=1}^q (1 - \alpha_k z^{-1})} \end{aligned}$$

A expansão de $1/B(z)$ em frações parciais permite escrever:

$$A(z) = \frac{1}{B(z)} = \frac{A_1}{1 - \alpha_1 z^{-1}} + \dots + \frac{A_q}{1 - \alpha_q z^{-1}}$$

Da transformada Z inversa:

$$h_{1/B(z)}[n] = [A_1 \alpha_1^n + \dots + A_q \alpha_q^n] d[n] \quad (5.2)$$

onde $d[n]$ é a sequência degrau unitário:

$$d[n] = \begin{cases} 1 & ; n \geq 0 \\ 0 & ; n < 0 \end{cases}$$

A equação (5.2) mostra que enquanto $|a_k| < 1$, a resposta impulsiva associada a $1/B(z)$ decresce exponencialmente com n , indicando um comprimento ilimitado e, portanto, uma ordem infinita para $A(z)$. Entretanto, se suas amplitudes tornam-se desprezíveis para valores de n maiores que L , será possível truncá-la neste valor gerando um polinômio $A(z)$ de ordem L , ou seja, um filtro AR equivalente de ordem L . Podemos inferir de imediato que quanto mais próximos à CRU no plano Z estiverem os zeros de $B(z)$, maior será o valor de L necessário para garantir uma boa aproximação para o processo $MA(q)$.

Do ponto de vista da aplicacão para análise espectral, devemos observar que os vales espectrais serão representados pelos zeros do polinômio $B(z)$ do modelo $MA(q)$ a ser estimado. Logo, os zeros deste modelo deverão se situar tanto mais próximos da CRU quanto mais abruptos forem os vales do espetro a ser avaliado. Assim, quanto mais abruptos forem os vales maior deverá ser a ordem L do modelo AR longo, de modo a garantir uma boa qualidade na estimativa do modelo $MA(q)$.

Deve-se observar que a adoção de uma ordem L finita faz com que os parâmetros $a[n]$ sejam nulos para $n > L$ e a igualdade da equação (5.1) dá lugar a uma aproximação. Expressando este último fato através de um erro $e[n]$, podemos reescrever (5.1) da seguinte forma:

$$e[n] = a[n] + \sum_{k=1}^q b[k] a[n-k] ; 0 \leq n \leq L \quad (5.3)$$

Seria desejável que $e[n]$ fosse nulo para todo valor de n exceto $n=0$, onde deveria ser unitário, uma vez que, por hipótese, $a[0]=1$. Na impossibilidade, podemos escolher os parâmetros MA, dados os $a[n]$, de modo a minimizar a potênciia de erro $e[n]$ sujeito à restrição $e[0] = a[0] = 1$.

A estrutura da equação (5.3) é semelhante à de um filtro de erro de predição progressiva de ordem q e coeficientes $b[k]$, onde $\{1, a[1], \dots, a[L]\}$ é a seqüência de entrada deste filtro. Assim, os coeficientes $b[k]$ ótimos podem ser obtidos da teoria do capítulo 4, segundo o critério dos mínimos quadrados. Logo, vamos analisar a possibilidade de aplicação dos métodos Autocorrelação e Covariância a este caso.

No método Autocorrelação, os parâmetros $b[k]$ serão estimados minimizando a potência média do erro de predição, P_{AT} , dada por:

$$P_{AT} = \frac{1}{L+1} \sum_{n=0}^L \left| a[n] + \sum_{k=1}^q b[k] a[n-k] \right|^2 \quad (5.4)$$

onde os $a[n]$ são considerados nulos fora do intervalo de observação ($0 \leq n \leq L$). Isto garante que o erro de predição para $n=0$ será igual a $a[0]$.

Já no método Covariância, os parâmetros $b[k]$ são encontrados minimizando a potência média do erro de predição, P_{cv} , dada por:

$$P_{cv} = \frac{1}{L+1-q} \sum_{n=q}^L \left| a[n] + \sum_{k=1}^q b[k] a[n-k] \right|^2 \quad (5.5)$$

Os limites da soma na equação (5.5) fazem com que sejam considerados apenas os $a[n]$ no intervalo $0 \leq n \leq L$. Logo, nenhuma hipótese é colocada sobre os valores de $a[n]$ fora deste intervalo. Ainda e por esta razão, o erro de predição para $n=0$ não será igual a $a[0]$ (de fato este erro não é utilizado no processo de minimização, como podemos deduzir da equação (5.5)).

Podemos concluir que o método Autocorrelação é o mais adequado, pois a hipótese de amostras nulas fora do intervalo de observação é coerente com o fato de que os parâmetros $a[k]$ do modelo AR longo deverão ser nulos para $n < 0$ e $n > L$. Além destes fatos, é interessante mencionar que o método Autocorrelação fornece a estimativa de máxima verossimilhança dos parâmetros do modelo MA a partir dos parâmetros do modelo AR longo, [2].

O método Covariância Modificado também não é adequado para a solução da equação (5.3), pois os erros de predição regressiva não são semelhantes aos desta equação.

Por fim, a estimativa da variância P_w do ruído branco que compõe a entrada do modelo MA desejado, é obtida quando da estimativa dos parâmetros do modelo AR(L).

Em resumo, o algoritmo de Durbin pode ser decomposto nos seguintes passos:

- Passo 1: Dado um conjunto finito de amostras do processo $x[n]$, estimar os parâmetros do modelo AR(L) e a variância do ruído branco, através de um dos métodos de estimação dos parâmetros AR.

- Passo 2: Com os dados $\{1, a[1], \dots, a[L]\}$, estimar os parâmetros do modelo MA(q) através do método Autocorrelação.

Dado que o método Autocorrelação sempre fornece estimativas de fase mínima, a seqüência de parâmetros MA estimada pelo método de Durbin será também de fase mínima mesmo que a função de sistema do modelo AR longo não apresente esta característica.

Para a seleção da ordem q do modelo MA podemos utilizar o critério CIA, o qual apresenta as mesmas características da seleção da ordem do modelo AR.

Entretanto, para processos MA este critério frequentemente determina uma ordem muito pequena, [1]. Uma forma de testar se a ordem selecionada é correta, consiste em verificar se a seqüência residual do filtro MA inverso é um processo branco.

Um outro esquema para estimar a ordem do modelo MA foi proposto no texto de referência [15]. Sabe-se que a seqüência de autocorrelação, $r_{xx}[m]$, de um processo MA(q) é nula para $|m| > q$. Esta proposta consiste em procurar o valor mínimo de m a partir do qual as estimativas de autocorrelação do processo $x[n]$ tornam-se desprezíveis. Este valor mínimo é adotado como a estimativa de q.

5.3 Método de Durbin: Análise Qualitativa

O objetivo aqui é realizar uma análise qualitativa do desempenho do método de Durbin em relação a vários parâmetros. Para tal, supomos que o processo $x[n]$ sob análise foi gerado por um modelo MA de ordem q e que conhecemos apenas N amostras do mesmo. Esta hipótese é interessante pois garante que a utilização de um

modelo MA(q) para a análise do processo é a melhor opção. Com isto conseguimos separar fatores de influência e eliminar os efeitos que resultam quando não se adota o modelo mais adequado para a análise de um dado sinal. Poderemos então avaliar de forma isolada a influência de fatores como a posição dos zeros do filtro gerador do sinal, número de amostras disponíveis e método de estimação do modelo AR longo.

Dado que o primeiro passo do método de Durbin é estimar os parâmetros de um modelo AR longo, vamos considerar inicialmente a questão da seleção de um método para tal estimativa.

Nas referências [1] e [2], utiliza-se apenas o método Autocorrelação. Também, não temos conhecimento de nenhum trabalho que aborde o uso de outros métodos. Entretanto, foi mencionado no capítulo 4 que os métodos Covariância e Covariância Modificado permitem atingir estimativas AR de melhor qualidade, principalmente quando o número de amostras disponíveis para análise é relativamente pequeno e o espectro do processo apresenta picos agudos. E podemos imaginar que a qualidade da estimativa do modelo AR longo é bastante importante para a qualidade da estimativa MA final. Isto nos motiva a iniciar aqui uma análise comparativa sobre a aplicação destes três métodos.

No método Autocorrelação é utilizado o estimador polarizado de correlação, o qual, como foi mostrado no capítulo 2, fornece estimativas cuja variância não cresce em demasia à medida que o índice destas se aproxima do número de amostras. Este fato, aliado à positividade da matriz de correlações associada, permite escolher ordens auto-regressivas próximas do número de amostras e ainda obter estimativas espectrais relativamente estáveis estatisticamente.

Por outro lado, as matrizes de correlações associadas aos métodos Covariância e Covariância Modificado se tornam singular quando a ordem auto-regressiva L é grande em relação ao número N de amostras. O valor de L deve ser menor ou igual a $N/2$ no método Covariância, e menor ou igual a $2N/3$ no Covariância Modificado. Logo, tais métodos impõem restrições mais severas para a escolha da ordem L .

Porém, se as restrições acima favorecem o método Autocorrela-

cão, os métodos Covariância e Covariância Modificado produzem estimativas de melhor qualidade. Assim, torna-se necessário um estudo mais detalhado que permita identificar qual o fator predominante para a qualidade final da estimativa MA.

Consideremos agora a localização dos zeros do processo MA sob o qual realizaremos a análise espectral. Quando estes zeros se encontram próximos à CRU, o espectro de potência apresenta vales abruptos e o comprimento efetivo da resposta impulsiva associada a $1/B(z)$ é elevado. Isto significa que a ordem do modelo AR longo também deverá ser elevada. A possibilidade de utilizarmos uma ordem AR elevada e ainda respeitar os limites de singularidade e estabilidade dos métodos de estimação auto-regressiva, dependerá principalmente do número de amostras disponível. Se este for pequeno é provável que não possamos escolher uma ordem AR adequada.

No caso em que os zeros do processo MA se encontram afastados da CRU, a ordem do modelo AR pode ser menor que na situação anterior. Com isto fica mais fácil conseguirmos uma ordem auto-regressiva adequada. Como o espectro de potência deste tipo de processo é caracterizado por formas suaves, sem vales abruptos, é de se esperar que os três métodos da predição linear sejam capazes de fornecer boas estimativas espetrais.

Esta análise revela a necessidade da realização de simulações para observação do desempenho em função dos parâmetros discutidos.

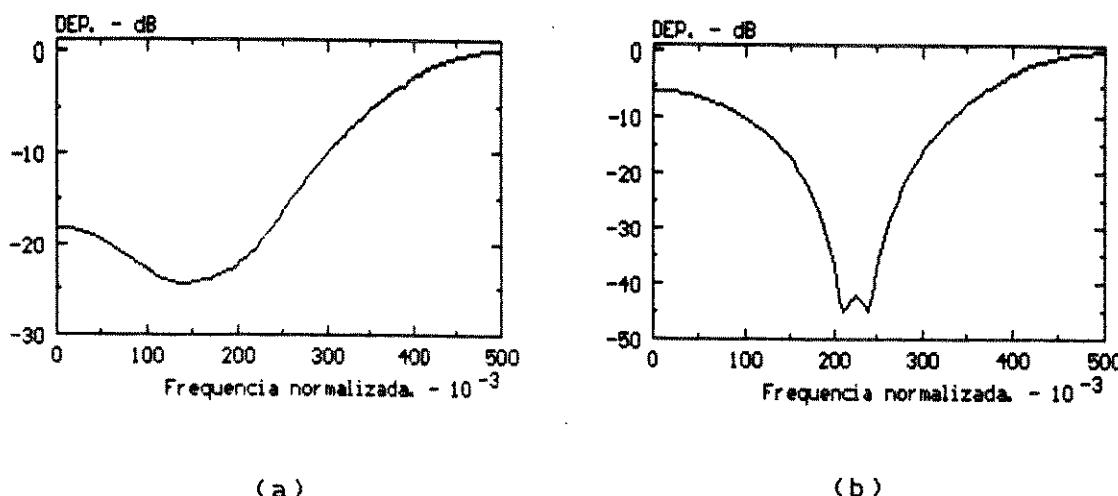
5.4 Método de Durbin: Análise Quantitativa

Avaliaremos aqui o desempenho do método de Durbin nas estimativas espetrais de dois processos MA(4). Os parâmetros e o espectro de potência teórico de cada processo são mostrados na Tabela 5.1 e na figura 5.1, respectivamente. O processo MA_0 foi tomado da referência [2], e o MA_1 foi escolhido da forma a termos um processo com vales abruptos no espectro da potência.

Para cada processo foram geradas trinta seqüências com 256 amostras cada uma, através de uma rotina de geração de dados. De posse destas seqüências efetuamos dois conjuntos de simulações: um com as 256 amostras, o outro com 64 amostras.

Processo	Zeros	Parâmetros				
		b[1]	b[2]	b[3]	b[4]	Pv
MA ₀	0.7 exp[±j2π(0.21)] 0.7 exp[±j2π(0.12)]	-1.352	1.338	-0.662	0.240	1
MA ₁	0.96 exp[±j2π(0.24)] 0.96 exp[±j2π(0.21)]	-0.598	1.900	-0.551	0.849	1

Tabela 5.1 Processos MA Utilizados nas Simulações

Figura 5.1 Espectro de Potência dos processos: (a) MA₀, (b) MA₁

A ordem do modelo AR longo foi selecionada segundo os seguintes critérios:

L = N/5, conforme sugestão presente em [2].

L = N/3, valor para o qual o método Covariância Modificado apresenta melhor desempenho para a detecção de senóides em ruído branco.

L = N/2, limite de singularidade no método Covariância.

L = 2N/3, limite de singularidade no método Covariância Modificado.

A ordem do modelo MA a ser estimado, foi fixada em q=4, ou seja, a mesma do processo a ser analisado.

As estimativas espectrais pelo método de Durbin (estimativas Durbin), e as fornecidas pelo modelo AR longo (estimativas AR),

são apresentadas da seguinte forma:

- a média das estimativas e o espectro de potência teórico (curva pontilhada) são apresentadas simultaneamente de modo a permitir a visualização da polarização dos estimadores;

- as estimativas isoladas estão traçadas de forma sobreposta de modo a explicitar a variação das mesmas.

Consideremos inicialmente o processo MA_6 . Dado que o espectro de potência não apresenta vales abruptos, não é necessário que a ordem do modelo AR longo seja muito grande. De fato, o módulo dos zeros é 0.7 e para a menor ordem utilizada, $L=12$ ($L=N/5$ para $N=64$ amostras), temos $0.7^{12}=0.014$ (equação (5.2)). Portanto, podemos considerar que as amplitudes da resposta impulsiva de $1/B(z)$ serão pequenas a partir de $n=12$, o que garante boas aproximações do processo MA_6 para todos os valores de L considerados.

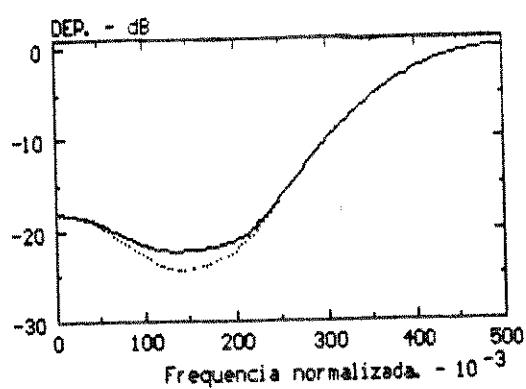
Passemos às simulações. Para o conjunto das trinta seqüências com $N=64$, referente ao processo MA_6 , utilizamos as seguintes ordens para o modelo AR longo: $L=12$ ($N/5$), $L=21$ ($N/3$), $L=32$ ($N/2$) e $L=42$ ($2N/3$). Os resultados obtidos foram:

Para $L=12$, Figuras 5.2 e 5.3

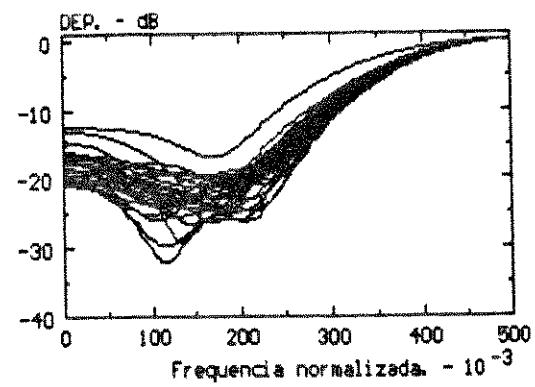
As estimativas Durbin apresentaram boa qualidade e foram semelhantes entre si, tanto na média como na variação. As estimativas espectrais AR no gráfico das estimativas se afastam do espectro de potência do processo MA_6 , uma vez que elas, em geral, apresentam as formas agudas típicas produzidas pelos pólos do modelo AR. Entretanto, tais variações são bastante atenuadas ao realizarmos a conversão do modelo AR para MA. Este comentário deve ser levado em conta sempre que observemos uma estimativa espectral AR de um processo MA.

Para $L=21$, Figuras 5.4 e 5.5

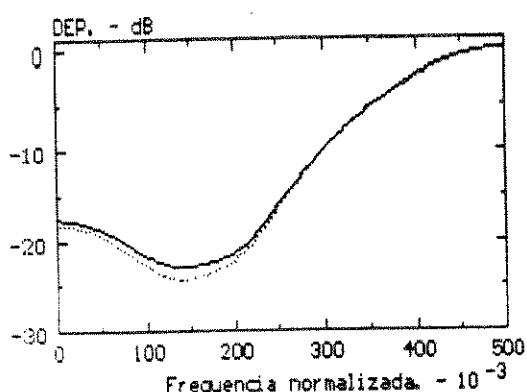
Os resultados para os três métodos da predição linear apresentaram diferenças significativas entre si. Os de melhor qualidade foram aqueles obtidos com método Autocorrelação. Suas estimativas Durbin são semelhantes àquelas do caso $L=12$; razão pela qual seus gráficos foram omitidos, visando economia de espaço. As estimativas com os métodos Covariância e Covariância Modificado foram inferiores àquelas para $L=12$. Entre os dois métodos o Covariância Modificado foi melhor.



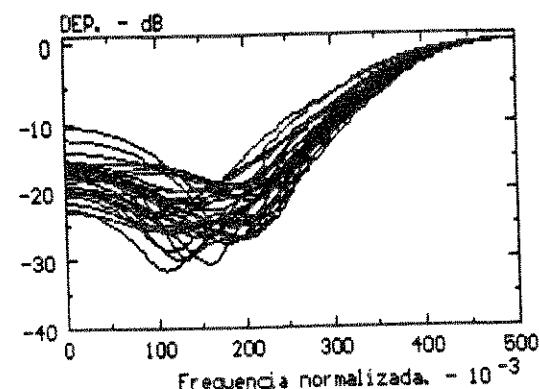
(a) média



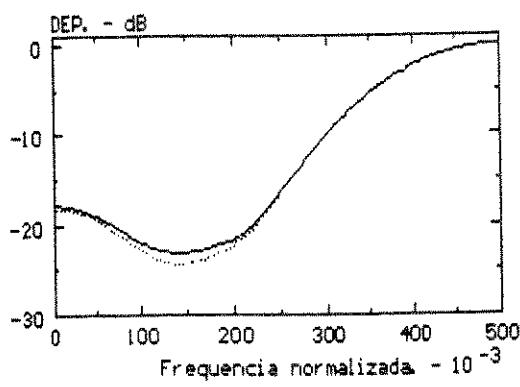
(a) estimativas



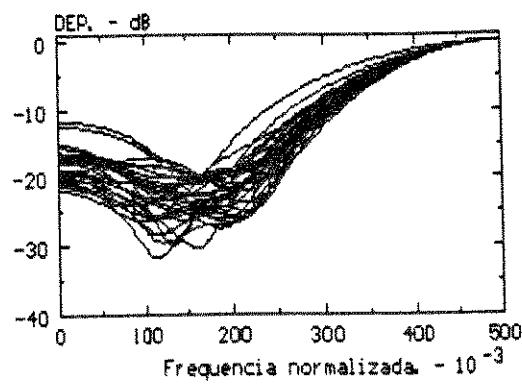
(b) média



(b) estimativas

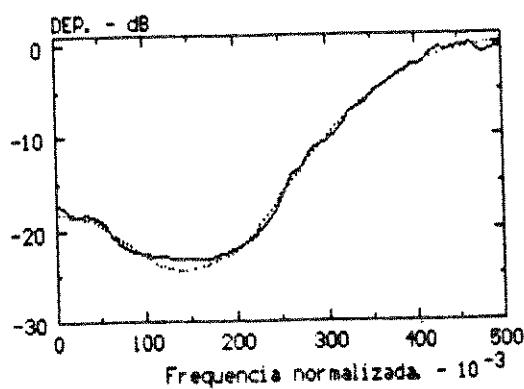


(c) média

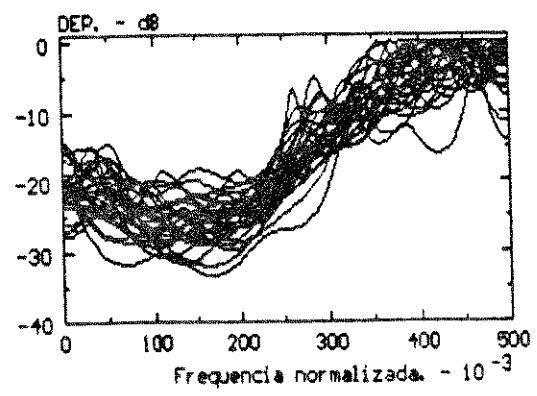


(c) estimativas

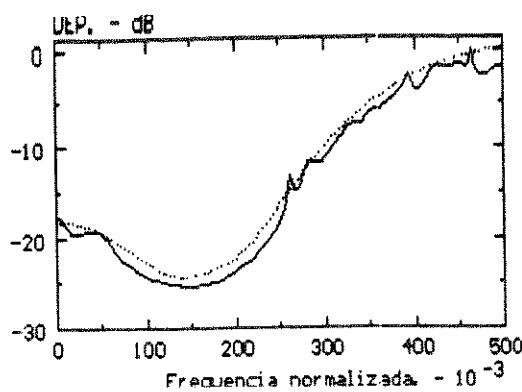
Figura 5.2 Estimativas Durbin, Processo MA_6 , N=64, Modelo AR**Longo de Ordem 12:****(a) Método Autocorrelação,****(b) Método Covariância,****(c) Método Covariância Modificado.**



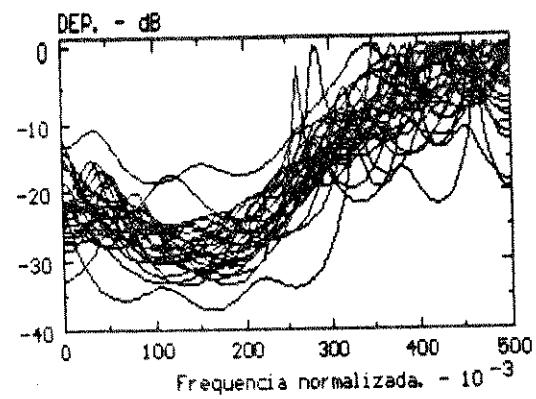
(a) média



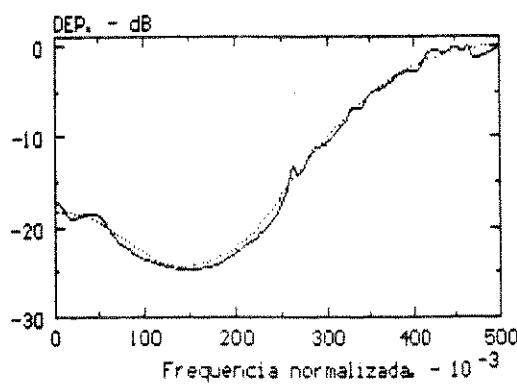
(a) estimativas



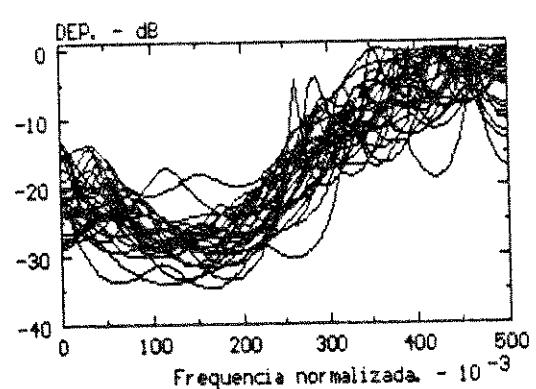
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 5.3 Estimativas AR de Ordem 12, Processo MA₁₂, N=64,
(a) Método Autocorrelação,
(b) Método Covariância,
(c) Método Covariância Modificado.

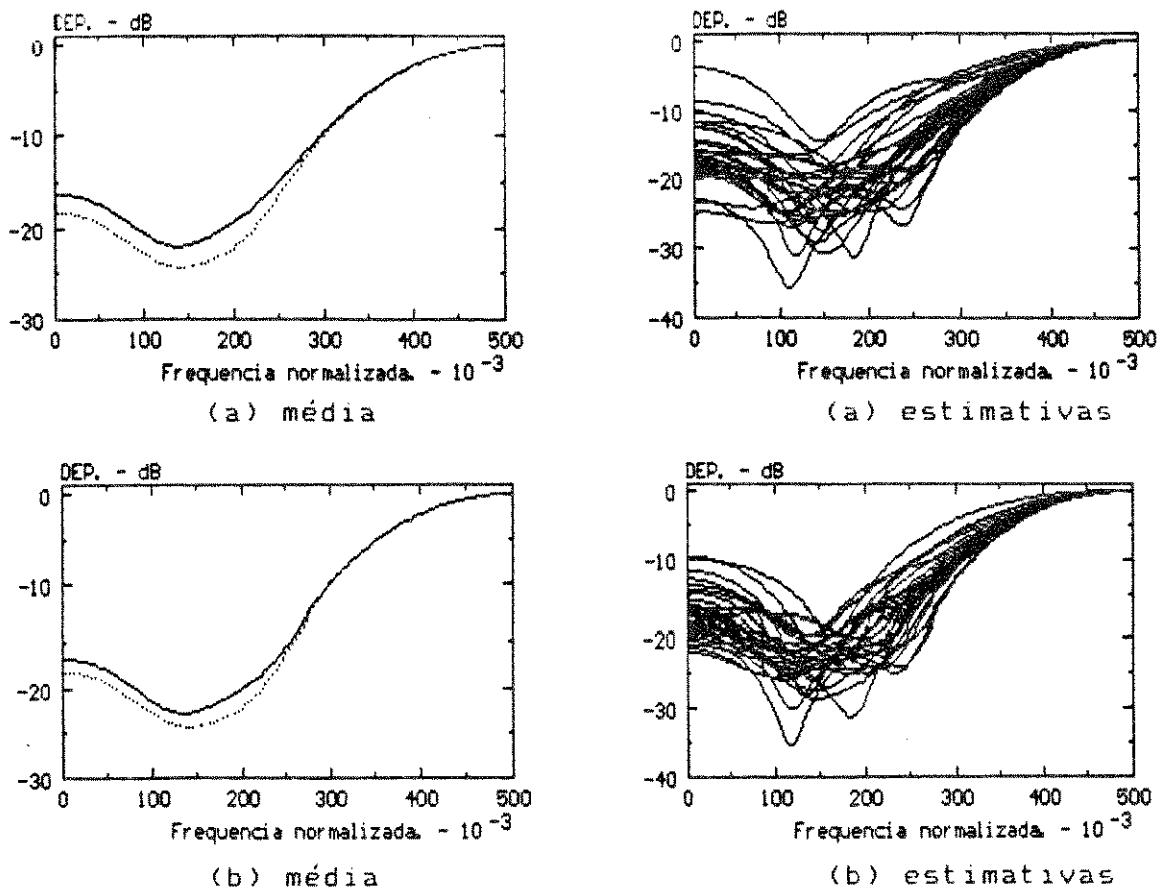
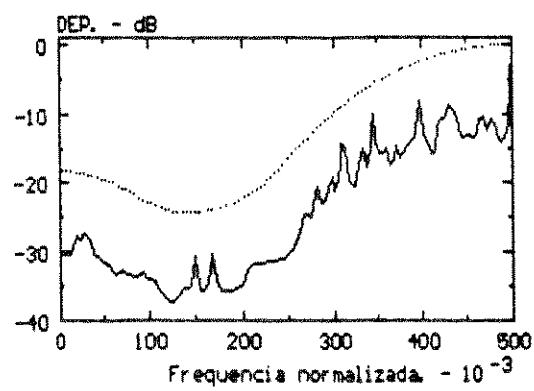


Figura 5.4 Estimativas Durbin, Processo MA_6 , $N=64$, Modelo AR Longo de Ordem 21: (a) Método Covariância, (b) Método Covariância Modificado.

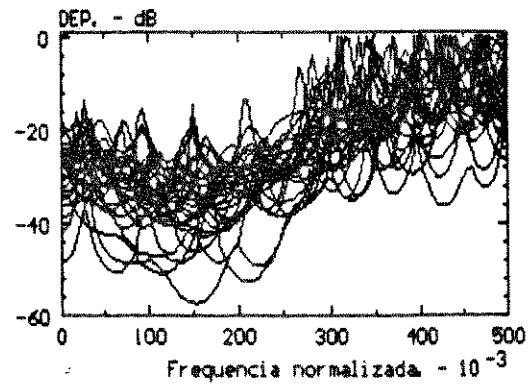
Nos gráficos de média das estimativas AR aparece uma diferença entre as curvas de aproximadamente 10 dB para a Covariância e de 5 dB para a Covariância Modificado. Tal diferença é consequência da normalização efetuada para o traçado das estimativas (valor máximo igual a 0 dB), e não do estimador em si.

Para $L=32$, Figuras 5.6 e 5.7

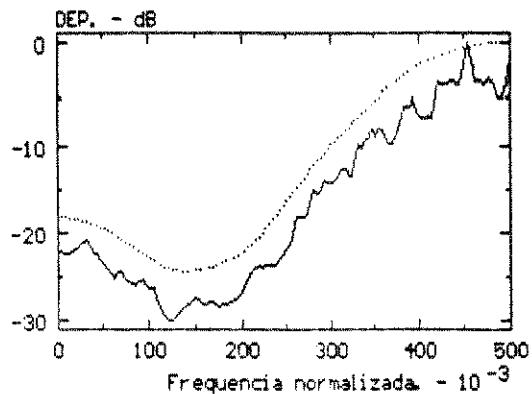
As diferenças neste caso se tornaram mais significativas. A matriz de correlações associada ao método Covariância se tornou singular para todas as seqüências de amostras (observe que esta ordem é o limite de singularidade do método), o que inviabilizou seu uso neste caso. Novamente, os resultados do método Autocorrelação foram os melhores, e ainda semelhantes aos de $L=12$. As estimativas com o método Covariância Modificado foram inferiores às anteriores.



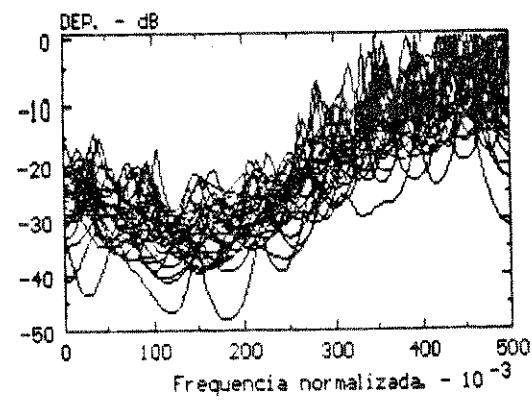
(a) média



(a) estimativas



(b) média

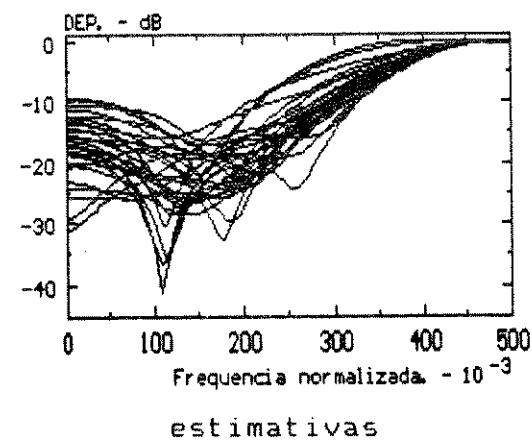
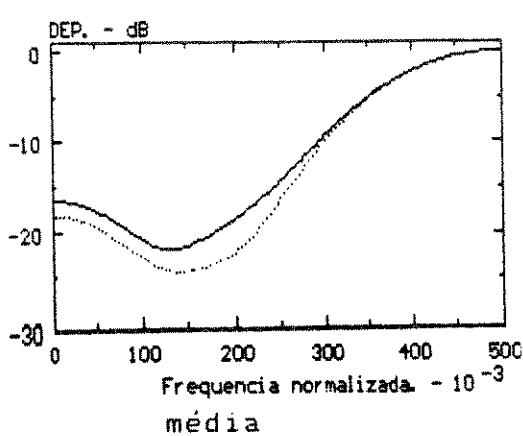


(b) estimativas

Figura 5.5 Estimativas AR de Ordem 21, Processo MA_{α} , N=64,

(a) Método Covariância,

(b) Método Covariância Modificado.

**Figura 5.6. Estimativas Durbin, Processo MA_{α} , N=64, Modelo AR Longo de Ordem 32, Método Covariância Modificado.**

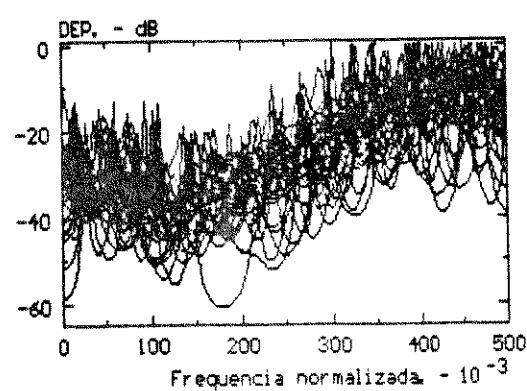
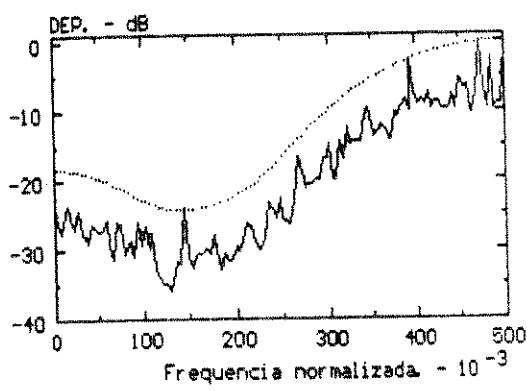


Figura 5.7 Estimativas AR de Ordem 32, Processo MA_e , N=64, Método Covariância Modificado.

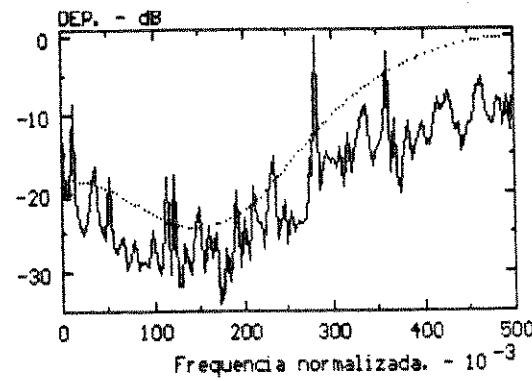
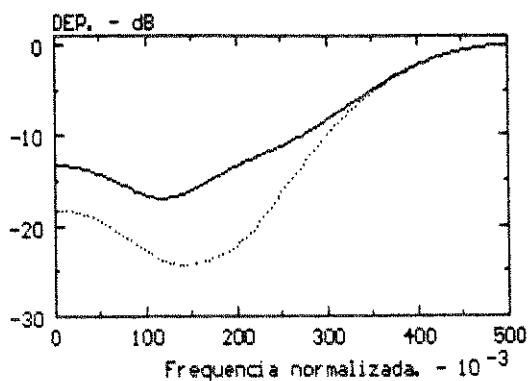
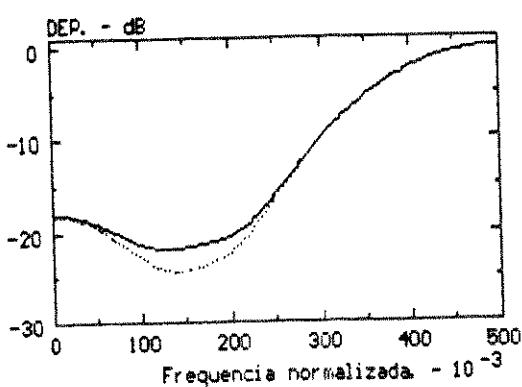


Figura 5.8 Médias das Estimativas Durbin (a) e AR de Ordem 42 (b), Processo MA_e , N=64, Método Covariância Modificado.

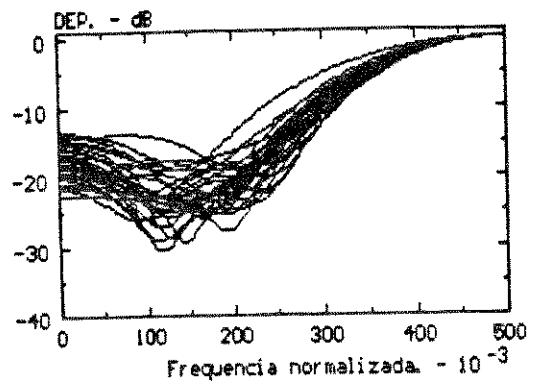
Para L=42, Figuras 5.8 e 5.9

A qualidade das estimativas AR e Durbin foi ruim com o método Covariância Modificado, como podemos inferir dos gráficos da média na figura 5.8. Por outro lado, as estimativas Durbin com o método Autocorrelação, figura 5.9a, ainda foram semelhantes às das ordens anteriores, enquanto que nas estimativas AR somente ficou mais evidente o aumento do número de pólos.

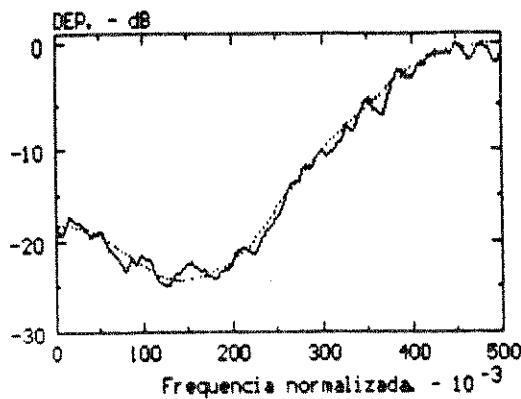
Podemos explicar os resultados obtidos através da discussão da seção anterior.



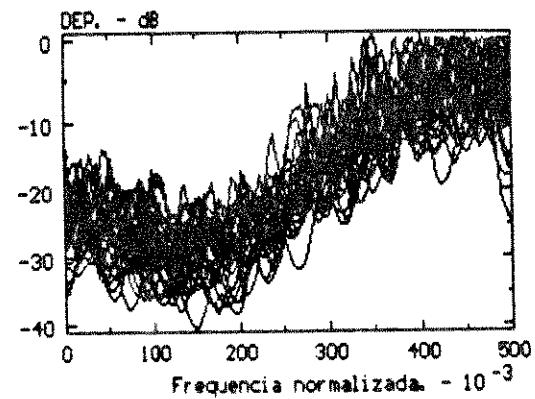
(a) média



(a) estimativas



(b) média



(b) estimativas

Figura 5.9 Estimativas Durbin (a) e AR de Ordem 42 (b), Processo MA_e , N=64, Método Autocorrelação.

A boa qualidade das estimativas AR produzidas pelos três métodos para $L=12$, se deve ao fato que tal ordem foi suficiente para obtermos uma boa aproximação do processo MA_e . Valores inferiores de L tendem a degradar a aproximação deste processo, enquanto que a elevação da ordem L tende a produzir estimativas com os picos agudos, típicos da modelagem AR com ordem elevada, particularmente nos casos dos métodos Covariância e Covariância Modificado.

As estimativas espectrais Durbin não se degradaram com o aumento da ordem do modelo AR longo quando utilizamos o método Autocorrelação, pois este método fornece estimativas relativamente estáveis quando a ordem do modelo se aproxima do número de amostras.

Já a degradação observada quando do uso dos métodos Covariância e Covariância Modificado para $L=21$ e para $L=32$ se deve em par-

te ao fato da característica de alta resolução destes métodos se evidenciar com o aumento da ordem auto-regressiva. Logo, os pólos se tornam mais agudos e a variação das estimativas AR aumenta, como podemos conferir nos gráficos correspondentes. Nestes, a faixa de excursão de cada um é maior (pólos mais agudos), que no gráfico da estimativas AR do método Autocorrelação para $L=42$, figura 5.9.

Um segundo fator a provocar a degradação acima é o grau crescente de instabilidade estatística nos métodos Covariância e Covariância Modificado, à medida que L cresce. Isto porque vai-se convergindo para o limite onde a matriz de correlação associada a cada um se torna singular. Este efeito está evidente na figura 5.8b. Tal instabilidade seria observada também, se a matriz de correlações não tivesse se tornado singular quando do método Covariância para $L=32$.

Passemos agora às simulações sobre as seqüências com $N=256$. Em função dos resultados anteriores, a ordem do modelo AR longo foi fixada em $L=51$ ($N/5$).

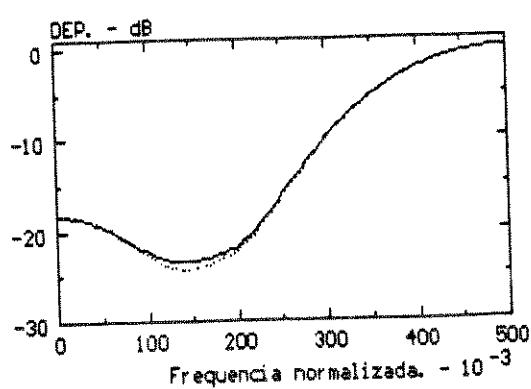
As estimativas Durbin e AR são apresentadas nas figuras 5.10 e 5.11, respectivamente.

