

Adaptação do sistema especialista Mammalyzer para análise de imagens MRI de alta resolução por meio de uso de filtro baseado em difusão anisotrópica não-linear

Ronaldo de Oliveira

Pós-graduação em Engenharia Elétrica

Departamento de Engenharia Elétrica

Laboratório de Controle e Microinformática - LCMI

Trabalho apresentado como parte dos requisitos para a obtenção do título de Mestre em

Engenharia Elétrica

Engenharia Elétrica na Universidade Federal de Santa Catarina,

Março de 2004

Resumo

O presente trabalho visa ampliar o horizonte de análise do sistema especialista Mammalyzer permitindo o auxílio no diagnóstico precoce de nódulos de câncer de mama, nos casos de imagens MRI de mama com fatias(slices) de espessura menor que 2 milímetros. Para tal, foi utilizada uma técnica de segmentação baseada no conceito de um filtro de difusão anisotrópica não-linear caracterizado pela preservação da região das bordas da imagem. Antes porém, da identificação da técnica de segmentação, o estudo do processo de implementação da primeira versão do Mammalyzer foi necessário. Isto envolveu tanto a análise do algoritmo implementado de uma rede neural artificial, baseada na técnica dos mapas auto-organizáveis de Kohonen, que se constitui no principal módulo do sistema Mammalyzer bem como o mecanismo dos parâmetros utilizados para a identificação de características nas imagens analisadas. Como resultado do estudo, obteve-se desempenho satisfatório na eliminação de artefatos de movimento pelo uso conjunto do filtro de difusão anisotrópica não linear, baseado no modelo de Perona-Malik, para parâmetros de contraste do filtro $\lambda=15$ e 100 iterações, com o modelo de mapas auto-organizáveis de Kohonen. Desta forma, o modelo não-linear de Perona-Malik demonstrou eficiência na remoção de pequenas texturas irregulares presentes próximo à região das bordas da imagem e nos contornos internos da imagem.

Abstract

The present work aims at to extend the horizon of analysis of the Mammalyzer expert system being allowed assists it in the early diagnosis of breast cancer nodules in the cases of magnetic resonance images(MRI) of breast with slices of thickness less than 2mm. For such, one technique of segmentation based on the concept of a nonlinear filter of anisotropic diffusion was used characterized by the preservation of the region of the image edges. However, before the identification of the segmentation technique, the study of the implementation of the first version of the Mammalyzer it was necessary. This involved in such a way analyzes it of the implemented algorithm of artificial a neural net, based in the technique of Kohonen self organizing maps, that it constitutes in the main module of the Mammalyzer expert system, as well as the mechanism of the parameters used for the identification of characteristics in the analyzing images. How result of the study, it was well succeffully in motion artifacts remove, by joint use of nonlinear anisotropic diffusion, based in the model of Perona-Malik,with contrast parameter $\lambda=15$ and 100 iterations and the self organizing maps model. In order to the nonlinear model of Perona-Malik it demonstrated efficiency in the removal of small irregular textures that exist on the region of the edges and in the internal contours of the image.

Agradecimentos

- A DEUS, pela saúde, bênçãos e oportunidades em toda a minha vida.
- À UFSC (Universidade Federal de Santa Catarina), por ter sido o palco da realização deste trabalho.
- Ao LISHA ,laboratório de integração de software hardware que disponibilizou infra-estrutura para a realização da parte teórica e prática deste trabalho.
- À minha mãe, irmãos, e pai (in memorian) pelo amor e compreensão despendidos em todas as realizações de minha vida.
- -Aluno-pesquisador Leonardo Ribeiro por todo suporte na área de informática e pelo apoio moral.
- Marcos Aurélio Pedroso por toda ajuda nas revisões.
- Washington Luiz Martins pelos incentivos nas horas mais críticas.

Este trabalho é dedicado à: Deus, minha mãe, meu pai(*in memorian*), meus irmãos.

Sumário

<i>Resumo</i>	<i>III</i>
<i>Abstract</i>	<i>IV</i>
<i>Agradecimentos</i>	<i>V</i>
<i>Lista de figuras</i>	<i>5</i>
<i>Lista de abreviaturas</i>	<i>10</i>
<i>Capítulo 1 Introdução</i>	<i>1</i>
1.1 Objetivo	2
1.2 Histórico do sistema especialista Mammalyzer	3
1.2.1 Matcher / Adaptador de imagens	4
1.2.2 Marker/Marcador	4
1.3 Panorama do câncer de mama no Brasil	5
1.4 Partes constituintes da mama	7
1.5 Patologias comuns encontradas no tecido mamário e alguns casos especiais	9
1.6 Limitações de diagnósticos convencionais de câncer de mama	12
1.7 Considerações sobre a densidade da mama	13
1.8 Técnica de ressonância magnética de mama	13
1.9 Utilização de agente de contraste para diagnóstico em imagens de ressonância magnética de mama	15
<i>Capítulo 2 Aquisição de imagens digitais e processamento da imagem no domínio espacial</i>	<i>21</i>
2.1 Aquisição de sinal luminoso pelos sensores	21
2.2 Processo de digitalização da imagem	22
2.3 Suavização no domínio espacial	24
2.4 Filtros derivativos	26
<i>Capítulo 3 Considerações sobre a teoria dos mapas auto-organizáveis de Kohonen e a implementação do módulo matcher do sistema mammalyzer</i>	<i>28</i>
3.1 Princípio biológico do modelo SOM de Kohonen	28

3.2 Método de classificação SOM	29
3.2.1 Ativação das unidades e aprendizagem	31
3.3 O fenômeno do agrupamento	32
3.4 Agrupamento Local e Global	33
3.5 Modificação de regra de aprendizagem SOM	33
3.6 Implementação do método dos mapas auto-organizativos	34
3.6.1 Algoritmo de Kohonen	34
3.6.2 Simulação do algoritmo	35
3.7 Diagrama de blocos de funcionamento do módulo de casamento de imagens(Matcher)	43
3.8 Detalhamento do módulo de entrada da rede neural, RNA	44
3.8.1 Extração e seleção de grupo de pixels na imagem nativa:	44
3.8.2 Extração e seleção de grupo de pixels na imagem com contraste:	45
3.9 Detalhamento do módulo de processamento da rede neural, RNA	48
3.10 Análise dos parâmetros relevantes para descrição de textura presente nas imagens MRI	50
3.11 Ambigüidade na identificação de pontos em duas imagens em instantes diferentes	50
<i>Capítulo 4 Escala espacial e filtros de difusão</i>	55
4.1 Teoria da escala espacial no contexto da análise de imagens	55
4.2 Representação multi-escala da informação da imagem	57
4.2.1 Representação formal da escala-espacial	58
4.3 Representação multi-escala de sinais discretos	62
4.4 Representação de detalhes finos em imagens por meio de modelo vetorial	66
4.5 Princípio físico do processo de difusão	68
4.6 Filtragem baseada em difusão não-linear	70
4.6.1 O modelo de Perona-Malik	70
4.7 Regularização de modelos não-lineares	75
4.7.1 Regularização de Perona-Malik	76
4.8 Difusão anisotrópica com conservação de borda de imagem	78
4.9 Discretização da equação de difusão anisotrópica	81
<i>Capítulo 5 Metodologia de validação e material empregado</i>	84
5.1 Fluxograma de procedimentos adotados para validação da pesquisa	84
5.2 Algumas considerações sobre os procedimentos de avaliação	87
5.2.1 Subtração de imagens	87
5.2.2 Dados de validação empregados	89
5.3 Meios computacionais empregados	90
<i>Capítulo 6 Resultados obtidos e discussão</i>	94
<i>Capítulo 7 Conclusão e trabalhos futuros</i>	107
<i>BIBLIOGRAFIA</i>	108

Lista de figuras

<i>Fig 1-1 Incidência de câncer de mama no Brasil por região(em milhões de habitantes)</i>	6
<i>Fig 1-2 Taxas brutas(%) de mortalidade por câncer de mama feminino no Brasil,entre 1979 e 1998.</i>	7
<i>Fig 1-3 Esquema mostrando partes constituintes da mama. Fonte: Inca</i>	7
<i>Fig 1-4 Esquema ilustrando formas benignas de tumores</i>	9
<i>Fig 1-5 Esquema mostrando forma comum de carcinoma presente em duto mamário</i>	11
<i>Fig 1-6 Correspondência entre a frequência de ocorrência de patologias com a idade. Nota-se a maior probabilidade de ocorrências malignas a partir de 60 anos. Fonte: ACS 2003</i>	11
<i>Fig 1-7 Equipamento de ressonância magnética. Fonte: www.prontocormg.com.br/Ressonan.htm</i>	14
<i>Fig 1-8 Observa-se lesão nodular espiculada na mama direita com forte impregnação do Gd-DTPA.</i>	15
<i>Fig 1-9 (a) Acréscimo de sinal devido a tumor maligno. (b) Acréscimo de sinal devido a ocorrência de patologia benigna.</i>	16
<i>Fig 1-10 Na figura acima, carcinoma ductal infiltrante multifocal e multicêntrico e correspondente gráfico de evolução do sinal de contraste. Nas duas figuras abaixo, carcinoma lobular infiltrante e correspondente gráfico de evolução do sinal de contraste.</i>	18

<i>Fig 1-11 Esquema mostrando perfusão sanguínea em meio rugoso devido a infiltração por tumor maligno.</i>	18
<i>Fig 1-12 Curva representando Wash-out precoce devido a tumor maligno.</i>	19
<i>Fig 2-1 Esquema mostrando funcionamento de câmera digital.</i>	22
<i>Fig 2-3 Esquema mostrando vizinhança de um ponto(x,y) na imagem.</i>	25
<i>Fig 2-4 Funções de suavização da imagem. (a) Restringe níveis de cinza. (b) Permite apenas dois níveis claro e escuro.</i>	26
<i>Fig 2-5 Vizinhança de um ponto central P0.</i>	27
<i>Fig 3-1 Esquema mostrando ampliação de área cerebral devido a estimulação de membro do corpo de um animal.</i>	29
<i>Fig 3-2. Mostrando exemplo de processo de assimilação de padrões por uma RNA baseada no modelo SOM.</i>	30
<i>Fig 3-3 Curva de aprendizagem da RNA. A curva define que os neurônios vizinhos ao vencedor, à distância menor que o raio r, tem seus pesos atualizados.</i>	32
<i>Fig 3-4 Esquema mostrando tentativa de identificação de grupos de pontos correspondentes pela rede neural som.</i>	52
<i>Fig 3-5 Na figura superior são mostrados contornos de uma das partes da mama, na figura abaixo variação do gradiente na direção X de X=205 à X=215.</i>	53
<i>Fig 3-6 Figura mostrando detalhes do contorno da imagem nativa. Nota-se pequenos contornos na parte central da imagem.</i>	54
<i>Fig 3-7 Figura mostrando detalhes do contorno da imagem com contraste. Nota-se, também, pequenos contornos na parte central da imagem.</i>	54
<i>Fig 4-1 Esquema mostrando segmentação da imagem como um arranjo de múltiplas camadas</i>	57
<i>Fig 4-2 Esquema mostrando sinal original da imagem na parte superior e múltiplos sinais derivados conforme diminui a escala espacial.</i>	58
<i>Fig 4-3. Distinção entre níveis de detalhe entre escalas maiores e menores</i>	60

<i>Fig 4-4 Esquema mostrando de forma genérica distribuição dos níveis de cinza em uma imagem e o modelo vetorial representado a direção de sua variação.</i>	68
<i>Fig 4-5 Esquema mostrando processo de propagação do calor em regiões de uma placa metálica.</i>	69
<i>Fig 4-6 Grafico do fluxo Φ, de difusão, na imagem I como função da relação entre o módulo do gradiente de I e do parâmetro de contraste λ. Conforme o gráfico, o fluxo Φ, aumenta até um valor de $\lambda = \nabla I$ e após decresce suavemente.</i>	72
<i>Fig 4-7 A esquerda é mostrada imagem com forte presença de ruído. A direita é mostrada imagem após utilização de filtro de difusão anisotrópica não-linear, nota-se forte arredondamento de regiões antes retas resultante do efeito de suavização.</i>	77
<i>Fig 4-8 Esquema mostrando vizinhança de um ponto $P(x,y,t)$, qualquer na imagem, composta por 8 pontos. A expressão diferencial contida nos coeficientes de condutância c_1 à c_8 é discretizada como a diferença entre o valor do ponto central e o valor do ponto em uma das 8 direções.</i>	82
<i>Fig 5-1 Esquema representando a obtenção de uma imagem $I_a(x,y)$ como resultado de uma subtração ponto à ponto de outras duas $I_1(x,y)$ e $I_2(x,y)$.</i>	88
<i>Fig 5-2 Comparação entre imagens processadas pela 1. versão do Mammalyzer(à esquerda) com as processadas pela nova versão(à direita). Notar presença de maior quantidade de detalhes irregulares de textura na imagem à direita.</i>	90
<i>Fig 5-3 Tela do Sistema Mammalyzer integrado ao editor de imagens Dicom.</i>	92
<i>Fig 5-4 Detalhe de interface do sistema Mammalyzer destacando, ao centro, tela de configuração de parâmetros do filtro de difusão anisotrópica.</i>	93
<i>Fig 6-1 Imagem Nativa, no caso 1.</i>	82
<i>Fig 6-2 Imagem com contraste, no caso 1.</i>	82
<i>Fig 6-3 Imagem resultante de subtração entre imagem com contraste e nativa, no caso 1.</i>	83
<i>Fig 6-4 Imagem casada resultante de utilização de rede neural SOM, no caso 1.</i>	83
<i>Fig 6-5 Imagem resultante de subtração entre imagem casada e com contraste, no caso 1.</i>	83

<i>Fig 6-6 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=3$ $I=5$, no caso1.</i>	83
<i>Fig 6-7 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=20$, no caso1.</i>	84
<i>Fig 6-8 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=50$, no caso1.</i>	84
<i>Fig 6-9 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=90$, no caso1.</i>	84
<i>Fig 6-10 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=90$, no caso1.</i>	84
<i>Fig 6-11 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$, no caso1.</i>	85
<i>Fig 6-12 Imagem resultante de subtração entre imagem casada e com contraste, com "Matcher" operando em vizinhança local e uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$, no caso1.</i>	85
<i>Fig 6-13 Imagem nativa, no caso2.</i>	83
<i>Fig 6-14 Imagem com contraste, no caso2.</i>	83
<i>Fig 6-15 Imagem resultante entre subtração de imagem nativa e com contraste, no caso2.</i>	83
<i>Fig 6-16 Imagem casada resultante de aplicação de rede neural SOM, no caso2.</i>	83
<i>Fig 6-17 Imagem resultante de subtração entre imagem casada e com contraste, no caso2.</i>	87
<i>Fig 6-18 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=3$ $I=5$, no caso2.</i>	87
<i>Fig 6-19 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=20$, no caso2.</i>	87
<i>Fig 6-20 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=50$, no caso2.</i>	87
<i>Fig 6-21 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=90$, no caso2.</i>	87
<i>Fig 6-22 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=90$, no caso2.</i>	87

<i>Fig 6-23 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$,no caso2</i>	88
<i>Fig 6-24 Imagem resultante de subtração entre imagem casada e com contraste, com “Matcher” operando em vizinhança local e uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$,no caso2.</i>	88
<i>Fig 6-25 Imagem nativa,no caso3.</i>	88
<i>Fig 6-26 Imagem com contraste,no caso3.</i>	88
<i>Fig 6-27 Imagem resultante de subtração entre imagem nativa e com contraste,no caso3.</i>	89
<i>Fig 6-28 Imagem casada obtida de processamento por rede neural SOM,no caso3.</i>	89
<i>Fig 6-29 Imagem resultante de subtração de imagem casada com imagem com contraste,no caso3.</i>	90
<i>Fig 6-30 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=3$ $I=5$,no caso3.</i>	90
<i>Fig 6-31 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=20$,no caso3.</i>	90
<i>Fig 6-32 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=50$,no caso3.</i>	90
<i>Fig 6-33 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=90$,no caso3.</i>	91
<i>Fig 6-34 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=90$,no caso3.</i>	91
<i>Fig 6-35 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$,no caso3.</i>	91
<i>Fig 6-36 Imagem resultante de subtração entre imagem casada e com contraste, com “Matcher” operando em vizinhança local e uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$,no caso3</i>	91

Lista de abreviaturas

FDANL – Filtro de difusão anisotrópica não-linear baseado no modelo de conservação de bordas da imagem de Perona-Malik.

SOM – Modelo de rede neural baseado no princípio dos mapas auto-organizáveis de Kohonen.

Gd-DTPA – Gadolínio Dietileno Triamina Penta Acético Acido. Agente de contraste utilizado para realçar o brilho em imagens obtidas de ressonância magnética de mama.

MRI – (Magnetic resonance images). Imagens de ressonância magnética.

INCA – Instituto Nacional do Câncer.

ACS – American Câncer Society.

Capítulo 1

Introdução

O sistema especialista *Mammalyzer*, desenvolvido pelo Grupo Cyclops, de informática médica do INE, teve por objetivo o diagnóstico rápido e preciso do câncer de mama. Através do auxílio do módulo denominado *Matcher*, este diagnóstico era efetuado por meio de comparação de regiões da imagem em instantes diferentes. Naturalmente a próxima etapa do processo consistiria na validação com um grande número de dados de pacientes. Um aspecto importante nesta etapa de validação é a utilização de dados provenientes de mamografias retiradas de mamas com distribuição irregular de tecido muscular. Estas mamas apresentam um diagnóstico particularmente difícil, devido ao fato dos tumores malignos serem semelhantes à própria distribuição da fibra muscular, gerando falsas avaliações quando se utilizam métodos baseados em simples inspeção visual. Técnicas de processamento de imagem melhoram consideravelmente o grau de acerto no auxílio as conclusões do diagnóstico. Porém ainda assim certas inconsistências no processo de análise de imagens utilizado pelo *Mammalyzer* ainda persistem. Do ponto de vista da imagem em si, o tecido muscular da mama é representado por uma distribuição regular de textura e alguns pequenos trechos irregulares. Quando localizado em regiões da borda da mama este conjunto com trechos irregulares, apresentam distribuições de pequenos gradientes em meio a valores elevados de gradiente. Esta descontinuidade gera erros de verificação de similaridade de regiões correspondentes da imagem em instantes diferentes. Esta verificação de similaridade é a etapa

mais importante no processo de análise, e é feita pelo módulo Matcher do Mammalyzer, quando no processo de casamento de imagens. Para eliminar estas inconsistências foi proposto uma ferramenta que remove pequenos detalhes presentes na textura da imagem. Esta ferramenta é baseada em princípios da difusão anisotrópica não-linear. Esta nova versão do sistema especialista Mammalyzer foi desenvolvida por meio de parceria entre o Grupo de visão computacional do Departamento de automação e sistemas, DAS e o Grupo Cyclops do INE.

