

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

**Medidas de Estruturas Cardíacas Fetais
Através de Imagens Ecocardiográficas
Segmentadas**

por

MOZART LEMOS DE SIQUEIRA

Dissertação submetida a avaliação,
como requisito parcial para a obtenção do grau de
Mestre em Ciência da Computação

Prof. Dr. Philippe Olivier Alexandre Navaux
Orientador

Porto Alegre, maio de 2002.

CIP — CATALOGAÇÃO NA PUBLICAÇÃO

Siqueira, Mozart Lemos de

Medidas de Estruturas Cardíacas Fetais Através de Imagens Ecocardiográficas Segmentadas / por Mozart Lemos de Siqueira. — Porto Alegre: PPGC da UFRGS, 2002.

121 f.: il.

Dissertação (mestrado) — Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR-RS, 2002. Orientador: Navaux, Philippe Olivier Alexandre.

1. Processamento de imagens. 2. Medidas cardíacas. 3. Cardiologia fetal. 4. Ultra-som. 5. Redes neurais artificiais. I. Navaux, Philippe Olivier Alexandre. II. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitora: Prof^a. Wrana Maria Panizzi

Pró-Reitor de Ensino: Prof. José Carlos Ferraz Hennemann

Pró-Reitor Adjunto de Pós-Graduação: Prof. Jaime Evaldo Fernsterseifer

Diretor do Instituto de Informática: Prof. Philippe Olivier Alexandre Navaux

Coordenador do PPGC: Prof. Carlos Alberto Heuser

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

Esta dissertação é dedicada à minha noiva, Cristiane Fernandes. Ela também é dedicada aos meus pais, Circe e Edvard, às minhas irmãs, Niara e Gabriela e especialmente à minha avó, Benta.

Agradecimentos

Agradeço ao Professor Navaux, por ter me aceito como orientando de mestrado, ter acreditado em meu potencial e dedicado um pouco do seu tempo ajudando-me no desenvolvimento da dissertação;

Ao pessoal do Grupo de Processamento Paralelo e Distribuído, onde encontrei respostas para muitas dúvidas;

Ao pessoal do SEGIME, tanto aqueles que saíram: Duda, Piccoli, Juliano e Caroline; quanto a atual equipe: Daniel, Jeferson e Dênis. Esse pessoal ajudou muito no desenvolvimento desse trabalho;

Aos colegas do CtPetro André e César e aos Professores Netto e Cechin.

Ao Professor Jacob Scharcanski pelas sugestões pertinentes e dúvidas esclarecidas;

À Professora Silvia Olabarriga por ter dividido um pouco dos seus conhecimentos e ter ajudado na análise dos resultados.

À equipe de Cardiologia Fetal do Instituto de Cardiologia do Rio Grande do Sul, em especial aos Doutores Paulo Zielinsky e Stelamaris Luchese, pelas imagens, pela avaliação dos resultados e pelas sugestões.

Aos colegas Wives, Marcia, Juliana, Patricia, Pilla, Elgio e Bohrer pela amizade e pelos momentos de descontração das horas de almoço que ajudaram muito a diminuir a tensão do dia-a-dia.

À excelente Biblioteca do Instituto de Informática e aos seus funcionários, em especial à Grace, Henrique, Ida e Bea;

Ao Instituto de Informática que ofereceu ótimas condições de trabalho, excelentes professores e funcionários. Em especial à Silvania, Luis Otávio, Claudinha, Lourdes, Eliane e Astrogildo;

Ao CNPq, pela bolsa de mestrado;

À Têre e ao Cata, que têm me dado muito apoio nesses últimos anos;

À tia Eni, pelos conselhos, sabedoria e lições de positivismo;

Ao primão Fabiano, que me dá muita força e amizade;

Às minhas irmãs, Niara e Gabriela que sempre me apoiaram me dando muito carinho;

Aos meus pais, Circe e Edvard por terem ajudado em todos os momentos de minha vida, com paciência e dedicação, dando condições para eu chegar até aqui;

À minha amada Cristiane Fernandes, pela força, pela paciência, pelo companheirismo, pelo Amor que me dedicou ao longo dessa caminhada.

Muitos ajudaram durante o desenvolvimento dessa dissertação, provavelmente esquecerei de alguém, mas somente no texto. A todos gostaria de dizer: Muito Obrigado!

Sumário

Lista de Abreviaturas	7
Lista de Figuras	9
Lista de Tabelas	11
Resumo	12
Abstract	13
1 Introdução	14
2 O Panorama de Imagens Médicas	17
2.1 Ultra-som	17
2.1.1 Formação da Imagem de Ultra-som	18
2.1.2 Transdutor	19
2.1.3 Problemas no ultra-som	22
2.1.4 Ecocardiografia fetal	24
2.2 Medicina Nuclear	26
2.3 Ressonância Magnética	26
2.4 Radiografia	27
2.5 Tomografia Computadorizada	28
3 Processamento de Imagens Aplicado à Medicina	30
3.1 Aquisição	30
3.2 Pré-Processamento	32
3.3 Segmentação	34
3.3.1 Crescimento de Regiões	35
3.3.2 <i>Thresholding</i>	35
3.3.3 <i>Split and Merge</i>	36
3.3.4 Uso de Redes Neurais na Segmentação de Imagens	36
3.4 Análise de Imagens	38
4 Redes Neurais Artificiais	40
4.1 Aprendizado Artificial	41
4.1.1 Aprendizado Supervisionado	42
4.1.2 Aprendizado Não-Supervisionado	43
4.2 Modelos de RNAs	43
4.2.1 O Perceptron e o Adaline	44
4.2.2 O Perceptron Multicamadas e o Backpropagation	46
4.2.3 Rede de <i>Hopfield</i>	47
4.2.4 Mapas Auto-Organizáveis de Kohonen	48
4.2.5 Teoria de Adaptação Ressonante	50
4.3 Aplicações	51

5	O Modelo de Medidas	53
5.1	O processo de obtenção das medidas	53
5.1.1	Técnica para suavização das bordas	55
5.2	Estruturas cardíacas fetais	56
5.2.1	Espessura do septo interventricular	57
5.2.2	Diâmetro do ventrículo esquerdo	58
5.2.3	Índice de excursão do <i>Septum Primum</i>	58
6	O Ambiente de Desenvolvimento	61
6.1	O ambiente Khoros	61
6.1.1	Desenvolvimento de novas rotinas no Khoros	62
6.1.2	O ambiente de programação visual Cantata	64
6.2	A aquisição das imagens	65
6.3	A etapa de pré-processamento	65
6.4	A Segmentação das Imagens	65
7	Resultados Obtidos	68
7.1	Avaliação dos resultados	68
7.2	Medidas do Septo Interventricular	69
7.3	Medidas do Ventrículo Esquerdo	72
7.4	Medidas para o Índice de Excursão do <i>Septum Primum</i>	74
7.4.1	Excursão do <i>Septum Primum</i>	75
7.4.2	Diâmetro do Átrio Esquerdo	75
7.4.3	Índice de Excursão do <i>Septum Primum</i>	77
8	Conclusão	78
Anexo 1	Artigo no <i>Journal of VLSI Signal Processing</i>	80
Anexo 2	Artigo publicado no NNSP 2000	92
Anexo 3	Artigo publicado no SBRN 2000	103
Anexo 4	Artigo publicado no ICIE 2000	108
Bibliografia		118

Lista de Abreviaturas

AE	Átrio esquerdo
AD	Átrio direito
ACE	Artéria carótida esquerda
AoA	Aorta ascendente
AoD	Aorta descendente
ASE	Artéria subclávia esquerda
2D	Bidimensional
CA	Canal arterial
ESP	Expansão do <i>septum primum</i>
Hz	Hertz
IA	Inteligência artificial
ICRGS	Instituto de Cardiologia do Rio Grande do Sul
IIUFRGS	Instituto de Informática da UFRGS
IRSP	Índice de redundância do <i>septum primum</i>
kg/m ³	Quilogramas por centímetro cúbico
MHz	MegaHertz
MLP	Perceptron multicamadas
mm	Milímetros
m/s	Metros por segundo
RDAP	Ramo direito da artéria pulmonar
RM	Ressonância magnética
RNAs	Redes neurais artificiais
RNA	Rede neural artificial
ROI	Região de interesse (<i>Region on interest</i>)
SEGIME	Segmentação de Imagens Médicas
SiA	Septo interatrial
SiV	Septo interventricular
SOM	Mapas auto-organizáveis (<i>Self-organizing maps</i>)
TBC	Tronco braquicefálico
3D	Tridimensional
TM	Tomografia computadorizada
TP	Tronco pulmonar

UFRGS	Universidade Federal do Rio Grande do Sul
VAo	Válvula aórtica
VCI	Veia cava inferior
VCS	Veia cava superior
VD	Ventrículo direito
VE	Ventrículo esquerdo
VHS	<i>Video home system</i>
VM	Válvula mitral
VP	Válvula pulmonar
VT	Válvula tricúspide

Lista de Figuras

FIGURA 2.1 – Exemplo do uso de ultra-som pelos golfinhos.	18
FIGURA 2.2 – Ecocardiografia fetal.	19
FIGURA 2.3 – Comportamento do cristal de quartzo na produção de ultra-som.	20
FIGURA 2.4 – Método de mapeamento A ou modo-A.	21
FIGURA 2.5 – Esquema do método de captura em modo-B de um feto.	22
FIGURA 2.6 – Modo-B de ultra-som do abdômen superior.	22
FIGURA 2.7 – Efeitos de reverberação em ondas de som.	23
FIGURA 2.8 – Captura de imagens ecocardiográficas fetais.	24
FIGURA 2.9 – Incidência do feixe de ultra-som para cada plano do coração fetal.	25
FIGURA 2.10 – Imagem de medicina nuclear da estrutura óssea.	26
FIGURA 2.11 – Imagens obtidas através de ressonância magnética.	27
FIGURA 2.12 – Radiografias da coluna cervical.	27
FIGURA 2.13 – Imagens obtidas através de tomografia computadorizada.	28
FIGURA 2.14 – Esquema de emissão e detecção de raio-X em tomografias.	28
FIGURA 3.1 – Etapas fundamentais no processamento de imagens médicas.	30
FIGURA 3.2 – Exemplos de <i>scanners</i> médicos.	31
FIGURA 3.3 – Equalização do histograma dos níveis de cinza.	32
FIGURA 3.4 – Exemplos de vizinhança e máscara.	33
FIGURA 3.5 – Exemplo da filtragem mediana para extração de ruído.	34
FIGURA 3.6 – Algoritmo e máscara usados pelo filtro de <i>crimmins</i>	34
FIGURA 3.7 – Representação gráfica do algoritmo de crescimento de regiões.	35
FIGURA 3.8 – <i>Threshold</i> realizado com dois limiares diferentes.	36
FIGURA 3.9 – Exemplo do algoritmo de <i>split and merge</i>	37
FIGURA 3.10 – Exemplo do treinamento <i>backpropagation</i>	37
FIGURA 3.11 – Exemplo do processamento do <i>SOM</i>	38
FIGURA 3.12 – Imagem microscópica de células.	39
FIGURA 4.1 – O Neurônio biológico e um modelo de neurônio artificial.	41
FIGURA 4.2 – Esquema de treinamento supervisionado.	42
FIGURA 4.3 – Esquema de treinamento não-supervisionado.	43
FIGURA 4.4 – Classificação das principais RNAs ([LIP 87]).	44
FIGURA 4.5 – Problema linearmente e não-linearmente separável.	44
FIGURA 4.6 – Estrutura das redes Perceptron e Adaline.	45
FIGURA 4.7 – Estrutura da rede MLP.	46
FIGURA 4.8 – Estrutura da rede Backpropagation.	47
FIGURA 4.9 – Estrutura da rede de Hopfield.	47
FIGURA 4.10 – Estrutura da rede SOM.	49
FIGURA 4.11 – Vizinhança de um neurônio.	50
FIGURA 4.12 – Topologia básica da rede ART.	51
FIGURA 5.1 – Fluxo do processo de obtenção de medidas.. . . .	54
FIGURA 5.2 – Medidas obtidas a partir de diferentes números de linhas.	54
FIGURA 5.3 – Modo-M, utilizado na medida de algumas estruturas.	55
FIGURA 5.4 – Parte irregular da borda.	56
FIGURA 5.5 – Aplicação da média do quadrado mínimo nas bordas.	56

FIGURA 5.6 – Descrição das estruturas cardíacas.	57
FIGURA 5.7 – Processo de medida do septo interventricular.	58
FIGURA 5.8 – Processo de medida da espessura do ventrículo esquerdo.	58
FIGURA 5.9 – Excursão do <i>septum primum</i> para o interior do átrio esquerdo.	59
FIGURA 5.10 – Medidas para o IRSP.	59
FIGURA 6.1 – Tela do ambiente Craftsman.	62
FIGURA 6.2 – Tela do aplicativo Composer, disponível no Craftsman.	63
FIGURA 6.3 – Janela de edição do Pane.	63
FIGURA 6.4 – Exemplo de fluxo de dados no Cantata.	64
FIGURA 6.5 – Descrição das características de um <i>glyph</i>	65
FIGURA 6.6 – Extração da região de interesse.	66
FIGURA 6.7 – Processo aleatório de escolha das amostras.	66
FIGURA 6.8 – Fase de treinamento e geração do mapa agrupado pelo SOM.	67
FIGURA 6.9 – Fase de pós-processamento do mapa pelo <i>K-means</i>	67
FIGURA 6.10 – Processo de segmentação.	67
FIGURA 7.1 – Indicação dos pontos marcados pela especialista.	69
FIGURA 7.2 – Resultados obtidos pelo método semi-automático.	70
FIGURA 7.3 – Resultados obtidos pelo método semi-automático no <i>G2</i>	71
FIGURA 7.4 – Resultados obtidos pelo método semi-automático no <i>G3</i>	71
FIGURA 7.5 – Resultados obtidos pelo método semi-automático para o VE no <i>G1</i>	73
FIGURA 7.6 – Resultados obtidos pelo método semi-automático no <i>G2</i>	73
FIGURA 7.7 – Resultados obtidos pelo método semi-automático no <i>G3</i>	74
FIGURA 7.8 – Resultados obtidos pelo método semi-automático no IRSP.	75

Lista de Tabelas

TABELA 2.1 – Densidade e velocidade do som em diferentes meios [BER 2000].	19
TABELA 7.1 – Medidas referentes ao SiV no $G1$ (ver texto).	70
TABELA 7.2 – Medidas referentes ao SiV no $G2$ (ver texto).	70
TABELA 7.3 – Medidas referentes ao SiV no $G3$ (ver texto).	71
TABELA 7.4 – Medidas referentes ao VE no $G1$.	72
TABELA 7.5 – Medidas referentes ao VE no $G2$.	73
TABELA 7.6 – Medidas referentes ao VE no $G3$.	73
TABELA 7.7 – Medidas referentes à extensão do SP.	76
TABELA 7.8 – Medidas referentes ao diâmetro do AE .	76
TABELA 7.9 – Índice de excursão do <i>septo primum</i> (IRSP).	77
TABELA 8.1 – Avaliação dos resultados.	79

Resumo

O presente trabalho implementa um método computacional semi-automático para obter medidas de estruturas cardíacas de fetos humanos através do processamento de imagens de ultra-som. Essas imagens são utilizadas na avaliação cardíaca pré-natal, permitindo que os médicos diagnostiquem problemas antes mesmo do nascimento.

A dissertação é parte de um projeto desenvolvido no Instituto de Informática da Universidade Federal do Rio Grande do Sul, denominado SEGIME (Segmentação de Imagens Médicas). Neste projeto, está sendo desenvolvida uma ferramenta computacional para auxiliar na análise de exames ecocardiográficos fetais com o apoio da equipe de Cardiologia Fetal do Instituto de Cardiologia do Rio Grande do Sul.

O processamento de cada imagem é realizado por etapas, divididas em: aquisição, pré-processamento, segmentação e obtenção das medidas. A aquisição das imagens é realizada por especialistas do Instituto de Cardiologia. No pré-processamento, é extraída a região de interesse para a obtenção das medidas e a imagem é filtrada para a extração do ruído característico das imagens de ultra-som. A segmentação das imagens é realizada através de redes neurais artificiais, sendo que a rede neural utilizada é conhecida como Mapa Auto-organizável de Kohonen. Ao final do processo de segmentação, a imagem está pronta para a obtenção das medidas.

A técnica desenvolvida nesta dissertação para obtenção das medidas foi baseada nos exames realizados pelos especialistas na extração manual de medidas. Essa técnica consiste na análise da linha referente à estrutura de interesse onde serão detectadas as bordas. Para o início das medidas, é necessário que o usuário indique o ponto inicial sobre uma borda da estrutura. Depois de encontradas as bordas, através da análise da linha, a medida é definida pela soma dos pixels entre os dois pontos de bordas.

Foram realizados testes com quatro estruturas cardíacas fetais: a espessura do septo interventricular, o diâmetro do ventrículo esquerdo, a excursão do *septum primum* para o interior do átrio esquerdo e o diâmetro do átrio esquerdo.

Os resultados obtidos pelo método foram avaliados através da comparação com resultados de referência obtidos por especialistas. Nessa avaliação observou-se que a variação foi regular e dentro dos limites aceitáveis, normalmente obtida como variação entre especialistas. Desta forma, um médico não especializado em cardiologia fetal poderia usar esses resultados em um diagnóstico preliminar.

Palavras-chave: Processamento de imagens, medidas cardíacas, cardiologia fetal, ultra-som, redes neurais artificiais.

TITLE: “FETAL CARDIAC STRUCTURE MEASUREMENT THROUGH SEGMENTED ECHOCARDIOGRAPHIC IMAGES”

Abstract

Keywords: Image processing, cardiac measurements, fetal cardiology, ultrasound, artificial neural networks.

This work implements a semi-automatic computational method to measure cardiac structures from human fetus through the processing of ultrasound images. These images are used in the prenatal cardiac evaluations, allowing physicians to diagnose diseases even before the birth.

This Master’s Thesis is part of a research project developed at the Informatics Institute of the Federal University of Rio Grande do Sul, called SEGIME (Medical Image Segmentation). A computational tool is being developed in this project to aid in fetal echocardiographic examinations, with support of the the Fetal Cardiology team from the Cardiology Institute of Rio Grande do Sul .

Each image is processed in stages, divided in: acquisition, preprocessing, segmentation, and measure acquisition. The image acquisition is done by experts from the Cardiology Institute. The region of interest is extracted for measurements in the preprocessing stage and is filtered to reduce the noise found in ultrasound images. The image segmentation is executed by an artificial neural network known as Kohonen’s Self-organizing Maps. By the end of the segmentation process, the image is ready for the measure acquisition.

The technique of measure acquisition developed in this master’s thesis has been based in manual measurements done by experts. This technique consists on analysing the line relative to the structure of interest where borders will be detected. The user is asked to inform the start point over the structure borders. After the borders are found by the line analysis, the measure is defined by the sum of pixels between the two border points.

Tests with four fetal cardiac structures were done: interventricular septum thickness, left ventricle diameter, *septum primum* excursion inside the left atrium, and left atrium diameter.

The results obtained with the proposed method have been evaluated through comparison with reference results from experts. In this evaluation, the variation was regular and within the acceptable limits usually obtained with expert measurements. Therefore, a physician who is not specialised in fetal cardiology may use these results in a preliminary diagnostic.

1 Introdução

O uso da computação para fins médicos virou rotina dentro de hospitais e clínicas pelo mundo afora. É uma disciplina em constante desenvolvimento que gera muitos benefícios para a saúde humana. Os estudos nesse campo são variados e abrangem uma grande quantidade de áreas da computação e da medicina, formando uma imensa rede de pesquisas.

Uma das áreas da computação, que tem desenvolvido muitos trabalhos para a Medicina é o processamento de imagens. Com a constante evolução dos dispositivos de captura de imagens médicas, as aplicações do processamento de imagens se multiplicam, com tarefas como aquisição, formação, reconstrução, realce, compressão, armazenamento, análise e visualização de imagens.

Dentre os dispositivos de captura de imagem, o uso do ultra-som se destaca como uma técnica não-invasiva¹ que permite aos médicos obter imagens mais precisas do corpo humano, possibilitando o diagnóstico e tratamento de diversas doenças. O uso de ultra-som é fortemente recomendado para casos em que a saúde deve ser preservada, como quando é examinado o desenvolvimento de um feto humano.

O ultra-som representa uma ferramenta importante para detecção de defeitos congênitos no coração do feto. O exame é conhecido como ecocardiografia fetal. As imagens são obtidas por um aparelho denominado ecocardiógrafo. Esse aparelho possui uma sonda - o transdutor, que é manuseado pelo operador sobre o abdômen da gestante apontando para o coração do feto. A estrutura do coração é mapeada através da reflexão do ultra-som nas estruturas internas. Como resultado, uma seqüência de vídeo da dinâmica cardíaca é gerada [NEL 98, ALL 86].

O trabalho produzido ao longo dessa dissertação é parte de um projeto desenvolvido no IIUFRGS (Instituto de Informática da Universidade Federal do Rio Grande do Sul) que tem o apoio da equipe de cardiologia fetal do ICRGS (Instituto de Cardiologia do Rio Grande do Sul), liderada pelo Dr. Paulo Zielinsky. Trata-se do projeto SEGIME (Segmentação de Imagens Médicas), o qual direciona suas pesquisas à análise de imagens ecocardiográficas fetais e tem como objetivo gerar uma ferramenta computacional que auxilie no diagnóstico de exames ecocardiográficos fetais. Para atingir tal objetivo, a ferramenta deve ser capaz, entre outras coisas, de obter medidas de estruturas cardíacas a partir das imagens ecocardiográficas.

Neste contexto, a dissertação foi desenvolvida com o propósito de obter medidas de algumas estruturas cardíacas fetais. A idéia é criar um método que consiga medir todas as estruturas analisadas pelos especialistas ao longo do exame. Nesse trabalho foram analisadas quatro estruturas cardíacas, as quais interessam aos especialistas. Essas estruturas foram medidas pelo método. Os resultados foram avaliados através da comparação com uma medida de referência obtida por especialistas.

Embora imagens de ultra-som apresentem muita informação sobre as estruturas cardíacas do feto, estas são contaminadas por ruído do tipo *speckle* [BUR 78, CRI 85], que corrompe as bordas das estruturas, dificultando o processamento e por conseqüência a obtenção de medidas. Além do ruído característico do ultra-som, outros fatores influenciam a qualidade da imagem nos exames fetais, dentre eles: a posição do transdutor, o posicionamento do feto e a composição do tecido entre o feto e o transdutor [MAT 99].

A fim de resolver alguns problemas das imagens ecocardiográficas, são necessárias

¹ não necessita corte na pele, inserir instrumento ou contraste no corpo do paciente

algumas etapas de processamento de imagens antes que o método possa trabalhar diretamente nas medidas. Dentre as etapas realizadas antes das medidas estão a aquisição, o pré-processamento e a segmentação.

A etapa de aquisição consiste na obtenção das imagens a serem processadas, é realizada pelos médicos através do aparelho ecocardiógrafo. As imagens utilizadas nesse trabalho foram coletadas por membros da equipe de Cardiologia Fetal do ICRGS e cedidas ao pessoal do SEGIME para fins de pesquisa.

O pré-processamento visa a melhora da qualidade da imagem e sua adequação às fases posteriores, nessa etapa foram utilizados alguns filtros para extração de ruído e realce das imagens.

O objetivo da segmentação é identificar regiões similares, de acordo com algum critério. As imagens segmentadas são melhores de manipular, pois consistem de uma versão simplificada, contendo as características principais da imagem original. Assim, a imagem segmentada pode ser usada para obter medidas como distâncias, áreas e volumes. As imagens utilizadas nesse trabalho foram segmentadas em duas regiões, formando uma imagem binária que representa cavidade e tecido cardíaco.

Considerando imagens ecocardiográficas fetais, a segmentação é uma tarefa complexa, devido, principalmente, à baixa qualidade das imagens. Essa característica dificulta a obtenção de resultados através de métodos tradicionais. Com o intuito de obter resultados confiáveis, o grupo SEGIME tem estudado alguns modelos de redes neurais para serem utilizados na segmentação das imagens em sua ferramenta de software. Neste trabalho foi utilizada a rede neural desenvolvida por Kohonen, conhecida como Mapas Auto-organizáveis [KOH 90], que foi adaptada para realizar a segmentação de ecocardiografias por Piccoli [PIC 99a].

O método de obtenção das medidas é baseado nas técnicas utilizadas pelos especialistas para a realização das medidas nos exames tradicionais. Nesses exames é analisada uma linha na imagem, de onde são obtidas as medidas. Eles utilizam uma imagem conhecida como modo-M, que está descrita na Seção 5.1. Desta forma, é através da análise da linha, na imagem segmentada, que o método desenvolvido procura as bordas das estruturas de interesse.

Para iniciar o processo de medidas é necessária a interação do usuário, pois o método precisa de um ponto inicial para obter as medidas. Essa característica dá maior controle e confiança ao método por parte dos especialistas.

Neste trabalho são apresentados os resultados obtidos na medida de quatro estruturas cardíacas fetais, que são:

- a espessura do septo interventricular;
- o diâmetro do ventrículo esquerdo;
- a excursão do *septum primum* para o interior do átrio esquerdo;
- o diâmetro do átrio esquerdo.

As duas últimas medidas são utilizadas para obter o índice de excursão do *septum primum*. Esse índice foi sugerido pelos especialistas como uma medida importante e que tem sido pesquisada no ICRGS.

O septo interventricular é a parede que separa os ventrículos esquerdo e direito, sua espessura é importante na análise cardíaca para a determinação da massa ventricular

e detecção de malformações. A comunicação interventricular e a hipertrofia miocárdica fetal são exemplos de cardiopatias congênitas onde essa medida ajuda no diagnóstico [ZIE 97a, ZIE 97].

O ventrículo é uma das câmaras musculares que bombeiam o sangue para fora do coração, o seu diâmetro pode ser utilizado, juntamente com a espessura do septo interventricular e da sua parede, na determinação da massa ou volume ventricular [ARA 96].

O *septum primum* é uma fina membrana interatrial, ela inicia a separação dos átrios. É também conhecida como membrana do forâme oval, porque funciona como uma válvula que fecha o forâme oval na contração atrial. O forâme oval é um orifício de passagem de fluxo interatrial que se fecha permanentemente após o nascimento [FIR 95]. Essa membrana expande-se para dentro do átrio esquerdo, por isso é necessário o diâmetro do átrio esquerdo para a medida do seu índice de excursão.

O restante deste texto está organizado da seguinte forma: O Capítulo 2 aborda alguns dos principais métodos de captura de imagens utilizados na medicina, nesse trabalho foi dada ênfase às imagens bidimensionais. O Capítulo 3 apresenta alguns conceitos da área de processamento de imagens e processamento de imagens médicas. Devido à utilização de redes neurais artificiais no decorrer da dissertação foi necessário um estudo mais profundo da área, o qual está expresso no Capítulo 4; A partir do Capítulo 5, começa a descrição do trabalho realizado na dissertação, nesse Capítulo são apresentadas as medidas trabalhadas, junto com uma idéia básica da anatomia cardíaca fetal, necessária ao entendimento do trabalho. No Capítulo 6 são apresentadas as ferramentas computacionais e os métodos utilizados para a resolução das etapas, desde o pré-processamento, até a obtenção das medidas. No Capítulo 7 são descritos os resultados obtidos pelo método. Para finalizar, são apresentadas as conclusões.

2 O Panorama de Imagens Médicas

O objetivo principal das imagens na Medicina é prover os médicos com informações necessárias para o diagnóstico preciso das condições do paciente e acompanhar sua reação à terapia. As imagens auxiliam os médicos a avaliarem funções e estruturas de partes do corpo. Essa área tem passado por diversas transformações nos últimos anos, devido principalmente ao progresso da tecnologia de captura de imagem.

Para analisar uma possível fratura, no acompanhamento pré-natal, monitoramento de um tumor, assim como em diversas outras aplicações médicas algum tipo de imagem está sendo analisada. Entre elas destacam-se exames como raio-x, tomografia computadorizada (TC), ultra-som, ressonância magnética (RM), imagens de medicina nuclear, micrografias, endoscopias, fotografias e exames relacionados a especialidades em particular como a oftalmologia, entre outras.

Assim como os médicos possuem suas especializações que normalmente abrangem um área específica da medicina (cardiologia, pediatria, etc.), geralmente as técnicas são direcionadas a um exame específico (fraturas, pré-natal, tumores, etc.). Cabe ao profissional optar pelo melhor exame, levando em conta as necessidades de diagnóstico e as limitações de cada técnica.

As modalidades de captura de imagens médicas utilizam diversas técnicas para obter os resultados, sendo que algumas podem ser nocivas ao paciente, que é o caso dos exames que utilizam radiação como a tomografia computadorizada e a radiografia por raio-X. Outro problema com a saúde do paciente são os chamados exames invasivos, onde há uso de contraste ¹, como as imagens de medicina nuclear. Alguns exames não agridem de forma alguma o paciente, mas também tem seus problemas, é o caso dos exames que utilizam ultra-som que geram imagens de baixa qualidade ou a RM, onde as imagens são de boa qualidade mas o custo do exame é alto.

O processamento de imagens por computador tem obtido resultados espetaculares e colaborado na evolução das técnicas de imagens médicas. Existem muitas aplicações para processamento dessas imagens, seja para a atenuação de ruído, segmentação de estruturas, cálculo de medidas, volume, visualização 3D, 2D entre outras tarefas muito úteis no dia a dia da medicina.

Neste capítulo será dada ênfase ao exame de ultra-som, por ser o tipo de imagem usada durante os testes para obtenção das medidas na presente pesquisa. Porém, também serão introduzidos os principais métodos de geração de imagens médicas.

No decorrer do texto serão apresentadas as principais modalidades de imagens médicas, na próxima Seção é apresentada a modalidade mais importante para o desenvolvimento desse trabalho, o ultra-som. A Seção 2.2 apresenta as imagens geradas através da Medicina Nuclear. As imagens de ressonância magnética são apresentadas na Seção 2.3. Na Seção 2.4 é feita uma rápida apresentação das imagens de Raio-X. Finalmente, a tomografia computadorizada é apresentada na Seção 2.5.

2.1 Ultra-som

Dentre as diversas modalidades de imagens utilizadas para visualização médica, ultra-som destaca-se por ser um exame rápido e barato que não expõe o paciente à radiação

¹injeção de algum tipo de substância no corpo do paciente para obter uma melhor qualidade

e normalmente não necessita contraste. Neste exame, é possível avaliar estruturas do corpo do paciente. Abordaremos em maior profundidade este assunto por ser a base da pesquisa a ser apresentada nos próximos capítulos.

Ultra-sonografias utilizam energia acústica para formar uma imagem do corpo. Estes exames estão baseados no princípio do sonar. Num sonar subaquático, um pulso de onda sonora é enviado e refletido num objeto. Com o tempo requerido para receber o eco e a velocidade do som na água, a distância do objeto pode ser determinada. Esse princípio é inspirado em morcegos e golfinhos, que o usam para orientação e busca de alimentos. Na Figura 2.1 é apresentado um exemplo do golfinho. O golfinho envia ondas ultra-sônicas e usa ecos para localizar o alimento.

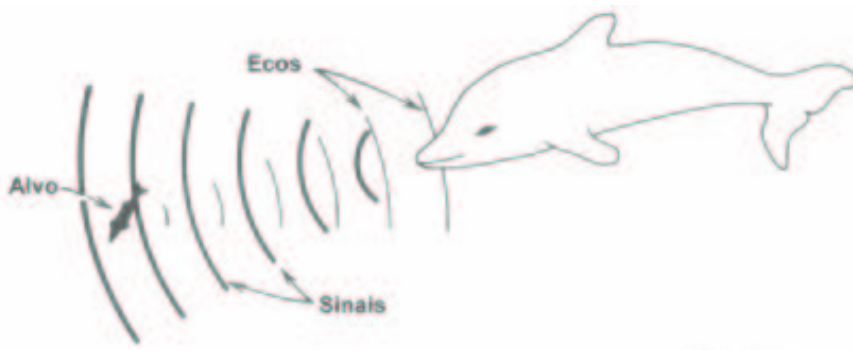


FIGURA 2.1 – Exemplo do uso de ultra-som pelos golfinhos.

As imagens possuem muitos problemas na visualização, algumas das causas da degradação são:

- o transdutor ser manual na captura;
- as estruturas analisadas são imprevisíveis e não homogêneas.

O exame de ultra-som não possui a qualidade da TC ou da RM. A imagem contém grande quantidade de ruído denominado *speckle* [BUR 78] que dificulta o problema da identificação de estruturas. Técnicas para atenuação do ruído e segmentação automática da imagem beneficiam o diagnóstico.

2.1.1 Formação da Imagem de Ultra-som

O ouvido humano escuta frequências de 20 a 20000 Hertz ou ciclos por segundo (Hz). As ondas do ultra-som possuem frequências maiores que 20000 Hz. Para gerar imagens médicas, a frequência normalmente usada está entre 1 e 10 MHz (1 milhão até 10 milhões de Hz) [NEL 98]. Algumas aplicações específicas em oftalmologia, dermatologia e imagem intravascular podem utilizar frequências maiores (15–100 MHz).

Ultra-som é uma onda de som que propaga através de um meio com frequência superior a 20000 Hz [FER 86]. O meio determina a velocidade na qual ela viaja. No ar a velocidade do som é de 331 metros por segundo (m/s), já no tecido humano ela viaja a média de 1540 m/s. Esse valor é uma média porque a velocidade varia conforme o tecido. Na Tabela 2.1 são apresentadas as variações de velocidade do som em diferentes substâncias do corpo humanos.

TABELA 2.1 – Densidade e velocidade do som em diferentes meios [BER 2000].

	densidade (kg/m ³)	velocidade (m/s)
Água	1000	331
Cérebro	1020	1530
Músculo	1040	1580
Gordura	920	1450
Osso	1900	4040

Na Tabela 2.1, há um bom exemplo de como a velocidade varia com a densidade e compressão de um material. A densidade do osso é muito maior que a da gordura e, conseqüentemente, a velocidade do som através do osso é maior que na gordura. Essa diferença de densidade e compressão é responsável pela geração de ecos. Quando uma onda de som encontra meios de diferentes densidades, parte da onda é refletida, criando um eco. Quanto maior a diferença na densidade do meio, mais forte o eco e maior a quantidade de sinal refletido.