Observamos que tal como no caso de $N=64$ e $L=12$, as estimativas Durbin e AR foram boas tanto em termos de média como de variação. Também, a qualidade das estimativas neste caso é superior àquelas correspondentes para $N=64$, como consequência do aumento do número de amostras disponíveis.

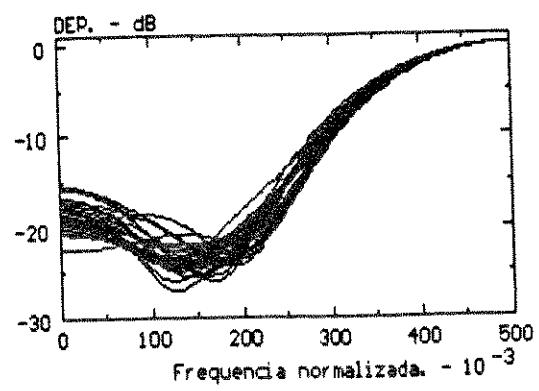
As simulações para valores superiores de L não são apresentadas aqui pois sofrem dos mesmos problemas analisados anteriormente para $N=64$. Além disto, esta elevação de ordem acarreta um aumento do esforço computacional.

Concluímos assim que uma ordem para o modelo AR longo de cerca de 20% do número de amostras é adequada para este tipo de processo.

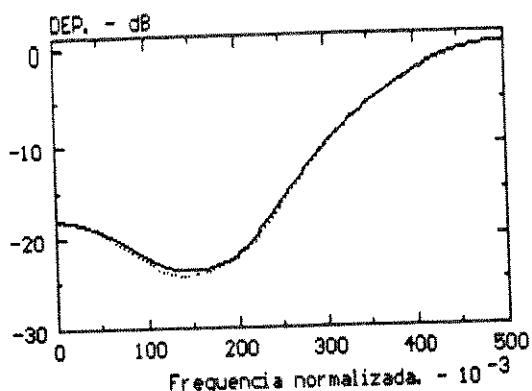
Consideremos agora o segundo processo, MA_1 , utilizado nas simulações. Seu espectro de potência apresenta vales abruptos, já que os zeros se encontram perto da CRU (módulo igual a 0.96). Isto significa que as amplitudes da resposta impulsiva de $1/B(z)$ decaem mais lentamente que no caso do processo MA_∞ . Portanto, é necessário que a ordem do modelo AR longo seja maior.



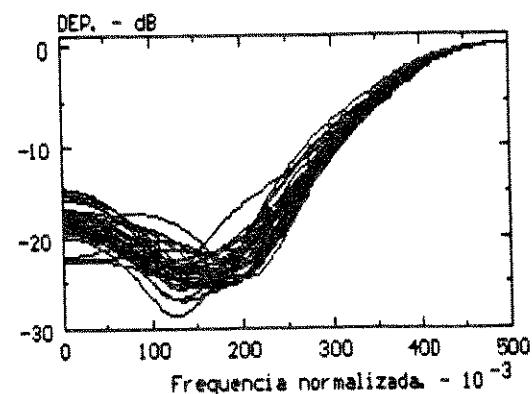
(a) média



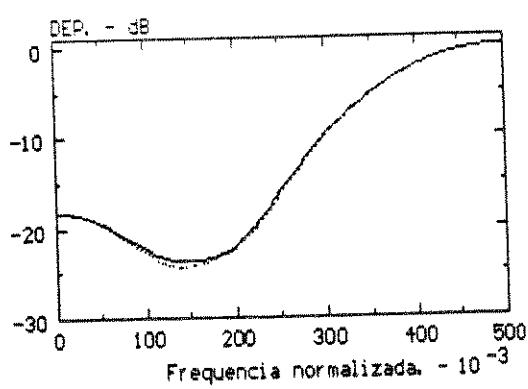
(a) estimativas



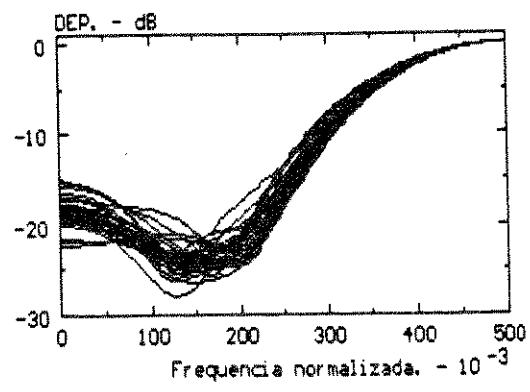
(b) média



(b) estimativas



(c) média



(c) estimativas

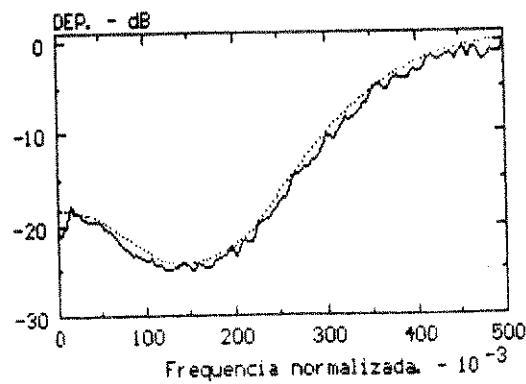
Figura 5.10 Estimativas Durbin, Processo MA_5 , N=256, Modelo AR

Longo de Ordem 51:

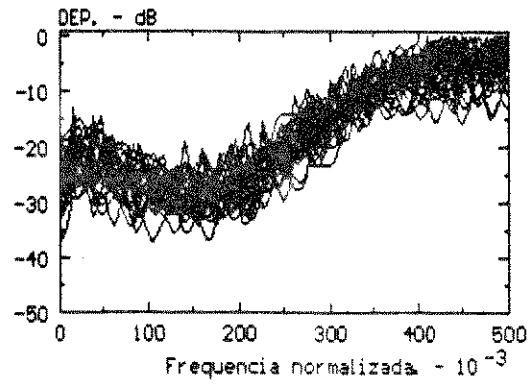
(a) Método Autocorrelação,

(b) Método Covariância,

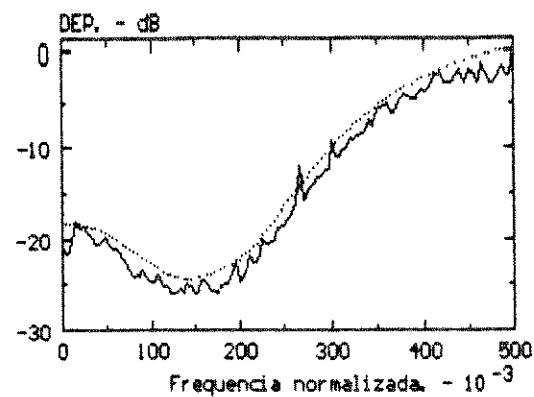
(c) Método Covariância Modificado.



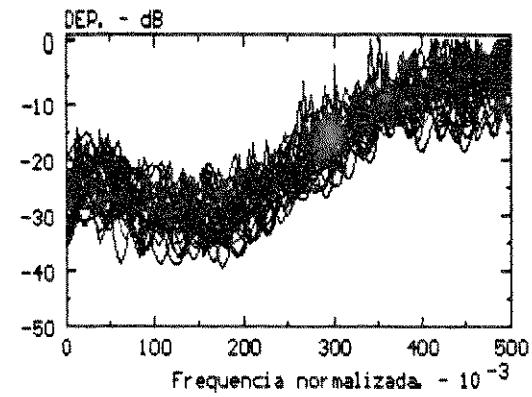
(a) média



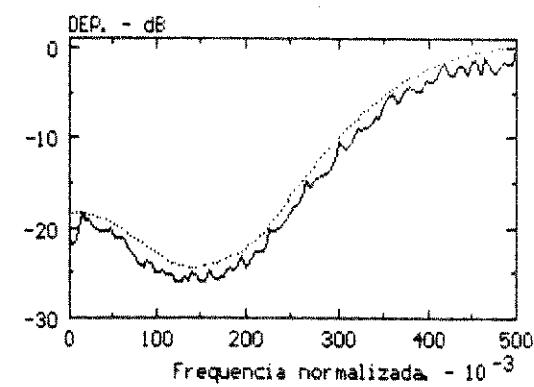
(a) estimativas



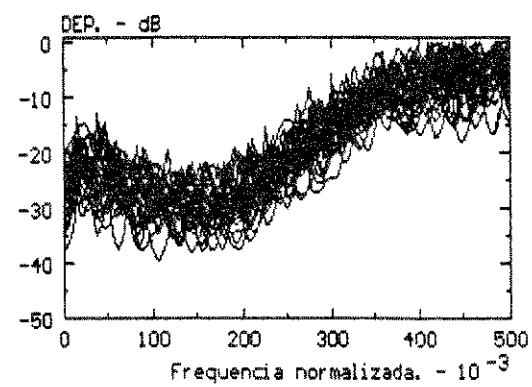
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 5.11 Estimativas AR de Ordem 52, Processo MA_{θ} , N=256,

- (a) Método Autocorrelação,
- (b) Método Covariância,
- (c) Método Covariância Modificado.

Tomando inicialmente as simulações sobre as sequências com 64 amostras e as ordens 12 ($N/5$) e 21 ($N/3$), observamos que $0.96^{24} = 0.424$. Assim, da equação (5.2), temos que ambas ordens são insuficientes para fornecer boas aproximações do processo MA_1 , e, portanto, podemos prever estimativas espectrais ruins. Os resultados obtidos foram:

Para $L=12$

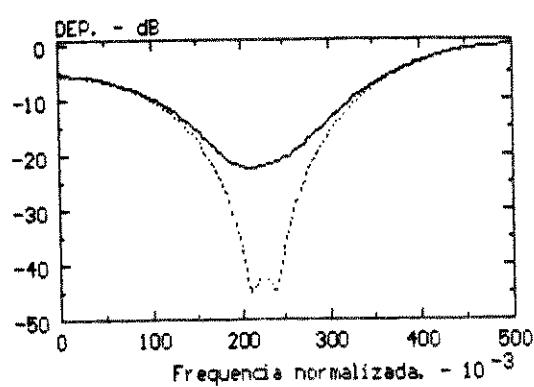
As estimativas Durbin e AR não foram boas. A polarização e a variação se mostraram excessivas na vizinhança dos vales abruptos. O desempenho do método Autocorrelação foi o pior, enquanto que as duas outras estimativas foram semelhantes entre si.

Para $L=21$, Figura 5.12 e 5.13

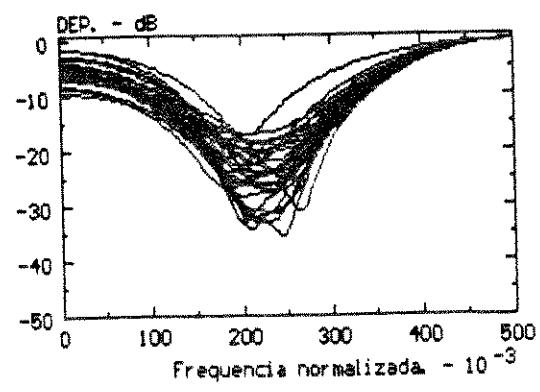
Os resultados com o método Autocorrelação foram tão ruins quantos os da ordem anterior. O desempenho dos métodos Covariância e Covariância Modificado foi superior àquele obtido com $L=12$ e ainda semelhantes entre si. Suas estimativas porém, não mostram a mesma qualidade observada quando do processo sem vales abruptos e $L=12$.

Observando os gráficos das estimativas AR, figura 5.13, notamos que nas vizinhanças das freqüências dos zeros do processo MA_1 não há picos espectrais (pólos). Isto ocorre pois a depressão que corresponde aos vales das estimativas Durbin é produzida de forma indireta, ou seja, pela ausência de pólos. Por outro lado, a reprodução da curva nas regiões de maior energia se dá pela concentração de pólos. Portanto, podemos afirmar, sob esta ótica, que o aumento da ordem AR e o uso de estimadores de alta resolução criam condições favoráveis para uma melhor aproximação. Daí o aumento da qualidade das estimativas quando passamos de $L=12$ para $L=21$ e a supremacia dos métodos Covariância e Covariância Modificado.

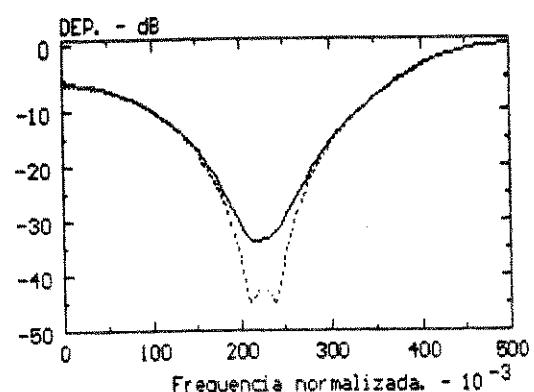
Ordens maiores que $L=21$ não são adequadas com 64 amostras. Mesmo assim testamos $L=42$ ($2N/3$) e os métodos Autocorrelação e Covariância Modificado. Os resultados do primeiro não foram diferentes dos obtidos para $L=21$, e os do segundo mostraram a mesma instabilidade estatística observada na figura 5.8. Concluimos que 64 amostras é um número muito pequeno para este tipo de processo, não permitindo atingir estimativas melhores que aquelas das figuras 5.12b e 5.12c.



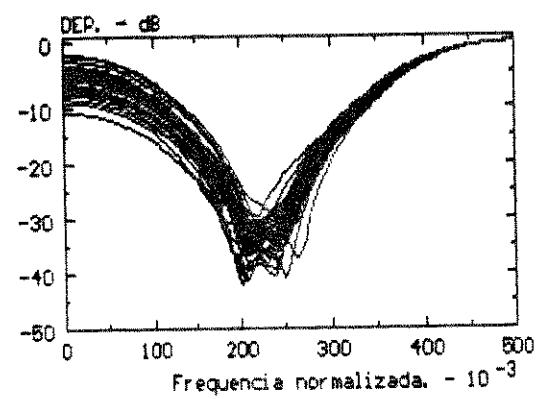
(a) média



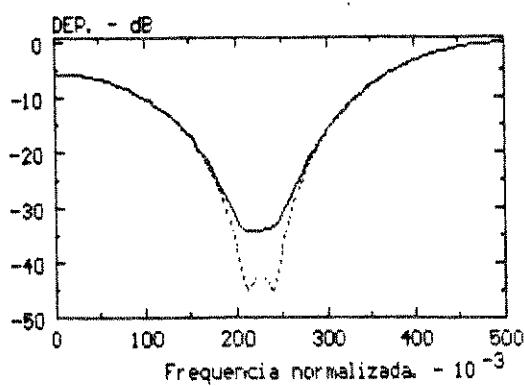
(a) estimativas



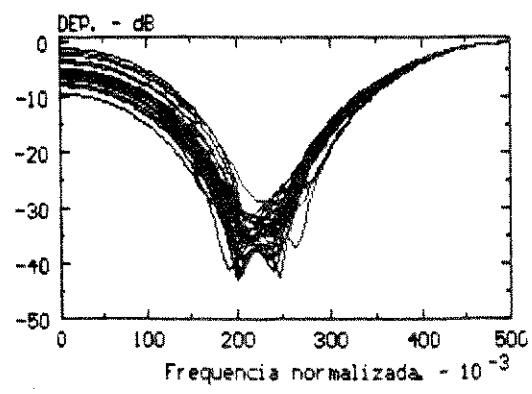
(b) média



(b) estimativas



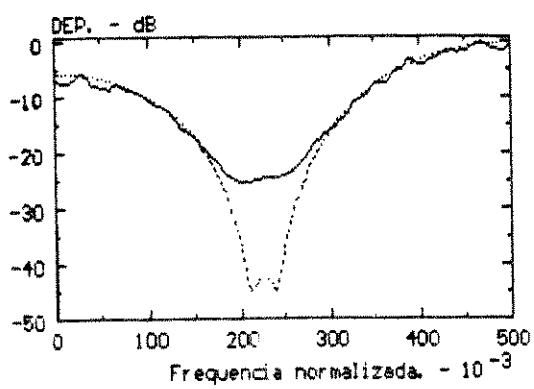
(c) média



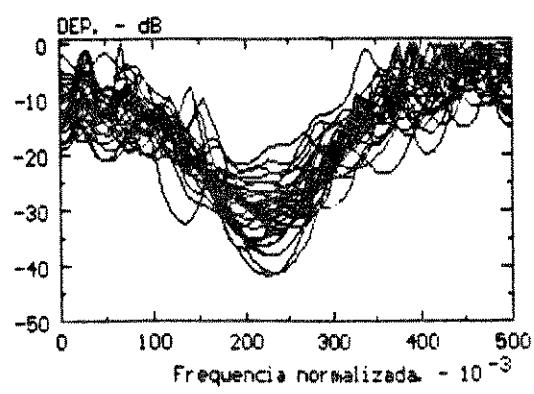
(c) estimativas

Figura 5.12 Estimativas Durbin, Processo MA_1 , N=64, Modelo AR longo de Ordem 21:

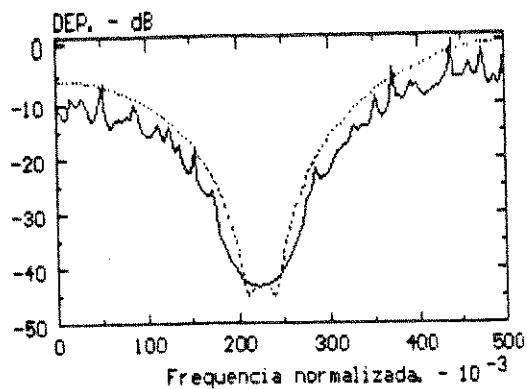
(a) Método Autocorrelação,
 (b) Método Covariância,
 (c) Método Covariância Modificado.



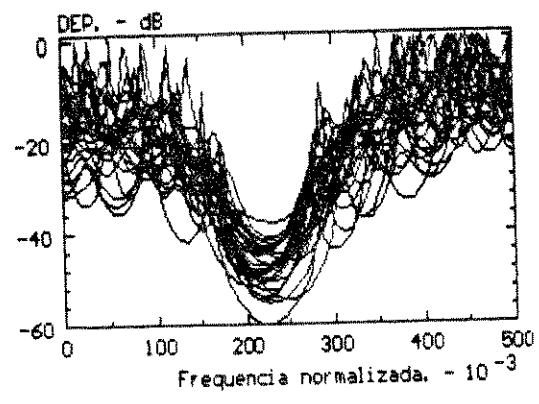
(a) média



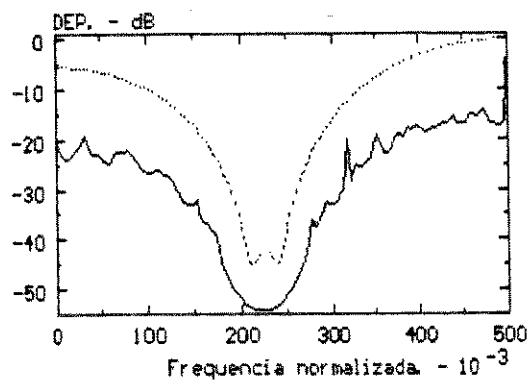
(a) estimativas



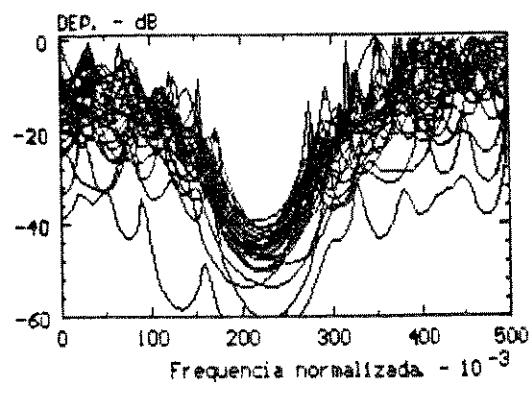
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 5.13 Estimativas AR de Ordem 21, Processo MA_1 , N=64

(a) Método da Autocorrelação,

(b) Método da Covariância,

(c) Método da Covariância Modificado.

Ordens maiores para o modelo AR longo foram utilizadas com as seqüências de 256 amostras. $L=85$ ($N/3$) e $L=125$ ($N/2$) permitem melhores aproximações do processo MA_1 , pois $0.96^{85} = 0.031$.

Os resultados obtidos foram:

Para $L=85$, Figuras 5.14 e 5.15

Os métodos Covariância e Covariância Modificado forneceram boas estimativas espectrais, enquanto que o desempenho do método Autocorrelação foi, novamente, inferior.

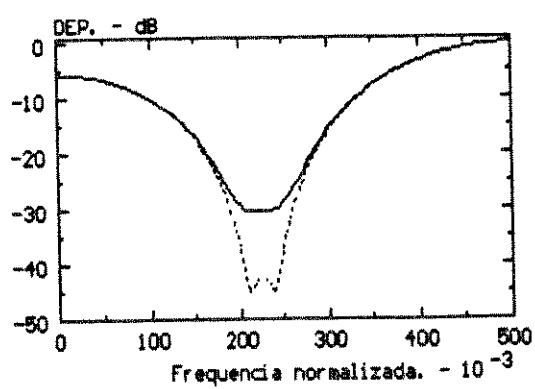
Para $L=125$, Figura 5.16

As estimativas com o método Covariância Modificado foram inferiores às obtidas com a ordem anterior, o que pode ser explicado lembrando que 125 ($N/2$) não é o valor onde este método atinge seu melhor desempenho.

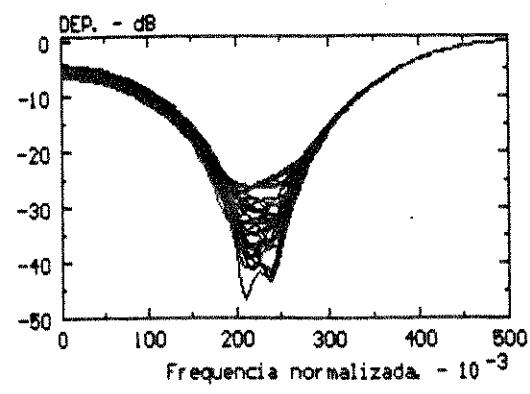
O melhor desempenho dos métodos Covariância e Covariância Modificado para este processo decorre da característica de estimadores de alta resolução, como foi comentado anteriormente. Por outro lado, podemos observar que os vales abruptos nas estimativas AR estão melhor definidos que no caso de 64 amostras. Isto é consequência do aumento da ordem do modelo AR e do número de amostras. O aumento da ordem permitiu até a alocação de pólos no centro do vale espectral, como pode ser observado nas figuras 5.15b e 5.15c.

Concluimos então que para processos com vales abruptos no espetro de potência, o método de Durbin com os métodos Covariância e Covariância Modificado fornece estimativas espectrais de boa qualidade e estabilidade estatística, quando um terço do número de amostras é utilizado como ordem do modelo AR e este número é grande o suficiente.

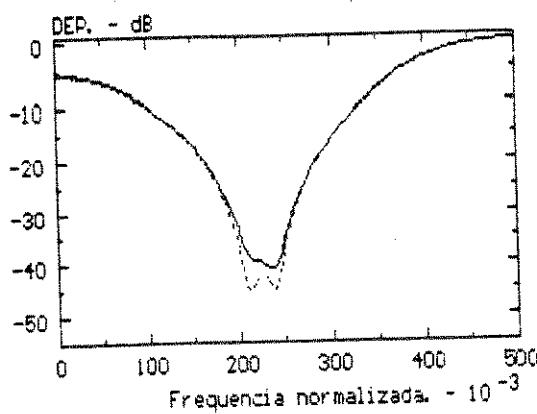
Por outro lado, para processos sem vales abruptos, o método de Durbin fornece boas estimativas quando utilizamos um quinto do número de amostras como ordem do modelo AR longo e qualquer dos três métodos da predição linear para estimá-lo. Também, a qualidade das estimativas apresenta menor sensibilidade em relação ao número de amostras, quando comparado com os processos com vales abruptos.



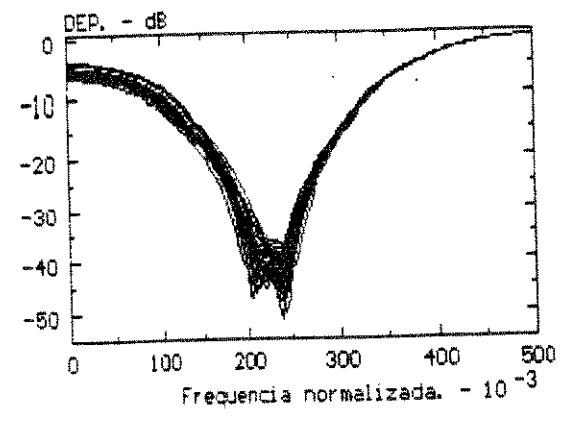
(a) média



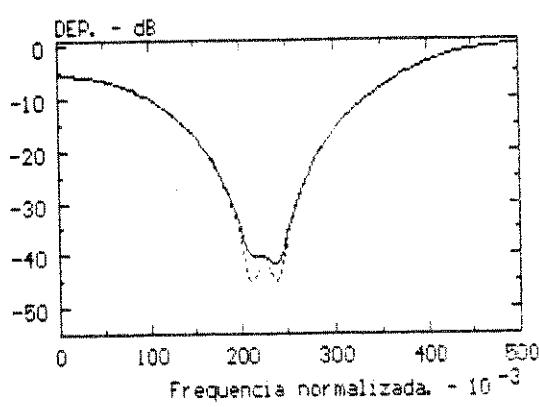
(a) estimativas



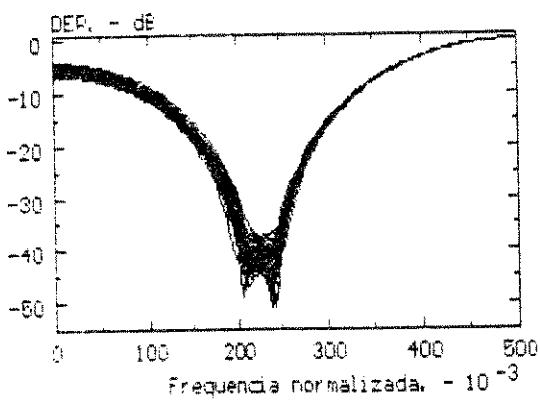
(b) média



(b) estimativas

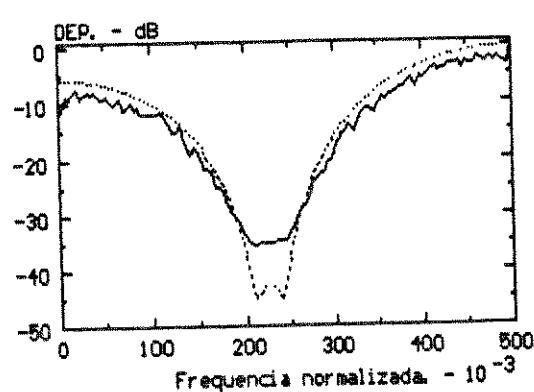


(c) média

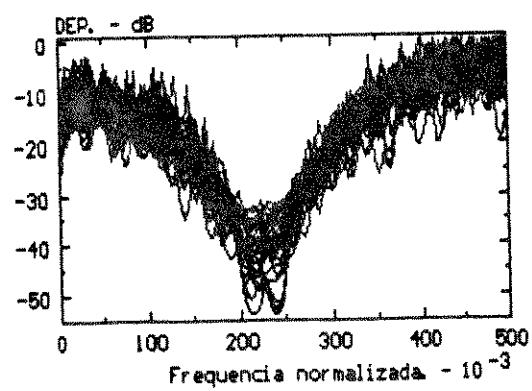


(c) estimativas

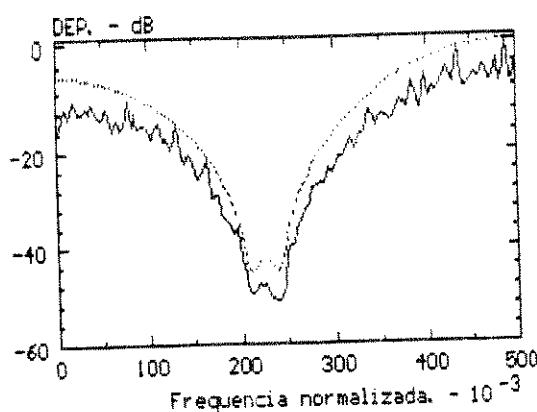
Figura 5.14 Estimativas Durbin, Processo MA₁, N=256, Modelo AR**Longo de Ordem 85:****(a) Método da Autocorrelação,****(b) Método da Covariância,****(c) Método da Covariância Modificado.**



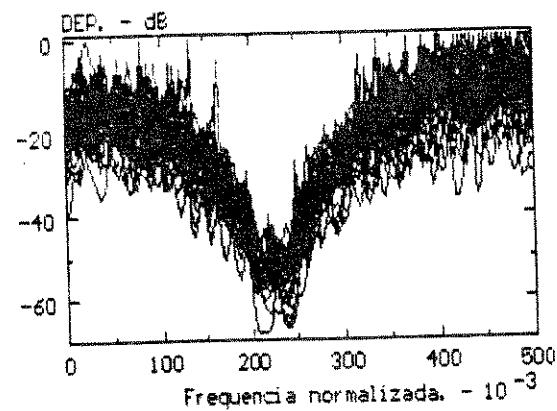
(a) média



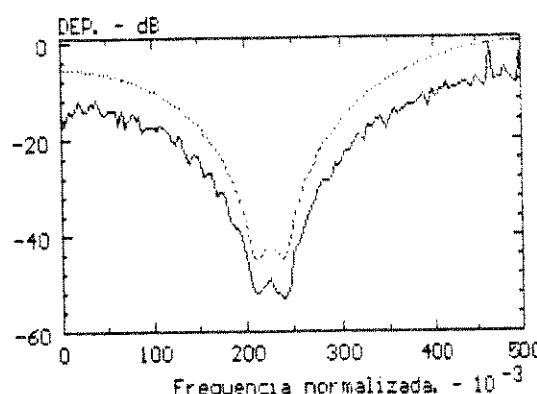
(a) estimativas



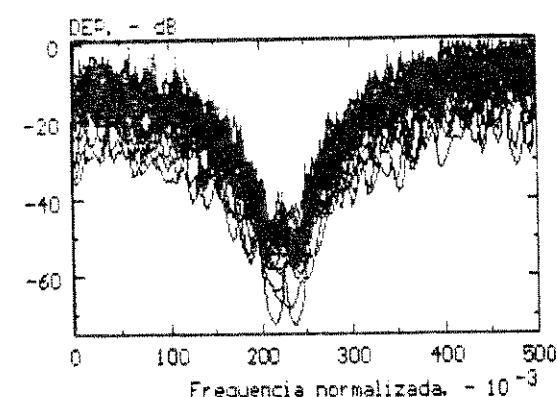
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 5.15 Estimativas AR de Ordem 85, Processo MA₁, N=256:

(a) Método da Autocorrelação,

(b) Método da Covariância,

(c) Método da Covariância Modificado.

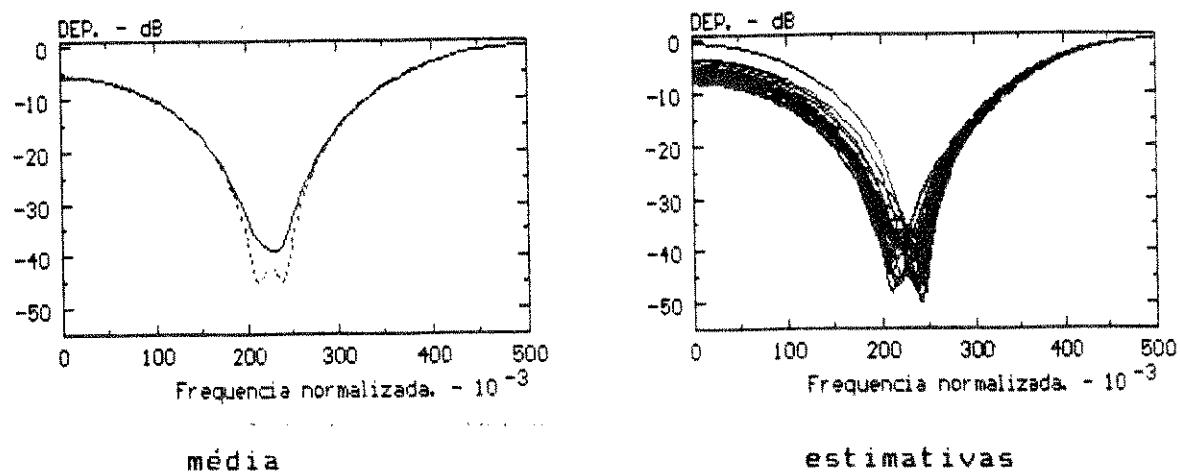


Figura 5.16. Estimativas Durbin, Processo MA₁, N=256, Modelo AR Longo de Ordem 125, Método Covariância Modificado.

Embora os três métodos utilizados para estimar o modelo AR longo tenham apresentado bom desempenho quando do processo sem vales abruptos, o método Autocorrelação é mais adequado por requerer um esforço computacional menor.

Em resumo, as estimativas pelo método de Durbin serão tanto melhores quanto melhor for a aproximação fornecida pelo modelo AR longo. Esta, por sua vez, depende muito da localização dos zeros, do número de amostras disponível e do método de estimação do modelo AR.

5.5 Estimativas Espectrais MA com Base nos Métodos Clássicos

Foi visto na seção 3.4 que a SAC de um processo MA(q) apresenta comprimento finito, pois é nula para $|m| > q$. Em função deste fato a equação (3.19) da DEP-MA

$$P_{MA}(f) = P_w \left| 1 + \sum_{k=1}^q b[k] \exp(-j2\pi kfT) \right|^2$$

pode ser escrita como:

$$P_{MA}(f) = \sum_{m=-q}^q r_{xx}[m] \exp(-j2\pi m f T) \quad (5.6)$$

Esta expressão é semelhante à equação (2.19) do método Correlograma, utilizando a SAC teórica e $C=q$.

As duas expressões acima sugerem que as estimativas especiais pelo modelo MA(q) e pelo método Correlograma serão semelhantes. Logo, a estimativa paramétrica poderia ser substituída pela clássica com $C=q$. Entretanto é preciso levar em conta que nas situações práticas não conhecemos a SAC teórica e que somente podemos obter uma estimativa da mesma a partir das amostras disponíveis. Esta SAC estimada não apresentará, necessariamente, o comprimento finito adequado e o método Correlograma manterá suas limitações naturais.

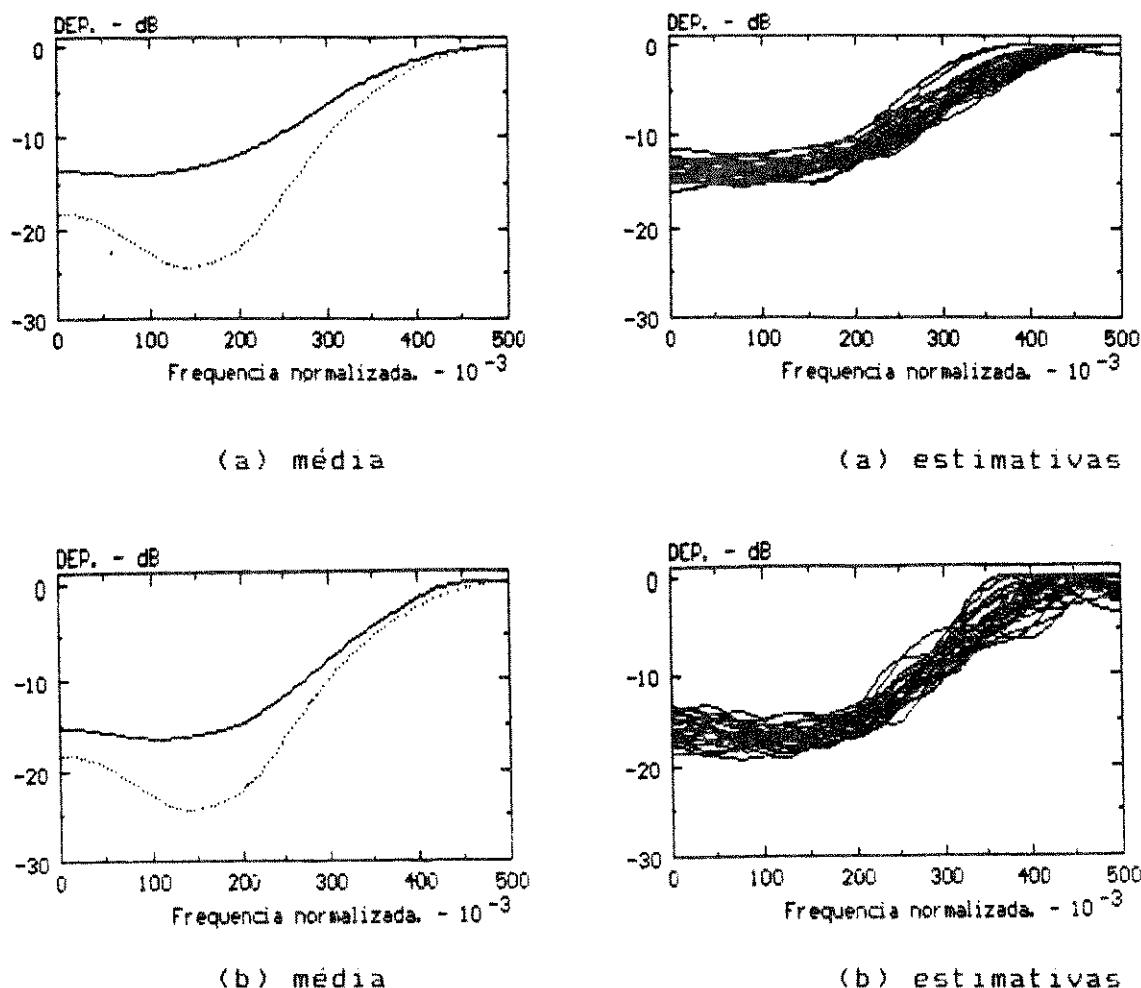
Contudo, o uso do método Correlograma, bem como o Periodograma, tem sido sugeridos como meio de efetuar uma estimativa espectral MA(q), [1], [2], [16], como forma de contornar as dificuldades impostas pela não-linearidade presente na expressão (3.20) e reduzir o esforço computacional requerido pelo método de Durbin.

Visando avaliar a eficácia desta sugestão, estudaremos aqui o desempenho dos métodos clássicos na estimativa da DEP dos dois processos MA(4) apresentados na seção 5.4. As estimativas fornecidas por estes métodos serão comparadas entre si e com aquelas obtidas com o método de Durbin.

No caso do método Correlograma não é necessário que o maior índice das estimativas de autocorrelação, C , seja igual à ordem do processo MA ($C=q=4$). Vejamos as razões para isto.

Como já foi comentado, na prática, por dispormos de um conjunto finito de amostras, as estimativas de autocorrelação de um processo MA(q) não são necessariamente nulas para $|m|>q$. Estas estimativas não nulas contêm informação sobre o processo sob análise e, portanto, não devem ser desprezadas. Desta forma, melhores estimativas espetrais devem ser obtidas fazendo o valor de C maior que a ordem MA teórica (desde que seja $C < N-1$).

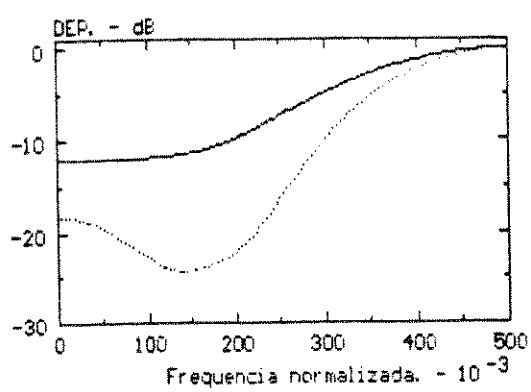
Tratando-se do método Periodograma, seção 2.6, o desempenho será avaliado em função de seus parâmetros na busca da melhor estimativa espectral possível.



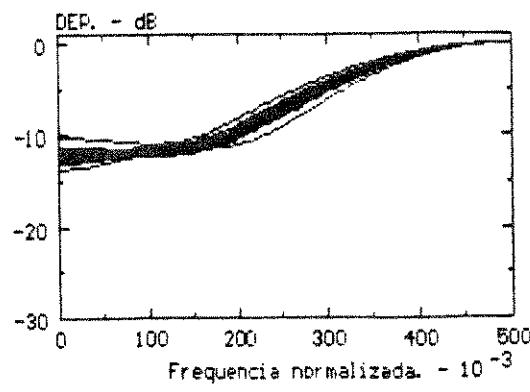
**Figura 5.17 Estimativas Espectrais do Processo MA_e , $N=64$, Método Correlograma: (a) $C=6$ ($N/10$),
(b) $C=12$ ($N/5$).**

Iniciando a avaliação do método Correlograma, utilizamos, para este, janela triangular de comprimento $2C+1$, estimativas polarizadas de correlação e os seguintes valores para o índice C : 4 (ordem MA_4), $N/10$, $N/5$. Os resultados são mostrados nas figuras 5.17 e 5.18 para $MA_e(4)$ e nas figuras 5.19 e 5.20 para $MA_1(4)$.