1.1 Objetivo

A utilização da análise de imagens vem crescendo de importância para os diagnósticos que antecedem intervenções cirúrgicas. Por meio desta técnica se pode extrair informações úteis para auxiliar médicos ou equipamentos a caracterizar este diagnóstico. As técnicas computacionais, em especial a técnica baseada em análise por meio de redes neurais artificiais representam em conjunto com técnicas de segmentação de imagens uma importante parcela, no passo seguinte da evolução dos diagnósticos. Enquanto a primeira trata do processamento dos dados da imagem, sem aparente relação entre si, a segunda caracteriza-se pela divisão da imagem em regiões específicas e bem definidas, com este conjunto de técnicas, informações relevantes para o diagnóstico clínico são extraídas. Mesmo assim, ainda as técnicas de análise de imagens não estão imunes a inconsistências. As mamas com distribuição irregular de tecido muscular representam um sério problema quando se desejam extrair informações para diagnóstico por imagem por parte do radiologista, devido ao fato do tecido muscular obscurecer tumores. Dentro do contexto do sistema especialista Mammalyzer, a imagem de mama com regiões descontínuas de tecido fibro-glandular, gera informações ambíguas para o módulo de casamento de imagens, "Matcher", que devido a isto gera

um resultado inconsistente. Tendo isso vista, o presente trabalho, propõe uma ferramenta auxiliar ao módulo "Matcher" do sistema especialista Mammalyzer, com a finalidade de realizar um pré-processamento das imagens oriundas de ressonância magnética de mama de alta resolução. Este pré-processamento tem a finalidade de eliminar detalhes irrelevantes da imagem de mama e ressaltar regiões do contorno externo e estruturas internas que ocupem grande extensão. Com esta ferramenta pretende-se que o Mammalyzer passe a identificar regiões de tumores em seu estágio inicial em tecidos de mama com distribuição irregular de tecido muscular.

1.2 Histórico do sistema especialista Mammalyzer

O Sistema especialista Mammalyzer[1] foi desenvolvido com o objetivo de operar imagens de mama que apresentem ruído e forte deformação. Para tal foram desenvolvidos uma série de passos envolvendo filtros de processamento de imagem, o que permitiu aos médicos por meio de uma interface gráfica a possibilidade de escolher dois modos de análise (FAST ou Accurate). Por meio destes modos foi dada possibilidade ao médico de avaliar qualitativamente a quantidade de erro gerado pelos movimentos da paciente entre as imagens a serem analisadas.

A possibilidade de escolha dos parâmetros para a análise também pôde ser realizada interativamente. Alternativamente, foi dada a possibilidade do usuário escolher o modo "Automatic", onde tanto a mensuração dos artefatos de movimento quanto a escolha, parametrização e controle dos filtros podiam ser realizadas pelo software de sistema especialista Mammalyzer. Imagens nativa e com contraste (Gd-DTPA) podem ser selecionadas on-line diretamente da base de dados DICOM de pacientes. Abaixo são relacionados os dois principais módulos que compõe o Mammalyzer:

1.2.1 Matcher / Adaptador de imagens

O módulo de casamento de imagens (matcher) compensa disparidades nas imagens causadas pelos movimentos da paciente. Esse módulo opera em dois modos: bi e tridimensional. Ele toma duas imagens ou dois volumes de imagens, dependendo do modo de operação, sendo um o volume nativo e o outro o volume Gd-DTPA ou a imagem Gd-DTPA correspondente à imagem nativa escolhida e computa uma imagem ou um volume correspondente através de deformações locais iterativas até que uma alta taxa de correspondência entre imagem nativa e a Gd-DTPA seja atingida. Esta imagem casada resultante serve, então, para uma comparação pixel a pixel a fim de detectar o acréscimo de sinal de cada ponto do tecido, uma vez que ela representa a imagem nativa transformada de acordo com os movimentos da paciente. Dessa forma, computações posteriores podem ser realizadas sem que os movimentos da paciente tenham de ser levados em consideração. Uma vez que esse módulo representa o componente mais importante entre os utilizados nas duas seqüências de análise de mamografias, uma discussão mais detalhada desse módulo e do algoritmo utilizado será encontrada na próxima seção.

1.2.2 Marker/Marcador

Por meio deste módulo é computado o acréscimo relativo de sinal pixel à pixel ou voxel à voxel entre os pontos correspondentes das imagens nativa e com contraste(Gd-DTPA). A presença de ruído é levada em consideração por meio da representação do marcador, basicamente como um operador, sobre uma vizinhança local. Ao contrário dos operadores de vizinhança convencionais em processamento de imagens, esse operador trabalha em duas imagens simultaneamente. O pixel/voxel mais adequado em uma vizinhança é aquele utilizado para o cálculo do acréscimo de sinal de acordo com uma regra especialmente desenvolvida. A determinação desse

pixel/voxel "mais adequado" é realizada através de uma comparação de similaridades de contextos. Para esse fim é selecionado um ponto na imagem nativa e, na vizinhança das coordenadas correspondentes a esse ponto na imagem com contraste(Gd-DTPA), é selecionado o ponto "mais similar". Essa medida de similaridade pode ser definida pelo usuário e, no caso mais simples, é puramente o ponto dentro da vizinhança com tom de cinza mais próximo. Ela pode ser estendida até ser equivalente a definição de contexto de vetores de gradientes utilizada no módulo de casamento de imagens. Através deste método foi possível computar acréscimos de sinal de contraste de 90%, que caracteriza a existência de uma região de tumor.

1.3 Panorama do câncer de mama no Brasil

Segundo o Ministério da Saúde (2001), o câncer é a segunda causa de morte por doença e demanda a realização de ações dos mais variados graus de complexidade. Nas mulheres a taxa de aumento na mortalidade por câncer teve um aumento considerável, analisando o gráfico da Fig-1-2, de 1979 à 1998, o aumento foi de 6,14 para 9,70 por 100 mil mulheres. Sendo que no ano de 2001, ocupou o primeiro lugar nas estatísticas de incidência e mortalidade. Esta tendência é semelhante a existente em países desenvolvidos onde os costumes urbanos, acabaram tornando freqüentes os fatores de risco para o desenvolvimento da doença, tais como gravidez tardia. Nesses países houve um aumento na incidência do câncer de mama, acompanhado da redução da taxa de mortalidade na faixa acima dos 50 anos, devido principalmente a políticas de prevenção e assistência médico hospitalar eficientes. Em alguns países em desenvolvimento porém ocorre o contrário, pois um aumento na taxa de incidência é acompanhado de uma taxa de mortes atribuído, devido a falta de políticas preventivas e procedimentos terapêuticos inadequados. A elevada incidência e mortalidade

por câncer de mama no Brasil justifica o planejamento de políticas de prevenção. Segundo o INCA é fundamental, que haja mecanismos, pelos quais indivíduos motivados a cuidar de sua saúde, encontrem uma rede pública de saúde apta quantitativamente e qualitativamente para suprir as necessidades destes indivíduos, em todo o território nacional. Torna-se necessário para enfrentar tal desafio, a adoção de uma política que contemple, entre outras estratégias, a capacitação de recursos humanos para o diagnóstico precoce de câncer.




Fig 1-1 Incidência de câncer de mama no Brasil por região(em milhões de habitantes)

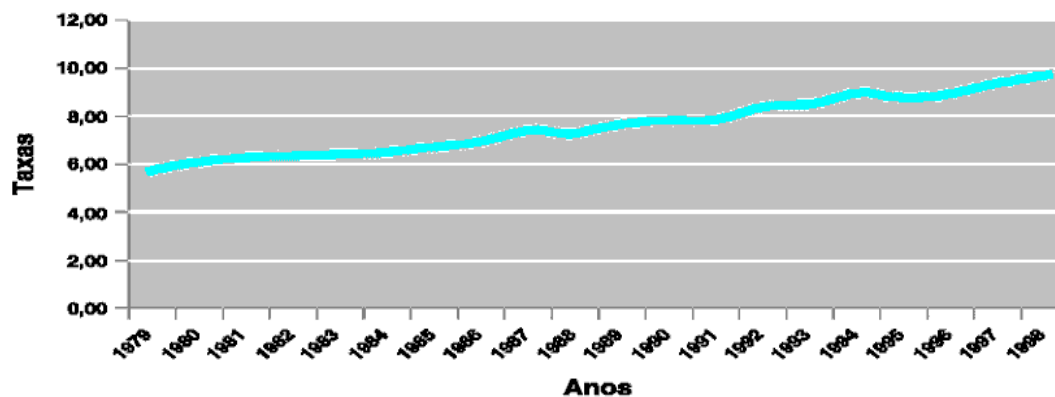


Fig 1-2 Taxas brutas(%) de mortalidade por câncer de mama feminino no Brasil,entre 1979 e 1998.




Fig 1-3 Esquema mostrando partes constituintes da mama. Fonte: Inca

1.4 Partes constituintes da mama

As mamas são órgãos pares, situadas na parede anterior do tórax, sobre os músculos Grande Peitoral. Externamente, cada mama, na sua região central, apresenta uma aréola e uma papila. Na papila mamária exteriorizam-se 15 a 20 orifícios ductais, que correspondem às vias de drenagem das unidades funcionais, que são os lobos mamários. A mama é dividida em 15 a 20 lobos mamários independentes, separados por tecido fibroso, de forma que cada um tem a sua via de drenagem, que converge para a papila, através do sistema ductal. As partes internas da mama são mostradas na figura 1.3 e detalhadas abaixo:

ÁCINO – porção terminal da “árvore” mamária, onde estão as células secretoras.

LÓBULO MAMÁRIO – conjunto de ácinos.

LOBO MAMÁRIO - unidade de funcionamento formada por um conjunto de lóbulos (15-20) que se liga à papila por meio de um ducto lactífero.

DUCTO LACTÍFERO – sistema de canais (15-20) que conduz o produto de secreção até a papila, o qual se exterioriza através do orifício ductal.

PAPILA – protuberância composta de fibras musculares elásticas onde desembocam os ductos lactíferos.

ARÉOLA – estrutura central da mama onde se projeta a papila.

TECIDO ADIPOSEO – todo o restante da mama é preenchido por tecido adiposo ou gorduroso, cuja quantidade varia com as características físicas, estado nutricional e idade da mulher.

LIGAMENTOS DE COOPER - responsáveis pela retração cutânea nos casos de câncer de mama, são expansões fibrosas que se projetam na glândula mamária. As mulheres mais jovens apresentam mamas com maior quantidade de tecido glandular, o que torna esses órgãos mais densos e firmes. Ao se aproximar da menopausa, o tecido mamário vai se atrofiando e sendo substituído progressivamente por tecido gorduroso, até se constituir, quase que exclusivamente, de gordura e resquícios de tecido glandular na fase pós-menopausa.

Têm como função principal a produção de secreção para a amamentação, mas têm também grande importância psicológica para a mulher, representando papel fundamental na constituição de sua auto-estima e auto-imagem. Embelezam a silhueta do corpo feminino e desempenham também função erógena e de atração sexual.

1.5 Patologias comuns encontradas no tecido mamário e alguns casos especiais

Alguns diagnósticos benignos [2] comuns encontrados na mama são os seguintes, conforme mostra figura 1-4:

Fibroadenoma: apresenta-se como um nódulo duro e elástico, sólido, não doloroso, móvel à palpação, de limites precisos e mede de 1 a 3 cm. Surge quase sempre na mulher jovem, entre 15 e 30 anos. Trata-se de uma lesão sem potencial de malignização. Certos tipos de câncer, chamados tumores circunscritos, podem simular um fibroadenoma sendo, portanto, prudente que os fibroadenomas sejam submetidos à confirmação histopatológica.

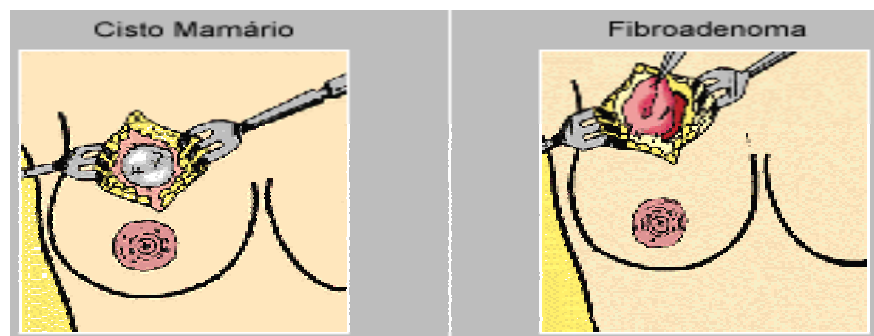


Fig 1-4 Esquema ilustrando formas benignas de tumores. Fonte: Inca

Cistos: são tumores de conteúdo líquido, facilmente palpados, de consistência amolecida e podem atingir grande volumes. Existem cistos pequenos, chamados microcistos, que não são palpáveis e que são detectados pela ultrasonografia. Quase sempre são múltiplos, não representam problema clínico e não precisam receber qualquer atenção específica. Alguns tipos de cistos grandes podem exibir crescimento tumoral no seu interior lembrando uma vegetação em desenvolvimento. Estas aglomerações intra-císticas merecem

investigação, pois podem representar lesões pré-malignas ou malignas. O cisto exibe-se bem à mamografia e à ultra-sonografia como nódulo de contornos bem definidos e sem calcificações. A ultra-sonografia é o método diagnóstico ideal da doença cística. O tratamento do cisto é a punção aspirativa esvaziadora com agulha. Ele deve ser extraído cirurgicamente nos casos de conteúdo sanguinolento à punção, persistência de tumor após punção, vegetação intra-cística ao ultra-som ou em casos de reaparecimento do cisto no local já puncionado(recidiva). Em relação aos diagnósticos malignos o caso mais geral é:

Nódulo maligno genérico: apresenta-se como um nódulo de consistência dura e de formato irregular. A pele que reveste o tumor pode estar intacta, ulcerada pelo tumor ou com aspecto enrugado semelhante à casca de laranja [5].

Alguns casos especiais [6] de patologia que podem ser destacados são:

Carcinoma ductal in situ: é aquele que não invadiu a membrana basal e, portanto, não tem capacidade de enviar êmbolos para o sistema vascular. É um tumor quase sempre descoberto em fase subclínica, por meio de mamografia, através da presença de microcalcificações. Sua localização é mostrada na figura 1-5. O seu tratamento atinge índice de curabilidade próximo de 100% e é baseado em quadrantectomia ou mastectomia, dependendo da extensão do próprio tumor.

Sarcomas:Os sarcomas originam-se do tecido conjuntivo que existe nos septos do tecido glandular.São raros e se disseminam pela corrente sangüínea. Podem crescer rapidamente e atingir grandes volumes locais sem ulcerações. Seu tratamento é cirúrgico, com a retirada total da mama.

Carcinoma de Paget: é uma lesão especial que, freqüentemente, se manifesta como dermatite eczematóide unilateral da papila mamária, por isto ela deve sempre merecer um certo grau de suspeição e requer biópsia.

Carcinoma inflamatório: O carcinoma inflamatório é uma forma especial de tumor caracterizada pelo comprometimento difuso da mama, que adquire características de inflamação. Ao microscópio, observa-se a presença de êmbolos subdérmicos maciços. Clinicamente, a pele apresenta calor, rubor e edema, lembrando a casca de uma laranja. Trata-se de um tumor agressivo, fundamentalmente tratado pela quimioterapia. Na figura 1-6 é mostrado gráfico da Sociedade Americana de Câncer(ACS 2003) que mostra a freqüência de ocorrência das patologias conforme a idade.




Fig 1.5 Esquema mostrando forma comum de carcinoma presente em ducto mamário. Fonte: Inca.




Fig 1-6 Correspondência entre a freqüência de ocorrência de patologias com a idade. Nota-se a maior probabilidade de ocorrências malignas a partir de 60 anos. Fonte: ACS 2003

1.6 Limitações de diagnósticos convencionais de câncer de mama

Afetando 1 em cada 10 mulheres, o câncer de mama tornou-se a mais importante causa de mortalidade entre mulheres. Uma detecção precoce de tumores malignos e sua distinção de irregularidades naturais presentes na mama se fazem necessário para a cura. A mamografia apresenta uma sensibilidade de quase 100% em mamas que apresentam grande ocorrência de tecido gorduroso. No entanto em mamas densas ou muito densas a sensibilidade da mamografia decreta significativamente, tumores que apresentam microcalcificações são ainda detectáveis, porém os que não apresentam são ofuscados pelo tecido sobreposto da mama. Distinções entre Carcinomas e simples tecido muscular por vezes se torna impossível. Excluindo-se casos como: distorções sutis de forma, retração, assimetria, ou alguma mudança com o tempo desperte atenção de quem analisa a mamografia, tumores que exibem a mesma radiodensidade que a vizinhança de tecidos de mamas densas, são invisíveis. Embora alguns tumores muito pequenos possam ser detectados por auto-exame, a maioria das lesões palpáveis são maiores que 1 cm. A distinção entre espessuras individuais de fatia normais e anormais ou menos luminescentes pode ser difícil de ser realizada, dependendo de como é feita em uma consistência variável de tecido normal ou anormal. A técnica de ultrassom pode ser utilizada para confirmar casos de tumores malignos palpáveis em mamas densas. No entanto, em alguns casos de tumores malignos como os carcinomas não-invasivos e os carcinomas com aspecto difusivo crescente pode não haver visibilidade por ultra-som.