Embora um eco seja gerado na diferença de densidade dos meios, nem todo o sinal é refletido, parte continua através do tecido restante. Apesar de sua força inicial, o eco e a onda de som original deterioram-se com o tempo. Devido a deterioração natural das ondas de som e a perda da força causada pela reflexão, os dados obtidos de ultra-som são normalmente fracos ou pouco nítidos gerando imagens de baixa qualidade. Na Figura 2.2 é apresentada uma imagem obtida com ondas de ultra-som.



FIGURA 2.2 – Ecocardiografia fetal.

2.1.2 Transdutor

Um dispositivo que converte energia elétrica em energia mecânica, ou vice-versa, é chamado transdutor [FER 86]. Geradores de ultra-som são freqüentemente chamados de transdutores. Embora existam vários métodos de geração de ultra-som, o mais importante para aplicações médicas envolve efeitos piezoelétricos. Muitos cristais podem ser cortados de modo que uma voltagem oscilante através deles produz uma vibração, gerando uma onda sonora. Esses cristais são conhecidos como cristais piezoelétricos. Na

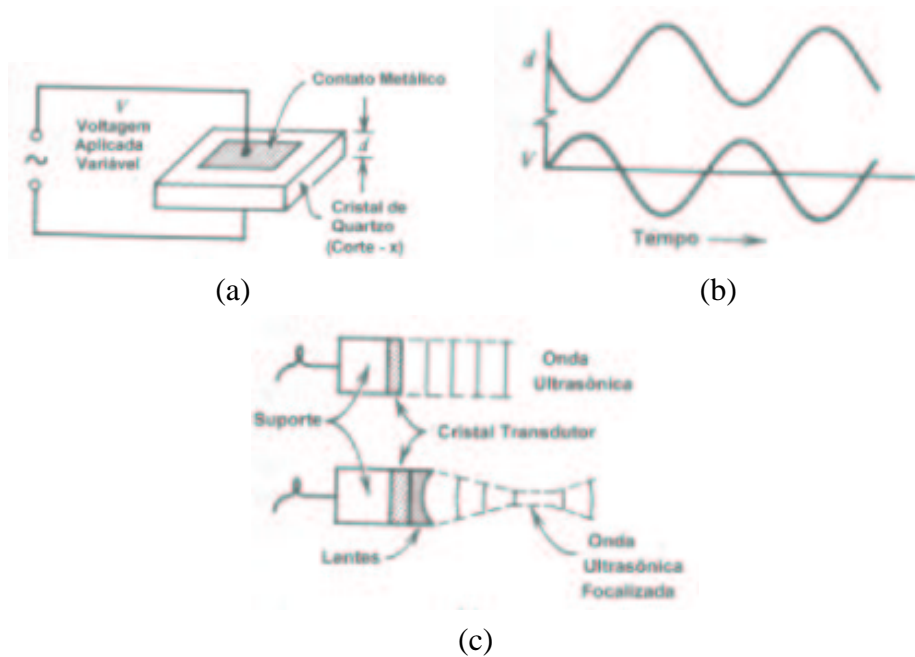


FIGURA 2.3 – Comportamento do cristal de quartzo na produção de ultra-som.

Figura 2.3 é apresentado o comportamento de um cristal de quartzo usado na produção de ultra-som. Os cristais são cobertos com uma camada condutora, normalmente prata. Fios elétricos são conectados à camada condutora para aplicar e detectar a voltagem. Na Figura 2.3(a) temos a ligação dos eletrodos, a Figura 2.3(b) apresenta a variação da espessura d do cristal devido a voltagem alternada V aplicada e na Figura 2.3(c) tem-se o cristal montado numa boquilha para produzir o feixe de ultra-sons que é focalizado e produzido quando uma lente acústica é ligada ao cristal.

A seqüência dos eventos realizados no transdutor inicia com a aplicação da voltagem nos cristais piezoelétricos que deformam-se criando “distúrbios mecânicos” (ondas de som) de uma determinada freqüência. A rajada de som dura aproximadamente um microsegundo. A onda de som entra no corpo e viaja através do tecido macio até uma região onde haja variação na densidade. Essa troca de meio gera um eco, o qual volta para o transdutor. Na seqüência o transdutor entra em fase de escuta que demora aproximadamente um milissegundo. Durante a fase de escuta o cristal detecta o eco (vibração mecânica) e o converte em impulso elétrico. Esse impulso elétrico é enviado, através dos fios conectados aos cristais, ao ecocardiógrafo onde é exibido em vídeo. A partir da detecção dos impulsos elétricos, há várias maneiras nas quais a informação pode ser apresentada. A mais antiga e simples é conhecida como modo-A ou mapeamento A.

Nas imagens do modo-A, o eco (voltagem) é exibido com picos de amplitude no vídeo de um osciloscópio. Enquanto a onda de som é lançada no corpo, um ponto de luz move-se através do osciloscópio. Detectando um eco, um pico é gerado. O eixo horizontal representa o tempo. Portanto, a profundidade da região que criou o eco pode ser encontrada usando a Equação 2.1.

$$\text{Profundidade} = 1/2 * c * t \quad (2.1)$$

onde “ t ” é o tempo (o ponto ao longo do eixo horizontal no qual o pico ocorreu) e “ c ” é a velocidade do som em determinado meio (as mais comuns são apresentadas na




FIGURA 2.4 – Método de mapeamento A ou modo-A.

Tabela 2.1).

A Figura 2.4 apresenta uma encefalografia modo-A, uma esquema de como funciona a captura de imagens neste tipo de mapeamento pode ser visto em 2.4(a), lá é apresentada a localização da linha média do cérebro. Pulsos de ultra-som são enviados ao cérebro pelo transdutor T e os ecos são mostrados no osciloscópio. Na Figura 2.4(b) é apresentado um par de mapeamentos de um cérebro normal. O transdutor T está no lado direito da cabeça no mapeamento de cima e do lado esquerdo no mapeamento de baixo, F indica ecos do lado de trás do crânio, não existindo deslocamento do eco de linha média. Já na Figura 2.4(c), há um par de mapeamentos de um cérebro anormal, mostrando um deslocamento de 7 milímetros (mm) adiante no lado direito (mapeamento de cima) que poderia ser causado por um tumor no lado esquerdo do cérebro.

Outro meio de exibir informações do eco é chamado modo-B ou mapeamento B. O modo-B produz imagens bidimensionais (2D) de “fatias” do corpo. O modo-B estabelece informação sobre a estrutura interna do corpo. Ele tem sido usado nos diagnósticos de olhos, fígado, seios, coração e feto. Um esquema do modo-B é apresentado na Figura 2.5, onde o posicionamento do transdutor na gestante e como a imagem do feto é apresentada no vídeo.

No modo-B, as ondas de som avançam de trás para frente um número de vezes por segundo. O sistema segue cada onda e quando um eco é detectado, um ponto em uma linha correspondente é produzido. O tempo entre a detecção de ecos de uma onda permite ao sistema calcular a distância do ponto que criou o eco, esta é traduzida em uma linha com pontos separados pela distancia d . O brilho desses pontos é proporcional a força dos ecos. Por isso todos os pontos criam uma imagem de uma fatia do corpo. Nos trabalhos iniciais com modo-B todos os ecos mostrados tinham o mesmo brilho e era conhecido como *exposição margem fundo*. O método melhorado eletronicamente muda o brilho de modo que os ecos fortes aparecem mais brilhantes que os fracos, *exposição escalas de cinza*. A Figura 2.6 mostra um exemplo de modo-B nos dois tipos de exibição, onde a Figura 2.6(a) apresenta a exposição margem fundo, e a Figura 2.6(b) a exposição em escalas de cinza.




FIGURA 2.5 – Esquema do método de captura em modo-B de um feto.




FIGURA 2.6 – Modo-B de ultra-som do abdômen superior.

2.1.3 Problemas no ultra-som

Infelizmente, nem todos os pontos apresentados em uma imagem representam as estruturas de interesse. Esses pontos que não pertencem às estruturas são conhecidos como artefatos [NEL 98]. A causa desses artefatos geralmente é atribuída a ruído eletrônico, interferência, processamento do sinal ou reverberação.

Ruído eletrônico ou interferência podem vir de dentro ou fora do aparelho de ultrassom. Dentro desse dispositivo eletrônico os elétrons movem-se de maneira aleatória até o sinal ser aplicado. Mas mesmo depois disso, alguns elétrons ainda se movem aleatoriamente. Isto pode criar pontos cinza na imagem que não representam a estrutura de interesse. Da mesma maneira, sinais de alta frequência criados fora do aparelho de ultrassom (em outros aparelhos) produzem resultados similares. Quando um sinal é recebido pela unidade, o caminho pelo qual ele é processado pode criar artefatos. Um eco muito forte oculta outros sinais de eco recebidos depois dele e cria artefatos de omissão.

Muitas modificações são feitas no sinal no sentido de melhorar a imagem resultante. Algumas técnicas de processamento suavizam a imagem, enquanto outras realçam as bordas. A suavização pode gerar perda de detalhes enquanto o reconhecimento de bordas pode incluir artefatos, gerando ruído nos ecos. Muitos desses artefatos não são prejudiciais do ponto de vista de diagnóstico, mas contribuem para a diminuição da qualidade da imagem.

Artefatos de reverberação geralmente resultam de reflexão de um eco retornado

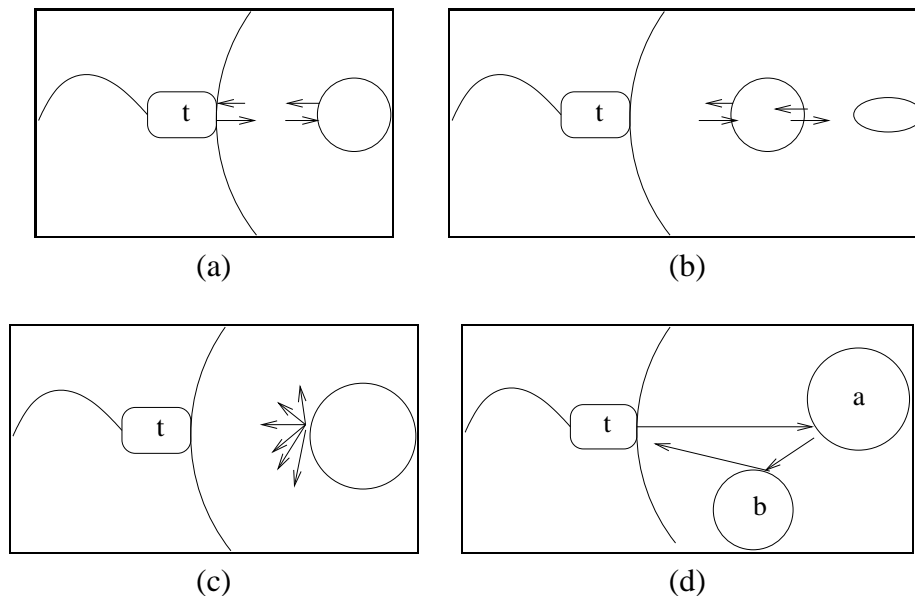


FIGURA 2.7 – Efeitos de reverberação em ondas de som.

pelo transdutor ou reflexão de uma onda sonora fora da estrutura. Alguns exemplos de diferentes tipos de reverberação podem ser vistos na Figura 2.7.

Na Figura 2.7(a) pode ser visto que a onda de som emitida pelo transdutor t é refletida por uma superfície interna. Esse eco retorna para o transdutor, onde ele é detectado. O eco encontrando outra superfície, que é o próprio transdutor, é refletido para o corpo do paciente novamente, encontrando as mesmas estruturas já gravadas. A profundidade da estrutura é determinada pelo tempo da detecção do eco. O segundo encontro com a mesma estrutura cria outro ponto com a mesma profundidade da verdadeira estrutura. Essa reverberação continua até a onda se deteriorar. A Figura 2.7(b) mostra quando uma onda encontra uma estrutura, parte daquela onda é refletida como um eco, para ser detectada pelo transdutor, outra parte da onda original continua além daquela estrutura para encontrar estruturas mais profundas, quando a onda é novamente refletida. No caminho de volta ao transdutor ela encontra aquela estrutura onde ecoou antes, parte dela continuando até o transdutor e parte é refletida novamente ao corpo e encontra estruturas já detectadas. Isso dura até a onda se deteriorar.

Artefatos de reverberação podem também conter reflexões de ondas de estruturas a menos de 180° . Essas ondas não retornaram ao transdutor mas viajaram pelo corpo em outras direções. Elas podem eventualmente ser detectadas pelo transdutor depois de terem sido refletidas diversas vezes. Isso inclui artefatos dispersos e com múltiplas direções. Quando uma onda atinge a superfície de uma estrutura, reflexões são criadas em diversas direções, não apenas 180° . Estes ecos dispersos podem ser detectados pelo transdutor criando um padrão de ponto “salpicado” na imagem, conhecido como ruído *speckle*. Um exemplo de dispersão pode ser visto na Figura 2.7(c) onde a onda emitida pelo transdutor t ecoou em diversas direções quando encontrou uma estrutura. Além das reflexões em estruturas, as ondas e os ecos podem colidir, se dispersar e gerar o ruído *speckle*.

Artefatos de múltiplas direções ocorrem quando as ondas de som encontram uma superfície. A onda é sempre refletida para fora do transdutor e encontra outra superfície. O eco criado por essa superfície eventualmente chega ao transdutor. Desde que o transdutor interprete ecos que ocorram diretamente no caminho, o ponto é colocado no lugar

errado do eixo do transdutor onde a superfície realmente ocorreu, criando um artefato. Um exemplo desse tipo de problema pode ser visto na Figura 2.7(d) com uma reflexão nas estruturas *a* e *b* antes de voltar ao transdutor *t*.

Todos estes artefatos colaboram para desfocar e gerar ruído na imagem. Somando-se esses problemas com as imagens pouco nítidas criadas pelas verdadeiras estruturas, a tarefa de avaliação dessas imagens torna-se bastante difícil e por isso o processamento de imagens de ultra-som auxilia o diagnóstico.

2.1.4 Ecocardiografia fetal

Uma ecocardiografia fetal é um ultra-som do coração de um feto. Da mesma forma que outro tipo de exame baseado em ultra-som, utiliza essas ondas para formar imagens. Não há exposição à radiação e nenhum risco conhecido com esse tipo de exame. A época ideal para a visualização do coração fetal estende-se da 18^a à 24^a semana gestacional. Já no 3^o trimestre, a coluna vertebral é frequentemente anterior e as costelas são mais calcificadas, sombreando a área cardíaca e podendo dificultar a adequada avaliação do coração [TAT 97].

O exame é feito em uma sala privada com a gestante deitada sobre uma cama na posição dorsal (barriga para cima). O médico aplica um gel especial sobre o abdômen dela a fim de deslizar o transdutor, evitar o contato das ondas com o ar e resfriar o transdutor. Esse é movido em torno do abdômen da gestante para capturar as imagens do bebê, como na Figura 2.8.



FIGURA 2.8 – Captura de imagens ecocardiográficas fetais.

O exame ecocardiográfico fetal engloba avaliação anatômica, hemodinâmica, funcional e do ritmo cardíaco [MAT 99]. Na avaliação anatômica são analisados átrios, ventrículos e suas conexões. É durante essa análise que os especialistas realizam as medidas nas estruturas de interesse.

O ultra-som é um dos maiores avanços da medicina fetal para o diagnóstico precoce, capaz de identificar 90% das malformações fetais [VAR 2000]. Tem sido de considerável ajuda para avaliação dos padrões de crescimento do feto e no diagnóstico de cardiopatias congênitas². Esse exame tem sido usado na avaliação pré-natal há aproximadamente duas décadas [KAN 98].

A visualização do coração fetal tem orientações diferentes daquelas padronizadas na ecocardiografia extra-uterina [MAT 99], sendo alguns “planos de corte” exclusivos

²Problema congênito no sistema cardiovascular fetal




FIGURA 2.9 – Incidência do feixe de ultra-som para cada plano do coração fetal.

desta fase do desenvolvimento humano [SIL 85]. Os seis principais planos de cortes para a análise cardíaca fetal são: imagem de 4 câmaras, imagem longitudinal das câmaras esquerdas, imagem oblíqua das câmaras direitas, imagem transversa dos ventrículos, imagem do arco aórtico e imagem do arco ductal [MAT 99], os quais são apresentados na Figura 2.9.

O corte quatro câmaras (Figura 2.9(a)) é o mais valioso na detecção de malformações cardíacas estruturais, além de ser o mais fácil de ser obtido. Nesta projeção, o coração ocupa cerca de um terço do tórax fetal. Dentre as estruturas visualizadas na imagem quatro câmaras estão o átrio esquerdo (AE), átrio direito (AD), ventrículo direito (VD), ventrículo esquerdo (VE), valva mitral (VM), valva tricúspide (VT), septo interventricular (SiV), septo interatrial (SiA) e o forame oval (Fo). No corte longitudinal das câmaras esquerdas (Figura 2.9(b)) são apresentadas com melhores detalhes as correlações entre as vias de entrada e de saída do coração esquerdo. Pode-se identificar estruturas como o AE, VM, VE, SiV, valva aórtica (VAo), aorta ascendente (AoA), VD e valva pulmonar (VP). A imagem oblíqua das câmaras direitas (Figura 2.9(c)) é uma imagem intermediária entre 4 câmaras e longitudinal, nela pode-se visualizar o AE, AD, SiA, Fo, VT, VD, VP, tronco pulmonar (TP), VAo. Poucos detalhes anatômicos podem ser observados na imagem transversa dos ventrículos (Figura 2.9(d)) entre eles o VD, SiV e VE. Na visão do arco aórtico (Figura 2.9(e)), todos os segmentos da aorta, desde a ascendente até o nível abdominal da AoD podem ser documentados numa mesma imagem. A imagem do arco ductal ou arco pulmonar (Figura 2.9(f)) é exclusiva da vida intra-uterina.

O exame de ultra-som normalmente é caracterizado por imagens muito precárias. Nas ecocardiografias fetais além de todos os problemas normais já discutidos, a qualidade do exame pode ser limitada pela movimentação constante e o posicionamento fetal, além

disso outro fator que colabora com a degradação das imagens é a obesidade materna [ALL 86]. A qualidade dessas imagens é muito baixa (ver Figura 2.2), tornando complexo o processamento.

2.2 Medicina Nuclear

A Medicina Nuclear é uma das mais modernas técnicas de investigação e vem se impondo gradativamente como excelente método de diagnóstico por imagem. Utilizando-se de pequenas quantidades de substâncias radioativas e equipamento especial (câmara de cintilação ou Gama-Câmera), são obtidas várias imagens dos órgãos a serem estudados sem a utilização de grandes quantidades de radiação. A cintilografia permite o estudo da fisiologia dos órgãos e constitui método não invasivo de diagnóstico.

A Medicina Nuclear utiliza substâncias radioativas para a obtenção de imagens. Estas substâncias, conhecidas como traçadores, podem ser injetados ou ingeridos, dependendo do tipo do estudo a ser realizado. Um exemplo de imagem por Medicina Nuclear é apresentado na Figura 2.10.




FIGURA 2.10 – Imagem de medicina nuclear da estrutura óssea.

Essa modalidade de exame é utilizada numa grande variedade de diagnósticos de doenças, entre elas, câncer e patologias renais, hepáticas, cerebrais e do sistema músculo-esquelético.

2.3 Ressonância Magnética

Ressonância magnética é um dos métodos não invasivos mais poderosos para o diagnóstico e pesquisa médica. Este método aproveita as propriedades naturais dos átomos existentes no corpo humano para criar uma imagem diagnóstica. Os exemplos na Figura 2.11, apresentam a imagem da cabeça (a) e uma imagem de RM do cérebro (b). É um método que não utiliza radiação como acontece com os exames baseados em raios-X, que são a fonte da imagem por exemplo da TC. A imagem por RM explora a magnetização natural do átomo mais abundante do corpo humano, o hidrogênio, o qual contém apenas um próton e apresenta por isso um pequeno momento magnético. O contraste entre os diversos tecidos do corpo humano (normais e patológicos) é criado em função do número de átomos de hidrogênio existentes num determinado tecido e do meio onde se encontram. As aplicações clínicas da RM são muito dispersas destacando-se, entre as mais importantes, o estudo do crânio, coluna e do sistema músculo-esquelético.




FIGURA 2.11 – Imagens obtidas através de ressonância magnética.

2.4 Radiografia

O raio-X é uma forma de radiação eletromagnética (como a luz) de elevada energia e que ao penetrar através do corpo humano vai formar uma imagem em algum meio sensível ao raio-X. O meio pode ser um filme, uma câmera de televisão combinada com um conversor de raios-X para fótons ou detectores discretos cujas saídas sejam combinadas para a reconstrução de uma imagem digital. As estruturas do corpo humano que são mais densas (ossos) aparecem no filme em branco. O ar e estruturas da mesma densidade aparecem em preto e as outras estruturas aparecem em gradientes de cinza de acordo com a seu grau de absorção de raios-X. Na Figura 2.12, são apresentados dois exemplos de imagens de raio-X.



FIGURA 2.12 – Radiografias da coluna cervical.

A obtenção de uma radiografia convencional pode ser definida, de maneira simplificada, como a leitura, sobre um filme radiográfico, dos fótons de Raio-X atenuados pela estrutura radiografada. Essa atenuação diferenciada dos feixes incidentes, produto da falta de homogeneidade dos tecidos, sensibiliza cristais de prata disseminados sobre uma emulsão fotográfica, produzindo pontos de maior ou menor transparência, resultado




FIGURA 2.13 – Imagens obtidas através de tomografia computadorizada.

de uma maior ou menor taxa de transferência energética para o filme.

Na realização do exame radiográfico comum, os riscos de radiação são muito reduzidos porque há uma monitoração e regulação mínima da quantidade de exposição necessária para se produzir uma imagem. No entanto, não é muito indicado às gestantes. Pelo nível de definição de imagem, ossos e pulmões são as estruturas que melhor se adaptam a avaliação com o Raio-X.

2.5 Tomografia Computadorizada

A tomografia computadorizada (TC) é um método de exame radiológico fundamentado no trabalho simultâneo de um computador e um aparelho de raio-X. Os fótons de raio-X atravessam o corpo do paciente para depois serem lidos e quantificados por um conjunto de detectores que encaminham estas informações à uma central de processamento de dados onde os mesmos são processados e transformados em imagem. Na Figura 2.13 são apresentados exemplos de TC onde a Figura 2.13(a) apresenta uma imagem tridimensional do crânio e a Figura 2.13(b) uma imagem do abdômen (órgãos internos).



FIGURA 2.14 – Esquema de emissão e detecção de raio-X em tomografias.

O tomógrafo aplica ondas de raio-X através do corpo em vários ângulos. Os raios são disparados por um turbilhão que gira em torno do paciente, como na Figura 2.14.

A obtenção da imagem na TC é semelhante à de Raio-X, diferenciando-se apenas na leitura das informações e formas de aquisição. No método convencional, as imagens são obtidas no filme por projeção, enquanto que na TC a estrutura é decomposta pelos feixes de raio-X, lida nos detectores e finalmente montada ponto a ponto (*pixels*) através de cálculos matemáticos efetuados pelo computador. Através de um monitor, essa decomposição ponto a ponto derivada do movimento do tubo de raios-X ao redor do paciente possibilita a individualização das estruturas contidas em um corte, sem superposição de imagens, permitindo o estudo individual de cada um desses cortes.

3 Processamento de Imagens Aplicado à Medicina

Rotinas de diagnósticos em hospitais e clínicas médicas normalmente envolvem alguma modalidade de imagens do corpo humano e sua análise. Em muitas dessas modalidades as imagens geradas são ruins, como já foi apresentado no capítulo 2. Essa característica dificulta a análise da imagem tornando apropriado o uso de técnicas de processamento de imagens.

O processamento de imagens possui diversas técnicas úteis para a área de diagnóstico por imagem. Compactação de imagens, reconstrução de dados 3D, realce de bordas, segmentação, extração de medidas, detecção de estruturas anormais, hemorragias e tumores são algumas das aplicações que ajudam os especialistas a analisar as imagens.

Para o processamento de imagens médicas são necessárias algumas etapas pré-estabelecidas, que basicamente são quatro: aquisição, pré-processamento, segmentação e análise de imagens. Normalmente, essas etapas seguem uma ordem cronológica fixa, sendo que as vezes não é necessária uma ou outra para chegar ao resultado final. Na Figura 3.1 é apresentado um esquema com as etapas fundamentais ao processamento de imagens médicas.




FIGURA 3.1 – Etapas fundamentais no processamento de imagens médicas.

A aplicação das técnicas de processamento de imagens médicas tem algumas peculiaridades. Enquanto o sinal usado em processamento de imagens em geral é razoavelmente bem definido, em imagens médicas isto não ocorre.

A avaliação dos resultados é muito importante no desenvolvimento de aplicações de processamento de imagens médicas. É difícil definir uma metodologia para avaliar os resultados. Normalmente, a avaliação de resultados em processamento de imagens é realizada por um conjunto de observadores especialistas ou através da comparação de resultados manuais (especialista) e automáticos.

A área de processamento de imagens médicas é muito ampla, existindo diversos tipos de imagem e cada um tem suas peculiaridades. Nesse Capítulo, serão descritas as etapas básicas para processar imagens médicas, dando ênfase àquelas utilizadas na implementação dessa dissertação.

Na próxima Seção será apresentada a etapa de aquisição de imagens. A etapa de pré-processamento é introduzida na Seção 3.2, enquanto a Seção 3.3 apresenta a etapa de segmentação e suas técnicas. Finalmente na Seção 3.4 é apresentada a etapa de análise de imagens.

3.1 Aquisição

Para visualização e processamento de uma imagem é necessário que os dados (a imagem) sejam representados de forma apropriada, como por exemplo em uma matriz. Cada imagem digital é um conjunto de pontos chamados *pixels* que de uma forma discreta

representam os componentes da região de interesse. A imagem capturada por um sensor ¹ é expressa como uma função contínua $f(x,y)$ de duas coordenadas no plano em uma matriz de M linhas e N colunas [SON 98].

A aquisição de imagens médicas consiste em obter imagens do corpo humano. Essa etapa do processamento não pode ser implementada em *software* e necessita *hardware* especializado. Os dispositivos de captura de imagens (*scanners*), variam conforme o tipo das imagens de interesse (TC, RM, Ultra-som, Raio-X, etc.).

Normalmente, os *scanners* de captura de imagens médicas estão instalados em hospitais ou clínicas e a tarefa de captura é realizada pelo pessoal da área médica. Quando necessário as imagens são gravadas em alguma mídia (disco ótico, disquetes, fitas de vídeo, disco rígido, filme radiográfico, etc.). *Scanners* modernos geralmente possuem saída digital de imagens. Os tomógrafos (Figura 3.2(a)), por exemplo, geram as imagens diretamente dentro do computador bem como *scanners* de ressonância magnética e medicina nuclear. *Scanners* de ultra-som (Figura 3.2(b)) normalmente gravam a imagem de maneira analógica em fitas VHS, sendo que muitos deles possuem unidades de gravação digital da imagem. Imagens de Raio-X são normalmente geradas em filmes radiográficos, embora já existam dispositivos que gravam as imagens diretamente na forma digital.



(a)



(b)

FIGURA 3.2 – Exemplos de *scanners* médicos.

Dependendo da necessidade da aplicação, as imagens podem ser adquiridas em preto e branco, nível de cinza ou coloridas. Imagens em preto e branco são pobres em detalhes mas têm a vantagem de requerer pouco espaço de armazenamento e os procedimentos para trabalhar com essas imagens são geralmente simples e rápidos. Imagens em níveis de cinza têm uma escala que, normalmente, varia de 2 até 256 tonalidades. Quanto maior a escala de níveis de cinza, maior é a riqueza de detalhes da imagem, porém, maior também a necessidade de espaço para o armazenamento e os procedimentos para manipulação tendem a ser mais complexos e lentos. Imagens coloridas ainda oferecem algumas restrições, devido a espaço de armazenamento e velocidade de processamento.

Embora todos os cuidados na aquisição das imagens, alguma informação indesejável sempre aparece. No ultra-som fetal, a qualidade dependerá de alguns fatores como o tipo de equipamento, a idade gestacional, posição fetal, anomalias anatômicas, estrias abdominais e obesidade da gestante, os quais não podem ser controlados pelo operador

¹o sensor pode ser uma câmera digital, um tomógrafo, ecocardiógrafo, etc.

[ALL 86]. Quanto melhor a qualidade da imagem adquirida, mais fáceis e rápidos serão os processamentos das fases posteriores.

3.2 Pré-Processamento

Pré-processamento abrange as operações necessárias antes do processamento da imagem, seja para melhorá-la ou suprimir informação irrelevante. Nessa etapa, procura-se modificar e preparar os valores dos *pixels* da imagem com o objetivo de facilitar as operações subseqüentes e obter melhores resultados [AWC 96]. As operações realizadas nesta etapa são dependentes do problema apresentado, ou seja, são soluções específicas para cada caso. Algumas técnicas que funcionam bem em determinado tipo de imagem podem ser totalmente inadequadas para outros tipos.

O pré-processamento pode ser dividido em duas abordagens: realce e restauração de imagens [AWC 96]. Ambos têm o objetivo de melhorar a imagem em algum aspecto. O realce de imagens é utilizado para melhorar a qualidade da imagem ou enfatizar algum aspecto particular na imagem. Os resultados podem produzir uma imagem muito diferente da original, alguns aspectos podem ser sacrificados de forma a melhorar outros. A restauração é um processo que tenta reconstruir ou recuperar uma imagem que foi degradada, usando algum conhecimento do fenômeno que originou a degradação e aplicando o processo inverso para recuperar a imagem original [GON 93].

Para diferenciar as duas abordagens, pode-se dizer que o realce é a aplicação de procedimentos heurísticos projetados para manipular a imagem. Por exemplo aumento do contraste e manipulação de histograma, que são essencialmente baseados nos aspectos agradáveis que podem ser apresentados ao observador. Funções de suavização de ruído ou borramento são consideradas técnicas de restauração porque envolvem a extração de características da imagem.

Uma das mais simples e importantes técnicas de realce é a equalização do histograma. O histograma de uma imagem em níveis de cinza representa as freqüências relativas de ocorrência de vários níveis de cinza da imagem [JAI 89]. Pode-se dizer que um histograma informa quantos *pixels* na imagem possuem um determinado nível de cinza, definido entre 0 (preto) a 255 (branco). Histogramas mal distribuídos, concentrados em um determinado ponto, apresentam imagens ruins (muito claras ou escuras). A equalização do histograma de uma imagem serve exatamente para melhor distribuir (uniformizar) os valores dos níveis de cinza de tal forma que se obtenha uma imagem com melhor qualidade. O resultado de uma equalização de histograma pode ser observado comparando-se as Figuras 3.3(a) e 3.3(b) e seus respectivos histogramas.



FIGURA 3.3 – Equalização do histograma dos níveis de cinza.

Já foi visto no Capítulo 2 que ruído é uma característica comum em imagens mé-

dicas, o que torna útil a utilização de técnicas para suprimir essa degradação. Alguns dos filtros mais comuns aplicados na redução de ruído são os filtros da média e mediana [SON 98]. Além desses, podem ser citados alguns eficientes para a suavização de ruído, tais como o filtro de *crimmins* e o *alpha trimmed* [BUS 95, BED 84].

Dois conceitos importantes para o entendimento das técnicas descritas nesse capítulo são vizinhança e máscara (janela) [FAC 93]. A vizinhança de um *pixel* consiste nos *pixels* à sua volta. O raio da vizinhança determina o número de *pixels* vizinhos envolvidos no processamento. O processamento de uma imagem baseado em máscara consiste em criar uma nova versão da imagem onde cada *pixel* é o cálculo dos *pixels* da vizinhança, na mesma posição da imagem original. A máscara pode ser vista como uma matriz de *pixels*, ou ainda uma sub-imagem usada em processamento local para modificar cada *pixel* na imagem. Na Figura 3.4(a) é apresentada uma imagem e na Figura 3.4(b) está expresso seu formato *ASCII*, na Figura 3.4(c) pode-se notar um quadrado no centro da imagem, esse quadrado corresponde a uma máscara 3x3, sendo que a vizinhança do *pixel* central possui raio 1 nessa máscara. Na Figura 3.4(d) é exibida a modificação realizada com a máscara em relação a Figura 3.4(a). Essa modificação consiste em substituir os valores dos *pixels* da vizinhança por preto (zero).

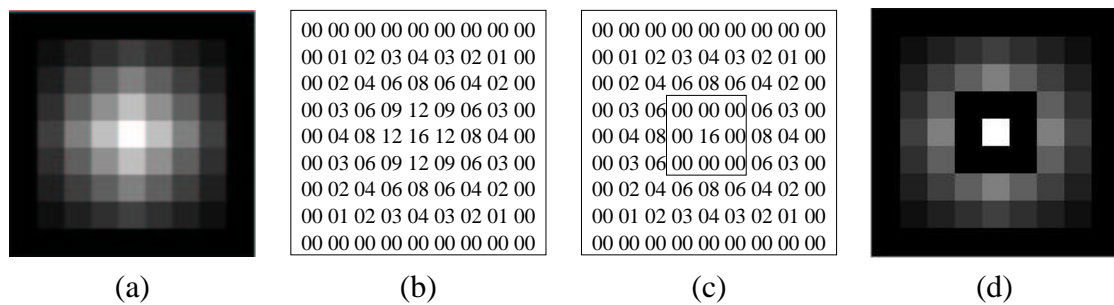


FIGURA 3.4 – Exemplos de vizinhança e máscara.

O filtro da média é obtido calculando a média dos *pixels* da máscara e atribuindo esse valor ao *pixel* central. Já o filtro da mediana corresponde à atribuição do valor central² da vizinhança ao *pixel* central da máscara na imagem original. Este filtro descarta valores extremos, altos ou baixos e é bom para suavização de ruídos isolados, como *salt and pepper* [MAL 96].

