



Universidade do Minho
Escola de Engenharia

Nelson Costa Martins

**Desenvolvimento de Técnicas de Realce
Baseados em Filtros Wavelet para Imagens
de Mamografia Digital Direta**

Mestrado Integrado em Engenharia Biomédica

Trabalho realizado sob orientação do
Professor Doutor Manuel João Ferreira

Outubro 2012

DECLARAÇÃO

Nome: Nelson Costa Martins

Endereço eletrónico: a52560@alunos.uminho.pt

Telefone: 968715971

Número do Bilhete de Identidade: 13547164

Titulo da Tese: Desenvolvimento de Técnicas de Realce Baseadas em Filtros Wavelet para Imagens de Mamografia Digital Directa

Orientador: Professor Doutor Manuel João Ferreira

Ano de conclusão: 2012

Designação do Mestrado: Mestrado Integrado em Engenharia Biomédica

É AUTORIZADA A REPRODUÇÃO INTEGRAL DESTA TESE APENAS PARA EFEITOS DE INVESTIGAÇÃO, MEDIANTE DECLARAÇÃO ESCRITA DO INTERESSADO, QUE A TAL SE COMPROMETE.

Universidade do Minho, ___ / ___ / _____

Assinatura: _____

Agradecimentos

Gostaria de começar por agradecer ao meu orientador, Professor Doutor Manuel João Ferreira, e à minha colega de trabalho Carla Pereira pelos conhecimentos que me transmitiram e pelo apoio prestado quando algum problema ultrapassava os meus conhecimentos.

Um agradecimento à EnerMeter e ao CCG (Centro de Computação Gráfica) pela disponibilidade demonstrada a nível de infraestruturas e promoção do trabalho, permitindo a sua realização num ambiente com profissionais especializados.

Ao consultório de Imagiologia Médica Dr. Campos Costa, fica aqui o meu sincero agradecimento pelo apoio logístico e intelectual, através de imagens de mamografia e pelo feedback sobre as metas a alcançar com este trabalho.

À minha família e amigos agradeço pelo apoio pessoal que me prestaram de forma incondicional.

Este trabalho foi financiado pelo programa QREN (Quadro de Referência Estratégico Nacional), projeto n. 21564.

Resumo

O cancro é a segunda principal causa de morte nos países desenvolvidos. Nas mulheres, o cancro da mama é o mais frequente, anualmente milhares são diagnosticadas com esta doença, sendo a segunda principal causa de morte devido a cancro. O sucesso do tratamento desta doença está intimamente ligado a uma detecção precoce, sendo a etapa fundamental no combate à mesma o diagnóstico. Atualmente o método de diagnóstico mais utilizado é a mamografia, este método é relativamente simples, e consegue-se extrair informação essencial por um preço relativamente baixo.

Nos últimos anos têm-se apostado em melhorar a capacidade de detecção dos exames médicos tirando partido das potencialidades do processamento digital das imagens adquiridas. Este tipo de ferramentas provaram conseguir aumentar a sensibilidade dos médicos na detecção de patologias. A sua função é descartar imagens ou zonas sem interesse, salientar locais importantes e quando aplicável emitir alertas ou cancelos.

Neste trabalho é estudado o potencial da transformada de Wavelet, no pré-processamento de imagens de mamografia. O objectivo principal é construir uma ferramenta de realce de microcalcificações, frequentemente indicadoras de patologias cancerígenas. A transformada de Wavelet permite decompor uma imagem de tal forma que é possível analisá-la como uma soma de detalhes e aproximações em diferentes escalas. Esta capacidade revela-se interessante pois as microcalcificações podem ser consideradas como detalhes numa imagem, podendo ser desta forma isoladas e processadas.

Os resultados demonstraram que existem inúmeras abordagens possíveis na aplicação da transformada de Wavelet em imagens de mamografia. O realce foi medido utilizando métricas adequadas, obtendo-se maiores contrastes depois do processamento, como esperado. Os vários métodos apresentados apresentam vantagens e desvantagens distintas, portanto para uma aplicação CAD deve ser feita uma análise prévia cuidada, neste aspecto este trabalho poderá ser um bom ponto de partida.

Abstract

Cancer is the second main cause of death in developed countries. In women, the most frequent type of this disease is breast cancer. Every year, thousands of women are diagnosed with this illness, making cancer the second leading cause of death in women.

The main step towards fighting this disease lays the diagnosis, and an early detection is crucial to the success of the treatment. Nowadays, mammography is the most used diagnosis method. It is a simple medical tool that gives essential information at a relatively low cost.

In recent years, several efforts have been done in order to improve the detection efficiency of mammograms, by using the potential offered by digital image processing. This kind of tool has proved effective in improving diagnosis accuracy. It allows us to disregard images that show no visible pathologies, while stressing important areas by improving their visualisation and, whenever necessary, issuing alerts and advice.