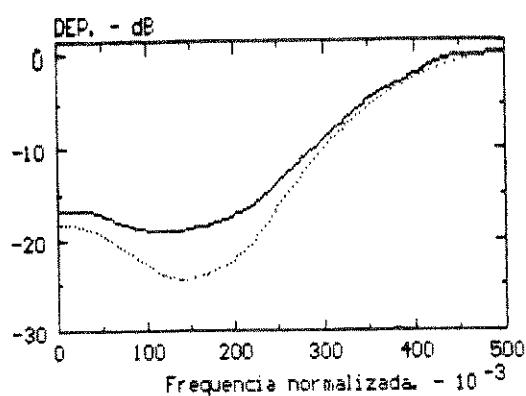
Observamos que para ambos processos a variação das estimativas espectrais aumentou e a polarização diminuiu à medida que aumentamos o valor de C . Este resultado era esperado pois o aumento de C permite utilizar mais valores da SAC estimada, enquanto que a qualidade destes valores diminui à medida que C aumenta, levando a uma maior variação das estimativas do espectro.



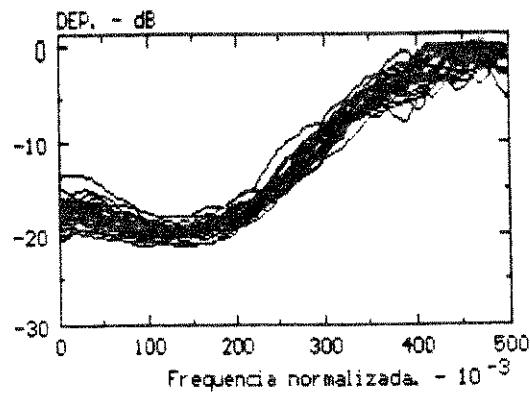
(a) média



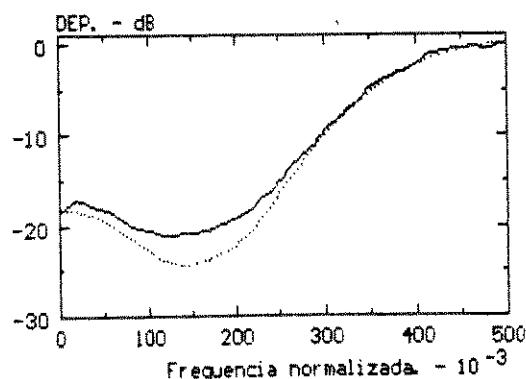
(a) estimativas



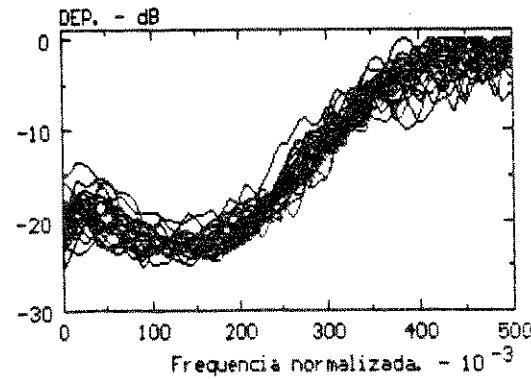
(b) média



(b) estimativas



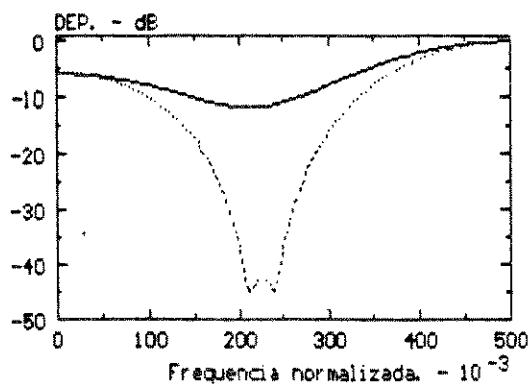
(c) média



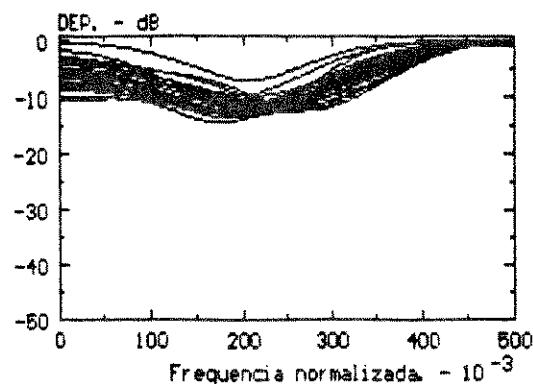
(c) estimativas

Figura 5.18 Estimativas Espectrais do Processo MA_8 , $N=256$, Método Correlograma:

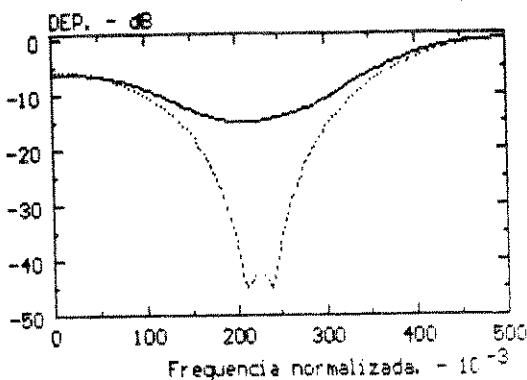
- (a) $C=4$,
- (b) $C=25$ ($N/10$),
- (c) $C=51$ ($N/5$).



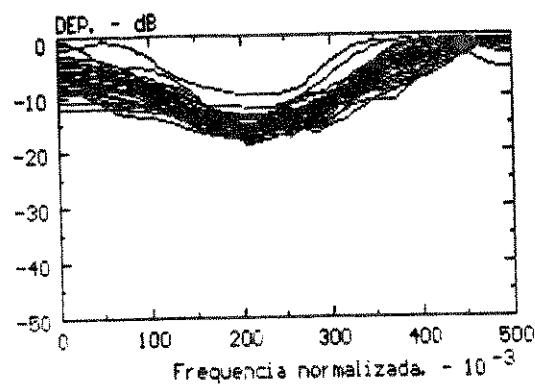
(a) média



(a) estimativas



(b) média



(b) estimativas

Figura 5.19 Estimativas Espectrais do Processo MA_1 , $N=64$, Método Correlograma: (a) $C=6$ ($N/10$),
(b) $C=12$ ($N/5$).

O valor $C=N/10$ é sugerido em [8] como um bom compromisso entre a polarização e variância das estimativas. Entretanto, embora os resultados aqui mostrados confirmem esta sugestão, a falta de qualidade das estimativas mostra que tal condição não é importante para sinais do tipo MA_1 .

No método Periodograma utilizamos janela de Hamming, sobreposição entre segmentos igual a 50% do número de amostras por segmento e este número teve os seguintes valores: $N/10$, $N/5$, e N . Os resultados são mostrados nas figuras 5.21 e 5.22 para o processo MA_0 e nas figuras 5.23 e 5.24 para MA_1 .

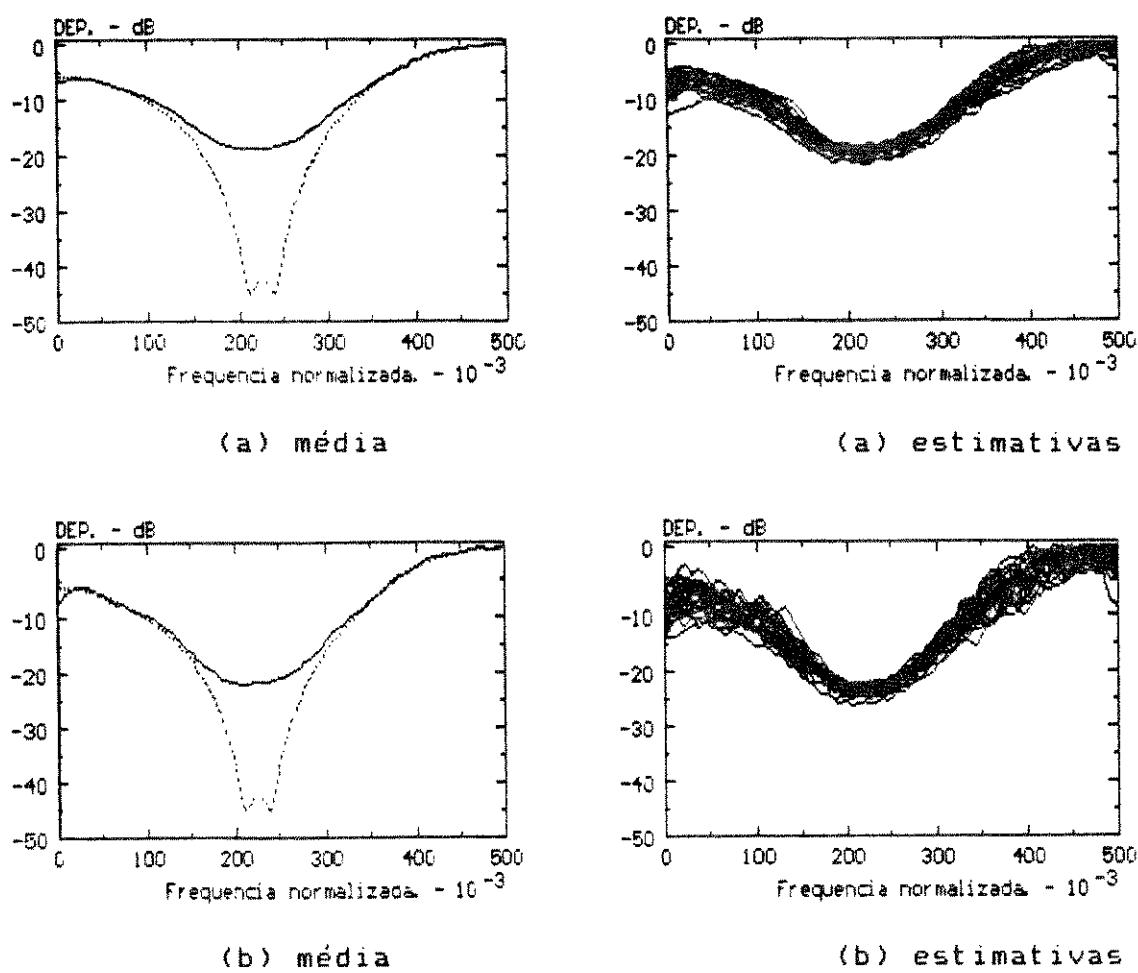
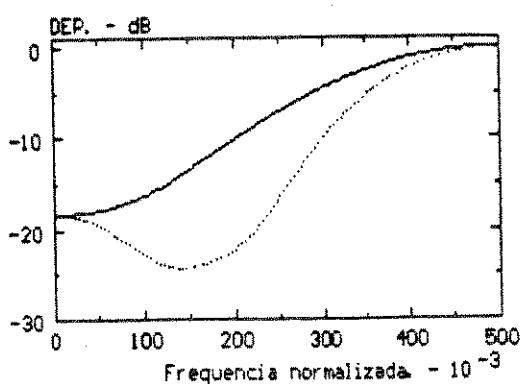


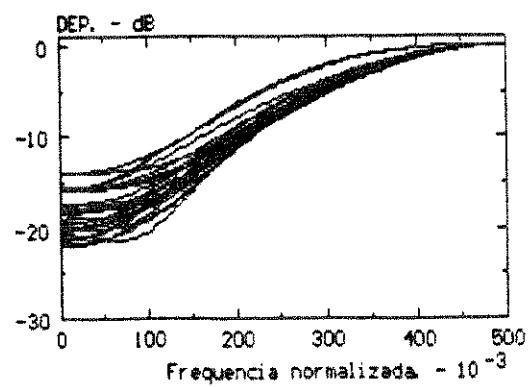
Figura 5.20 Estimativas Espectrais do Processo MA_1 , $N=256$, Método Correlograma: (a) $C=25$ ($N/10$),
(b) $C=51$ ($N/5$).

Para ambos processos a variação das estimativas espectrais aumentou e a polarização diminuiu com o incremento do número de amostras por segmento. Quando este número foi máximo as estimativas apresentaram a instabilidade estatística decorrente da falta de mediação sobre os segmentos; quando este número foi pequeno as estimativas apresentaram resolução pobre em função da redução do comprimento dos segmentos.

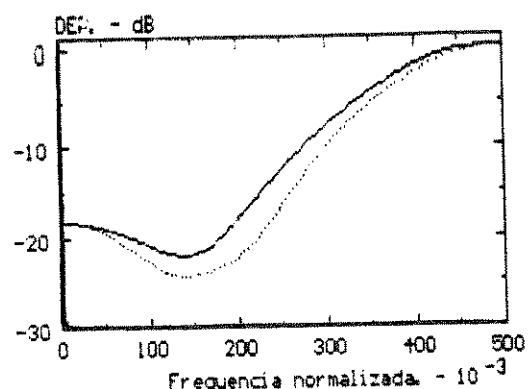
O número de amostras por segmento que forneceu o melhor compromisso resolução-variancia foi: $N/5$ para $N=64$ e $N/10$ para $N=256$, no processo MA_0 ; $N/5$ no processo MA_1 . Porém, considerando que a diferença entre as estimativas com $N/5$ e $N/10$ no caso MA_0 , não foram significativas, podemos adotar o valor $N/5$ em todos os casos.



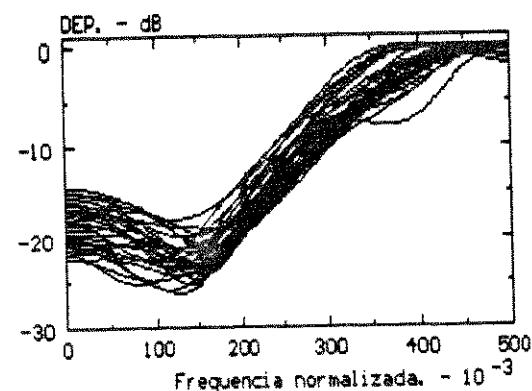
(a) média



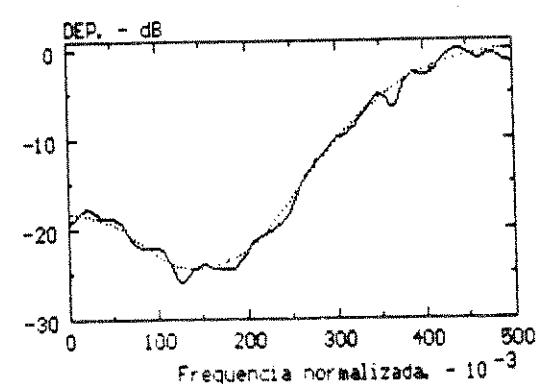
(a) estimativas



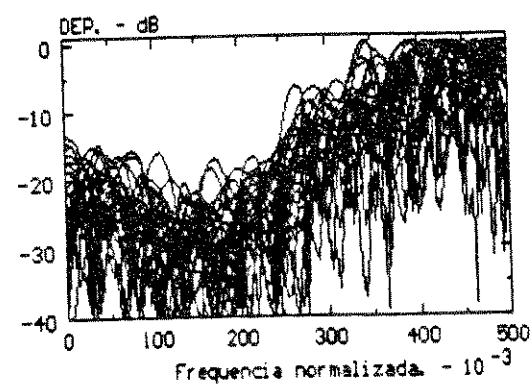
(b) média



(b) estimativas



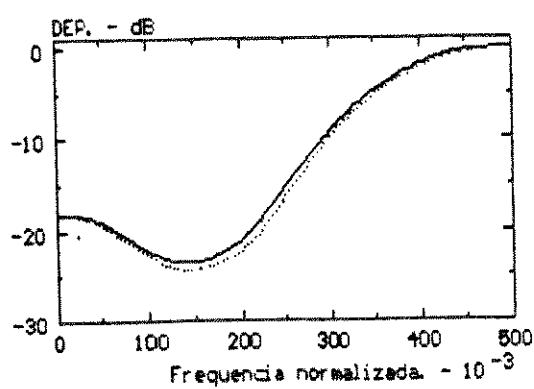
(c) média



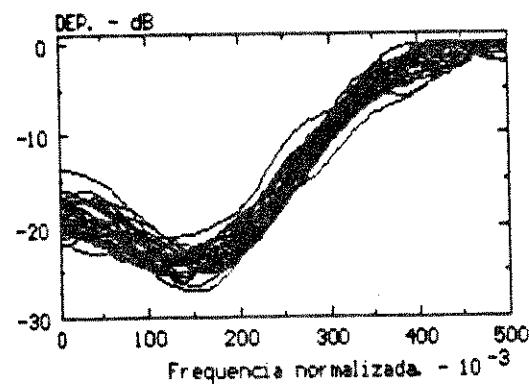
(c) estimativas

Figura 5.21 Estimativas Espectrais do Processo MA_{θ} , $N=64$, Método Periodograma:

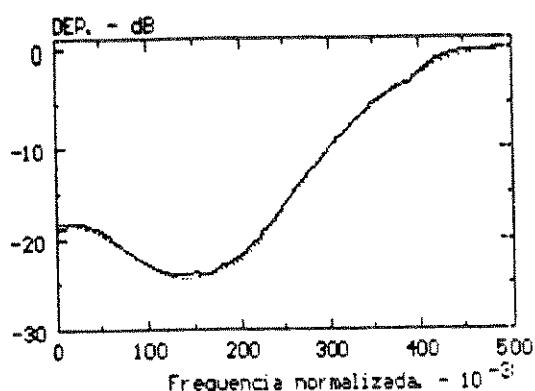
- (a) $P=6$ ($N/10$),
- (b) $P=12$ ($N/5$),
- (c) $P=64$ (N).



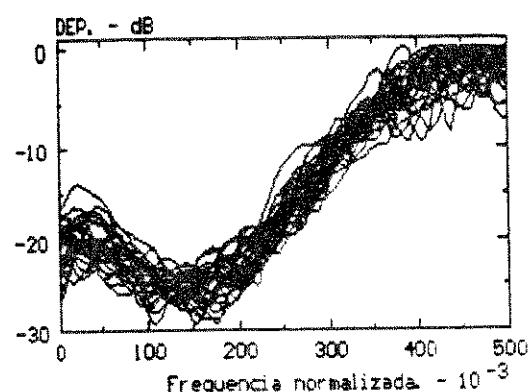
(a) média



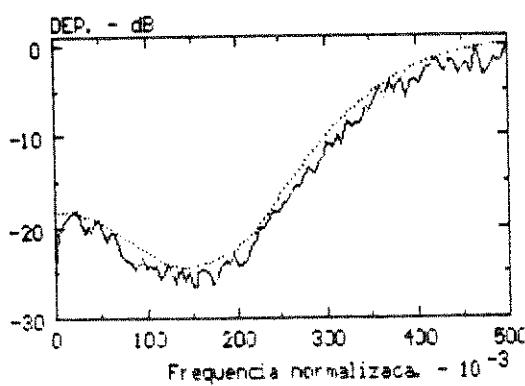
(a) estimativas



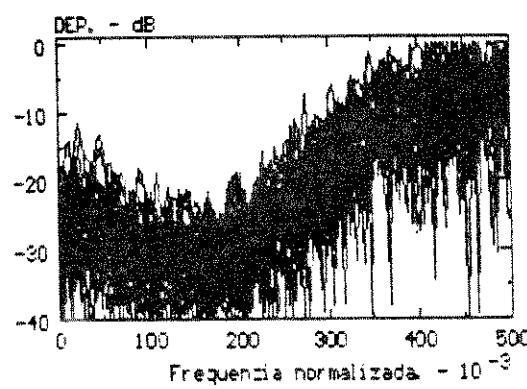
(b) média



(b) estimativas

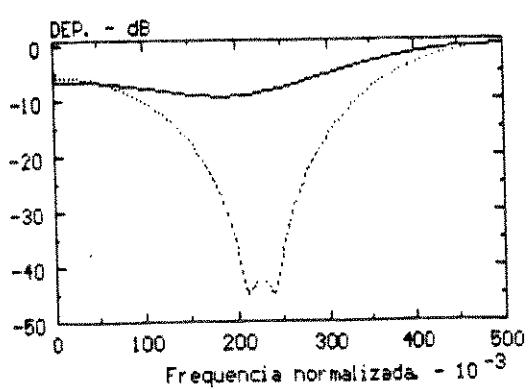


(c) média

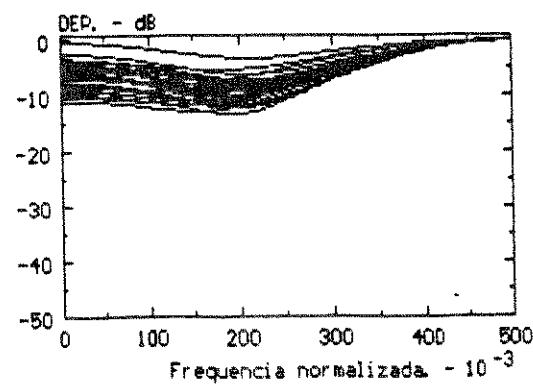


(c) estimativas

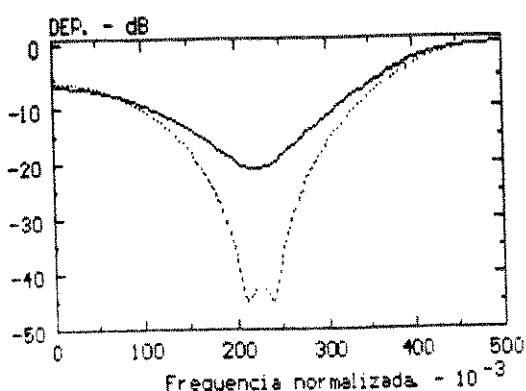
**Figura 5.22 Estimativas Espectrais do Processo MA_0 , $N=256$, Método Periodograma, (a) $P=24$ ($N/10$),
(b) $P=50$ ($N/5$),
(c) $P=256$ (N).**



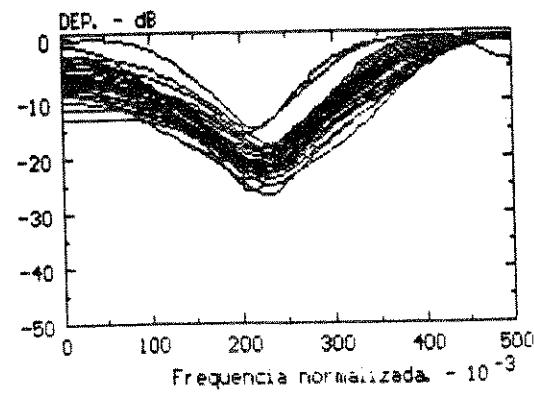
(a) média



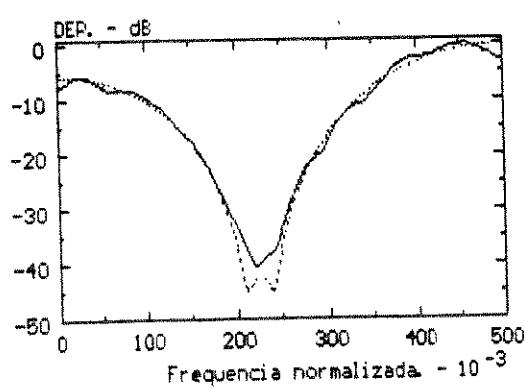
(a) estimativas



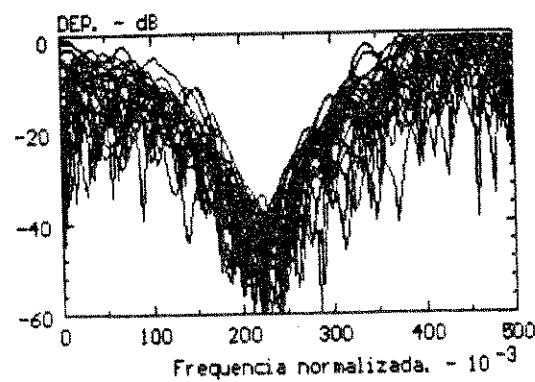
(b) média



(b) estimativas



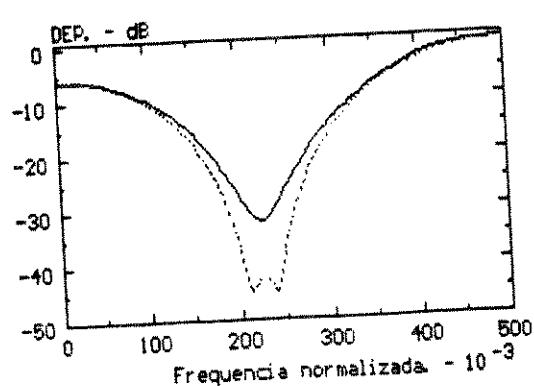
(c) média



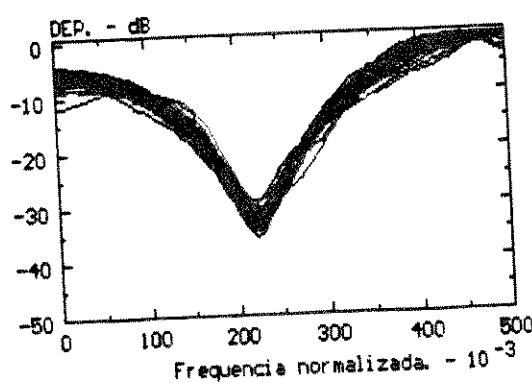
(c) estimativas

Figura 5.23 Estimativas Espectrais do Processo MA_1 , $N=64$, Método Periodograma

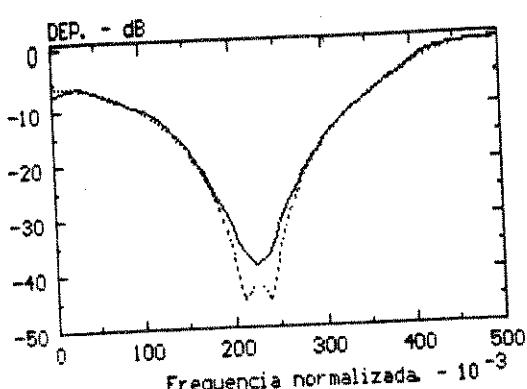
- (a) $P=6$ ($N/10$),
- (b) $P=12$ ($N/5$),
- (c) $P=64$ (N).



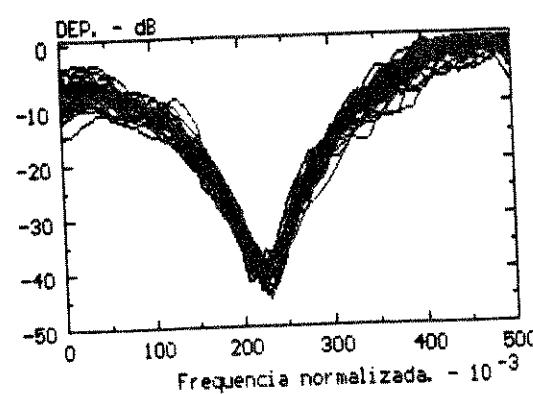
(a) média



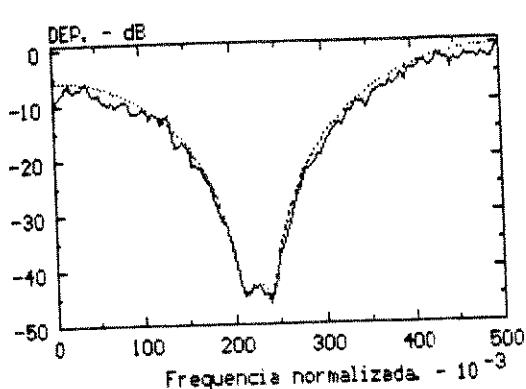
(a) estimativas



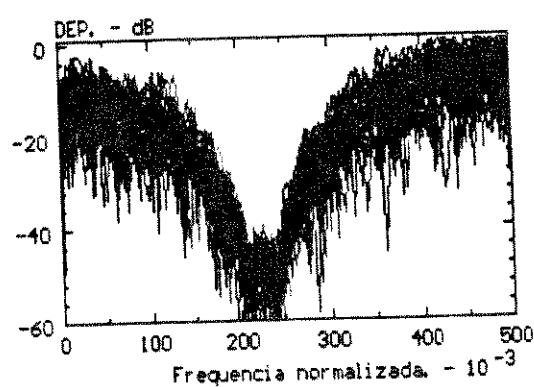
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 5.24 Estimativas Espectrais do Processo MA_1 , $N=256$, Método Periodograma:

- (a) $P=24$ ($N/10$),
- (b) $P=50$ ($N/5$),
- (c) $P=256$ (N).

Para este valor, ($N/5$), do número de amostras por segmento, o método Periodograma forneceu boas estimativas espectrais do processo sem vales abruptos. Entretanto, a definição dos vales abruptos do processo MA₁ não foi boa, particularmente para $N=64$. Embora estes resultados sejam melhores que aqueles atingidos pelo método Correlograma, ainda são inferiores àqueles obtidos através do método de Durbin na seção 5.4.

Logo, podemos afirmar que de maneira geral o método de Durbin deve ser preferido para a estimativa de espectros do tipo MA. Somente quando o número de amostras disponível for bastante grande é que será razoável substitui-lo pelo Periodograma, visando reduzir o esforço computacional. O método Correlograma não apresenta condições de ser utilizado nesta substituição.

5.6 Considerações Finais

Como foi afirmado anteriormente o objetivo do trabalho desenvolvido neste capítulo foi o de criar uma base para a análise espectral de processos MA, visando sua aplicação na estimativa do numerador espectral ARMA que será o objeto do próximo capítulo. Em função disto, as simulações aqui efetuadas não foram exaustivas, já que poderíamos considerar ainda situações como: um número de amostras maior ou menor que os utilizados, processos com zeros mais próximos da origem ou da própria CRU, ou uma combinação destes, ou ainda, zeros que se encontrem mais próximos ou afastados entre si. Por fim, um trabalho posterior poderia ainda analisar a variação do desempenho em função da ordem atribuída ao processo MA.

Entretanto, este capítulo apresentou vários aspectos inéditos tais como: 1) o uso de outros métodos que não a Autocorrelação, para estimar o modelo AR longo; 2) a análise da seleção da ordem do modelo AR longo em função do método escolhido para sua estimativa, do número de amostras disponíveis e das características espectrais do processo sob estudo; 3) a aplicabilidade da característica de alta resolução dos métodos de estimação AR na estimativa de espectros com vales abruptos e 4) a comparação entre as estimativas da DEP de processos MA usando o método de Durbin e os estimadores clássicos.

CAPÍTULO 6

ESTIMAÇÃO ESPECTRAL AUTO-REGRESSIVA MÉDIA-AJUSTÁVEL, ARMA

6.1 Introdução

O estimador espectral ARMA tem por característica principal a capacidade de fornecer formas espectrais com picos agudos e vales abruptos utilizando um número reduzido de parâmetros. Esta característica é particularmente importante se considerarmos o número elevado de parâmetros que os estimadores espectrais AR e MA requerem para gerar simultaneamente tais formas espectrais.

Paralelamente, na prática quase todos os processos com características auto-regressivas se encontram corrompidos por algum tipo de ruído e, portanto, não podem ser modelados como sendo puramente AR, sendo a modelagem ARMA mais adequada para esta finalidade [2].

Também, é crescente o interesse pelo uso do modelo ARMA para o tratamento de sinais de voz, uma vez que o trato vocal exige um modelo com pólos e zeros para a representação adequada de certos sons, como, por exemplo, os nasalados [17], [18].

Por outro lado, como consequência da não-linearidade das relações da SAC no modelo ARMA, não se dispõe de algoritmos simples para estimar seus parâmetros, tal como ocorre no caso AR [2].

Os métodos disponíveis para estimar os parâmetros de um modelo ARMA podem ser divididos em duas categorias:

1. Métodos ótimos: Utilizam técnicas iterativas com base no estimador de máxima verossimilhança para estimar simultaneamente os parâmetros do modelo. Porém, requerem a solução de um conjunto de equações não-lineares, o que exige considerável esforço computacional e não apresentam garantia de convergência [1], [2].

2. Métodos sub-ótimos: Utilizam relações lineares e requerem menor esforço computacional. Dentro desta categoria há dois tipos:

- estimação simultânea: onde os parâmetros são estima-

dos iterativamente através de relações lineares. Também não garantem convergência [1], [2], [19].

- estimacão separada: são métodos indiretos que estimam de forma separada o denominador e o numerador da função de sistema ARMA.

O objetivo deste capítulo é o estudo do estimador espectral ARMA com base nos métodos sub-ótimos de estimacão separada. Este estudo comprende o desenvolvimento teórico desse método e a realização de simulações que permitam avaliar seu desempenho em função de parâmetros tais como o tipo de sinal a ser analisado, o número de amostras disponíveis e os métodos empregados para estimar a parte auto-regressiva e a média-ajustável

6.2 Estimação Separada dos Parâmetros do modelo ARMA

Seja $x[n]$ um sinal gerado por um filtro ARMA(p, q), alimentando por ruído branco $u[n]$. A equacão a diferenças (3.5) que descreve $x[n]$, pode ser reescrita na seguinte forma:

$$x[n] + \sum_{k=1}^p a[k] x[n-k] = y_f[n] \quad (6.1)$$

$$y_f[n] = u[n] + \sum_{k=1}^q b[k] u[n-k] \quad (6.2)$$

A expressão (6.1) pode ser interpretada como a equacão a diferenças que descreve um filtro FIR (Finite Impulsive Response) de ordem p , com parâmetros iguais aos parâmetros auto-regressivos do filtro ARMA(p, q). Na entrada do filtro temos o processo $x[n]$ e na saída, um processo residual $y_f[n]$. Este processo residual é do tipo MA(q) com os mesmos parâmetros média-ajustável do filtro ARMA, como podemos constatar através da equacão (6.2).

Considerando o problema da estimacão dos parâmetros $a[k]$ e $b[k]$ a partir de um conjunto de N amostras de $x[n]$, observamos das equacões (6.1) e (6.2) que se obtivermos os parâmetros auto-regressivos poderemos obter um processo residual MA ao qual é plausível aplicar as técnicas de estimacão espectral MA. Esta in-

interpretação é a base dos métodos de estimação separada para os parâmetros ARMA.

O problema inicial neste contexto é estimar os parâmetros auto-regressivos do modelo ARMA. Sabemos da equação (3.10a), que a relação entre a SAC e os parâmetros $a[k]$ é linear para $m > q$, ou seja:

$$r_{xx}[m] = - \sum_{k=1}^p a[k] r_{xx}[m-k]; \quad m > q \quad (6.3)$$

O primeiro método desenvolvido para estimar os parâmetros auto-regressivos do modelo ARMA utiliza estas relações substituindo a SAC por estimativas de autocorrelação, polarizadas ou não, do processo $x[n]$. As estimativas dos parâmetros auto-regressivos são, então, obtidas através da solução do sistema de p equações, semelhante as Equações Modificadas de Yule-Walker, EMYW, que resulta ao escrevermos (6.3) para $q+1 \leq m \leq q+p$.

Entretanto, em diversos trabalhos sobre estimação espectral ARMA foi constatado que, em geral, este método fornece estimativas de baixa qualidade para os parâmetros auto-regressivos do modelo ARMA [2], [20].

Como forma de melhorar a qualidade destas estimativas, foi sugerido o uso de mais de p equações e a solução do sistema de equações resultante através da análise de mínimos quadrados. Este algoritmo é conhecido como sobredeterminação ou análise de mínimos quadrados das Equações Modificadas de Yule-Walker (MQEMYW) [1], [2], [16], [21].

A motivação para este procedimento vem da observação de que se conhecessemos a SAC teórica de $x[n]$, as p equações mencionadas acima forneceriam os valores corretos dos parâmetros auto-regressivos e os demais valores de $r_{xx}[m]$, para $m > q+p$, poderiam ser calculados por recorrência através da equação (6.3). Logo, toda a informação de $r_{xx}[m]$ para $m > q+p$ estaria contida nos parâmetros $a[k]$ e em $r_{xx}[m]$ no intervalo $q+1 \leq m \leq q+p$.

Entretanto, ao utilizarmos estimativas de autocorrelação para obter os parâmetros $a[k]$, as relações exatas não mais se verificam. Com isto a extrapolação de $r_{xx}[m]$ para $m > q+p$ com base nos

$a[k]$ obtidos, conterá erros em relação à SAC estimada. Por outro lado, ao utilizarmos mais que p equações para estimar os parâmetros $a[k]$, a informação disponível nas estimativas de autocorrelação para $m > p+q$ será utilizada de forma direta, criando a possibilidade de atingirmos estimativas mais precisas para estes parâmetros. Neste caso, a extrapolação de $\hat{r}_{xx}[m]$ será mais fiel à SAC estimada a partir das amostras de $x[n]$ disponíveis.

Estas considerações podem ser confirmadas observando que a expressão (6.3) é semelhante à equação de um filtro predição linear com coeficientes $a[k]$, aplicado para a predição dos "dados" representados por $\hat{r}_{xx}[m]$. Segundo esta interpretação, ao utilizarmos mais que p equações, os parâmetros $a[k]$ devem ser obtidos pela aplicação da teoria dos mínimos quadrados, onde os valores ótimos dos parâmetros resultam da minimização da soma dos quadrados dos erros entre as estimativas $\hat{r}_{xx}[m]$ e a predição das mesmas. Estas predições para $m > p+q$ são as extrapolações mencionadas acima. Da teoria dos mínimos quadrados, sabemos que a qualidade das predições aumenta à medida que envolvemos mais erros na soma a ser minimizada, ou seja, à medida que aumentamos o número de equações.

Supondo que o maior índice das estimativas de autocorrelação a ser utilizado seja M , onde $M > p+q \leq M < N$, a equação (6.3) fornecerá um sistema com $M-q$ equações e p incógnitas, do tipo:

$$\hat{\mathbf{r}} = -\hat{\mathbf{R}} \mathbf{a}$$

onde os $M-q$ elementos do vetor $\hat{\mathbf{r}}$ são:

$$r[j] = \hat{r}_{xx}[q+1+j] ; 0 \leq j \leq M-q-1$$

os da matriz $\hat{\mathbf{R}}$ de dimensão $(M-q) \times p$ são:

$$rr[j, k] = \hat{r}_{xx}[q+j-k] ; 0 \leq j \leq M-q-1 ; 0 \leq k \leq p-1$$

e o vetor \mathbf{a} é:

$$\mathbf{a} = [a[1], a[2], \dots, a[p]]^T$$

Entretanto, devido ao excesso de equações e às estimativas de autocorrelação, a igualdade das EMYW não poderá ser satisfeita. Será, então, necessário introduzir um erro de aproximação na equação anterior:

$$\mathbf{e} = \hat{\mathbf{r}} + \hat{\mathbf{R}} \mathbf{a} \quad (6.4)$$

onde o vetor \mathbf{e} possui $M-q$ elementos do tipo:

$$\mathbf{e} = [e[q+1], \dots, e[M]]^T$$

É conveniente utilizar estimativas não-polarizadas de autocorrelação na equação acima para que a polarização do erro de aproximação seja nula [2], [22]:

$$\begin{aligned} E\{\mathbf{e}\} &= E\{\hat{\mathbf{r}}\} + E\{\hat{\mathbf{R}} \mathbf{a}\} \\ &= \mathbf{r} + \mathbf{R} \mathbf{a} \end{aligned}$$

onde os elementos de \mathbf{r} e \mathbf{R} são as autocorrelações teóricas do processo $x[n]$ e o vetor \mathbf{a} resultante é aquele ótimo da Teoria de Wiener.

Da análise de mínimos quadrados podemos deduzir que o vetor \mathbf{a} que minimiza a soma dos quadrados dos erros:

$$P = \sum_{m=q+1}^M |e[m]|^2$$

é dado por:

$$\mathbf{a} = - \left[\hat{\mathbf{R}}^H \hat{\mathbf{R}} \right]^{-1} \left[\hat{\mathbf{R}}^H \hat{\mathbf{r}} \right] \quad (6.5)$$

A matriz $\hat{\mathbf{R}}^H \hat{\mathbf{R}}$, de dimensão $p \times p$, é Hermitiana e, em geral, positiva definida. Sua inversa pode ser calculada através do algoritmo de Cholesky [1], [2].

Temos, então, que a estimacão dos parâmetros auto-regressivos do modelo ARMA através do método MQEMYW, pode ser interpretada como a aplicacão do método Covariância, apresentado no capítulo 4, sobre a seqüência de "dados" $\{r_{xx}[q-p+1], \dots, r_{xx}[M]\}$.

A seqüência de estimativas de parâmetros auto-regressivos dada pela equação (6.5) não é, em geral, de fase mínima, e uma fatoraçao espectral pode ser necessária para deslocar os eventuais pólos situados no exterior da CRU para o interior desta [1], [5]. Isto, porém, não é necessário se os parâmetros forem estimados visando a realizacão de uma análise espectral.

O desempenho deste método é, em geral, superior àquele obtido com o uso de apenas p equações, e depende do tipo de espetro a ser estimado [23], [24], [25].

O número de equações, $M-q$, a ser utilizado também depende das características espetrais de $x[n]$. Como já foi comentado, à medida que aumentamos este número, aumenta a quantidade de informaçao contidas nas estimativas de autocorrelaçao. Entretanto, a qualidade das estimativas de autocorrelaçao fornecidas pelo estimador não-polarizado, decae com o aumento do deslocamento, conforme mostrado no capítulo 2. Logo, à medida que aumentamos o número de equações, passamos a utilizar valores de $r_{xx}[m]$ cada vez menos confiáveis. Isto mostra a existênciade um compromisso, o qual depende das características espetrais do processo $x[n]$.

Para compreendermos esta dependênci, devemos considerar que a função de sistema do filtro gerador de um processo ARMA é formada por pólos e zeros. Assim, quanto mais próximos da CRU se localizarem os pólos, ou seja, quanto mais agudos forem os picos espetrais de $x[n]$, maior será o comprimento efetivo da resposta impulsiva do filtro. Neste caso se considerarmos a resposta do filtro a dois impulsos espaçados no tempo, concluimos que a influênciade uma resposta sobre a outra aumenta à medida que os pólos se aproximam da CRU. Isto significa que o decaimento das amplitudes da SAC, $r_{xx}[m]$, ao longo do eixo m será tanto mais lento quanto mais agudos foram os picos espetrais.