Na Figura 3.5 é apresentado o resultado do filtro da mediana em uma imagem ruidosa. A Figura 3.5(a) é a imagem original, a Figura 3.5(b) a imagem ruidosa e a Figura 3.5(c) a imagem filtrada. Sua performance cai quando o número de *pixels* ruidosos é mais do que a metade do número de *pixels* da máscara [AWC 96]. Um problema comum nesse filtro é a perda de detalhes.

O filtro *alpha-trimmed* [SAN 99] descarta os *outliers*, que são os *pixels* com níveis de cinza mais baixos e mais altos, e realiza o filtro da média com base nos *pixels* restantes. Desta forma, a influência de ruídos é evitada, pois o ruído geralmente está nas altas e baixas tonalidades de cinza. O maior problema deste filtro está na escolha do valor de *alpha*, o qual define o percentual de *pixels* que será descartado.

O filtro de *Crimmins* reduz o ruído *speckle* de uma imagem. Ele usa o algoritmo *eight hull* (Figura 3.6(a)), desenvolvido por Thomas Crimmins [CRI 85]. O objetivo é reduzir a intensidade de ruído *salt and pepper* de uma imagem. Conforme o número de

²metade dos valores da vizinhança são menores do que o valor central e a outra metade são maiores




FIGURA 3.5 – Exemplo da filtragem mediana para extração de ruído.

iterações do algoritmo aumenta, o nível de redução de ruído aumenta e a suavização dos detalhes na imagem também. O algoritmo consiste em comparar cada *pixel* da imagem com os oito *pixels* de sua vizinhança. Essa comparação é realizada em quatro direções, conforme é indicado na Figura 3.6(b). O *pixel* é comparado com os quatro pares de vizinhos, onde é verificado se ele é claro ou escuro em relação aos vizinhos. Caso seja claro, a tonalidade de cinza do *pixel* é decrementada para escurecer, caso contrário é incrementada para clarear [FIS 2000].

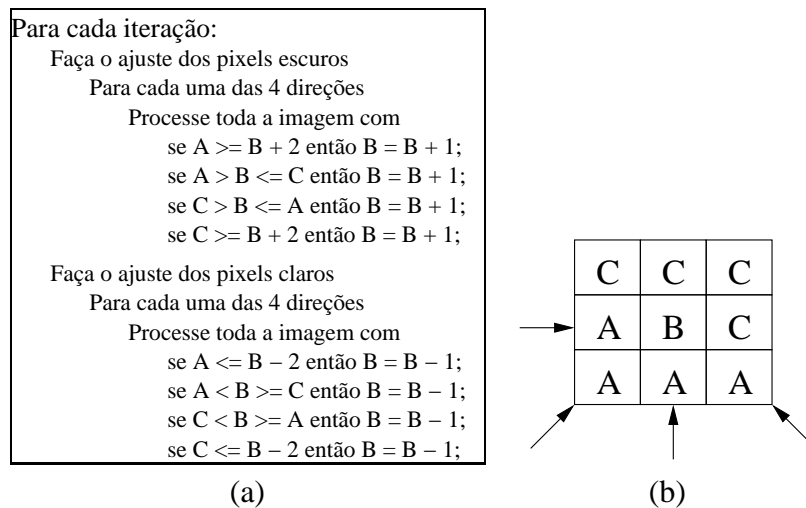


FIGURA 3.6 – Algoritmo e máscara usados pelo filtro de *crimmins*.

3.3 Segmentação

A segmentação é uma importante etapa no tratamento de imagens médicas. Em muitos casos pode-se dizer que a segmentação das imagens é fundamental para o diagnóstico. Em análise de estruturas cardíacas, por exemplo, normalmente é necessário o isolamento de uma ou mais regiões de interesse para que as medidas sejam feitas. A segmentação consiste em juntar partes da imagem que provavelmente pertencem à mesma estrutura [SON 98].

Essa etapa pode ser muito simples se a imagem de interesse possuir poucos objetos bem definidos e com um bom contraste em relação ao fundo, e muito complexa quando o objetivo é separar diversas regiões com muito ruído e pouco contraste, com acontece normalmente em imagens médicas.

A segmentação de imagens em níveis de cinza é baseada na descontinuidade ou na similaridade de valores de intensidade da vizinhança do *pixel*. Dentre as técnicas tradicionais utilizadas na segmentação estão o crescimento de região por agrupamento de pixel, a limiarização (*threshold*) e o processo de divisão e fusão (*split and merge*), que utilizam a similaridade da vizinhança dos *pixels*. As redes neurais artificiais também são usadas na segmentação, com bons resultados onde os métodos tradicionais têm dificuldades em segmentar as bordas.

3.3.1 Crescimento de Regiões

A técnica de crescimento de regiões consiste em indicar um ou mais *pixels* que serão usados como “semente” (ponto inicial do processo), determinar o valor da intensidade que será usado como comparação. Em casos de múltiplas sementes a média dos valores pode ser usada. A intensidade dos valores dos quatro *pixels* (esquerdo, direito, superior e inferior) da vizinhança do *pixel* semente é comparada. Se a diferença estiver dentro de um limite pré definido, o *pixel* é adicionado à região e seus vizinhos são então avaliados, caso contrário ele é descartado. Este processo continua enquanto existirem *pixels* para serem analisados.

A Figura 3.7 mostra um exemplo da progressão do algoritmo de crescimento de regiões. Nestas quatro imagens da seqüência cada imagem é apresentada em forma de uma grade, onde cada posição representa um *pixel*. Na Figura 3.7(a) a letra “S” representa um pixel semente e a letra “V” representa os *pixels* que estão sendo avaliados. A Figura 3.7(b) mostra os *pixels* da etapa anterior que foram selecionados, marcados com “S” e suas vizinhanças marcadas com “V” para análise. As Figuras 3.7(c) e 3.7(d) são a seqüência do processo até a vizinhança não apresentar nenhuma homogeneidade. Uma forma otimizada desta abordagem é começar a análise com várias sementes em regiões diferentes da imagem, desta maneira, várias regiões são encontradas ao invés de uma só, agilizando o resultado quando a imagem possui várias regiões.




FIGURA 3.7 – Representação gráfica do algoritmo de crescimento de regiões.

3.3.2 Thresholding

Threshold ou limiarização é uma técnica que realiza a segmentação da imagem utilizando um ou mais valores limiares de níveis de cinza. Estes valores são normalmente obtidos com a análise do histograma da imagem em questão. Em um exemplo simples de *threshold*, um valor de limiar é escolhido. Aos *pixels* que possuem um valor de intensidade menor que o limiar é atribuído um valor branco e aos restantes valor preto. Se dois limiares são usados, os *pixels* com intensidade menor que o primeiro limiar recebem um

valor, aqueles com intensidade maior que o segundo limiar recebem outro valor e aqueles com intensidade entre os dois limiares recebem um terceiro valor. Este método permite a simples separação de objetos do fundo da imagem, ou objetos com valores variados de intensidade. A Figura 3.8 apresenta dois exemplos de *threshold* diferentes para a mesma imagem cardíaca de cineangiocardiografia. Na Figura 3.8(b) foi utilizado o limiar 118 e na Figura 3.8(c) o limiar 160. Note a diferença na área de segmentação de cada uma delas.




FIGURA 3.8 – *Threshold* realizado com dois limiares diferentes.

A dificuldade do método é justamente encontrar o limiar ou limiares. Essa tarefa pode ser feita com a análise do histograma da imagem [GRA 97]. A utilização da técnica de *threshold* pode não ser útil em muitos casos. A melhora dos resultados pode ser obtida usando *threshold* multidimensional. Neste método são levados em consideração outras características da imagem além do valor da intensidade do *pixel*. Mesmo assim, quando as imagens são de baixa qualidade e com bordas pouco definidas, essa técnica é inadequada.

3.3.3 *Split and Merge*

A técnica de *split and merge* ou divisão e fusão consiste na procura por homogeneidade na imagem. Uma imagem ou região é homogênea quando todos os *pixels* possuem intensidade semelhante ou igual ao valor médio de intensidade daquela região. O processamento inicia com toda a imagem considerada com uma região. Caso não seja totalmente homogênea, ela é particionada em quatro regiões menores. Cada região é analisada, se uma ou mais sub-regiões não forem homogêneas, serão particionadas novamente. Esse procedimento é repetido enquanto existirem regiões não homogêneas ou até não ser possível particionar a imagem. Na Figura 3.9, é apresentado um exemplo desse método. As linhas grifadas nas Figuras 3.9(b), 3.9(c) e 3.9(d) representam a seqüência do particionamento e fusão.

3.3.4 Uso de Redes Neurais na Segmentação de Imagens

As redes neurais artificiais tem alcançado uma grande popularidade nos últimos anos. O processamento de imagem aparece como uma das áreas onde elas têm sido largamente utilizadas [GRA 97]. Dentre as vantagens que tornam as redes neurais artificiais uma alternativa para processamento de imagens pode-se citar a adaptação e aprendizagem, o paralelismo inerente, tolerância a falhas e a possibilidade de processar dados degradados ou incompletos.

As técnicas de segmentação de imagens através de redes neurais artificiais, na maio-




FIGURA 3.9 – Exemplo do algoritmo de *split and merge*.

ria dos casos, utilizam o processo de treinamento baseado em amostragem de uma ou mais característica da imagem. Em termos de treinamento, as redes neurais artificiais são classificadas como aprendizado supervisionado ou não-supervisionado (auto-aprendizado).

O treinamento supervisionado consiste em apresentar à rede um padrão juntamente com a resposta que ela deve fornecer ao deparar-se com o mesmo padrão. Dahmer, em [DAH 98], apresenta a aplicação de uma rede neural multi-camadas com treinamento *backpropagation* para segmentação de imagens ecocardiográficas em duas regiões, cavidade (regiões que contém sangue, tais como ventrículos) e tecido (as regiões restantes tais como septos e paredes cardíacas). O aprendizado por *backpropagation* baseia-se na propagação retrógrada do erro para os níveis anteriores da rede, de acordo com o grau de participação que cada neurônio teve no nível posterior [FER 95].

A rede neural usada por Dahmer é constituída por três camadas de neurônios, com 5, 20 e 2 elementos. Os 5 neurônios na primeira camada (entrada) recebem informações texturais (contraste, entropia e homogeneidade) e de intensidade dos níveis de cinza (média e variância) como entrada, e a camada de saída com 2 neurônios responde se uma amostra pertence a classe de tecido ou a classe cavidade, conforme Figura 3.10. Normalmente as regiões de cavidade apresentam uma baixa reflexão ao ultra-som e são identificadas nas partes mais escuras da imagem, enquanto regiões de tecido são identificadas em áreas mais claras, como é possível observar na “imagem original” na Figura 3.10.




FIGURA 3.10 – Exemplo do treinamento *backpropagation*.

O algoritmo requer duas fases, treinamento e classificação. Inicialmente, são extraídas as amostras de um conjunto de imagens e rotuladas como cavidade ou tecido. Essas amostras são então usadas para treinar a rede. Depois do treinamento, a rede neural está pronta para a segmentação. A imagem inteira é segmentada usando uma janela des-

lizante, a qual associa o *pixel* central com uma das classes, tecido ou cavidade. Depois da classificação, a imagem terá sido segmentada em duas classes ou regiões.

No treinamento com auto-aprendizado ou não-supervisionado, os padrões são apresentados à rede e ela encarrega-se de agrupar aqueles que possuírem características similares. Este processo é também chamado de clusterização. Um dos problemas apresentados com o treinamento supervisionado em imagens médicas é a dificuldade para definir padrões em determinados tipos de imagens. Isso deve-se à baixa qualidade e à falta de homogeneidade. Métodos não-supervisionados tendem a obter melhores resultados nestes casos [PIC 99a].

No trabalho de Piccoli em [PIC 99], é proposto um método não-supervisionado para segmentação, baseado em mapas auto-organizáveis de Kohonen (*SOM*) [KOH 90]. Esta rede agrupa dados desconhecidos de padrões similares de acordo com algum critério de similaridade. Nesse trabalho foi utilizada a distância Euclidiana [HAY 2001]. Uma importante característica desta rede é sua habilidade para processar dados ruidosos. Para evitar dados tendenciosos, a aquisição das amostras para treinamento foi realizada de forma aleatória, sem a interferência humana. O operador apenas especifica o número de amostras. Durante o treinamento o conjunto de amostras é comparado com o mapa e a cada passo um neurônio é eleito vencedor ³. Os pesos do vencedor e de seus neurônios vizinhos são ajustados, desse modo eles convergem para o padrão apresentado. O processo é apresentado na Figura 3.11. No fim do treinamento os neurônios estão aglomerados por similaridade. Diversos neurônios podem estar associados à mesma classe, isso ocorre porque o *SOM* projeta dados para uma grade N-dimensional, observando sua estrutura topológica.




FIGURA 3.11 – Exemplo do processamento do *SOM*.

As redes neurais artificiais têm conseguido bons resultados onde os métodos tradicionais apresentam dificuldades na detecção de bordas em imagens muito ruidosas. Como grande parte das imagens médicas apresentam essas características, espera-se que essa tecnologia ajude os médicos na busca por métodos de diagnóstico mais precisos.

3.4 Análise de Imagens

A análise de imagens é a área do processamento responsável pela extração e pela interpretação de informações presentes na imagem. É nessa fase que são extraídas medidas de estruturas em imagem, por exemplo.

Para a análise da imagem é necessário que os componentes da mesma sejam isolados, essa tarefa é realizada pela segmentação. Uma exemplo de análise de imagem é

³o mais próximo à amostra no espaço de características

apresentado na Figura 3.12 a qual mostra uma imagem microscópica de células. A contagem das células e a detecção do tamanho médio das mesmas pode ser visto como uma aplicação de análise de imagem, é uma tarefa relativamente simples após a imagem ser segmentada.




FIGURA 3.12 – Imagem microscópica de células.

Para o diagnóstico por imagens, normalmente são realizadas diversas medidas nas estruturas relacionadas ao exame, o que torna a fase de análise extremamente importante na obtenção de medidas automáticas em imagens médicas.

4 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) consistem em métodos para solucionar problemas de inteligência artificial (IA). Baseadas no comportamento neural de seres inteligentes, elas tentam simulá-lo artificialmente. As RNAs têm a capacidade de aprender, memorizar e criar relações entre dados.

Os trabalhos neste campo iniciaram a partir dos estudos do cérebro e da fisiologia neural, sendo que em meados da década de 40 surgiu o primeiro neurônio artificial, fruto do trabalho do neurofisiologista Warren McCulloch e do matemático Walter Pitts.

Mesmo com muitos trabalhos importantes publicados nesse período, foi só a partir dos anos 80 que a comunidade científica percebeu o verdadeiro potencial de RNAs. Hoje muitos pesquisadores trabalham com RNAs. Há diversos institutos de pesquisa e empresas privadas com projetos nessa área. Uma prova da difusão das RNAs é a quantidade de revistas (*IEEE Transactions on Neural Network Journal*, *Neural Networks*, *Neural Computation*, *International Journal of Neural Systems*) e conferências especializadas no assunto, além da infinidade de *sites* retornados em uma pesquisa simples sobre o assunto na *Internet*.

Embora as máquinas realizem cálculos com velocidade muito superior à humana, em muitas tarefas nosso cérebro é imbatível. Visão, audição e raciocínio são alguns exemplos considerados simples onde as máquinas ainda apresentam grandes dificuldades. A tentativa de atingir níveis de processamento iguais ou superiores ao cérebro humano tem motivado estudos e gerado uma série de algoritmos e técnicas de RNAs.

Para chegar a modelos neurais artificiais robustos, foi necessário estudar o funcionamento do cérebro. As pesquisas foram direcionadas aos fenômenos neurais. Os neurônios são células do tecido nervoso que tem a propriedade de receber e transmitir impulsos nervosos e dentre suas funções incluem-se receber os impulsos de outros neurônios processá-los repassando o resultado e controlar a taxa de transmissão nas sinapses.

Os neurônios biológicos possuem três partes principais: o corpo da célula, os dendritos e o axônio (Figura 4.1(a)). O axônio é responsável pelo envio de pulsos elétricos aos outros neurônios, enquanto que os dendritos recebem os sinais passando-os para o corpo celular. O corpo da célula recebe as informações, processa-as e, conforme o resultado, repassa ou não o sinal. A conexão entre o axônio e os dendritos de outros neurônios é chamada de sinapse. Estima-se que o cérebro humano possua 100 bilhões de neurônios, cada um com mil dendritos, chegando a 100 trilhões de sinapses, aproximadamente. Essa rede neural é responsável pela atividade cerebral.

O neurônio artificial tenta simular o biológico, possuindo diversas entradas, uma saída e uma função de adaptação dos pesos das conexões, conforme a Figura 4.1(b). Diversas funções contínuas são usadas para a adaptação, entre elas a sigmoideal e a radial [TAK 97].

Na busca por aplicações para RNAs, é possível encontrar uma infinidade de linhas de pesquisa. Aplicações tais como reconhecimento de padrões [ELB 2000, MUR 98], processamento de imagens [DAH 98, PIC 99], reconhecimento de fala [PHA 2000], análise de séries temporais [COR 95] e diagnóstico médico [PIC 99a, ZHA 99] são alguns exemplos da versatilidade e do potencial das RNAs.

Embora a implementação de uma RNA seja complexa, o uso do programa é simples e sem muita participação do usuário, por isso as RNAs são consideradas “caixas pretas”. Quanto aos resultados, são normalmente satisfatórios, levando em consideração o trabalho




FIGURA 4.1 – O Neurônio biológico e um modelo de neurônio artificial.

com dados ruidosos.

O princípio das RNAs consiste basicamente em processar através da RNA um conjunto com amostras dos dados que pretende-se analisar para que a RNA aprenda como cada amostra estará relacionada com o resultado esperado. Durante o aprendizado, a rede ajusta os pesos¹ de seus neurônios até que produza uma resposta precisa.

Existem algumas classificações aplicadas às RNAs. Dependendo de como os dados são processados pode-se classificá-las como retroalimentada ou com alimentação a frente. Outra forma de classificar os tipos de RNAs é pelo treinamento: uma RNA pode ser treinada de maneira supervisionada ou não supervisionada.

Existem muitos tipos de RNAs. Dentre os mais populares, estão o Perceptron, o Adaline, o Perceptron multicamadas (é treinado com o algoritmo *backpropagation*), as redes Hopfield, os mapas auto-organizáveis de Kohonen e a rede ART.

Neste Capítulo, essas redes clássicas serão descritas com uma análise das características do aprendizado neural artificial de cada uma delas. Na Seção 4.1 são descritos os dois tipos de aprendizado. Os principais modelos de RNAs serão apresentados na Seção 4.2. A Seção 4.3 apresenta algumas aplicações para RNAs.

4.1 Aprendizado Artificial

A principal característica de uma RNA é a capacidade de aprender e se adaptar às situações mais variadas e, com isso, melhorar seu desempenho. Essa propriedade provém do processo iterativo de ajuste dos pesos, o treinamento. A RNA é considerada treinada quando ela atinge uma solução generalizada para determinado tipo de problema.

Segundo [HAY 2001], aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulos, do ambiente no qual está operando. O tipo específico de aprendizagem realizada é definido pela maneira como ocorrem os ajustes de parâmetros.

Para que a RNA chegue a solução de um problema, o treinamento é a primeira e mais importante etapa do processamento, quando são apresentadas amostras do problema à rede e ela trata de extrair informações relevantes sobre tal problema. A rede cria uma espécie de representação do problema.

O algoritmo de treinamento deve ser confiável, visto que dele depende o sucesso da rede. Existem muitos tipos de algoritmos de treinamento. Cada tipo de rede é caracterizada por este algoritmo, o qual apresenta diferenças principalmente na maneira como recebe

¹conexões entre os neurônios também conhecidas como sinapses

o conjunto de dados para o aprendizado e na forma como os pesos são modificados.

O treinamento é realizado até que uma determinada condição seja satisfeita. A condição de parada do treinamento pode ser simplesmente um número pré-definido de iterações, ou a minimização de uma função de erro. A idéia é parar a partir do momento em que o treinamento identifique padrões de entrada, o que indica que a rede aprendeu.

Mesmo existindo diversos tipos de algoritmos de treinamento de RNAs, existem alguns pontos comuns nas diferentes abordagens. Esses pontos são usados para classificar os tipos de treinamento. Existem dois principais paradigmas para classificação do aprendizado. Ao longo desta seção serão discutidos o aprendizado supervisionado e o não-supervisionado.

4.1.1 Aprendizado Supervisionado

O aprendizado supervisionado é aquele no qual a rede é treinada com um conjunto de dados conhecidos. O usuário (supervisor) sabe o tipo de dado e qual o resultado esperado antes de treinar a rede, com isso a rede é treinada ajustando pesos para que a entrada esteja relacionada com o resultado.

O processo consiste em rotular amostras, isto é, apresentar um conjunto de treinamento indicando os valores de entrada para o treinamento da rede e o resultado esperado. Após o processamento dos dados, o resultado é comparado com aquele informado na entrada. Se houver erro significativo, a rede torna a processar os dados para ajustes, como apresenta o esquema da Figura 4.2. O erro é a diferença entre o resultado obtido pela rede e o resultado esperado. Quando o erro for insignificante, acaba o treinamento.

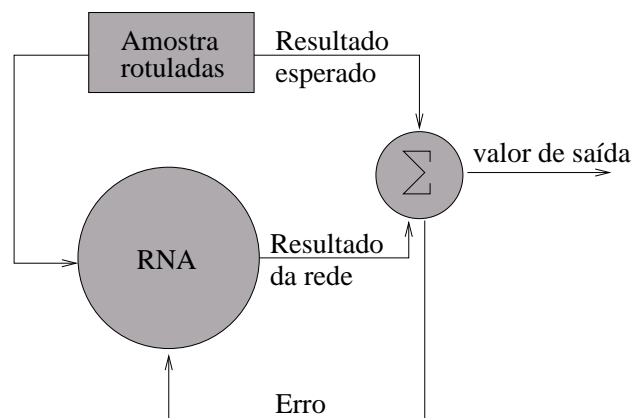


FIGURA 4.2 – Esquema de treinamento supervisionado.

Nesse paradigma de aprendizagem, o conhecimento dos dados por parte do supervisor é transferido à RNA na etapa de treinamento. Após a rede estar ajustada para determinado conjunto de dados (treinada), ela está apta a processar dados da mesma natureza daqueles usados como amostras.

A principal desvantagem desse paradigma de aprendizagem é a dificuldade de processar dados desconhecidos, onde seja difícil prever, a princípio, os resultados.

Uma regra para a implementação do aprendizado supervisionado é conhecida como adaptação por correção de erros [HAY 2001], a qual procura minimizar o erro da resposta da RNA. Um algoritmo que utiliza aprendizado supervisionado por correção de erro é o famoso *Backpropagation* [DAH 98], utilizado para treinamento de redes de múltiplas camadas.

4.1.2 Aprendizado Não-Supervisionado

Na abordagem não-supervisionada somente os padrões de entrada estão disponíveis para a rede não sendo conhecidos os resultados esperados, como acontece no aprendizado supervisionado. A Figura 4.3 apresenta o esquema de aprendizado não-supervisionado. Esse tipo de aprendizado é encontrado em muitos dos sistemas biológicos de seres inteligentes, como por exemplo os estágios iniciais de visão e audição.




FIGURA 4.3 – Esquema de treinamento não-supervisionado.

Os algoritmos de aprendizado não-supervisionado normalmente avaliam a similaridade entre modelos agrupados em *clusters*, ou seja, a rede trabalha com os valores similares dentro do espaço de entrada. Muitos métodos tomam como critérios de separação de classes alguma definição de distância. Para modelos com características numéricas, a distância avaliada pode ser a distância Euclidiana [HAY 2001].

No aprendizado não-supervisionado, não são usadas informações sobre a resposta esperada para fazer modificações nos valores das conexões sinápticas da rede. Usa-se, por outro lado, um esquema para que, em exemplos de dados semelhantes no espaço de entrada, a rede responda de modo semelhante. O resultado é um agrupamento de dados semelhantes no espaço de saída.

Existem diversos métodos de implementação do aprendizado não-supervisionado, como o aprendizado Hebbiano, o modelo de Linsker, a regra de Oja, a regra de Yuille e o aprendizado por competição [BRA 98, HAY 2001]. Alguns modelos de RNAs que utilizam aprendizado não-supervisionado serão discutidos no decorrer deste capítulo, como é o caso dos mapas auto-organizáveis de Kohonen [KOH 90].

4.2 Modelos de RNAs

Nesta Seção serão abordados os principais modelos de RNAs segundo uma classificação descrita por Lippman [LIP 87]. Nesse conjunto foram incluídas algumas RNAs importantes na história da computação por redes neurais e com boa capacidade de aprendizado e processamento.

Uma taxionomia de classificação das RNAs é apresentada na Figura 4.4. A primeira classificação é referente ao tipo de entrada da rede, em valores binários ou contínuos. A segunda classificação é referente ao tipo de treinamento, o qual pode ser supervisionado ou não-supervisionado (auto aprendizado). Tal característica foi discutida previamente na Subseção 4.1. A última classificação apresentada está relacionada com as redes que serão descritas no decorrer desta Seção.

O objetivo dessa seção é fazer um apanhado com as características dos principais modelos de RNAs de maneira rápida e objetiva, não aprofundando os detalhes de cada modelo. Será dada atenção especial para a RNA conhecida como “mapas auto-organizáveis de Kohonen” por ser usada no desenvolvimento desta dissertação.

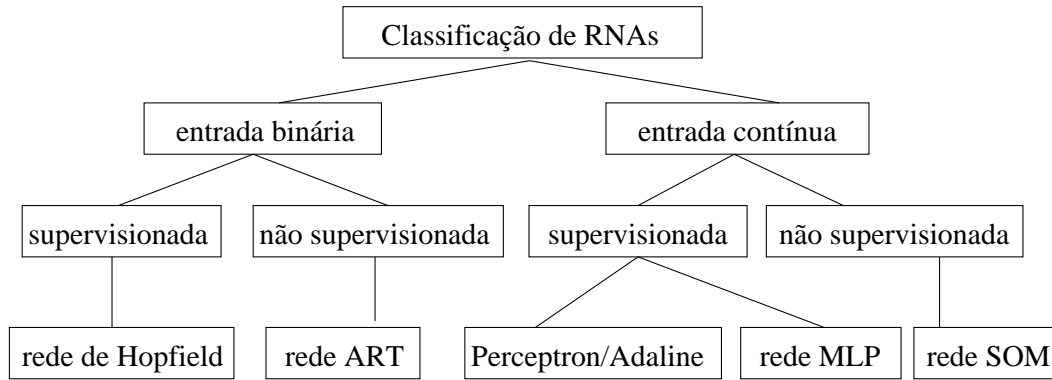


FIGURA 4.4 – Classificação das principais RNAs ([LIP 87]).

4.2.1 O Perceptron e o Adaline

Proposto em 1958 pelo psicólogo francês Frank Roseblatt, o Perceptron é reconhecido como um dos primeiros modelos de RNA. Através dele, foi introduzido o conceito de aprendizado das redes. É uma rede simples composta de uma unidade de entrada, uma camada intermediária formada de unidades de associação e uma camada de saída formada por unidades de resposta. Apesar destes três níveis, ela é conhecida como uma rede de uma única camada, porque só a unidade de saída possui propriedades adaptativas.

O Adaline é bastante semelhante ao Perceptron. Foi apresentado por Bernard Widrow em 1960 e, embora tenham sido desenvolvidos na mesma época, eram aplicados em áreas diferentes. O Perceptron foi apresentado em uma revista de Psicologia enquanto que o Adaline apareceu em uma conferência na área de engenharia como uma ferramenta para processamento de sinais.

O fato de possuírem uma só camada adaptativa limita-os à representação de funções linearmente separáveis². Essa característica gerou várias críticas aos modelos [MIN 69], levando inclusive ao desinteresse pela área de RNAs na década de 70.

Para exemplificar um problema linearmente separável, pode-se usar os padrões a, b, c e d distribuídos em um espaço de características bidimensionais, conforme a Figura 4.5(a), sendo que a e b são da Classe C_1 e c e d são da classe C_2 . Neste caso, é possível separar as classes C_1 e C_2 através de um hiperplano, Figura 4.5(b) (neste caso uma reta). Se for considerado que a e d são da Classe C_1 e b e c são da classe C_2 não será mais possível separar as classes através do uso de uma simples reta e neste caso o problema não é linearmente separável, como na Figura 4.5(c).




FIGURA 4.5 – Problema linearmente e não-linearmente separável.

²funções que se encontram em lados opostos de um hiperplano

Ambos os modelos de rede são caracterizados pelo aprendizado supervisionado, alimentação à frente e utilizam como base o neurônio artificial de McCulloch e Pitts. Na Figura 4.6, é apresentado um exemplo da topologia dessas redes. Observa-se que os neurônios da camada de entrada não realizam processamento, apenas distribuem os valores de entrada para todos os neurônios da camada de saída onde será realizada a adaptação dos pesos.

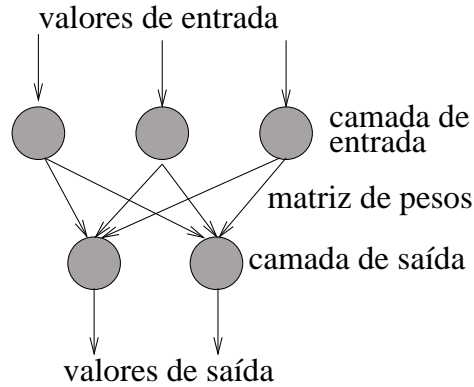


FIGURA 4.6 – Estrutura das redes Perceptron e Adaline.

Para realização dos cálculos nos neurônios, tanto o Perceptron quanto o Adaline utilizam o *combinador adaptativo linear*, onde a saída de um neurônio é a combinação linear das entradas da RNA, sendo um vetor que é multiplicado por pesos pré-estabelecidos no neurônio e assumindo a forma da Equação 4.1:

$$y(t) = \sum_{i=0}^{n-1} w_i(t)x_i(t) \quad (4.1)$$

onde w_i é um elemento da matriz de pesos, x_i é um elemento de entrada da rede, t é o número da amostra de entrada e y é a saída do neurônio.

A principal diferença entre os dois modelos está no cálculo de atualização dos pesos. O algoritmo do Perceptron de atualização, apresentado na Equação 4.2, foi descrito baseado no erro de saída não-linear, descrito na Equação 4.3. O erro é o resultado da aplicação de uma função linear sobre a diferença entre a saída desejada e a resultante. Enquanto a atualização dos pesos do Adaline, conhecida como regra delta e descrita na Equação 4.4, baseia-se no erro de saída linear (Equação 4.5), o erro não tem quantização.

$$w(t+1) = w(t) + \alpha \left(\frac{\varepsilon(t)}{2} E(t) \right) \quad (4.2)$$

onde α é o coeficiente de aprendizado e ε é o erro da saída quantizada do neurônio.

$$\varepsilon(t) = d(t) - f_{lim}(y(t)) \quad (4.3)$$

onde d é a saída desejada, visto que estamos tratando de um algoritmo supervisionado.

$$w(t+1) = w(t) + \alpha \left(\frac{\varepsilon(t)E(t)}{|E(t)|^2} \right) \quad (4.4)$$

$$\varepsilon(t) = d(t) - y(t) \quad (4.5)$$

O Adaline pode ser visto com uma generalização do Perceptron, ou seja, o mesmo algoritmo mas com o treinamento baseado em minimização de erros. No Adaline, a saída é usada sem que seja mapeada para valores -1 ou $+1$ enquanto que a regra de aprendizagem do Perceptron precisa usar a saída mapeada por uma função limiar para o aprendizado (-1 ou $+1$).

4.2.2 O Perceptron Multicamadas e o Backpropagation

O Perceptron Multicamadas (MLP) foi criado para resolver a carência das redes de uma só camada na solução de problemas não linearmente separáveis. A idéia foi colocar camadas intermediárias que possibilitaram a implementação de funções contínuas. A precisão obtida e a implementação da função objetivo dependem do número de nodos utilizados nas camadas intermediárias [BRA 98]. A Figura 4.7 apresenta uma rede MLP típica.

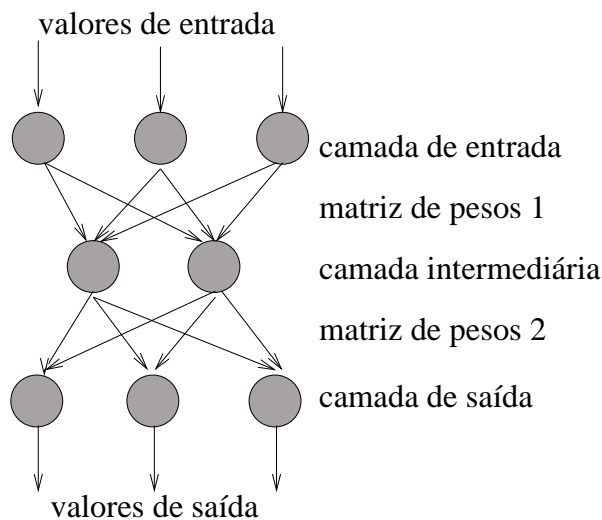


FIGURA 4.7 – Estrutura da rede MLP.

Um fator importante para o sucesso das redes MLP é a escolha do número de camadas intermediárias. Esse número não pode ser muito grande, devido ao erro medido durante o treinamento. A única camada que tem a noção exata do erro cometido pela rede é a camada de saída, enquanto que as camadas intermediárias recebem apenas uma estimativa sobre o erro.

Segundo alguns autores, duas camadas intermediárias são suficientes para aproximar qualquer função matemática. Outro fator importante na resolução de problemas é o número de neurônios das camadas intermediárias: não existe uma fórmula para definir esse número, sendo que deve ser apontado de maneira empírica, através de testes. Normalmente, esse número varia conforme o problema.

O algoritmo de aprendizado mais conhecido para o treinamento de redes MLP é o *Backpropagation* [DAH 98]. Esse algoritmo supervisionado utiliza o treinamento em dois momentos: no primeiro, a rede é percorrida com alimentação para a frente e no segundo momento é realizada a retroalimentação. A topologia de uma RNA *backpropagation* é apresentada na Figura 4.8, onde as setas contínuas representam a alimentação e as pontilhadas a retroalimentação.