In this work, we study the potential of the Wavelet Transform in the mammography images pre-processing phase. Its aim is to create a tool that enhances micro-calcifications, which is a frequent indicator of breast cancer. The Wavelet Transform allows to breakdown an image to an extent that it becomes possible to analyse it as the summation of details and approximations in different scales. This is a useful function, because micro-calcification are mere details in mammographic images and, this way, it becomes possible to isolate them, enabling the physician to separately process them from the rest of the image.

Results have shown that numerous approaches using Wavelet Transform can be used to enhance mammographic images. The enhancement level was measured using appropriate techniques, and the results proved that image enhancement was achieved upon applying image processing, as expected. The various methods presented showed different results, with different advantages and disadvantages as well, making it difficult to select the best out of the considered methods. A careful evaluation of the problem must be performed and, in this sense, this work can become a good starting point to launch this process.

Índice

Agradecimentos	iii
Resumo	v
Abstract	vii
Índice de Figuras	xi
Índice de Tabelas	xv
Lista de Acrónimos	xvii
Capítulo I - Introdução	21
1.1 <i>Epidemiologia</i>	22
1.2 <i>Estrutura da Tese</i>	23
Capítulo II - Enquadramento Teórico	27
2.1 - <i>Mama</i>	27
2.1.1 - <i>Anatomia e Fisiologia</i>	27
2.1.2 - <i>Patologia</i>	29
2.2 - <i>Mamografia Digital Direta</i>	36
2.2.1 - <i>DICOM</i>	39
2.2.2 - <i>BI-RADS</i>	40
2.3 - <i>Sistemas CAD</i>	42
Capítulo III - Transformada De Wavelet	47
3.1 - <i>Teoria de Wavelets</i>	49
3.2 - <i>CWT</i>	51
3.3 - <i>Função de Escala</i>	52
3.4 - <i>Serie de Wavelet</i>	53
3.5 - <i>DWT</i>	54
3.6 - <i>SWT</i>	58
Capítulo IV - Estado da Arte - Aplicação da WT no realce de imagens	63
4.1 - <i>Wavelets no realce de imagens</i>	63
4.2 - <i>Realce de imagens de mamografia</i>	66
4.3 - <i>Wavelets no realce de imagens de mamografia</i>	67
Capítulo V - Trabalho Experimental	71
5.1 - <i>Dados</i>	71
5.2 - <i>Pré-processamento</i>	72
5.2.1 - <i>Redução do Ruído</i>	72
5.2.2 - <i>Realce da Imagem</i>	75
Capítulo VI - Resultados e Discussão	89
6.1 - <i>Algoritmos de comparação</i>	89
6.2 - <i>Remoção de Ruído</i>	92
6.3 - <i>Realce</i>	98
6.3.1 - <i>Imagens da Base de Dados Dr. Campos Costa</i>	98
6.3.2 - <i>DDSM</i>	103
Capítulo VII - Conclusão	111
Bibliografia	115