Esta explicacão pode ser efetuada de outra forma, lembrando que DEP de um processo e sua SAC formam um par de Transformadas de Fourier e que uma contraçao no domínio da freqüênciа corresponde a

uma expansão no domínio do tempo e vice-versa. Assim, à medida que os pólos se aproximam da CRU, vão se pronunciando os picos na DEP, com um correspondente espalhamento da SAC no eixo m. Na situação inversa, o afastamento dos pólos leva a uma suavização do espectro, com a consequente contração da SAC no eixo m.

Admitindo que os erros de estimacão da SAC não dependam deste comportamento, concluimos que a influência relativa destes para $m > q$ será tanto maior quanto mais rápido for o decaimento da SAC. Logo, podemos prever que o compromisso na escolha do número de equações dependerá das características espectrais a serem analisadas e que para espectros com picos agudos devemos utilizar um número de equações maior que no caso de espectros suaves.

Este comportamento da qualidade das estimativas da SAC se reflete nos erros das equações, $e[m]$, fazendo com que a "qualidade" destes erros decresça à medida que o índice m aumenta. Uma maneira eficiente de enfatizar a participação dos erros referentes a valores de m próximos à ordem média-ajustável, q, em relação àqueles referentes a m próximo a M, é a utilização de uma janela de ponderação, $w[m]$, na minimização da soma dos quadrados dos erros [21], [23], [24], [26]:

$$P = \sum_{m=q+1}^M w[m] |e[m]|^2$$

ou na forma matricial:

$$P = \mathbf{e}^H \mathbf{W} \mathbf{e} \quad (6.6)$$

onde $w[m]$ é uma seqüência positiva, monotônica decrescente, de forma a atribuir pesos cada vez menores à medida que m aumenta, e \mathbf{W} é uma matriz de dimensões $(M-q) \times (M-q)$ e elementos:

$$w_{j,k} = \begin{cases} 0 & ; j \neq k \\ w[q+1+j] & ; j=k \end{cases} \quad 0 \leq j, k \leq M-q-1 \quad (6.7)$$

Substituindo a equação (6.4) em (6.6), obtemos:

$$\begin{aligned}\rho &= (\hat{r} + \hat{R}a)^H W (\hat{r} + \hat{R}a) \\ &= a^H \hat{R}^H W \hat{R} a + \hat{r}^H W \hat{R}^H a + a^H \hat{R}^H W \hat{r} + \hat{r}^H W \hat{r}\end{aligned}$$

Derivando esta expressão em relação ao vetor a :

$$\frac{\delta\rho}{\delta a} = 2 \hat{R}^H W \hat{R} a + 2 \hat{R}^H W \hat{r}$$

de modo que o vetor a que torna $\delta\rho/\delta a$ nulo será:

$$a = - [\hat{R}^H W \hat{R}]^{-1} [\hat{R}^H W \hat{r}] \quad (6.8)$$

Os elementos da matriz $\hat{R}^H W \hat{R}$, com dimensão $p \times p$, são:

$$c[j, k] = \sum_{l=0}^{M-q-1} w_w[l, 1] r_r^*[l, j] r_r[l, k], \begin{cases} 0 \leq j \leq M-q-1 \\ 0 \leq k \leq p-1 \end{cases} \quad (6.9)$$

e os da matriz $\hat{R}^H W \hat{r}$, com dimensão $p \times 1$, são:

$$cr[j] = \sum_{l=0}^{M-q-1} w_w[l, 1] r_r^*[l, j] r[l], \quad 0 \leq j \leq p-1 \quad (6.10)$$

com $r_r[j, k]$, $r[l]$ e $w_w[l, 1]$ como definidos anteriormente.

A matriz $\hat{R}^H W \hat{R}$ é Hermitiana e, em geral, positiva definida, tal que sua inversa pode ser calculada através do algoritmo de Cholesky.

Se a matriz W for igual à matriz identidade, ou seja, se a janela de ponderação tiver pesos unitários, as equações (6.5) e (6.8) serão idênticas. A questão agora é escolher o tipo de janela a ser utilizada para produzir o ponderamento desejado.

Da equação (2.12), observamos que o índice m contribui para a variância das estimativas não-polarizadas de autocorrelação com

um fator $(N-m)^{-2}$. Como a soma dos quadrados dos erros de aproximação a ser minimizada é uma função quadrática de $\hat{r}_{xx}[m]$, constatamos que tal fator está implícito nas parcelas do somatório da expressão (6.6) e assume a forma $(N-m)^{-4}$. Isto sugere que uma janela do tipo:

$$ww[m] = \begin{cases} 0 & ; \text{c.c.} \\ (N-m)^4 & ; q+1 \leq m \leq M \end{cases}$$

seja adequada para corrigir o efeito da variância das estimativas de autocorrelação. De fato, janelas do tipo $(N-m)^4$ e $(N-m)^3$ foram propostas nas referências [26] e [21], respectivamente, e sua influência será avaliada aqui através de simulações.

Devemos, por fim, observar que o uso da janela de ponderação atenua o compromisso na escolha no número de equações, uma vez que ela automaticamente reduz a importância da participação dos erros, $e[m]$, à medida que m aumenta.

Lembrando que a DEP de um processo ARMA é do tipo:

$$P_{\text{ARMA}}(f) = \frac{P_w |B(f)|^2}{|A(f)|^2} \quad (6.11)$$

a estimativa dos parâmetros $a[k]$ fornece o fator de denominador desta expressão. Isto nos motiva a utilizar a denominação: estimativa do denominador espectral do modelo ARMA (DEN-ARMA) para o fator $1/|A(f)|^2$. Também, estes parâmetros estimados permitem a realização da filtragem que produz o processo residual $y_f[n]$ segundo a equação (6.1). Com base neste processo podemos atacar o problema da estimativa dos parâmetros $b[k]$ e da variância P_w do ruído branco, ou seja do numerador espectral do modelo ARMA (NUM-ARMA).

Nos métodos de estimação separada dos parâmetros do modelo ARMA, a qualidade das estimativas dos parâmetros auto-regressivos é muito importante, pois quanto mais exatas forem estas, mais o processo residual $y_f[n]$ se aproximará do processo MA(q) caracterizado por P_w e os parâmetros $b[1], \dots, b[q]$.

6.3 Estimação do Numerador Espectral do Modelo ARMA

Dado que teoricamente o processo residual $y_f[n]$ é um processo MA(q), seu espectro de potência e, portanto, a estimativa do NUM-ARMA, pode ser encontrado com base nos conceitos do capítulo 5:

- aplicando o método de Durbin já apresentado.
- através dos métodos Correlograma e Periodograma.

O NUM-ARMA também pode ser estimado, sem explicitar os parâmetros média-ajustável, através de outros métodos:

- que utilizam as estimativas dos parâmetros auto-regressivos e das estimativas de autocorrelação do processo $x[n]$ em questão [27], [28], [29].

- que dividem a SAC estimada do processo $x[n]$, em uma seqüência causal e outra anti-causal [21].

Mosses e Beex, [30], reduzem estes métodos a uma forma comum e os analisam em função da polarização, variância e positividade da estimativa do NUM-ARMA. Estes não serão abordados aqui pois seus desempenhos são inferiores àqueles propiciados pelo método de Durbin e pelos estimadores espectrais clássicos, além de, na sua maior parte, não garantirem estimativas positivas do numerador espectral.

No contexto de detecção de senóides em ruído branco através da modelagem ARMA, os métodos Correlograma e Periodograma têm sido freqüentemente utilizados para estimar o numerador espectral, fornecendo bons resultados, [26], [31].

Embora tenhamos concluído no capítulo 5 que os métodos Correlograma e Periodograma não são competitivos com o método de Durbin, vamos considerá-los novamente no contexto ARMA. Isto porque $y_f[n]$ a ser analisado é o resultado de uma filtragem envolvendo os parâmetros $a[k]$, a qual pode ser realizada de duas maneiras distintas: 1) através de um filtro de predição linear progressiva, como na equação (6.1), dando origem a $y_f[n]$ e, 2) através de um filtro de predição linear regressiva, descrito pela seguinte equação:

$$y_b[n] = x[n] + \sum_{k=1}^P a^*[k] x[n+k] ; 0 \leq n \leq N-1 \quad (6.12)$$

Esta é uma situação semelhante àquela encontrada no método Covariância Modificado, apresentado no capítulo 4. Da mesma forma que lá, os resultados destas duas filtragens possuem informações distintas, as quais podem ser usadas simultaneamente através dos métodos clássicos [30].

Vejamos primeiro o método do Correlograma. A partir da seção 2.5, podemos afirmar que a estimativa do NUM-ARMA, $\hat{N}(f)$, com base:

- nos resíduos progressivos é dada por:

$$\hat{N}(f) = \sum_{m=-C}^C w[m] \hat{r}_{y_f}[m] \exp(-j2\pi mfT) \quad (6.13)$$

- nos resíduos progressivos e regressivos:

$$\hat{N}(f) = \frac{1}{2} \left[\sum_{m=-C}^C w[m] (\hat{r}_{y_f}[m] + \hat{r}_{y_b}[m]) \exp(-j2\pi mfT) \right] \quad (6.14)$$

onde

- $\hat{r}_{y_f}[m]$ e $\hat{r}_{y_b}[m]$ são as estimativas de autocorrelação dos processos $y_f[m]$ e $y_b[m]$, respectivamente, as quais devem ser obtidas através do estimador polarizado de autocorrelação.

- $w[m]$ é uma janela de ponderação, a qual deve ser positiva semidefinida.

- C é o maior índice de autocorrelação utilizado, que de acordo com a seção 5.6 pode ser maior que a ordem MA assumida.

Em relação ao método do Periodograma, da seção 2.4, deduzimos que a estimativa do NUM-ARMA com base:

- nos resíduos progressivos é dada por:

$$\hat{N}(f) = \frac{1}{P} \sum_{p=0}^{P-1} \left\{ \frac{1}{D} \left| \sum_{n=0}^{D-1} w[n] y_f[n+pS] \exp(-j2\pi nfT) \right|^2 \right\} \quad (6.15)$$

- nos resíduos progressivos e regressivos será:

$$\hat{N}(f) = \frac{1}{2P} \sum_{p=0}^{P-1} \left\{ \frac{1}{D} \left| \sum_{n=0}^{D-1} w[m] y_f[n+pS] \exp(-j2\pi n f T) \right|^2 + \right. \\ \left. + \frac{1}{D} \left| \sum_{n=0}^{D-1} w[m] y_b[n+pS] \exp(-j2\pi n f T) \right|^2 \right\} \quad (6.16)$$

onde:

D é o número de amostras por segmento.

P é o número de segmentos mediados.

S é o deslocamento de cada segmento.

w[m] é uma janela de ponderação sobre as amostras dos processos residuais.

A escolha destes parâmetros deve ser efetuada em função dos conceitos da seção 2.4.

6.4 Seleção da ordem do modelo ARMA(p, q)

Tal como nos casos dos modelos AR e MA, podemos utilizar o critério de Akaike, CIA, para escolher as ordens do modelo ARMA, [23]:

$$CIA(p, q) = N \ln P_w + 2(p + q) \quad (6.17)$$

onde p e q são as ordens auto-regressiva e média-ajustável assumidas e P_w é a estimativa de máxima verossimilhança da variância do ruído branco, obtida sob a hipótese de que $x[n]$ é um processo ARMA(p, q). As ordens adequadas são aquelas que minimizam CIA(p, q).

Também, podemos testar se as ordens selecionadas são as corretas, verificando se a sequência residual do filtro ARMA inverso é um ruído branco [32].

6.5 Simulações

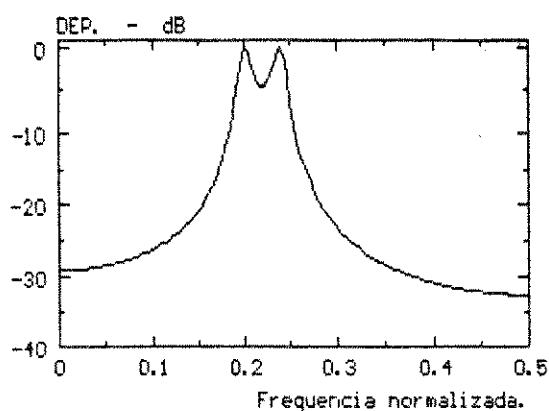
6.5.1 Apresentação das Simulações

Os métodos apresentados nas seções 6.2 e 6.3 foram aplicados na estimativa da DEP de quatro processos ARMA(4, 2) perfeitamente conhecidos, de modo a permitir a avaliação do desempenho. A escolha da localização dos pólos e zeros destes processos foi efetuada de forma a obtermos espectros de potência com características distintas quanto aos picos e vales espectrais. Os parâmetros dos processos são mostrados na Tabela 6.1

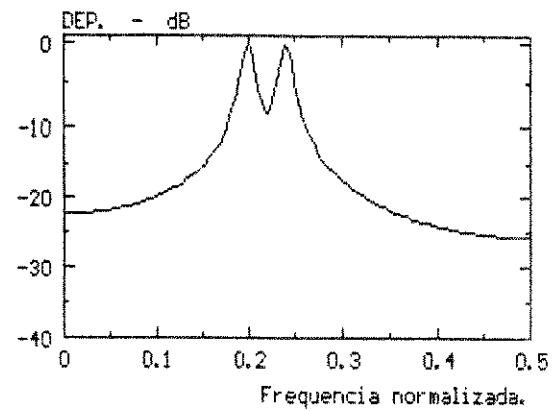
Processo	Parâmetros AR				Parâmetros MA		P_v
	a[1]	a[2]	a[3]	a[4]	b[1]	b[2]	
ARMA ₀	-0.714	1.915	-0.658	0.849	-0.262	0.490	1
ARMA ₁	-0.714	1.915	-0.658	0.849	-0.337	0.810	1
ARMA ₂	-0.520	1.018	-0.255	0.240	-0.075	0.040	1
ARMA ₃	-0.520	1.018	-0.255	0.240	-0.337	0.810	1
Localização dos pólos e zeros							
	pólos			zeros			
ARMA ₀	$0.96 \exp[\pm j2\pi(0.20)]$ $0.96 \exp[\pm j2\pi(0.24)]$			$0.70 \exp[\pm j2\pi(0.22)]$			
ARMA ₁	$0.96 \exp[\pm j2\pi(0.20)]$ $0.96 \exp[\pm j2\pi(0.24)]$			$0.90 \exp[\pm j2\pi(0.22)]$			
ARMA ₂	$0.70 \exp[\pm j2\pi(0.20)]$ $0.70 \exp[\pm j2\pi(0.24)]$			$0.20 \exp[\pm j2\pi(0.22)]$			
ARMA ₃	$0.70 \exp[\pm j2\pi(0.20)]$ $0.70 \exp[\pm j2\pi(0.24)]$			$0.90 \exp[\pm j2\pi(0.22)]$			

Tabela 6.1 Processos ARMA Utilizados nas Simulações.

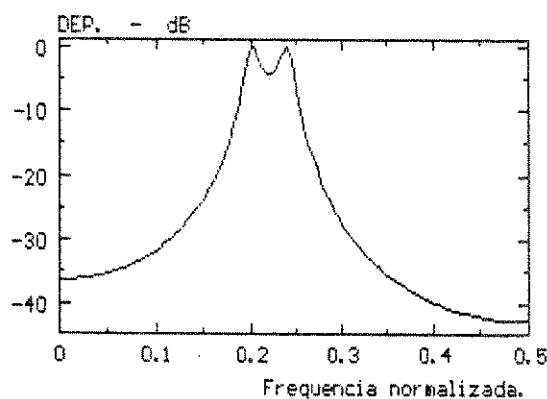
Os processos ARMA₂ e ARMA₁ apresentam DEP com picos estreitos, como podemos observar nas figuras 6.1a e 6.1b, respectivamente. Ambos possuem os mesmos parâmetros auto-regressivos e, portanto, o mesmo denominador espectral (figura 6.1c), diferindo apenas quanto ao módulo dos zeros. Estes, no processo ARMA₂, se encontram afastados da CRU de forma a não produzirem vales espectrais. Ao contrário, os zeros do processo ARMA₁ se encontram próximos à CRU de modo a acentuar o vale espectral entre os picos estreitos, produzindo variações abruptas.



(a)



(b)



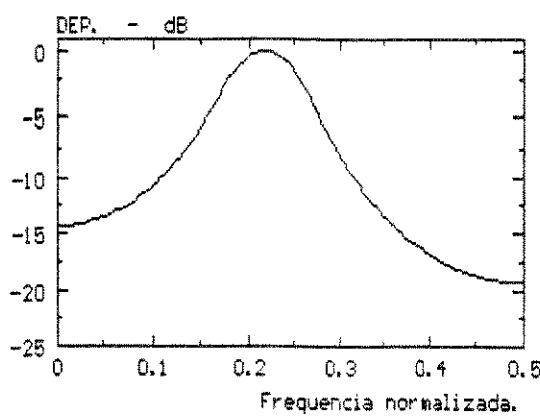
(c)

Figura 6.1 (a) Espectro de Potência do Processo ARMA₂

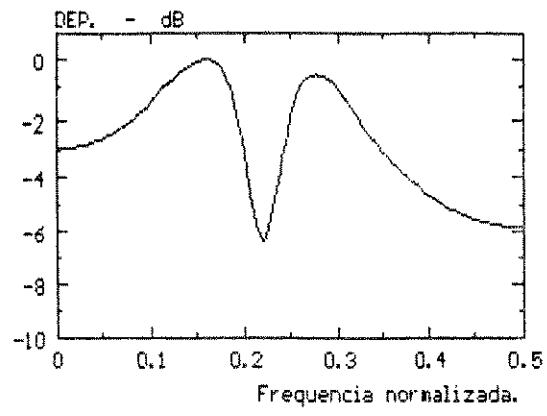
(b) Espectro de Potência do Processo ARMA₁

(c) Denominador Espectral dos Processos ARMA₂ e ARMA₁

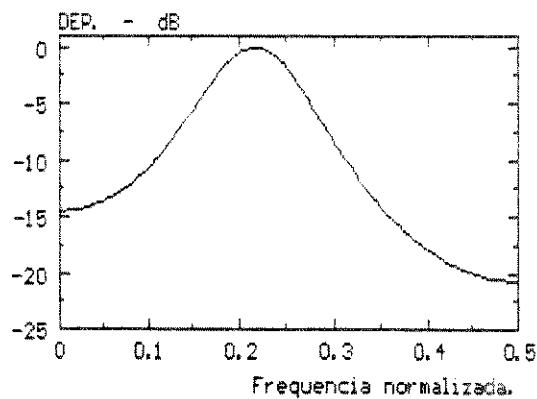
Os processos ARMA₂ e ARMA₃ foram escolhidos de forma a não apresentarem picos espectrais agudos, conforme mostrado nas figuras 6.2a e 6.2b, respectivamente. Ambos possuem o mesmo denominador espectral (figura 6.2c) e os zeros do processo ARMA₂ se encontram afastados da CRU, enquanto que os zeros do processo ARMA₃ se encontram próximos à CRU provocando um vale abrupto. É importante observar que a localização angular dos zeros se situa na posição intermediária àquelas dos pólos. Logo, a DEP apresenta o vale entre duas elevações.



(a)



(b)



(c)

Figura 6.2 (a) Espectro de Potência do Processo ARMA₂

(b) Espectro de Potência do Processo ARMA₃

(c) Denominador Espectral dos Processos ARMA₂ e ARMA₃

Para cada processo foram geradas trinta seqüências com 256 amostras, através de uma rotina de geração de dados, sobre as quais foram efetuados dois conjuntos de simulações: um com seqüências de 64 amostras e o outro com seqüências de 256 amostras. As estimativas obtidas serão apresentadas através de um gráfico para a média e outro para as estimativas, da mesma forma que no capítulo 5. As ordens escolhidas para o modelo ARMA a ser estimado foram as mesmas dos processos utilizados: $p=4$ e $q=2$.

A execução das simulações foi dividida em três etapas:

1º Foi estimado o DEN-ARMA com base no método MQEMYW, com e sem ponderação: seção 6.7.2.

2º O NUM-ARMA foi estimado utilizando-se o método de Durbin: seção 6.7.3.

3º O NUM-ARMA foi estimado utilizando-se os métodos Correlograma e Periodograma: seção 6.7.4.

Objetivando realizar uma análise detalhada da característica do método MQEMYW decidimos estudar inicialmente a estimativa do denominador da DEP-ARMA. Isto é possível, pois o estudo das simulações foi realizado com base em parâmetros conhecidos, de modo que sabemos a forma exata do denominador espectral e podemos utilizá-la como referência para suas estimativas.

Uma vez que os métodos sub-ótimos de estimação separada dos parâmetros do modelo ARMA, dependem inicialmente da estimativa da parte auto-regressiva, esta divisão permite avaliar o desempenho do método apresentado na seção 6.2 para a estimativa dos parâmetros auto-regressivos do modelo ARMA, bem como a validade dos conceitos teóricos lá desenvolvidos. Também, permitirá observar a influência da qualidade das estimativas do DEN-ARMA sobre a estimativa espectral ARMA.

Paralelamente, a divisão das simulações também permite observar o efeito da localização dos pólos e zeros sobre o desempenho do método MQEMYW e avaliar a influência das janelas de ponderação propostas.

Por fim, permitirá comparar novamente o método de Durbin com os métodos Correlograma e Periodograma levando em conta os dois sinais residuais apresentados na seção 6.3.

6.5.2 Estimativas do Denominador Espectral com Base na Análise de Mínimos Quadrados das Equações Modificadas de Yule-Walker

Nesta seção são apresentados os resultados das estimativas do denominador espectral dos quatro processos ARMA(4, 2), utilizando o método MQEMYW, com e sem ponderação.

Para cada conjunto de seqüências com 64 e 256 amostras, utilizamos três valores para o número de equações, $M-q$: número máximo de equações ($M=N-1$, e $q=2$), 16 e 8 equações (número pequeno de equações).

As janelas de ponderação $w[m]$ utilizadas foram (com $q+1 \leq m \leq M$):

- $w[m]=1$; janela unitária ou ausência de ponderação,
- $w[m]=(N-m)^4$,
- $w[m]=(N-m)^3$.

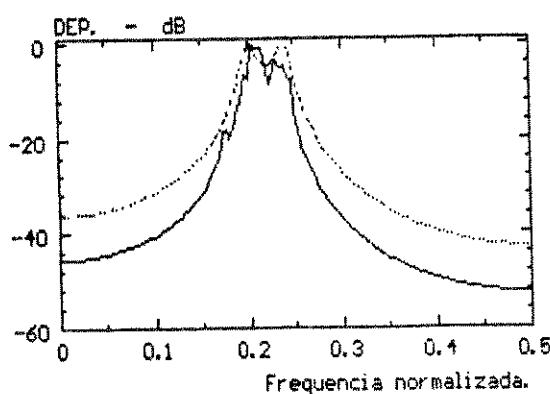
A. Estimativas do Denominador Espectral do Processo ARMA₈

O processo ARMA₈ tem seus pólos próximos à CRU e os zeros afastados. Em função da localização dos pólos, sua SAC apresentará um decaimento relativamente lento e, portanto, haverá informação relevante nos índices de autocorrelação elevados. Assim, podemos prever que o desempenho do método MQEMYW será melhor com um número grande de equações e, por causa deste número, com o uso das janelas de ponderação.

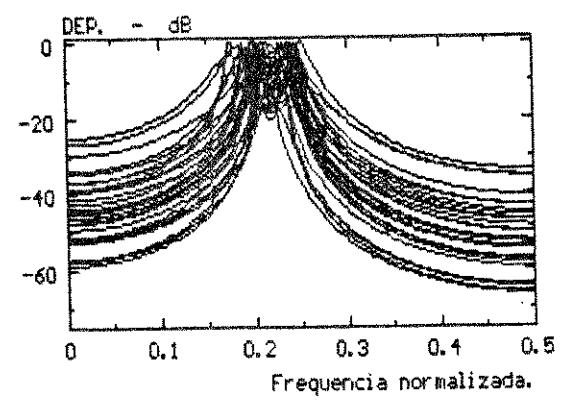
Para as simulações com as seqüências de 64 amostras, as figuras apresentadas são: figura 6.3, para as estimativas com máximo de equações, $M-q=61$, e figura 6.4, para as estimativas com 16 e equações, ambas com as três janelas descritas.

Das figuras 6.3 e 6.4, observamos que:

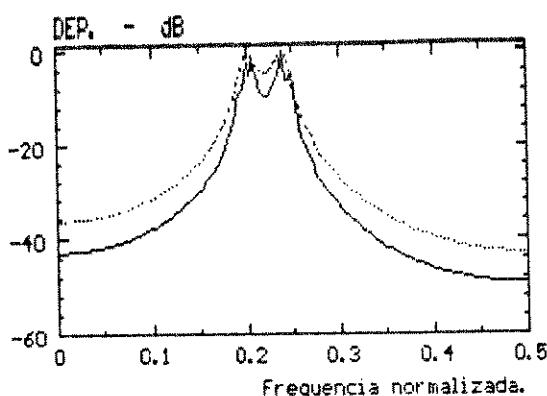
- o melhor desempenho do método MQEMYW foi obtido com o máximo de equações e ponderação.
- a ponderação não apresentou efeitos significativos para o caso com 16 equações.
- a ponderação com $(N-m)^3$ é ligeramente melhor que com $(N-m)^4$.



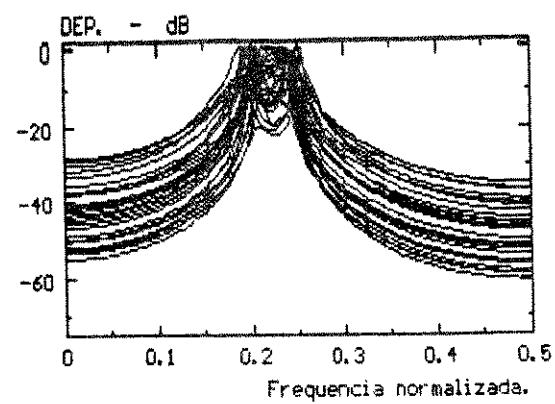
(a) média



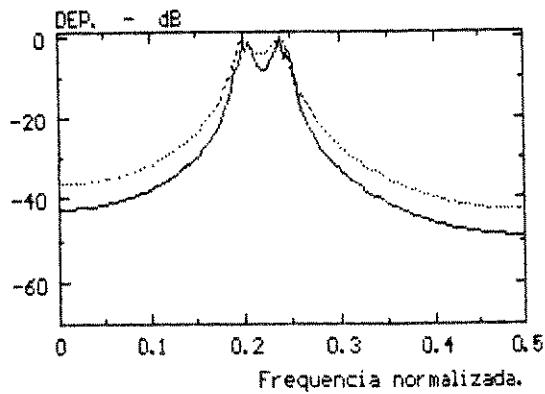
(a) estimativas



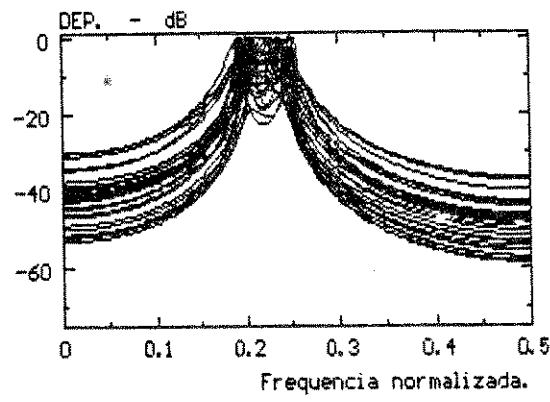
(b) média



(b) estimativas



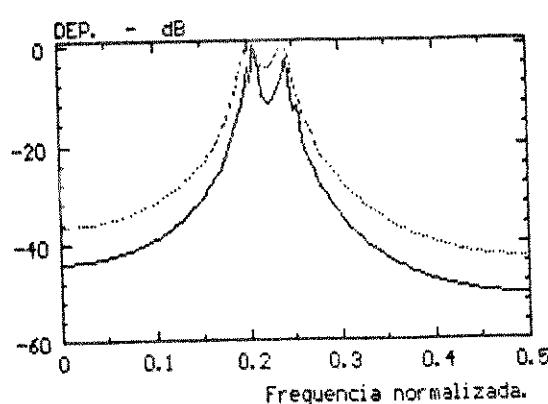
(c) média



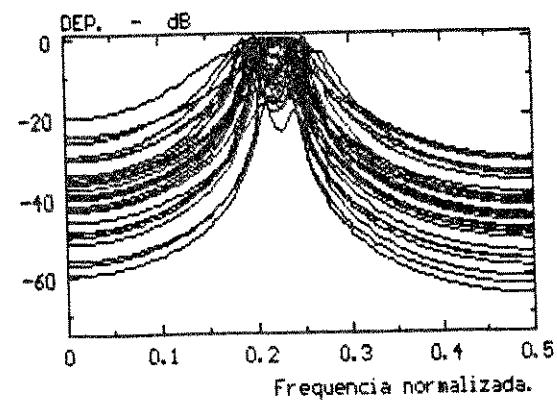
(c) estimativas

Figura 6.3 Estimativas do DEN-ARMA do Processo ARMA_0 , para $N=64$ e Máximo de Equações:

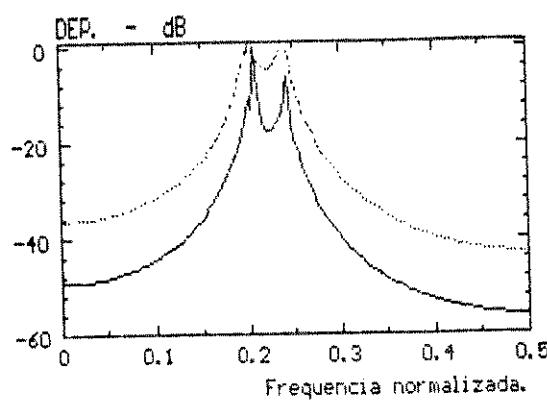
- (a) Sem Ponderação,
- (b) Ponderação com $(N-m)^4$,
- (c) Ponderação com $(N-m)^3$.



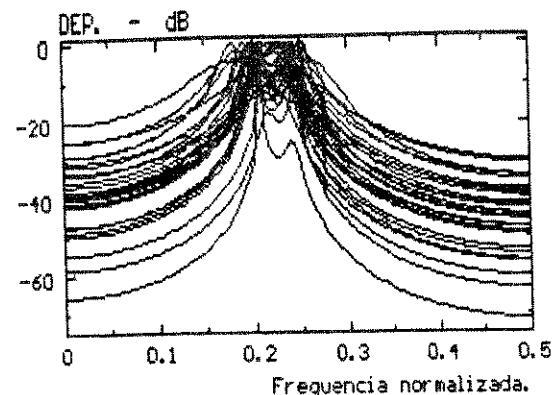
(a) média



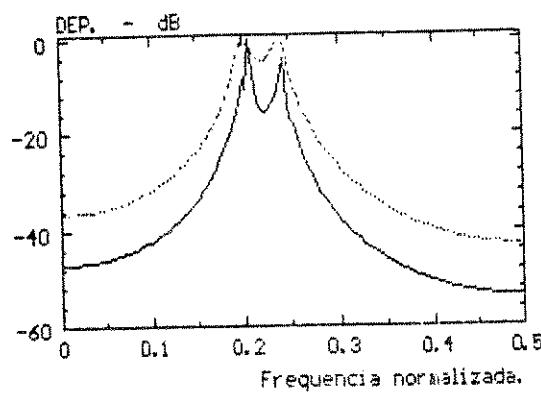
(a) estimativas



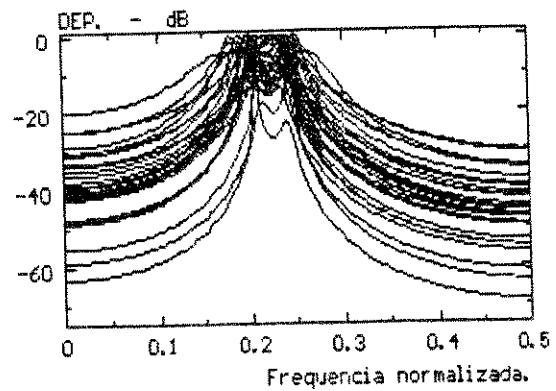
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.4 Estimativas do DEN-ARMA do Processo ARMA_{0,1}, para N=64 e 16 Equações:

- (a) Sem Ponderação,
- (b) Ponderação com $(N-m)^4$,
- (c) Ponderação com $(N-m)^3$.

Também foram efetuadas simulações com:

- número de equações igual a 32 e as três janelas descritas, obtendo-se um desempenho intermédio aos dois anteriores.

- número de equações igual a 8 e ponderação $(N-m)^2$, obtendo-se o pior desempenho entre todos.

Logo, o melhor desempenho do método MQEMYW foi obtido com máximo de equações e ponderação, confirmando a previsão propiciada pela análise teórica desenvolvida na seção 6.2.

Para as simulações com as seqüências de 256 amostras, as figuras apresentadas são: figura 6.5, para as estimativas com máximo de equações, $M-q=253$, e figura 6.6, para as estimativas com 16 equações, ambas com as três janelas descritas.

Das figuras 6.5 e 6.6, observamos que:

- exceto para o caso com o máximo de equações e ausência de ponderação, o desempenho dos MQEMYW foi bom.

- baseando-se principalmente nos gráficos das estimativas, observamos que o melhor desempenho foi obtido com máximo de equações e ponderação. É preciso ter cuidado ao analisar os gráficos de médias, pois a normalização pelo pico espectral produz falsas polarizações.

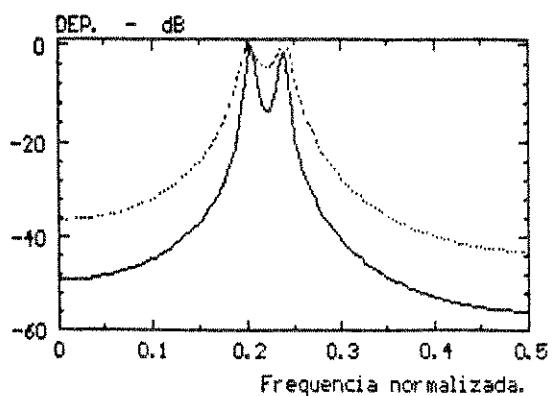
- com 16 equações, os desempenhos foram semelhantes entre si. Isto evidencia novamente a fraca influência da ponderação quando o número de equações é relativamente pequeno.

- é difícil distinguir diferenças entre os dois tipos de ponderação.

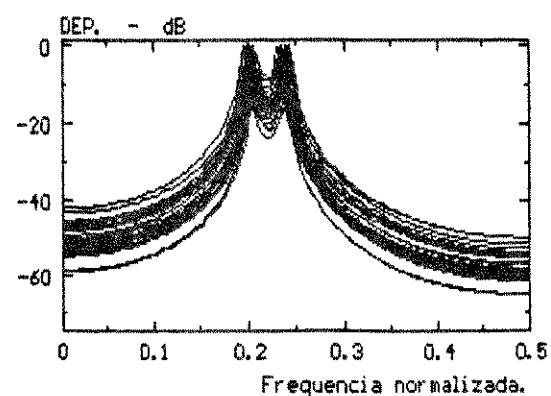
Também foram realizadas simulações com:

- número de equações igual a 48 e as três janelas descritas: o desempenho foi intermédio aos dois anteriores. Este número de equações é valor utilizado na referência [2].

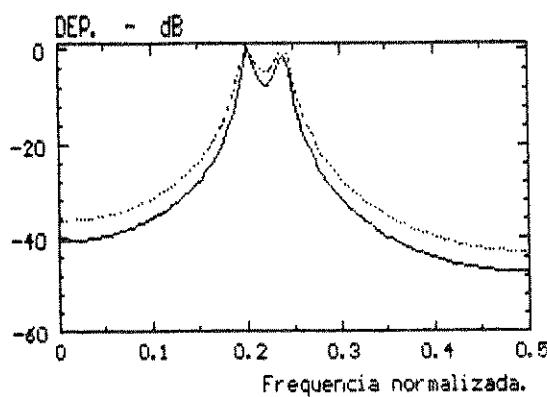
- número de equações igual a 8 e ponderação $(N-m)^2$: as estimativas foram inferiores a todos os casos ponderados, porém ainda com bom desempenho.



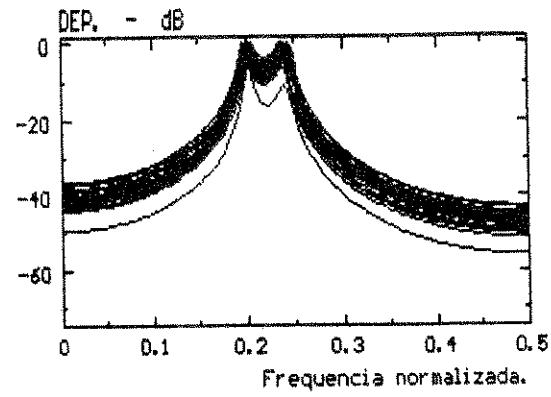
(a) média



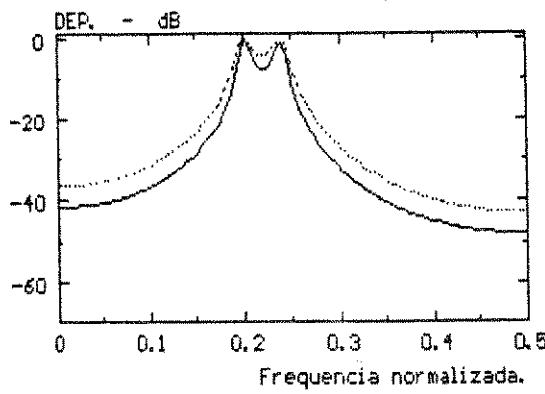
(a) estimativas



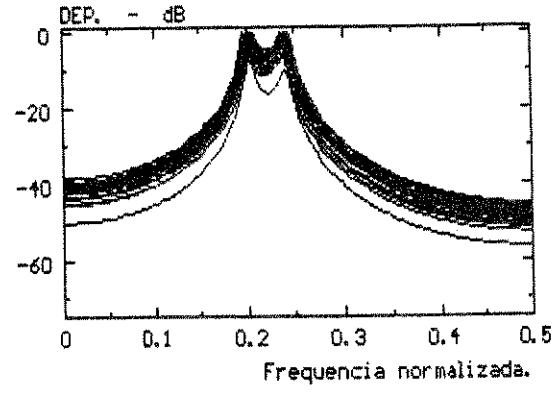
(b) média



(b) estimativas



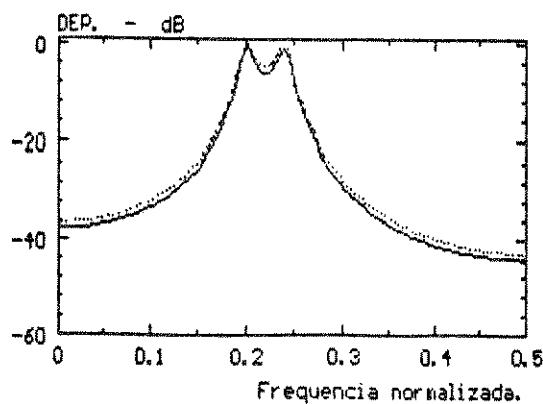
(c) média



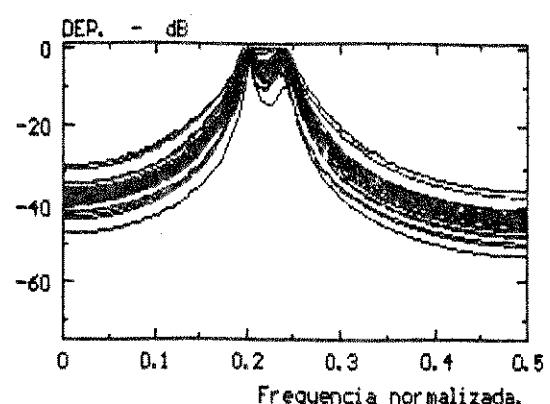
(c) estimativas

Figura 6.5 Estimativas do DEN-ARMA do Processo ARMA_{2,1}, para N=256 e Máximo de Equações:

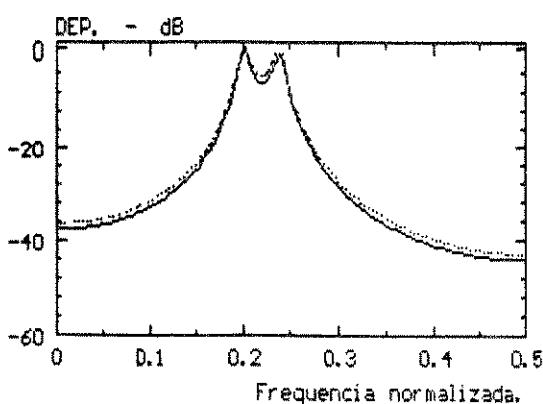
- (a) Sem Ponderação,
- (b) Ponderação com $(N-m)^4$,
- (c) Ponderação com $(N-m)^3$.