O *Backpropagation* baseia-se na regra delta de aprendizado. É a generalização de tal regra para vários neurônios na camada de saída. A idéia central associada a esse algo-

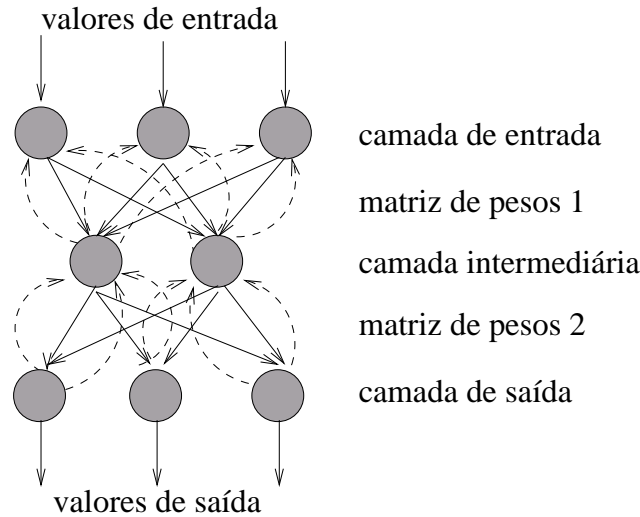


FIGURA 4.8 – Estrutura da rede Backpropagation.

ritmo é que os erros para os neurônios das camadas intermediárias são a retropropagação dos erros dos neurônios da camada de saída.

4.2.3 Rede de Hopfield

A rede de Hopfield foi introduzida pelo físico J. J. Hopfield em 1982 [BRA 98]. Ela foi uma das responsáveis pela retomada dos estudos em RNAs ocorrido na década de 80. Através desta rede, Hopfield ressaltou as propriedades associativas das redes neurais. Também mostrou a relação entre redes recorrentes auto-associativas e sistemas físicos, abrindo espaço para a utilização de teorias da Física no estudo de tais modelos.

A RNA de Hopfield é caracterizada pelo aprendizado supervisionado e pela retroalimentação. Ela consiste de um conjunto de N neurônios interconectados, Figura 4.9 os quais atualizam seu pesos de maneira assíncrona e independente entre si. Não há diferenciação entre neurônios de entrada e neurônios de saída, ou seja, todos são entrada e saída. É normalmente usada com entrada binária mas geralmente usa valores $+1$ e -1 . Esses valores bipolares são usados para que o zero não cause problemas no cálculo das saídas.

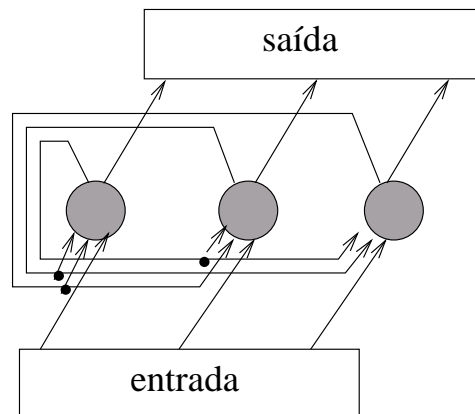


FIGURA 4.9 – Estrutura da rede de Hopfield.

O fato de possuir entrada binária torna a rede um boa alternativa para o proces-

samento de imagens em preto e branco onde a entrada seja o valor dos *pixels*. A rede também se adapta bem ao reconhecimento de texto ASCII onde as entradas sejam a representação binárias de cada caracter. Estas redes não são muito apropriadas para processar problemas com valores de entrada contínuos.

O treinamento está baseado no conceito de energia da rede [HAY 2001], onde esta é proporcional a troca de estados da rede. Quanto maior a oscilação entre um estado e outro na saída, maior é a energia. Na fase de reconhecimento, o objetivo é minimizar a energia, para que com isso a rede converge para um único estado na saída.

O algoritmo de Hopfield possui quatro etapas principais. O primeiro passo é a inicialização dos pesos das conexões neurais através da Equação 4.6. Então, um padrão de entrada desconhecido é apresentado à rede no tempo zero ($y_i(0) = x_i$, onde $y_i(0)$ é a saída do neurônio i no tempo zero e x_i é o vetor de entradas) com a intenção de forçar a saída da rede a encontrar o padrão. O terceiro passo é a iteração da rede até convergir usando a Equação 4.7. A partir daí, a rede verifica se há alteração nas saídas dos neurônios. Caso haja volta à segunda etapa. Se a saída não alterou após sucessivas iterações, considera-se que a rede convergiu para um único estado de saída.

$$w_{ij} = \begin{cases} \sum_{s=1}^M x_i^s x_j^s, & i \neq j \\ 0, & i = j \end{cases} \quad (4.6)$$

onde w_{ij} é o vetor de pesos da conexão entre o neurônio i e o neurônio j , x_i^s é o elemento de entrada do neurônio i contendo a classe s (com valor +1 ou -1) e M é o número de padrões a treinar.

$$y(t+1) = f_{lim} \left(\sum_{i=1}^N w_{ij} y_i(t) \right) \quad (4.7)$$

onde y é a saída do neurônio, f_{lim} é a função de limiar e N é o número de neurônios.

Uma aplicação com bons resultados para a rede de Hopfield é a solução do problema do caixeiro viajante, onde um caminho com a distância mínima deve ser encontrado para percorrer n cidades, sendo que o ponto inicial e final são os mesmos.

4.2.4 Mapas Auto-Organizáveis de Kohonen

Os Mapas Auto-Organizáveis (SOM³) são RNAs classificadas como não-supervisionadas. A idéia básica é ter uma matriz de neurônios (mapa) que será comparada com a entrada da rede, elegendo um neurônio como vencedor a partir de algum critério de similaridade. No decorrer do treinamento, onde todas as entradas são comparadas com todos os neurônios, há tendência dos padrões similares de entrada agruparem-se no mapa. Devido à escolha do neurônio vencedor, a rede é conhecida como competitiva.

O SOM tem sido aplicado a tarefas já exploradas por outros modelos neurais, como reconhecimento de padrões, robótica, segmentação de imagens e controle de processos. Os resultados demonstram um alto grau de eficiência na realização de tais operações.

O desenvolvimento do SOM pelo físico finlandês Teuvo Kohonen na década de 80 teve inspiração científica em trabalhos sobre a representação interna de informações pelo cérebro de seres inteligentes. Sabe-se que o cérebro possui áreas que são responsáveis por funções específicas dedicadas por exemplo à fala ou audição. Essas regiões se dividem em sub-regiões organizadas de forma espacial em um mapa topológico. Kohonen analisou diversos estudos de neurofisiologia que comprovam a teoria [KOH 90].

³do inglês - Self-Organizing Maps

Para entender o processo de aprendizagem do SOM toma-se como exemplo uma rede bidimensional de neurônios representada pela matriz de pesos $w = [w_{i1}, w_{i2}, \dots, w_{in}]$ e um vetor com as entradas da rede $x = [x_1, x_2, \dots, x_n]$ cujos elementos são todos números pertencentes ao conjunto dos reais. Essa estrutura é descrita juntamente com a topologia da rede SOM na Figura 4.10.




FIGURA 4.10 – Estrutura da rede SOM.

O aprendizado se dá através do processo iterativo no qual os neurônios são comparados com as entradas da rede através de algum critério de similaridade. Normalmente é utilizada a distância euclidiana como critério de similaridade. A distância euclidiana entre a entrada x_i e o vetor de peso w_{in} , é definida na Equação 4.8.

$$d_i = \left[\sum_{i=1}^n ||x_i - w_{in}|| \right] \quad (4.8)$$

Quanto mais próximos entre si estiverem os elementos dos vetores x e w , menor será a distância euclidiana $d(x, w)$ e maior será a similaridade entre eles.

Para cada iteração, há uma etapa de adaptação dos pesos da rede. Desta forma, sempre que um neurônio é eleito o vencedor seu peso sináptico é atualizado juntamente com os da sua vizinhança. A vizinhança de um neurônio é definida como a delimitação de uma região de raio conhecido ao redor do mesmo. O raio da vizinhança pode ser fixo ou variar conforme o tempo. A Figura 4.11 ilustra a região vizinha a um neurônio, bem como alguns formatos para a mesma.

Além da vizinhança, outro detalhe que deve ser definido na fase de aprendizado, é a função de atualização dos pesos do neurônio vencedor e da sua vizinhança. As formas mais comuns são a utilização de uma função gaussiana [PIC 99] onde o fator de atualização dos pesos (α) é determinado pela distância entre a vizinhança e o vencedor. Quanto mais próximo do neurônio vencedor maior o valor de α e a utilização da função bolha, onde o valor de α é independente da distância, não variando e atualizando uniformemente a vizinhança.

A atualização dos pesos é realizada dentro da vizinhança. Os neurônios fora desse raio permanecem intactos. O processo de atualização através da função bolha é descrito na Equação 4.9.

$$w_i(t + 1) = w_i(t) + \alpha(t)[x(t) - w_i(t)] \quad (4.9)$$

onde α é o fator de atualização, $0 < \alpha < 1$.

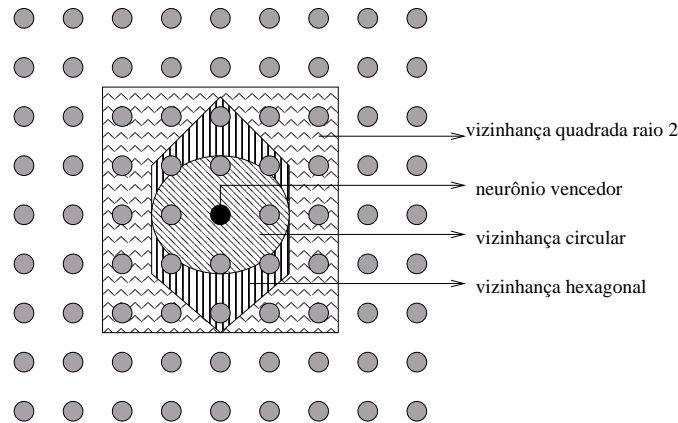


FIGURA 4.11 – Vizinhança de um neurônio.

Depois que a rede está treinada, são observados agrupamentos (*clusters*) dos valores similares da entrada no mapa de neurônios. A rede SOM não possui a característica de classificação de padrões, ela realiza agrupamentos dos padrões de entradas semelhantes. Para usar o SOM, como reconhecedor de padrões em tarefas como segmentação de imagens, por exemplo, é necessário o uso de algum algoritmo que realize essa tarefa sobre o mapa treinado.

Na próxima Seção será apresentado um exemplo de aplicação para a rede SOM com a descrição das etapas em uma forma mais prática. O SOM foi utilizado para segmentação de imagens ecocardiográficas fetais, sendo a escolha motivada pela capacidade do modelo no processamento de dados ruidosos.

4.2.5 Teoria de Adaptação Ressonante

A Teoria de Adaptação Ressonante (ART⁴) foi inicialmente proposta por Grossberg e Carpenter nos anos 80 como outro método adaptativo para *clusterização* auto-organizável. A rede possui entrada binária, aprendizado não-supervisionado e retroalimentação. Há uma semelhança com o modelo de Kohonen em termos de armazenamento de padrões, há distinção de agrupamentos, há comparação entre as distâncias das entradas e dos neurônios e a escolha de um neurônio vencedor. A ART é uma rede incremental, pois não precisa recomeçar seu treinamento do ponto inicial à cada vez que aparecem novos padrões de entrada, preservando o conhecimento adquirido.

A idéia básica é simples mas muito eficiente em muitas aplicações. A rede consiste em ciclos através de dados repetidamente. Em um determinado tempo, há um número finito de *clusters* representativos. Quando uma entrada é apresentada a rede, o *cluster* mais próximo é procurado. Se a distância entre o *cluster* e a entrada é a mínima conforme algum critério, então o *cluster* é atualizado na direção da entrada, caso contrário a entrada é transformada em um novo *cluster* e o processo continua. Há um método de balanceamento entre a criação de um novo *cluster* e o quanto distante o dado está da saída. Essa tarefa pode ser controlada por um parâmetro de vigilância e a distância métrica usada.

Em termos de arquitetura, a ART possui normalmente duas camadas de neurônios, uma de entrada e outra de saída (Figura 4.12). A camada de entrada é responsável pelo processamento das entradas e a camada de saída realiza o agrupamento dos padrões do

⁴do inglês - Adaptive Resonance Theory




FIGURA 4.12 – Topologia básica da rede ART.

treinamento nos *clusters*. A rede é totalmente conectada, e possui retroalimentação, pois as camadas de saída estão conectadas as entradas e vice-versa.

Esse modelo discutido aqui foi o primeiro modelo a ser desenvolvido e é conhecido como ART1. Ele trabalha apenas com padrões de entrada binários, porém muitos problemas utilizam valores contínuos, por isso foi desenvolvida a rede ART2 no ano de 1987 [BRA 98], sendo a principal diferença justamente aceitação de valores de entrada contínuos.

4.3 Aplicações

Técnicas de RNAs tem sido bastante utilizadas em muitas áreas da ciência, como ferramentas de modelagem, otimização, classificação, aproximação, categorização, etc. Elas são usadas em situações onde modelos analíticos tradicionais não conseguem obter bons resultados ou são extremamente complexos de implementar para tais tarefas. A gama de áreas que as RNAs são aplicadas é extensa. Basta abrir uma revista especializada para ter uma idéia da diversidade de assuntos. Seria uma tarefa muito difícil abranger todas as aplicações de RNAs. Neste trabalho foi feita uma análise restrita àquelas áreas mais conhecidas, bem como um apanhado onde foram citadas as principais aplicações das redes apresentadas neste Capítulo.

Uma importante área de aplicações de RNAs é no campo da robótica, onde são encontrados diversos trabalhos que tratam da trajetória de robôs autônomos móveis [SOU 2000], controle de braços mecânicos bem como tarefas de decisão necessárias aos robôs. O principal problema envolve a aplicação de determinados movimentos a partir de dados capturados por sensores.

O MLP com treinamento *Backpropagation* possui muitas aplicações práticas. O reconhecimento ótico de caracteres (OCR) é uma delas, bem como o reconhecimento de notas musicais, reconhecimento de sinais, treinamento de robôs e processamento de imagens [DAH 98].

O modelo de Hopfield também foi usado para segmentação de imagens médicas [POL 95]. Especificamente, foram segmentadas imagens de tomografia computadorizada e raio-X. Nesse trabalho foram apresentados bons resultados.

Uma aplicação clássica, desenvolvida inicialmente por Kohonen [KOH 90], usa o SOM para reconhecimento de fala, é conhecida como Máquina de Escrever Fonética e

aprende fonemas para posteriormente transformá-los em palavras. Essa transformação se dá através de uma gramática denominada contexto dinamicamente expansível. Mas as mais importantes aplicações práticas do SOM são em reconhecimento de padrões, robótica, diagnóstico e controle industrial e médico. O SOM também pode ser aplicado em milhares de outras tarefas onde necessite-se classificar dados desconhecidos.

A rede ART tem sido utilizada em áreas como o reconhecimento de caracteres, diagnóstico médico, sensoriamento remoto, processamento de voz, robótica e reconhecimento de imagens [BRA 98].

Outro exemplo da utilização de redes neurais é o uso de redes na medicina, no auxílio à tomada de decisões e no diagnóstico médico. Em seu aprendizado, são submetidos uma série de diagnósticos de pacientes, de várias características, com vários sintomas e os resultados de seus testes. Quando forem apresentados os dados de um novo paciente com seus sintomas, a rede fornecerá um diagnóstico para estes novos casos e criará um sistema com o conhecimento de vários médicos.

5 O Modelo de Medidas

Ecocardiografias têm sido largamente utilizadas no estudo do desenvolvimento cardiovascular fetal, sendo sua manipulação extremamente importante no diagnóstico de cardiopatias congênitas. Nesse contexto, a obtenção de medidas referentes às estruturas cardíacas surge como uma importante etapa. As medidas têm alto valor diagnóstico, pois algumas doenças são caracterizadas pelo deslocamento, alteração de forma, ou tamanho anormal de estruturas do coração [ZIE 97].

Nesta dissertação, foi desenvolvido um método para obter medidas cardíacas de forma semi-automática, a partir de imagens ecocardiográficas segmentadas. No método tradicional, as medidas são obtidas de forma manual durante a execução do exame. Quando o médico tem alguma dúvida sobre os resultados, procura outro especialista para confirmar o diagnóstico. A ferramenta de obtenção semi-automática de medidas pode ser usadas, quando surgirem as dúvidas, no lugar do segundo profissional.

Foram selecionadas quatro medidas para serem utilizadas nos testes de avaliação do método. As medidas trabalhadas foram:

- a espessura do septo interventricular;
- o diâmetro do ventrículo esquerdo;
- a máxima excursão do *septum primum* para o interior do átrio esquerdo;
- o máximo diâmetro do átrio esquerdo.

As duas últimas medidas listadas, são usadas para calcular o índice de excursão do *septum primum*. A escolha dessas medidas foi baseada em critérios que serão descritos ao longo desse Capítulo.

Devido à complexidade das imagens e à dificuldade na escolha de regiões para a extração das medidas, foi necessária a participação do usuário ao longo do processo. Ele informa o ponto inicial e a partir desse ponto o processo de localização das bordas da estrutura é disparado.

Esse Capítulo objetiva apresentar o modelo de medidas desenvolvido ao longo dessa dissertação. Na Seção seguinte é descrito o método de obtenção medidas e na Seção 5.2 é feita uma descrição da anatomia cardíaca juntamente com a apresentação das medidas trabalhadas.

5.1 O processo de obtenção das medidas

No início dos estudos para o desenvolvimento desse trabalho, foi proposta a obtenção automática de medidas cardíacas. A intenção era desenvolver um método que encontrasse automaticamente a estrutura de interesse com base em algumas características anatômicas e extraísse as medidas. Devido à complexidade das imagens trabalhadas, foi difícil detectar tais estruturas automaticamente. A utilização de interação com o usuário foi a solução para esse problema, além de dar mais controle na obtenção das medidas, aumenta a confiança dos profissionais que utilizarão o sistema, pois combina o método com sua experiência.

O método necessita de um ponto inicial para obter as medidas. A partir dele, o processo de localização das bordas da estrutura é disparado. A linha referente ao ponto

inicial é varrida, na horizontal, em busca de variações de intensidade dos níveis de cinza. As bordas são detectadas a partir da mudança na intensidade dos *pixels*, visto que as imagens usadas para medidas são segmentadas em duas regiões, preto e branco, como apresentado no Capítulo 6. A medida é igual ao número de pixels encontrados entre as bordas da estrutura. Na figura 5.1 é apresentado um fluxograma com as etapas do processo de obtenção das medidas.

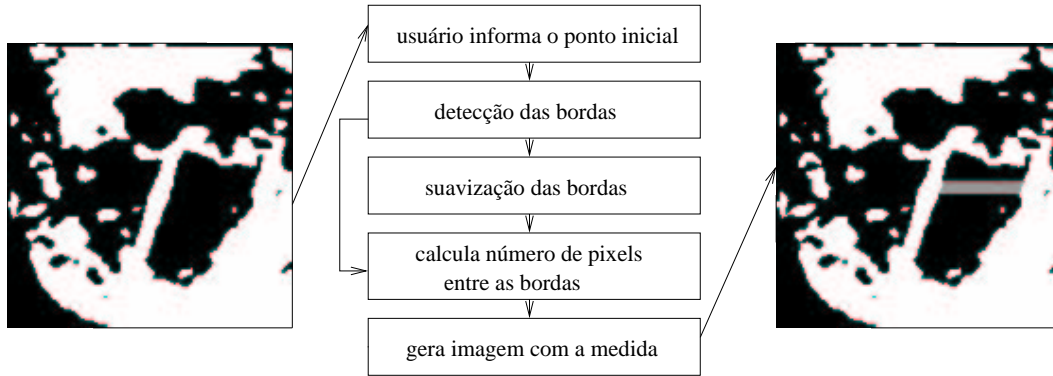


FIGURA 5.1 – Fluxo do processo de obtenção de medidas..

Se a medida está sendo extraída de uma seqüência de imagens, basta selecionar o ponto inicial na primeira imagem, a partir desse ponto o algoritmo trabalha na linha referente e busca as bordas em todas as imagens da seqüência. A partir dos pontos encontrados, as bordas são procuradas nas imagens subseqüentes.

O número de linhas para obtenção das medidas é configurado pelo usuário. E essa solução foi adotada devido às irregularidades comuns nas paredes internas do coração, que poderão comprometer o resultado em alguns casos. Com várias linhas, pode ser extraído o valor médio. Na Figura 5.2, são apresentados dois exemplos de medidas. Na primeira imagem (a), utilizou-se sete linhas para obter a medida enquanto na segunda (b), foram utilizadas vinte e uma linhas. A utilização de uma técnica para modelar as bordas foi outra solução adotada para diminuir a influência das irregularidades no resultado. Essa técnica será descrita na Seção 5.1.1.




FIGURA 5.2 – Medidas obtidas a partir de diferentes números de linhas.

O método para a obtenção das medidas através da análise da linha, onde o usuário determina o ponto inicial, foi inspirado nos exames realizados pelos especialistas. Estes medem algumas estrutura (por exemplo, septo interventricular e cavidades) através da

imagem em modo-M, também conhecida como unidimensional. O processo de formação dessas imagens é semelhante ao modo-A, descrito na Seção 2.1, porém o modo-M é obtido a partir de uma seqüência de imagens bidimensionais já capturadas, enquanto o modo-A é obtido diretamente do ultra-som.

A imagem modo-M é a formada por um conjunto de linhas extraídas de uma seqüência ecocardiográfica e exibidas de forma contígua. A orientação dessa linha é a mesma para todas as imagens da seqüência e é definida pelo especialista. Na Figura 5.3 são apresentadas duas imagens. Na Figura 5.3(a), está a imagem normal de ecocardiografia fetal. Essa imagem é apresentada para mostrar uma linha pontilhada, ao centro, que cruza átrio e ventrículo, de onde foi extraído o modo-M mostrado na Figura 5.3(b).

A espessura de estruturas mais realçadas é medida com maior facilidade na imagem modo-M, na Figura 5.3(b). Observa-se a movimentação de sístole e diástole das duas cavidades demarcadas para serem exibidas em modo-M.




FIGURA 5.3 – Modo-M, utilizado na medida de algumas estruturas.

5.1.1 Técnica para suavização das bordas

A técnica para suavização é aplicada imediatamente após o algoritmo detectar as bordas. Essa solução foi adotada visando diminuir os efeitos das irregularidades das bordas nas medidas. A técnica conhecida como quadrado mínimo [MIX 96] escolhe a curva que melhor ajusta os pixels localizados nas bordas.

A Figura 5.4 mostra um conjunto de pixels, correspondente a uma parte irregular na borda. Cada pixel é identificado pelo seu par de coordenadas (x, y) . Para modelar aquela parte da curva e reduzir o efeito do ruído nas medidas, foi usado o seguinte modelo de segunda ordem:

$$x = c_0 + c_1y + c_2y^2 \quad (5.1)$$

onde x e y são as coordenadas dos pixels nas bordas, c_0 , c_1 e c_2 são os parâmetros que modelam a curva. Tais parâmetros minimizam o erro médio quadrático da localização dos pixels especificados pelo modelo da curva (isto é, para cada coordenada y , o modelo encontra a coordenada x). Para estimar esses parâmetros, o sistema de equações lineares e algébricas apresentado na Equação 5.2 é resolvido.

$$\begin{bmatrix} n & \sum y_i & \sum y_i^2 \\ \sum y_i & \sum y_i^2 & \sum y_i^3 \\ \sum y_i^2 & \sum y_i^3 & \sum y_i^4 \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \\ c_2 \end{bmatrix} = \begin{bmatrix} \sum x_i \\ \sum y_i x_i \\ \sum y_i^2 x_i \end{bmatrix} \quad (5.2)$$

onde n é o número de pixels. Para resolver este sistemas de equações lineares e algébricas, foi usado o método de eliminação Gaussiana [MOR 89].




FIGURA 5.4 – Parte irregular da borda.

Os pixels da borda são ajustados por uma curva, como descrito acima, e a distância média da estrutura em questão é calculada. A Figura 5.5 mostra os resultados da técnica para modelar bordas. Na Figura 5.5(b), pode-se observar as bordas sem serem modeladas, enquanto a Figura 5.5(c) mostra o mesmo exemplo de medida do septo interventricular e do ventrículo esquerdo com as bordas ajustadas pela técnica do quadrado mínimo.




FIGURA 5.5 – Aplicação da média do quadrado mínimo nas bordas.

5.2 Estruturas cardíacas fetais

O objetivo dessa seção é orientar o leitor sobre o posicionamento das estruturas cardíacas de interesse. Como são imagens de péssima qualidade, é difícil para quem não é da área médica ou não tenha experiência com as imagens, visualizar as estruturas cardíacas presentes nas ecocardiografias.

Convém salientar que, a partir de medidas de estruturas cardíacas, são detectadas muitas cardiopatias congênitas (malformações no coração do feto). A detecção desses problemas ainda no estágio fetal implica em uma melhor estratégia de tratamento.

Como descrito na Subseção 2.1.4, o corte quatro câmaras é o mais valioso na detecção de malformações cardíacas estruturais, além de ser o mais fácil de ser obtido, o que fez dele o corte escolhido para a realização das medidas. Dentre as estruturas visualizadas na imagem quatro câmaras estão o átrio esquerdo (AE), átrio direito (AD), ven-

trículo direito (VD), ventrículo esquerdo (VE), válvula mitral (VM), válvula tricúspide (VT), septo interatrial (SiA), septo interventricular (SiV), forãme oval (Fo) e o *septum primum*, também conhecido como membrana do forãme oval (SP). Na Figura 5.6, é apresentado um exemplo do corte quatro câmaras com o posicionamento das estruturas de interesse (Figura 5.6(a)) bem como um desenho esquemático do coração fetal capturado pelo corte quatro câmaras (Figura 5.6(b)).

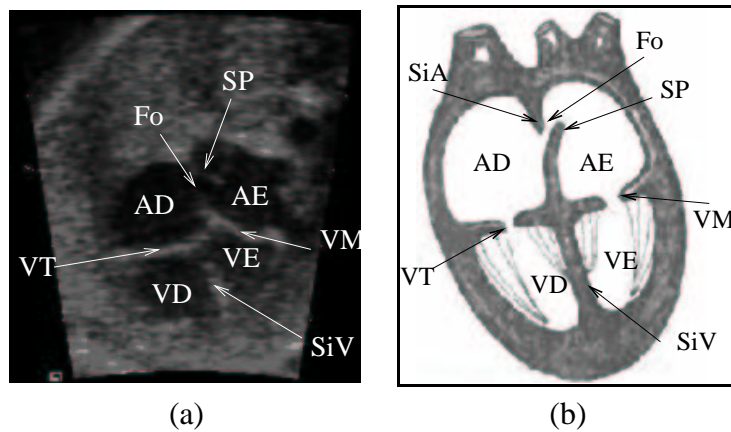


FIGURA 5.6 – Descrição das estruturas cardíacas.

A espessura do septo interventricular e a espessura do ventrículo esquerdo são importantes para o exame e aparentemente fáceis de detectar na imagem. As estruturas mais complexas são as duas que geram o índice de excursão do *septum primum*, a razão da excursão máxima do *septum primum* e o diâmetro espessura do átrio esquerdo. Convém ressaltar que as medidas são obtidas quando o coração encontra-se na máxima diástole, conforme ocorre nos exames realizados pelos especialistas.

5.2.1 Espessura do septo interventricular

O septo interventricular é a parede que separa os ventrículos esquerdo e direito. Sua espessura é importante na análise cardíaca para determinação de massa ventricular e detecção de malformações, entre outras funções. A comunicação interventricular e a hipertrofia miocárdica fetal são exemplos de cardiopatias congênitas onde essa medida é importante para a detecção [ZIE 97a, ZIE 97].

Para a obtenção da espessura do SiV é necessário que o usuário informe um ponto dentro do ventrículo esquerdo. A partir desse ponto, o método busca as paredes do septo interventricular. Esse ponto deve estar em uma linha logo abaixo da válvula mitral, este posicionamento é utilizado por especialistas na obtenção manual dessas medidas. O processo de obtenção da medida é o mesmo já descrito neste Capítulo, em seções anteriores, sendo que a medida pode ser obtida em uma ou várias linha com foi apresentado na Figura 5.2. Na Figura 5.7, são apresentados exemplos das etapas do processo. Na Figura 5.7(a), é descrita a região do ponto inicial, representado pela letra X. A Figura 5.7(b) apresenta a linha que é processada a partir do ponto inicial e a Figura 5.7(c) mostra a medida da espessura do septo interventricular destacada por um círculo.




FIGURA 5.7 – Processo de medida do septo interventricular.

5.2.2 Diâmetro do ventrículo esquerdo

O trabalho com essa medida, foi motivado pela necessidade de ter um método para avaliar os resultados obtidos na segmentação das imagens ecocardiográficas fetais. A partir de medidas precisas conclui-se que a segmentação é satisfatória. Além disso, o diâmetro do ventrículo esquerdo pode ser utilizada juntamente com a espessura do septo interventricular e da parede posterior do ventrículo, na determinação da massa do ventrículo [ARA 96], entre outras funções.

A escolha dessa medida é justificada por ser uma estrutura realçada nas imagens e menos complexa para a detecção.

Assim como na medida da espessura do septo interventricular, para medir o ventrículo esquerdo também é necessária a interação com o usuário. O usuário deve informar o ponto inicial dentro o ventrículo e na altura que deseja iniciar a medida. Na Figura 5.8 são apresentados exemplos das etapas do processo de obtenção diâmetro do ventrículo esquerdo, na Figura 5.8(a), pode-se acompanhar a região do ponto inicial, a qual deve ser informada pelo usuário, representada pela letra *X*. A Figura 5.8(b) apresenta a linha que é processada a partir do ponto inicial e na Figura 5.8(c) é mostrada a medida sobre a imagem original.




FIGURA 5.8 – Processo de medida da espessura do ventrículo esquerdo.

5.2.3 Índice de excursão do *Septum Primum*

O índice de excursão do *septum primum* é estudado pela equipe de Cardiologia Fetal do ICRGS. A medida está associada, entre outros problemas, à presença de extra




FIGURA 5.9 – Excursão do *septum primum* para o interior do átrio esquerdo.

sistolia atrial [FIR 95]. O interesse dos especialistas do ICRGS motivou o trabalho com essa medida.

Para a obtenção do índice, é necessário a obtenção de duas medidas que, calculadas, resultam no índice de excursão do *septum primum*. O índice de excursão é igual à razão entre a máxima excursão do *septum primum* para o interior do átrio esquerdo e a medida do máximo diâmetro do átrio esquerdo.

O *septum primum* é uma fina membrana interatrial que inicia a separação dos átrios, também é conhecida como membrana do forâme oval, porque funciona como uma válvula que fecha o forâme oval na contração atrial. O forâme oval é um orifício de passagem de fluxo interatrial que se fecha permanentemente após o nascimento [FIR 95].

O *septum primum* expande-se para dentro do átrio esquerdo durante a diástole. Quando o coração está em diástole máxima é medida a máxima excursão do *septum primum*. A Figura 5.9 apresenta um desenho esquemático da excursão do *septum primum* para o interior do átrio esquerdo durante a diástole, nela pode-se observar os rótulos *A*, *A*¹ e *B*, onde *A* e *A*¹ são graus variáveis de excursão do *septum primum* enquanto *B* representa o máximo diâmetro do átrio esquerdo ao final da diástole.

O algoritmo que extrai essas medidas, assim como nos outros casos, necessita a interação do usuário para que seja informado o ponto inicial. Esse ponto deve estar sobre o septo interatrial e na região do forâme oval. A região é difícil de analisar porque se trata de um orifício.

Pode-se visualizar o processo de medida a partir da Figura 5.10. Na Figura 5.10(a) pode-se acompanhar a região do ponto inicial, representado pela letra *X*. A Figura 5.10(b)




FIGURA 5.10 – Medidas para o IRSP.

apresenta a linha que representa a máxima excursão do *septum primum* para o interior do átrio esquerdo e a Figura 5.10(c) mostra a medida do máximo diâmetro do átrio esquerdo.

Os resultados obtidos durante o processo de obtenção das medidas, a avaliação desses resultados, bem como as dificuldades encontradas na implementação do trabalho serão apresentadas nos próximos Capítulos.

6 O Ambiente de Desenvolvimento

Conforme descrito no Capítulo 3, o processamento de imagens segue algumas etapas pré-definidas. Neste Capítulo, serão apresentadas as soluções adotadas na dissertação para resolver tais etapas, além da apresentação da ferramenta de *software* utilizada na implementação do método.

A ferramenta escolhida para ser utilizada no desenvolvimento do *software* foi o Khoros [KON 94]. O Khoros é um ambiente especializado em processamento de imagens que agrega uma série de rotinas já desenvolvidas. Além de disponibilizar os fontes do *software*.

A etapa de aquisição das imagens foi realizada por médicos do Instituto de Cardiologia do Rio Grande do Sul, os quais cederam as mesmas para que fossem realizados os testes de avaliação dos resultados. Essa cessão é fruto da interação da equipe do projeto SEGIME com a equipe de Cardiologia Fetal do ICRGS.

A segmentação das imagens através de RNAs tem sido estudada pelo grupo SEGIME visando a definição de um método que gere resultados confiáveis. Dahmer [DAH 98] propôs o uso de um MLP treinado pelo algoritmo *Backpropagation*. Esse método obteve os primeiros resultados na segmentação. Posteriormente, Piccoli [PIC 99] aprimorou os resultados utilizando a abordagem não-supervisionada de Kohonen, descrita na subseção 4.2.4. Esses foram os resultados obtidos em termos de segmentação pelo grupo SEGIME. Como essa dissertação está inserida no contexto do grupo SEGIME, o método desenvolvido por Kohonen e adaptado por Piccoli está sendo usado para segmentar as imagens. Além disso, outras RNAs têm sido analisadas pelo grupo SEGIME [FER 2001].