1.7 Considerações sobre a densidade da mama

O diagnóstico precoce, é a maior preocupação médica para a cura efetiva do câncer de mama. As mamas densas representam um obstáculo a essa detecção precoce devido ao fato do tecido de aspecto escuro ofuscar tumores que se encontram entre as camadas do tecido. Uma solução adotada é a execução de exames periódicos a partir de determinada idade. Por meio deste método se consegue avaliar a mudança do padrão mamográfico que ocorre com o aumento da idade das pacientes. No entanto, as terapias de reposição hormonal tem agravado o problema das mamas densas, pacientes que em avaliações anteriores não se enquadravam nestes casos, com esta terapia passaram a ter características nas mamas de tecido denso. Considerando-se que a idade é um fator de risco e que a maioria das mulheres que se utilizam desta terapia se situam na idade de risco, a reposição hormonal vem se tornando um obstáculo na detecção de tumores por meio de imagens. Segundo estudos nos anos 90, aproximadamente 20% das mulheres que se submeteram a esta terapia apresentaram crescimento de tecido denso. Apesar de haver bastante polêmica a respeito do assunto, geralmente na literatura médica, a densidade de mama é considerada um fator de risco com relação à doença.

1.8 Técnica de ressonância magnética de mama

A ressonância magnética(MRI) de mama com contraste tem se tornado desde a última década uma ferramenta adicional valiosa para os problemas de diagnóstico em mamas. A MRI foi descoberta em 1946 e usada para fins industriais por Purcell, Torey e Pourd, aplicada em medicina em 1979, utiliza magnetos gigantes que possuem capacidade de gerar campos até 40.000 vezes o campo magnético da Terra. Seu princípio de funcionamento é

baseado no fato de todo ser vivo possuir água em seus corpos. A água é composta de átomos de hidrogênio cujos prótons em seus núcleos, inicialmente encontram-se em posição desordenada. Quando a parte do corpo a ser analisada, é colocada dentro do magneto, os prótons dos núcleos de hidrogênio são então ordenados de tal forma que sejam capazes de captar sinais de ressonância. A seguir bobinas emitem ondas de rádio, este sinal de radiofrequência (RF) emitido produz desordenamento dos prótons de hidrogênio. Quando a emissão de RF é suspensa, os prótons voltam a sua posição inicial de alinhamento e liberam energia. Essa energia liberada forma uma imagem que posteriormente é utilizada para identificação de regiões de diferentes densidades no tecido vivo. A grande vantagem desta técnica é que o paciente não tem o corpo submetido a radiações ionizantes como o raio-x. Abaixo é mostrado um equipamento de ressonância magnética.

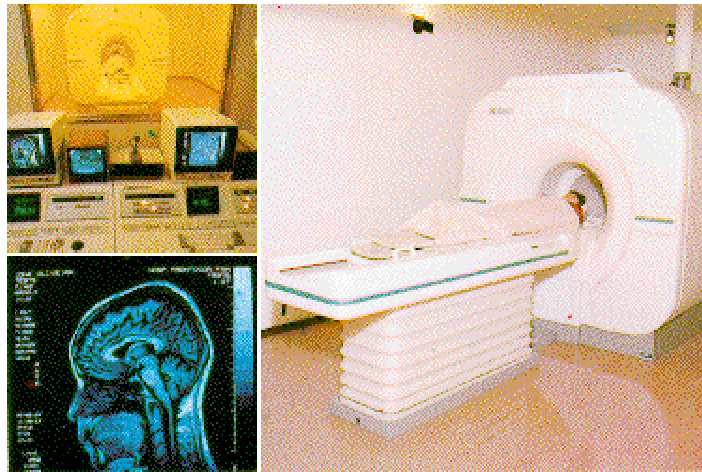


Fig 1.7 Equipamento de ressonância magnética. Fonte: www.prontocormg.com.br/Ressonan.htm

1.9 Utilização de agente de contraste para diagnóstico em imagens de ressonância magnética de mama

Para que a técnica de ressonância magnética de mama (MRI) tenha maior eficiência se faz necessário o uso conjunto com um marcador químico (Gd-DTPA) que ajuda a realçar o contraste da imagem [29], desta forma é possível analisar regiões antes obscurecidas. O efeito de realce de contraste obtido é possível devido ao fato, de o Gd-DTPA se situar em regiões onde ocorre bloqueio na corrente sanguínea. Ora, os tumores malignos concentram grande perfusão sanguínea, em razão possuírem vasos sanguíneos de aspecto rugoso, isso pode ser visto na figura 1-11, [30]. Detalhes do cálculo da concentração de Gd-DTPA podem ser vistas em [30]. De uma forma geral as lesões tumorais malignas possuem aspecto irregular, margens mal definidas e espiculadas [3].




Fig 1-8 Observa-se lesão nodular espiculada na mama direita com forte impregnação do Gd-DTPA.

Na lesão tumoral maligna, diferentemente da benigna em termos estatísticos (83% dos carcinomas) [4], a impregnação precoce do agente de contraste, conforme visto na imagem à direita da figura 1-8, ocorre no primeiro

e terceiro minuto após sua aplicação endovenosa, além disso, ocorre *wash-out* precoce conforme gráfico da figura 1-12. Também ocorre impregnação focal, seguindo a trajetória do duto mamário e impregnação periférica da lesão tumoral.


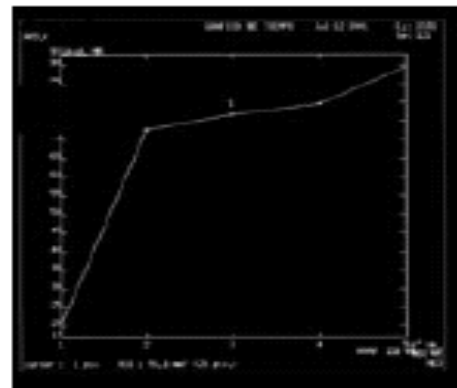



Fig 1.9 (a) Acréscimo de sinal devido a tumor maligno. (b) Acréscimo de sinal devido a ocorrência de patologia benigna.

Através da análise das taxas de absorção do agente de contraste nas imagens de tomografia de diferentes volumes são tomadas em tempos diferentes se pode prever a existência de tecido canceroso. Durante o exame de MRI, são tomados da paciente a imagem nativa, e após a aplicação do Gd-DTPA são tomados volumes subsequentes após 20 segundos e 1 minuto após, em intervalos de 1 minuto. Por meio de subtração das seqüências de volumes de imagem, a evolução da distribuição do Gd-DTPA é analisada. Uma região suspeita é definida como aquela que apresenta um acréscimo relativo de sinal de 90% durante o 1. minuto, como mostrado nas figuras 1-9. Na figura 1-10 esses sinais são mostrados ao lado das imagens MRI com as respectivas patologias.






Fig 1.10 Na figura acima, carcinoma ductal infiltrante multifocal e multicêntrico e correspondente gráfico de evolução do sinal de contraste. Nas duas figuras abaixo, carcinoma lobular infiltrante e correspondente gráfico de evolução do sinal de contraste. Fonte: www.cesemed.com




Fig 1-11 Esquema mostrando perfusão sanguínea em meio rugoso devido a infiltração por tumor maligno. A direção do fluxo sanguíneo é dado por F.

A grande vantagem deste método reside no fato de possibilitar maior qualidade na análise de uma lesão de mama. Através do uso do agente

de contraste, é possível a técnica MRI analisar o formato das lesões, seus contornos, sua extensão, presença de microcalcificações. Estes dados são de extrema relevância uma vez que prestam suporte ao médico na decisão de se realizar uma cirurgia de mastectomia ou apenas uma cirurgia localizada. O uso conjunto com o Gd-DTPA possibilita à técnica MRI de mama um aumento de sensibilidade na detecção de lesões malignas de 88%-100%.




Fig 1-12 Curva representando Wash-out precoce devido a tumor maligno.

O *Mammalyzer* [1] quantifica, nas imagens MRI, regiões de elevada impregnação por contraste por meio da comparação de absorção de agente contraste na imagem de referência (nativa) e com contraste (Gd-DTPA). Conforme mostrado na figura 1-13, a quantificação do incremento de sinal ocasionado pelo acúmulo de Gd-DTPA, após identificação de pontos correspondentes por meio de parâmetros de similaridade definidos pelo usuário [1], é computado como a diferença ponto a ponto entre as imagens nativa e com contraste.

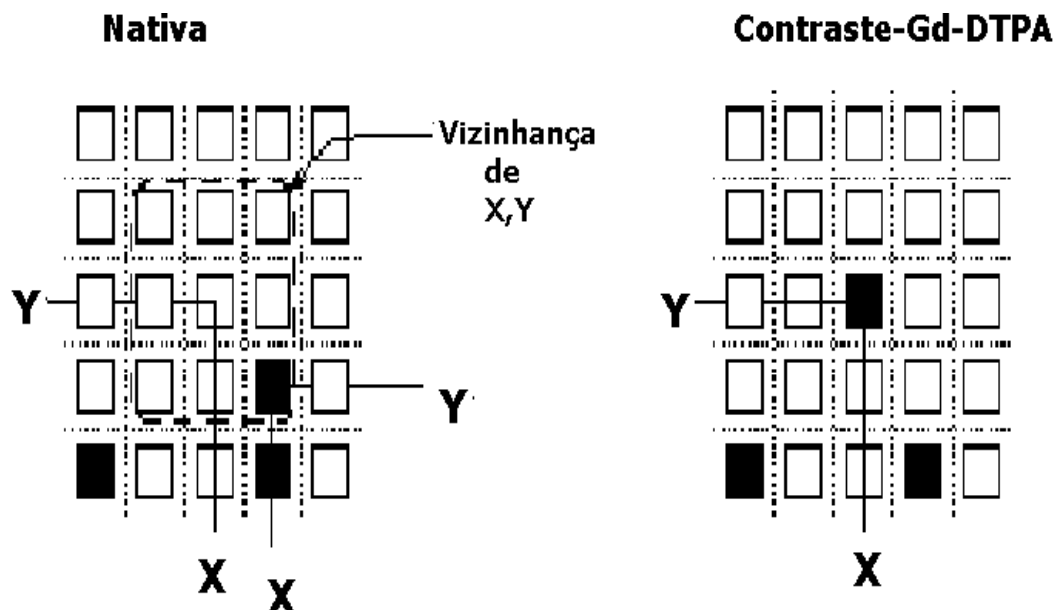


Fig 1-13 Método empregado pelo *Mammalyzer* para computar acréscimo de sinal devido ao acúmulo de Gd-DTPA.

A melhora constante dos resultados, no diagnóstico precoce de câncer de mama, utilizando técnicas combinadas, ajuda a reduzir drasticamente a possibilidade de erros de avaliação (falso-positivo, falso-negativo), aumentando assim a confiabilidade no diagnóstico de tumores malignos de câncer de mama.

Capitulo 2

Aquisição de imagens digitais e processamento da imagem no domínio espacial

O processo de aquisição de imagens consiste na conversão de sinais elétricos em informação numérica para posterior processamento isto é feito por meio de duas etapas aquisição do sinal luminoso pelos sensores e processo de digitalização da imagem. Na etapa do processamento da imagem uma das fases mais importantes é o processo suavização.

2.1 Aquisição de sinal luminoso pelos sensores

Os sensores são dispositivos físicos que convertem energia luminosa em um sinal elétrico proporcional. A etapa de aquisição do sinal luminoso é mostrado na Figura 2-1 em que se utiliza o exemplo do funcionamento de uma câmera digital onde, onde após cruzar a objetiva o sinal luminoso incide em uma grade de fotosensores onde é convertido em corrente elétrica proporcional.




Fig 2-1 Esquema mostrando funcionamento de câmera digital.

2.2 Processo de digitalização da imagem

A etapa de digitalização consiste na conversão de um sinal elétrico contínuo em um sinal que possui apenas dois níveis de tensão elétrica, isso é feito por meio de um conversor analógico/digital. Cada sinal

convertido então em um número, é arranjado em uma matriz, mostrada na Figura 2-2, composta por $N \times M$ elementos. A esses elementos dá-se o nome de pixel, cada pixel então representa uma quantidade discreta. A imagem contínua $f(x,y)$ é então aproximada por meio desta matriz. Os pixels na matriz são localizados por suas coordenadas (x,y) da imagem $f(x,y)$.

$$\begin{pmatrix}
 f(0,0) & f(0,1) & \dots & f(0,M-1) \\
 f(1,0) & f(1,1) & \dots & f(1,M-1) \\
 \vdots & \vdots & \ddots & \vdots \\
 f(N-1,0) & f(N-1,1) & \dots & f(N-1,M-1)
 \end{pmatrix}$$

Fig 2-2 Imagem na forma de matriz de valores discretos

Os valores de M e N representam a resolução espacial da imagem, que é exatamente o número de pixels em sua linha e coluna. Quanto maior os valores de M e N mais detalhes possui uma imagem. A digitalização das coordenadas espaciais (x,y) se dá o nome de amostragem da imagem, e a digitalização da amplitude dá-se o nome de quantização do nível de cinza. O processo de digitalização requer escolhas sobre os valores M e N , e o número de níveis de cinza discretos alocados para cada pixel. Geralmente se expressa estas quantidades por inteiros em potências de 2, $N=2^n$, $M=2^j$ e $P=2^m$ onde P representa o número de níveis de cinza. Cada número que representa o nível de cinza é composto por um determinado número de bits, o número de bits requerido b , é dado pela seguinte expressão: $b=M \times N \times m$ se $M=N$, $b=N^2 m$. Quanto maior o número de bits b , portanto maiores os valores de M e N e por consequência um maior o número de detalhes pode ser representado na imagem.

2.3 Suavização no domínio espacial

Após a etapa de obtenção da imagem digital, os pixels e seus valores discretos podem ser manipulados matematicamente. O processo de

suavização no domínio espacial consiste em adequar a amplitude dos níveis de cinza de cada pixel. Isto é feito percorrendo cada coordenada (x,y) . A função de suavização no domínio espacial podem ser expressas por: $g(x,y)=T[F(x,y)]$ onde $f(x,y)$ é a imagem a ser suavizada, $g(x,y)$ é a imagem resultante e T representa a operação de suavização. Uma das principais abordagens da operação de suavização é se definir uma vizinhança $V(x,y)$ sobre o ponto (x,y) por meio de um quadrado ou retângulo centrado no ponto (x,y) , conforme mostrado na Figura 2-3.




Fig 2-3 Esquema mostrando vizinhança de um ponto (x,y) na imagem.

Geralmente na operação de suavização, o centro da subimagem formada por $V(x,y)$ é movida de pixel à pixel começando do canto superior esquerdo e aplicando a operação a cada localização (x,y) obtendo o valor de g desta localização. Em sua forma mais simples T é implementado em uma vizinhança $V(x,y)$ com os vizinhos mais próximos (local). Neste caso, g depende apenas do valor de f na localização (x,y) e T torna-se uma transformação de

níveis de cinza da seguinte forma: $s=T(r)$, sendo r e s correspondentes aos valores dos níveis de cinza de $f(x,y)$ e $g(x,y)$, respectivamente. Tomando como exemplo $s=T(r)$ na Figura 2.4(a), a transformação $T(r)$ gera na imagem resultante um contraste maior devido ao escurecimento e clareamento dos níveis de cinza sobre m , restringindo o numero de valores de níveis de cinza possíveis, no limite, com $s=T(r)$ conforme Figura 2.4(b) a imagem é composta por apenas dois valores de níveis de cinza, claro e escuro.




Fig 2.4 Funções de suavização da imagem. (a) Restringe níveis de cinza. (b) Permite apenas dois níveis claro e escuro.

2.4 Filtros derivativos

O método mais comum de diferenciação no processamento da imagem é o gradiente. Para uma função $f(x,y)$, o gradiente de f na coordenada (x,y) é definida pelo vetor definido em (2.1).

$$\nabla f = [\partial f/\partial x, \partial f/\partial y] \quad (2.1)$$

O módulo do vetor expresso em (2.1) é pela equação (2.2).

$$|\nabla f| = \sqrt{(\partial f/\partial x)^2 + (\partial f/\partial y)^2} \quad (2.2)$$

A expressão em (2.2) é usada como base por várias técnicas de diferenciação de imagens. Considerando, como mostrado na Figura 2-5, que uma vizinhança do ponto P_0 na imagem digital é agora uma matriz de pontos com valores discretos, $V_1 \dots V_9$, o módulo do gradiente pode ser aproximado pela expressão (2.3), considerando apenas duas direções.

$$|\nabla f| = \sqrt{(v_0 - v_7)^2 + (v_0 - v_5)^2} \quad (2.3)$$

Onde as derivadas parciais se tornam o valor absoluto da diferença entre os valores de níveis de cinza dos pontos.

P_1	P_2	P_3
P_4	P_0	P_5
P_6	P_7	P_8

Fig 2-5 Vizinhança de um ponto central P_0 .

O operador derivativo gradiente é especialmente interessante, como será visto mais adiante, para identificar características de contexto de um ponto na imagem que dependem do valor do contraste, como a região das bordas e texturas irregulares. Na região das bordas da imagem o valor do gradiente é elevado.

Capítulo 3

Considerações sobre a teoria dos mapas auto-organizáveis de Kohonen e a implementação do módulo matcher do sistema mammalyzer

Neste capítulo é dada uma breve explanação sobre a teoria dos mapas auto-organizáveis de Kohonen e a forma de sua implementação pelo módulo de casamento de imagens "Matcher" do Mammalyzer, isso se faz necessário para que se discuta mais a frente características de parâmetros em sua implementação, que apresentam inconsistências.

3.1 Princípio biológico do modelo SOM de Kohonen

As redes neurais que obedecem o modelo SOM de Kohonen, imitam os processos que ocorrem no córtex cerebral. O córtex cerebral pode ser considerado um mapa subdividido em regiões que são responsáveis pelo pensamento, por nossos atos conscientes e pela resposta a estímulos do ambiente externo. Essas sub-regiões foram formadas durante nosso aprendizado desde os primeiros anos de vida. O aprendizado passado pode

modificar nosso comportamento bem como produzir alterações estruturais no organismo graças a uma propriedade denominada plasticidade cerebral. Na Figura 3-1 é mostrada a expansão das sub-regiões cerebrais responsáveis pelas pontas dos dedos na mão de um macaco. As sub-regiões 2,3 e 4 que antes do estímulo ocupavam determinada área cortical ocupam agora área maior.