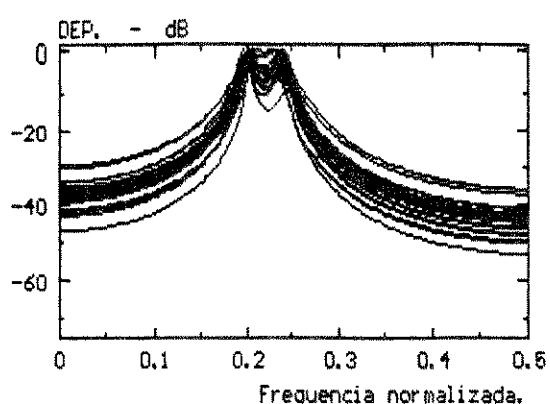
(a) média



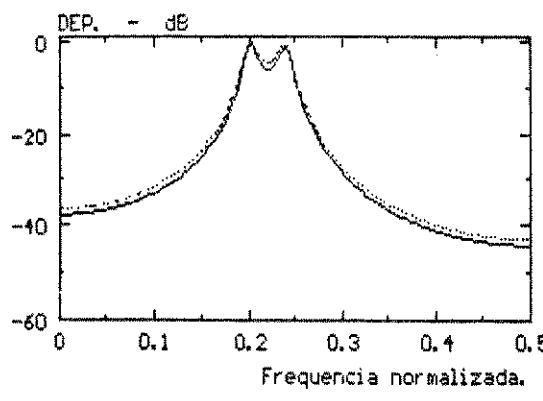
(a) estimativas



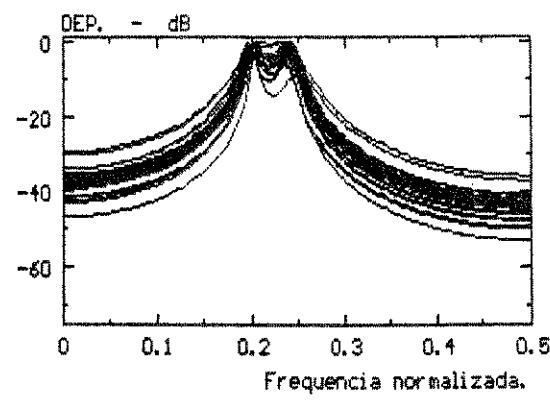
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.6 Estimativas do DEN-ARMA do Processo $ARMA_0$, para $N=256$ e 16 Equações:

- (a) Sem Ponderação,
- (b) Ponderação com $(N-m)^4$,
- (c) Ponderação com $(N-m)^3$.

Comparando os resultados obtidos concluímos que o desempenho para todos os casos com 256 amostras foi superior àqueles com 64 amostras e que os benefícios produzidos pelo incremento do número de equações tornam-se menos significativos à medida que é aumentado o número de amostras. Isto ocorre pois as estimativas de autocorrelação apresentam melhor qualidade, o que explica, também, porque obtivemos bom desempenho no caso com 256 amostras e 8 equações: embora o número de equações fosse pequeno, a informação utilizada foi de melhor qualidade.

É importante observar, particularmente na figura 6.5a, uma tendência na estimativa fornecida pelo método MQEMYW de enfatizar os picos espectrais. Tal tendência é responsável pelo nível de polarização nestes picos da referida figura.

Em resumo, para este processo com pólos perto da CRU e zeros afastados, o método MQEMYW apresentou as seguintes características gerais:

- o melhor desempenho é atingido com o número máximo de equações e janela de ponderação do tipo $(N-m)^3$.
- quando se dispõe de um número grande de amostras, é possível reduzir o número de equações, de modo a privilegiar a redução do esforço computacional.

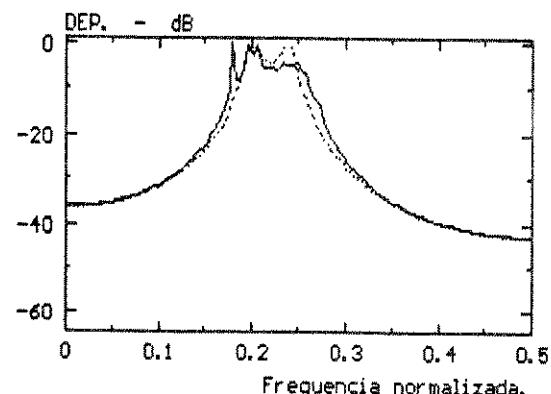
B. Estimativas do Denominador Espectral do Processo ARMA₁

O processo ARMA₁ tem os mesmos pólos do processo ARMA_q e, portanto, espera-se que o método MQEMYW apresente o mesmo comportamento do caso anterior.

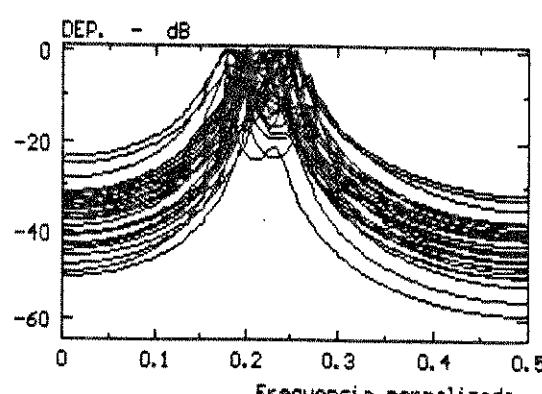
As simulações com as seqüências de 64 amostras são apresentadas na figura 6.7, para as estimativas com o máximo de equações, M-q=61, e figura 6.8, para as estimativas com 16 equações, ambas com as três janelas descritas.

Das figuras 6.7 e 6.8, observamos que:

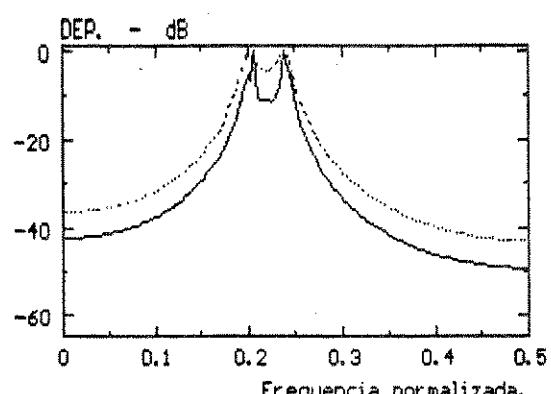
- não houve aumento de qualidade ao se aumentar o número de equações.
- o efeito da ponderação foi signifativo nos dois casos, particularmente por permitir melhor reprodução dos picos espectrais.



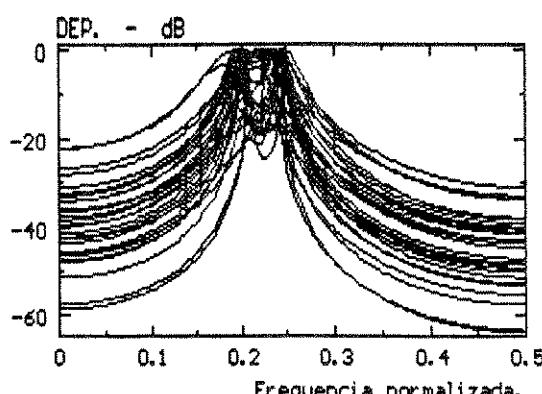
(a) média



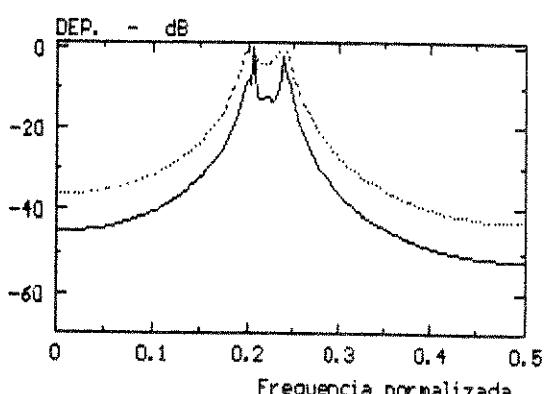
(a) estimativas



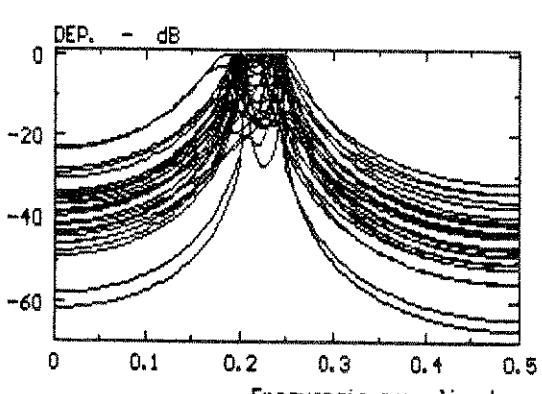
(b) média



(b) estimativas

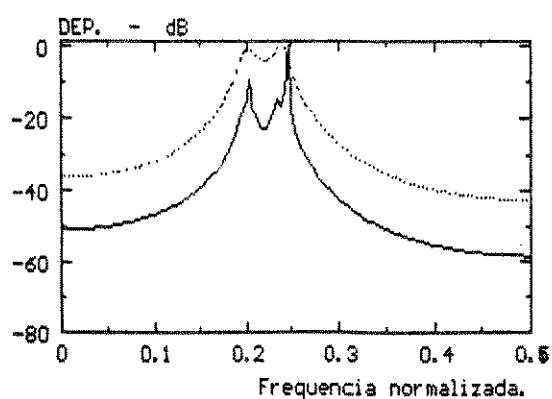


(c) média

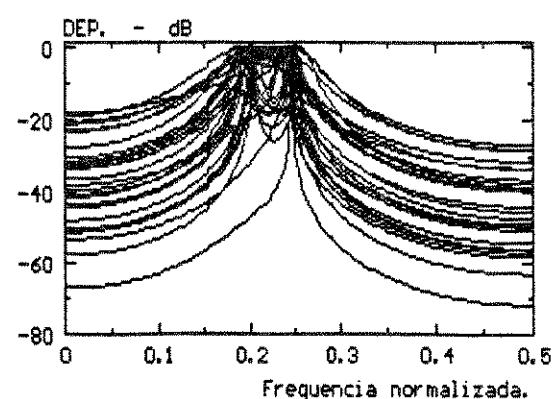


(c) estimativas

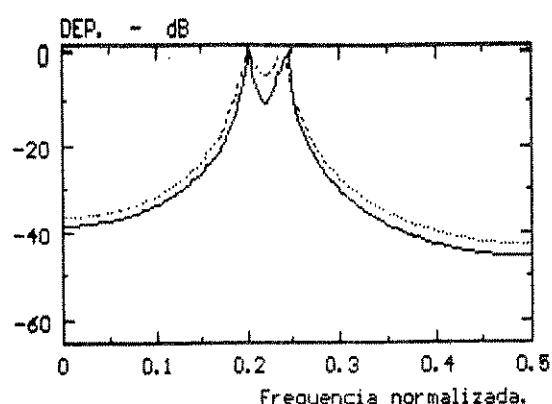
Figura 6.7 Estimativas do DEN-ARMA do Processo ARMA_{1,1}, para N=64 e Máximo de Equações: (a) Sem Ponderação,
 (b) Ponderação com $(N-m)^4$,
 (c) Ponderação com $(N-m)^3$.



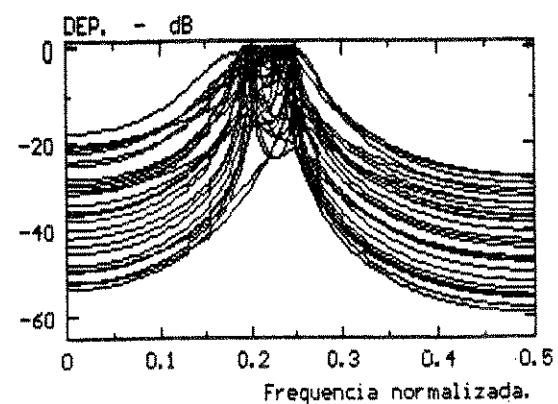
(a) média



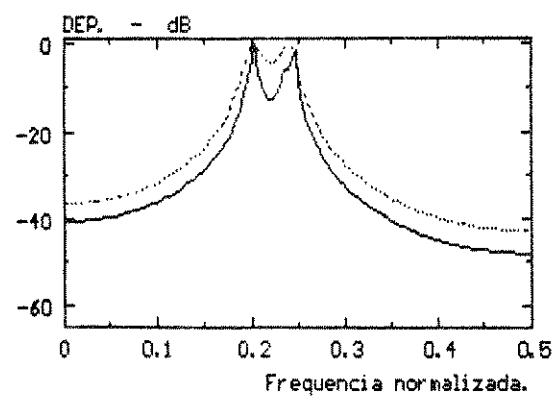
(a) estimativas



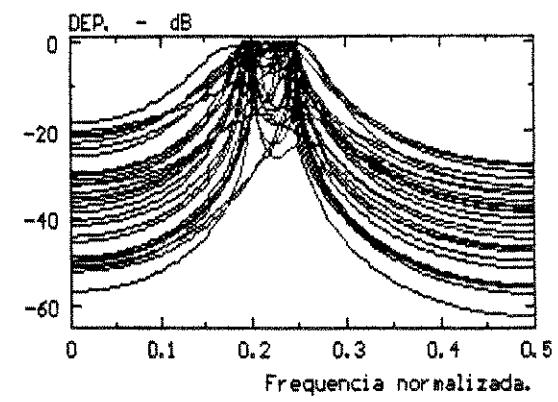
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.8 Estimativas do DEN-ARMA do Processo ARMA_{1,1}, para N=64 e 16 Equações: (a) Sem Ponderação,
(b) Ponderação com $(N-m)^4$,
(c) Ponderação com $(N-m)^3$.

- não há diferenças significativas entre os resultados fornecidos pelos dois tipos de ponderação. Porém, $(N-m)^4$ é ligeiramente melhor.

- a ênfase nos picos espectrais é notória em todas as figuras exceto a 6.7a.

Também utilizamos 8 equações e ponderação $(N-m)^3$ obtendo um desempenho inferior aos casos analisados.

Dado que os processos ARMA₆ e ARMA₄ possuem parâmetros auto-regressivos idênticos, a expectativa era de que os resultados fossem semelhantes. Podemos deduzir, então, que as diferenças observadas são consequência da diferença nas posições dos zeros dos processos. Este assunto será tratado posteriormente.

As simulações com as seqüências de 256 amostras, são apresentadas na figura 6.9, para as estimativas com máximo de equações, $M-q=253$, e na figura 6.10, para as estimativas com 16 equações.

Das figuras 6.9 e 6.10, podemos concluir:

- o melhor desempenho foi obtido com o máximo de equações e ponderação.

- não há diferenças significativas entre os resultados dos dois tipos de ponderação.

- houve enfatização do pico espectral situado ao redor da freqüência 0.2, particularmente com 16 equações.

Foi utilizado também 8 equações e ponderação $(N-m)^3$, e novamente o desempenho foi o menor de todos.

Os resultados para 256 amostras apresentaram melhor qualidade que os correspondentes com 64 e o comportamento do método com $N=256$ se assemelhou àquele observado no caso do processo ARMA₆.

Este último fato permite afirmar que as diferenças de comportamento no caso $N=64$ (bem como a qualidade inferior das estimativas obtidas) evidenciam a insuficiência de amostras para uma melhor atuação do método MQEMYW. A necessidade de um número maior amostras para o processo ARMA₄ em relação ao ARMA₆, deve ser consequência exclusiva do posicionamento dos seus zeros, os quais deram origem a um vale entre os dois picos espectrais. Aparentemente, este posicionamento provocou um aumento da tendência para enfatizar estes picos, a qual é compensada com o aumento do número de amostras.

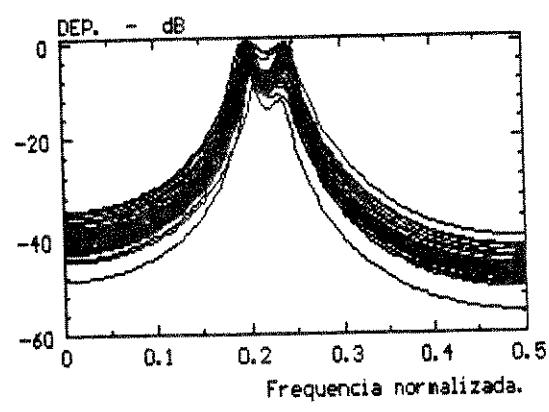
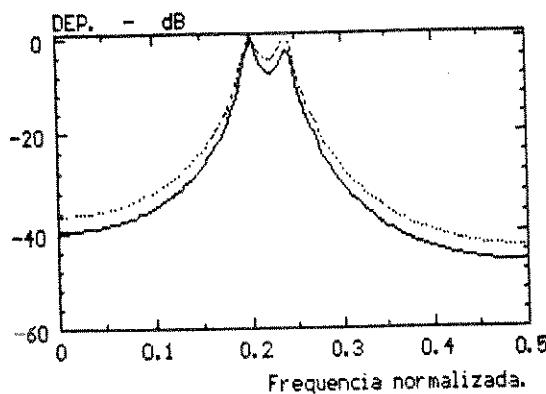
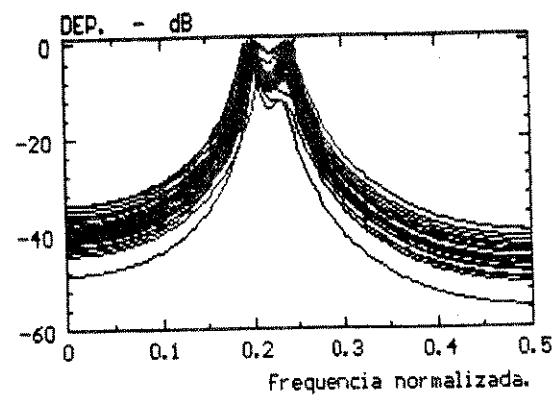
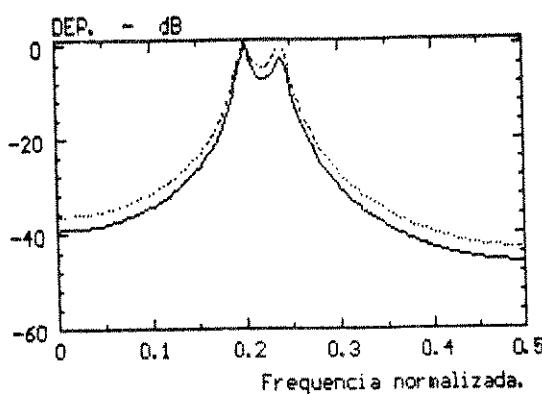
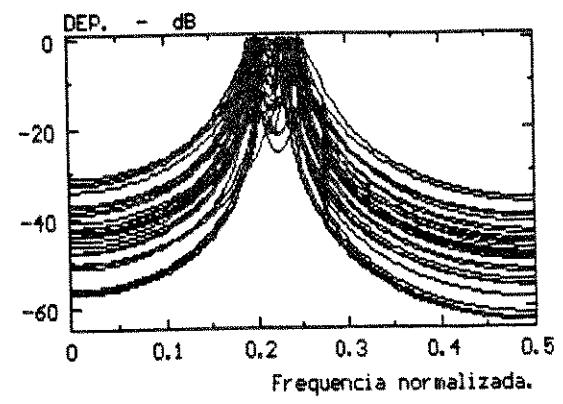
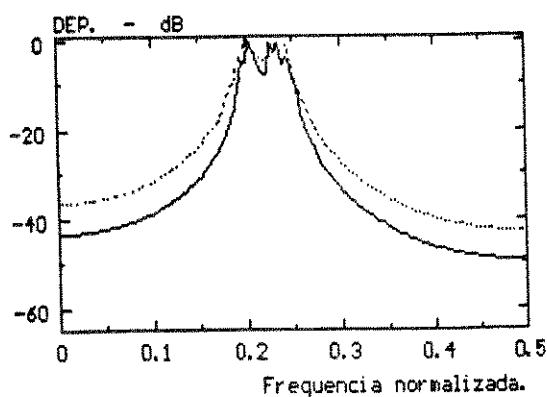
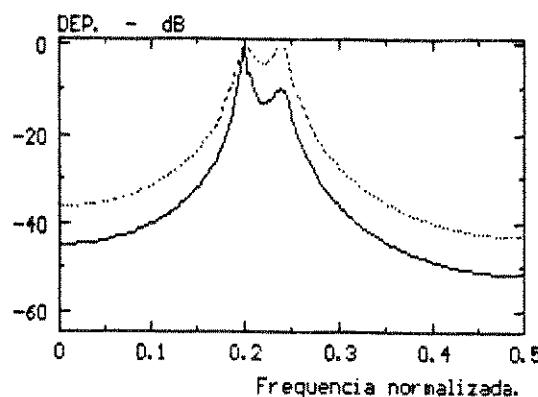
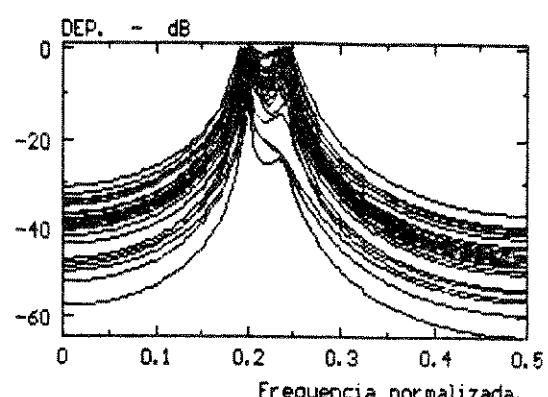


Figura 6.9 Estimativas do DEN-ARMA do Processo ARMA_{1,1}, para N=256 e Máximo de Equações:

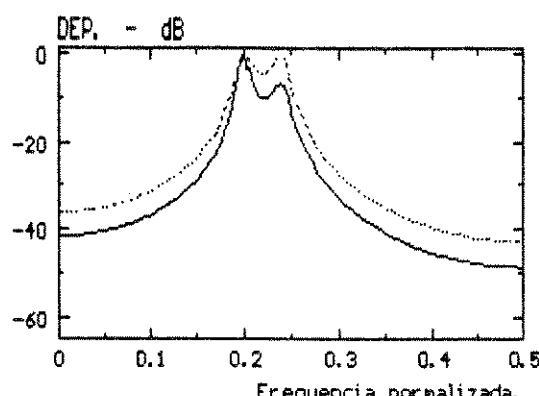
- (a) Sem Ponderação,
- (b) Ponderação com $(N-m)^4$,
- (c) Ponderação com $(N-m)^3$.



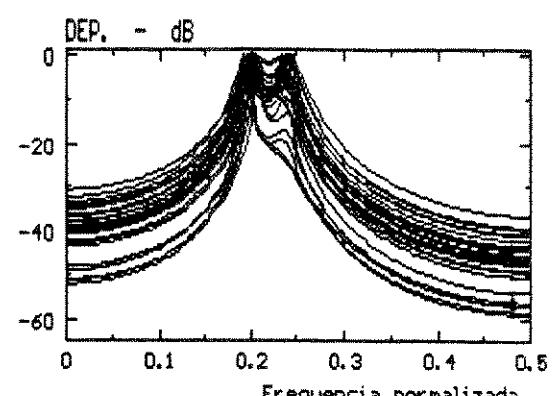
(a) média



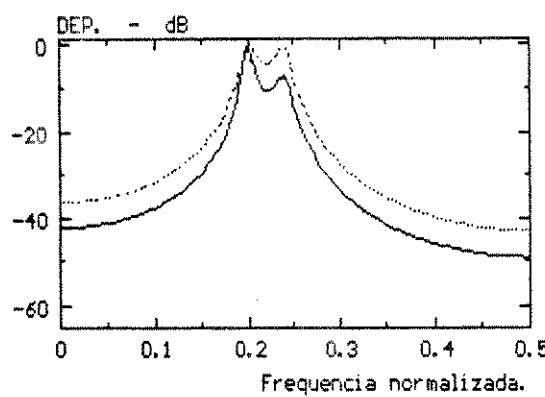
(a) estimativas



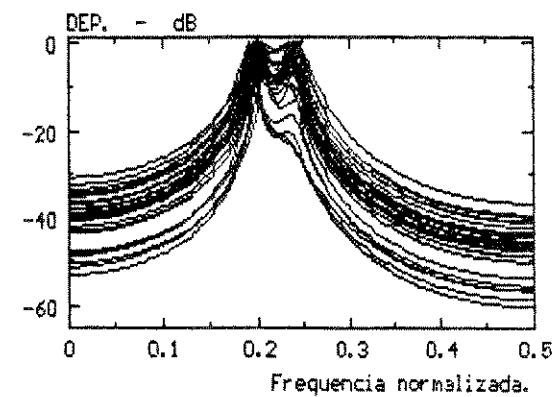
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.10 Estimativas do DEN-ARMA do Processo ARMA_{1,1}, para N=256 e 16 Equações:

- (a) Sem Ponderação,
- (b) Ponderação com $(N-m)^4$,
- (c) Ponderação com $(N-m)^3$.

Por fim, no contexto do processo ARMA₄, não podemos afirmar que o aumento do número de amostras, até cerca de 256, permite reduzir o número de equações de modo a privilegiar a redução do esforço computacional. As estimativas do denominador espectral deste processo apresentaram diferenças significativas para os três números de equações utilizados.

Dado que as duas formas de ponderação analisadas apresentaram resultados semelhantes, resolvemos adotar apenas uma delas no restante deste capítulo, como forma de economizar espaço. Escolhemos a janela do tipo $(N-m)^3$ em função de alguns desempenhos ligeiramente superiores.

C. Estimativa do Denominador Espectral do Processo ARMA₂

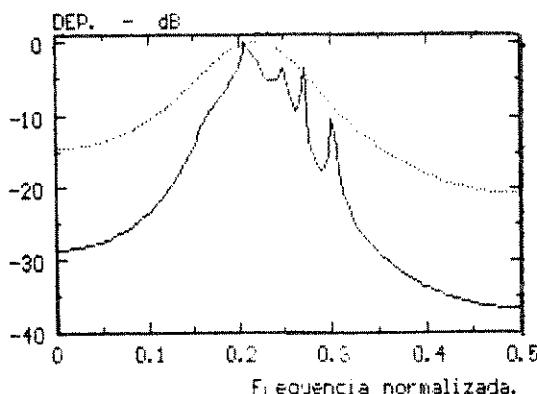
O processo ARMA₂ tem seus pólos e zeros afastados da CRU, indicando que a SAC correspondente decairá de forma mais rápida que nos casos anteriores. Logo, não haverá informação relevante nos índices de autocorrelação elevados, o que permite prever que o método MQEMYW apresentará melhor desempenho com um número pequeno de equações. Em função deste, não deve ocorrer diferenças significativas entre as estimativas com e sem ponderação.

As simulações com o conjunto de seqüências de 64 amostras são apresentadas na figura 6.11 para o máximo de equações, M-q=61, e na figura 6.12 para 8 equações, as quais permitem concluir que:

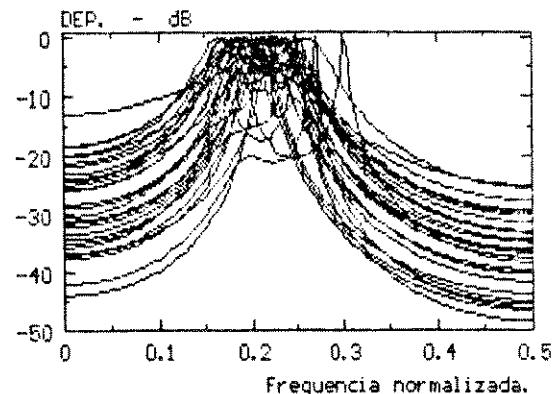
- o melhor desempenho foi obtido com o número pequeno de equações, e neste caso a ponderação não foi importante.
- a qualidade das estimativas com o máximo de equações é bastante inferior.

Também, com 16 equações o desempenho foi muito inferior àquele com 8 equações.

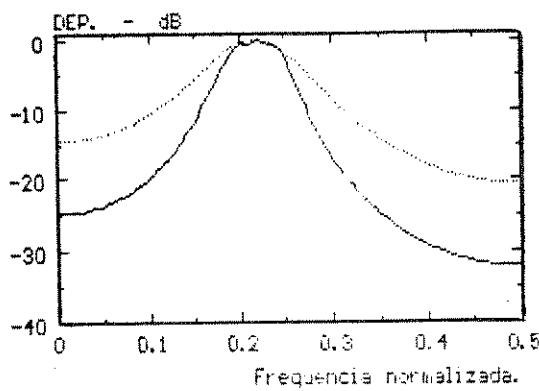
Podemos concluir que de fato a informação relevante do processo se encontra nas autocorrelações com índices pequenos. Também, a janela de ponderação atribui pesos bastantes semelhantes aos erros de aproximação das oito equações utilizadas, não produzindo, portanto, efeito significativo.



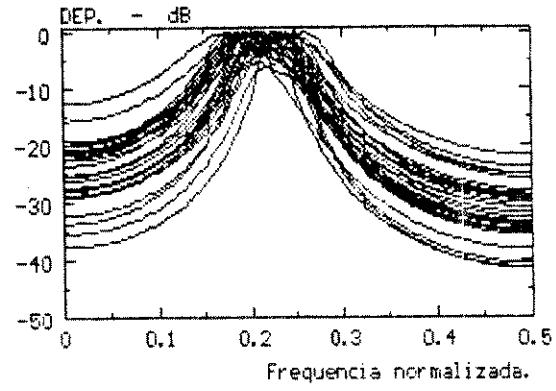
(a) média



(a) estimativas



(b) media

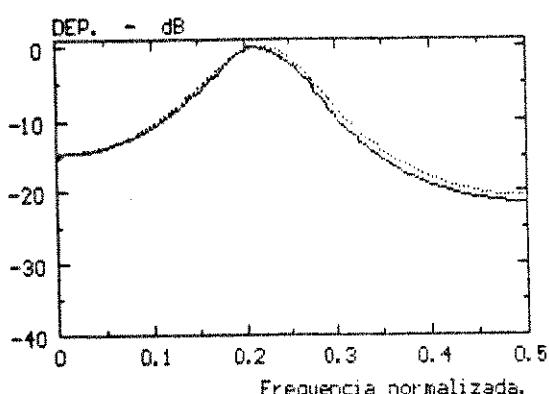


(b) estimativas

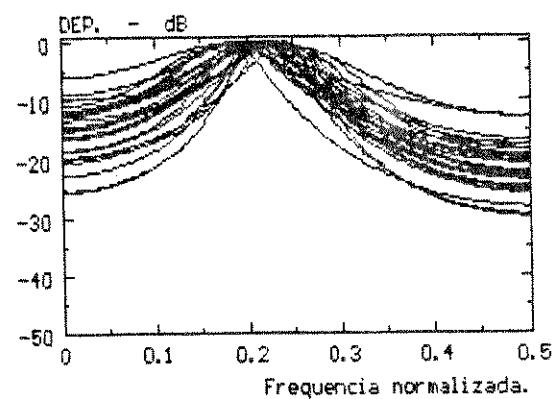
Figura 6.11 Estimativas do DEN-ARMA do Processo ARMA_{2,1}, para N=64 e Máximo de Equações: (a) Sem Ponderação,
(b) Ponderação com $(N-m)^3$.

As simulações com o conjunto de seqüências de 256 amostras são apresentadas nas figuras 6.13 e 6.14. A análise destas figuras leva às mesmas conclusões atingidas para o caso com 64 amostras. As curvas mais pronunciadas observadas nas estimativas da figura 6.14 são aqui consideradas atípicas.

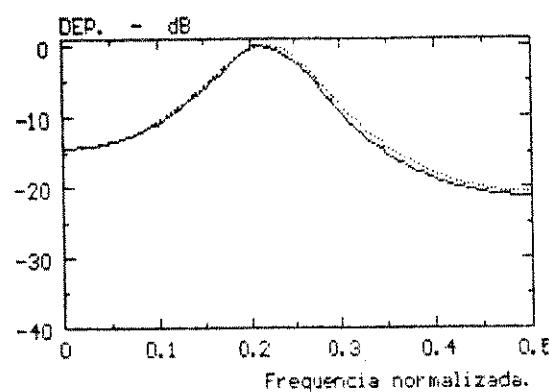
É interessante observar que as melhores estimativas do denominador espectral, aquelas das figuras 6.12 e 6.14, são bastante semelhantes entre si. Isto indica que mesmo 64 amostras são suficientes para obtermos boas estimativas do denominador espectral do



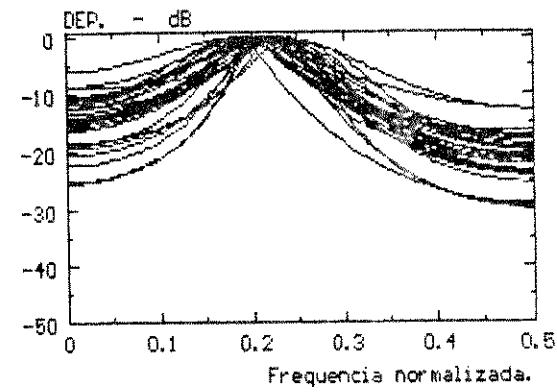
(a) média



(a) estimativas



(b) média

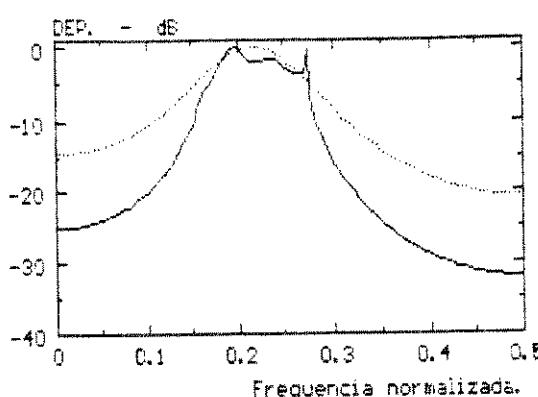


(b) estimativas

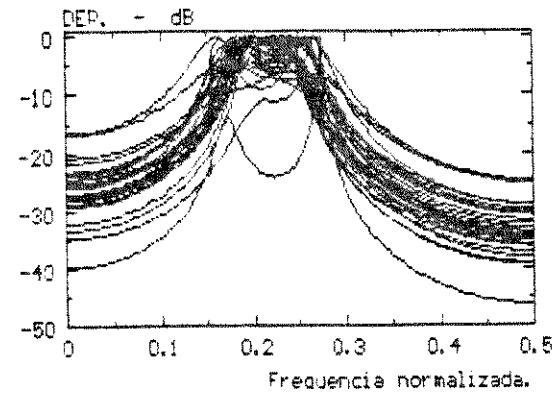
**Figura 6.12 Estimativas do DEN-ARMA do Processo ARMA₂, para N=64 e 8 Equações: (a) Sem Ponderação,
(b) Ponderação com $(N-m)^3$.**

processo ARMA₂. A suavidade de sua característica espectral assegura um decaimento suficientemente rápido da SAC como para permitir-nos o uso de poucas equações. Logo, necessitamos apenas das estimativas $r_{xx}^{(m)}$ próximas à origem do eixo m, as quais são bem estimadas a partir das 64 amostras.

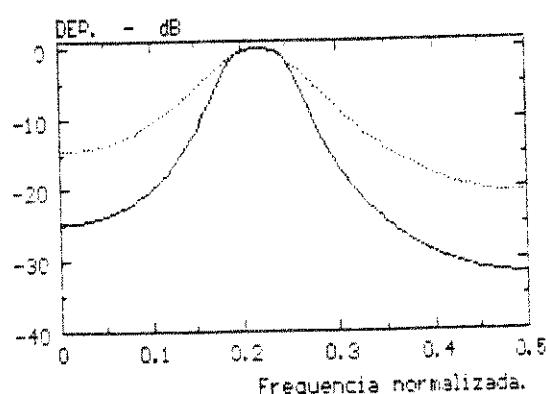
Por outro lado, a tendência de polarização no pico espectral se fêz sentir apenas com o uso do número máximo de equações, porém não foi atenuada com o aumento do número de amostras.



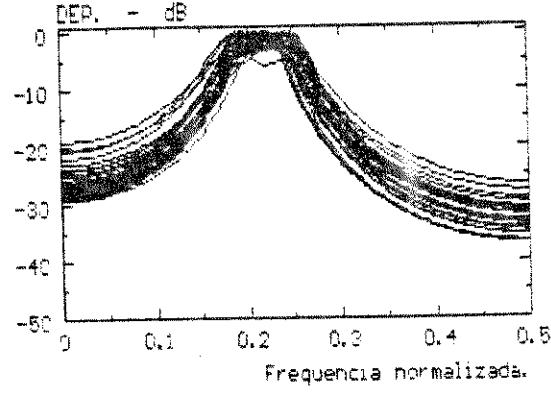
(a) média



(a) estimativas



(b) média



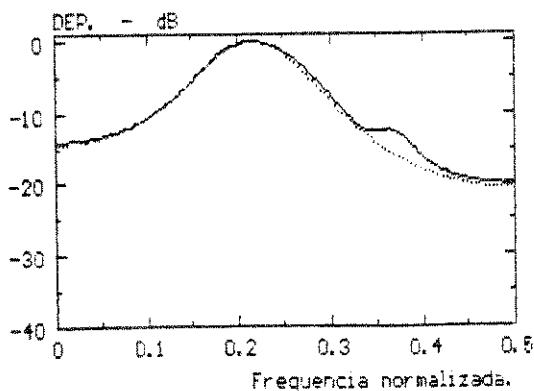
(b) estimativas

Figura 6.13 Estimativas do DEN-ARMA do Processo ARMA₂, para N=256 e Máximo de Equações: (a) Sem Ponderação, (b) Ponderação com (N-m)³.

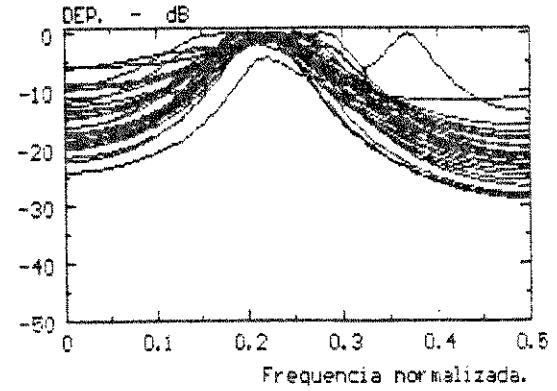
D. Estimativa do Denominador Espectral do Processo ARMA₃

O processo ARMA₃ tem os mesmos pólos do processo ARMA₂. Porém como seus zeros se encontram próximos à CRU, deverão afetar de forma adversa o desempenho do método MQEMYW, tal como ocorreu com o processo ARMA₁.

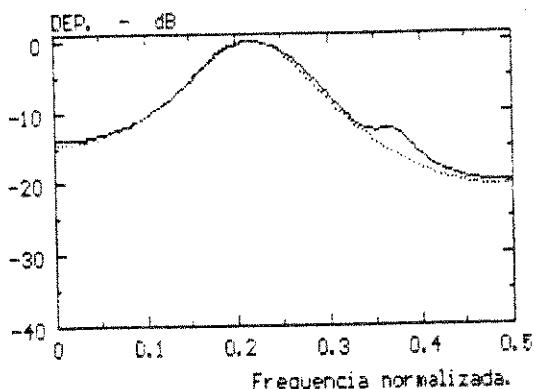
Nas figuras 6.15 e 6.16 são mostrados os resultados para N=64 amostras, enquanto que as figuras 6.17 e 6.18 se referem ao caso com 256 amostras.



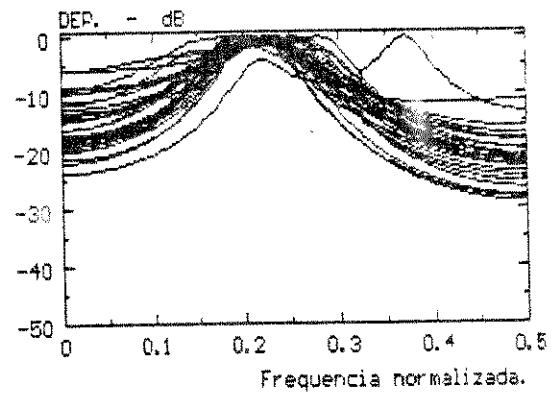
(a) média



(a) estimativas



(b) media

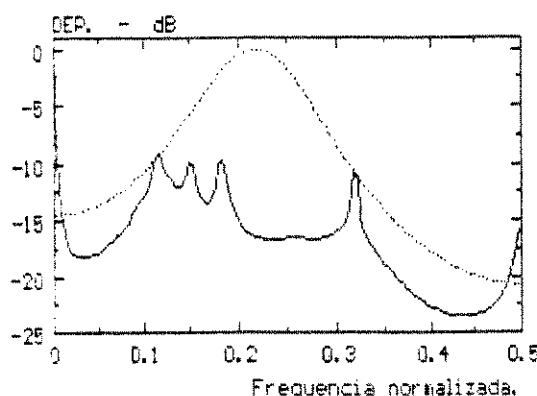


(b) estimativas

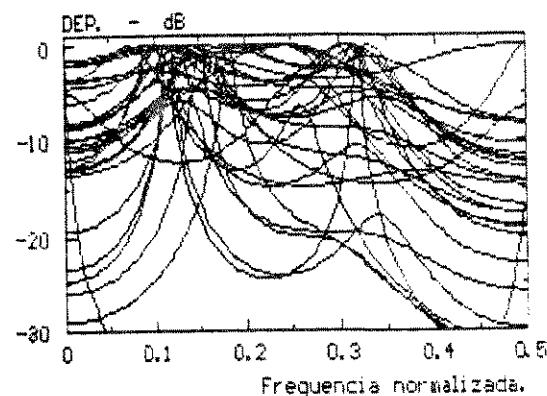
Figura 6.14 Estimativas do DEN-ARMA do Processo ARMA₂, para N=256 e 8 Equações: (a) Sem Ponderação,
 (b) Ponderação com $(N-m)^3$.

Das figuras 6.15 e 6.16 observamos que com 64 amostras o desempenho do método foi muito ruim tanto para o máximo de equações como para 8 equações.