No decorrer deste Capítulo é apresentado o ambiente de desenvolvimento da dissertação. Na Seção 6.1 é apresentado o ambiente de desenvolvimento de *software* utilizado na implementação, o Khoros. A Seção 6.2 apresenta a etapa de aquisição das imagens realizada neste trabalho. Na Seção 6.3 são apresentadas as alternativas utilizadas na etapa de pré-processamento. A etapa de segmentação, juntamente com a configuração da RNA utilizada é apresentada na Seção 6.4.

6.1 O ambiente Khoros

A implementação dos protótipos para medidas, bem como a segmentação e o pré-processamento das imagens, foram gerados no ambiente Khoros. O Khoros tem sua origem nos laboratórios da Universidade do Novo México, nos Estados Unidos, e é um ambiente de desenvolvimento direcionado para processamento e visualização de imagens [RAS 91]. Além da especialização no trabalho com imagens, outra característica atrativa do Khoros é o livre acesso para pesquisa, inclusive com códigos fonte abertos [DAH 98], disponível até a versão 2.2 do software, a qual é usada pelo SEGIME. A partir da versão 2000, o pacote começou a ser comercializado.

O Khoros disponibiliza aos desenvolvedores dezenas de rotinas já implementadas, distribuídas em *toolboxes*. Um *toolbox* pode ser visto como um diretório que imita a estrutura do ambiente Khoros, onde são colocados todos os arquivos necessários à execução e manutenção das rotinas. O usuário pode optar por linguagens tradicionais como C, C++ e FORTRAN para o desenvolvimento de novas rotinas.

O desenvolvimento de uma aplicação no Khoros é dividido em etapas:

- implementação do *software*;
- desenvolvimento da aplicação.

Na primeira etapa é desenvolvida no ambiente *Craftsman*. A segunda etapa é realizada no ambiente de programação visual *Cantata*.

6.1.1 Desenvolvimento de novas rotinas no Khoros

Para a manipulação de rotinas no Khoros o programador tem à sua disposição o ambiente *Craftsman*, onde é realizado o gerenciamento dos *toolboxes*. O *Craftsman* apresenta um conjunto de aplicativos com funções específicas para desenvolver, modificar ou remover rotinas.

O ambiente *Craftsman* disponibiliza o acesso às rotinas do Khoros. A Figura 6.1 mostra a janela principal do ambiente, a qual apresenta duas listagens. À esquerda, são listados os *toolboxes* e, à direita, pode-se acessar os objetos, compostos das rotinas que formam cada *toolbox*. Para acessar essa lista, basta selecionar o *toolbox*. O acesso às rotinas é possível através do aplicativo *Composer*, o qual faz parte das ferramentas do *Craftsman*.

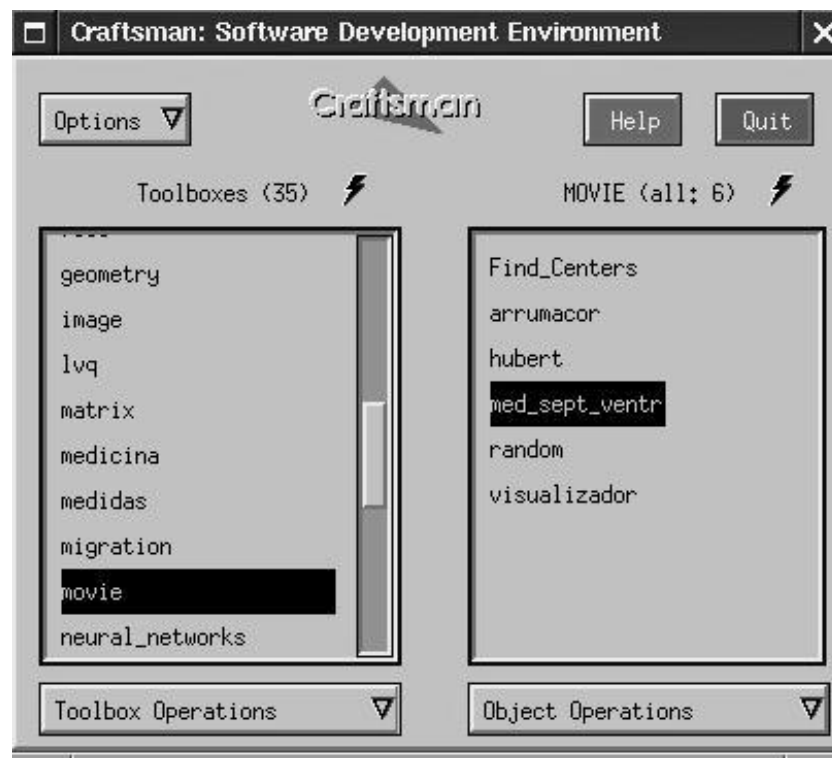


FIGURA 6.1 – Tela do ambiente Craftsman.

O aplicativo *Composer* serve para editar cada objeto existente dentro dos *toolboxes* e é nele que são realizadas operações sobre as rotinas que compõem os objetos. O *Composer* possibilita a edição de código fonte das rotinas, criação e edição das janelas de *interface* com o usuário e inclusive editar documentos para serem exibidos como *help* das rotinas. Na Figura 6.2, é apresentada a janela do *Composer*.

Para a criação e modificação da *interface* com o usuário, o *Composer* possui um aplicativo denominado *Guise*, onde é possível definir os parâmetros que devem ser passa-

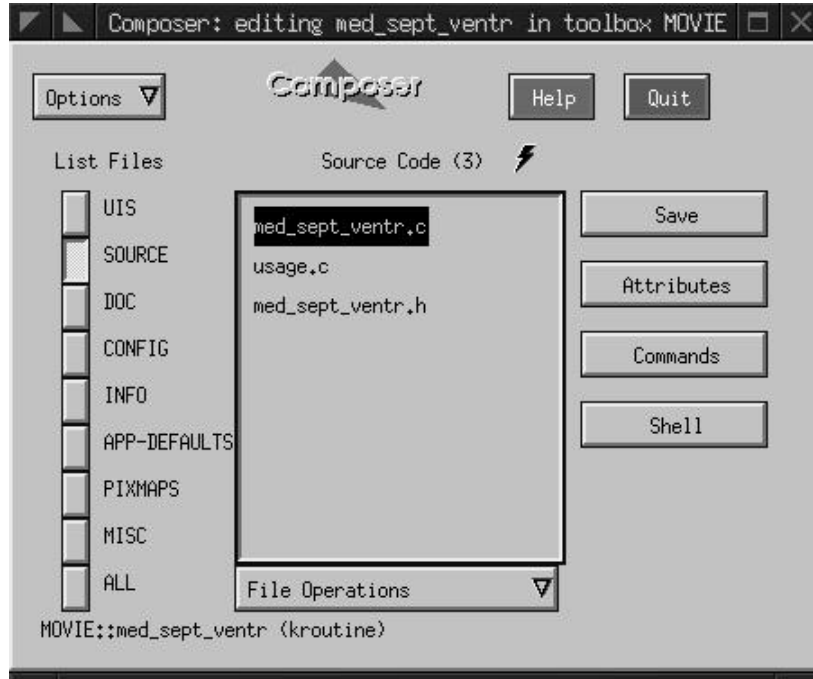


FIGURA 6.2 – Tela do aplicativo Composer, disponível no Craftsman.

dos pelo usuário, os arquivos de entrada e saída, determinar variáveis de entrada e definir como será exibida a *interface* com o usuário, apresentada na Figura 6.3. No Khoros, as janelas de *interface* são chamadas de *pane*. Nessas janelas são inseridos botões, campos de texto, variáveis, entre outros componentes. Todas as modificações podem ser feitas arrastando campos para alterar sua localização, definindo os valores para cada campo, além de algumas operações com os dados de entrada e saída de cada rotina.

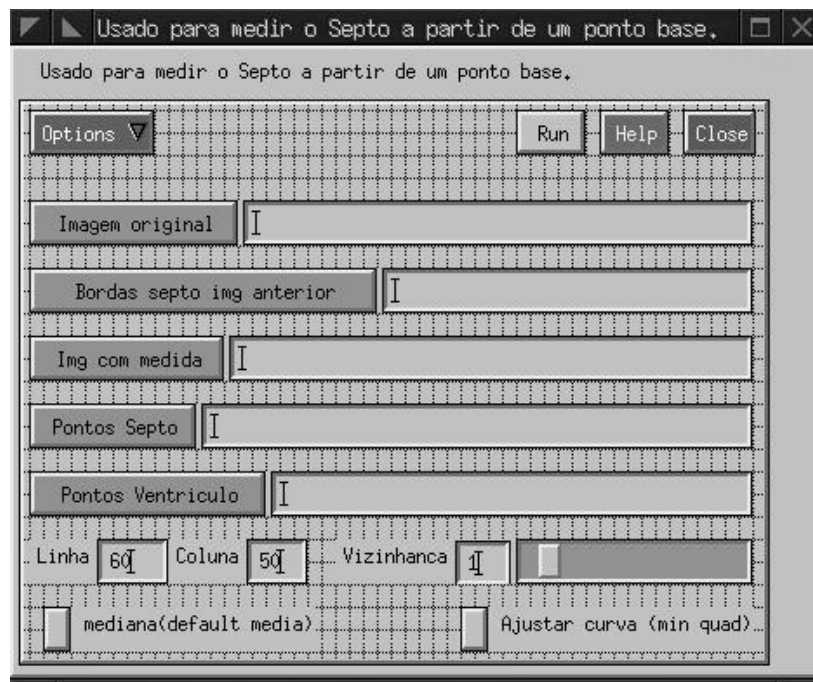


FIGURA 6.3 – Janela de edição do Pane.

O Khoros possibilita a escolha de linguagens de programação já consagradas como C, C++ e FORTRAN. Além disso, diversos editores de textos podem ser usados na edição do código-fonte dos programas.

6.1.2 O ambiente de programação visual Cantata

O ambiente de programação visual do Khoros é uma linguagem orientada por fluxo de dados. Cada rotina do sistema recebe um conjunto de dados de entrada e gera um conjunto de dados de saída. As rotinas são interconectadas para a solução das tarefas, gerando um *workspace*. Na Figura 6.4, é apresentado o ambiente de programação visual Cantata juntamente com um exemplo de *workspace*. Neste exemplo há quatro rotinas, a primeira caixa, da esquerda para direita, representa uma rotina para abrir o arquivo da imagem, a segunda, uma rotina para segmentar a imagem, enquanto as outras duas rotinas servem para exibir o resultado no vídeo e salvar o arquivo gerado, respectivamente.

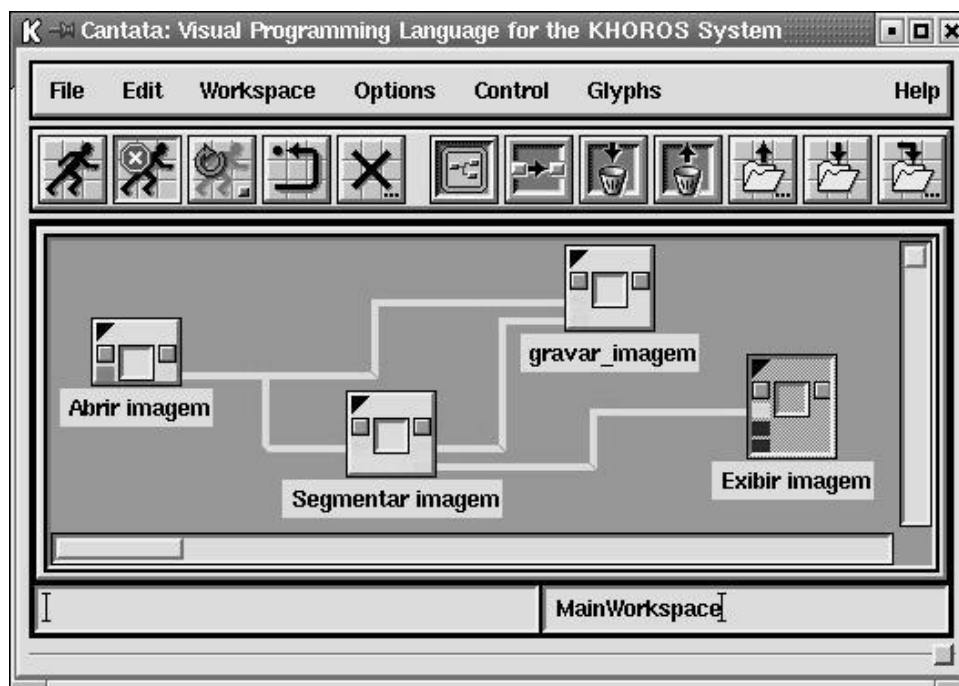


FIGURA 6.4 – Exemplo de fluxo de dados no Cantata.

O exemplo da Figura 6.4 apresenta algumas características do Cantata. Neste ambiente, as rotinas são representadas por uma espécie de ícone chamado de *glyph* (Figura 6.5(a)). No *glyph*, existem botões para executar a rotina que ele representa (Figura 6.5(b)) e para acessar o painel de parâmetros (pane) associados a rotina em questão (Figura 6.5(c)). Através dos *glyphs*, é possível saber o número de entradas e saídas das rotinas. Essas são representadas por pequenos quadrados dentro do *glyph*, sendo os da esquerda as entradas (Figura 6.5(d)) e os da direita as saídas (Figura 6.5(e)). Essas entradas e saídas podem ou não estar conectadas a outros *glyphs*, como mostra a Figura 6.4.




FIGURA 6.5 – Descrição das características de um *glyph*.

6.2 A aquisição das imagens

O conjunto de imagens utilizadas nos experimentos é muito importante para a obtenção de bons resultados, podendo comprometê-los se não forem cuidadosamente escolhidos. As imagens utilizadas neste trabalho foram cedidas pela equipe de Cardiologia Fetal do ICRGS, através dos médicos Paulo Zielinsky e Stelamaris Luchesi.

As primeiras imagens trabalhadas, as quais foram utilizadas nos testes para a medida da espessura do septo interventricular e do ventrículo esquerdo, estavam gravadas em uma fita VHS de forma analógica. As imagens utilizadas para a medida do índice de excursão do *septum primum* foram gravadas no formato digital, facilitando a etapa de aquisição, pois não foi necessária a digitalização das mesmas.

A melhora no método de gravação das imagens foi resultado da compra de um novo equipamento no instituto de cardiologia. O ecocardiógrafo Aspen, fabricado por uma empresa do grupo Siemens, possibilita a gravação dos exames diretamente na forma digital. Essa característica melhora a qualidade das imagens trabalhadas, que anteriormente sofriam degradação na digitalização.

6.3 A etapa de pré-processamento

Nesta etapa as imagens são ajustadas para melhorar o desempenho do método de extração das medidas. São basicamente duas tarefas realizadas atualmente no pré-processamento: a extração da região de interesse (ROI) e a filtragem para realçar a imagem.

A ROI dentro da imagem ecocardiográfica fetal é aquela que representa o coração do feto. O procedimento de extração desta região é justificado pela melhora no desempenho computacional do método. Como a imagem possui muita informação que não interessa na extração das medidas e influencia a computação, a ROI é extraída e o resto da imagem é descartado. A Figura 6.6 mostra a ROI dentro do contexto da ecocardiografia.

Devido à baixa qualidade das imagens e à grande incidência de ruído, foram utilizados os filtros da mediana, o *alpha trimmed* e o *crimmins*, descritos no Capítulo 3. A equalização do histograma [SON 98] também foi usada para aumentar o contraste e auxiliar na segmentação.

6.4 A Segmentação das Imagens

O modelo usado para segmentar as ecocardiografias fetais foi a rede neural SOM, definido por Kohonen [KOH 90] e já descrita no Capítulo 4. O critério de similaridade segue o padrão que normalmente é usado nesta rede, a distância Euclidiana. Cada neurônio da rede é capaz de representar, de maneira compacta, um conjunto de padrões similares da




FIGURA 6.6 – Extração da região de interesse.

imagem. A rede foi treinada com um mapa de tamanho 20x20 e foi utilizada a atualização Gaussiana de vizinhança [PIC 99a].

Nos trabalhos de Dahmer e Piccoli [DAH 98, PIC 99] foram estudadas características relevantes das ecocardiografias para serem usadas como amostras para o treinamento das redes. Dahmer propôs o uso da média e da variância dos níveis de cinza juntamente com atributos de textura das imagens e Piccoli comprovou que o uso dos atributos de textura comprometiam o processamento sem melhorar significativamente os resultados. Com base nesses estudos, a média dos níveis de cinza foi usada como amostra de entrada para o treinamento da rede. A rede foi treinada para representar as amostras mais frequentes.

As amostras foram escolhidas aleatoriamente. O usuário apenas especifica o número de amostras, que serão obtidas de algumas imagens das ecocardiografias. São colhidas 100 amostras de cada imagem. O número de imagens da amostragem depende do tamanho da seqüência analisada. O processo de coleta é exemplificado através da Figura 6.7.




FIGURA 6.7 – Processo aleatório de escolha das amostras.

Durante a fase de treinamento, os neurônios do mapa tendem a aglomerarem-se em diferentes grupos, de acordo com a similaridade das médias dos níveis de cinza encontradas nas amostras. A Figura 6.8 mostra o efeito dessa fase do processamento neural.

Embora cada neurônio na rede possa ser considerado como um padrão (cluster), melhores resultados podem ser obtidos pelo agrupamento de neurônios semelhantes, reduzindo o número de *clusters*. Para agrupar os neurônios semelhantes, o mapa treinado foi pós-processado através de um algoritmo de *clusterização*. O método utilizado foi o *K-means* [SON 98], o qual analisa os pesos dos neurônios e reúne aqueles pertencentes a diferentes grupos de acordo com um número pré-definido pelo usuário, diminuindo a distância conhecida como *inter-cluster*. Depois desta etapa, há um reduzido número de




FIGURA 6.8 – Fase de treinamento e geração do mapa agrupado pelo SOM.

clusters, os quais representam as regiões mais significativas da imagem. A Figura 6.9 apresenta um exemplo desta etapa do processamento.




FIGURA 6.9 – Fase de pós-processamento do mapa pelo *K-means*.

A segmentação de cada imagens é feita sobre o mapa pós-processado. O algoritmo compara o mapa com a imagem e determina a similaridade entre os dois. Esse processo é realizado através de uma janela móvel (3x3), a qual percorre a imagem extraindo as médias dos níveis de cinza e comparando-as com os valores do mapa pós-processado (k-means), um neurônio do mapa é eleito o mais similar à imagem, seu valor é atribuído à imagem resultante, gerando a imagem segmentada. Essa situação é ilustrada na Figura 6.10. Nesse exemplo, a imagem foi segmentada em duas regiões, sendo esse o número usado para obtenção das medidas.




FIGURA 6.10 – Processo de segmentação.

A segmentação da imagem em duas regiões é justificada pela evidência das estruturas cardíacas de interesse na imagem, ou seja, são as principais estruturas e portanto mais realçadas. Contudo, a classificação em duas regiões pode causar perda de informações referentes a estruturas menos evidentes. Para que seja possível detectar estruturas menores, uma alternativa seria a segmentação da imagem em mais regiões. Esse não é o caso das estruturas trabalhadas nessa dissertação, as quais conseguiram se distinguir na imagem binária.

7 Resultados Obtidos

Este Capítulo apresenta os resultados obtidos pelo método de medidas desenvolvido nesta dissertação. Os testes foram realizados para a avaliação do desempenho do método apresentado.

Nos testes com as medidas da espessura do septo interventricular e do diâmetro do ventrículo esquerdo foram usados três grupos de imagens. Cada grupo pertence a um paciente diferente e é formado por cinco imagens. Essas imagens foram extraídas de uma seqüência ecocardiográfica. A escolha das imagens foi realizada com a ajuda de uma especialista em Cardiologia Fetal do ICRGS. Ela elegeu aquelas que julgou mais apropriadas para a realização dos testes.

Já nos testes com as medidas para o índice de excursão do *septum primum*, foram utilizadas dezessete imagens de diferentes pacientes. A partir dessas imagens foram extraídas as medidas da excursão máxima do *septum primum* e o máximo diâmetro do átrio esquerdo. Tais imagens fazem parte de um novo conjunto de imagens recebidas diretamente na forma digital. Foram gravadas por um especialista em Cardiologia Fetal do ICRGS.

A avaliação dos resultados será baseada em medidas de referência gerados por especialistas. Todas as imagens trabalhadas nestes testes, foram analisadas pelos especialistas, através de medidas. Conforme descrito na Seção seguinte.

As medidas dos primeiros testes são apresentadas em *pixel*, isso se deve a inexistência de uma escala que pudesse ser utilizada para medir os *pixels*. As imagens recebidas para os testes do índice de excursão do *septum primum* possuíam uma escala que possibilitou a conversão para centímetros.

O Capítulo será dividido em quatro Seções. Na próxima Seção são apresentados os critérios utilizados na avaliação dos resultados. Na Seção 7.2 serão apresentados os resultados referentes à medida das espessuras do septo interventricular. A Seção 7.3 apresentará os resultados obtidos nas medidas do diâmetro do ventrículo esquerdo. Finalmente, na Seção 7.4 serão apresentados os resultados obtidos com as medidas necessárias ao índice de excursão do *septum primum*.

7.1 Avaliação dos resultados

As imagens utilizadas nos testes foram escolhidas com a ajuda de especialistas em cardiologia fetal, os quais fazem parte da equipe de cardiologia fetal do Instituto de Cardiologia do Rio Grande do Sul. Tratam-se de profissionais altamente capacitados e experientes.

A avaliação dos resultados foi realizada através da comparação entre as medidas obtidas pelo método (semi-automáticas) e as medidas obtidas manualmente pelo especialista. Essa avaliação é expressa através da diferença entre os resultados. As medidas de referência foram realizadas por especialistas do ICRGS em todas as imagens utilizadas nos testes.

A comparação foi realizada com base no número de *pixels*. Para as medidas da excursão do *septum primum* e o diâmetro do AE foi utilizada a medida em centímetros. Não foi levado em consideração a localização espacial dos *pixels* dentro da imagem.

A Figura 7.1 mostra os pontos marcados pelos especialistas sobre uma imagem, os

quais foram quantificados para montagem da referência. Nas imagens utilizadas para a avaliação das medidas da excursão do *septum primum* e o diâmetro do átrio esquerdo, as medidas de referência foram realizadas no próprio aparelho ecocardiógrafo, durante o exame (Figura 7.1(a)). Para as outras duas medidas, essa operação foi realizada após o exame em um computador, através de um editor gráfico (Figura 7.1(b)).




FIGURA 7.1 – Indicação dos pontos marcados pela especialista.

Para cada estrutura medida nesse trabalho, foi calculada a média das diferenças entre as medidas obtidas pelo método semi-automático e as medidas de referência. O valor médio obtido foi utilizado para fazer uma avaliação do método semi-automático em relação aos resultados normalmente obtidos pelos especialistas. A avaliação tomará como referência a “variabilidade inter-observador”, uma medida conhecida na área médica para calcular a variação dos resultados obtidos por dois ou mais especialistas em uma mesma medida. Nesse caso a variação será entre as medidas de um especialista e do método semi-automático.

7.2 Medidas do Septo Interventricular

Nesta Seção, serão apresentadas as medidas realizadas sobre três grupos de imagens, extraídos de três diferentes seqüências, com os resultados gerados pelo método e a referência (medida feita pelo especialista), para a espessura do septo interventricular. Os valores das medidas são expressos em *pixels*.

Nas Tabelas 7.1, 7.2 e 7.2 são apresentados os resultados da medida da espessura do *SiV* obtidos pelo método (W) e também os usados como referência (R), obtidos pelo especialista. Nessas tabelas, são apresentadas as medidas feitas nos três grupos de imagens, respectivamente G_1 , G_2 e G_3 . As tabelas também apresentam a diferença entre os valores do método e a referência para cada imagem (Δ), em *pixels* (Δ (*pixels*)) e em termos percentuais, obtidos pelo cálculo: $(\Delta\%) = ((W - R) * 100) / R$.

Os testes realizados com o primeiro grupo de imagens (Tabela 7.1), não apresentaram diferenças significativa entre os resultados obtidos pelo método e pela referência. Entre as cinco imagens medidas, somente a medida de uma apresentou variação em relação à medida do especialista, que foi mínima (10%).

Além dos valores expressos em números, o método também apresenta os resultados através das imagens. Na Figura 7.2, são apresentados os resultados obtidos para a medida da espessura do septo interventricular no primeiro grupo de imagens. Nessa Figura, é

TABELA 7.1 – Medidas referentes ao SiV no $G1$ (ver texto).

imagem	SiV			
	R	W	Δ (<i>pixels</i>)	$\Delta\%$
1	10	10	0	0%
2	8	8	0	0%
3	9	9	0	0%
4	10	9	1	10%
5	9	9	0	0%

apresentada uma imagem pertencente ao grupo, nesse caso a quinta imagem. Essa Figura exhibe a imagem original (a) e a imagem segmentada, com a medida realizada pelo método (b). A medida é apresentada por uma tonalidade de cinza sobre o septo interventricular. Foi colocado manualmente um círculo em torno da medida.




FIGURA 7.2 – Resultados obtidos pelo método semi-automático.

A Tabela 7.2 apresenta as maiores diferenças observadas nestes testes. Mesmo sendo na ordem de dois *pixels*, os resultados foram afetados pela diferença média de 20,33%. Esses resultados serão discutidos nas conclusões. Na Figura 7.3, é apresentada uma amostra do resultado, expressa de forma gráfica através das imagens geradas pelo método. Esta Figura representa a terceira imagem do grupo dois. A medida está grifada por um círculo.

TABELA 7.2 – Medidas referentes ao SiV no $G2$ (ver texto).

imagem	SiV			
	R	W	Δ (<i>pixels</i>)	$\Delta\%$
1	10	11	1	10,0%
2	8	10	2	25,0%
3	9	11	2	22,2%
4	9	11	2	22,2%
5	9	11	2	22,2%

Os resultados apresentados no $G3$ foram semelhantes àqueles do $G1$ e estão descritos na Tabela 7.3. Não apresentaram diferença significativa em relação aos valores de referência. A média de diferença foi de 4,22% e em três casos os resultados do método foram iguais aos obtidos pelo especialista.




FIGURA 7.3 – Resultados obtidos pelo método semi-automático no $G2$.

TABELA 7.3 – Medidas referentes ao SiV no $G3$ (ver texto).

imagem	SiV			
	R	W	Δ (<i>pixels</i>)	$\Delta\%$
1	9	10	1	11,1%
2	10	10	0	0,00%
3	10	11	1	10,0%
4	10	10	0	0,00%
5	9	9	0	0,00%

Na Figura 7.4 é apresentada a última imagem do $G3$, a qual foi gerada pelo método. As imagens com as medidas geradas pelo método servem para que os usuários visualizem os resultados. Através delas os especialistas podem avaliar se os resultados são coerentes.




FIGURA 7.4 – Resultados obtidos pelo método semi-automático no $G3$.

A partir da análise das medidas obtidas para os três grupos de imagens, a diferença mínima verificada foi nula, pois em alguns casos a medida do método foi igual à medida de referência. A diferença máxima foi de 25% enquanto a média das diferenças foi 8,84%, um valor relativamente pequeno quando comparado com as diferenças observadas entre especialistas.

7.3 Medidas do Ventrículo Esquerdo

As medidas do diâmetro do ventrículo esquerdo foram realizadas nos mesmos grupos de imagens utilizadas nas medidas do septo interventricular. Com o mesmo ponto inicial, pode-se obter as duas medidas, haja visto que são extraídas da mesma altura na imagem.

Para exibir os resultados, foram geradas tabelas, as quais serão apresentadas no decorrer desta seção. Nas tabelas, os resultados estão descritos em *pixels*, pois, assim como ocorreu na medida do SiV, não foi possível transformar os *pixels* em uma unidade de medida usual (por exemplo, centímetros ou milímetros).

As Tabelas 7.4, 7.5 e 7.6 apresentam os resultados das medidas do diâmetro do ventrículo esquerdo realizadas sobre os três grupos de testes. As medidas referentes ao método são apresentadas em W , enquanto os resultados usados como referência e medidos pela especialista estão nas colunas (R). A diferença entre os resultados obtidos para cada imagem é apresentada em *pixels* Δ e em termos percentuais na coluna $\Delta\%$. A diferença percentual é obtida a partir do cálculo de $((W - R) * 100)/R$.

Embora haja uma relativa diferença na ordem de grandeza das medidas do VE, apresentadas nesta Seção, em relação às medidas do SiV (40 e 10 *pixels* respectivamente), a diferença apresentada nesses resultados é menor, em termos percentuais, àquela apresentada na Seção 7.2.

Na Tabela 7.4, com os resultados do $G1$, pode-se observar a maior diferença dentre os três grupos, nas medidas do VE, que foi de 10, 25% e é equivalente a 4 *pixels*. A média da diferença nesse conjunto foi de 5, 07%.

TABELA 7.4 – Medidas referentes ao VE no $G1$.

imagem	VE			
	R	W	Δ (<i>pixels</i>)	$\Delta\%$
1	39	43	4	10,25%
2	40	41	1	2,43%
3	39	41	2	5,12%
4	39	41	2	5,12%
5	40	41	1	2,43%

Na Figura 7.5 é apresentado o resultado obtido para uma das imagens do $G1$. A medida é expressa na imagem através de uma faixa cinza dentro do VE. Os resultados gerados pelos grupos $G2$ e $G3$ são apresentados dessa mesma forma nas Figuras 7.6 e 7.7 respectivamente.

Analisando a Tabela 7.5, com os resultados da medida do VE para o $G2$, percebe-se que houve uma regularidade entre os resultados obtidos pelo método e a referência. A indicação desse fato foi a pequena diferença dos resultados. Somente uma, das cinco medidas, apresentou diferença superior a 2, 5%. A média das diferenças foi de 3, 25%.

Os melhores resultados, para a medida do VE, foram apresentados no $G3$, conforme pode-se observar na Tabela 7.6, sendo que dois valores obtidos pelo método, foram exatamente iguais aos obtidos pelo especialista na referência. A média das diferenças foi de 1, 93%.

Um exemplo das medidas obtidas no $G3$ pode ser analisado na Figura 7.7, referente à quinta imagem do grupo. Assim como em Figuras anteriores, a primeira apresenta a imagem original (a) e a segunda a imagem segmentada e com a medida (b).




FIGURA 7.5 – Resultados obtidos pelo método semi-automático para o VE no $G1$.

TABELA 7.5 – Medidas referentes ao VE no $G2$.

imagem	VE			
	R	W	Δ (pixels)	$\Delta\%$
1	41	42	1	2,43%
2	44	45	1	2,27%
3	44	43	1	2,27%
4	43	40	3	6,97%
5	43	42	1	2,32%




FIGURA 7.6 – Resultados obtidos pelo método semi-automático no $G2$.

TABELA 7.6 – Medidas referentes ao VE no $G3$.

imagem	VE			
	R	W	Δ (pixels)	$\Delta\%$
1	44	44	0	0,00%
2	40	42	2	5,00%
3	41	41	0	0,00%
4	42	41	1	2,38%
5	44	43	1	2,27%

Os resultados obtidos nesses três grupos de imagens foram os melhores, dentre as quatro medidas analisadas. A diferença mínima entre os resultados obtidos pelo método e os de referência obtidos pelo especialista foi nula, devido à ocorrência de valores iguais




FIGURA 7.7 – Resultados obtidos pelo método semi-automático no $G3$.

para o método e a referência. A diferença máxima obtida foi de 10,25%, um número bastante baixo se levarmos em consideração a diferença entre especialistas, que está em torno de 20%. Outro resultado satisfatório foi a média das diferenças que atingiu 3,42%.

7.4 Medidas para o Índice de Excursão do *Septum Primum*

As medidas do índice de excursão do *septum primum*, obtidas nos testes realizados nessa dissertação, serão apresentadas nessa Seção, juntamente com a avaliação dos resultados. A avaliação será baseada na comparação da medida obtida pelo método e a medida de referência obtida pelo especialista. Não será considerada a posição espacial dos *pixels* dentro da imagem.

Para obter o índice de excursão do *septum primum*, são necessárias duas medidas cardíacas, conforme descrito na Subseção 5.2.3. O índice é obtido a partir da razão entre a medida da excursão do *septum primum* para o interior do átrio esquerdo e o diâmetro do átrio esquerdo.

Para que a avaliação fique mais consistente, os resultados obtidos para as duas medidas serão apresentadas isoladamente. Logo após esses resultados serem expressos, será feita a avaliação dos resultados do índice de excursão do *septum primum* em relação à referência obtida pelo especialista.

Os testes foram realizados sobre dezessete imagens de diferentes pacientes, essas imagens foram cedidas pela equipe de Cardiologia Fetal do ICRGS. Ao contrário das imagens utilizadas nos testes anteriores, essas possuíam a medida de referência gravada pelo especialista no momento do exame.

Uma forma de avaliar os resultado é através das imagens. Como a imagem gerada pelo método e a imagem com as medidas de referência estão disponíveis, as medidas podem ser avaliadas de forma gráfica. Embora essa avaliação deva ser feita por especialistas, essas imagem são apresentadas nesta Seção.

Na Figura 7.8(a) é apresentada a imagem com as medidas obtidas pelo especialista, usadas como referência. Na Figura 7.8(b) é apresentado o resultado obtido pelo método proposto. Para melhor visualização, dos resultados obtidos, o método traça três linhas verticais e uma horizontal sobre a imagem, sendo que os pontos encontrados pelo método são as intersecções das linhas verticais com a horizontal.

Nas Subseções seguintes serão apresentados, os resultados da medida da excursão máxima do *septum primum* para o interior do átrio esquerdo, seguida pela Subseção que




FIGURA 7.8 – Resultados obtidos pelo método semi-automático no IRSP.

descreve os resultados da medida do diâmetro do átrio esquerdo e pela Subseção que apresenta os resultados do índice de excursão do *septum primum*.

7.4.1 Excursão do *Septum Primum*

O *septum primum* é uma fina membrana sobre o forãme oval que se funde com o septo interatrial logo após o nascimento. Durante o período fetal, há vazão de sangue do átrio direito para o esquerdo, através do forãme oval e esse fluxo movimentava a membrana. Essa movimentação que é avaliada na medida do índice de excursão do *septum primum*.