3.2 Método de classificação SOM

As redes neurais baseadas na concepção dos mapas auto-organizativos de kohonen (SOM), são mostradas na Figura 3-1. Inicialmente seus pesos (w_{ij}) contém valores aleatórios. Após uma seqüência valores (padrões) é aplicada a sua entrada. Durante o processo de aprendizagem, a realimentação positiva se estenderá desde a unidade central (vencedora) as demais unidades a uma distribuição finita em torno da unidade central. Na camada de competição, só se permitirá aprender a unidade ganhadora (aquela cujo vetor de pesos mais se parece com o vetor de entrada) e as unidades vizinhas mais próximas.




Fig 3-1 Esquema mostrando ampliação de área cerebral devido a estimulação de membro do corpo de um animal.

Fonte: <http://www.epub.org.br/cm/n05/tecnologia/plasticidade2.html>

Pelo método SOM todas as unidades competitivas que recebem realimentação positiva procedente da unidade ganhadora participam do processo de aprendizagem. Na Figura 3-2 é mostrada a unidade de saída (neurônio) vencedora em amarelo e sua vizinhança em preto. A seta vermelha define o raio da vizinhança, r , que corresponde à quantidade de neurônios vizinhos próximos que participarão do aprendizado junto com o neurônio vencedor. O conjunto de padrões que aparece mais freqüentemente na entrada é o que ocupara mais neurônios na camada de saída. Na Figura 3-2 a seqüência de entrada se parece com a região mapeada na camada de saída.

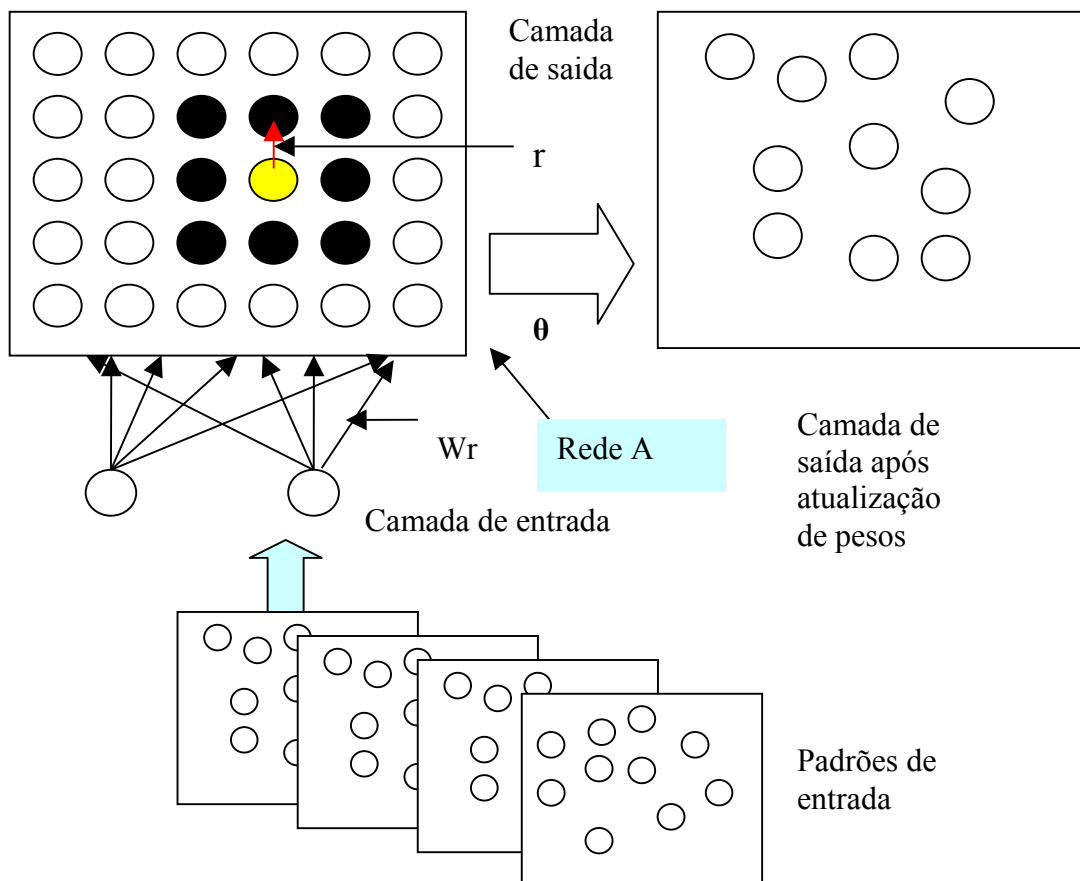


Fig 3-2. Mostrando exemplo de processo de assimilação de padrões por uma RNA baseada no modelo SOM.

3.2.1 Ativação das unidades e aprendizagem

Matematicamente [7], a ativação dos elementos da rede é definida segundo as equações 3.1 e 3.2.

$$\|W-X\| = \min \|W_r - X\| \quad (3.1)$$

Onde W_r corresponde ao peso do r -ésimo neurônio vencedor da rede. X é o conjunto de entradas.

Durante o período de treinamento, cada unidade que tenha atividade positiva dentro da competição gerada pela unidade vencedora participa do processo de aprendizagem. O processo de aprendizagem pode ser descrito pela equação abaixo que representa a dinâmica da alteração dos pesos w :

$$W_{r \text{ atual}} = \lambda h_{rs}(t)(X - W_{r \text{ anterior}}) \quad (3.2)$$

Onde W_r é o vetor de pesos da r -ésima unidade e X é o vetor de entrada, o fator $h_{rs}(t)$ expressa a mudança do peso W com o tempo de aprendizagem. De forma geral, nas aplicações, o desejo é que o aprendizado decresça a medida que aumenta o raio r da vizinhança a forma da função de aprendizado $h_{rs}(t)$ é mostrada na Figura 3-3. O comportamento Gaussiano da função de aprendizagem permite que em $s=r$ o aprendizado seja máximo e decresça a zero a medida que aumenta a distância $\|s-r\|$

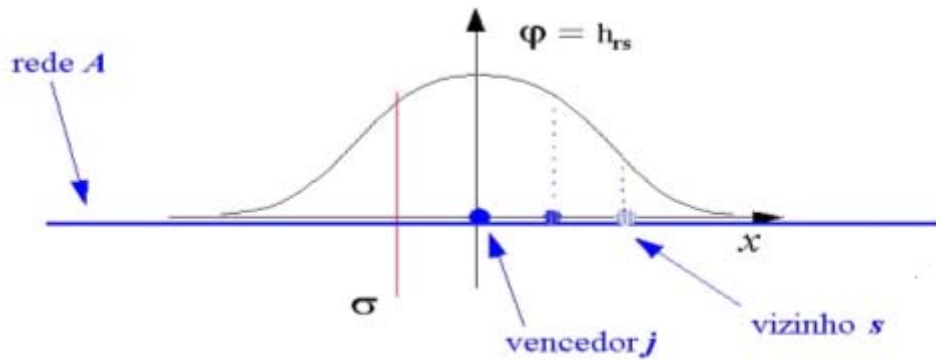


Fig 3-3 Curva de aprendizagem da RNA. A curva define que os neurônios vizinhos ao vencedor, à distância menor que o raio r , tem seus pesos atualizados.

3.3 O fenômeno do agrupamento

Uma das consequências importantes dos resultados obtidos pelos experimentos de Kohonen, é o fenômeno de agrupamento ou "Clustering". A rede agrupa dados que possuem alguma similaridade gerando com isso classes distintas. Cada uma dessas classes se situa em uma região da rede formando sub-areas que possuem tamanhos diferenciados podendo ocupar um tamanho maior ou menor dependendo da frequência com que um padrão de entrada se apresenta. Este agrupamento é decorrente dos ajustes de pesos dos neurônios situados numa fronteira próxima do neurônio vencedor. Isto representa uma evolução em relação ao modelo inicial idealizado por Kohonen em que apenas o neurônio vencedor atualizava seus pesos. Com o novo modelo a rede Kohonen incorpora uma característica de "segregação" podendo desta forma detectar conjuntos de padrões. No entanto esta propriedade apresenta o inconveniente de que o algoritmo de treinamento durante o aprendizado não encontra uma adaptação (Matching) ótima ao padrão de entrada, uma vez que informação similar é reunida em regiões fechadas.

3.4 Agrupamento Local e Global

A representação de informação visual não é feita apenas por contextos locais. Existe o problema de perda de informação no ordenamento topológico: entradas provindas da direção da fronteira do campo visual precisam excitar os neurônios da fronteira no processamento por camadas. Se este ordenamento topológico continua sobre toda a camada sem nenhuma irregularidade (defeito topológico) então a camada é globalmente ordenada: varrendo o campo visual ao longo de alguma linha estreita poder-se-ia excitar uma linha de neurônios que não se auto-intercepta na camada. De forma semelhante, uma organização esta aparentemente em vantagem em termos de processamento de informação.

Isto foi reconhecido por Grosseberg (1976) e por Willshaw e Von der Malsburg (1976), que um pequeno refinamento, o mecanismo de inibição lateral, o qual esta presente em nosso cérebro, é suficiente para encontrar ordenamento topológico local. Isto é conhecido como "arranjo do chapéu mexicano" de conexões internas nas camadas, por meio deste arranjo as conexões mais próximas do neurônio vencedor atualizam seus pesos enquanto as mais distantes são inibidas.

Uma importante característica deste arranjo é que os neurônios da fronteira tem a tendência de se ativarem simultaneamente. Então, apenas por meio do aprendizado Hebbiano, as conexões do tipo "feedforward" ativas dentro da camada com os neurônios da fronteira tornam-se gradualmente similares umas com outras, e ensinam-se mutuamente a responder a entradas na fronteira.

3.5 Modificação de regra de aprendizagem SOM

A característica de clusterização deve ser removida para que a

rede neural possa estar apta a reconhecer contextos locais, como em aplicações envolvam conjunto de padrões que tenham comportamento elástico [8]. Fisicamente esse comportamento pode ser modelado como um sistema de segunda ordem descrito pelas equações de Lagrange [9]. Para mapear esse sistema de segunda ordem na RNA, uma vez determinado o neurônio vencedor, sua vizinhança deve ser adaptada na mesma direção que se desloca o neurônio vencedor e não propriamente em sua direção, isto é mostrado na equação (3.3)

$$W_{r \text{ atual}} = W_{r \text{ anterior}} + h_{rs}(t) \cdot (-\text{dist}(n, \text{vencedor})/r)^2 \cdot (X - W_{\text{vencedor}}) \quad (3.3)$$

Onde r , sendo o raio adaptativo da curva de Gauss, determina a região vizinha ao neurônio vencedor. Desta forma, através da contração de r , a rede neural incorpora a característica de elasticidade desejada.

A grande surpresa desta metodologia, é que a combinação do arranjo do tipo “chapéu mexicano” com aprendizado hebbiano intercamadas resolve o problema da estabilidade ao mesmo tempo em que habilita a rede a adquirir novos conhecimentos.

3.6 Implementação do método dos mapas auto-organizativos

3.6.1 Algoritmo de Kohonen

Passo 0. Inicialização dos pesos w_{ji} (*aleatória*).

Inicialização dos parâmetros de vizinhança

Inicialização dos parâmetros de aprendizagem

Passo 1. WHILE condição de parada for falsa, EXECUTAR Passo 2-8

Passo 2. PARA cada vetor de entrada \mathbf{x} , EXECUTAR Passo 3-5.

Passo 3. PARA cada j , calcula:

$$D(j) = \sum_i (w_{ji} - x_i)^2$$

Passo 4. Calcular o índice J tal que $D(J)$ seja mínimo

Passo 5. PARA todas as unidades j dentro duma vizinhança de J , e para todos os i :

$$w_{ji}(t+1) = w_{ji}(t) + h(x_i - w_{ji}(t))$$

Passo 6. Atualização da velocidade de aprendizagem

Passo 7. Redução do raio r da vizinhança topológica

Passo 8. Teste à condição de parada

3.6.2 Simulação do algoritmo

A seguir é apresentado uma pequena simulação em uma rede

SOM composta de dois neurônios de entrada e dois de saída, ilustrando a aplicação de um padrão de entrada representado por um vetor de quatro elementos (X_1, X_2, X_3, X_4) :

Dados os seguintes vetores de entrada, $(1,1,0,0)$, $(0,0,0,1)$, $(1,0,0,0)$, $(0,0,1,1)$

Passo 0. Matriz dos pesos iniciais

$$\begin{matrix} .2 & .8 \\ .6 & .4 \\ .5 & .7 \\ .9 & .3 \end{matrix} \begin{pmatrix} \\ \\ \\ \end{pmatrix}$$

Raio inicial $R=0$

Coefficiente de aprendizagem $H(0) = 0.6$

Passo 1. Início de treinamento

Passo 2. Para o vetor 1 $(1,1,0,0)$, EXECUTAR passo 3-5

Passo 3. $D(1) = (.2-1)^2 + (.6-1)^2 + (.5-0)^2 + (.9-0)^2 = 1.86$

$$D(2) = (.8-1)^2 + (.4-1)^2 + (.7-0)^2 + (.3-0)^2 = 0.98$$

Passo 4. O vetor de entrada esta mais próximo do neurônio 2

Portanto $J=2$

Passo 5. Atualização dos pesos do neurônio vencedor:

$$W_{2i}(1) = W_{2i}(0) + 0.6(x_i - W_{2i})$$

$$W_{2i}(1) = 0.4W_{2i}(0) + 0.6x_i$$

A matriz de pesos é portanto:

$$\begin{pmatrix} 0.2 & .92 \\ 0.6 & .76 \\ 0.5 & .28 \\ 0.9 & .12 \end{pmatrix}$$

Passo 2. Para o vetor 2 (0,0,0,1), EXECUTAR passo 3-5

Passo 3. $D(1) = (.2-0)^2 + (.6-0)^2 + (.5-0)^2 + (.9-1)^2 = 0.66$

$$D(2) = (.92-0)^2 + (.76-0)^2 + (.28-0)^2 + (.12-1)^2 = 0.98$$

Passo 4. O vetor de entrada está mais próximo do neurônio 1

Portanto J=1

Passo 5. Atualização dos pesos do neurônio vencedor:

$$W_{1i}(1) = W_{1i}(0) + 0.6(x_i - W_{1i})$$

$$W_{1i}(1) = 0.4W_{1i}(0) + 0.6x_i$$

A matriz de pesos é portanto agora:

$$\begin{pmatrix} .08 & .92 \\ .24 & .76 \\ .20 & .28 \\ .96 & .12 \end{pmatrix}$$

Passo 2. Para o vetor 3 (1,0,0,0), EXECUTAR passo 3-5

Passo 3. $D(1) = (.08-1)^2 + (.24-0)^2 + (.20-0)^2 + (.96-0)^2 = 1.8656$

$$D(2) = (.92-1)^2 + (.76-0)^2 + (.28-0)^2 + (.12-0)^2 = 0.6768$$

Passo 4. O vetor de entrada esta mais próximo do neurônio 2

Portanto J=2

Passo 5. Atualização dos pesos do neurônio vencedor:

$$W_{2i}(1) = W_{2i}(0) + 0.6(x_i - W_{2i})$$

$$W_{2i}(1) = 0.4W_{2i}(0) + 0.6x_i$$

A matriz de pesos é portanto agora:

$$\begin{pmatrix} .08 & .968 \\ .24 & .304 \\ .20 & .112 \\ .96 & .048 \end{pmatrix}$$

Passo 2. Para o vetor 4 (0,0,1,1), EXECUTAR passo 3-5

Passo 3. $D(1) = (.08 - 0)^2 + (.24 - 0)^2 + (.20 - 1)^2 + (.96 - 1)^2 = 0.7056$

$$D(2) = (.968 - 0)^2 + (.304 - 0)^2 + (.112 - 1)^2 + (.048 - 1)^2 = 2.724$$

Passo 4. O vetor de entrada esta mais próximo do neurônio

Portanto J=1

Passo 5. Atualização dos pesos do neurônio vencedor:

$$W_{2i}(1) = W_{2i}(0) + 0.6(x_i - W_{2i})$$

$$W_{2i}(1) = 0.4W_{2i}(0) + 0.6x_i$$

A matriz de pesos é portanto agora:

$$\begin{pmatrix} .032 & .968 \\ .096 & .304 \\ .680 & .112 \\ .984 & .048 \end{pmatrix}$$

Passo 6. Redução dos coeficientes de aprendizagem

$$H = 0.5(0.6) = 0.3$$

As equações de atualização de pesos são agora:

$$W_{ji}(t+1) = W_{ji}(t) + 0.3(X_i - W_{ji}(t)) = 0.7W_{ji}(t) + 0.3X_i$$

A matriz de pesos após a segunda instância de treino é dado por:

$$\begin{pmatrix} .016 & .980 \\ .047 & .360 \\ .630 & .055 \\ .999 & .24 \end{pmatrix}$$

Modificando o procedimento de aprendizagem de modo que o coeficiente de aprendizagem H decresça geometricamente de 0.6 para 0.01 com 100 iterações se obtém os seguintes resultados:

Iteração 0, a matriz de pesos é:

$$\begin{pmatrix} .2 & .8 \\ .4 & .4 \\ .5 & .7 \\ .9 & .3 \end{pmatrix}$$

Iteração 1, a matriz de pesos é:

$$\begin{pmatrix} .32 & .970 \\ .96 & .300 \end{pmatrix}$$

.680 .110
.984 .048

Iteração 2, a matriz de pesos é:

.0053 .990
-.1700 .3000
.7000 .0200
1000 .0086

Iteração 10, a matriz de pesos é:

15e-7 10000
46e-7 .3700
.6300 5.4e-7
1000 23e-7

Iteração 50, a matriz de pesos é:

15e-19 10000
57e-15 .4700
.5300 66e-15
1000 28e-15

Iteração 100, a matriz de pesos é:

67e-17 10000
20e-17 .4900

.5100 23e-16
1000 10e-16


Os pesos das matrizes parecem convergir para a matriz:

$$\begin{bmatrix} 0.0 & 1.0 \\ 0.0 & 0.5 \\ 0.5 & 0.0 \\ 1.0 & 0.0 \end{bmatrix}$$

Sendo a 1ª coluna constituída pela média das componentes dos vetores colocados no **cluster 1** e a 2ª constituída pela média dos dois vetores colocados no **cluster 2**. Portanto acaba-se verificando o seguinte agrupamento:

Neurônio 1:(0,0,01),(0,0,1,1) Neurônio 2: (1,1,0,0),(1,0,0,0)


3.7 Diagrama de blocos de funcionamento do módulo de casamento de imagens(Matcher)



3.8 Detalhamento do módulo de entrada da rede neural, RNA

3.8.1 Extração e seleção de grupo de pixels na imagem nativa:

Com base na idéia de mapeamento denso da RNA. Uma vez adquirida a imagem nativa, os pixels relevantes são armazenados nos pesos iniciais da RNA segundo o critério mostrado no esquema abaixo:



1- Obtém seqüencialmente grupos de pixels da imagem nativa, por meio de uma janela que percorre a imagem e seleciona os pontos que encontram-se em uma vizinhança com gradiente estes pixels são mapeados como neurônios na RNA.