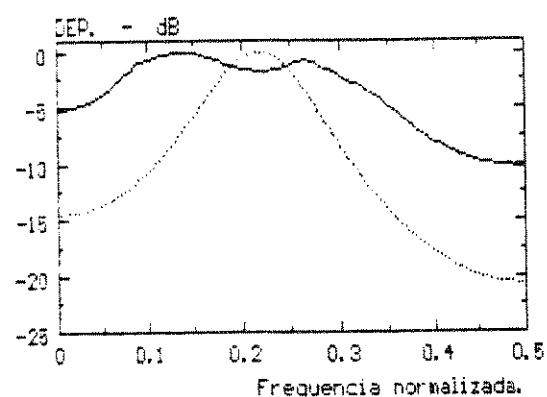
Para N=256, figuras 6.17 e 6.18, o aumento do número de amostras e, portanto, a melhor qualidade das estimativas de autocorrelação, permitiu um aumento no desempenho. Entretanto, mesmo no melhor caso, com o número pequeno de equações, o desempenho ainda é bastante ruim.



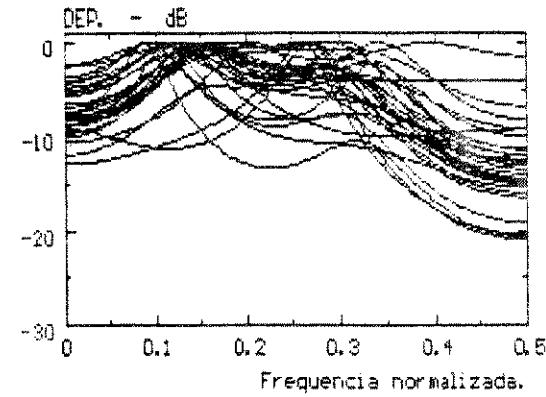
(a) média



(a) estimativas



(b) média



(b) estimativas

Figura 6.15 Estimativas do DEN-ARMA do Processo ARMA_3 , para $N=64$ e Máximo de Equações: (a) Sem Ponderação,
(b) Ponderação com $(N-m)^2$.

Fica evidente ao compararmos os resultados para os processos ARMA_2 e ARMA_3 , que a presença dos zeros deste último, localizados entre os pólos e próximos à CRU, afeta de forma drástica o desempenho do método MQEMYW. Ocorre uma polarização nas estimativas das freqüências destes pólos, gerando duas elevações espectrais ligeiras adjacente à posição onde deveria ocorrer o pico espectral largo, presente na curva espectral teórica do denominador do ARMA_3 . Tudo se passa como se houvesse uma tentativa de reproduzir a curva espectral completa deste processo. Acreditamos que de fato esta é

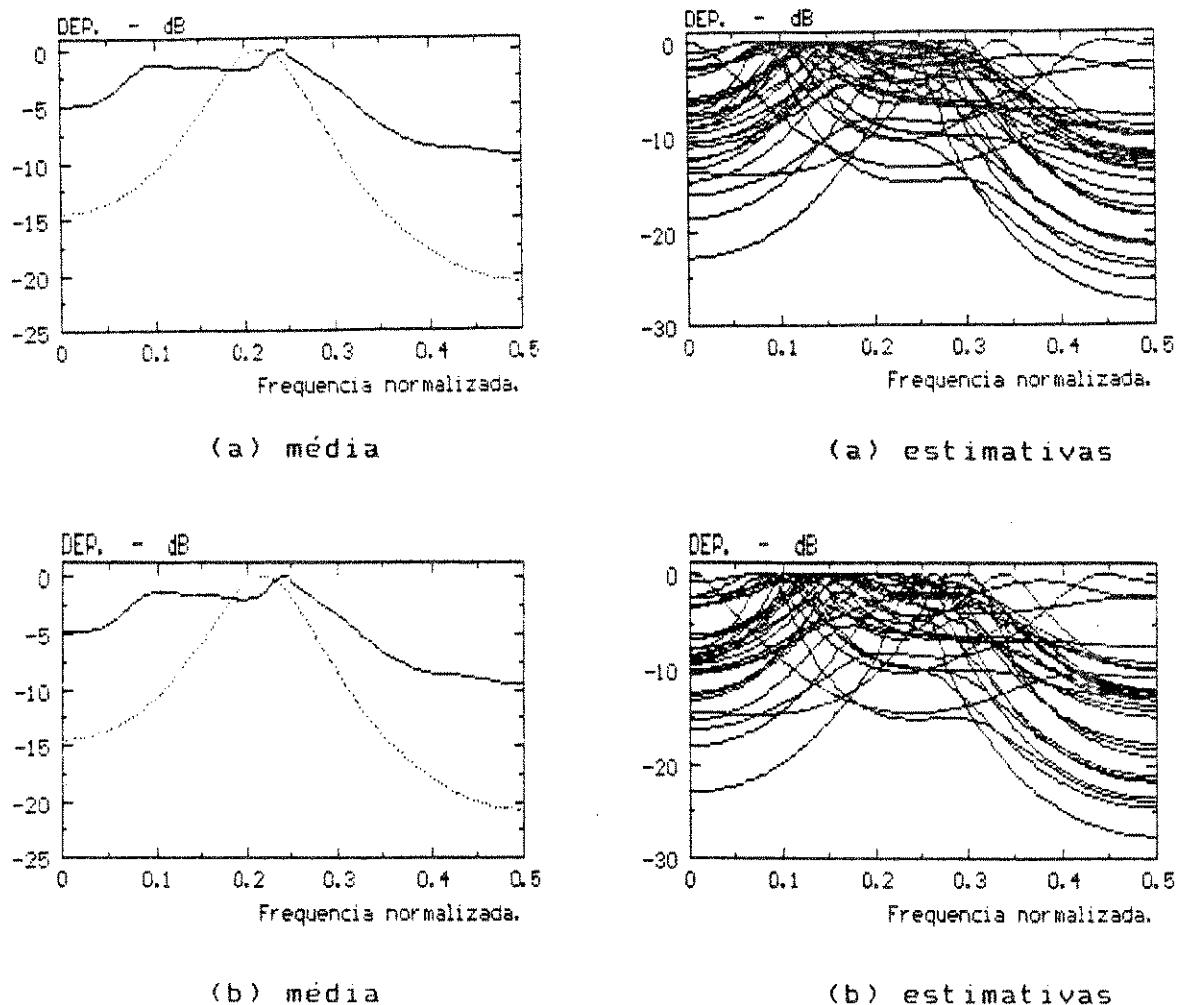
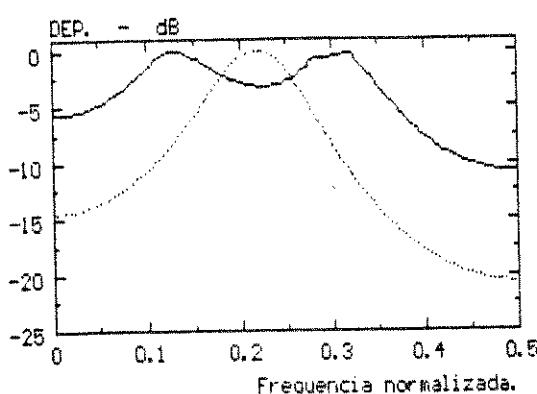
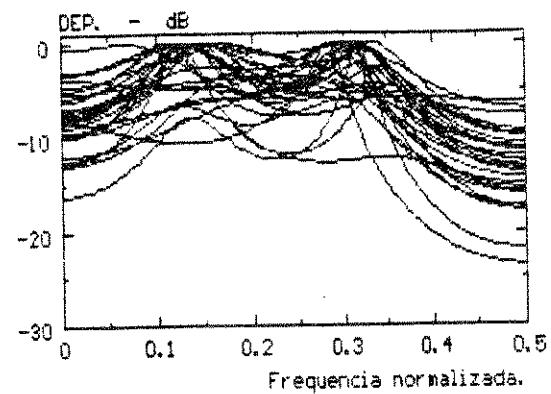


Figura 6.16 Estimativas do DEN-ARMA do Processo ARMA_{3,3}, para N=64 e 8 Equações: (a) Sem Ponderação, (b) Ponderação com $(N-m)^3$.

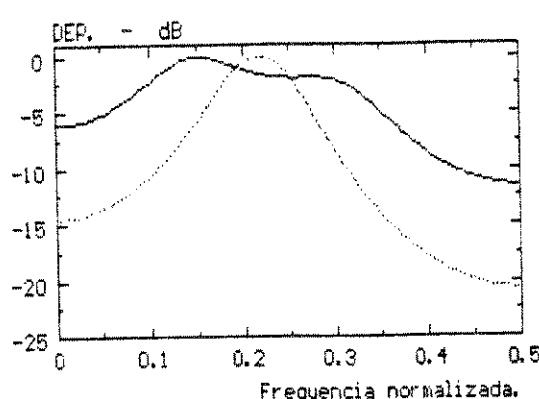
a explicação para os resultados, e é uma consequência da tentativa de estimar de forma separada os efeitos dos pólos e dos zeros. Enquanto estamos estimando os parâmetros do denominador ARMA de forma isolada, não há como direcionar o processo de estimativa no sentido de se ater apenas às características do denominador, uma vez que são as amostras do processo ARMA que proporcionam as informações para tal estimativa. Por esta análise, somente através de estimativas simultâneas de numerador e denominador é que poderíamos atingir melhores resultados.



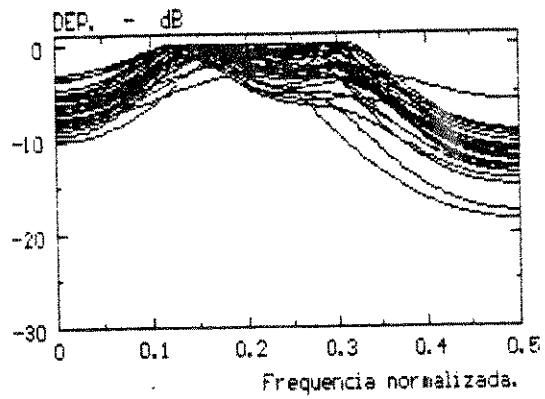
(a) média



(a) estimativas



(b) média

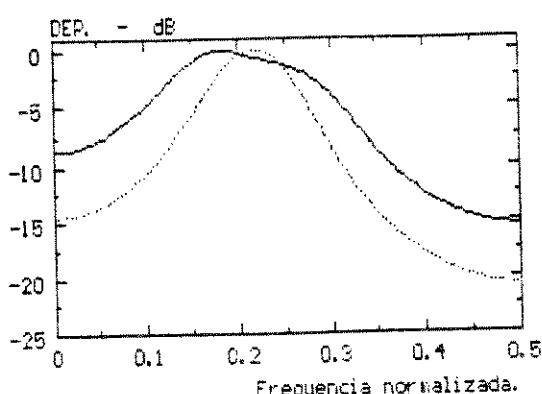


(b) estimativas

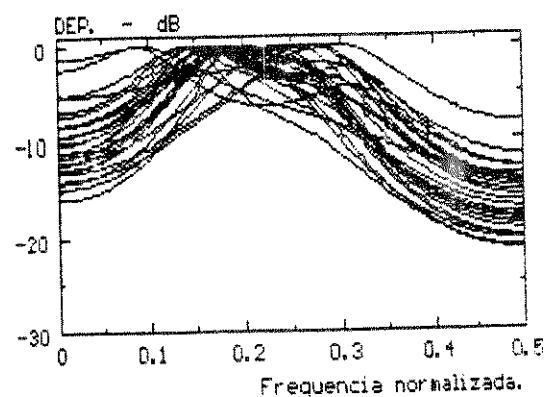
Figura 6.17 Estimativas do DEN-ARMA do Processo ARMA₃, para N=256 e Máximo de Equações: (a) Sem Ponderação, (b) Ponderação com $(N-m)^3$.

E. Conclusões gerais

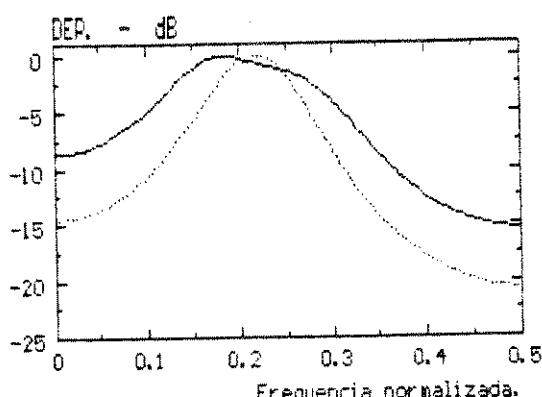
Os resultados obtidos na estimativa do denominador espectral dos quatro processos ARMA(4, 2) através do método MQEMYW permitiram concluir que a localização dos pólos condiciona o número de equações a ser utilizado. Tal número deve ser elevado quando os pólos se encontram perto da CRU, e próximo do mínimo quando se encontram afastados. Também, o uso da ponderação é necessário



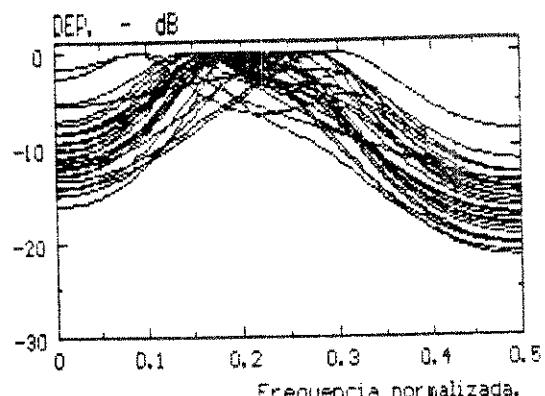
(a) média



(a) estimativas



(b) média



(b) estimativas

**Figura 6.18 Estimativas do DEN-ARMA do Processo $ARMA_3$, para $N=256$ e 8 Equações: (a) Sem Ponderação,
(b) Ponderação com $(N-m)^2$.**

quando o número de equações é elevado mas não produz efeitos significativos quando o número de equações é pequeno. Os dois tipos de ponderação examinados produziram resultados bastante semelhantes. Em função disto optou-se por um deles em particular o tipo $(N-m)^2$.

Os resultados confirmaram também que os conceitos teóricos desenvolvidos na seção 6.2 sobre a aplicação do método MQEMYW. De fato o desempenho do método mostrou ser altamente dependente da localização dos pólos do processo a ser analisado. Da mesma forma, confirmou-se a previsão de que o número adequado de equações seria

função das características espectrais do processo sob análise.

A constatação do efeito da localização dos zeros do processo sob análise no desempenho do método, principalmente quando os pólos se encontram afastados e os zeros próximos à CRU, permitiu observar a limitação natural da estratégia de estimativa separada: não conseguimos isolar os efeitos de tais zeros sobre a estimativa do DEN-ARMA. Assim, as estimativas deste tendem a reproduzir as características que deveriam ser retratadas pelas estimativas do NUM-ARMA.

Observamos também que o método MQEMYW apresenta polarização na estimativa dos picos espectrais, a qual tende a realçar tais picos, ou seja, existe uma polarização na estimativa da posição dos pólos na direção radial, com tendência a localizá-los exageradamente próximos à CRU.

Finalmente, os resultados mostraram que o melhor desempenho do método MQEMYW ocorre quando os pólos e zeros se encontram afastados da CRU. O desempenho ainda é satisfatório quando os pólos se aproximam da CRU mas os zeros permanecem afastados, ou quando os pólos e zeros se aproximam da CRU, porém também próximos entre si. O pior desempenho ocorre com pólos afastados e zeros próximos à CRU, porém todos situados em posições angulares próximas entre si.

6.5.3 Estimação do Numerador Espectral com Base no Método de Durbin

Nesta seção serão apresentados os resultados das estimativas da DEP completa dos quatro processos ARMA(4, 2), utilizando o método de Durbin para a avaliar o numerador espectral. Nestas simulações foram utilizadas algumas das estimativas do denominador espectral de cada processo.

Temos por objetivo destacar que a qualidade das estimativas da DEP depende da qualidade das estimativas dos parâmetros auto-regressivos, confirmar as conclusões sobre o método MQEMYW obtidas quando das estimativas do denominador espectral e confirmar as conclusões do capítulo 5 sobre as estimativas espectrais MA, agora dentro do contexto da estimativa do numerador espectral ARMA.

Com base nos resultados da seção 5.4, os métodos utilizados para obter o modelo AR longo e a ordem atribuída a este, foram:

- método Autocorrelação com a ordem do modelo AR longo igual a $ND/5$ (ordem adequada para processos MA sem vales abruptos na DEP).

- método Covariância Modificado com a ordem do modelo AR longo igual a $ND/3$ (ordem adequada neste método para processos MA com vales abruptos na DEP).

onde $ND=N-p$, é o número de amostras na saída do filtro que gera o sinal residual MA a partir das amostras $x[n]$ do processo ARMA, N é o número de amostras disponíveis e p é a ordem auto-regressiva assumida.

É importante observar que consideraremos apenas as amostras do sinal residual MA produzidas quando todos os registros do filtro contém amostras $x[n]$. Serão desprezadas aquelas referentes às situações onde nem todos os registros contêm amostras.

No decorrer desta, sempre que tratarmos dos métodos Autocorrelação e Covariância Modificado, estaremos nos referirmos ao seu uso na obtenção do modelo AR longo no método de Durbin. Também, utilizaremos apenas as estimativas do denominador espectral obtidas com a ponderação do tipo $(N-m)^3$.

A. Estimativas da DEP do Processo $ARMA_0$

Para este processo $ARMA_0$, com pólos próximos à CRU e zeros afastados, o método MQEMYW apresentou melhor desempenho quando utilizamos o máximo de equações e ponderação. Entretanto, calculamos as estimativas da DEP para as seguintes estimativas do denominador espectral: número máximo de equações e ponderação, 16 equações com e sem ponderação, 8 equações e ponderação, tanto para 64 como para 256 amostras.

Os melhores resultados obtidos são apresentados nas figuras 6.19 e 6.20 para as seqüências com 64 amostras e figuras 6.21 e 6.22 para as seqüências com 256 amostras.

Analisando inicialmente a qualidade destas estimativas em relação às estimativas do denominador espectral, constatamos que o conjunto de estimativas da DEP do processo $ARMA_0$ mostrou (independ-

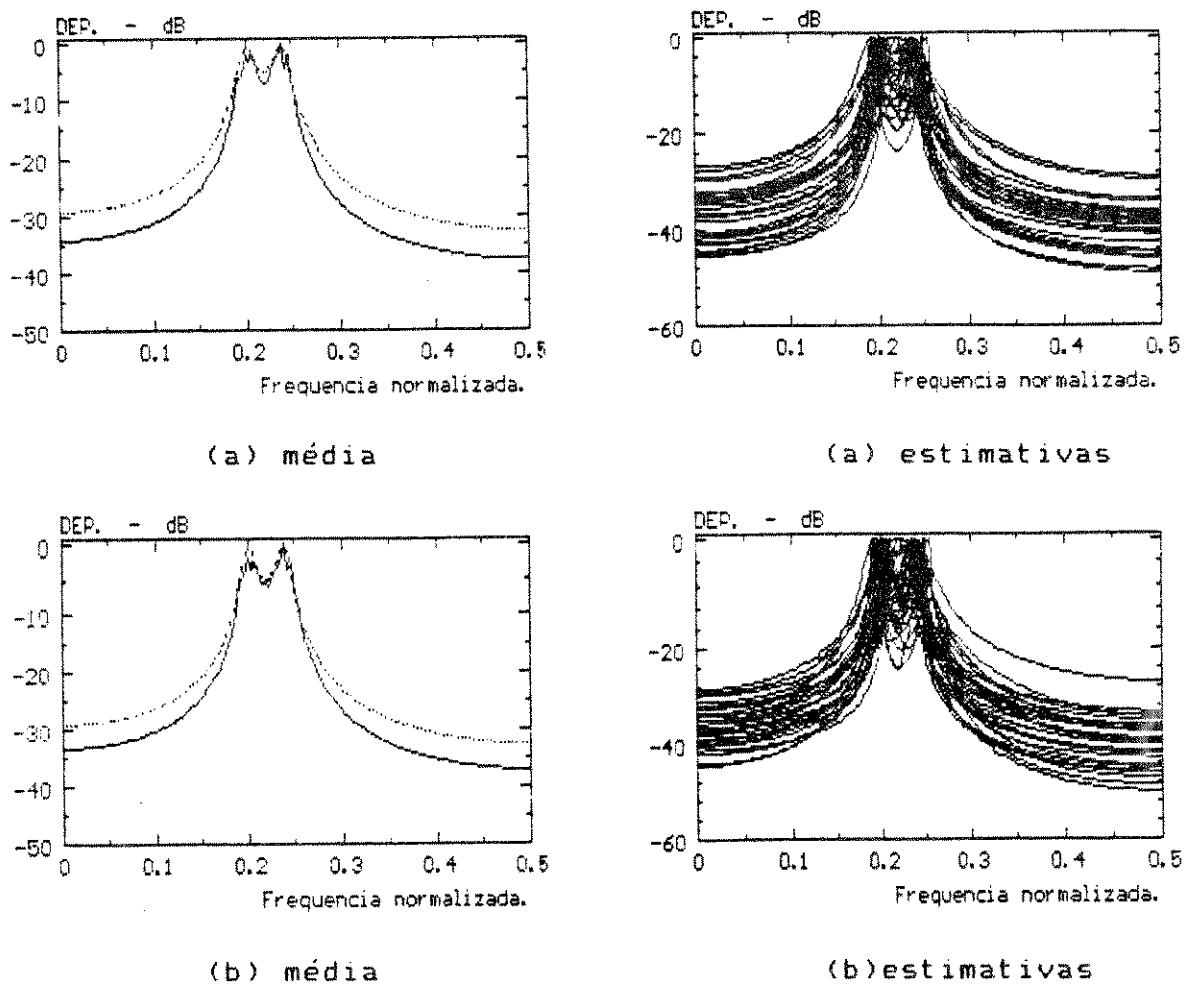
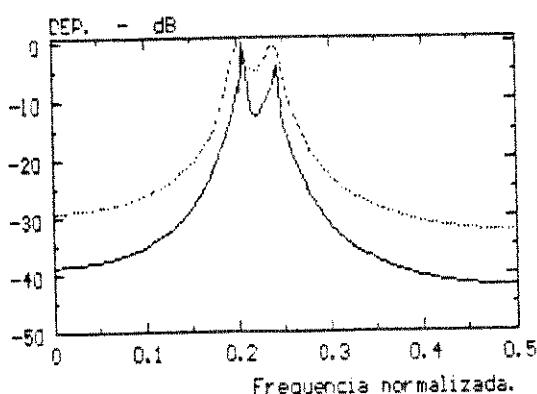


Figura 6.19 Estimativas da DEP do Processo ARMA_e : N=64, Máximo de Equações, Ponderação $(N-m)^3$ e

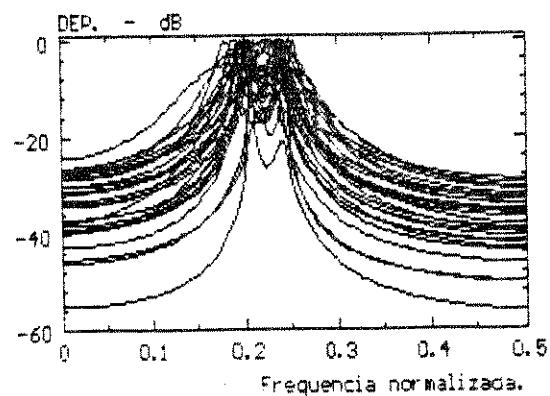
- (a) Método Autocorrelação,**
- (b) Método Covariância Modificado.**

dente dos métodos Autocorrelação e Covariância Modificado) o mesmo padrão observado nas estimativas do denominador espectral, ou seja:

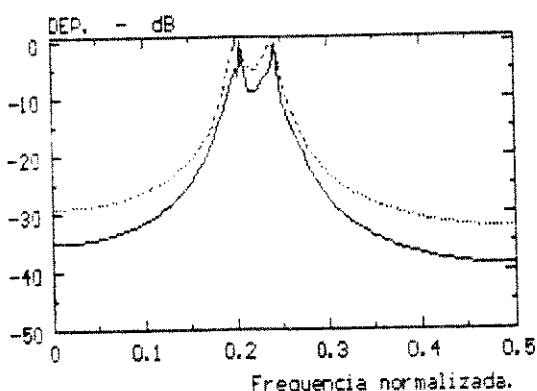
- para N=64, as melhores estimativas espetrais foram obtidas com o máximo de equações e ponderação.
- para N=256, tal como na estimativa do DEN-ARMA, foram obtidas boas estimativas espetrais, exceto no caso com o máximo de equações e ausência de ponderação. E, com base nos gráficos das estimativas, as melhores foram aquelas quando do máximo de equações e ponderação.



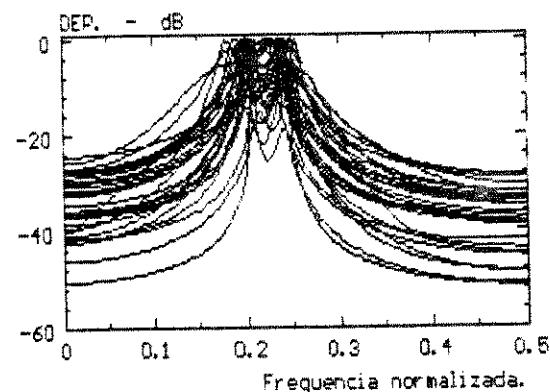
(a) média



(a) estimativas



(b) média



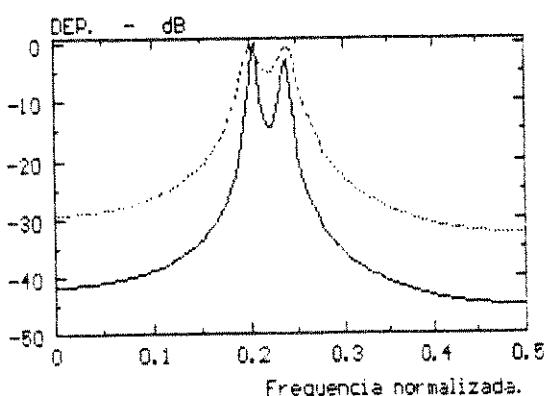
(b) estimativas

Figura 6.20 Estimativas da DEP do Processo ARMA_{2,1}: N=64, 16 Equações, Ponderação $(N-m)^3$ e
(a) Método Autocorrelação,
(b) Método Covariância Modificado.

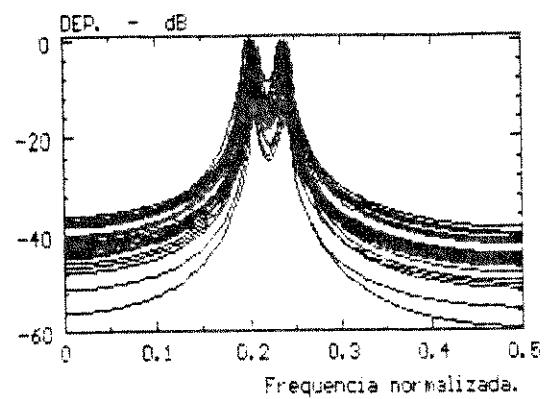
- a qualidade aumenta com a elevação do número de amostras.

Temos aqui uma primeira comprovação de que a qualidade da estimativa da DEP-ARMA depende do grau de qualidade das estimativas do denominador espectral.

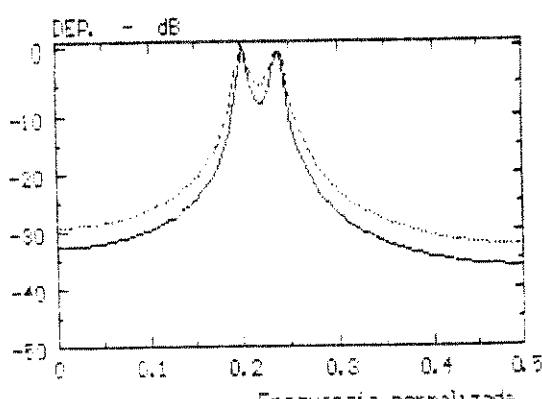
Analisando a qualidade dos resultados em relação à estimação do numerador espectral constatamos que:



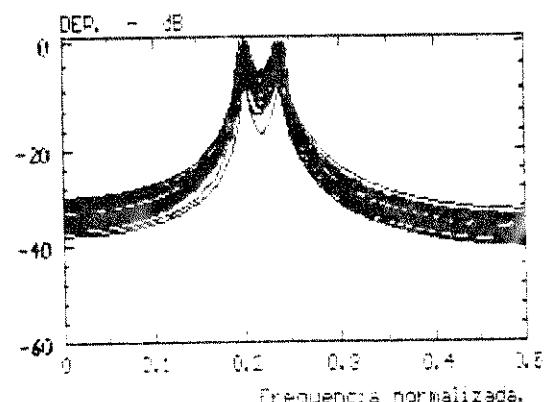
(a) média



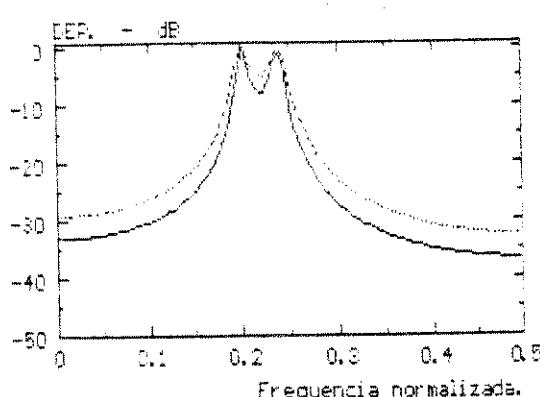
(a) estimativas



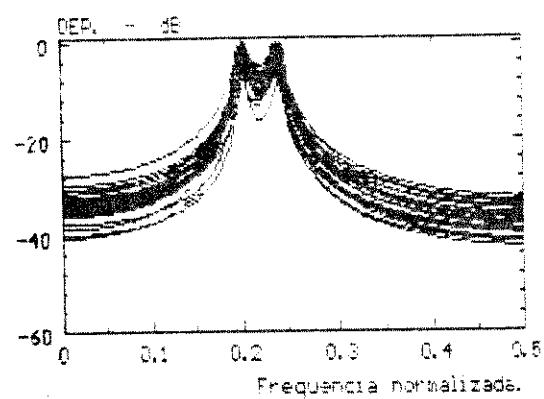
(b) média



(b) estimativas



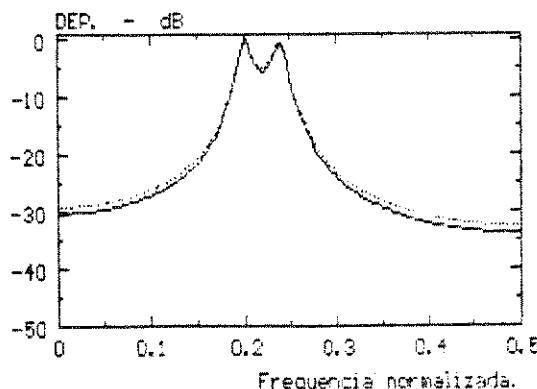
(c) média



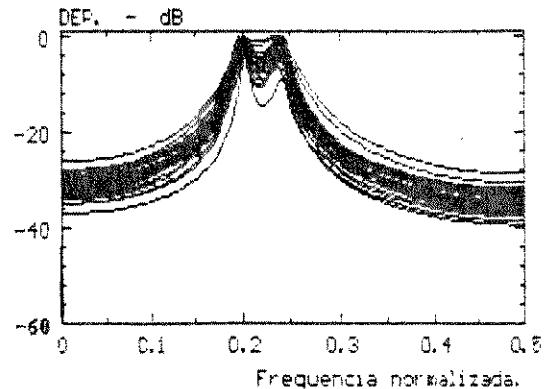
(c) estimativas

Figura 6.21 Estimativas da DEP do Processo ARMA_{2,1}: N=256, Número Máximo de Equações

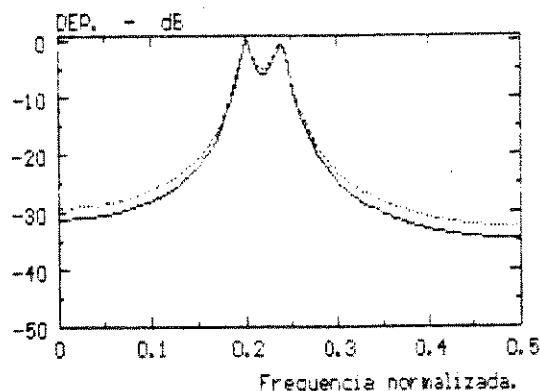
(a) Sem Ponderação, Método Autocorrelação,
 (b) Ponderação (N-m)³, Método Autocorrelação,
 (c) Ponderação (N-m)³, Método Covariância Modificado.



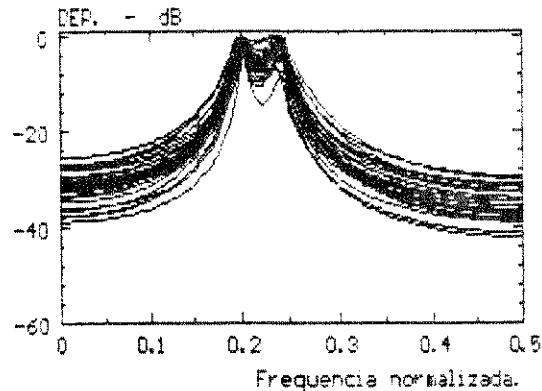
(a) média



(a) estimativas



(b) média



(b) estimativas

Figura 6.22 Estimativas da DEP do Processo ARMA₉: N=256, 16 Equações, Ponderação (N-m)³ e
(a) Método Autocorrelação,
(b) Método Covariância Modificado.

- em geral, as diferenças entre as estimativas espectrais com os métodos Autocorrelação e Covariância Modificado foram pequenas. Este resultado era esperado uma vez que os zeros da parte MA se encontram afastados da CRU e, portanto, não há vales espectrais abruptos.

- com 64 amostras, não foram significativas as diferenças entre as estimativas espectrais com estes métodos, principalmente para o caso com o máximo de equações e ponderação.

- com 256 amostras, a qualidade das estimativas espectrais foram ligeiramente melhores com o método Autocorrelação.

Embora a ordem atribuída ao modelo AR longo no método Covariância Modificado seja aquela adequada para estimativas espectrais MA de processos com zeros próximos à CRU, tal fato não apresentou influência negativa na estimativa da DEP do processo ARMA₆.

Dado que o método Covariância Modificado requer um esforço computacional maior que o Autocorrelação e as diferenças entre as estimativas fornecidas por ambos são pequenas, concluimos que este último deve ser escolhido para estimar o NUM-ARMA de processos com zeros afastados da CRU, como o ARMA₆.

B. Estimativas da DEP do Processo ARMA₄

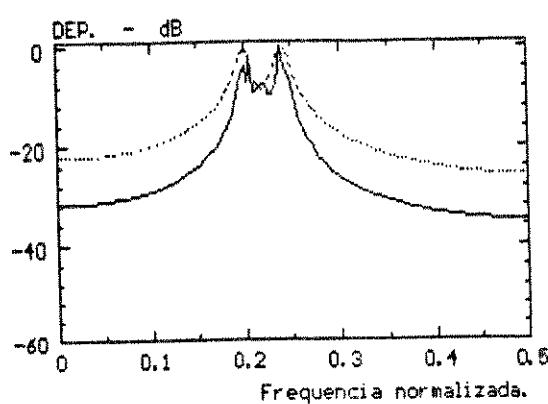
No processo ARMA₄ (com pólos e zeros próximos à CRU) o método MQEMYW, quando das seqüências com 64 amostras, mostrou desempenho semelhante entre os casos ponderados com 16 equações e com o número máximo de equações; quando das seqüências com 256 amostras, o melhor desempenho foi o obtido com máximo de equações e ponderação.

As estimativas do denominador espectral utilizadas para estimar a DEP foram, com 64 e 256 amostras: máximo e 16 equações, ambas com e sem ponderação e 8 equações com ponderação.

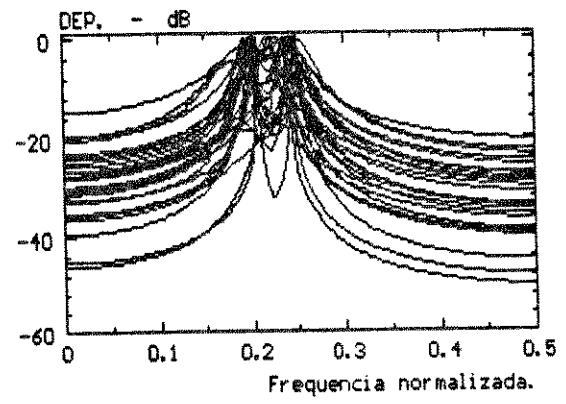
Parte dos resultados obtidos são apresentados na figura 6.23 para as seqüências com 64 amostras e figura 6.24 para as seqüências com 256 amostras.

Observamos que as melhores estimativas da DEP com 256 amostras provêm do caso com máximo de equações e ponderação, enquanto que para 64 amostras não houve aumento significativo de qualidade ao aumentar-se o número de equações. Estas foram as conclusões quando das estimativas do denominador espectral, confirmando a importância da qualidade destas.

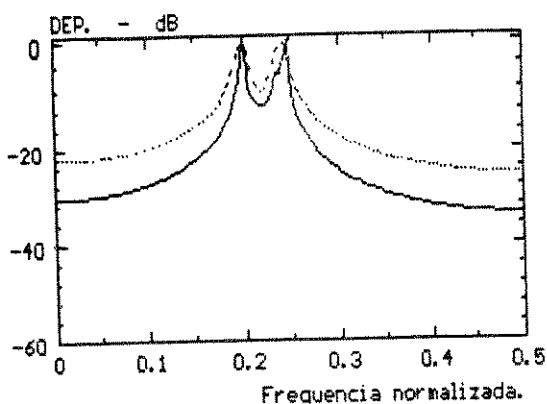
Tal como no processo ARMA₆, observamos nas estimativas da DEP que, em geral, as diferenças entre os resultados atingidos com os métodos Autocorrelação e Covariância Modificado foram pequenas. Independente do número de amostras, ambos métodos forneceram bons resultados.



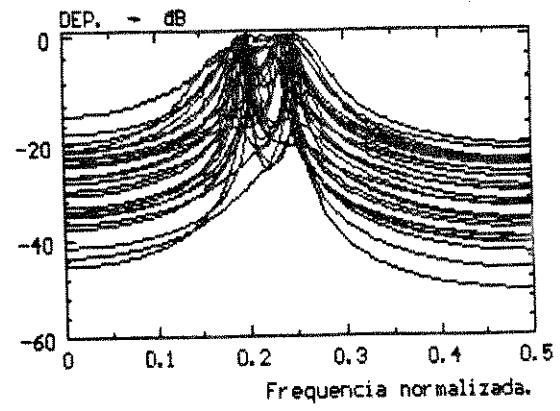
(a) média



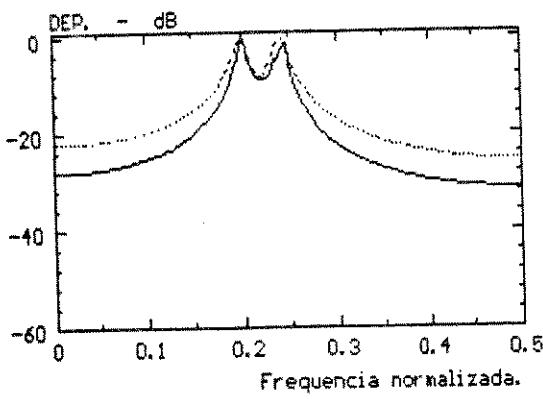
(a) estimativas



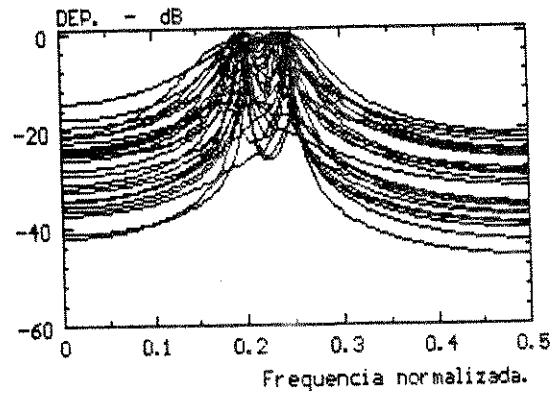
(b) média



(b) estimativas



(c) média



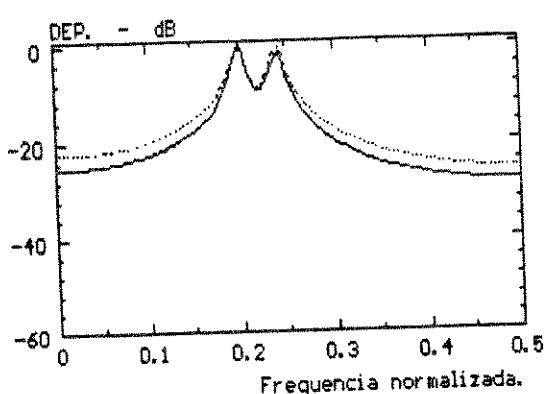
(c) estimativas

Figura 6.23 Estimativas da DEP do Processo ARMA₁: N=64, Ponderação $(N-m)^3$ e

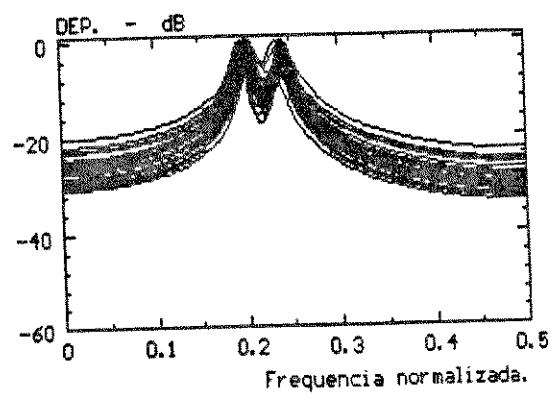
(a) Máximo de Equações, Método Autocorrelação,

(b) 16 Equações, Método Autocorrelação,

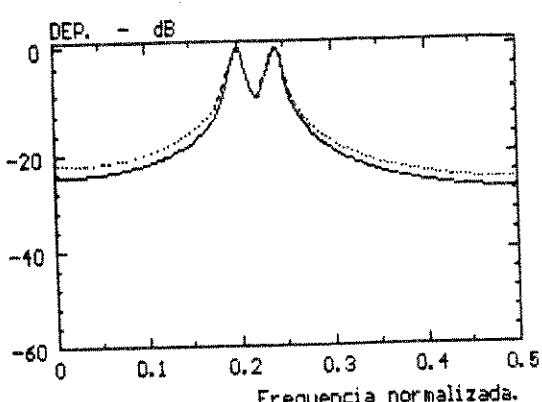
(c) 16 Equações, Método Covariância Modificado.