A tabela de avaliação dos resultados é semelhante às Tabelas apresentadas nos testes com as medidas do SiV e VE, embora os resultados, nesse caso, sejam apresentados em centímetros.

A Tabela 7.7 apresenta os resultados obtidos pelo método na medida da excursão máxima do *septum primum* para o interior do átrio esquerdo (coluna W) e também os valores usados como referência (coluna R), obtidos pelo especialista. Essa Tabela também apresenta, na coluna Δ , a diferença entre os valores do método e da referência. Esses valores são expressos em centímetro e em termos percentuais (obtidos pelo cálculo: $((W - R) * 100) / R$ e apresentados na coluna $\Delta\%$).

A partir das medidas apresentadas na Tabela 7.7, foram extraídos os valores das diferenças mínima, máxima e média dos resultados obtidos pelo método em relação à referência. A diferença mínima foi obtida em 4 casos, o que representa 23,5% das imagens e foi obtida quando os resultados da referência e do método foram iguais, portanto, diferença nula. A diferença máxima chegou ao pico de 26,41%, enquanto a média da diferença foi de 8,35%. Abaixo da média da diferença entre especialistas.

Por ser uma estrutura muito fina e a imagem muito ruidosa, o *septum primum* é difícil de ser localizado e visualizado na imagem. Em alguns casos, o método de obtenção de medidas não consegue localizá-lo, o que impossibilita a medida semi-automática. Nesses casos, o especialista deve realizar a medida manualmente.

7.4.2 Diâmetro do Átrio Esquerdo

O átrio esquerdo é a cavidade cardíaca para onde o *septum primum* se expande durante o período fetal. É uma das principais estruturas cardíacas. A medida do seu diâmetro também é utilizada no cálculo do índice de excursão do *septum primum*.

Essa estrutura é mais realçada na imagem do que o *septum primum*, isso se deve

TABELA 7.7 – Medidas referentes à extensão do SP.

imagem	SP			
	<i>R</i>	<i>W</i>	Δ (cm)	$\Delta\%$
1	0,42	0,42	0	0,00%
2	0,50	0,51	0,01	2,56%
3	0,39	0,39	0	0,00%
4	0,50	0,50	0	0,00%
5	0,54	0,53	0,01	2,17%
6	0,73	0,65	0,08	10,53%
7	0,57	0,48	0,09	16,22%
8	0,53	0,39	0,14	26,41%
9	0,50	0,51	0,01	2,44%
10	0,52	0,45	0,07	13,46%
11	0,33	0,39	0,06	17,86%
12	0,59	0,57	0,02	2,70%
13	0,59	0,49	0,10	16,94%
14	0,37	0,31	0,06	16,21%
15	0,46	0,46	0	0,00%
16	0,64	0,69	0,05	8,00%
17	0,35	0,33	0,02	6,45%

à maior absorção de ondas de ultra-som das cavidades cardíacas em relação a regiões de tecido, gerando regiões com valores mais baixos de cinza, regiões escuras e mais homogêneas.

Na Tabela 7.8 são apresentados os resultados obtidos pelo método para a medida do diâmetro do átrio esquerdo (*W*), juntamente com o valor de referência (*R*) e as respectivas diferenças, em centímetros (Δ) e valores percentuais ($\Delta\%$).

TABELA 7.8 – Medidas referentes ao diâmetro do *AE*.

imagem	<i>AE</i>			
	<i>R</i>	<i>W</i>	Δ (cm)	$\Delta\%$
1	0,89	0,90	0,01	1,45%
2	0,96	0,93	0,03	2,63%
3	1,22	1,13	0,09	7,00%
4	1,35	1,36	0,01	1,00%
5	1,17	1,30	0,13	11,11%
6	1,25	1,31	0,06	5,15%
7	0,93	0,93	0	0,00%
8	0,88	1,08	0,20	22,72%
9	1,10	1,13	0,03	2,72%
10	1,06	1,23	0,17	16,03%
11	0,65	0,64	0,01	1,82%
12	1,59	1,54	0,05	3,09%
13	1,31	1,25	0,06	4,58%
14	0,81	0,87	0,06	7,40%
15	0,72	0,73	0,01	1,30%
16	1,41	1,37	0,04	2,70%
17	0,79	0,80	0,01	1,45%

Foi observada a diferença mínima de 0cm, como já havia acontecido na medida do *septum primum* na Subseção anterior. Essa diferença nula aparece porque o método obteve uma medida igual à da referência. A diferença máxima foi de 0,20cm, correspondendo a 22,72% em relação a medida de referência. A média de diferença dos resultados obtidos pelo método em relação à referência foi de 5,42%. Resultado animador por estar muito abaixo da diferença encontrada na literatura, para a variabilidade entre especialistas, que é de 20% em média [JEA 2001].

7.4.3 Índice de Excursão do *Septum Primum*

A partir das imagens segmentadas foram obtidas as medidas das estruturas necessárias para a obtenção do índice de excursão do *septum primum*, já apresentadas nas Subseções 7.4.1 e 7.4.2. Nessas Subseções, as medidas foram analisadas individualmente.

A Tabela 7.9 foi desenvolvida com base nos resultados apresentados nas Seções 7.4.1 e 7.4.2. Na coluna *R* são apresentados os resultados do índice de excursão do *septum primum*, obtidos pelo especialista e utilizados como referência na avaliação dos resultados obtidos pelo método, que são apresentados na coluna *W*. A diferença percentual dos resultados é apresentada na coluna $\Delta\%$.

TABELA 7.9 – Índice de excursão do *septo primum* (IRSP).

imagem	IRSP		
	<i>R</i>	<i>W</i>	$\Delta\%$
1	0,47	0,47	0,00%
2	0,52	0,55	5,77%
3	0,32	0,35	9,38%
4	0,37	0,37	0,00%
5	0,46	0,41	10,87%
6	0,58	0,50	13,79%
7	0,61	0,52	14,75%
8	0,60	0,36	40,00%
9	0,45	0,45	0,00%
10	0,49	0,37	24,49%
11	0,51	0,61	19,61%
12	0,37	0,37	0,00%
13	0,45	0,39	13,33%
14	0,46	0,36	21,74%
15	0,64	0,63	1,56%
16	0,45	0,50	11,11%
17	0,44	0,41	6,82%

A partir da Tabela 7.9 foram extraídas as diferenças mínima e máxima juntamente com a média das diferenças entre os resultados do método e a referência para o índice de excursão do *septum primum*. A diferença mínima foi observada nas imagens 1, 4, 9 e 12. Nessas imagens os valores obtidos pelo método foram iguais aos valores de referência, chegando à diferença nula. A diferença máxima foi atingida na imagem 8 e chegou a 40%, um valor elevado que está bem acima da média das diferenças, que foi de 11,36%. São resultados animadores, considerando os resultados citados na literatura, que estão em torno de 20% entre diferentes observadores [JEA 2001].

8 Conclusão

Esta dissertação propôs o desenvolvimento de um método computacional para a realização de medidas de estruturas do coração do feto humano. As medidas devem ser obtidas a partir de imagens ecocardiográficas segmentadas e de forma semi-automática. Para chegar a tais medidas o método realiza algumas etapas de processamento de imagens. Tais etapas tratam da aquisição, do pré-processamento e da segmentação das imagens.

Na aquisição das imagens foi observado que as imagens gravadas diretamente no formato digital diminui o trabalho da etapa de aquisição, não necessitando mais a tarefa de digitalização. Esta aquisição era anteriormente feita através de uma placa de captura de vídeo. Apesar da resolução das imagens digitais ser maior que as imagens gravadas de forma analógica, em fitas VHS, não foram observadas melhoras significativas na segmentação das mesmas.

Baseado na má qualidade das imagens de ultra-som e na grande ocorrência de ruído *speckle*, o filtro de *Crimmins* e a equalização do histograma foram ferramentas úteis no pré-processamento das imagens, ajudando em alguns casos.

A etapa mais importante para a obtenção de bons resultados nas medidas é a segmentação das imagens. A partir dos resultados obtidos nas medidas, foi comprovado que os Mapas Auto-organizáveis de Kohonen se adaptam bem à segmentação de imagens de ultra-som.

A obtenção das medidas de forma semi-automática apresentou vantagens que consolidaram o uso da interação com o usuário, além de ser difícil encontrar automaticamente o ponto inicial para as medidas, com base em padrões anatômicos cardíacos. Nessa forma os especialistas não teriam muito controle sobre o método. O uso da interação traz mais segurança e confiabilidade ao método.

A partir da avaliação das medidas apresentadas no Capítulo 7 foi possível chegar a algumas conclusões sobre o método. Na Tabela 8.1 são apresentadas as diferenças, mínimas e máximas dentro dos conjuntos de medidas. As diferenças nas medidas da espessura do SiV são expressas na linha *SiV*. As diferenças nas medidas do diâmetro do VE são apresentadas na linha *VE*. As diferenças para as medidas da expansão do *septum primum* estão na linha *ESP*. As diferenças para as medidas do diâmetro do átrio esquerdo são apresentadas na linha *AE* e as diferenças do índice de excursão do *septum primum* na linha *IRSP*. A variação média geral dentro de cada conjunto de medidas é apresentada na coluna *média*.

As diferenças mínima e máxima são obtidas a partir da subtração dos valores do conjunto de referência com os valores do conjunto de medidas obtidas pelo método. São apresentadas em termos percentuais para que seja possível a comparação entre os valores das diferentes medidas.

Os resultados apresentados na Tabela 8.1 mostram que a média das diferenças entre as medidas não ultrapassou 12% em relação ao valor de referências. Em todos os grupos de medidas é possível encontrar variações nulas, ou seja, o método obteve valores iguais aos da referência.

Dentro de cada medida, em suas respectivas Tabelas, pode-se observar que houve uma uniformidade nas diferenças. Às vezes as medidas obtidas pelo método é menor do que as da referência, às vezes é maior e em outros casos é igual. Há coerência nas diferenças para as medidas de referência e as do método. Esta característica poderia indicar aceitação do método.

TABELA 8.1 – Avaliação dos resultados.

medida	diferenças		
	mínima (%)	máxima (%)	média (%)
<i>SiV</i>	0	25	8,84
<i>VE</i>	0	10,25	3,42
<i>ESP</i>	0	26,41	8,35
<i>AE</i>	0	22,72	5,42
<i>IRSP</i>	0	40	11,36

A quantificação dos resultados em medidas, tais como *mm* ou *cm*, depende do tamanho do *pixel* na imagem. Essa quantificação só foi possível nas medidas do índice de excursão do *septum primum*, pois as imagens foram obtidas especialmente para a realização dos testes e possuíam uma escala para transformação dos *pixels*.

A variação entre os valores obtidos pelo método em relação a referência, está abaixo do percentual de 20%, normalmente obtido entre especialistas. Essa variação é conhecida como variação inter-observador. Estes resultados são bastante bons, considerando que em alguns casos, mencionados na literatura, este percentual é superior a 30% [JEA 2001].

Como trabalhos futuros, é provável que o método seja aplicado à outras estruturas cardíacas, aumentando sua abrangência. Essa é uma tarefa que deve ser abordada pelo grupo SEGIME para que a ferramenta seja concluída.

Anexo 1 Artigo no *Journal of VLSI Signal Processing*

Artigo aceito para publicação no periódico *Journal of VLSI Signal Processing Systems for Signal, Image and Video Technology - Advances in Neural Networks for Signal Processing* da editora Kluwer.

Na web: <http://www.kluweronline.com/issn/0922-5773>

Anexo 2 Artigo publicado no NNSP 2000

Artigo publicado nos *Proceedings of IEEE Workshop on Neural Networks for Signal Processing*”, nas páginas 594 até 603. A conferência foi realizada em dezembro de 2000, na cidade Australiana de Sydney. Organizado pela *IEEE Signal Processing Society* juntamente com a *IEEE Neural Network Council*.

Anexo 3 Artigo publicado no SBRN 2000

Artigo publicado nos Anais do VI Simpósio Brasileiro de Redes Neurais. Realizado na cidade do Rio de Janeiro, em novembro de 2000. Organizado pela Sociedade Brasileira de Computação.

Anexo 4 Artigo publicado no ICIE 2000

Artigo publicado nos Anais do VI Congresso Internacional de Ingenieria Informatica. Realizado na cidade do Buenos Aires, Argentina, no período de 26 a 28 de abril de 2000.

Bibliografia

- [ALL 86] ALLAN, L. D. **Manual of fetal echocardiography**. Norwell, MA.USA: MTP Press, 1986. 175p.
- [ARA 96] ARAÚJO MARRA, M. de. O ecocardiograma na avaliação da massa ventricular. **Contactos - Ecoar**, Belo Horizonte, v.10, p.3–6, 1996.
- [AWC 96] AWCOCK, G. J.; THOMAS, R. **Applied image processing**. New York: McGraw-Hill, 1996.
- [BED 84] BEDNAR, J.; WATT, T. Alpha-trimmed means and their relationship to the median filters. **IEEE Transactions on Acoustic, Speech, Signal Processing**, New York, v.32, p.145–153, 1984.
- [BER 2000] BERTOLO, L. **O som na medicina**. [S.l.: s.n.], 2000. Disponível em: <<http://www.lui-bertolo.hpg.com.br/Som/ULTRASOM.htm>>. Acesso em: mar. 2001.
- [BRA 98] BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. Fundamentos de redes neurais artificiais. In: ESCOLA DE COMPUTAÇÃO, 11., 1998, Rio de Janeiro. **Tutorial...** Rio de Janeiro: UFRJ, 1998.
- [BUR 78] BURCKHARDT, C. B. Speckle in ultrasound *b*-mode scans. **IEEE Transactions on Sonics and Ultrasonics**, New York, v.SU-25, n.1, p.1–6, Jan. 1978.
- [BUS 95] BUSSE, L. J.; CRIMMINS, T. R.; FIENUP, J. R. A model based approach to improve the performance of the geometric filtering speckle reduction algorithm. In: ULTRASONICS SYMPOSIUM, 1995. **Proceedings...** Los Alamitos: CA: IEEE Computer Society, 1995. v.2, p.1353–1356.
- [COR 95] CORTEZ, F. et al. A neural network based time series forecasting system. In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1995. **Proceedings...** Los Alamitos: CA: IEEE Computer Society, 1995. p.2689–2693.
- [CRI 85] CRIMMINS, T. R. Geometric filter for speckle reduction. **Applied Optics**, [S.l.], v.24, n.10, p.1438–1443, 1985.
- [DAH 98] DAHMER, A. **Segmentação de imagens ecocardiográficas utilizando redes neurais e medidas de textura**. 1998. 100p. Dissertação (Mestrado em Ciência da Computação) — Instituto de Informática, Universidade federal do Rio Grande do Sul, Porto Alegre.
- [ELB 2000] EL-BAKRY, H. M.; ABO-ELSOU, M. A.; KAMEL, M. S. Automatic face recognition system using neural networks. In: IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS, 2000, Geneva, Switzerland. **Proceedings...** Los Alamitos: CA: IEEE Computer Society, 2000. p.543 – 546.

- [FAC 93] FACON, J. Processamento e análise de imagens. In: ESCUELA BRASILEÑO-ARGENTINA DE INFORMÁTICA, 6., 1993. **Anais...** Cordoba: Ebai, 1993. p.198.
- [FER 2001] FERNANDES, D. **Segmentação de imagens baseada em redes neurais oscilatórias**. 2001. Trabalho Individual (Doutorado em Ciência da Computação) — Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- [FER 95] FERNANDES, L. G. **Utilização de redes neurais na análise e previsão de séries temporais**. 1995. Dissertação (Mestrado em Ciência da Computação) — Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- [FER 86] FERREIRA, A. B. H. **Novo dicionário da língua portuguesa**. 2.ed. Rio de Janeiro/RJ: Nova Fronteira, 1986.
- [FIR 95] FIRPO, C. **Estudo evolutivo do comportamento do septum primum durante a vida intra-uterina e sua relação com a presença de extrasístoles atriais no feto**. 1995. 73p. Dissertação (Mestrado em Medicina: Pediatria) — Instituto de Cardiologia, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- [FIS 2000] FISHER, R. et al. **Crimmins speckle removal**. Edinburgh: University of Edinburgh, Division of Informatics Artificial Intelligence, 2000. Disponível em: <<http://www.dai.ed.ac.uk/HIPR2/crimmins.htm#1>>. Acesso em: mai. 2002.
- [GON 93] GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. Massachusetts: Addison-Wesley, 1993. 716p.
- [GRA 97] GRAHAN, D.; BARRETT, A. **Knowledge-based image processing**. London: Springer-Verlag, 1997. 178p.
- [HAY 2001] HAYKIN, S. **Redes neurais princípios e práticas**. 2.ed. Porto Alegre: Bookman, 2001.
- [JAI 89] JAIN, A. K. **Fundamentals of digital image processing**. Englewood Cliffs, NJ: Prentice Hall, 1989. 569p.
- [JEA 2001] JEANTY, P.; LOPES, L.; BINCHER, A. M. **The Heart**. Nashville: Women's Health Alliance, 2001. Disponível em: <http://www.thefetus.net/sections/articles/Cardiovascular/echo_lopes_files/Introduction%20to%20fetal%20echo.pdf>. Acesso em: jan. 2002.
- [KAN 98] KANZEPOLSKY, L.; BECKER, C. A. **Exploracion ecografica en el primer trimestre del embarazo, primeras 10 semanas**. Buenos Aires: Tocogineconet, 1998. Disponível em: <<http://www.tocogineconet.com.ar/revisiones/ecografia1trimestre.htm>>. Acesso em: fev. 2002.

- [KOH 90] KOHONEN, T. The self-organizing map. **Proceedings of the IEEE**, New York, v.78, n.9, p.1464–1480, Sept. 1990.
- [KON 94] KONSTANTINIDES, K.; RASURE, J. R. The Khoros software development environment for image and signal processing. **IEEE Transactions on Image Processing**, New York, v.3, n.3, p.243–252, May 1994.
- [LIP 87] LIPPMANN, R. P. An introduction to computing with neural nets. **IEEE ASSP Magazine**, New York, Apr. 1987.
- [MAL 96] MALLADI, R.; SETHIAN, J. Image processing: flows under min/max curvature and mean curvature. **Graphical Models and Image Processing**, [S.l.], v.58, n.2, p.127–141, 1996.
- [MAT 99] MATTOS, S. S. **O coração fetal**. Rio de Janeiro/RJ: Revinter, 1999. 268p.
- [MIN 69] MINSKY, M. L.; PAPERT, S. A. **Perceptrons** : an introduction to computational geometry. Cambridge: Mit Press, 1969. 258p.
- [MIX 96] MIX, D. F. **Random signal processing**. Upper Saddle River: Prentice Hall, 1996.
- [MOR 89] MORAES, C. D. **Cálculo numérico computacional: teoria e prática**. São Paulo: Atlas, 1989.
- [MUR 98] MURINO, V. Structured neural networks for pattern recognition. **IEEE Transactions on Systems, Man and Cybernetics**, New York, v.28, p.553–561, 1998.
- [NEL 98] NELSON, T. R. Ultrasound visualization. In: ZELKOWITZ, M. V. (Ed.). **Advances in computers**. New York: Academic Press, 1998. v.47, p.185–253.
- [PHA 2000] PHAN, F.; TZANAKOU, E. M.; SIDEMAN, S. Speaker identification using neural networks and wavelets. **IEEE Engineering in Medicine and Biology Magazine**, New York, v.19, p.91–101, 2000.
- [PIC 99] PICCOLI, L. **Segmentação e classificação de imagens ecocardiográficas utilizando redes neurais**. 1999. Dissertação (Mestrado em Ciência da Computação) — Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- [PIC 99a] PICCOLI, L. et al. Fetal echocardiographic image segmentation using neural networks. In: INTERNATIONAL CONFERENCE IEE ON IMAGE PROCESSING AND APLICATIONS, 1999. **Proceedings...** London: IEE, 1999. v.2, p.507–511.
- [POL 95] POLI, R.; VALLI, G. **Optimum segmentation of medical images with hopfield neural networks**. Birmingham: University of Birmingham : School of Computer Science, 1995. CSRP-95-12.

- [RAS 91] RASURE, J.; WILLIAMS, C. An integrate visual language and software development environment. **Journal of Visual Languages and Computing**, New York, v.2, p.217–246, 1991.
- [SAN 99] SANTANA, J. Pré-processamento de imagens ecocardiográficas. In: SEMANA ACADÊMICA DO PPGC, 4., 1999, Porto Alegre. **Anais...** Porto Alegre: PPGC da UFRGS, 1999. p.259–262.
- [SIL 85] SILVERMAN, N. H.; GOLBUS, M. S. Echocardiographic techniques for assessing normal and abnormal fetal cardiac anatomy. **Journal of the American College of Cardiology**, New York, v.5, n.1, p.20s–29s, 1985.
- [SON 98] SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing, analysis and machine vision**. Pacific Grove: PWS Publishing, 1998.
- [SOU 2000] SOUSA JUNIOR, C. de; HEMERLY, E. M. Neural network-based controllers for mobile robot. In: BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS, 6., 2000. **Proceedings...** Rio de Janeiro: IEEE, 2000. p.50–55.
- [TAK 97] TAKAGI, H. Introduction to fuzzy systems, neural networks, and genetic algorithms. In: RUA, D. (Ed.). **Intelligent hybrid systems: fuzzy logic, neural networks, and genetic algorithms**. Norwell, USA: Kluwer Academic Publishers, 1997. p.3–33.
- [TAT 97] TATANI, S. B. Ecocardiografia fetal. apresentando o método. **Arquivo Brasileiro de Cardiologia**, Porto Alegre, v.69, n.3, p.197–201, 1997.
- [VAR 2000] VARELLA, F.; POLES, C. Check-up - a cura pela prevenção. **Veja**, São Paulo, n.26, jun. 2000.
- [ZHA 99] ZHANG, H.; LIN, F. C. Medical diagnosis by the virtual physician. In: IEEE SYMPOSIUM ON COMPUTER-BASED MEDICAL SYSTEMS, 12., 1999. **Proceedings...** Los Alamitos: CA: IEEE Computer Society, 1999. p.296–302.
- [ZIE 97] ZIELINSKY, P. Malformações cardíacas fetais: diagnóstico e conduta. **Arquivo Brasileiro de Cardiologia**, São Paulo, v.69, p.209–218, dez. 1997.
- [ZIE 97a] ZIELINSKY, P. et al. Estudo da história natural da hipertrofia miocárdica e sua associação com hiperinsulinismo em filhos de mães diabéticas. **Arquivo Brasileiro de Cardiologia**, São Paulo, v.69, n.6, p.389–394, 1997.



Echocardiographic Image Sequence Segmentation and Analysis Using Self-Organizing Maps

MOZART L. SIQUEIRA, JACOB SCHARCANSKI AND PHILIPPE O.A. NAVAUX

Federal University of the Rio Grande do Sul, Porto Alegre, Brazil*

Received April 30, 2001; Revised October 3, 2001; Accepted November 19, 2001

Abstract. This paper presents a new approach for echocardiography image sequence segmentation and a practical application of the results. The proposed method uses the self-organizing map to approximate the probability density function of the image patterns. The map is post-processed, by the k -means clustering algorithm, in order to detect groups of neurons whose weights are similar. Each segmented image of the sequence is generated by correlating its pixels and clusters found in the map. The image sequence segmented was used to measure fetal heart structures. To refine the measurements we used a border detection technique based on the least-means squares error. The segmentation procedure was validated successfully by physicians.

Keywords: echocardiography image sequence, self-organizing map, measurements of the fetal heart, segmentation

1. Introduction

Nowadays, image acquisition systems are used by physicians for the early detection of a number of diseases. Within this context, fetal echocardiography represents an important tool for the detection of congenital fetal heart defects. An impressive number of about 8 to 10 per 1000 babies are born in the south of Brazil with cardiac problems, which could be treated if detected in advance [1]. Images of the fetal heart are acquired by a transducer, freely maneuverable, which maps the heart structure through the ultrasound reflection on the internal structures, and generate a video sequence of the heart movements. Although the ultrasound image reveal many details of the heart structure, non-specialists usually have difficulty in interpreting these information. The segmentation of such images can help the operators to analyze these exams.

Image segmentation is broadly used in a variety of images, e.g. natural images, multi-spectral images and medical images. The segmentation aims at identifying

regions, whose properties are similar according to some criteria. The segmented images are easier to deal with, because they are simplified versions of the originals which preserve their main features. Thus, it is possible to automatically obtain measurements from these segmented images, such as distances, areas and volumes.

In the specific case of echocardiographic image sequences, segmentation can help a non-specialist to detect and diagnose congenital heart defects, and better define important structures that are not easily visible in the original image. Sometimes, based on such analysis, physicians may suspect of specific diseases, and suggest accurate examinations in a pregnant woman. Besides, automatic measurements (e.g. intraventricular septum width, or volume of cavities) can also be used to identify possible fetal diseases.

Although ultrasound images present a lot of information, they are severely contaminated by *speckle* noise [2]. This noise corrupts the borders of anatomical structures, making it difficult to perform the segmentation task. Another problem concerning fetal echocardiography is its non-stationarity—the resulting image depends on the transducer position, on the

*web: <http://www.inf.ufrgs.br/~segime>

fetus position and on the tissue composition between the fetus and the transducer [3].

In order to reduce these problems, some segmentation techniques based on neural networks have been proposed [4–6]. Süßner [4] proposes a backpropagation network, whose inputs are the mean gray value, variance and texture parameters retrieved from the local gray-level co-occurrence matrix (contrast, entropy and homogeneity), for detecting the borders of the left ventricle. A similar network is described by Dahmer [5], where a backpropagation network is used to classify an entire fetal heart image into tissue and cavity. This approach uses the same parameters: mean, variance, contrast, entropy and homogeneity. Similar to Poli and Valli in [6], who proposed a neural architecture based in Hopfield approach to segment medical images in 2D and 3D.

Self-organizing maps (SOM) are successfully used in variety of applications, especially concerning image segmentation [7] and data mining [8]. This paper proposes the use of self-organizing maps [9], post-processed by the *k*-means clustering algorithm, for fetal echocardiographic image segmentation. After the learning phase, a clustering algorithm is used to group neurons whose weights are similar in feature space. Parameters used in [4, 5] are analyzed and the most significant, according to the Bhattacharyya distance [10], are chosen—i.e. mean and variance.

The following section describes the image sequences used in this work, and the most important anatomical structures appearing in them. Section 3 discusses the features that are extracted from these echocardiographic images, showing the most representative ones, and makes considerations about performance and processing time. Section 4 presents the proposed model; the neural network and the clustering phase are explained. Section 5 discusses the performance of the proposed model, comparing it with traditional segmentation methods. Section 6 presents measurement results of intraventricular septum and ventricle width for those sequences. These measurements may indicate the presence of congenital heart problems. Finally, we present some final remarks at Section 7.

2. Echocardiographic Image Sequences

Echocardiography represents a quick and safe way to acquire images from the fetal heart. These images are stored as video, and may be divided in many frames for




Figure 1. Structures present in the four chamber view.

individual processing. Based on these frame sequences, physicians can diagnose different heart diseases. There are different standard views of the fetal heart, and each of them emphasizes some specific structure. Among them, the four chamber view is the most complete. In the four chamber view it is possible to check many structures at the same time and detect almost two thirds of the known congenital heart diseases [11]. Figure 1 is an example of a fetal echocardiography frame in the four chamber view. This figure shows the region of interest, where the heart is placed. It is possible to detect the main structures in this view. These structures are: Left Ventricle (LV); Right Ventricle (RV); Left Atrium (LA); Right Atrium (RA); Tricuspid Valve (TV); Mitral Valve (MV); Moderator Band (MB); Intraventricular Septum (S); and Descending Aorta (DAo).

Some diseases are characterized by the displacement of certain heart structures, or by their abnormal size or shape. For example, the Ebstein's abnormality consists of the displacement of the Tricuspid valve, making the Right Ventricle become smaller. Another common problem is the hypertrophy of the Septum [12].

3. Feature Selection

Feature selection plays an important role in the image analysis. With feature selection techniques it is possible to reduce the dimensionality of the problem, making image analysis more efficient. The selection of features should be based on the separability of the classes. The features that promote higher class separability are the most significant, and should be chosen to segment the image.

There are different methods to evaluate the class separability. One common technique is the Bhattacharyya distance, described by Fukunaga [10]. This distance was designed to measure the total overlap area of two probability functions. The smaller the overlapping area, the higher is the Bhattacharyya distance. Equation 1




Figure 2. (a) Original image; (b) mean; (c) variance; (d) entropy; (e) contrast; (f) homogeneity.

describes the Bhattacharyya distance.

$$B = -\ln \int_{-\infty}^{\infty} \sqrt{p(x/w_1)p(x/w_2)} dx \quad (1)$$

Features previously used to classify blocks and segment echocardiographic images, include the mean gray-level, variance, entropy, contrast and homogeneity [4, 5]. The last three features are extracted from the local gray-level co-occurrence matrix. Figure 2 illustrates these features and their occurrence in an echocardiography.

The separability between the classes was measured for each combination of features. Using only the mean, we achieved 7.673 of separability. Using the variance, the separability was 0.290. Contrast, entropy and homogeneity presented 0.270, 0.211 and 0.189, respectively. This shows that the mean gray value is the most significant feature among the five available. Using two features, i.e. combining mean and variance, we obtained 12.507. On the other hand, combining mean and contrast we obtained 11.741. Using three features, the highest class separability value (i.e. 13.396) was achieved by mean, contrast and entropy. It should be noticed that class separability was increase by 4.834 when using two, instead of one feature; and it was increased only by 0.889 when using three features, instead of two. Table 1 presents these results.

It is clear that class separability is similar for two or for three features, and also that contrast, homogeneity and entropy require the calculation of local gray-level co-occurrence matrices. Therefore, we chose mean and

Table 1. Bhattacharyya inter-class distances for different features.

Feature	Bhattacharyya distance
Mean	7.673
Variance	0.290
Contrast	0.270
Entropy	0.211
Homogeneity	0.189
Mean and variance	12.507
Mean, contrast and entropy	13.396

variance as inputs to train our neural net for echocardiographic image sequence segmentation.

4. Our Proposed Approach

The proposed model uses the self-organizing map (SOM), defined by Kohonen [9], to segment echocardiographic image sequences. This network provides an unsupervised approach to extract patterns from unknown data and organize them in groups, according to their similarities. The similarity criterion adopted by the self-organizing map is the Euclidean distance. Each neuron from the network is able to represent, in a compact way, a set of similar patterns.

The network must be trained to represent the most frequent samples. In order to avoid human interference in the process, the samples are randomly chosen with a sliding window. The user just specifies the number of samples, which must be enough to cover the entire area of interest. The samples are extracted from some images of the sequence, chosen randomly, as Fig. 3 shows.

During the training phase, neurons tend to agglomerate into different groups, according to the probability density function of pattern occurrence, Fig. 4. For this reason, SOM is used for clustering in different applications [8, 13]. Although each neuron in the network can




Figure 3. Process of choosing samples randomly.




Figure 4. Training phase and generation of the clustered map by SOM.

be considered as a center, better results can be achieved by grouping neighboring neurons in the feature space.

For this reason, this paper proposes the application of a clustering method on the trained SOM, in a post-processing phase. The method to detect the clusters is the well known *K*-means algorithm [14]. This method, applied to the SOM, analyses the weights of the neurons, and increases the distances among neurons belonging to the different cluster (inter-cluster distance). Thus, after clustering, the neurons are regrouped into a reduced set of clusters. This set represents significant groups in the map, the Fig. 5 show an example of a trained map post-processed by *K*-means.

The segmentation of each image of the sequence is done after SOM clustering. The neural network detects the representative regions of the images, and identifies such regions on the entire image sequence. A sliding window moves through each image, extracting its features (mean and variance) and passing them to the network. The winner neuron is found and the pixel on the resulting image receives its label. This situation is illustrated in the Fig. 6.




Figure 5. Post-processing phase by *K*-means.




Figure 6. Segmentation process.




Figure 7. Classification of the segmented image. (a) Original image; (b) segmented image.

Physicians are interested in the detection of the cavity and tissue regions in echocardiographic images. So it is necessary to identify which segments correspond to these regions. It is known that cavity regions absorb more ultrasound waves than tissue regions. As result, pixels representing cavity have darker gray levels, whereas pixels representing tissues have brighter gray levels. The regions whose pixels have darker gray levels are considered as cavity, and the others regions are considered tissue. This situation is illustrated in Fig. 7.

However, to classify the image in only two regions using the pixel gray levels may cause loss of important information about the heart structures. The most adequate segmentation depends on the application. For example, to measure the intraventricular septum width, the 2-clusters segmented sequence was considered adequate. However, the images segmented using more clusters are better to visualize some less evident heart structures.

The following section discusses the results obtained by the application of the proposed method to echocardiographies.

5. Sequence Segmentation Experimental Results

The proposed model has been evaluated for echocardiographic image sequence, and compared with the *k*-means method directly applied to each image. The images have been pre-processed through histogram equalization and the median filter. The criterion adopted to compare these techniques is the medical visual evaluation. Figure 8 shows a subset of the images contained in the sequence: Figure 8(a) shows the heart at the instant maximum of systole, when the heart is contracted and both valves are open; Figure 8(b) shows the heart in an intermediate moment between systole and diastole; and Fig. 8(c) shows the heart at the instant




Figure 8. Subset of the sequence used for testing.

maximum diastole, when the heart are expanded and both valves are closed.

Each image of Fig. 8 was segmented with the proposed model-SOM + k -means, and just using the k -means method, based on 2 and 4 clusters. For these tests we used a 20×20 SOM, square neighborhood with Gaussian actualization in SOM training, and a 3×3 kernel for the k -means. Figures 9 and 10 show




Figure 9. Subset of the sequence used for testing SOM + k -means; (a) 2 clusters; (b) 4 clusters.




Figure 10. Subset of the sequence used for testing k -means; (a) 2 clusters; (b) 4 clusters.

the results of the application of the methods SOM + k -means, and just using the k -means, on the images presented in Fig. 8.