2-Inicializa pesos da rede neural com grupo de pixels relevantes.

3-Extraí características de contexto local do ponto: norma do gradiente e gradiente normalizado.

3.8.2 Extração e seleção de grupo de pixels na imagem com contraste:

De forma semelhante a extração de pixels na imagem nativa, os pixels relevantes na imagem com contraste são carregados nas entradas da

rede neural segundo o critério mostrado no esquema abaixo:



1- Obtém seqüencialmente grupos de pixels da imagem com contraste, por meio de uma janela que percorre a imagem e seleciona os pontos que encontram-se em uma vizinhança com gradiente estes pixels são mapeados como padrões de entrada da RNA.

2- Padrões são aplicados as entradas da RNA de forma aleatória.

3- Extrai características de contexto local do ponto: norma do gradiente e gradiente normalizado.

3.9 Detalhamento do módulo de processamento da rede neural, RNA

Cada neurônio da camada de saída, segue o modelo na Figura 3-3.1 possuindo sinapses $W(0)$, $W(1)$, $W(2)$ que representam características obtidas anteriormente, de coordenada X, Y e escala de cinza.




Fig 3-3.1 Representação de neurônio com 3 sinapses(pesos)

As características baseadas no gradiente do ponto terão importância fundamental em futura análise sobre os problemas de correspondência envolvidos quando se trata de imagens com grande quantidade de textura. A partir das características armazenadas (obtidas da imagem nativa) acima citadas obtém-se as respectivas distâncias em relação aos padrões apresentados sucessivamente nas entradas (obtidos da imagem destino) e com estas distâncias se efetua o cálculo de uma média ponderada $F(\text{dist})$ da seguinte forma:

$$F = \frac{sd * \text{SpatDistF} + cd * \text{ColDistF} + cad * \text{ColAVDistF} + gd * \text{GradNormF} + gsd * \text{detGradScProd} + qme * \text{QuadErrorF}}{\text{SpatDistF} + \text{ColDistF} + \text{GradScProdF} + \text{GradNormF} + \text{ColAVDistF} + \text{QuadErrorF}}$$

onde:

$$sd = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (gl_1 - gl_2)^2} \quad (3.4)$$

A expressão (3.4) corresponde a distância entre os pontos na imagem original e seu nível de cinza (x_1, y_1, gl_1) em relação aos pontos na imagem destino e seu respectivo nível de cinza (x_2, y_2, gl_2) ;

$cd = |g_{l_1} - g_{l_2}|$, que é a distância absoluta entre os níveis de cinza correspondentes aos pixels na imagem original(neurônios) e os pixels na imagem destino(padrões);

O valor de cad é a distância entre as médias de níveis de cinza ao redor de uma janela centrada em pixel correspondente ao neurônio e níveis de cinza correspondentes ao pixel correspondente ao padrão de treinamento da entrada;

$$gd = |normg1 - normg2| =$$

$$= \left| \left(\sqrt{\left(\sum_{x=1}^M \Delta g_{l_{1x}} \right)^2 + \left(\sum_{y=1}^N \Delta g_{l_{1y}} \right)^2} \right) - \left(\sqrt{\left(\sum_{x=1}^M \Delta g_{l_{2x}} \right)^2 + \left(\sum_{y=1}^N \Delta g_{l_{2y}} \right)^2} \right) \right| \quad (3.5)$$

que é a distância absoluta entre as normas dos gradientes entre o neurônio posicionado na imagem nativa e o padrão localizado na imagem destino em uma janela $M \times N$ ao redor destes pixels.

$$gsd = \left(\left(\frac{\sum_{x=1}^M \Delta g_{l_{1x}}}{normg1} \right) * \left(\frac{\sum_{x=1}^M \Delta g_{l_{2x}}}{normg2} \right) + \left(\frac{\sum_{y=1}^N \Delta g_{l_{1y}}}{normg1} \right) * \left(\frac{\sum_{y=1}^N \Delta g_{l_{2y}}}{normg2} \right) \right) \quad (3.6)$$

A expressão (3.6) é o ângulo entre os gradientes do pixel correspondente ao neurônio analisado e o pixel que representa o respectivo padrão em questão;

O valor de qme é o erro médio quadrático entre níveis de cinza gl de pixel correspondente a neurônio e padrão na imagem com contraste.

Os pesos são parâmetros definidos conforme tipo de imagem.

A partir do cálculo da média ponderada F , se pode obter a partir do mínimo valor de F a ativação do neurônio N e a consequente definição do grupo de pixels ligados a este neurônio como correspondentes aos padrões da imagem com contraste apresentados nos neurônio de entrada.

3.10 Análise dos parâmetros relevantes para descrição de textura presente nas imagens MRI

A análise do aspecto de textura envolvido na similaridade local e global de duas regiões equivalentes, em uma mesma imagem em instantes diferentes, que apresenta deformações não-lineares, conforme [8], dependem fortemente dos seguintes parâmetros:

Gradiente: Tem por objetivo descrever, por meio de sua variação, de regiões limítrofes da imagem. Esta delimitação de fronteira é particularmente importante no momento de se definir os pontos mais externos no momento de se deformar a imagem original. Desta forma, se define o lugar exato da região das bordas da imagem.

Norma do gradiente: Esta medida quantitativa serve como parâmetro de comparação para verificar a existência dos limites de regiões na imagem descritos anteriormente.

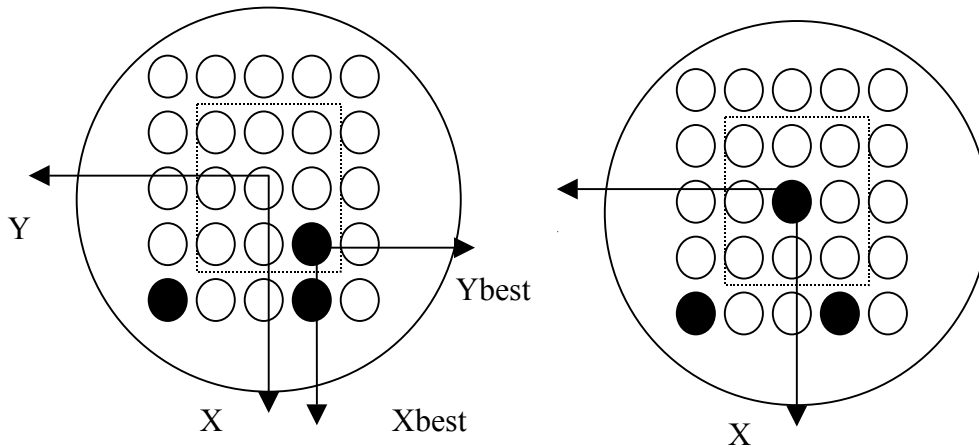

Ângulo entre gradientes: Esta medida qualitativa para verificar se um grupo de pontos como um todo define uma direção de variação idêntica em uma região da imagem e em outra num instante diferente.

Em [12], puderam ser comprovados bons resultados com o uso dos parâmetros acima em uma RNA de duas camadas SOM.

3.11 Ambigüidade na identificação de pontos em duas imagens em instantes diferentes


O modelo de rede neural adotado falha na identificação de pontos correspondentes entre duas imagens quando as respectivas imagens possuem grande quantidade de textura, devido ao fato de a rede neural ter

parâmetros fortemente dependentes da estrutura local da imagem, o gradiente. A grande quantidade de textura pode ser descrita por uma distribuição de gradiente com irregularidades ao longo da imagem [11]. Isto pode ser visto nas imagens MRI abaixo, representando a mesma imagem em dois momentos diferentes, nas regiões irregulares mais escuras, correspondentes à parte de tecido muscular circundadas pela região branca.




Grupo de pontos tomados de imagem nativa

Grupo de pontos tomados de imagem com contraste



Varição de níveis de cinza ao longo de X



Varição de níveis de cinza na imagem com contraste

Fig 3-4 Esquema mostrando tentativa de identificação de grupos de pontos correspondentes pela rede neural som.

Logo abaixo das imagens das tomografias são ilustrados os

grupos de pontos identificados pela rede neural como equivalentes, abaixo uma análise mais detalhada do problema. Medidas de similaridade utilizadas baseadas nos vetores de gradiente, acabam gerando informação falsa na situação em que ocorre variação na escala de cinza nas direções X e Y, semelhante as que ocorrem em regiões no interior da borda, situação esta verificada na região de tecido muscular conforme ilustrado nas duas imagens na Figura 3-4. Na Figura 3-5, é mostrada os contornos de uma imagem com pequenas texturas bem como o gráfico do gradiente na direção x. Pode-se notar uma grande variação do gradiente seguindo-se a isso uma pequena variação, pegando como exemplo a direção da coordenada x (x=205 à x=215).




Fig 3-5 Na figura superior são mostrados contornos de uma das partes da mama, na figura abaixo variação do gradiente na direção X de X=205 à X=215.




Fig 3-6 Figura mostrando detalhes do contorno da imagem nativa. Nota-se pequenos contornos na parte central da imagem.




Fig 3-7 Figura mostrando detalhes do contorno da imagem com contraste. Nota-se, também, pequenos contornos na parte central da imagem.

Capítulo 4

Escala espacial e filtros de difusão

No final do capítulo 3 foi mostrado uma inconsistência no modelo de RNA implementado pelo módulo "Matcher" decorrente do excesso de informações que representam as pequenas texturas distribuídas ao longo dos contornos mais externos da imagem MRI de mama. Desta forma se faz necessário a separação de informação relevante que define a forma da imagem de informação espúria semelhante a ruído, que são as pequenas texturas. Em virtude disso é apresentado neste capítulo um modelo de filtro espacial que se baseia na abordagem da separação da informação da imagem em escalas. Em primeiro lugar é mostrado formalmente o modelo matemático da escala espacial e em seguida o filtro propriamente dito baseado no modelo de difusão anisotrópica não-linear que utiliza os conceitos de escala espacial para eliminar as pequenas texturas da imagem.

4.1 Teoria da escala espacial no contexto da análise de imagens

Muitos problemas existentes em análise de imagem, derivam da separação de informação relevante e não-relevante presentes na imagem. A imagem deste modo pode ser separada em diferentes níveis de escala representando em cada nível uma quantidade de detalhes com diferentes graus de relevância. Pela comparação de estruturas com diferentes escalas

obtém-se uma hierarquia de estruturas de imagem, a qual facilita sua posterior interpretação. A escala espacial é uma forma de representação da imagem com um contínuo de escalas, incluindo a imagem original f dentro de versões simplificadas, modificadas gradualmente dela, $\{T_t f \mid t \geq 0\}$, onde t é o parâmetro de escala, isto gera uma série de propriedades de suavização e invariância. Uma importante propriedade é a recursividade, para $t=0$ a representação na escala espacial obtém a imagem original f , e a filtragem pode ser separada dentro de uma sequência de banco de filtros expressos por (4.1) e (4.2).

$$T_0 f = f \quad (4.1)$$

$$T_{t+s} f = T_t (T_s f) \quad \forall s, t \geq 0 \quad (4.2)$$

Esta propriedade é também as vezes referida como propriedade de semigrupos.

A redução de informação surge do desejo de que durante o processo de aplicação da transformação envolvendo suavização, não sejam gerados artefatos visuais, quando se passa de uma representação mais fina para uma mais grosseira da imagem. Desta forma com uma escala grosseira, não se pode ter estruturas adicionais as quais são geradas pelo método de filtragem utilizado e não por estruturas presentes nas escalas mais finas, a escala na imagem pode ser visualizada como uma série de camadas onde cada camada representa a mesma imagem com diferentes níveis de detalhe, como mostrado na Figura 4-1.




Fig 4-1 Esquema mostrando segmentação da imagem como um arranjo de múltiplas camadas

4.2 Representação multi-escala da informação da imagem

A idéia básica por trás da representação multi-escala de imagens é incluir o sinal original dentro de uma família de sinais derivados de um único parâmetro. Um requisito crucial para representação destas estruturas é que as estruturas em escala mais grosseira necessitam ser simplificações das estruturas correspondentes em escalas mais finas, eles não podem ser fenômenos "acidentais" criados pelo método de suavização. Na Figura 4-2 é possível visualizar uma família de sinais derivados do sinal original [14].




Fig 4-2 Esquema mostrando sinal original da imagem na parte superior e múltiplos sinais derivados conforme diminui a escala espacial.

4.2.1 Representação formal da escala-espacial

Antes de se introduzir aspectos do filtro de difusão propriamente dito algumas definições preliminares se fazem necessárias, estas definições inicialmente se baseiam em modelos lineares de representação de imagens. A

representação da escala-espacial é um tipo especial de representação multi-escala que compreende um parâmetro de escala contínuo e preserva a mesma amostragem espacial em todas as escalas. A representação na escala espacial esta incluído o sinal original e uma família de parâmetros de sinais derivados oriundos de operações de convolução com uma família de núcleos Gaussianos com um único parâmetro de largura crescente.

Formalmente, a representação de uma escala espacial linear de um sinal contínuo é construída da seguinte forma:

Seja $f: \mathfrak{R}^N \rightarrow \mathfrak{R}$ representando um dado sinal, sua representação na escala espacial é então $L: \mathfrak{R}^N \times \mathfrak{R}_+ \rightarrow \mathfrak{R}$ é definido por $L(\cdot; 0) = f$ e por (4.3).

$$L(\cdot; t) = g(\cdot; t) * f \quad (4.3)$$

O parâmetro $t \in \mathfrak{R}_+$ é o parâmetro de escala, e $g: L: \mathfrak{R}^N \times \mathfrak{R}_+ \setminus \{0\} \rightarrow \mathfrak{R}$ é o núcleo Gaussiano; em dimensões arbitrárias é descrito na forma da equação (4.4), e cujas definições podem ser vistas em **[13]**.

$$g(x; t) = \frac{1}{(2\pi t)^{N/2}} e^{-X^T X / (2t)} = \frac{1}{(2\pi t)^{N/2}} e^{-\sum_{i=1}^N x_i^2 / (2t)} \quad (x \in \mathfrak{R}^N, x_i \in \mathfrak{R}). \quad (4.4)$$

A raiz quadrada do parâmetro de escala, $\sigma = \sqrt{t}$, é o desvio padrão de núcleo g , e é uma medida natural da escala espacial em um sinal submetido a processo de suavização na escala t . A família de escala espacial L pode equivalentemente ser definida como solução para a equação de difusão, descrita pela equação (4.5), com condição inicial $L(\cdot; 0) = f$, a qual é uma bem conhecida equação da física, que descreve como a distribuição de calor L evolui com o tempo t em uma média homogênea com condutividade uniforme,

dada uma distribuição inicial de calor $L(\cdot;0) = f$;

$$\partial_t L = \frac{1}{2} \nabla^T \nabla L = \frac{1}{2} \sum_{i=1}^N \partial_{x_i^2} L \quad (4.5)$$

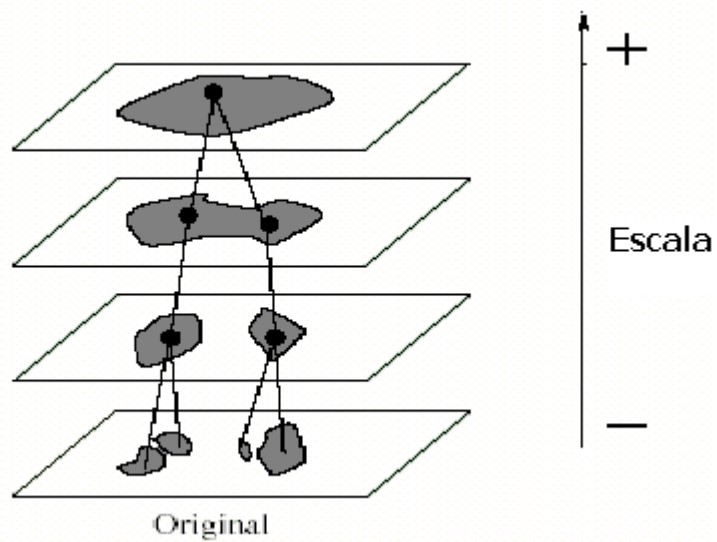


Fig 4-3. Esquema mostrando distinção entre níveis de detalhe entre escalas maiores e menores.

A Figura 4-3 mostra o resultado da aplicação do processo de

suavização em um sinal unidimensional com diferentes escalas. Nota-se que estas sucessivas suavizações capturam a noção intuitiva dos sinais tornando-se gradualmente mais suavizados.

Desta representação da escala espacial, as derivadas das múltiplas escalas espaciais podem ser definidas pela equação (4.6):

$$L_{X^n}(\cdot; t) = \partial_{X^n} L(\cdot; t) = g_{X^n}(\cdot; t) * f, \quad (4.6)$$

onde g_{X^n} denota uma derivada de alguma ordem n . Em termos de integrais explícitas, a operação de convolução mostrada pela equação (4.6) é reescrita na equação (4.7).

$$L_{X^n}(x; t) = \int_{X^f \in \mathfrak{R}^N} g_{X^n}(x - x^f; t) f(x^f) dx^f = \int_{X^f \in \mathfrak{R}^N} g_{X^n}(x; t) f(x - x^f) dx^f \quad (4.7)$$

Esta representação tem uma forte propriedade de regularidade. Se f é representado por alguma função polinomial, se existem constantes $C_1, C_2 \in \mathfrak{R}_+$ tal que:

$$|f(x)| \leq C_1 (1 + x^T x)^{C_2} \quad (x \in \mathfrak{R}^n), \quad (4.8)$$

então para a integral é garantida a condição de convergência para algum $t > 0$. Desta forma, a equação (4.6) providencia uma bem definida forma de se construir derivadas multi-escala de uma função f . Desta forma a representação da escala-espacial dada pela equação (4.3) para cada $t > 0$ é tratada como infinitamente diferenciável (C^∞).