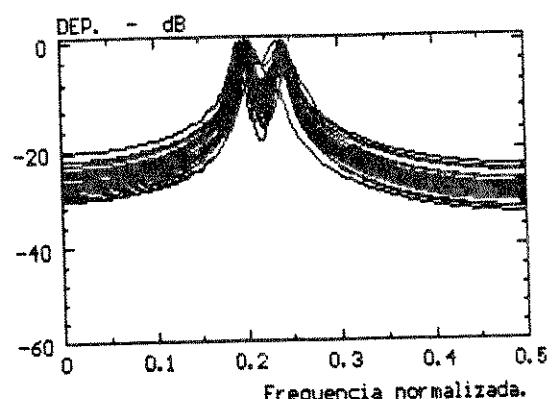
(a) média



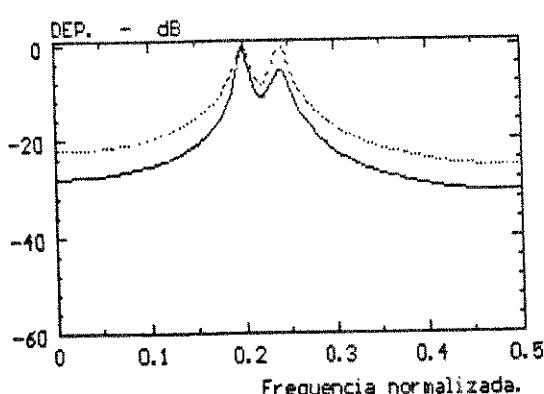
(a) estimativas



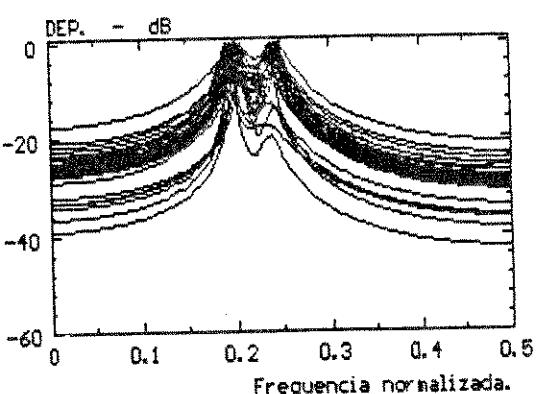
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.24 Estimativas da DEP do Processo ARMA₁: N=256, Ponderação $(N-m)^3$ e
(a) Máximo de Equações, Método Autocorrelação,
(b) Máximo de Equações, Método Covariância Modificado,
(c) 16 Equações, Método Covariância Modificado.

O não haver diferenças significativas entre as estimativas espectrais obtidas com os métodos Autocorrelação e Covariância Modificado, é um resultado contrário àquele quando da estimativa, no capítulo 5, da DEP do processo MA_1 com zeros próximos à CRU, onde os resultados foram superiores com o método Covariância Modificado. Atribuimos isto à tendência do método MQEMYW de enfatizar os picos espectrais, a qual modelou o nulo espectral abrupto, do processo $ARMA_{1,2}$, quando da estimativa do denominador espectral.

C. Estimativas da DEP do Processo $ARMA_{1,2}$

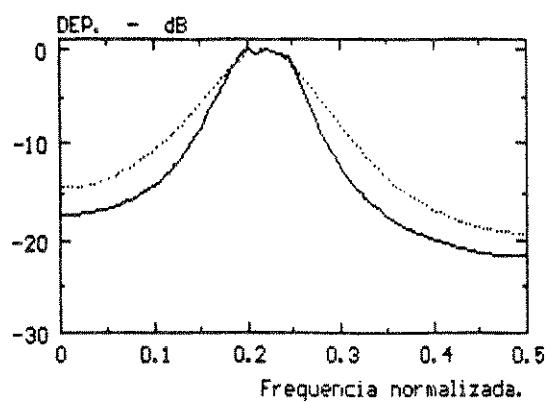
O processo $ARMA_{1,2}$ tem seus pólos e zeros afastados da CRU e o melhor desempenho do método foi obtido com o número pequeno de equações, $M-q=8$. Neste caso a ponderação não produziu efeitos significativos.

As estimativas do denominador espectral utilizadas para estimar a DEP foram, para $N=64$ e 256 amostras: o máximo e o número pequeno de equações, ambas com ponderação.

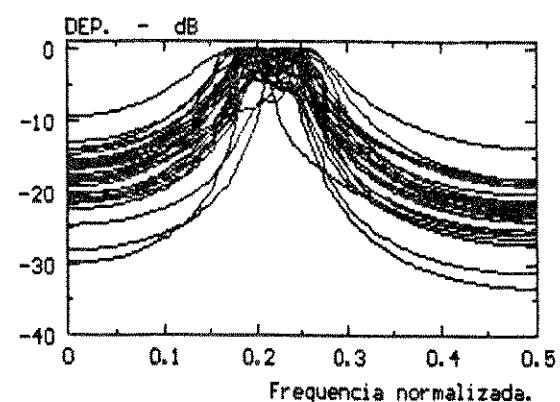
As figuras apresentadas são: figura 6.25 e figura 6.26 para as seqüências com 64 e 256 amostras, respectivamente.

Independente do uso do método Autocorrelação ou Covariância Modificado, as estimativas da DEP mostraram o mesmo padrão observado nas estimativas do denominador espectral, ou seja, as melhores estimativas espectrais foram obtidas com o número pequeno de equações. Entretanto, foi observado que as estimativas do denominador espectral com o número pequeno de equações, foram semelhantes para ambos conjuntos de amostras. Porém, o mesmo não aconteceu nas estimativas correspondentes da DEP, estas, com 256 amostras, apresentaram menor variação que aquelas obtidas com 64 amostras.

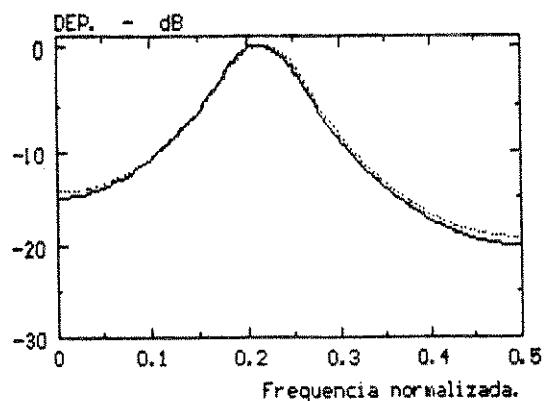
Como foi comentado quando da estimativa do denominador espectral deste processo, os "dados" do método MQEMYW são as estimativas da SAC, tal que se estas forem de boa qualidade o resultado final será bom (independente do número de amostras). Por outro lado, no método de Durbin, o desempenho dos métodos utilizados para obter o modelo AR longo depende muito do número de amostras disponíveis, sendo melhor quando este número é elevado. Daí a diferença agora observada na qualidade das estimativas espectrais em função do número de amostras.



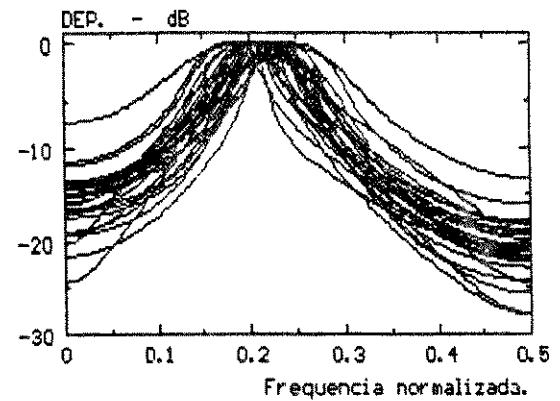
(a) média



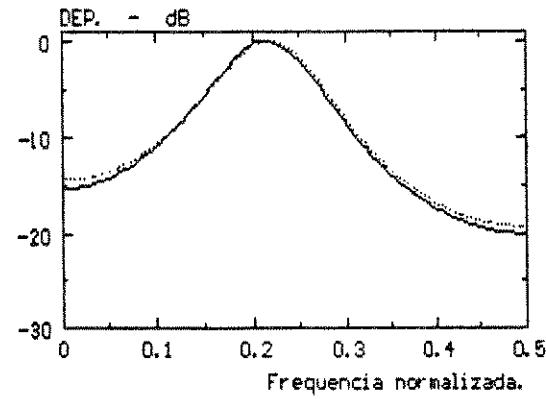
(a) estimativas



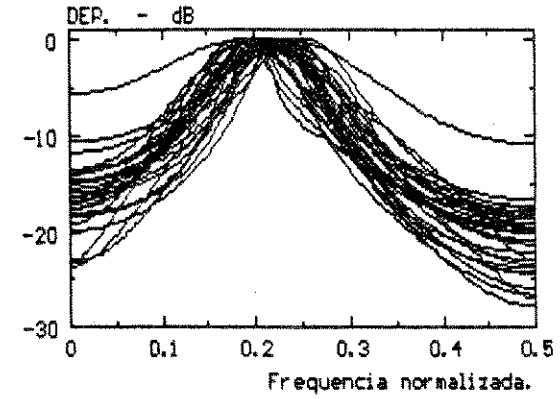
(b) média



(b) estimativas



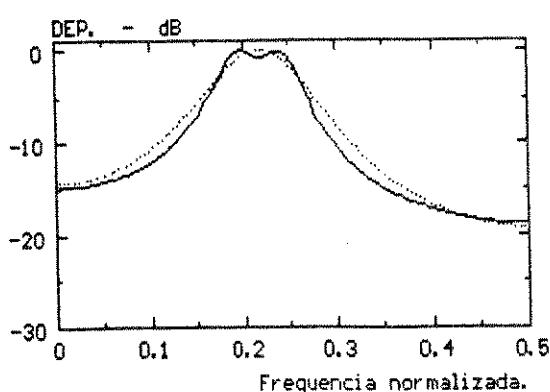
(c) média



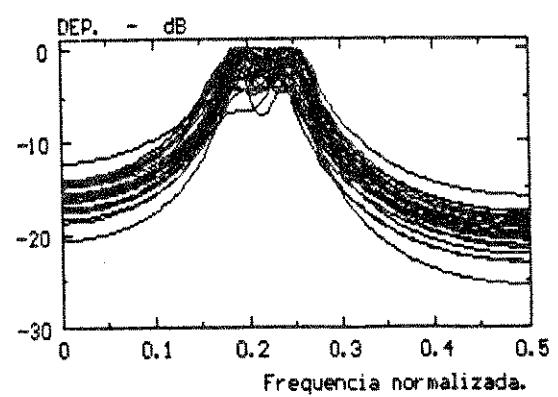
(c) estimativas

Figura 6.25 Estimativas da DEP do Processo ARMA₂: N=64, Ponderação (N-m)³ e

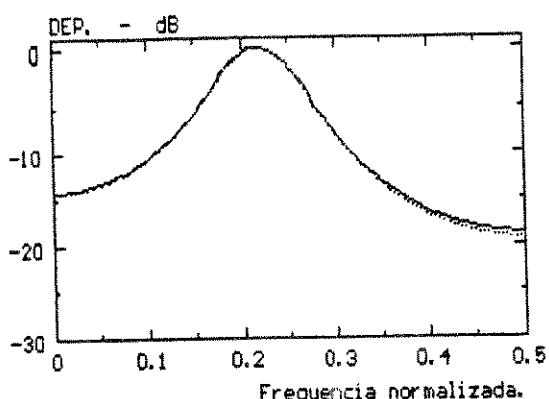
- (a) Máximo de Equações, Método Autocorrelação,**
- (b) 8 Equações, Método Autocorrelação,**
- (c) 8 Equações, Método Covariância Modificado.**



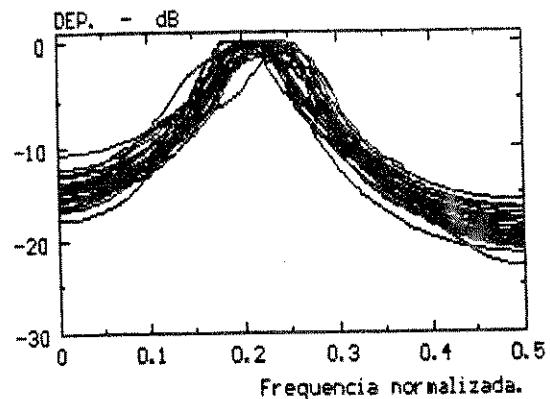
(a) média



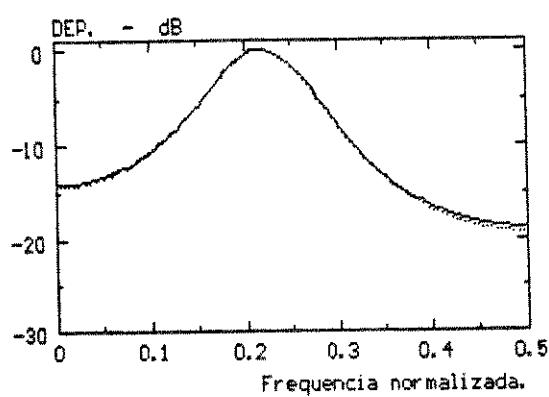
(a) estimativas



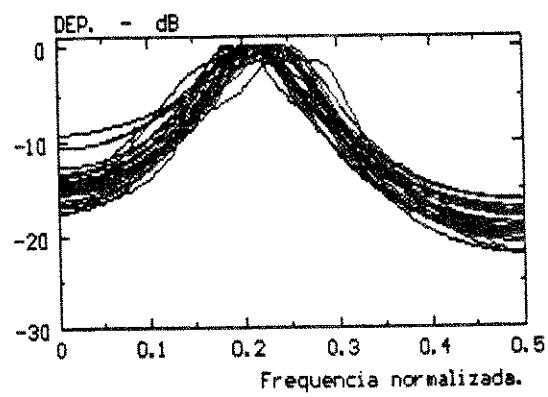
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.26 Estimativas da DEP do Processo ARMA₂: N=256, Ponderação (N-m)³ e

- (a) Máximo de Equações, Método Autocorrelação,
- (b) 8 Equações, Método Autocorrelação,
- (c) 8 Equações, Método Covariância Modificado.

Ambos os métodos, Autocorrelação e Covariância Modificado, apresentaram bom desempenho e não houve diferenças suficientes para destacar um deles. Isto era de se esperar, pois os zeros da parte MA do processo ARMA₂ se encontram muito próximos à origem da CRU.

D. Estimativa da DEP do Processo ARMA₃

Para este processo, com pólos afastados e zeros próximos à CRU, o método MQEMYW apresentou desempenho ruim para ambos conjuntos de amostras.

As estimativas do denominador espectral utilizadas para estimar a DEP foram, tanto para 64 como 256 amostras: máximo de equações, 16 equações e o número pequeno de equações M-q=8, todos com ponderação. Parte destes resultados são apresentados nas figuras 6.27 e 6.28 para as seqüências com 64 e 256 amostras, respectivamente.

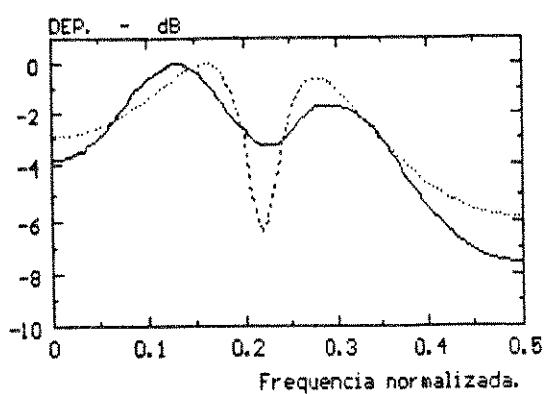
Todas as estimativas da DEP tiveram o mesmo padrão de baixa qualidade observado nas estimativas do denominador espectral, o que mostra de outra forma, a dependência das estimativas espetrais ARMA da qualidade das estimativas dos parâmetros auto-regressivos.

Podemos resumir os resultados obtidos da seguinte forma:

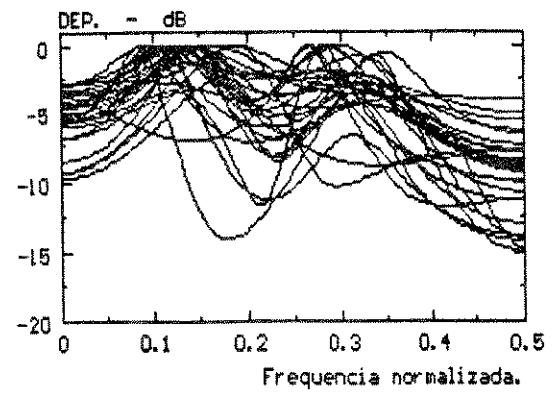
- com 64 amostras: todas as estimativas espetrais foram de baixa qualidade, tal que não é possível apontar o número de equações mais adequado no método MQEMYW, ou caracterizar qual dos métodos, Autocorrelação ou Covariância Modificado, foi o melhor.

- com 256 amostras: por dispormos de um maior número de amostras, a qualidade das estimativas foi melhor que no caso anterior, porém a polarização e variância ainda foram elevadas. Quanto ao número de equações no método MQEMYW e à comparação entre os métodos Autocorrelação e Covariância Modificado, repetimos os comentários acima.

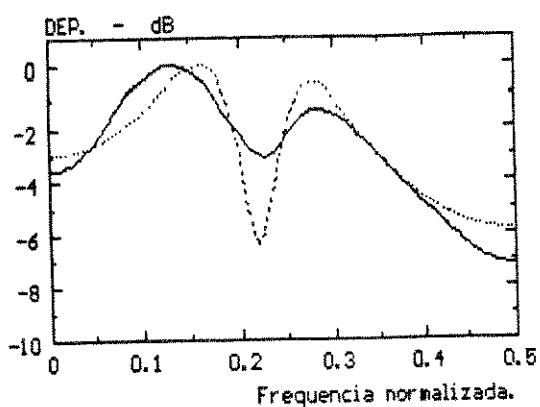
Uma vez que os parâmetros auto-regressivos não foram bem estimados, não há garantia de que o processo residual seja de fato uma aproximação da parte MA do processo ARMA₃. Com isto podemos reafirmar que o desempenho das técnicas de estimação separada depende fortemente da qualidade das estimativas do denominador ARMA.



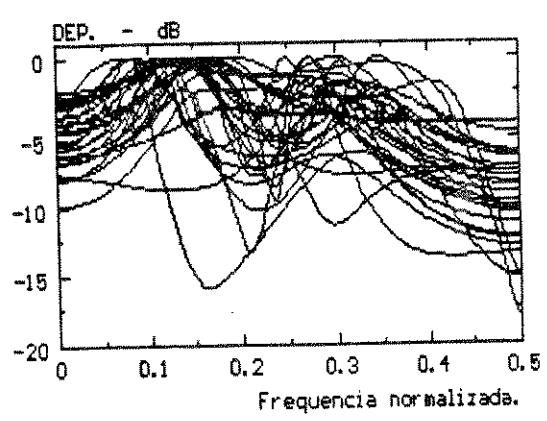
(a) média



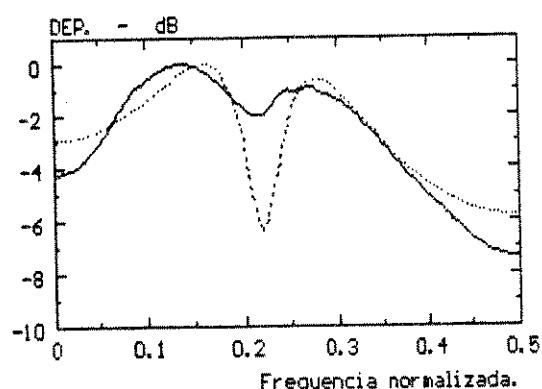
(a) estimativas



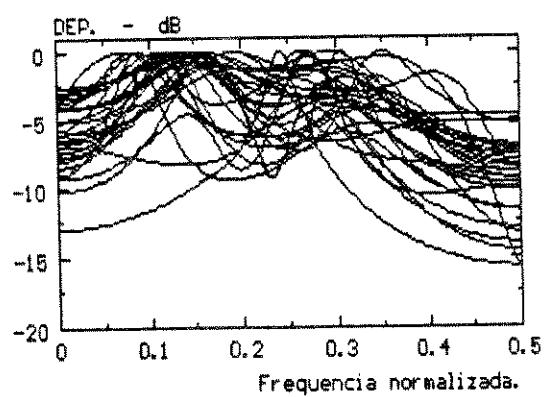
(b) média



(b) estimativas



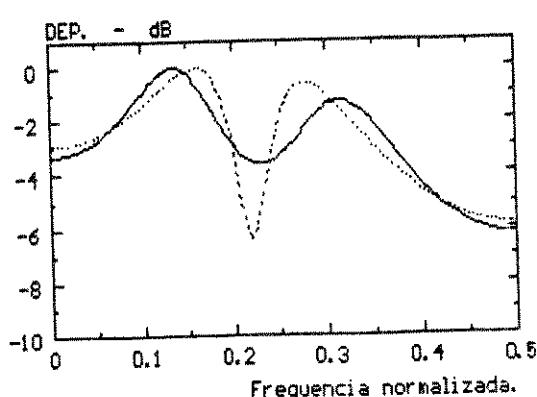
(c) média



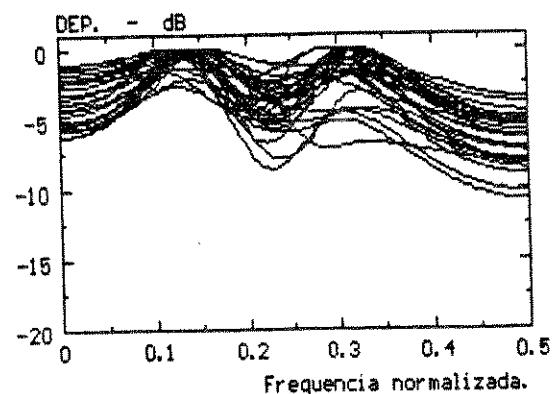
(c) estimativas

Figura 6.27 Estimativas da DEP do Processo ARMA₃: N=64, Ponderação $(N-m)^3$ e

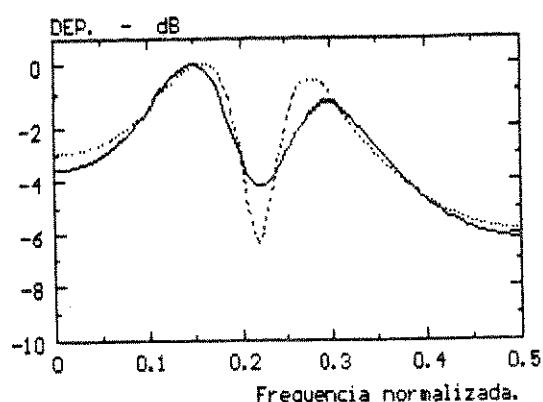
- (a) Máximo de Equações, Método Covariância Modificado,
- (b) 8 Equações, Método Covariância Modificado,
- (c) 8 Equações, Método Autocorrelação.



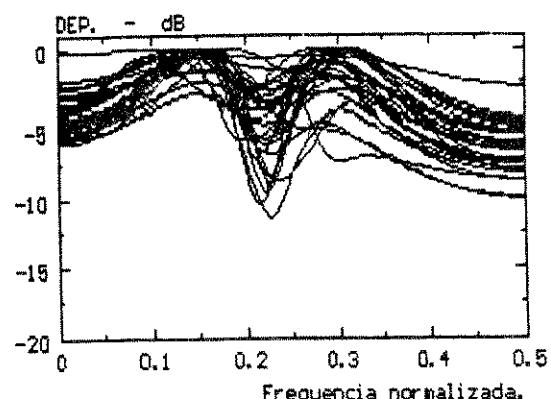
(a) média



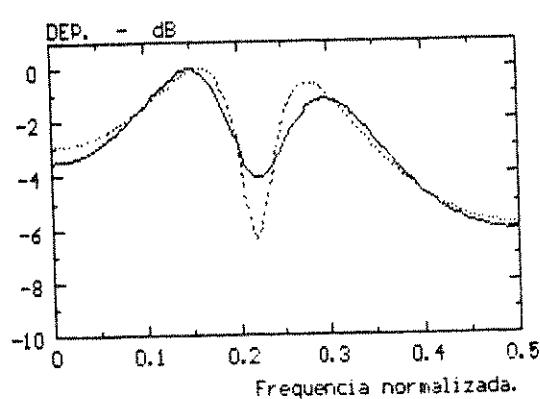
(a) estimativas



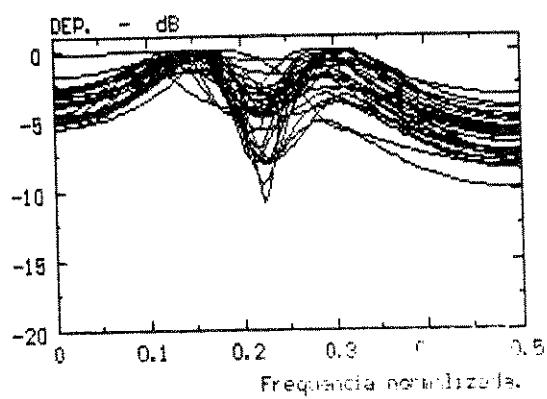
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.28 Estimativas da DEP do Processo ARMA₃: N=256, Ponderação $(N-m)^3$ e

- (a) Máximo de Equações, Método Covariância Modificado,
- (b) 8 Equações, Método Covariância Modificado,
- (c) 8 Equações, Método Autocorrelação.

Isto nos leva a concluir que os métodos sub-ótimos de estimação separada não são adequados para a estimativa espectral de processos com pólos afastados da CRU e zeros próximos a esta, como o ARMA₃, exceto quando dispomos de um número muito elevado de amostras ($N > 256$).

E. Conclusões gerais

Os resultados obtidos nesta seção confirmaram que quanto melhor as estimativas dos parâmetros auto-regressivos, melhor será a estimativa espectral. Em relação ao método MQEMYW, devemos utilizar um número elevado de equações e ponderação para processos com pólos próximos à CRU, independente da localização dos zeros e do número de amostras disponíveis. Porém, para processos com pólos e zeros afastados da CRU o número de equações deve ser pequeno, independente do número de amostras.

Em relação ao método de Durbin, é mais indicado utilizar o método Autocorrelação quando os zeros do processo ARMA se encontram afastados da CRU. O método Covariância Modificado deve ser empregado quando os zeros se encontram próximos à CRU, embora, para os casos aqui estudados, as diferenças entre os resultados dos dois métodos tenham sido pequenas, não confirmando as conclusões do capítulo 5. Atribuimos isto ao fato dos vales espectrais não terem sido abruptos e quando o foram, a qualidade das estimativas do denominador espectral não permitiu que as diferenças entre estes métodos se destacassem.

Os resultados nos permitiram concluir que os métodos sub-ótimos de estimação separada não são adequados para a estimativa espectral de processos ARMA com pólos afastados e zeros próximos à CRU, porém todos situados em posições angulares próximas entre si. Exceto quando o número amostras disponíveis é muito elevado, a qualidade das estimativas é ruim, particularmente na região do vale espectral.

Paralelamente, foram utilizados dois processos ARMA com picos estreitos próximos entre si, ARMA₆ e ARMA₁. As simulações mostraram que o uso do método MQEMYW neste tipo de processo conduz a

estimativas espectrais de alta resolução, desde que utilizado com máximo de equações e ponderação sobre os erros de aproximação. Esta característica é particularmente importante, pois indica que os métodos de estimação ARMA separada, são adequados para a estimativa espectral de processos AR (com pólos próximos à CRU) corrompidos por ruído, assim como para a detecção de senóides em ruído branco.

6.5.4 Estimação do Numerador Espectral com Base nos Métodos Correlograma e Periodograma

Nesta seção são apresentados os resultados das estimativas da DEP dos quatro processos ARMA(4, 2), utilizando os métodos Correlograma e Periodograma para estimar o numerador espectral, como descrito na seção 6.5

Temos por objetivo observar a viabilidade de se utilizar os estimadores espectrais clássicos sobre os processos residuais MA progressivos e sobre os processos residuais progressivos e regressivos simultaneamente, assim como também comparar estas estimativas com aquelas obtidas na seção anterior através do método de Durbin.

Seja ND o número de amostras na saída dos filtros progressivo e regressivo na condição "cheia". Tendo em conta os resultados da seção 5.5, escolhemos os seguintes parâmetros para os dois métodos:

- janela triangular de comprimento $2C+1$ e $C=ND/10$, com 64 e 256 amostras, para o método Correlograma.
- janela de Hamming, 50% de sobreposição entre segmentos e número de amostras por segmento igual a $ND/5$, para o caso de 64 amostras e $ND/10$ para 256 amostras, no Periodograma.

As estimativas dos parâmetros auto-regressivos utilizadas foram aquelas correspondentes ao melhor desempenho do método MQEMYW: para os processos ARMA_0 e ARMA_1 , máximo de equações e ponderação, para o processo ARMA_2 , número pequeno de equações, $M-q=8$, e ponderação. Para o processo ARMA_3 , optou-se pelo número pequeno de e-

quações e ponderação.

As figuras apresentadas para cada processo são:

- Processo ARMA₀: figura 6.29 com o método Correlograma e figura 6.30 com o método Periodograma.

- Processo ARMA₁: figura 6.31 com o método Correlograma e figura 6.32 com o método Periodograma.

- Processo ARMA₂: figura 6.33 com o método Correlograma e figura 6.34 com o método Periodograma.

- Processo ARMA₃: figura 6.35 com o método Correlograma e figura 6.36 com o método Periodograma.

Os resultados obtidos para os três primeiros processos foram semelhantes e são os seguintes:

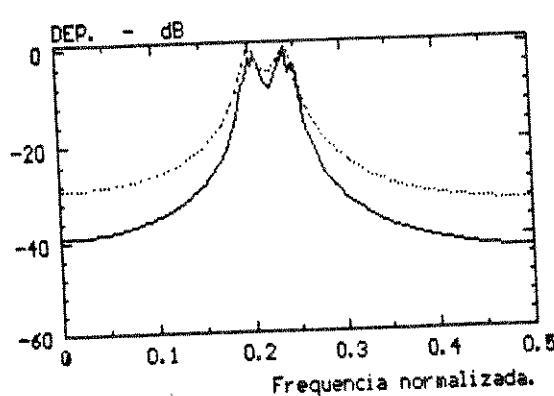
- a utilização dos resíduos progressivos-regressivos, tanto no Correlograma como no Periodograma, propiciou resultados semelhantes ao caso dos resíduos progressivos apenas.

- as estimativas com o método Periodograma foram melhores que aquelas obtidas com o Correlograma, porém as diferenças foram pequenas.

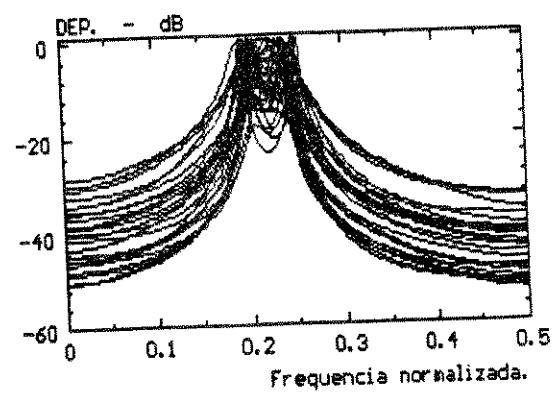
O método de Durbin, propiciou melhores estimativas espectrais que aquelas obtidas com o método Periodograma. Porém, as diferenças foram pequenas e menores ainda quando do processo ARMA₂.

Nos processos ARMA₀, ARMA₁ e ARMA₂, a DEP tem praticamente a mesma forma do denominador espectral e as estimativas que utilizamos deste foram as de melhor qualidade. Assim, a tarefa legada aos estimadores do NUM-ARMA para a complementação da estimativa de DEP-ARMA é relativamente leve. Daí o bom desempenho destes e a semelhança dos resultados dos métodos clássicos entre si e com aqueles obtidos através do método de Durbin. Isto explica também a pequena diferença de desempenho entre os métodos Autocorrelação e Covariância Modificado para estimar o modelo AR longo no método de Durbin.

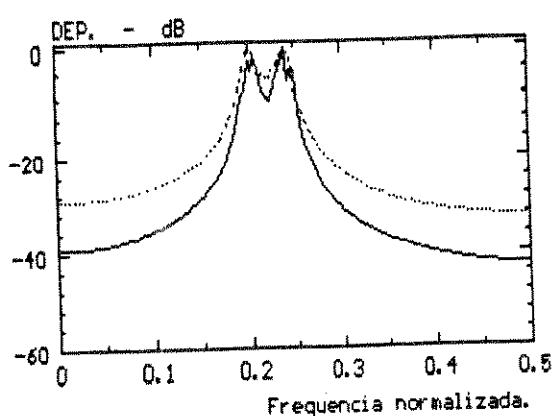
Também os zeros dos processos ARMA₀ e ARMA₂ se encontram próximos à origem da CRU, e o processo ARMA₁ tem somente um vale abrupto no espectro de potência. Em ambas situações o método Periodograma tem bom desempenho.



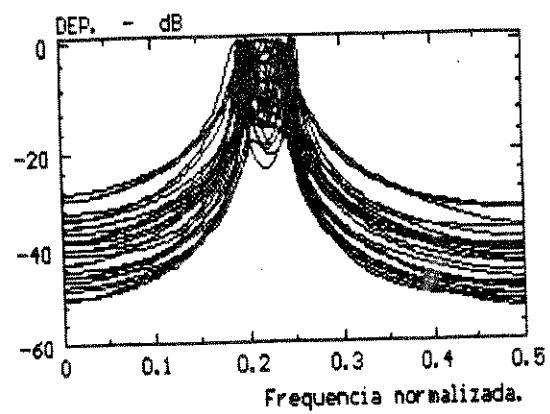
(a) média



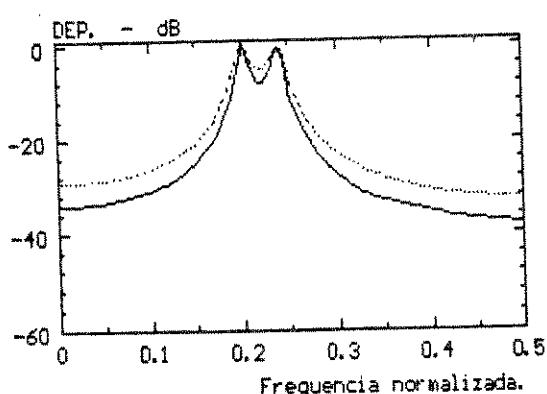
(a) estimativas



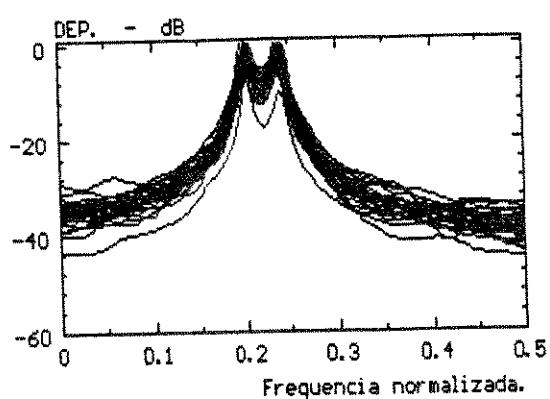
(b) média



(b) estimativas

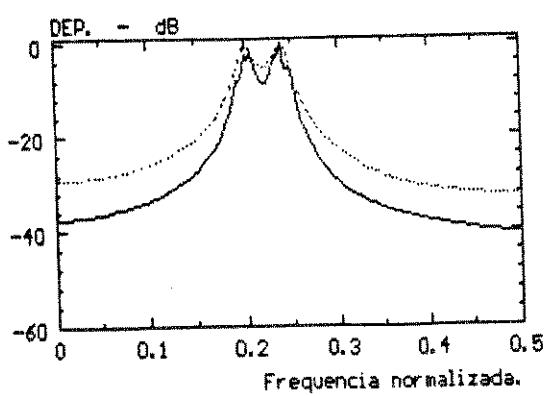


(c) média

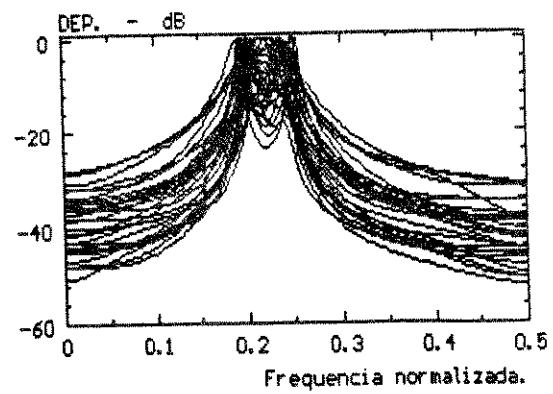


(c) estimativas

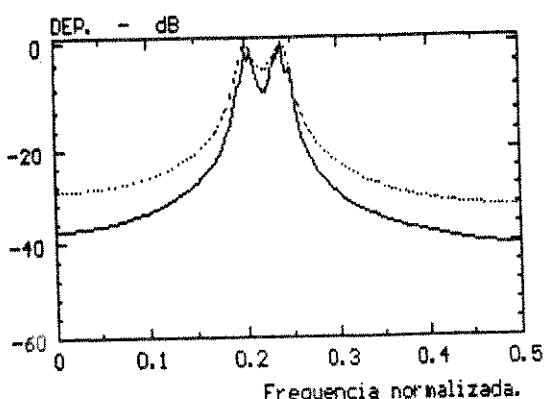
Figura 6.29 Estimativas da DEP do Processo ARMA_{2,1}: Método Correlograma Sobre
(a) os Resíduos Progressivos e N=64,
(b) os Resíduos Progressivos-Regressivos e N=64,
(c) os Resíduos Progressivos e N=256.



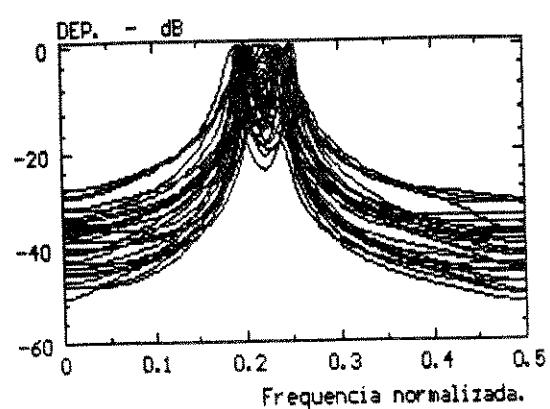
(a) média



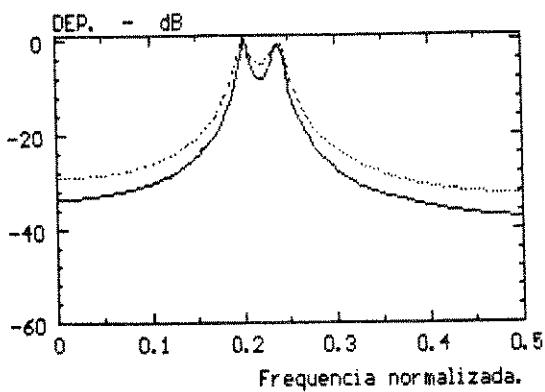
(a) estimativas



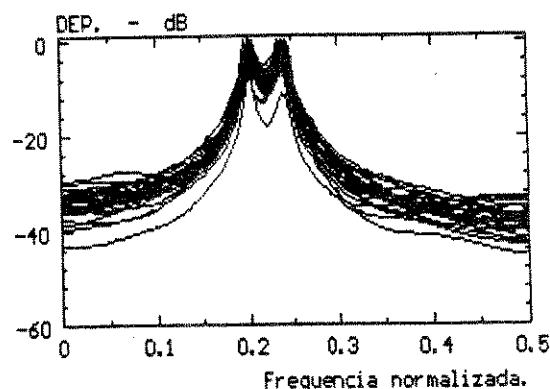
(b) média



(b) estimativas

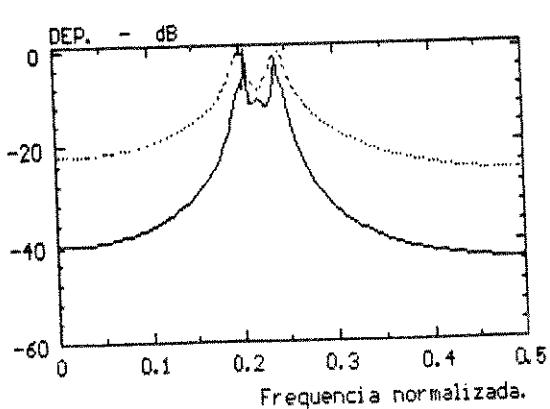


(c) média

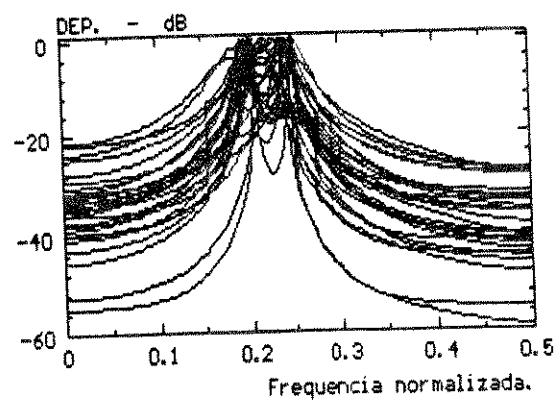


(c) estimativas

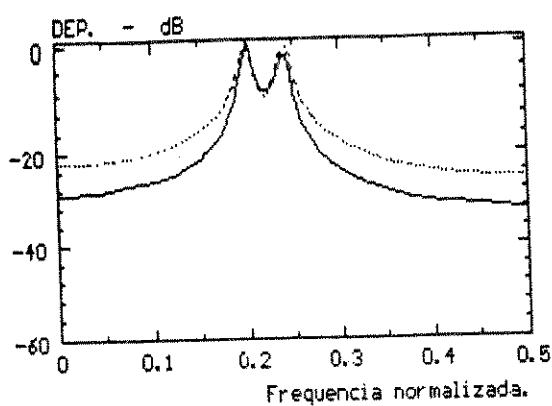
Figura 6.30 Estimativas da DEP do Processo ARMA_{2,1}: Método Periodograma Sobre
(a) os Resíduos Progressivos e N=64,
(b) os Resíduos Progressivos-Regressivos e N=64,
(c) os Resíduos Progressivos e N=256.