Visually, the experimental results show that it is possible to identify correctly the structures present on the echocardiographic images. For a physician, a segmented image should preserve as much as possible the heart structures present in the original, including its thickness. This is necessary because diagnoses uses all structural information available.

The images classified by the proposed model, and by the k -means algorithm directly applied to the image, were similar when segmented using 2 clusters (Figs. 9(a) and 10(a))—the structures detected were the same, valves and intraventricular septum. However, using SOM + k -means, the dimensions of the cavities are closer to the original dimension than just using the k -means algorithm. The precise dimension of cavities is important to obtain useful measurements, as well as the volumes of cavities, and differences of areas between ventricles. A troublesome region for segmentation is the border between the Descending Aorta and the left Ventricle. Both methods do not segmented well this region.

We can observe more clearly the differences between the methods in the images segmented with 4 clusters: images of Fig. 9(b) are clearer than ones of Fig. 10(b)—the cavities are better delimited. Segmenting with 4 clusters shows more heart structures, such as the Descending Aorta and the Moderator Band.

Considering the quality of this kind of image and the complex structure of the heart, the global performance of the proposed method is considered satisfactory. In the resulting images, it is possible to detect defects whether structures are missing or displaced.

An advantage of the proposed approach over other approaches is that the clustering process is done only once. The SOM is trained and then clustered. Thus, to segment the images, it is only required to find the winner neuron for each pixel. In the k -means, and other clustering techniques, for each image all the clustering process is repeated.

6. Measurements of Anatomical Structures Using the Segmented Images

We developed an algorithm to measure semi-automatically the width of the intraventricular septum, as well as the width of the left ventricle cavity, based on the proposed segmentation model. The analysis of




Figure 11. Manual measurements made by an expert: (a) ventricle; (b) intraventricular septum.

the variability of these width measurements indicate the presence of congenital heart defects, like the hypertrophy of the intraventricular septum [12], caused by the existence of diabetes in the mother. These are among the most popular measurements utilized for fetal echocardiographic image analysis.

In general, experts in fetal cardiology measure the septum and/or the ventricle width when the fetal heart is in its maximum diastole. These measurements are often based on the heart position immediately below the mitral valve. A manual ventricle width measurement is shown in Fig. 11(a). The width of the intraventricular septum is shown in Fig. 11(b).

Our algorithm implements the procedure described above, and it is intended to be used as a validation of our segmentation method, as well as to provide physicians with a tool for extracting information from fetal echocardiographies.

Our first results were affected by ventricle internal wall discontinuities, which usually occur in these images. According to physicians, these irregularities,




Figure 12. Results obtained for sequence 1.




Figure 13. Results obtained for sequence 2.




Figure 14. Results obtained for sequence 3.

which are called trabeculations, must not interfere with measurements. The solution adopted to reduce the location error of the ventricle internal walls will be discussed in the subsection 6.1.

Figures 12–14 present the results obtained with three different echocardiographic image sequences. For each sequence, three sample frames are shown. The frames of the first sequence are shown in Fig. 12, which has 14 images in total. The frames of the second and third sequences are shown in Figs. 13 and 14, and have 70 and 60 frames in total, respectively. In each one of those figures, the original frames are presented as the set *a*, and the processed frames, as well as the measurements obtained using our approach, are shown as the set *b*.

For the sake of clarity, the width measurements obtained for the ventricle and intraventricular septum are displayed in gray values, but the images were in fact segmented in two regions, i.e. the cavities are displayed as black and tissue as white.

Au: Fig. 13, 14, 15 and 16 has been renumbered. Pls. check

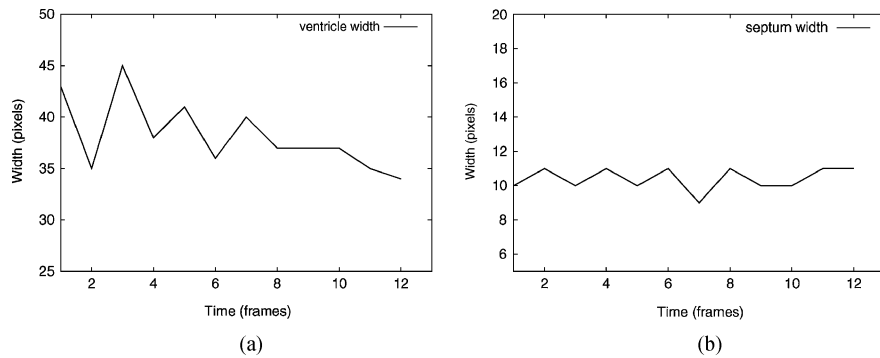


Figure 15. Plots of the results obtained for sequence 1.




Figure 16. Plots of the results obtained for sequence 2.




Figure 17. Plots of the results obtained for sequence 3.

Figures 15–17 show plots of the measured widths of the three sequences, frame-by-frame. In those plots, part *a* shows the ventricle widths, and part *b* shows the measured intraventricular septum widths. We adopted “pixels” as a standard unit for all frame measurements. The axis *x* represent the frame positions in the sequences, and the axis *y* represent the measured width in

each frame. Such information is relevant to physicians, because it allows to evaluate the fetal heart dynamics based on the ventricular and intraventricular septum width variability.

Our method requires little user interaction. The width measurement algorithm starts at a pixel informed by the user, indicating the location of the

Table 2. Evaluation of the measurements for sequence 1.

Image position in the sequence	Septum width (pixels)			Ventricle width (pixels)		
	Expert	Our method	Variation	Expert	Our method	Variation
05	10	10	–	39	43	10.25%
07	8	8	–	40	41	2.43%
09	9	9	–	39	41	5.12%
11	10	9	10%	39	41	5.12%
13	9	9	–	40	41	2.43%
Means	9.2	9	2.17%	39.4	40.6	3.04%

Table 3. Evaluation of the measurements for sequence 2.

Image position in the sequence	Septum width (pixels)			Ventricle width (pixels)		
	Expert	Our method	Variation	Expert	Our method	Variation
02	10	11	10%	41	42	2.43%
04	8	10	25%	44	45	2.27%
06	9	11	22.22%	44	43	2.27%
08	9	11	22.22%	43	40	6.97%
10	9	11	22.22%	43	42	2.32%
Means	9	10.8	20%	43	42.4	1.39%

Table 4. Evaluation of the measurements for sequence 3.

Image position in the sequence	Septum width (pixels)			Ventricle width (pixels)		
	Expert	Our method	Variation	Expert	Our method	Variation
03	9	10	11.11%	44	44	–
04	10	10	–	40	42	5%
08	10	11	10%	41	41	–
09	10	10	–	42	41	2.38%
18	9	9	–	44	43	2.27%
Means	9.6	10	4.16%	42.2	42.2	–

intraventricular border in one particular frame of the sequence. However, it proceeds without user interaction, and estimates the border locations in the other frames of the sequence. This interactive feature was designed to provide a better control and sense of security for the physician operating the system.

Our experimental results have been validated by experts in fetal cardiology. Tables 2–4 present their evaluation (i.e. manual width measurements), as well as the measurement variability and mean width values. It is a common practice to have width measurements obtained from just one image (i.e. frame),

corresponding to one maximum diastole in a sequence. For this work, the physicians have chosen five images with maximum diastole from each sequence, and their manual measurements were compared with the measurements obtained by our technique (i.e. the width measurements are made available for all frames of a sequence, after the user provides initialization). An advantage of our technique over the experts' analysis is the possibility of using the mean measured widths, obtained from selected images in a sequence, which improves measurement precision. These data can also be used to make other important

measurements, such as ventricle volume and cavity area.

Despite of ventricle border irregularities, our segmentation technique has showed reliable results. The difference between experts and our technique is consistent with differences found usually between experts.

6.1. Border Modeling and Tracking Technique

We model the border of a particular region of the image using a curve fitted by a least-means squared error technique. In this case, the least-means squared error estimation helps us to select the curve that best fits the pixels located at the border of the ventricle wall.

Figure 18 shows a set of pixels, corresponding to an irregular part of the wall border. Each pixel is identified by its (x, y) coordinate pair. In order to model that part of border by a curve, and reduce the noise effect on measurements, we use the following second-order model:

$$x = c_0 + c_1y + c_2y^2 \quad (2)$$

where x and y are the border pixel coordinates, and c_0, c_1 and c_2 are the curve model parameters. In order to estimate the curve parameters that minimizes the mean-squared error of the pixel locations with respect to those specified by the curve model (i.e. for each y coordinate, the curve model estimates the x coordinate) the following linear algebraic equation system is resolved:

$$\begin{bmatrix} n & \sum y_i & \sum y_i^2 \\ \sum y_i & \sum y_i^2 & \sum y_i^3 \\ \sum y_i^2 & \sum y_i^3 & \sum y_i^4 \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \\ c_2 \end{bmatrix} = \begin{bmatrix} \sum x_i \\ \sum y_i x_i \\ \sum y_i^2 x_i \end{bmatrix} \quad (3)$$

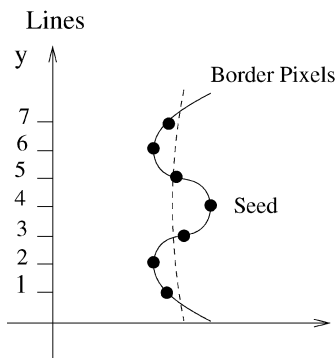


Figure 18. Irregular part of the wall border.




Figure 19. Application of least-means square on the borders.

where n is the number of pixels. To resolve this linear algebraic equation system we used the Gaussian elimination method [15].

The user informs the number of adjacent lines, and a seed point on the septum border, which is central to the border region to be tracked in all frames. The border pixels are fitted by a curve, as described above, and the mean distance to the ventricle border is calculated. The border is tracked in the subsequent frames looking at the set of border pixels that is closest to those found in the previous frame.

Figure 19 shows the local border shape approximation resultant from our technique. Figure 19(b) shows the measurements without modeling the borders, and Fig. 19(c) shows the same image with the boarder adjusted by the least-means squares error technique.

7. Concluding Remarks

This paper proposes a method for segmenting echocardiographic image sequences using the self-organizing map, post-processed by a clustering algorithm. The neural network is used for detecting the most significant regions on the sample patterns extracted randomly from the images.

An analysis on the features suggested by other authors for this kind of image, i.e. mean gray value, variance, entropy, contrast and homogeneity, shows that the last three are not significant enough to be used in the segmentation process. Besides, the quantization of such features requires the computation of the local gray-level co-occurrence matrix, increasing the total processing time.

The results achieved by the proposed method are better than the results of the direct application of a clustering algorithm, like the k -means on the images—the heart structures are correctly located and the cavities dimension are more defined. The good performance of the proposed method shows that the samples acquired by the random sampling have been enough to train the network.

Based on the segmented images, it is possible to check whether the heart structures are present, and if they are in the correct position. Images segmented with the proposed approach are suitable for different measurements. For example, the measurement of the intra-ventricular septum width produced satisfactory results. The experimental results indicate that our proposed method presents a performance comparable to manual measurements made on the same images. In the future, we intend to investigate further if the proposed method can be improved to obtain other measurements of anatomical structures. Also, we plan to investigate if it could be used for color image segmentation, using different features.

Acknowledgments

We would like to thank Dr. Paulo Zielinsky and Dr. Stelamares Luchese (Institute of Cardiology of Rio Grande do Sul, Porto Alegre, Brazil) for their useful comments, and for the image sequences.

References

1. C. Firpo, "Estudo Evolutivo do Comportamento do Septum Primum Durante a Vida Intra-Uterina e Sua Relação Com a Presença de Extra-Sístoles Atriais No Feto," Master' Thesis, CPGMP—Federal University of Rio Grande do Sul, Porto Alegre, Brazil, 1995, pp. 1–73.
2. C.B. Burckhardt, "Speckle in Ultrasound B-Mode Scans," *IEEE Transactions on Sonics and Ultrasonics*, vol. 25, 1978, pp. 1–6.
3. K.L. Reed and J.R. McCurdy, "Basic Technique of Fetal Echocardiography," *Semin Ultrasound CT, MRI*, 1993.
4. M. Süßner, Th. Budil, and G. Porenta, "Segmentation and Edge-Detection of Echocardiograms using Artificial Neuronal Networks," in *Proceedings of International Conference EANN*, 1995.
5. A. Dahmer, "Segmentação de Imagens Ecocardiográficas Utilizando Redes Neurais e Medidas de Textura," Master' Thesis, CPGCC—Federal University of Rio Grande do Sul, Porto Alegre, Brazil, 1998, pp. 1–100.
6. R. Poli and G. Valli, "Optimum Segmentation of Medical Images with Hopfield Neural Networks," Technical Report, School of Computer Science of University of Birmingham, 1995.
7. J. Moreira and L. da F. Costa, "Neural-Based Color Image Segmentation and Classification Using Self-Organizing Maps," in *Proceedings of SIBGRAPI*, Caxambú, Brazil, 1996, pp. 47–54.
8. J. Vesanto, "Data Mining Techniques Based on the Self-Organizing Map," Master's Thesis, Department of Engineering Physics and Mathematics of Helsinki University of Technology, Espoo, Finland, 1997, pp. 1–63.
9. T. Kohonen, "The Self-Organizing Map," in *Proceedings of the IEEE*, New York, USA, 1990, pp. 1464–1480.
10. K. Fukunaga, *Statistical Pattern Recognition*, San Diego, California: Academic Press, 1990.
11. J.C. Huhta and K.M. Rotondo, "Fetal Echocardiography," in *Proceedings of Seminars in Roentgenology*, vol. 26, 1991, pp. 5–11.
12. P. Zielinsky, "Malformações Cardíacas Fetais: Diagnóstico e Conduta," in *Arquivo Brasileiro de Cardiologia*, Porto Alegre, Brazil, 1998.
13. N.W. Campbell, B.T. Thomas, and T. Troscianko, "Segmentation of Natural Images Using Self-Organizing Feature Maps," in *Proceedings of British Machine Vision Conference*, London: British Machine Vision Association, Edinburgh, 1996, pp. 223–232.
14. M. Sonka, V. Hlavac, and R. Boyle, *Image Processing, Analysis and Machine Vision*, Pacific Grove: PWS Publishing, 1998.
15. C.D. Moraes, *Cálculo Numérico Computacional: Teoria e Prática*, São Paulo, Brazil: Atlas, 1989.



Mozart Lemos de Siqueira is Master student on Computer Science in the Informatics Institute at Federal University of Rio Grande do Sul. He received the B.Sc. degree on Computer Science from Lutheran University of Brazil, in 1998. His current research include image processing and neural networks.
mozart@inf.ufrgs.br



Jacob Scharcanski has a Ph.D. degree in Systems Design Engineering (University of Waterloo, 1993), a M.Sc. degree in Computer Science (1984) and a B.Eng. in Electrical Engineering (1981), both from the Federal University of Rio Grande do Sul (Brazil). His main areas of interest are image processing and analysis, information retrieval, pattern recognition and industrial automation. Dr. Scharcanski was a Post-Doctoral Fellow at the Pulp and Paper Centre, University of Toronto, working on simulation of paper forming using neural networks, and on the analysis and interpretation of paper formation. Also, he was a Post-Doctoral Fellow at the Communications Group, Department of Electrical and Computer Engineering, University of Toronto, working on image processing and analysis. Currently, he is an Associate Professor at the Institute of Informatics, Federal University of Rio Grande do Sul, Porto Alegre, RS, Brazil. He authored and co-authored more than 60 publications in Journals and Conferences,

and has led to innovations in paper structural analysis by combination of image analysis and statistical geometry.

jacobs@inf.ufrgs.br



Philippe Olivier Alexandre Navaux is Professor in the Informatics Institute at the Federal University of Rio Grande do Sul. He received

the B.Sc. degree on Engineering from Federal University of Rio Grande do Sul, Brazil, in 1970, the M.S. on Physics from the Federal University of Rio Grande do Sul, Brazil, in 1973, and his Ph.D. on Computer Science from the Ensimag, University of Grenoble, France, in 1979. His current research include computer architecture, performance evaluation, and parallel and distributed processing.

navaux@inf.ufrgs.br

ECHOCARDIOGRAPHIC IMAGE SEQUENCE SEGMENTATION USING SELF-ORGANIZING MAPS

Mozart L. Siqueira ¹; Caroline V. Gasperin ¹; Jacob Scharcanski ¹;
Paulo Zielinsky ² and Philippe O. A. Navaux ¹
Federal University of Rio Grande do Sul ¹
Av. Bento Gonçalves 9500, Porto Alegre, Brazil
Phone: +55 (51) 316 6159, 6168
and Institute of Cardiology of the Rio Grande do Sul ²
Av. Princesa Isabel, 395, Porto Alegre, Brazil
Phone: +55 (51) 230 3600
E-mail: segime@inf.ufrgs.br
Web: <http://www.inf.ufrgs.br/~segime>

Abstract. This paper presents a new approach for echocardiographic image sequence segmentation. The proposed method uses the self-organizing map to approximate the probability density function of the image patterns. The map is post-processed, by the k -means clustering algorithm, in order to detect groups of neurons whose weights are similar. Each segmented image of the sequence is generated by correlation its pixels and cluster found in the map. The best number of clusters is dependent on the application. To validate the segmentation procedure, we used a segmented sequence to measure successfully the variation of the interventricular septum width.

Keywords: Echocardiographic image sequence, segmentation, self-organizing map.

INTRODUCTION

Nowadays, image acquisition systems are used by physicians for the early detection of a set of diseases. Within this context, fetal echocardiography represents an important tool for the detection of congenital fetal heart defects. An impressive number of about 32000 babies are born in the US with cardiac problems, which could be treated if detected previously. Images of the fetal heart are acquired by a transducer, freely maneuverable, which maps the heart structure through the ultrasound reflection on the internal structures, and generate a video sequence of the heart movements. Although the

ultrasound image reveal many details of the heart structure, a non-specialist may not use these information in a correct manner. The segmentation of such images can help the operators to analyse these exams.

Image segmentation is broadly used in a variety of images, e.g. natural images, multi-spectral images and medical images. The segmentation aims at identifying similar regions, whose properties are similar according to some criteria. The segmented images are easier to deal with, because they consist of a simplified version, containing the main properties of the original. Thus, it is possible to automatically get measurements from these segmented images, such as distances, areas and volumes.

In the specific case of echocardiographic image sequences, segmentation can help a non-specialist to detect and diagnose congenital heart defects, or emphasize important structures, not visible in the original image, leading for example to conduct a more accurate examination in a pregnant woman. Besides, automatic measurements (e.g. interventricular septum width, cavities volume) can be used to identify some possible diseases.

Although ultrasound images present many information about the real structure of a body's region, they are severely contaminated by *speckle* noise [1]. This noise corrupts the structure borders, making it difficult for the segmentation task. Another problem concerning fetal echocardiograms is its non-stationarity - the resulting image depends on the transducer position, on the fetus position and on the tissue composition between the fetus and the transducer.

In order to reduce these problems, some segmentation techniques based on neural networks have been proposed [7, 2]. Süßner [7] proposes a back-propagation network, whose inputs are the mean gray value, variance and texture parameters retrieved from the local gray-level co-occurrence matrix (contrast, entropy and homogeneity), for detecting the borders of the left ventricle. A similar network is described by Dahmer [2], where a backpropagation network is used to classify an entire fetal heart image into tissue and cavity. This approach uses the same parameters: mean, variance, contrast, entropy and homogeneity.

Self-organizing maps (SOM) are successfully used in variety of applications, especially concerning image segmentation [6] and data mining [8]. This paper proposes the use of the self-organizing map [5], post-processed by the k -means clustering algorithm, for segmenting fetal echocardiographic images. After the learning phase, a clustering algorithm is used to group neurons whose weights are similar in the feature space. Parameters used in [7, 2] are analyzed and the most significant, according to the Bhattacharyya distance [3], are chosen - i.e. means and variance.

The following section describes the image sequences used, and their main structures. Section 3 discusses the features extracted from the echocardiographic images, showing the most representative ones, considering its performance and processing time. Section 4 presents the proposed model, and also the neural network and the clustering phase are explained. Section 5 discusses the performance of the proposed model, comparing it with traditional

segmentation methods. The section 6 presents the measurement results of the variation of interventricular septum width in the sequence. These measurements can indicate the presence of a congenital heart problem. Finally, the authors present their final remarks at section 7.

ECHOCARDIOGRAPHIC IMAGE SEQUENCES

Echocardiography represents a quick and safe way to acquire images from the fetal heart. These images are stored as video, and may be divided in many frames for individual processing. Based on these frame sequences, physicians can diagnose different heart diseases. There are different standard views of the fetal heart, each of them checks some specific structure. Within this set of views, the four chamber view is the most complete. In the four chamber view it is possible to check many structures at the same time and detect almost two thirds of the known congenital heart diseases [4]. Figure 1 is an example of a fetal echocardiography frame in the four chamber view. This figure shows the region of interest, where the heart is placed. It is possible to detect the main structures in this view. These structures are: Left Ventricle (LV); Right Ventricle (RV); Left Atrium (LA); Right Atrium (RA); Tricuspid Valve (TV); Mitral Valve (MV); Moderator Band (MB); Interventricular Septum (S); and Descending Aorta (DAo).




Figure 1: Structures present in the four chamber view

Some diseases are characterized by the displacement of certain heart structure, or by its abnormal size or shape. For example, the Ebstein's abnormality consists of the displacement of the Tricuspid valve, making the right Ventricle become smaller. Another common problem is the hypertrophy of the Septum.

FEATURE SELECTION

Feature selection plays an important role in the image analysis. With feature selection techniques it is possible to reduce the dimensionality of the problem, resulting a faster processing. The selection of features should be based on the separability of the classes. The features that promote higher class separability are the most significant, and should be chosen to segment the image.

There are different methods to evaluate the class separability. One common technique is the Bhattacharyya distance, described by Fukunaga [3]. This distance is capable to measure the total overlap area of two probability functions. The smaller the area, the higher is the Bhattacharyya distance. Equation 1 describes the Bhattacharyya distance.

$$B = -\ln \int_{-\infty}^{\infty} \sqrt{p(x/w_1)p(x/w_2)} dx \quad (1)$$

Features previously used to classify blocks of echocardiographic images and segment those images, include the mean gray-level, variance, entropy, contrast and homogeneity [7, 2]. The last three are extracted from the local gray-level co-occurrence matrix. Figure 2 illustrates these features showing their occurrence in an echocardiography.




Figure 2: (a) Mean; (b) Variance; (c) Entropy; (d) Contrast; (e) Homogeneity

The separability between the classes is measured for each combination of features. Using only the mean, we achieved 7.673 of separability. Using the variance, the separability was 0.290. Contrast, entropy and homogeneity presented 0.270, 0.211 and 0.189 respectively. This shows that the mean gray value is the most significant feature among the five available. Using two features, combining the mean and variance got 12.507, while combining mean and contrast we obtained 11.741. Using three features, the highest separability is achieved by the mean, contrast and entropy, with 13.396. It is possible to notice that the separability is increase by 4.834 points when using two instead of one feature, and only 0.889 when using three instead of two features.

Considering that the class separability is similar for two and for three features, and that the quantization of the contrast, homogeneity and entropy requires the extra computation of its local gray-level co-occurrence matrix, the mean and the variance are chosen for segmenting the echocardiographic image sequences.

THE PROPOSED APPROACH

The proposed model uses the self-organizing map (SOM), defined by Kohonen [5], to segment echocardiographic image sequences. This network provides an unsupervised approach to extract patterns from unknown data and organize them into groups, according to their similarities. The similarity criteria adopted by the self-organizing map is the Euclidean distance. Each neuron from the network is able to represent, in a compact way, a set of similar patterns.

The network must be trained to represent the most frequent samples. In order to avoid human interference in the process, the samples are randomly chosen. The user just specifies the number of samples, which must be enough to cover the entire area of interest. The samples are extracted from some images of the sequence, chosen randomly.

During the training phase, neurons tend to agglomerate into different groups, according to the probability density function of pattern occurrence. For this reason, SOM is used for clustering in different applications. Although each neuron in the network can be considered itself as a center, better results can be achieved by grouping neighboring neurons in the feature space.

For this reason, this paper proposes the application of a clustering method on the trained SOM, in a post-processing phase. The method to detect the clusters is the well known K -means algorithm. This method, applied to the SOM, analyse the weights of the neurons, and increase the distances among neurons belonging to the different cluster (inter-cluster distance). Thus, after clustering, the neurons are regrouped into a reduced set of clusters. This set represents significant groups in the map.

The segmentation of each image of the sequence is done after SOM clustering. The neural network detects the representative regions of the images, and identifies such regions on the entire image sequence. A sliding window moves through each image, extracting its features (mean and variance) and passing them to the network. The winner neuron is found and the pixel on the resulting image receives its label. This situation is illustrated in the figure 3. In this case, each cluster is identified by a different color and each class by a different letter. Observe that the number of clusters is not same as the number of classes defined by user.

Physicians are interested on the detection of the cavity and tissue regions in echocardiographic images. So it is necessary to identify which segments correspond to these regions. It is known that cavity regions absorb more ultrasound waves than tissue regions. As result, pixels representing cavity have lower gray levels, whereas pixels representing tissues have higher gray levels. The regions whose pixels have lower gray levels are considered as cavity, and the others regions are considered tissue. This situation is illustrated in figure 4.

However, classify the image in only two regions using the pixel gray levels may cause the loss of some important information about the heart structures. The most adequate segmentation depends on the purpose of the segmented

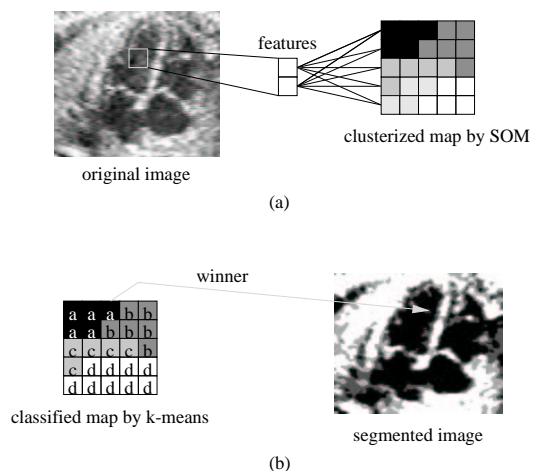


Figure 3: Segmentation process; (a) Training phase and generation of the clustered map by SOM; (b) Post-processing phase by k-means and segmentation




Figure 4: Classification of the segmented image; (a) Original image; (b) Segmented image; (c) Classified image

image sequence application, according to the expert evaluation. For example, to measure the interventricular septum width, the 4-clusters segmented sequence is more appropriated. However, the images segmented using 12-clusters are better to visualize some less evident heart structures.

The following section discusses the results obtained by the application of the proposed method to an echocardiographic image sequence.

EXPERIMENTAL RESULTS

The proposed model has been evaluated for an echocardiographic image sequence, and compared with the k -means method directly applied to each image. The images have been pre-processed through the histogram equalization and the median filter. The criteria adopted to compare these techniques is the medical visual evaluation. Figure 5 shows a subset of the images contained in the sequence: Figure 5(a) shows the heart at the instant maximum of systole, when the heart is contracted and both valves are open; figure 5(b) shows the heart in an intermediate moment between systole and diastole; and

figure 5(c) shows the heart at the instant maximum diastole, when the heart are expanded and both valves are closed.




Figure 5: Subset of the sequence used for testing

Each image of Figure 5 was segmented with the proposed model - SOM + k -means, and just using the k -means method, based on 4 and 12 clusters. Figures 6 and 7 shows the results of the application of the methods SOM+ k -means, and just using the k -means method on the images presented in figure 5.






Figure 6: Subset of the sequence used for testing SOM + k -means; (a) 4 clusters; (b) 12 clusters

Visually, the experimental results show that it is possible to identify correctly the structures present on the echocardiographic images. For a physician, a segmented image should preserve as much as possible the heart structures present in the original, including its thickness. This is necessary because diagnoses uses all structural information available.

The images classified by the proposed model, and k -means algorithm directly applied to the image, were similar when segmented using 4 clusters (figure 6(a) and figure 7(a)) - the structures detected were the same, valves and interventricular septum. However, using the SOM + k -means, the di-



(a)



(b)

Figure 7: Subset of the sequence used for testing k -means; (a) 4 clusters; (c) 12 clusters

mensions of the cavities is closer to the original dimension than using just the k -means algorithm. The precise dimension of cavities is important to obtain useful measurements, as well as the cavities volume and difference between the ventricles. A troublesome region for segmentation is the border between the Descending Aorta and the left Ventricle. Both methods is not segmented correctly this region.

We can observe more clearly the differences between the methods in the images segmented with 12 clusters: images of figure 6(b) are clearer than ones of figure 7(b) - the cavities are better delimited. Segmenting with 12 clusters shows more heart structures, such as the descending aorta and the moderator band.

Considering the quality of this kind of image and the complex structure of the heart, the global performance of the proposed method is considered satisfactory. In the resulting images, it is possible to detect defects whether structures are missing or displaced.

An advantage of the proposed approach over other approaches is that the clustering process is done only once. The SOM is trained and then clustered. Thus, to segment the images, it is only required to find the winner neuron for each pixel. In the k -means, and other clustering techniques, for each image all the clustering process is repeated.

MEASUREMENTS ON THE SEGMENTED IMAGE SEQUENCES

To validate the proposed model, we developed an algorithm to measure the interventricular septum width. The analysis of this measure variability indicates the presence of congenital heart defects, like the hypertrophy of the

septum, caused by the existence of diabetes in the mother.

Each image of the sequence was analysed, and the interventricular septum boundaries were marked in an arbitrary row of the image. Figure 8 shows the mark in the interventricular septum.




Figure 8: Marks in the Interventricular Septum boundaries

The variation of the distance between the initially marked points as time evolved was constant and repetitive, allowing to observe the heart systoles and diastoles. Figure 9 presents the plot of the septum width variation versus time.

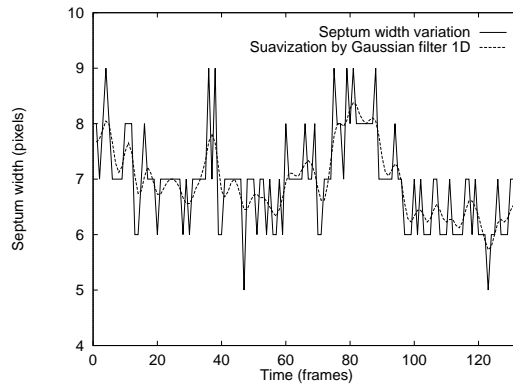


Figure 9: Plot of septum width variation versus time

CONCLUDING REMARKS

This paper proposes a method for segmenting echocardiographic image sequences using the self-organizing map, post-processed by a clustering algorithm. The neural network is used for detecting the most significant regions on the sample patterns extracted randomly from the images. It was used an image sequence of the same patient in order to evaluate the performance of the proposed method.

An analysis on the features suggested by other authors for this kind of image, i.e. mean gray value, variance, entropy, contrast and homogeneity, shows that the last three are not significant enough to be used in the segmentation process. Besides, the quantization of such features requires the computation of the local gray-level co-occurrence matrix, increasing the total processing time.

The results achieved by the proposed method are better than the results of the direct application of a clustering algorithm, like the k -means on the images - the heart structures are correctly located and the cavities dimension are more defined. The good performance of the proposed method shows that the samples acquired by the random sampling have been enough to train the network.

Based on the segmented images, it is possible to check whether the heart structures are present, and if they are in the correct position. Images segmented with the proposed approach are suitable for different measurements. For example, the measurement of the variation of interventricular septum width produced satisfactory values. In the future, we intend to investigate further if the proposed method also can be used for segmenting other type of images, with different features, such as color images.

REFERENCES

- [1] C. B. Burckhardt, "Speckle in Ultrasound B -Mode Scans," **IEEE Transactions on Sonics and Ultrasonics**, vol. SU-25, no. 1, pp. 1–6, Jan. 1978.
- [2] A. Dahmer, **Segmentação de Imagens Ecocardiográficas Utilizando Redes Neurais e Medidas de Textura**, Master's thesis, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1998.
- [3] K. Fukunaga, **Statistical Pattern Recognition**, Academic Press, 2nd edn., 1990.
- [4] J. C. Huhta and K. M. Rotondo, "Fetal Echocardiography," in **Seminars in Roentgenology**, 1991, vol. 26, pp. 5–11.
- [5] T. Kohonen, "The Self-Organizing Map," **Proceedings of the IEEE**, vol. 78, no. 9, pp. 1464–1480, Sept. 1990.
- [6] J. Moreira and L. da F. Costa, "Neural-Based Color Image Segmentation and Classification Using Self-Organizing Maps," in **SIBGRAPI**, Caxambú, MG: Caxambú: SBC, 1996, pp. 47–54.
- [7] M. Süßner, T. Budil and G. Porenta, "Segmentation and Edge-Detection of Echocardiograms using Artificial Neuronal Networks," in **International Conference EANN**, [S.l.:s.n], 1995.
- [8] J. Vesanto, **Data Mining Techniques Based on the Self-Organizing Map**, Master's thesis, Helsinki University of Technology, Espoo, Finland, 1997.

Uso de Mapas Auto-organizáveis de Kohonen na Segmentação do Átrio Esquerdo Fetal para Medir o Índice de Redundância do *Septum Primum*

Mozart Siqueira* Guilherme Drehmer† Philippe Navaux‡
Universidade Federal do Rio Grande do Sul - Instituto de Informática
Av. Bento Gonçalves 9500 - Bloco IV, Agronomia
Cep: 91.501-970 - Porto Alegre/RS - Brasil
E-mail: segime@inf.ufrgs.br
Web: <http://www.inf.ufrgs.br/~segime>

Abstract

The practice of ultra-sound techniques in fetal heart provides an opportunity to analyse both anatomical and blood dynamics, making possible the study of the cardiac physiology during fetal life. Among several measures used to diagnosis, we can highlight some obtained manually: the redundancy index of the septum primum that is associate with premature atrial contractions and the thickness of septum interventricular that can indicate the presence of miocardic hipertrophy in the fetus. From images of fetal echocardiography exams, we use the self-organizing maps of Kohonen to segment and afterwards obtain measures that can help the physicians in the analysis of several congenital cardiopatias.