4.3 Representação multi-escala de sinais discretos

A característica finita dos sinais de imagem impõe as mesmas condições aplicáveis a sinais discretos. Considerando-se também que em determinada região na imagem delimitada por uma borda a escala-espacial pode ser considerada linear, a definição de análise multi-escala [14] para sinais discretos parte do seguinte princípio:

Dado $L : \mathfrak{R}^N \times \mathfrak{R}_+ \rightarrow \mathfrak{R}$

a escala espacial de um sinal contínuo

$f : \mathfrak{R}^N \rightarrow \mathfrak{R}$

é representada pela convolução do sinal original com um núcleo de transformação Gaussiano, tal que:

$$L(.;t) = g(.;t) * f(.) \quad (4.9)$$

onde

$$g(x;t) = \frac{1}{\sqrt{2\pi t^N}} e^{-(x_1^2 + \dots + x_N^2) / 2t} \quad (4.10)$$

ou por meio da solução da equação de difusão:

$$\partial_t L = \frac{1}{2} \nabla^2 L, \text{ com condição inicial } L(.;0) = f$$

Tendo em vista as definições das equações (4.9) e (4.10), é

possível desenvolver uma teoria completa para sinais discretos baseado no princípio de que o número de extremos locais no sinal não necessitam incrementar com a escala.

Definição 1: Analisando inicialmente o caso unidimensional, um núcleo de transformação $K : Z \rightarrow \mathfrak{R}$ é dito um núcleo de transformação de uma escala espacial se para algum sinal $f_{in} : Z \rightarrow \mathfrak{R}$ o número de extremos locais em $f_{out} = K * f_{in}$ não excede o número de extremos locais em f_{in} . Quanto a classificação, um núcleo de transformação $K : Z \rightarrow \mathfrak{R}$ é um núcleo de uma escala espacial se e somente se sua função geradora

$\varphi_k(z) = \sum_{n=-\infty}^{\infty} K(n)z^N$, tem a forma **[14]** expressa em (4.11).

$$\varphi_k(z) = cz^k e^{(q_1 z^{-1} + q_1 z)} \prod_{i=1}^{\infty} \frac{(1 + \alpha_i)(1 + \delta_i z^{-1})}{(1 - \beta_i z)(1 - \gamma_i z^{-1})}, \quad (4.11)$$

$c > 0$;

$$k; \in Z; q_{-1}, q_1, \alpha_i, \beta_i, \gamma_i, \delta_i \geq 0, \beta_i, \gamma_i < 1; \sum_{i=1}^{\infty} (\alpha_i + \beta_i + \gamma_i + \delta_i) < \infty$$

A interpretação deste resultado é que os núcleos de transformação discretos seguem a seguinte propriedade de decomposição:

1. As transformações discretas primitivas de suavização de sinais discretos $Z \rightarrow \mathfrak{R}$ originam cinco tipos de primitivas de linearidade e invariância ao deslocamento em transformações de suavização;

- A média ponderada de dois pontos ou suavização binomial generalizada são dados pelas expressões (4.12) e (4.13).

$$f_{out}(x) = f_{in}(x) + \alpha_i f_{in}(x-1), (\alpha \geq 0), \quad (4.12)$$

$$f_{out}(x) = f_{in}(x) + \delta_i f_{in}(x+1), (\delta \geq 0), \quad (4.13)$$

- Média móvel ou filtro recursivo de primeira ordem são expressos em (4.14) e (4.15).

$$f_{out}(x) = f_{in}(x) + \beta_i f_{in}(x-1), (0 \leq \beta_i \leq 1), \quad (4.14)$$

$$f_{out}(x) = f_{in}(x) + \gamma_i f_{in}(x+1), (0 \leq \gamma_i < 1), \quad (4.15)$$

-suavização infinitesimal ou suavização por difusão

-reescalamiento e translação

Um núcleo discreto de transformação é um núcleo de transformação de escala espacial se e somente se pode ser decomposto dentro das transformações primitivas descritas anteriormente. Se a definição 1 é combinada com o requisito de que a família de transformações de suavização precisam possuir uma propriedade de semigrupo e tem um parâmetro de escala contínuo, então o resultado é que há em princípio apenas uma forma de se construir uma escala espacial para sinais discretos.

A escala espacial para sinais discretos é caracterizada com as

seguintes condições necessárias e suficientes:

Dado um sinal $f : Z \rightarrow \mathfrak{R}$, sendo $L : Z \times \mathfrak{R}_+ \rightarrow \mathfrak{R}$ uma família de funções de um único parâmetro definidas por:
 $L(x;0) = f(x), (x \in Z)$ e

$$L(x;t) = \sum_{n=-\infty}^{\infty} T(n;t) f(x-n), \quad (4.16)$$

$(x \in Z, t > 0)$ onde $T : Z \times \mathfrak{R}_+ \rightarrow \mathfrak{R}$ é uma família de funções simétricas de um único parâmetro satisfazendo a propriedade do semi-grupo $T(.,s) * T(.,t) = T(.,s+t)$ e o critério de normalização $\sum_{n=-\infty}^{\infty} T(n;t) = 1$. Para algum sinal f e algum $t_2 > t_1$ é requerido que o número de extremos locais (zero-crossings) em $L(x,t_2)$ não necessite exceder o número de extremos locais em $L(x,t_1)$, então são atendidas as condições necessárias e suficientes,

$$T(n;t) = e^{-\alpha t} I_n(\alpha t) \quad (4.17)$$

para algum α real e não negativo, onde I_n é a função modificada de Bessel de ordem inteira. Este núcleo de transformação T é denominado analogia discreta do núcleo Gaussiano.

O termo "suavização por difusão" pode ser entendido pela noção de que a família de escalas espaciais L satisfaz a versão semidiscreta da equação de difusão:

Definição 3: Formulação por difusão da escala espacial discreta. A representação $L : Z \times \mathfrak{R}_+ \rightarrow \mathfrak{R}$ dado por (4.16) com $T : Z \times \mathfrak{R}_+ \rightarrow \mathfrak{R}$ de acordo com (4.17) e $\alpha=1$ o sistema de equações diferenciais ordinárias é dado pela equação (4.18).

$$\partial_t L(x;t) = \frac{1}{2}(L(x+1;t) - 2L(x;t) + L(x-1;t)) = \frac{1}{2}(\nabla_2^2 L)(x;t) \quad (4.18)$$

com condição inicial $L(x;0)=f(x)$ para algum sinal discreto $f: Z \rightarrow \mathfrak{R}$ em l_1

Para o caso bidimensional, pode-se discretizar a expressão da difusão [15] conforme mostrado na equação (4.19).

$$\partial_t L(x,y;t) = \frac{1}{2}[(L(x+1,y;t) + L(x-1,y;t) + L(x,y+1;t) + L(x,y-1;t) - 2L(x,y;t)] \quad (4.19)$$

$$\text{Expressando como convolução de sinais: } \partial_t L = \frac{1}{2} L * G \quad (4.20)$$

$$\text{Onde } G = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -2 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

A forma matricial facilita a interpretação da difusão, quando da aplicação na imagem em si como será visto mais à frente.

4.4 Representação de detalhes finos em imagens por meio de modelo vetorial

Anteriormente foi feita uma abordagem mais aprofundada da representação dos aspectos globais e locais da imagem por meio de definições formais contidas na teoria de escala espacial. No entanto para o presente

trabalho restringe-se a abordagem da representação da imagem com por meio de uma estrutura composta por autovetores em duas dimensões e derivadas de primeira ordem. A identificação de características como cantos e medição da coerência local de estruturas em imagens pode ser feita por métodos derivativos tais como os baseados na variação do gradiente na vizinhança de algum ponto.

Por meio de um ponto P_0 se obtém a variação do gradiente ∇u , em sua vizinhança. Estruturas compostas por detalhes podem ser vistas como curvas com grande quantidade de picos e vales como mostra a Figura 3-5. Tendo em vista este aspecto, estas estruturas podem ser representadas em toda sua extensão por um tensor D com uma base ortonormal formado pelos autovetores V_1 e V_2 em que $V_1 \parallel \nabla u$ e $V_2 \perp \nabla u$ cujos autovalores correspondentes são $\mu_1 = |\nabla u|^2$ e $\mu_2 = 0$. Isto é representado na Figura abaixo em que se pode notar que V_1 aponta para direção da variação da curva enquanto V_2 aponta para a direção do deslocamento da curva. Por meio dos autovalores μ_1 e μ_2 se pode identificar determinadas regiões na imagem por meio das seguintes relações: com $\mu_1 \geq \mu_2 \geq 0$ se observa que V_1 aponta para a maior flutuação da curva que representa a variação dos níveis de cinza e V_2 aponta para a orientação da curva, $\mu_1 = \mu_2 = 0$ em áreas sem variação na textura, em bordas estreitas da imagem tem-se $\mu_1 \gg \mu_2 = 0$, em regiões de canto $\mu_1 \geq \mu_2 \gg 0$ e em estruturas que apresentam variação textura nas duas direções (estruturas anisotrópicas) $(\mu_1 - \mu_2)^2 \gg 0$, sendo possível assim se ter uma medida da coerência local da estrutura e por conseqüência avaliar a continuidade de um determinado contorno ou se trata-se de uma distribuição irregular consistindo neste caso em ruído. Em [16] é mostrada explicitamente a relação dessa representação de textura com o parâmetro de escala t . Detalhes em regiões curvas podem ser descritos satisfatoriamente por modelos baseados em contorno ativo [22].




Fig 4-4 Esquema mostrando de forma genérica distribuição dos níveis de cinza em uma imagem e o modelo vetorial representado a direção de sua variação.

4.5 Princípio físico do processo de difusão

O processo físico da difusão, tendo como exemplo a distribuição do calor sobre uma placa de metal, é descrito na Figura 4-5. O calor em uma região (massa) se redistribui como consequência da diferença de temperatura nesta região.

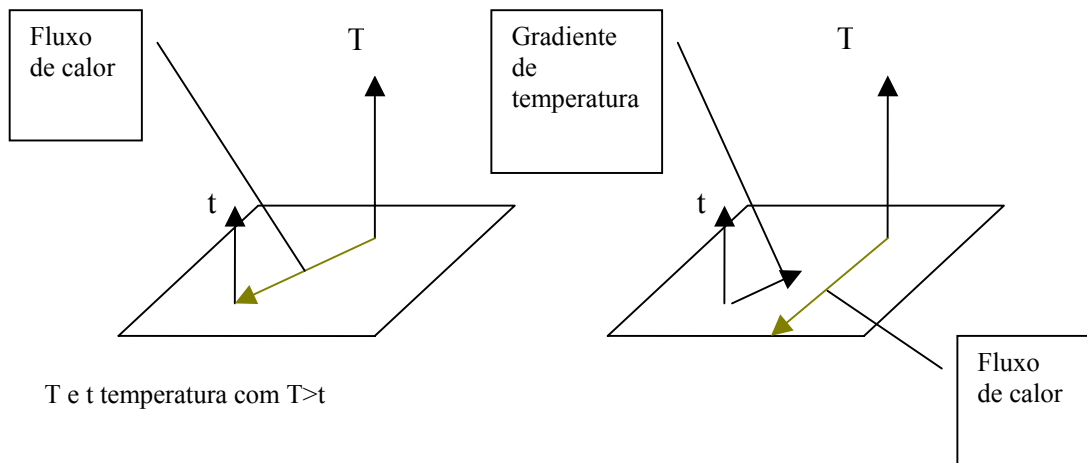


Fig 4-5 Esquema mostrando processo de propagação do calor em regiões de uma placa metálica.

O fluxo de calor esta em direção oposta ao gradiente de temperatura. Isto é formalizado pela expressão abaixo:

$$D = -j \nabla T \quad (4.21)$$

Onde ∇T é o gradiente de temperatura. Se nenhuma quantidade de calor é adicionada ou perdida pela placa, sua quantidade de calor é conservada. Isto é formalizado através da expressão abaixo:

$$\partial_t T + \nabla \cdot j = 0 \quad (4.22)$$

Raciocínio análogo é feito para concentração de massa(L), em que regiões com diferentes valor de L tendem ao equilíbrio de massa.

4.6 Filtragem baseada em difusão não-linear

A eliminação de pequenos gradientes enquanto aspectos globais da imagem são preservados recai na utilização de métodos adaptativos de difusão não-linear, baseados nas propriedades locais da imagem, como a existência de bordas ou pequenas linhas de fluxo. O modelo de Perona-Malik se adequa bem a este propósito, a seguir há uma discussão mais detalhada.

4.6.1 O modelo de Perona-Malik

As limitações impostas a filtragem de difusão linear como os efeitos de deformação da imagem provocadas por "blurring" e problemas de localização motivaram estudos por Perona e Malik de filtros de difusão não linear. Foram aplicados processos não uniformes (denominados anisotrópicos) que reduzem a difusividade em localizações específicas da imagem, como a região das bordas. Estas localizações específicas podem ser descritas por $|\nabla u|^2$. Portanto foi utilizado a relação descrita pela equação (4.23).

$$\partial_t u = \operatorname{div} (g(|\nabla u|^2), |\nabla u|) \quad (4.23)$$

A medida da quantidade de difusividade proposta é dado pela equação (4.24).

$$g (s ^ 2) = \frac{1}{1 + \frac{s^2}{\lambda^2}} (\lambda > 0) \quad (4.24)$$

É necessário notar que o filtro proposto por Perona-Malik é considerado um modelo isotrópico, desde que se faça uso de valores de difusão escalar e não de um tensor de difusão.




Fig 4-6 Gráfico do fluxo Φ , de difusão, na imagem I como função da relação entre o módulo do gradiente de I e do parâmetro de contraste λ . Conforme o gráfico, o fluxo Φ , aumenta até um valor de $\lambda = \nabla I$ e após decresce suavemente.

A característica do filtro de Perona-Malik de estabilização da região das bordas da imagem por longo tempo é dado bastante relevante como será visto mais adiante na análise de resultados. Ademais, há outras razões para uso destas características de preservação das bordas as quais

serão discutidas a seguir.

4.6.1.1 Preservação da região das bordas

Para compreensão do estudo do efeito do filtro de Perona-Malik nas bordas da imagem, é necessário primeiro restringir a análise ao caso unidimensional. Isto simplifica a notação e ilustra a maioria do comportamento, uma vez que próximo a uma borda estreita uma imagem bidimensional se aproxima a uma função de uma variável.

Pela difusividade, expressa por (4.24) decorre que a *função fluxo* $\Phi(s) = sg(s^2)$ satisfazendo a restrição, $\Phi'(s) \geq 0$ para $|s| \leq \lambda$, e $\Phi'(s) < 0$ para $|s| > \lambda$, conforme mostrado na Figura 4-6. Uma vez que a equação (4.23) pode ser reescrita como a equação (4.25).

$$\partial_t u = \Phi'(u_x) u_{xx} \quad (4.25)$$

Observa-se que a despeito de sua difusividade não-negativa, o modelo de Perona-Malik é uma função parabólica de λ , com $|u_x| \leq \lambda$ crescente e $|u_x| > \lambda$ decrescente. Portanto λ , representa um parâmetro de contraste que separa regiões de baixo contraste (onde a função é crescente) de regiões de alto contraste (onde a função é decrescente) na imagem. Não é difícil de verificar que o filtro de Perona-Malik incrementa a declividade na região dos pontos de inflexão nas bordas dentro de uma região de alta contraste[24]. Se existe uma solução de suavização suficiente u , ela satisfaz

a: $u_x u_{xx}$, isso é mostrado na equação (4.26).

$$\partial_t (u_x^2) = 2u_x \partial_x (u_t) = 2\Phi''(u_x)u_x^2 + 2\Phi'(u_x)u_x u_{xxx} \quad (4.26)$$

Um ponto x_0 onde u_x^2 é máxima com algum tempo t é caracterizado por $u_x u_{xx} = 0$ e $u_x u_{xxx} \leq 0$. Portanto, tendo em vista a equação (4.26) obtém-se a expressão (4.27), com desigualdade estrita para $u_x u_{xxx} < 0$.

.

$$(\partial_t (u_x^2))(x_0, t) \geq 0 \quad \text{para} \quad |u_x(x_0, t)| > \lambda \quad (4.27)$$

No caso bidimensional, (4.25) é substituído pela expressão dada em (4.28).

$$\partial_t u = \Phi'(\nabla u)u_{\eta\eta} + g(|\nabla u|^2)u_{\varepsilon\varepsilon} \quad (4.28)$$

Na equação (4.28) as coordenadas η e ε correspondem à notação das direções paralela e perpendicular a ∇u , respectivamente. Portanto, tem-se difusão de baixo contraste ao longo de linhas com níveis de cinza constante (isophotes) combinadas com difusão de baixo-alto contraste ao longo de linhas de máxima variação de níveis de cinza (flowlines).

Observa-se que o comportamento da difusão de baixo-alto contraste não é apenas restrita a uma difusividade especial, como em (4.24), mas para todas as difusividades $g(s^2)$ as quais rapidamente decaem gerando

funções fluxo não monotônicas $\Phi(s) = sg(s^2)$. Tais difusividades são explicitamente intencionais no método de Perona-Malik assim como elas dão resultados desejados de pequenas flutuações geradas por efeitos de deformação(blurring) e bordas mais definidas. Portanto, elas são a razão principal para os expressivos resultados obtidos por esta técnica.

4.6.1.2 Interpretação na escala espacial

Perona e Malik redefiniram os conceitos de escala espacial linear que tratavam todos os pontos no espaço e níveis de escala igualmente. Ao invés disto, definiram que a região da fronteira necessita possuir uma grande declividade e necessitam coincidir com a região da fronteira em cada nível de resolução(localização imediata) e que a suavização na região interna deve ser preferida à suavização entre as regiões(borda). Estas propriedades possuem significativo interesse prático, elas garantem que estruturas podem ser detectadas facilmente e problemas de correspondência podem ser ignorados.