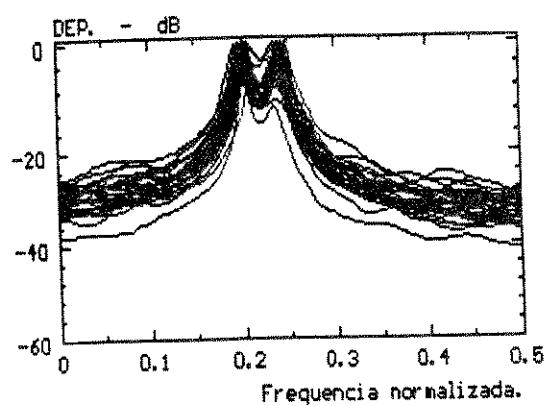
(a) média



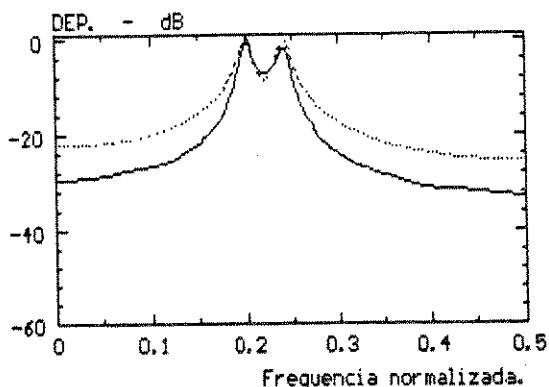
(a) estimativas



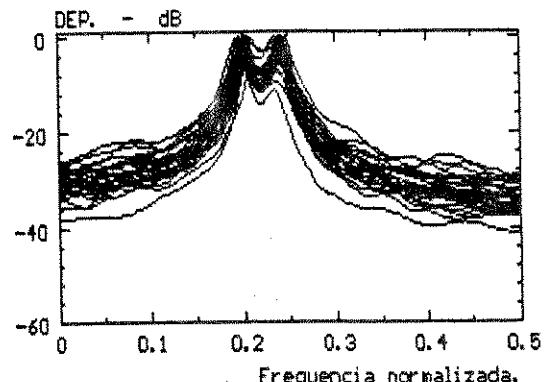
(b) média



(b) estimativas



(c) média



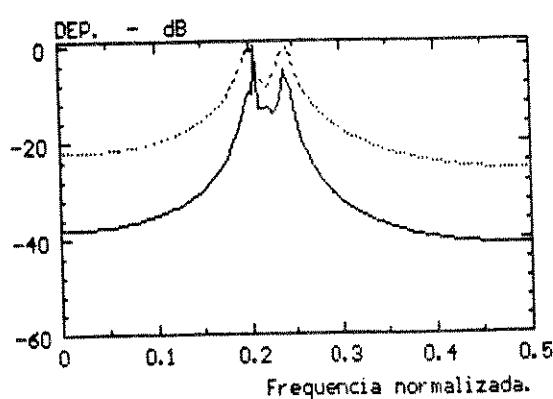
(c) estimativas

Figura 6.31 Estimativas da DEP do Processo ARMA_{1,1}: Método Correlograma Sobre

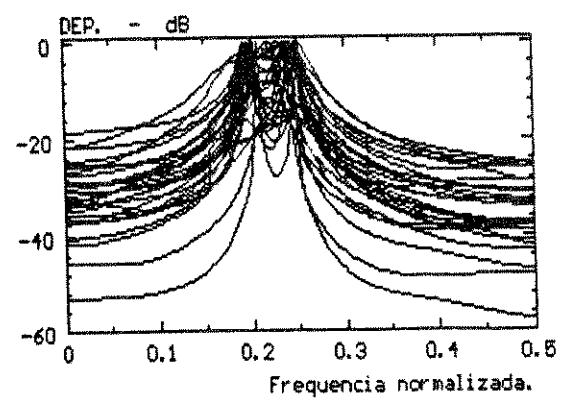
(a) os Resíduos Progressivos e N=64,

(b) os Resíduos Progressivos e N=256,

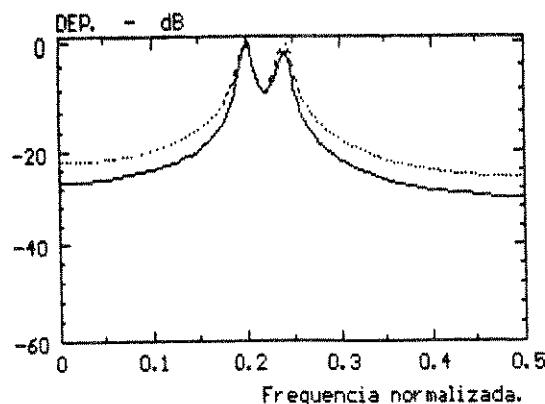
(c) os Resíduos Progressivos-Regressivos e N=256.



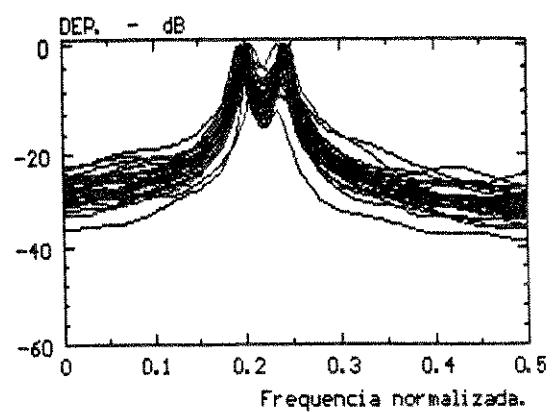
(a) média



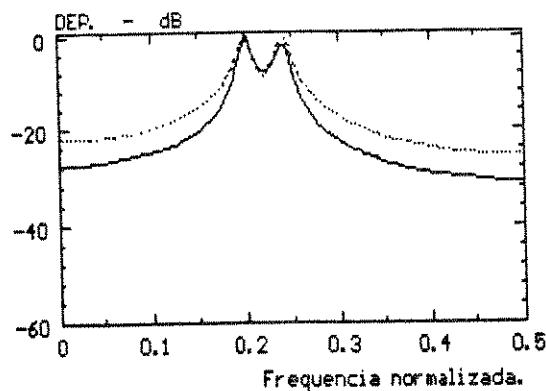
(a) estimativas



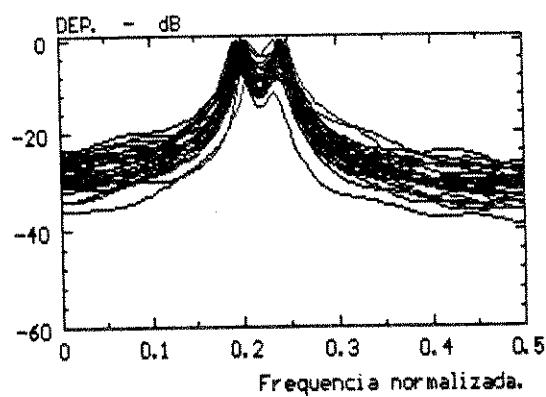
(b) média



(b) estimativas



(c) média



(c) estimativas

Figura 6.32 Estimativas da DEP do Processo ARMA₁: Método Periodograma Sobre
(a) os Resíduos Progressivos e N=64,
(b) os Resíduos Progressivos e N=256,
(c) os Resíduos Progressivos-Regressivos e N=256.

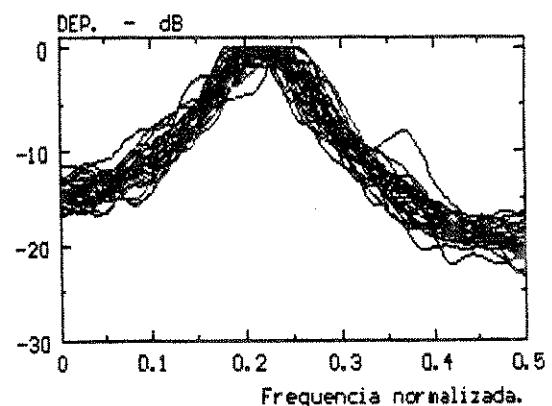
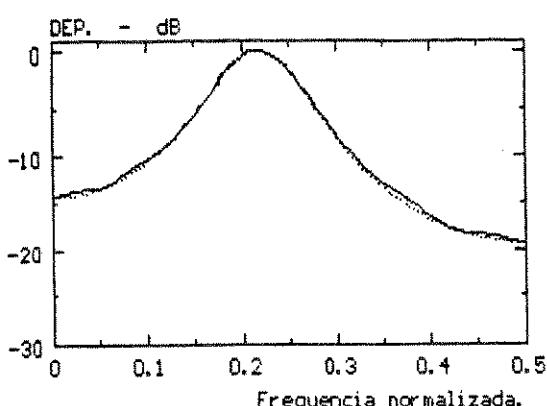
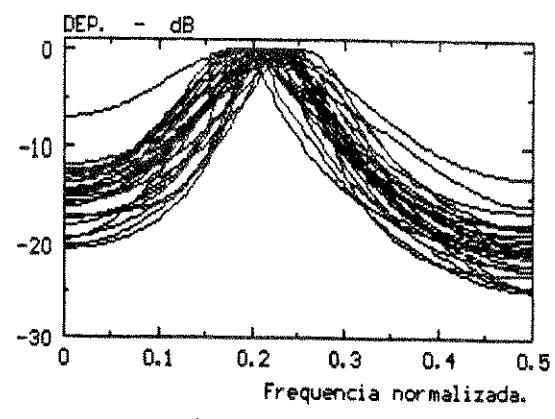
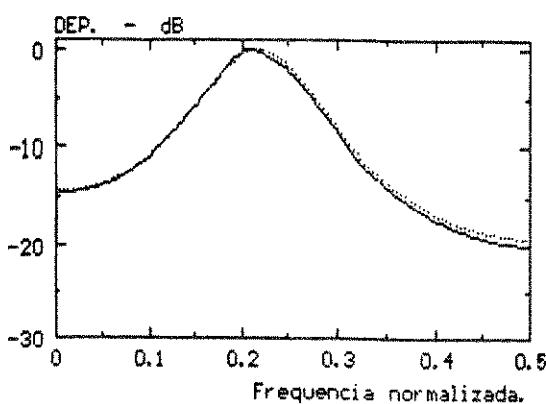


Figura 6.33 Estimativas da DEP do Processo ARMA₂: Método Correlograma

- (a) Sobre os Resíduos Progressivos e N=64,
- (b) Sobre os Resíduos Progressivos e N=256.

Em relação ao processo ARMA₂, temos que :

- a qualidade das estimativas com 64 amostras foi muito ruim, como era esperado, e não permite comparar os estimadores clássicos entre si. Também não houve diferença significativa entre os resultados obtidos com os resíduos progressivos ou progressivos-regressivos.

- com 256 amostras, a qualidade das estimativas especiais ainda é ruim. O método Periodograma propiciou um desempenho ligeiramente superior ao do Correlograma, como era de se esperar em função do vale abrupto do espectro de potência. Novamente não

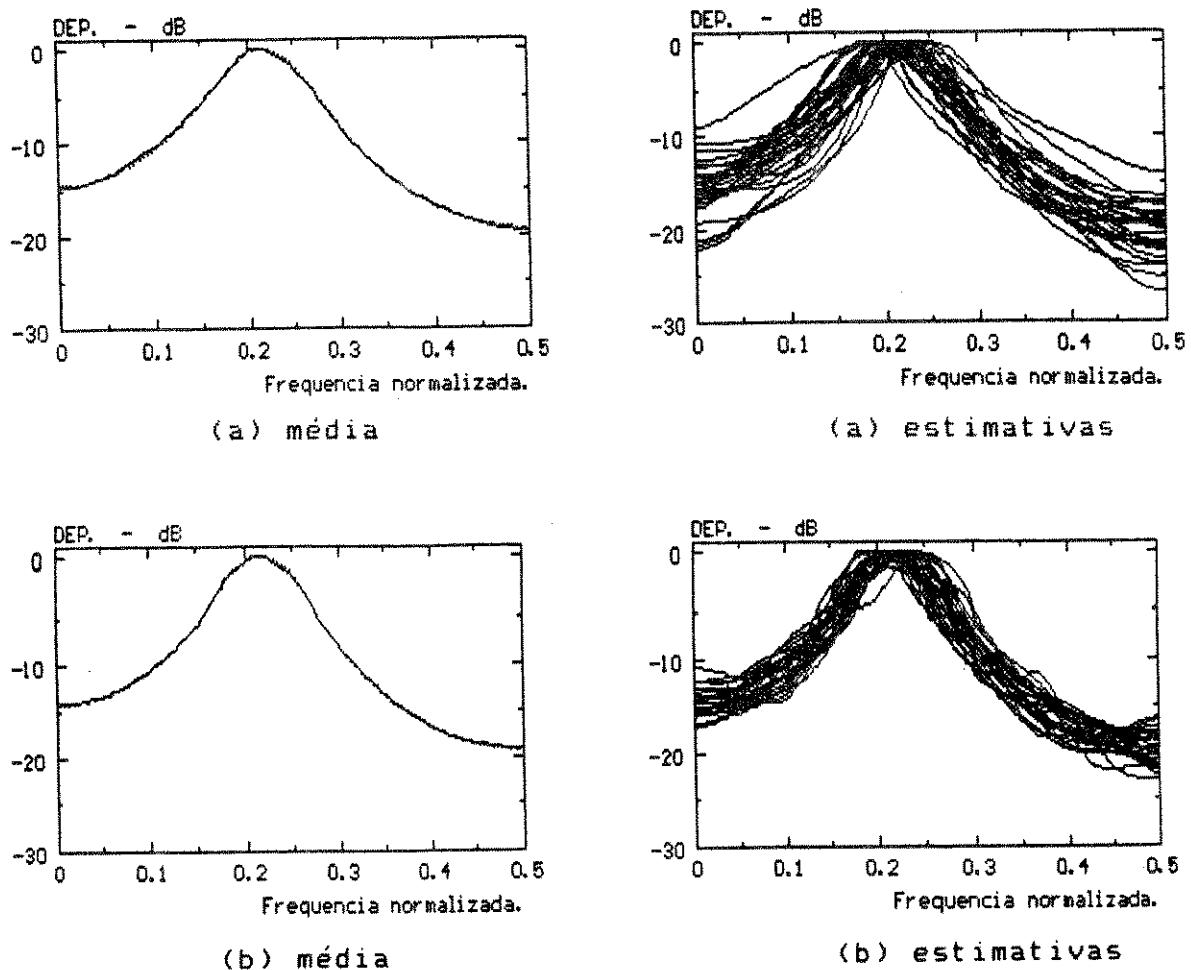
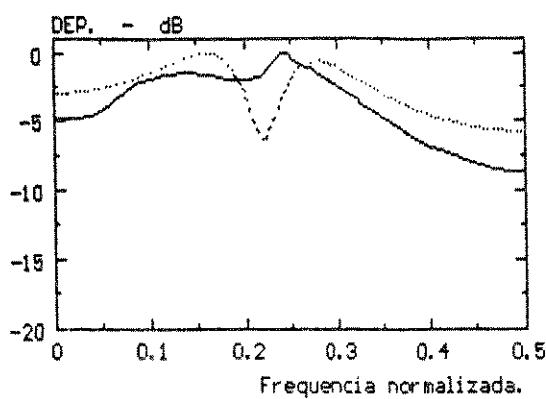


Figura 6.34 Estimativas da DEP do Processo ARMA_2 : Método Periodograma
 (a) Sobre os Resíduos Progressivos e $N=64$,
 (b) Sobre os Resíduos Progressivos e $N=256$.

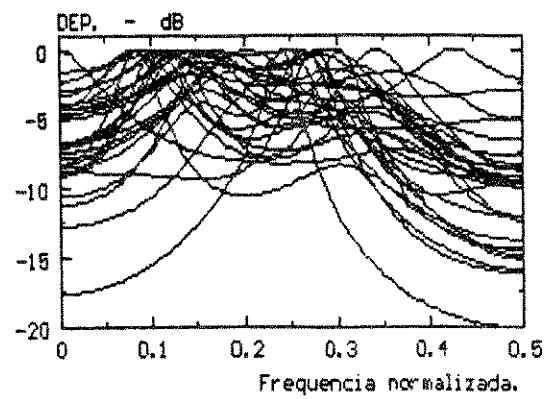
houve diferenças entre o uso dos resíduos progressivos e progressivos-regressivos. Em função da baixa qualidade do denominador espectral, não é possível afirmar que as estimativas espectrais tenham sido melhores com o método de Durbin.

Em resumo, os resultados obtidos confirmaram novamente que o desempenho do método Periodograma é superior ao Correlograma, porém inferior ao desempenho do método de Durbin.

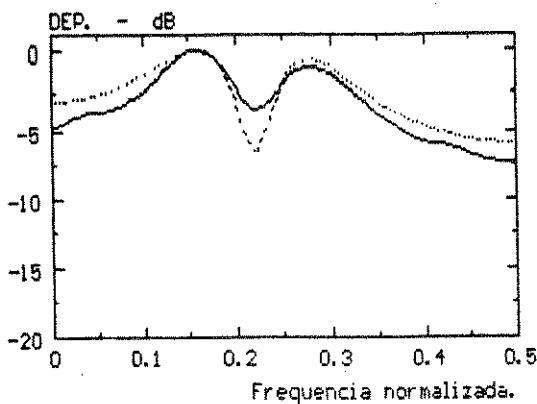
Também mostraram que a utilização dos resíduos progressivos-regressivos não resulta em estimativas espectrais de melhor qualidade que aquelas obtidas com os resíduos progressivos. Ao con-



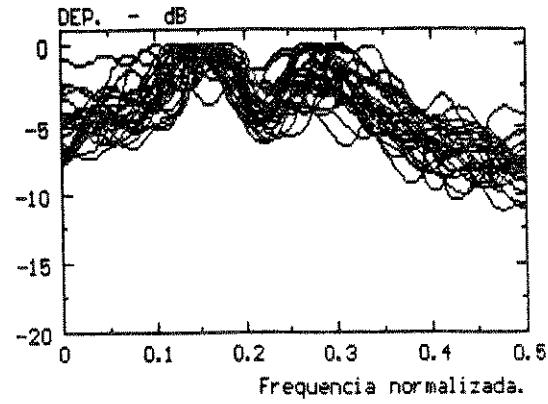
(a) média



(a) estimativas



(b) média



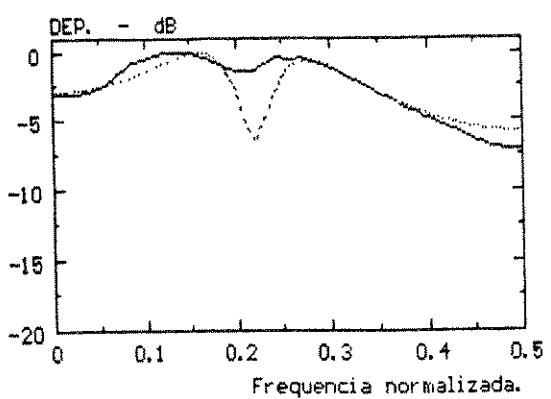
(b) estimativas

Figura 6.35 Estimativas da DEP do Processo ARMA₂: Método Correlograma

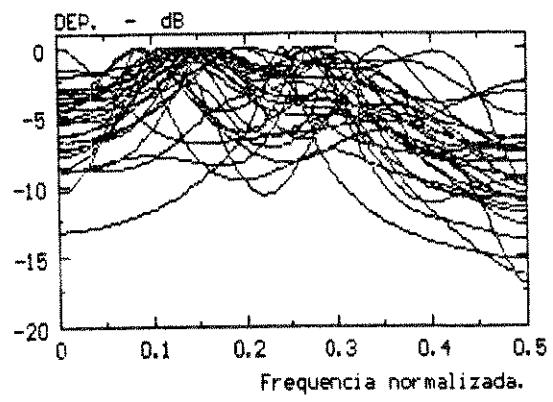
- (a) Sobre os Resíduos Progressivos e N=64,
- (b) Sobre os Resíduos Progressivos e N=256.

trário do que seria esperado, pelo menos nos casos onde o número de amostras é pequeno, em função da maior exploração dos dados.

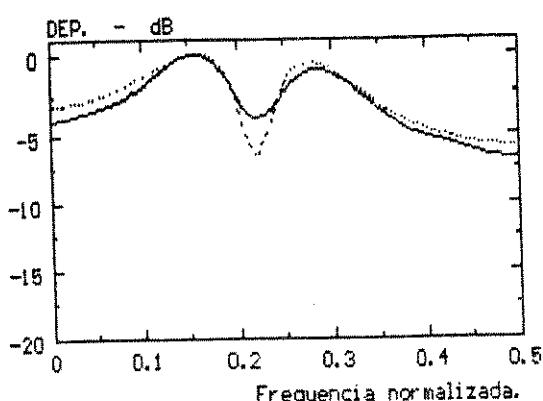
Por fim, nos casos onde a DEP é semelhante ao DEN-ARMA (zeros afastados da CRU) a substituição do método de Durbin pelo Periodograma é satisfatória. Este resultado é bastante significativo para a Análise Espectral, pois a substituição permite uma redução no esforço computacional referente à estimativa do NUM-ARMA. Entretanto, em aplicações onde se necessita dos parâmetros média-ajustável, como, por exemplo, na modelagem de voz, tal substituição não é possível.



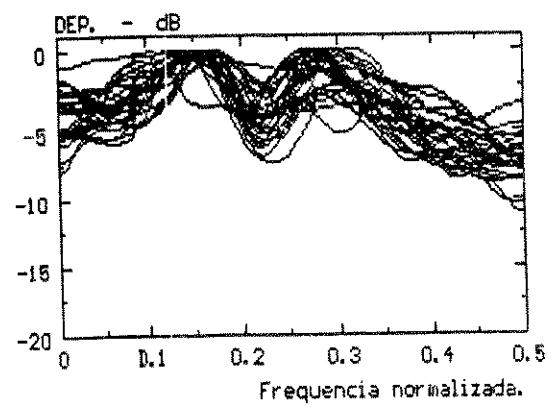
(a) média



(a) estimativas



(b) média



(b) estimativas

Figura 6.36 Estimativas da DEP do Processo ARMA₃: Método Periodograma
(a) Sobre os Resíduos Progressivos e N=64,
(b) Sobre os Resíduos Progressivos e N=256.

6.6 Conclusão

Resumindo as conclusões atingidas ao longo deste capítulo, observamos que a qualidade das estimativas da DEP depende da qualidade das estimativas do DEN-ARMA. Por sua vez, o desempenho do método MQEMYW depende das características espectrais do processo analisado, ou seja, da localização dos pólos e zeros do mesmo. Particularmente, a localização dos pólos condiciona o número de equações que deve ser utilizado neste método: este número deve ser elevado quando os pólos se encontram perto da CRU, e pequeno, pró-

ximo do mínimo, quando se encontram afastados.

Também foi analisado o uso de janela de ponderação sobre os erros de aproximação visando aumentar o desempenho do método. Os resultados mostraram que a ponderação é necessária quando o número de equações é elevado, porém não produz efeitos significativos quando este número é pequeno. As ponderações utilizadas, $(N-m)^4$ e $(N-m)^3$, produziram resultados bastante semelhantes, o que permitiu optarmos pela última.

Foi constatado ainda que a localização dos zeros do processo também afeta o desempenho do método, degradando-o à medida que os zeros se aproximam à CRU, particularmente quando os pólos do processo se encontram afastados da CRU.

Em resumo, o melhor desempenho do método MQEMYW ocorre quando os pólos e zeros se encontram afastados da CRU. Este ainda é satisfatório quando os pólos e zeros se aproximam à CRU, porém ambos próximos entre si. O pior desempenho ocorre com os pólos afastados e os zeros próximos à CRU, porém todos em posições angulares próximas entre si.

Ainda em relação ao método MQEMYW, este apresenta, principalmente quando o número de equações é elevado, polarização radial na estimativa da posição dos pólos, com tendência a localizá-los muito próximos à CRU. Por outro lado, a constatação do efeito da localização dos zeros permitiu observar a limitação natural dos algoritmos de estimação separada: não foi possível isolar os efeitos de tais zeros sobre a estimativa do DEN-ARMA, sendo que estas tendem a reproduzir as características espectrais que deveriam ser obtidas apenas quando da estimação do NUM-ARMA.

Em relação ao uso do método de Durbin na estimação do numerador espectral, esperavamos atingir as mesmas conclusões do capítulo 5 sobre a utilização dos métodos Autocorrelação e Covariância Modificado na obtenção do modelo AR longo. Nos casos em que os zeros dos processos se encontravam próximos à CRU, era esperado que os resultados do emprego do método Covariância Modificado fossem superiores àqueles obtidos com o Autocorrelação. Entretanto, observamos que as diferenças entre os resultados com os dois métodos foram pequenas, o que atribuímos ao fato da qualidade das estimativas do DEN-ARMA não terem permitido que tais diferenças se des-

tacassem. Contudo, as semelhanças entre os resultados mostram que pode-se utilizar o método Covariância Modificado quando os zeros do processo se encontram próximos à CRU, porém o esforço computacional neste método é maior que no Autocorrelação. Nos casos em que os zeros se encontram afastados da CRU, é mais adequado utilizar o método Autocorrelação, tal como foi concluído no capítulo 5.

Quanto ao uso dos métodos clássicos na estimação do numerador espectral, concluímos, tal como no capítulo 5, que o desempenho do método Periodograma é superior ao Correlograma, porém inferior ao desempenho do método de Durbin. E nos casos em que a DEP é semelhante ao denominador espectral (ou seja, aqueles onde os zeros se encontram afastados da CRU), a substituição do método de Durbin pelo Periodograma é satisfatória. Porém, tal substituição não é possível em situações onde se deseja os parâmetros média-ajustável, como, por exemplo, na modelagem de voz.

Ainda sobre o uso dos métodos clássicos, sua aplicação sobre os resíduos progressivos-regressivos não resultou em melhores estimativas espetrais que aquelas apenas com os resíduos progressivos, independente do número de amostras. De modo que podemos optar unicamente pelo emprego dos resíduos progressivos, reduzindo desta forma o esforço computacional.

Os resultados ao longo da seção 6.5 de simulações, também nos permitiram concluir que os métodos sub-ótimos de estimação separada não são adequados para a estimação da DEP de processos ARMA com pólos afastados e zeros próximos à CRU, porém todos situados em posições angulares próximas entre si.

O trabalho desenvolvido neste capítulo apresentou os seguintes aspectos importantes:

- a análise sobre o número de equações e o uso de ponderação no método MQEMYW, envolvendo quatro processos ARMA diferentes e dois número de amostras distintos.

- como resultado desta análise foram obtidas estimativas para da DEP-ARMA melhores que aquelas da referência [2], principalmente para processos com pólos e zeros afastados da CRU.

- a observação da tendência de polarização radial na estimativa da posição dos pólos, no método MQEMYW. Esta observação não foi encontrada em nenhum dos textos estudados.

- a constatação de que os métodos de estimação separada não são adequados para a estimativa da DEP de processo ARMA com pólos afastados e zeros próximos à CRU, porém ambos situados em posições angulares próximas entre si.

- a análise comparativa entre o método de Durbin e os métodos clássicos na estimativa do NUM-ARMA e a conclusão de que o uso simultâneo dos processos residuais progressivos e regressivos nos métodos clássicos não melhora a estimativa da DEP-ARMA em relação ao uso exclusivo dos resíduos progressivos. Estes aspectos não foram encontrados nos textos estudados.

Também, o algoritmo do método MQEMYW sem ponderação, apresentado neste capítulo, foi utilizado como parte de um algoritmo para a síntese de sinais de voz através da modelagem ARMA na tese da referência [18], fornecendo bons resultados.

CAPÍTULO 7

CONCLUSÕES

Este trabalho, cujo objetivo foi o estudo de métodos de estimação dos parâmetros dos modelos ARMA para Análise Espectral, deu inicio às pesquisas sobre a Análise Espectral nesta faculdade. Sendo assim foi tomado o cuidado de apresentar os principais conceitos e métodos da Análise Espectral sem realizar um tutorial sobre a mesma. Contudo, algumas contribuições foram produzidas.

No capítulo 2 tratamos do problema inerente à Análise Espectral em virtude de se dispor, na prática, de um número limitado de amostras do processo a ser analisado. Também foram apresentados os estimadores da seqüência de autocorrelação, os métodos clássicos Correlograma e Periodograma e uma breve discussão sobre os modelos paramétricos.

Um ponto importante neste capítulo é o estudo teórico sobre a característica de seqüência positiva semidefinida das estimativas polarizadas e não-polarizadas da seqüência de autocorrelação. Tal estudo confirma que as seqüências de estimativas polarizadas de autocorrelação são sempre positivas semidefinidas. Esta afirmação foi verificada nas simulações envolvendo o método Correlograma: nelas as estimativas do espectro de potência foram sempre não-negativas. Este resultado também confirma o uso da janela triangular para o truncamento da seqüência de estimativas polarizadas de autocorrelação, de forma a obtermos uma seqüência truncada positiva semidefinida.

No capítulo 5 foi desenvolvido o método de Durbin para a estimativa dos parâmetros do modelo MA e a possível substituição deste modelo pelos métodos clássicos na estimativa do espectro de potência de processos MA.

Embora o objetivo inicial deste capítulo fosse apenas o de servir de suporte para o capítulo sobre estimação espectral ARMA, o mesmo apresentou vários aspectos inéditos tais como: 1) o uso de outros métodos além do Autocorrelação para a obtenção do modelo AR

longo; 2) a análise da seleção da ordem do modelo AR longo em função do método escolhido para sua obtenção, do número de amostras disponíveis e das características espectrais do processo MA analisado; 3) a aplicabilidade da característica de alta resolução dos métodos de estimação AR na estimativa espectral de processos MA com vales espectrais abruptos e 4) a comparação entre o método de Durbin e os estimadores clássicos

As conclusões atingidas ao longo do capítulo 5 foram:

- em relação ao método de Durbin: a estimativa espectral com este método será tanto melhor quanto melhor for a aproximação fornecida pelo modelo AR longo. Esta, por sua vez, depende da localização dos zeros, do número de amostras disponíveis e do método de estimação do modelo AR longo. No caso em que os zeros se encontram afastados da CRU, os resultados mostraram que a ordem adequada para o modelo AR longo é um quinto do número de amostras. Para este valor os três métodos utilizados para estimar o modelo AR, Autocorrelação, Covariância e Covariância Modificado, forneceram resultados semelhantes, prevalecendo então o método Autocorrelação em função do menor esforço computacional. Para processos MA com zeros próximo à CRU, os métodos Covariância e Covariância Modificado apresentaram desempenho superior na estimação do modelo AR longo e a ordem adequada para este modelo é um terço do número de amostras.

- em relação aos métodos clássicos: o desempenho do método Periodograma é superior ao do Correlograma, porém inferior ao desempenho do método de Durbin, independente da localização dos zeros. Entretanto, os resultados mostraram que o método de Durbin pode ser substituído pelo Periodograma quando o número de amostras for bastante elevado. O método Correlograma não apresentou condições de ser utilizado em tal substituição.

O capítulo 6, sobre estimação espectral ARMA, é o tema central da tese e objetivou extraír o maior número possível de informações sobre os métodos de estimação separada, a partir dos conceitos teóricos apresentados e as simulações efetuadas.

Entre os aspectos mais importantes deste capítulo destaca-se o estudo sobre o número de equações e uso de janela de ponderação

no algoritmo da análise de mínimos quadrados das Equações Modificadas de Yule-Walker para a estimativa dos parâmetros auto-regressivos do modelo ARMA. Tal estudo permitiu obter melhores estimativas do espectro de potência de processos ARMA que aquelas observadas na referência [2] e permitiu constatar que este algoritmo apresenta tendência de polarização radial na estimativa da posição dos pólos. Por fim, destaca-se também a comparação entre o método de Durbin e os métodos clássicos, agora dentro do contexto da estimação do numerador espectral ARMA.

As principais conclusões alcançadas foram:

- a qualidade da estimativa do espectro de densidade de potência depende da qualidade da estimativa do denominador espectral.

- os métodos de estimação separada não são adequados para estimar o espectro de potência de processos com pólos afastados e zeros próximos à CRU, porém situados em posições angulares próximas.

- o desempenho do algoritmo da análise de mínimos quadrados das Equações Modificadas de Yule-Walker depende da localização dos pólos e zeros do processo, sendo melhor quando os pólos e zeros se encontram afastados da CRU, satisfatório quando ambos se aproximam à CRU e ruim quando os pólos se encontram afastados e os zeros próximo à CRU. O número de equações neste algoritmo deve ser elevado quando os pólos se encontram próximos à CRU e pequeno quando os pólos se encontram afastados. O número elevado de equações exige o uso de ponderação dos erros, ao passo que tal ponderação não produz efeitos significativos quando este número é pequeno.

- na estimativa do numerador espectral utilizando o método de Durbin, constatamos que é mais adequado o uso do método Autocorrelação na obtenção do modelo AR longo quando os zeros se encontram afastados da CRU. Porém, a qualidade das estimativas do denominador espectral, nos casos em que os zero se encontram próximos à CRU, não permitiu confirmar a superioridade do método Covariância Modificado em relação ao Autocorrelação. Em relação ao uso dos métodos clássicos, concluimos, novamente, que o desempenho

do método Periodograma é superior ao Correlograma, porém inferior ao do Durbin. Entretanto, a substituição do método de Durbin pelo Periodograma é satisfatória nos casos em que a densidade espectral de potência é semelhante ao denominador espectral.

O prosseguimento deste trabalho pode se dar em duas etapas. Em primeiro lugar, é necessário estudar se as tendências da estimativa do denominador espectral ARMA em reproduzir aspectos referentes ao numerador e gerar polarização radial na estimativa dos pólos, se manifestam em outros processos onde os zeros se encontram em posições angulares afastadas daquelas ocupadas pelos pólos. Este estudo permitirá avaliar o desempenho dos métodos de estimação separada quanto ao posicionamento angular dos pólos e zeros e observar se o afastamento leva a uma melhor estimativa do denominador ARMA nos casos mais difíceis tratados no capítulo 6.

Em seguida, pode-se tentar compensar a polarização radial na estimativa dos pólos, através de um fator de ajuste. Também, pode ser avaliado o uso do algoritmo da variável instrumental para a solução das Equações Modificadas de Yule-Walker, como proposto no texto de referência [33], onde é discutido o uso de uma ponderação ótima dos erros de aproximação que considere a parte média-ajustável do modelo ARMA. Tal proposta tem por objetivo melhorar a qualidade da estimativa dos parâmetros auto-regressivos.

Será interessante, ainda, um estudo sobre o comportamento dos métodos de estimação separada em função da ordem atribuída ao modelo ARMA.

Por fim, naqueles casos onde os métodos de estimação separada não ofereçam estimativas espetrais de qualidade aceitável, será necessário empregar outros métodos mais poderosos, tais como os métodos ótimos de estimação simultânea.

REFERÊNCIAS

- [1] Marple, S. L. Jr., Digital Spectral Analysis with Applications, Prentice-Hall, Inc. Englewood Cliffs, N.J., 1987.
- [2] Kay, S. M., Modern Spectral Estimation, Prentice Hall, Inc., Englewood Cliffs, N. J., 1988.
- [3] Lathi, B. P., An introduction to Random Signals and Communication Theory, International Textbook Co., 1968.
- [4] Jenkins, G. M., and D. G. Watts, Spectral Analysis and Its Applications, Holden-Day, Inc., San Francisco, 1968.
- [5] Cadzow, J. A., and Y. Sun, Sequences with Positive Semidefinite Fourier Transforms, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-34, pp. 1502-1510, December, 1986.
- [6] Haykin S., Adaptive Filter Theory, Prentice-Hall, Inc., Englewood Cliffs, N.J., 1986.
- [7] Noble, B., e J. W. Daniel, Álgebra Linear Aplicada, Segunda Edição, Prentice/Hall do Brasil, Rio de Janeiro, 1986
- [8] Balckman, R. B., and J. W. Tukey, The Measurement of Power Spectra from the Point of View of Communication Engineering, Dover Publications Inc., New York, 1958.
- [9] Welch, P. D., The USE of Fast Fourier Transform for Estimation of Power Spectra: A Method Based on Time Averaging over Short, Modified Periodogram, IEEE Trans. Audio Electroacoust., vol AU-15, pp 70-73, June 1967.
- [10] Oppenheim, A. V., and R.W. Schafer, Digital Signal Processing Prentice-Hall, Inc., Englewood Cliffs, N.J., 1975.

- [11] Box, G. F. P., and G. M. Jenkins, Time Series Analysis Forecasting and Control, Revised Edition, Holden-Day, Inc., San Francisco, 1976.
- [12] De Witt B., A. S. e A. Lopes, Introdução aos Modelos Paramétricos na Análise Espectral, RT-204 Convênio UNICAMP-TELEBRÁS, FEE-UNICAMP, Nov. 1990.
- [13] Lang, S. W., and J. H. McClellan, Frequency Estimation with Maximum Entropy Spectral Estimators, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-28 pp 716-724, December 1980.
- [14] Antunes, E. J. B. e A. Lopes, Detecção de Freqüências Através de Predição Linear, RT-223, Convênio UNICAMP-TELEBRÁS, FEE-UNICAMP, Nov. 1991.
- [15] Chow, J. C., On the Estimation of the Order of a Moving-Average Process, IEEE Trans. Autom. Control, vol. AC-17, pp 386-387, June 1972.
- [16] Cadzow, J. A., Spectral Estimation: An Overdetermined Rational Model Equation Approach, Proc. IEEE vol. 70 pp 907-938, September 1982.
- [17] Jacson, L. B., Digital Filters and Signal Processing, Kluwer Academic Publishers, 1989.
- [18] Oliveira, P. C. D., Aplicação do Processamento Homomórfico na Codificação de Voz a Baixas Taxas, Tese de Mestrado, FEE-UNICAMP, Fev. 1992.
- [19] Steiglitz, K., and L. E. McBride, A Technique for Identification of Linear System, IEEE Trans. Autom. Control, col. AC-10, pp 461-464 , October 1965.

- [20] Sakai, H., and H. Tokumaru, Statistical Analysis of a Spectral Estimator for ARMA Process, IEEE Trans. Autom Control, vol AC-25, pp 122-124, February 1980.
- [21] Cadzow, J. A., High Performance Spectral Estimation - A New ARMA Method, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-28, pp 524-529, October 1980.
- [22] Durbin, J. Estimation of Parameters in Time-Series Regression Models, J. Roy. Sttist. Soc., vol. 22, pp. 139-153, 1960.
- [23] Friedlander, B., and B. Porat, Modified Yule-Walker Method of ARMA Spectral Estimation, IEEE Trans. Aerosp. Electron. System, vol. AES-20, pp 158-172, March 1984.
- [24] Friedlander, B., and K. C. Sharman, Performance Evualtion of the Modified Yule-Walker Estimator, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-33, pp 719-725, June 1985.
- [25] Bruzzone, S. P., and M. Kaveh, Information Tradeoff in Using the Sample Autocorrelation Funtion in ARMA Parameter Estimation, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-32, pp 710-715, August 1984.
- [26] Cadzow, J. A., Autoregressive Moving-Average Spectral Estimation: A Model Equation Procedure, IEEE Trans. Geosci. Remote Sensing, vol. GE-19, pp 24-28, January 1981.
- [27] Kinkel, J. F., J. Perl, L. Scharf anf A. Stubberud, A Note Covariance-Invariant Digital Filter Desing and Autoregressive Moving-Average Spectral Estimaion, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-27, pp 200-202, April 1979.
- [28] Kaveh, M., High Resolution Spectral Estimation for Noisy Signals, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-27, pp 286-287, June 1979.

- [29] Bruzzone, S. P., and M. Kaveh, One Some Suboptimum ARMA Spectral Estimators, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-28, pp 753-755, December 1980.
- [30] Moses, R. L., and A. A. Beex, A Comparison of Numerator Estimators for ARMA Spectra, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-34, pp 1668-1671, December 1986.
- [31] Kay, S. M., A New ARMA Spectral Estimator, IEEE Trans. Acoust. Speech Signal Process., vol. ASSP-28, pp 585-588, October 1980.
- [32] Chow, J. C., On Estimating the Orders of an Autoregressive Moving-Average Process with Uncertain Observations, IEEE Trans. Autom. Control, vol. AC-17, pp 707-709, October 1972.
- [33] P. Stoica, T. Söderström and B. Friedlander, Optimal Instrumental Variable Estimates of the an ARMA Process, IEEE Trans. Autom. Control, vol AC-30, pp 1066-1074, November 1985.