1 Introdução

Segundo estimativas, o coração é o órgão mais afetado por doenças congênitas [5] sendo essa a terceira causa específica de mortalidade infantil no Rio Grande do Sul, a incidência na população é de 8 a 10/1000 [2]. Embora seja um método relativamente recente, fica claro que a ecocardiografia abriu as portas a uma infinidade de novos caminhos que podem beneficiar o feto, ajudando na compreensão de diversos aspectos anatômicos, funcionais e de progressão das cardiopatias congênitas, levando provavelmente a melhores resultados no acompanhamento clínico neonatal.

O forame oval é uma importante comunicação entre os dois lados do coração, durante a vida intra-uterina. Esta estrutura permite a passagem do fluxo sanguíneo para

o ventrículo esquerdo, promovendo o seu adequado desenvolvimento. A restrição ao fluxo através do forame oval constitui-se em grave distúrbio da circulação pré-natal, com seqüelas potenciais na vida pós-natal. Assim, uma avaliação completa do fluxo sanguíneo interatrial é essencial em fetos de alto risco. Uma maneira de avaliar o fluxo de sangue pelo forame oval é através da medida do índice de redundância do SP (*Septum Primum*) [2] obtida no exame de ecocardiografia fetal.

Embora imagens de ultra-som sejam extremamente ruidosas, o processo de obtenção da medida é realizado sem qualquer tipo de pré-processamento, sendo que são calculadas em um processo interativo onde o médico indica os pontos de interesse através de um ponteiro no vídeo do ecocardiograma, um exemplo pode ser observado na Figura 1, onde os pontos de interesse são marcados com sinais “+” e “x” e as medidas encontram-se na parte inferior esquerda da imagem.

Na tentativa de obter resultados com precisão igual ou superior aos obtidos manualmente pelos especialistas, as imagens foram segmentadas pelos mapas auto-organizáveis de Kohonen [3] e a partir dos resultados da segmentação foram realizadas medidas.

2 Imagens Ecocardiográficas e medidas

A ecocardiografia possibilita o estudo direto do desenvolvimento do coração humano. Esse método de diagnóstico não-invasivo fornece informações em tempo real sobre a anatomia do corpo humano. Uma das áreas da medicina onde este exame tem produzido ótimos resultados em diagnósticos é na cardiologia fetal, pois é um método absolutamente seguro para o feto e permite fazer diagnóstico pré-natal na maioria das cardiopatias congênitas. Através da ecocardiografia fetal é possível visualizar estruturas que medem apenas alguns milímetros, é

*Mestrando em Computação

†Bolsista de Iniciação Científica

‡Professor Titular

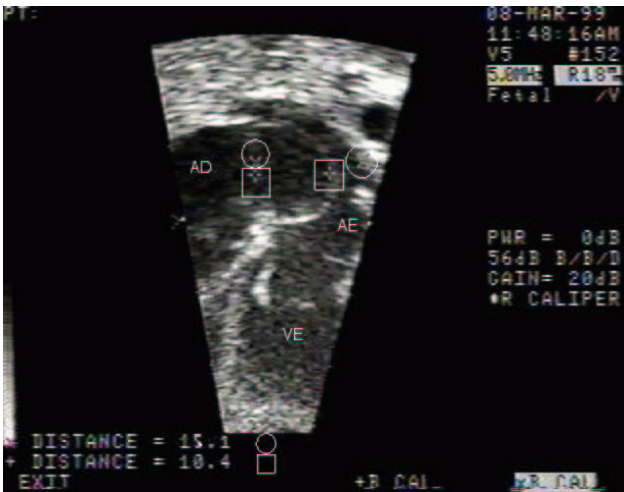


Figura 1. Imagem ecocardiográfica fetal utilizada para medir o índice de redundância do SP: AD: átrio direito, AE: átrio esquerdo, VE: ventrículo esquerdo, X: marcas apontadas pelo operador para medir o diâmetro do átrio esquerdo, +: marcas apontadas pelo operador para medir a extensão do SP

o caso do septo interventricular e do septo interatrial.

O transdutor, dispositivo do aparelho ecocardiógrafo que emite e capta as ondas de ultra-som, é colocado sobre o umbigo materno. Esta é a posição onde normalmente os especialistas iniciam a captura das imagens. O exame gera uma sequência de imagens corrompida por ruído. A baixa qualidade se deve a diversos fatores - a posição do feto, a idade do feto, gordura e estrias abdominais da mãe, qualidade do equipamento, entre outros [5].

O corte quatro câmaras é uma projeção comum obtida em ecocardiografias fetais que permite a identificação de muitas estruturas cardíacas. Um dos primeiros diagnósticos nessa projeção é a proporcionalidade do tamanho das câmaras cardíacas.

A anatomia do septo interatrial do feto propicia o direcionamento de parte do sangue com conteúdo de oxigênio relativamente alto para o átrio esquerdo através do forame oval [2]. Após o nascimento o átrio esquerdo passa a ter uma pressão um pouco mais elevada que o direito, ocasionando o fechamento funcional do forame oval que passa a ser uma depressão do septo interatrial denominada fossa oval.

A separação dos átrios inicia-se com o aparecimento do *septum primum*, uma fina membrana conhecida como membrana do forame oval. Posteriormente desenvolve-se o *septum secundum*, paralelo e à direita do *septum primum*, cobre parcialmente o seu orifício, denominado forame oval, veja




Figura 2. Corte esquemático do coração fetal. SIV: septo interventricular, fo: forame oval, 1: SP, 2: “septum secundum”, AD: átrio direito, AE: átrio esquerdo, VT: válvula tricúspede, VM: válvula mitral, VD: ventrículo direito e VE: ventrículo esquerdo

a Figura 2. Durante a vida fetal o *septum primum* funciona como uma válvula para fechar o forame oval na contração dos átrios, sendo que na diástole ele expande-se para dentro do átrio esquerdo. O índice de redundância do *septum primum* é a razão entre a medida da máxima excursão do *septum primum* para o interior do átrio esquerdo e a medida do máximo diâmetro do átrio esquerdo, ambas durante a diástole [2]. Um índice de redundância superior a “0,67” representa um fator de risco potencial para o aparecimento de problemas cardíacos [8].

3 Mapas Auto-Organizáveis de Kohonen

O mapa auto-organizável (SOM - self-organizing map) de Kohonen é conhecido pelo treinamento não-supervisionado, onde não é necessário o conhecimento prévio sobre as classes que serão apresentadas a rede, sendo assim é capaz de se auto-organizar e reconhecer padrões automaticamente. Devido a essa característica é um método bastante usado no processamento de imagens de baixa definição onde algoritmos tradicionais apresentam dificuldades em reconhecer bordas.

A partir da amostragem de características dos dados de interesse o algoritmo consiste em transformar um conjunto de entrada de dados n-dimensional em uma saída, o mapa, que melhor represente esta entrada a partir da análise de amostragem. A rede possui uma camada de neurônios os quais estão conectados em todos os n componentes da entrada, conforme Figura 3. Os neurônios são comparados com os n componentes da entrada e através de critérios de similaridade um dos neurônios é eleito o vencedor. A partir

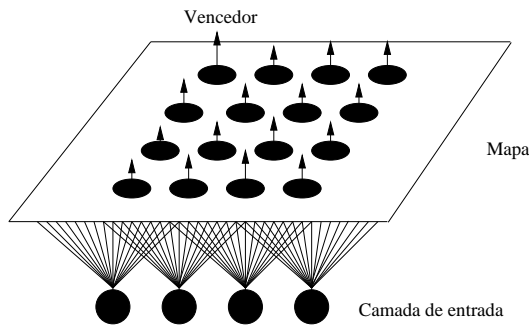


Figura 3. Arquitetura da rede de Kohonen

do vencedor é realizada a atualização dos neurônios vizinhos, esta resulta no aumento da similaridade do neurônio vencedor e seu vizinhos com a amostragem.

O resultado apresentado pela rede é um mapa topológico com agrupamentos ou *clusters* de nodos que correspondem a padrões de entrada semelhantes. Em algumas aplicações é necessário rotular os nodos de saída para indicar as classes que representam. Isto permite que sejam classificados os padrões desconhecidos.

O algoritmo de Kohonen segue as seguintes etapas [7]:

- Encontre a unidade mais semelhante à unidade de treinamento;
- Aumente a similaridade dessa unidade, e das unidades pertencentes à vizinhança, com a entrada.

A rede SOM funciona para agrupar padrões, sendo necessário a utilização de outro algoritmo para a tarefa de reconhecimento de padrões, por exemplo o *K-means* [6]. Esse algoritmo recebe como entrada a saída gerada pelo SOM.

4 Modelo e Resultados

Uma das etapas importantes na análise de imagens é identificar e isolar o objeto de estudo através de um processo conhecido por segmentação. A segmentação consiste em agrupar partes da imagem com características semelhantes [7].

As imagens ecocardiográficas fetais de interesse foram segmentadas em duas regiões, cavidade e tecido, conforme a Figura 4(b). A imagem binária facilita a extração das medidas porque realça as bordas das estruturas. O resultado é uma espécie de resumo da imagem, o que simplifica a análise.

Para obter as medidas, a primeira etapa do processo foi a aquisição das imagens, realizada no Instituto de Cardiologia do Rio Grande do Sul, pela equipe de cardiologia fetal.




Figura 4. (a) imagem original (b) imagem segmentada (c) medidas obtidas

Após a seleção das imagens de interesse, essas foram filtradas para a extração do ruído Speckle [1], característico de imagens de ultra-som.

As entradas utilizadas no treinamento da rede foram amostras da média da intensidade dos níveis de cinza extraídas aleatoriamente de um conjunto representativo das imagens.

Para o processamento da rede utilizou-se um mapa de Kohonen com dimensão 20x20 com inicialização randômica, vizinhança hexagonal de raio 2, função Gaussiana de atualização da vizinhança com taxa de aprendizado decrescendo de 0,9 até 0,1.

O algoritmo *K-means* foi empregado na classificação das regiões do mapa. Através dele é possível definir o número de classes em que se deseja dividir a imagem, resultando na segmentação.

A partir da imagem segmentada realizou-se as medidas das estruturas necessárias para a obtenção do índice de redundância da membrana do forame oval. Implementou-se um algoritmo que percorre a imagem segmentada em busca das bordas dessas estruturas. Estas bordas são reconhecidas pela mudança abrupta da intensidade de cinza.

A Figura 4(c) mostra os resultados obtidos com as medidas. Para melhor visualização foram traçadas três linhas verticais e uma horizontal sobre a imagem, sendo que os pontos encontrados pelo algoritmo são aqueles onde as lin-

Tabela 1. Comparação entre as medidas obtidas pelo especialista e protótipo

Medidas	médico	protótipo
Extensão máxima do SP (mm)	10,1	10,25
Diâmetro do átrio esquerdo (mm)	15,1	15,39
Índice de reundância do SP	0,6688	0,6660

has verticais cruzam a horizontal. Embora este protótipo não seja totalmente automático, devido a necessidade de apresentar o ponto inicial, as medidas foram similares aquelas obtidas manualmente pelos especialistas, a comparação é apresentada na Tabela 1.

Os resultados apresentados na tabela mostram que as medidas obtidas pelo algoritmo comparadas com as medidas pelo médico possuem uma diferença que não excede 2%. Esses resultados são bastante bons considerando que as medidas dos próprios médicos possuem um grau de incerteza.

O protótipo está sendo implementado no ambiente Khoros 2.2 [4], desenvolvido para processamento de imagens o qual disponibiliza uma série de rotinas básicas tais como filtros, conversões, transformadas, operações sobre histograma entre outras.

5 Conclusões

Baseado em estudos preliminares foram encontradas diversas medidas em estruturas cardíacas fetais que podem ser obtidas automaticamente a partir das imagens segmentadas pelo SOM. Essas medidas poderiam ser usadas para auxiliar os especialistas na análise dos exames.

É importante salientar que a utilização de filtros para a extração do ruído das imagens melhorou os resultados da segmentação. Visto que as imagens são bastante corrompidas por ruído, para obter medidas confiáveis, esse pré-processamento é necessário.

Embora elimine algumas estruturas cardíacas da imagem, a segmentação das ecocardiografias fetais em duas regiões mostrou-se suficiente na obtenção das medidas de interesse.

Os resultados atingidos nos testes experimentais foram bons visto que as medidas variaram pouco em relação àquelas obtidas pelos médicos especialistas.

O bom desempenho do método mostra que as amostras adquiridas aleatoriamente foram suficientes para treinar a rede.

Um importante fator na obtenção de melhores resultados na segmentação das imagens é a qualidade dos dados obtidos na aquisição. Atualmente esta é feita de maneira

precária, pois os exames são gravados inicialmente em uma fita VHS para depois serem digitalizados, muita informação é perdida neste processo. Atualmente esta sendo providenciado um sistema de aquisição digital.

Agradecimentos

Agradecemos pelo apoio e auxílio os professores Jacob Scharcanski e Sílvia Delgado Olabariaga do Instituto de Informática e o Instituto de Cardiologia do Rio Grande do Sul através dos médicos Stelamares Luchese e Paulo Zielinsky e sua equipe.

Referências

- [1] C. B. Burckhardt, "Speckle in Ultrasound *B*-Mode Scans," **IEEE Transactions on Sonics and Ultrasonics**, vol. SU-25, no. 1, pp. 1–6, Jan. 1978.
- [2] C. Firpo, **Estudo evolutivo do comportamento do septum primum durante a vida intra-uterina e sua relação com a presença de extra-sístoles atriais no feto**, Master's thesis, Ufrgs - Faculdade de medicina, Porto Alegre, 1995.
- [3] T. Kohonen, "The Self-Organizing Map," **Proceedings of the IEEE**, vol. 78, no. 9, pp. 1464–1480, Sept. 1990.
- [4] J. Rasure. and C. Williams, "An Integrate visual Language and Software Development Environment," in **Visual Languages and Computing**, [S.l.:s.n], 1991, pp. 217–246.
- [5] K. L. Reed and J. McCurdy, **Basic technique of fetal echocardiography. Semin Ultrasound CT, MRI**, 1993.
- [6] J. Richards, **Remote Sensing Digital Image Analysis**, Springer-Verlag, 2nd edn., 1993.
- [7] M. Sonka, V. Hlavac and R. Boyle, **Image processing, analysis and machine vision**, Pacific Grove: PWS Publishing, 1998.
- [8] P. Zielinsky et al., "Estudo da história natural da hipertrofia miocárdica e sua associação com hiperinsulinismo em filhos de mães diabéticas," **Arquivo Brasileiro de Cardiologia**, vol. 69 (6), pp. 389 – 394, 1997.

Segmentação de Sequências de Imagens Ecocardiográficas Utilizando Redes Neurais

Mozart L.Siqueira¹
Jacob Scharcanski³

Caroline V.Gasperin²
Philippe O.A. Navaux³

Universidade Federal do Rio Grande do Sul
Instituto de Informática
Av. Bento Gonçalves, 9500
Bloco IV, Agronomia
Porto Alegre - RS - Brazil
e-mail: segime@inf.ufrgs.br
Homepage: <http://www.inf.ufrgs.br/~segime>

Resumo

Este artigo apresenta uma nova abordagem para segmentação de sequências de imagens ecocardiográficas. O método proposto utiliza um mapa auto-organizável para aproximar a função densidade de probabilidade dos padrões da imagem. O mapa é pós-processado pelo algoritmo de clusterização *k-means*, para detectar grupos de neurônios cujos pesos sejam similares. Cada imagem segmentada da sequência é gerada pela análise de cada pixel e determinação do cluster correspondente no mapa. Tendo-se todas as imagens da sequência segmentadas, é gerada uma animação segmentada do coração, facilitando a detecção de cardiopatias congênitas. Para validação da segmentação, utilizou-se uma sequência segmentada em 4, 8 e 12 clusters.

Introdução

A crescente tecnologia de sistemas para aquisição de imagens permite aos médicos obter imagens internas mais precisas do corpo humano, possibilitando a detecção prévia de um conjunto de doenças. Desde a descoberta do raio-X e o uso do ultra-som na medicina, diferentes métodos para aquisição de imagens médicas tem sido estudados. Embora alguns métodos gerem imagens bem definidas, muitos deles requerem a injeção de substâncias no corpo (por exemplo medicina nuclear). Estes métodos são classificados como invasivos. Em alguns casos, o uso de métodos invasivos pode causar dano à saúde do paciente. Métodos não-invasivos são fortemente recomendados para casos em que a saúde deve ser mantida, como por exemplo quando é examinado o desenvolvimento de um feto.

¹ Mestrando da Universidade Federal do Rio Grande do Sul

² Pesquisadora da Universidade Federal do Rio Grande do Sul

³ Professor da Universidade Federal do Rio Grande do Sul
SEGIME – Projeto de Segmentação de IMagens MÉdicas

Neste contexto, a ecocardiografia fetal representa uma ferramenta importante para detecção de defeitos fetais congênitos do coração. O desenvolvimento anormal do coração, resultando em um defeito com o qual a criança nasce, é denominado cardiopatia congênita [ABD99]. A incidência de malformações congênitas varia de 2 a 2,5 % do total de nascimentos. Dentre as malformações, um terço é representado pelas cardiopatias congênitas (CC), que são responsáveis por 50% do total de óbitos por malformações. A maioria dos óbitos decorrente de CC ocorre intra-útero ou no período neonatal, os quais poderiam ser tratados se detectados anteriormente [SAD97]. Imagens do coração do feto são adquiridas por um transdutor, manuseado livremente, que mapeia a estrutura do coração através da reflexão do ultra-som nas estruturas internas, e gera uma seqüência de vídeo dos movimentos do coração. Embora as seqüências de imagens de ultra-som revelem muitos detalhes do coração, um profissional não-especialista pode não usar estas informações de maneira correta. A segmentação de tais imagens pode ajudar os operadores a melhor analisar estes exames.

A segmentação de imagens é largamente utilizada em uma variedade de imagens, por exemplo imagens naturais, imagens multi-espectrais e imagens médicas. A segmentação é a divisão da imagem em sub-regiões coerentes [NEY93]. As imagens segmentadas são mais facilmente manipuladas, pois consistem de uma versão simplificada, contendo as propriedades principais da imagem original. Assim, é possível obter-se medidas automáticas das imagens resultantes, como distâncias, áreas e volumes.

Considerando-se seqüências de imagens ecocardiográficas, a segmentação pode ajudar um não-especialista a detectar e diagnosticar defeitos congênitos. A segmentação pode enfatizar estruturas importantes, não visíveis na imagem original, possibilitando um exame mais preciso. Além disso, medidas automáticas (por exemplo largura do septo interventricular, volume das cavidades) podem ser utilizadas para identificar algumas doenças possíveis.

Embora imagens de ultra-som apresentem muitas informações sobre as estruturas de uma região do corpo, estas são contaminadas pelo ruído *speckle* [BUR78]. Este ruído corrompe as bordas das estruturas, dificultando a segmentação. Outro problema envolvendo ecocardiogramas fetais é a sua não-estacionariedade - a seqüência de imagens resultante depende da posição do transdutor, da posição do feto, e da composição do tecido entre o feto e o transdutor.

A fim de absorver este problema, algumas técnicas baseadas em redes neurais tem sido propostas [SUS95, DAH98]. Süssner [SUS95] propõem uma rede backpropagation, cujas entradas são o valor médio de tons de cinza, variância, e parâmetros de textura recuperados através da matriz de co-ocorrência dos níveis de cinza (contraste, entropia e homogeneidade), para detecção das bordas endocardiais do ventrículo esquerdo. Uma rede análoga descrita por Dahmer [DAH98], em que uma rede backpropagation foi usada para classificar uma imagem completa do coração fetal em cavidade e tecido. Esta abordagem utiliza os mesmos parâmetros: média, variância, contraste, entropia e homogeneidade.

Este trabalho propõe o uso de um mapa auto-organizável [KOH90], pós-processado pelo algoritmo de clusterização *k-means*, para segmentação de seqüências de imagens ecocardiográficas fetais. Mapas auto-organizáveis (SOM) são utilizados com sucesso em várias aplicações, especialmente para segmentação de imagens [MOR96] e mineração de dados [VES97]. Após a fase de treinamento do mapa, o algoritmo de clusterização é usado para agrupar neurônios com pesos similares no espaço de características. Os parâmetros

usados em [SUS95, DAH98] foram analisados e os mais significativos, de acordo com a distância de Bhattacharyya [FUK90], foram escolhidos - média e variância.

A seção seguinte detalha as seqüências de imagens utilizadas, apresentando as estruturas do coração. A seção 3 apresenta o método proposto, a rede neural e a fase de clusterização. A seção 4 mostra o desempenho do método proposto, comparando-o com métodos de segmentação tradicionais. Finalmente, os autores expõem as conclusões na seção 5.

2 Seqüências de Imagens Ecocardiográficas

Ecocardiografias representam uma maneira rápida e segura para adquirir imagens do coração do feto. Estas são imagens dinâmicas armazenadas como vídeos, que podem ser divididas em vários frames para processamento individual. Baseados nestas seqüência de frames, os médicos podem diagnosticar muitas doenças do coração. Há diferentes visões padrão do coração fetal, cada uma com com propósito de checar alguma estrutura específica. Dentro deste conjunto de visões ou cortes, o quatro-câmaras é o mais completo. No corte quatro-câmaras é possível verificar várias estruturas ao mesmo tempo e detectar quase dois terços das doenças cardíacas congênitas conhecidas [HUH91]. A Figura 1 é um exemplo de um frame (imagem) de uma seqüência ecocardiográfica fetal no corte quatro-câmaras. Esta figura mostra a região de interesse, onde está localizado o coração. Dentre as estruturas presentes, pode-se citar: Ventrículo Esquerdo (VE); Ventrículo Direito (VD); Átrio Esquerdo (AE); Átrio Direito (AD); Válvula Tricúspide (VT); Válvula Mitral (VM); Banda Moderadora (BM); Septo Interventricular (S); e Aorta Descendente (AoD).




Figura 1 - Estruturas cardíacas presentes no corte quatro-câmaras

Algumas doenças são caracterizadas pelo deslocamento ou pelo tamanho ou forma anormais de certas estruturas do coração. Por exemplo, a anomalia de Ebstein consiste no deslocamento da válvula Tricúspide, tornando o ventrículo direito menor. Outro problema é a hipertrofia do Septo, causada normalmente pela presença de diabetes na mãe [ZIE 97]. Essas cardiopatias congênitas podem ser detectadas através de medidas automáticas que devem ser conseguidas através das imagens segmentadas.

3 Modelo Proposto

O modelo proposto utiliza um mapa auto-organizável, definido por Kohonen [KOH90], para segmentar seqüências de imagens ecocardiográficas. Esta rede neural provê uma maneira não-supervisionada de extrair padrões de dados desconhecidos e organizá-los em grupos, de acordo com suas similaridades. O critério de similaridade adotado pelo mapa auto-organizável é a distância Euclidiana. Cada neurônio da rede é capaz de representar, de uma forma reduzida, um conjunto de padrões similares.

Uma análise, baseada na distância de Bhattacharyya [FUK90], mostrou que as características de média e variância são suficientemente significativas para serem usadas no processo de segmentação proposto. Descartando o uso das características de textura - entropia, contraste e homogeneidade, utilizadas no processamento deste tipo de imagem, pois a quantificação de tais características requer a computação da matriz de co-ocorrência dos níveis de cinza, aumentando o tempo total de processamento.

A rede deve ser treinada para representar as amostras mais freqüentes. A fim de evitar interferência humana no processo, as amostras são adquiridas aleatoriamente. O operador apenas especifica o número de amostras, que deve ser suficiente para cobrir toda a área de interesse. As amostras são extraídas de algumas imagens da seqüência escolhidas aleatoriamente.

Durante a fase de treinamento, os neurônios tendem a se aglomerar em diferentes grupos, de acordo com a função densidade de probabilidade dos padrões. Por isso, o SOM é usado para clusterização em diferentes aplicações. Embora cada neurônio na rede possa ser considerado como um centróide, melhores resultados são atingidos pelo agrupamento dos neurônios vizinhos no espaço de características.

Por esta razão, este artigo propõe a aplicação de um método de clusterização sobre o SOM, em uma fase de pós-processamento, após o treinamento. O método para detectar os clusters é o difundido algoritmo *k-means*. Este método, quando aplicado ao SOM, analisa os pesos dos neurônios e reduz as distâncias entre os neurônios de um mesmo cluster.

A segmentação efetiva de cada imagem da seqüência é feita após a clusterização do mapa. Espera-se que a rede neural detecte as regiões representativas da imagem, e seja capaz de detectá-las em toda a imagem. Uma janela deslizante se move através da imagem, extraindo suas características (média e variância) e passando-os para a rede. O neurônio vencedor é encontrado e o pixel na imagem resultante recebe seu rótulo. Esta situação é ilustrada na Figura 2. Neste caso, cada cluster é identificado por uma cor diferente.




Figura 2 - Processo de segmentação usando o mapa auto-organizável pós-processado

Para seqüências de imagens ecocardiográficas, os médicos estão interessados na detecção de regiões de cavidade e tecido. Para isso, é necessário identificar quais segmentos correspondem a estes componentes. É sabido que as regiões de cavidade absorvem mais ondas de ultra-som que as regiões de tecido. Sendo assim, os pixels que representam cavidade tem nível de cinza mais baixo, enquanto que os pixels que representam tecido tem nível de cinza mais alto. As regiões cujos pixels tem níveis de cinza baixos são consideradas cavidades, enquanto as demais regiões são consideradas tecido. Esta situação é ilustrada na Figura 3.




Figura 3 - Classificação da imagem segmentada - (a) Imagem original; (b) Imagem segmentada; (c) Imagem classificada

No entanto, classificar a imagem em apenas duas regiões baseado nos níveis de cinza dos pixels pode causar a perda de algumas informações importantes sobre as estruturas cardíacas. Assim, a análise médica é feita sobre a imagem segmentada (Figura 3(b)). De acordo com avaliação de especialistas, o número mais adequado de clusters, na segmentação, depende do propósito da aplicação da seqüência segmentada. Por exemplo, para medir a largura do septo interventricular, a seqüência segmentada em 4 clusters é mais apropriada, enquanto a com 12 clusters é melhor para visualização de estruturas do coração menos evidentes. Isto é possível analisar a partir da Figura 5 (a) e (c), onde nota-se que a imagem com 12 clusters (c) apresenta mais detalhe, enquanto a que foi segmentada em 4 clusters simplifica a imagem de maneira que só as regiões mais evidentes são notadas, é o caso do septo interventricular.

A seção seguinte discute sobre os resultados obtidos pela aplicação do método proposto sobre uma seqüência de imagens ecocardiográficas de um mesmo coração.

4 Resultados

O método proposto foi avaliado para uma seqüência de imagens ecocardiográficas, e comparado com o método k-means aplicado diretamente sobre a imagem. Cada imagem da seqüência foi pré-processada através da equalização de histograma e do filtro da mediana. O critério adotado para comparar estas técnicas é a avaliação visual do especialista. A figura 4 mostra um subconjunto das imagens contidas na seqüência: a figura 4 (a) mostra o coração no ponto máximo da sístole, quando o órgão está contraído e ambas as válvulas estão abertas; a figura 4 (b) mostra o coração em um momento intermediário entre a sístole e a diástole; e a figura 4 (c) mostra o coração no ponto máximo da diástole, quando o órgão está expandido e ambas as válvulas estão fechadas.




Figura 4 - Subconjunto da sequência utilizada para testes

Cada imagem da Figura 4 foi segmentada pelo o método proposto - SOM + *k-means*, e pelo o método *k-means*, com 4, 8, e 12 clusters. As figuras 5 e 6 mostram os resultados da aplicação dos métodos SOM + *k-means* e *k-means*, respectivamente, sobre as imagens apresentadas na figura 4.

Visualmente, segundo avaliação médica, os resultados do método proposto mostram que é possível identificar corretamente as estruturas presentes nas imagens ecocardiográficas. Para um médico, a sequência segmentada deve preservar o máximo possível das estruturas cardíacas presentes na sequência original, incluindo sua espessura. Isto é necessário devido ao diagnóstico utilizar todas as informações estruturais disponíveis.

As imagens classificadas pelo método proposto pelo algoritmo *k-means* aplicado diretamente sobre a imagem foram semelhantes quando segmentadas em 4 clusters (Figura 5 (a) e 6(a)) - as estruturas detectadas foram as mesmas, válvulas e septo interventricular. No entanto, nas imagens segmentadas por SOM + *k-means* a dimensão das cavidades está mais próxima da dimensão original do que as imagens com *k-means*. A dimensão precisa das cavidades é importante para obtenção de medidas relevantes, como o volume das cavidades e a diferença entre os ventrículos. Uma região problemática para a segmentação é a borda entre a Aorta Descendente e o Ventrículo Esquerdo, a qual ambos os métodos não segmentaram corretamente.

Nas imagens segmentadas com 8 clusters, pode-se observar mais diferenças entre os métodos: as imagens da Figura 5 (b) estão mais nítidas que as da Figura 6 (b) - as cavidades estão melhor delimitadas. A segmentação em 8 clusters evidencia mais estruturas do coração, como a Aorta Descendente e a Banda Moderadora.

Nas imagens com 12 clusters, das Figuras 5 (c) e 6 (c), novas estruturas são evidenciadas, como a Membrana da Fossa Oval (membrana que prolonga o septo, separando os átrios).

Considerando a qualidade deste tipo de imagem e a complexidade da estrutura do coração, o desempenho global do método proposto é tido como satisfatória. Nas sequências resultantes, é possível detectar defeitos se estruturas estiverem faltando ou deslocadas.

Uma vantagem do método proposto sobre o *k-means*, é que, em uma sequência de imagens do mesmo paciente, o processo de clusterização é feito apenas uma vez - o SOM é treinado e então clusterizado. Assim, para segmentar as imagens, é apenas requerido encontrar o neurônio vencedor para cada pixel. No *k-means*, para cada imagem todo o processo de clusterização é repetido.




Figura 5 - Subconjunto da seqüência segmentado pelo método SOM + *k-means*; (a) 4 clusters; (b) 8 clusters; (c) 12 clusters

5 Conclusões

Foi proposto um método para segmentação de seqüências de imagens ecocardiográficas através de um mapa auto-organizável, pós-processado pelo algoritmo de clusterização *k-means*. A rede neural é usada para detectar as regiões mais significativas nos padrões das amostras extraídas randomicamente das imagens. Foi utilizada uma seqüência de imagens do mesmo paciente a fim de avaliar o desempenho do método proposto.

Os resultados alcançados pelo método proposto são melhores que os resultados da aplicação do método *k-means* sobre as imagens - as estruturas do coração foram encontradas corretamente e a dimensão das cavidades foi melhor definida. O bom desempenho do método proposto mostra que as amostras adquiridas aleatoriamente foram suficientes para treinar a rede.

Com as imagens segmentadas é possível ao operador checar se as estruturas cardíacas estão presentes e se estão na posição correta. As seqüências geradas pela abordagem proposta são adequadas para extração de medidas. Adicionalmente, o método proposto pode ser também utilizado para segmentação de outros tipos de imagens, com diferentes características, por exemplo imagens coloridas, usando os parâmetros RGB dos pixels.

Em relação aos resultados com imagens estáticas (um único frame da seqüência), verificou-se que com a segmentação das imagens dinâmicas (todos os frames da seqüência) o

método consegue oferecer melhores visualizações para a análise do exame por parte do médico.




Figura 6- Subconjunto da seqüência segmentado pelo método *k-means*;
(a) 4 clusters; (b) 8 clusters; (c) 12 clusters

Referências Bibliográficas

- [ABD 99] ABDULLA, Ra-id; CUTILLETTA, Anthony. **Congenital Heart Disease**. 1999. Disponível por www em <http://www.rchc.rush.edu/mawebfiles/c%20for%20parents.htm>. (29.03.2000).
- [BUR 78] BURCKHARDT, C. B. SPECKLE IN ULTRASOUND *B*-MODE SCANS. IEEE Transaction on Sonics and Ultrasonics. New York, v.SU-25, n.1, p.1-6, 1978.
- [DAH 98] DAHMER, A. **Segmentação de Imagens Ecocardiográficas Utilizando Redes Neurais e Medidas de Textura**, Porto Alegre: CPGCC, 1998. Dissertação de Mestrado. 100 p.
- [FUK90] FUKUNAGA, K. **Statistical Pattern Recognition**. [S.1]: Academic Press, 1990.
- [HUH91] HUHTA, J.C.; ROTONDO, K.M. Fetal echocardiography. In: SEMINARS IN ROENTGENOLOGY, 1991. **Proceedings...** 1991. v.26, p5-11.

- [KOH90] KOHONEN, Teuvo. The Self-Organizing Map. **Proceedings of the IEEE**, v.78, n.9, p. 1464-1480, September. 1990.
- [MOR96] MOREIRA, J.; COSTA, L. Neural-based color image segmentation and classification using self-organizing maps. In: SIBGRAPI, 9., 1996, Caxambú, MG. **Anais...**: SBC, 1996. p.47-54
- [NEY93] NEY, Derek. **Three-Dimensional visualization Using Medical Data- Medical Image Acquisition**, Sibgraph93, 1993, Chapel Hill. Course Notes.
- [SAD97] SADECK, L.S.R.; AZEVEDO, R.; BARBATO, A.J.G.; CALIL, V.M.L.T.; LATORRE, M.R.D.O.; LEONE, C.R.; RAMOS, J.L.A. **Indicações Clínico-Epidemiológicas para Investigação Ecocardiográfica no Período Neonatal. Valor dos Grupos de Risco**, 1997. Disponível por WWW em <http://www.cardiol.br/abc/1997/6905/tnov2.htm> (22.02.2000).
- [SUS95] SUSSNER, M. Segmentation and Edge-Detection of Echocardiograms using Artificial Neuronal Networks. **Proceedings of the International Conference EANN**, 1995.
- [VES97] VESANTO, J. **Data mining techniques based on self-organizing map**. Espoo, Finland: Department of Engineering Physics and Mathematics, 1997. Master's thesis.
- [ZIE97] ZIELINSKI, P. **Malformações cardíacas fetais: diagnóstico e conduta**. 1997, Disponível por WWW em <http://www.cardiol.br/abc/1997/6903/eco4.htm> (22.02.2000).