4.7 Regularização de modelos não-lineares

O modelo numérico adotado é especificamente ajustado aos níveis de alto-baixo-contraste que se deseja no processo de difusão. Neste caso em específico, que se deseja separar escalas finas de ruído foi adotado o modelo de regularização espacial, seguindo a idéia exposta em [18] com um parâmetro de escala σ abaixo do qual todo ruído é ignorado, da seguinte forma:

$$\partial_t u = \text{div}(g(|\nabla u| \sigma^2) \nabla u) \quad (4.29)$$

onde $u_\sigma = K_\sigma * u$ e K é uma função Gaussiana.

A solução mostrada na equação (4.29) possui a característica das regularizações espaciais de convergirem para um estado constante.

Todos os filtros não-lineares de difusão que se tem investigado tem utilizado um valor escalar de difusão g o qual é adaptado ao tipo de estrutura existente na imagem. Portanto, eles são isotrópicos e o fluxo $j = -g \nabla u$ é sempre paralelo a ∇u . No entanto nesta aplicação as características de interesse encontram-se em duas direções. Estes requisitos não podem ser satisfeitos por difusão escalar, havendo a necessidade da introdução de um tensor no modelo do filtro de difusão, desta forma, então, se tem difusão anisotrópica. Utiliza-se a estratégia de regularização espacial.

4.7.1 Regularização de Perona-Malik

Analisando a equação (4.29) que representa um modelo de difusão não linear isotrópico, nota-se que seu comportamento no interior de um segmento é linear, mas na região das bordas esse comportamento é inibido. Todavia, esse processo não torna imune a região das bordas de ruído.




Fig 4-7 A esquerda é mostrada imagem com forte presença de ruído. A direita é mostrada imagem após utilização de filtro de difusão anisotrópica não-linear, nota-se forte arredondamento de regiões antes retas resultante do efeito de suavização.

Para se resolver este problema, deve-se restringir a análise à região das bordas, é necessário que o processo de difusão se desenvolva ao longo das bordas seguindo seu contorno, ou seja na direção tangencial, ao invés de uma direção perpendicular a ela. Modelos anisotrópicos não trazem apenas em sua formulação o módulo do descritor da borda $|\nabla u_\sigma|$ mas também sua direção. Desta forma se define um sistema ortonormal de autovetores v_1 e v_2 do tensor de difusão D tal que eles representam o comportamento da estrutura da borda da imagem com $v_1 \parallel \nabla u_\sigma$ e $v_2 \perp \nabla u_\sigma$.

Com a idéia de efetuar o processo de suavização ao longo das bordas, ao invés de sobre ela, foram adotados dois correspondentes autovalores λ_1 e λ_2 , da seguinte forma:

$$\lambda_1(\nabla u_\sigma) = g(|\nabla u_\sigma|^2),$$

$$\lambda_2(\nabla u_\sigma) = 1.$$

Em geral, ∇u não coincide com um dos autovetores de D assim como em sua trajetória para $\sigma > 0$. Todavia, este modelo tem comportamento anisotrópico. Se o parâmetro de regularização σ tende a 0, o processo descrito acima tem comportamento isotrópico.

4.8 Difusão anisotrópica com conservação de borda de imagem

Tendo em vista relações anteriores, considerando-se u_1, u_2 com $u_1 > u_2$ como sendo os autovalores do tensor J_p da estrutura, e v_1, v_2 os autovetores ortogonais correspondentes, desde que o tensor de difusão deve refletir a estrutura local da imagem, deve ser escolhido de tal maneira que revele o mesmo conjunto dos autovetores v_1, v_2 . A escolha dos autovalores correspondentes λ_1, λ_2 depende do objetivo do filtro. Uma vez que a idéia é restringir o alisamento dentro de cada região e inibi-lo através das bordas, reduz-se a componente normal de difusividade λ_1 , e às bordas é reservado um elevado contraste u_1 . Este comportamento desejado pode ser conseguido pela seguinte escolha ($m \in \mathbb{N}, C_m > 0, \lambda > 0$): $\lambda_1(u_1) = g(u_1), \lambda_2 = 1$.

$$\left. \begin{array}{l} \\ \\ \\ \end{array} \right\} 1 \quad (s \leq 0)$$

$$g(s) = \quad (4.35)$$

$$1 - e^{-\frac{C_m}{(s/\lambda)^m}} \quad (s>0)$$

A função exponencial decrescente, presente na equação (4.35), é escolhida a fim cumprir o requisito de suavização dentro no interior das regiões **[19]**. Desde que o ∇u_σ remanescente seja limitado em $\Omega \times [0, +\infty)$ **[18]** e , sabendo que a definição de D positivo e uniforme é satisfeito automaticamente por este filtro. O valor de C_m constante é calculado de tal maneira que o $sg(s)$ do fluxo, conforme mostrado na Figura 4-6, está aumentando para $s \in [0, \lambda]$ e está diminuindo para $s \in [\lambda, \infty]$. Assim, a estratégia precedente do filtro pode ser considerada como um modelo anisotrópico regular de Perona-Malik.

A filtragem por difusão anisotrópica é ainda capaz de possuir as propriedades de realce de contraste do filtro Perona-Malik (fornecido o parâmetro σ de regularização não demasiado grande). Ela descreve a evolução temporal de uma função como uma Gaussiana e as suas isolines. Pode-se observar que duas regiões com nível de cinza quase constante evoluem separadamente por uma borda razoavelmente íngreme. O efeito de realce da borda é devido ao fato da difusão diminuir rapidamente ,nisso, o alisamento local é priorizado em detrimento da difusão entre as duas regiões adjacentes. A posição da borda permanece estável sobre um intervalo muito longo do tempo. Isto indica que, na pratica, a determinação de um ponto de parada apropriado não é um problema crítico. Depois que o processo do realce do contraste é concluído, a declividade das bordas diminui muito lentamente até que o gradiente alcance um valor onde nenhuma difusão inversa seja mais possível. Então a imagem converge rapidamente para uma imagem constante. Em **[21]** é apresentada uma descrição mais detalhada a respeito desta

propriedade.

A difusão anisotrópica não-linear tem um comportamento mais rápido na escala espacial uma vez que a difusão ao longo das bordas é ainda permitida. Como em mostrado na Figura 4-7 na imagem à direita, isto causa um arredondamento mais acentuado das estruturas, que pode ser visto na ponta do triângulo. Uma consequência positiva deste efeito de "fast-shrinking" ,é que as estruturas pequenas ou alongadas e finas são melhor eliminadas que no caso isotrópico. Assim, é reconhecido que a maioria dos "segmentos descritos" coincidem com os objetos semanticamente corretos o que se esperaria nestas escalas. Finalmente as imagens tendem para uma silhueta de "shape", antes que convirjam a uma imagem constante. A tendência de produzir regiões bem divididas quase constantes indica que estas escalas-espaciais são ferramentas ideais do pré-processamento para a segmentação. Ao contrário dos modelos baseados em reação de difusão que obtém resultados de acordo com a segmentação para um tempo infinito, a evolução temporal destes modelos gera uma família hierárquica completa de acordo com os resultados da segmentação. A qualidade de realce de contraste distingue filtros não-lineares da difusão de outros na escala-espacial. Deve-se notar que o realce no contraste é um fenômeno local que não pode ser substituído por reescalamentos globais simples dos valores dos níveis de cinza. Conseqüentemente, geralmente não é possível obter segmentação como resultado apenas reescalando os resultados de uma escala-espacial reduzindo-se somente o contraste. Os parâmetros λ e σ referentes a contraste e ruído respectivamente dão liberdade para adaptar a escala-espacial não-lineares da difusão à finalidade desejada a fim de recompensar características interessantes com uma duração mais longa. Em [20] o modelo linear baseado no gradiente é utilizado para aplicação na eliminação de ruídos em mamogramas, no entanto se o parâmetro t for elevado haverá o problema de deslocamento das bordas da imagem. Neste sentido, o tempo t é função do grau de aceitação dos resultados, com respeito à tarefa especificada, ao invés

de um descritor na escala espacial. A vista comum que o parâmetro t da evolução da escala-espacial deve ser relacionado à escala-espacial reflete a suposição que os analisadores de uma escala-espacial devem ser não comprometidos. A Filtragem não-linear da difusão renuncia a esta exigência reservando-se para incorporar informação à-priori no processo da evolução. A idéia básica da escala-espacial, entretanto, é mantida: para fornecer uma família de versões subseqüentemente simplificadas da imagem original, que dá uma hierarquia das estruturas e a reserva para escolher a informação relevante de uma determinada escala. Além destas características específicas de escala-espacial não-lineares da difusão deve-se mencionar que, devido aos filtros lineares e não-lineares como os métodos da condição de limite homogênea de Neumann e do divergente, ambos mantêm a preservação do nível de cinza médio da imagem durante a difusão.

4.9 Discretização da equação de difusão anisotrópica

Na Figura 4-8, esta mostrado um determinado ponto central e sua vizinhança composta por 8 pontos[24], considerando-se a aproximação da formulação original da equação de difusão:

$$\frac{\partial}{\partial t} P(x, y; t) = [c(x, y, t) \cdot \frac{\partial}{\partial x} P(x, y, t)] + [c(x, y, t) \cdot \frac{\partial}{\partial y} P(x, y, t)] \quad (4.36)$$

com:

$$c(x, y, t) = 1 - e^{\frac{-C_m}{(s/\lambda)^m}} \quad s > 0 \quad (4.37)$$

$$c(x, y, t) = 1 - e^{\frac{-C_m}{(s/\lambda)^m}} \quad s \leq 0 \quad (4.38)$$




Fig 4-8 Esquema mostrando vizinhança de um ponto $P(x,y,t)$, qualquer na imagem, composta por 8 pontos. A expressão diferencial contida nos coeficientes de condutância c_1 à c_8 é discretizada como a diferença entre o valor do ponto central e o valor do ponto em uma das 8 direções.

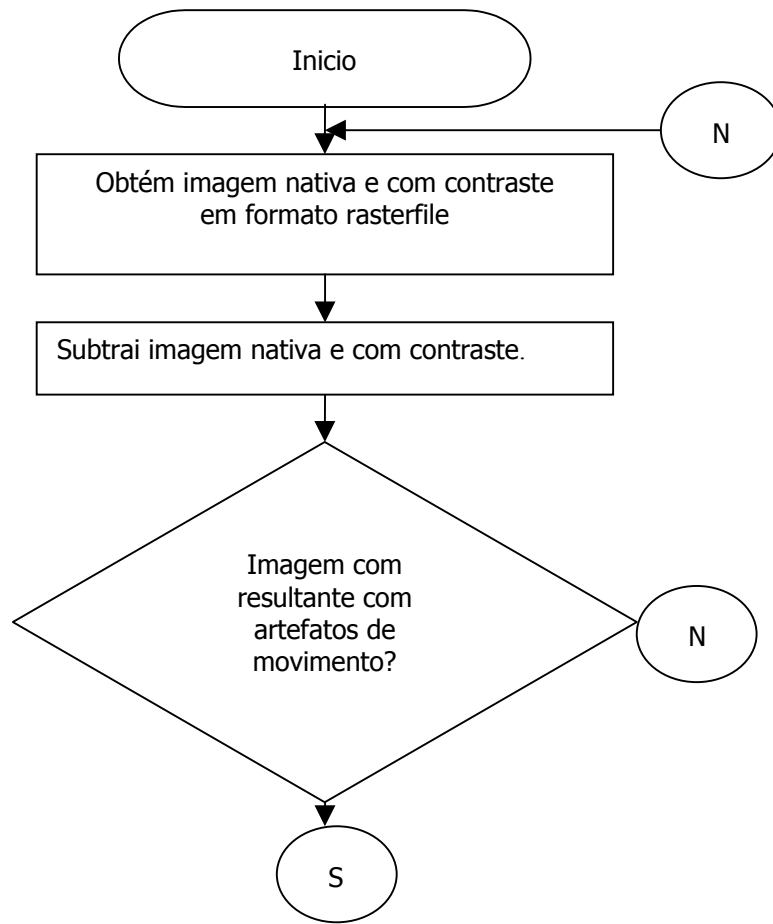
A variação de valor em cada ponto, considerando-se c_1 à c_8 os coeficientes de condutância correspondentes às 8 direções presentes na vizinhança mostrada na Figura 4-8 e levando em conta algumas simplificações, passa a ser: $P(x,y,t+\Delta t) = P(x,y,t) + \Delta t \cdot [c_5 + c_4 + c_1 + c_7 + \sqrt{2}/2 \cdot (c_3 + c_2 + c_6 + c_8)]$, que é a expressão para a implementação discreta da equação da difusão.

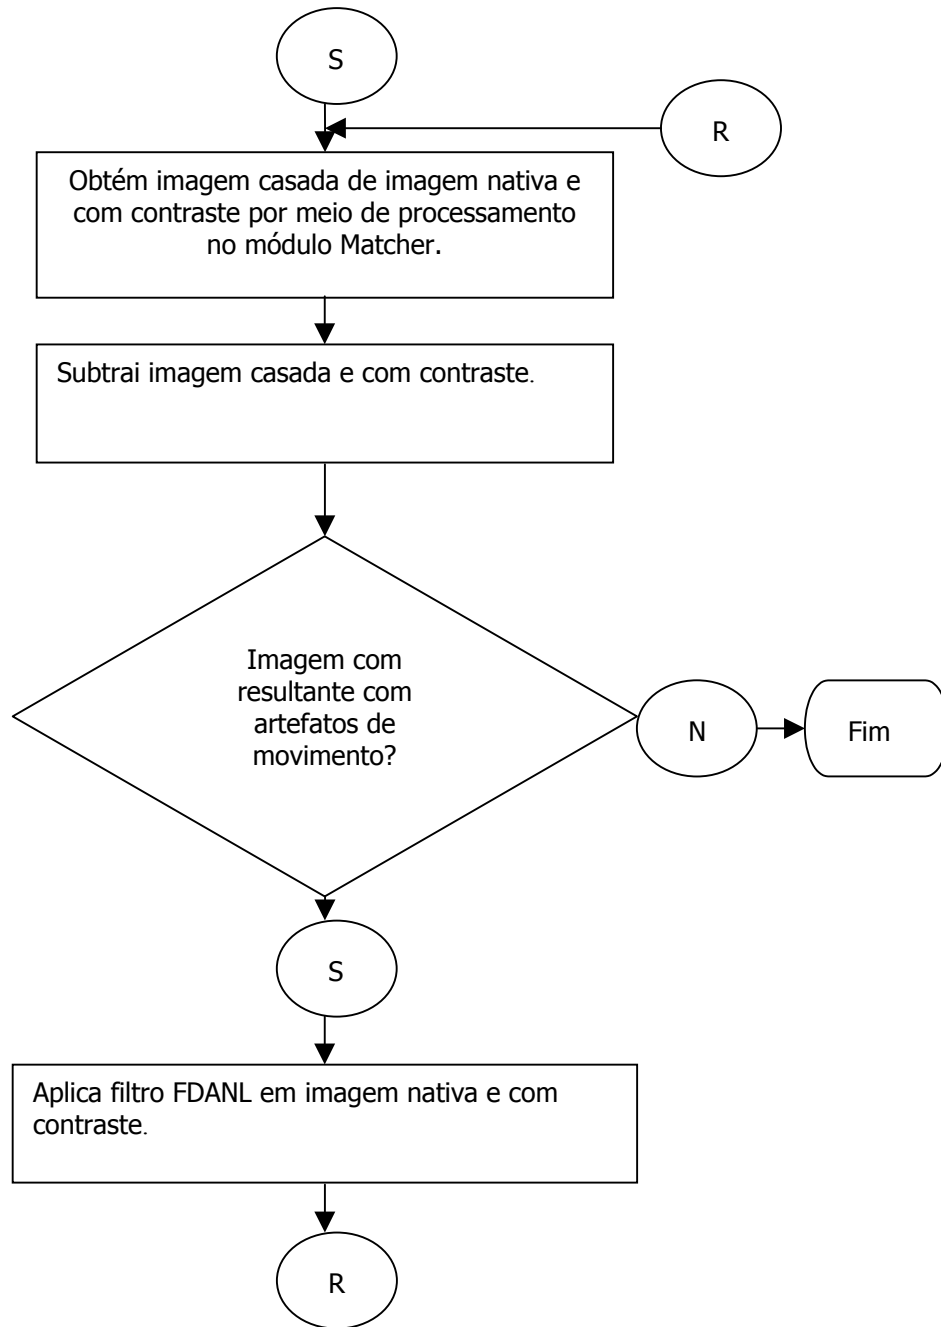
Capitulo 5

Metodologia de validação e material empregado

5.1 Fluxograma de procedimentos adotados para validação da pesquisa

Abaixo é descrito fluxograma com passos executados para validação do trabalho:





5.2 Algumas considerações sobre os procedimentos de avaliação

5.2.1 Subtração de imagens

O método de avaliação da presença de artefatos de movimento é a subtração de imagens pixel a pixel, conforme mostra Figura 5-1. A diferença utilizada é tomada como valor absoluto da seguinte forma: $I_d(x,y) = | I_1(x,y) - I_2(x,y) |$, após I_d é multiplicado por um fator de contraste. Onde I_d representa a escala de cinza do pixel da imagem resultante obtida, I_1 e I_2 os valores em escala de cinza do pixel correspondente na imagem original e destino.




Fig 5-1 Esquema representando a obtenção de uma imagem $I_d(x,y)$ como resultado de uma subtração ponto à ponto de outras duas $I_1(x,y)$ e $I_2(x,y)$.

Este método é muito comum na área médica e é chamado "radiografia modo máscara"[10]. Através da subtração de imagens é possível analisar as mudanças no contorno da borda e o movimento das regiões internas.

5.2.2 Dados de validação empregados

Na Figura 5-2 é mostrado a direita o tipo de imagem MRI utilizado, neste caso os cortes possuem espessura em torno de 2mm e resolução 512x256 pixels/8bits por pixel. Nota-se nesta imagem que os pequenos detalhes de textura estão mais nítidos em relação à imagem da esquerda que possui resolução 256x256/8bits por pixel e espessura de mais de 6mm. A imagem da direita era empregada na primeira versão do *MAMMALYZER*. As novas imagens MRI foram obtidas da Clínica Radiológica Budenbrook & Blasinger em Mainz, Alemanha




Fig 5-2 Comparação entre imagens processadas pela 1. versão do Mammalyzer(à esquerda) com as processadas pela nova versão(à direita). Notar presença de maior quantidade de detalhes irregulares de textura na imagem à direita.

Analisando a Fig 5-2, é perceptível que a Figura à direita possui uma quantidade de textura maior. Isto representa uma maior quantidade de informação a ser processada pelo módulo de casamento de imagens "Matcher" do Mammalyzer.

5.3 Meios computacionais empregados

O processo de validação foi realizado em um computador PC AMD Athlon (TM) XP 2000+ com 523MB de RAM. A ferramenta visual foi desenvolvida na linguagem de programação SmallTalk através do compilador VisualWorks 7.0. Os módulos de processamento da imagem foram desenvolvidos em linguagem de programação C padrão ANSI (American National Standards Institute) para o sistema operacional Linux.




Fig 5-3 Tela do Sistema Mammalyzer integrado ao editor de imagens Dicom.

A linguagem SmallTalk obedecendo ao paradigma da "orientação a objetos", torna o software bastante flexível permitindo incorporar melhorias sem alterações profundas em sua estrutura. Na Figura 5-3 é mostrado o editor de imagens DICOM a qual opera a nova versão do sistema especialista *MAMMALYZER*. Na barra superior é mostrado o menu de funções do *MAMMALYZER*. Na Figura 5-4 é mostrado a janela de configuração do filtro FDANL(Diffusion parameters), em que é possível configurar os parâmetros de contraste(λ) e iterações(epochs).




Fig 5-4 Detalhe de interface do sistema *Mammalyzer* destacando, ao centro, tela de configuração de parâmetros do filtro de difusão anisotrópica.

Capítulo 6

Resultados obtidos e discussão

A seguir são mostrados os resultados obtidos da aplicação do filtro de difusão anisotrópica não linear baseado no modelo de Perona-Malik(FDANL) com diversos parâmetros de contraste e níveis de iteração(parâmetro de escala) em conjunto com o módulo de casamento de imagens, "Matcher", do sistema especialista *Mammalyzer*. Parametrizou-se o módulo "Matcher" inicialmente, com vizinhança de pontos 7x7. No primeiro de três casos, é mostrada na Figura 6-1 a imagem nativa, na Figura 6-2 é mostrada a imagem com contraste, na Figura 6-3 é mostrada a diferença entre estas duas imagens, pela Figura 6-3 nota-se, pelos contornos brilhantes a presença de artefatos de movimento.




Fig 6-1 Imagem Nativa caso1




Fig 6-2 Imagem com contraste caso1

Na Figura 6-4 é mostrada a imagem casada resultante de aplicação do módulo de casamento de imagens sem a aplicação do filtro FDANL e na Figura 6-5 a diferença entre a imagem casada e a imagem destino e a imagem com contraste.

Como se pode notar pela Figura 6-5, ainda há a presença de artefatos de movimento na imagem. Em vista disto, procedeu-se a aplicação do filtro FDANL inicialmente com baixo contraste e poucos níveis de iteração. Na Figura 6-6 é mostrada a imagem resultante da diferença entre a imagem casada e a imagem destino deformada, aplicando-se FDANL com parâmetro de contraste $\lambda=3$ e iterações $I=5$, neste caso comparando com a Figura 6-5 há diferenças perceptíveis em algumas partes da região da borda da imagem. A seguir procedeu-se o aumento do parâmetro de contraste λ , para $\lambda=10$ e após novamente $\lambda=7$ e aumentou-se o numero de iterações para $I=20,50,90$.




Fig 6-3 Imagem resultante de subtração entre imagem com contraste e nativa no caso1.




Fig 6-4 Imagem casada resultante de utilização de rede neural SOM no caso1

Na Figuras 6-7 é mostrada a diferença entre a imagem casada e a imagem destino deformada resultante da aplicação do filtro FDANL com



Fig 6-5 Imagem resultante de subtração entre imagem casada e com contraste no caso1




Fig 6-6 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=3$ $I=5$ no caso1



Fig 6-7 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=20$, no caso1.




Fig 6-8 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=50$, no caso1.

As Figuras 6-8 e 6-9 mostram o resultado de utilização de $\lambda=7$, $I=50$ e $\lambda=7$, $I=90$ respectivamente. A Figura 6-10 mostra o resultado para $\lambda=10$, $I=90$. Neste ultimo caso em relação à Figura 6-9 há considerável redução da espessura da borda em toda extensão a exceção de uma pequena região em que reaparecem artefatos. Em virtude da característica de os artefatos de movimento não mostrarem grande extensão, configurou-se o módulo "Matcher" para processar a imagem por meio de operador de vizinhança local e conforme sugerido no capítulo 4 optou-se por relativamente baixo parâmetro de contraste e relativamente alto parâmetro de escala. O resultado disso é mostrado na Figura 6-12 com $\lambda=15$, $I=100$. Neste caso há uma redução aproximadamente de 80% na presença de artefatos de movimento em toda a extensão da borda da imagem. Para comparação de desempenho, na Figura 6-11 é mostrado o mesmo resultado com "Matcher" operando em vizinhança 7x7.




Fig 6-9 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=90$, no caso1.




Fig 6-10 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=90$, no caso1.



Fig 6-11 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$, no caso 1.




Fig 6-12 Imagem resultante de subtração entre imagem casada e com contraste, com "Matcher" operando em vizinhança local e uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$, no caso 1.

A seguir, no caso 2, são mostrados resultados de ensaio sobre imagens MRI que apresentam distribuição irregular de textura na forma de "estrias" em sua região interna e partes da região da borda. Na Figura 6-13 é mostrada a imagem nativa na Figura 6-14 a imagem com contraste, na Figura 6-15 a diferença entre a imagem com contraste e nativa. Em virtude da presença de artefatos de movimento, submete-se a imagem original ao módulo Matcher obtendo-se a imagem casada mostrada na Figura 6-16. Analisando-se a diferença entre a imagem casada e a imagem com contraste, mostrada na Figura 6-17, ainda nota-se a presença de artefatos de movimento, procede-se então a aplicação do filtro FDANL inicialmente com parâmetros $\lambda=3$, $I=5$, e o resultado é mostrado na Figura 6-18. Como se pode notar não há mudanças perceptíveis na espessura dos contornos interno e na borda. Analisando-se as Figuras 6-19 e 6-20 com parâmetros $\lambda=10$, $I=20$ e $\lambda=7$, $I=50$ respectivamente, começa-se a notar mudanças perceptíveis na espessura do contorno externo da imagem em algumas regiões.




Fig 6-13 Imagem nativa no caso2.




Fig 6-14 Imagem com contraste no caso2.

Nas Figuras 6-21 e 6-22 são mostrados resultados com parâmetros $\lambda=7$, $I=90$ e $\lambda=10$, $I=90$ respectivamente. Neste caso em 6-22 nota-se uma ligeira redução de espessura do contorno externo quando comparado com as Figuras 6-19 e 6-20.



Fig 6-15 Imagem resultante entre subtração de imagem nativa e com contraste, no caso2.




Fig 6-16 Imagem casada resultante de aplicação de rede neural SOM, no caso2

Nas Figuras 6-23 e 6-24 são mostrados resultados com parâmetros $\lambda=15, I=100$ e $\lambda=15, I=100$ com módulo de casamento de imagens "Matcher" operando em vizinhança local. Em ambos os casos nota-se considerável redução de artefatos de movimento, restringindo-se a uma pequena região da borda.



Fig 6-17 Imagem resultante de subtração entre imagem casada e com contraste, no caso 2




Fig 6-18 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=3$ $I=5$, no caso 2.




Fig 6-19 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=20$,no caso2



Fig 6-20 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=50$,no caso2




Fig 6-21 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=90$,no caso2




Fig 6-22 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=90$,no caso2.




Fig 6-23 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$, no caso 2.




Fig 6-24 Imagem resultante de subtração entre imagem casada e com contraste, com "Matcher" operando em vizinhança local e uso de filtro de difusão com parâmetros $\lambda=15$

A seguir é mostrado um terceiro caso, caso 3, em que há pequenas fibras bastante espalhadas. A Figura 6-25 mostra a imagem nativa na Figura 6-26 à imagem com contraste em 6-27 a diferença entre a imagem original e destino, em 6-28 a imagem casada resultante, e em 6-29 a diferença entre a imagem casada e a imagem com contraste. Novamente, em virtude da presença de artefatos de movimento procede-se aplicação de filtro FDANL inicialmente com parâmetros de baixo valor. Na Figura 6-30 é mostrado resultado com parâmetros $\lambda=3, I=5$.



Fig 6-25 Imagem nativa,no caso3.




Fig 6-26 Imagem com contraste,no caso3

Na Figura 6-31 é mostrado o resultado para $\lambda=10, I=20$, em 6-32 $\lambda=7, I=50$. Nas Figuras 6-33 e 6-34 para $\lambda=7, I=90$ e $\lambda=10, I=90$ respectivamente. Nota-se nestes últimos dois casos redução de espessura do contorno da imagem. Finalmente nas Figuras 6-35 e 6-36, são mostrados os resultados aumentando-se o contraste na região da borda, para $\lambda=15, e I=100$, sendo que na Figura 6-36 da mesma forma que no caso1 e caso2 o módulo "Matcher" opera com vizinhança local. Neste último caso, assim como nos dois primeiros (caso1 e caso2) não há grande extensão de artefatos de movimento. Em função disso efetuou-se mudança de parâmetros do módulo "Matcher" relativo ao tamanho da vizinhança de pontos (neurônios) utilizadas para treinamento da rede neural SOM de forma a operar com vizinhança local (8 pontos).



Fig 6-27 Imagem resultante de subtração entre imagem nativa e com contraste, no caso3




Fig 6-28 Imagem casada obtida de processamento por rede neural SOM, no caso3.




Fig 6-29 Imagem resultante de subtração de imagem casada com imagem com contraste, no caso3.



Fig 6-30 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=3$ $I=5$, no caso3.




Fig 6-31 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=20$, no caso3.




Fig 6-32 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=50$, no caso3.



Fig 6-33 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=7$ $I=90$, no caso3.



Fig 6-34 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=10$ $I=90$, no caso3.




Fig 6-35 Imagem resultante de subtração entre imagem casada e com contraste, com uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$, no caso3.




Fig 6-36 Imagem resultante de subtração entre imagem casada e com contraste, com "Matcher" operando em vizinhança local e uso de filtro de difusão com parâmetros $\lambda=15$ $I=100$, no caso3.

Capítulo 7

Conclusão e trabalhos futuros

O trabalho proposto teve como meta a ampliação do “dataset” de análise do sistema especialista *MAMMALYZER* por meio da criação de uma ferramenta auxiliar ao módulo de casamento de imagens. Os três casos analisados no capítulo 6 representam dados de imagem MRI bastante comuns no universo de pacientes que se submetem a exames de mama.

A aplicação do filtro de difusão anisotrópica não linear baseado no modelo de Perona-Malik, demonstrou ser uma ferramenta eficiente nos casos em que os pequenos detalhes de textura não apresentam grande variação de contraste com sua vizinhança, como prevê a equação (4.35).

Analisando os resultados mostrados no capítulo 6, nos casos de experimento com parâmetro de escala com valor relativamente elevado ($I=100$) para um parâmetro de contraste $\lambda=15$, as regiões em que ainda persistem artefatos de movimento, com maior extensão, representam menos de 20% de toda extensão da região da borda da imagem. Em vista disto, para diminuir ainda mais esta percentagem residual de artefatos de movimento, em áreas localizadas, como trabalho futuro, sugere-se a utilização conjunta com alguma técnica de difusão anisotrópica baseada em contornos ativos.

BIBLIOGRAFIA

- [1] WANGENHEIM. A. "Detecção automatizada em câncer de seio em tomografias de ressonância magnética", <http://wwwagr.informatik.uni-kl.de/~cyclops/mamma-paper-portuques.html> Abril 2002.
- [2] BARROS, ACSD, NAZÁRIO, F., et al. *Mastologia: Conduas*. Editora Revinter. 1998.
- [3] OREL S.G, MENDONÇA M.H., REYNOLD C, et al. *MR imaging of ductal carcinoma in situ*. *Radiology* 1997;202:413-20.
- [4] LIU P. F. DEBATIN J. F. CADUFF R. F. *et al*. Improved diagnostic accuracy in dynamic contrast enhanced MRI of the breast by combined quantitative and qualitative analysis *The british journal of radiology* 71(1998) 501-509.
- [5] BARROS, ACSD, NAZÁRIO, AC, DIAS, EN, SILVA, HMS, FIGUEIRA F., ASS. *Mastologia: Conduas*. Editora Revinter.1998.
- [6] BONADONNA, G, HORTOBAGYI, G, GIANNI, A. *Textbook of breast câncer. A Clinical guide to therapy*. Mosby. 1997.
- [7] FREEMAN J. SKAPURA D. *Neural Networks. Algorithms, Applications and Programming Techniques*. Addison-Wesley Publishing Company, Inc Reading, Massachussetts, EUA, 1997, pp 282-285.
- [8] HUWER, S., RAHMEL, J., v. WANGENHEIM, A.: *Data-Driven Registration for Local Deformations. Pattern Recognition Letters*. North-Holland, 1996 (no preto).

- [9] TERZOPOULOS, D., PLATT, J., BARR, A. and FLEISCHER, K. *Elastically Deformable Models*, Computer Graphics, v21, n. 4, p. 205-214, 1987.
- [10] R.C.GONZALES, D., PLATT, R. E. WOODS *Digital Image Processing*, Addison Wesley Publishing Company, EUA, 1992, pp 186.
- [11] TOMITA F. SABURO T. *Computer Analysis of Visual Textures*. Kluwer 1990.
- [12] DI BONA S., HUWER S., NIEMANN H. SALVETTI O. *Nonlinear Neural Enhancement of Anatomical Differences in Deformed Brain MR-Images*. Institute for Information Processing-CNR, Via S. Maria 46, I-56126 Pisa, Italy {dibona, salvetti}@iei.pi.cnr.it, Bayerisches Forschungszentrum für Wissensbasierte System, FORWISS, FG Wissensverarbeitung D-91058 Erlangen-Tennenlohe, Germany {niemann, huwer}@informatik.uni-erlangen.de
- [13] SALDEN H. A., HAAR T.B. VIERGEVER A. M. *Linear Scale-Space Theory from Physical Principles*, <http://citeseer.nj.nec.com/cache/papers/cs/18000/ftp:zSz zSzftp-robotvis.inria.frzSzpubzSzhtmlzSzPaperszSzaldental:95b.pdf/linear-scale-space-theory.pdf> Agosto 2002.
- [14] LINDENBERG T. *Scale-Space in Computer Vision*, <http://citeseer.nj.nec.com/cache/papers/cs/26839/ftp:zSz zSzftp.nada.kth.sezSzCVAPzSzscspzSzBook:Scale-Space Theory in Computer VisionzSzexcerpt.pdf/lindeberg94scalespace.pdf> Novembro 2002.
- [15] Discretização espacial <http://www.visgraf.impa.br/Courses/eescala/Notas/Cap06.pdf> fevereiro 2003.
- [16] V. HLAVAC R. SARA (Eds.) *Computer analysis of images and patterns*, Notas de leitura em ciência da computação, Vol 970 Springer Berlin pp 232.

- [17] L. ALVAREZ, GUICHARD F., LION P. , MOREL J. *Axioms and fundamental equations of image processing*, Arch Rational Mech Anal 123(1993) 199-257 Springer Verlag 1993.
- [18] L. ALVAREZ, GUICHARD F., LION P. , MOREL J. *Image selective smoothing and edge detection by non-linear diffusion*, Siam J. Numer. Anal. Vol. 29, N. 3, pp 845-850.
- [19] PERONA P. MALIK J. *Scale Space and edge detection using anisotropic diffusion* IEEE Transactions on pattern analysis and machine intelligence, vol 12, n. 7 julho 1990 pp. 833
- [20] WEICKERT J., SCHNORR C., *PDE-Based Preprocessing of medical images*, <http://www.ti.uni-manheim.de/~bmq/Publications-e.html>. dezembro 2002.
- [21] *Stability properties of Perona-Malik Scheme*, <http://www.ima.umn.edu/preprints/dec01/1823.pdf> janeiro 2002.
- [22] Active contour models, external energy, http://www.cs.sfu.ca/~stella/papers/blairthesis/main/nod_e30.html#SECTION00620000000000000000 , março 2003.
- [23] GRAHS T. *Nonlinear anisotropic diffusion filters for the numerical approximation of conservations law* , Vom Fachbereich für Mathematik und Informatik der Technischen Universität Braunschweig genehmigte Dissertation zur Erlangung des Grades eines, Eingereicht am 19. August 2002. pp 73.
- [24] *Discrete implementation of anisotropic diffusion* http://www.cs.sfu.ca/~stella/papers/blairthesis/main/nod_e25.html#SECTION00530000000000000000. novembro 2002
- [25] BOOMGAARD R.V.D, *Algorithms For Non-Linear Diffusion* , Intelligent Sensory Information Systems, University of Amsterdam, Kruislaan 403 1098 SJ, Amsterdam, Netherlands

- [26] SAHA P.K.,UDUPA J. K. *Scale-Based Diffusive Image Filtering Preserving Boundary Sharpness and Fine Structures* IEEE Transactions on Medical Imaging, vol. 20, no. 11, November 2001 pp 1143-1146
- [27] LIANG P, WANG Y. F. *Local Scale Controlled Anisotropic Diffusion with Local Noise Estimate for Image Smoothing and Edge Detection* <http://csdl.computer.org/comp/proceedings/iccv/1998/8295/00/82950193abs.htm> pp 3-7.
- [28] BARENBLATT G.I., VAZQUEZ J. L. *Nonlinear Diffusion and Image Contour Enhancement*, University of California at Berkeley, USA and Universidad Autônoma de Madrid, Spain. February 27, 2003.
- [29] WATSON, A.D. ROCKLAGE S. M. & CARVLIN, M. J. *Magnetic Resonance Imaging*. St. Louis, 1992.
- [30] LOPATA, R. HAACKE, E.M. HAAR, B.M.T *Tumor Perfusion Estimation with Dynamic Contrast Enhanced MRI* , MRI Institute & Harper University Hospital, Detroit, USA-Faculty of BioMedical Engineering, Eindhoven University of Technology. Detroit USA December 2002.