Índice de Figuras

<i>Figura 1 – Anatomia interna da mama humana, adaptado de [8]</i>	27
<i>Figura 2 – Unidade terminal ducto-lóbular, TDLU</i>	28
<i>Figura 3 – Exemplo de uma Assimetria benigna numa vista MLO (setas) [10]</i>	30
<i>Figura 4 – Exemplo de uma Assimetria maligna numa vista MLO (setas) [10]</i>	30
<i>Figura 5 – Representação simplificada da forma e contornos das massas. Adaptado de [12]</i>	31
<i>Figura 6 – a) massa oval e circular com contorno bem definido; b) massa lobular com contornos “enrugados”; c) massa com contornos bem definidos, encoberta por decido mamário; d) massa com contornos mal definidos [11]</i>	32
<i>Figura 7 – Exemplos de achados benignos. a) calcificação tipo pipoca; b) casca de ovo [15]</i>	33
<i>Figura 8 – Exemplo de Calcificações tipicamente benignas. a) vista CC e MLO a indicar microcalcificações cutâneas; b) calcificações vasculares; [15]</i>	34
<i>Figura 9 – Diferentes distribuições das microcalcificações; a) Difusa; b) Regional; c) Cluster local e Linear; d) Por Segmentos [15]</i>	35
<i>Figura 10 – Classificação das microcalcificações segundo a sua morfologia, adaptado de [15]</i>	35
<i>Figura 11 – Índice linear de atenuação para três tipos de tecido em função da energia emitida [1]36</i>	
<i>Figura 12 – Classificação em termos de densidades Radiológicas</i>	36
<i>Figura 13 – Mamografo, adaptado de [1]</i>	37
<i>Figura 14 – Mamografia digital direta (esquerda) Vs convencional (direita) [16]</i>	38
<i>Figura 15 – Ilustração do posicionamento do sensor e da mama nas vistas b) MLO c) CC.</i>	39
<i>Figura 16 – Etapas recomendadas pelo sistema BI-RADS no diagnóstico de imagens de mamografia, adaptado de [20]</i>	40
<i>Figura 17 – Exemplo das diferentes categorias BI-RADS para o tipo de mama. a) predominantemente adiposa; b) fibroglandular; c) heterogeneamente densa e d) Densa</i>	41
<i>Figura 18 – Divisão por etapas de um Sistema CAD genérico</i>	43
<i>Figura 19 – Exemplo de grelhas espaço-espectrais para várias formas de representar sinais</i>	47
<i>Figura 20 – Janela estreita (esquerda) e larga (direita) na STFT</i>	49
<i>Figura 21 – Exemplo de uma Wavelet do tipo chapéu mexicano (esquerda) e de uma onda sinusoidal (direita)</i>	50
<i>Figura 22 – Exemplo de Wavelets Daubechies 2 escaladas e deslocadas</i>	50
<i>Figura 23 – Exemplo de CWT; onda Chirp (em baixo) e resultado (em cima)</i>	51
<i>Figura 24 – Transformada de Wavelet 1D em duas escalas</i>	55
<i>Figura 25 – Representação da transformada de wavelet em termos da divisão das frequências em sub-bandas</i>	55
<i>Figura 26 – Transformada inversa de Wavelet de um sinal discreto 1D</i>	56
<i>Figura 27 – Esquema da decomposição de uma imagem nos vários coeficientes de aproximação e detalhe</i>	57
<i>Figura 28 – Esquema da reconstrução de uma imagem partindo dos coeficientes de detalhe e aproximação</i>	57

<i>Figura 29 – Resultado da aplicação da DWT (meio) e da FFT (direita) numa imagem (esquerda)</i>	58
<i>Figura 30 – Transformada de wavelet estatica em 3 escalas</i>	59
<i>Figura 31 – Alteração dos filtros na SWT</i>	59
<i>Figura 32 – Soft e Hard Threshold (vermelho e azul, respectivamente), Threshold =1, em xx valor de entrada e em yy valor de saída.</i>	64
<i>Figura 33 – Exemplo de Função de realce, dados normalizados para [-1, 1]; a) realce linear T= 0.2 e ganho=20; b) Realce usando função Sigmoides [28]</i>	65
<i>Figura 34 – Exemplo do histograma de uma imagem de mamografia digital direta (16 bits)</i>	73
<i>Figura 35 – Resultado do algoritmo de identificação do fundo. a) Imagem DDSM Original; b) Resultado da aplicação do threshold obtido do histograma; c) Mascara final, depois de algoritmo de enchimento e erosão</i>	74
<i>Figura 36 – Resultado da aplicação do algoritmo SIMPLES com S=3 e G=2; a) imagem original; b) realce com DWT; c) realce com SWT</i>	76
<i>Figura 37 – Imagens intervenientes na obtenção de es; a) Ms, [0, max(Ms)]; b) θ_s, [-pi, pi]; c) es, [0, max(Ms)]</i>	78
<i>Figura 38 – Imagens intervenientes no cálculo do mapa de probabilidades. a) D1H; b) D2H; c) C1H; d) 1-P1H;</i>	80
<i>Figura 39 – Comparação entre mapeamento obtido pelo método Correlações, a) e b) e pelo método correlações locais, c) e d)</i>	82
<i>Figura 40 – Magnitudes resultantes da aplicação do método de realce. a) Original; b) realce linear, g=1; c) realce não linear, g=2</i>	83
<i>Figura 41 – Mama artificial, 1024x1024 de 12bits</i>	92
<i>Figura 42 – Resultados dos algoritmos de Denoise para um ruído de 1280 a)Imagem original; b)imagem com ruído; c) Mediana; d) ROBUSTO; e) FUNDO</i>	93
<i>Figura 43 – Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=40 Níveis Cinzentos</i>	94
<i>Figura 44 – Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=80 Níveis Cinzentos</i>	94
<i>Figura 45 – Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=320 Níveis Cinzentos</i>	95
<i>Figura 46 – Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=640 Níveis Cinzentos</i>	95
<i>Figura 47 – Resultado visual do teste dos algoritmos de remoção de ruído em imagens reais. a) Imagem Original; b) Imagem Corrompida com ruído a 40 NCs; c) Imagem Corrompida com ruído a 640 NCs; d) Mediana com ruído = 40NCs; e) Robusto com ruído = 40NCs; f) Fundo com ruído = 40NCs; g) Mediana com ruído = 640NCs; h) Robusto com ruído = 640NCs; i) Fundo com ruído = 640NCs;</i>	97
<i>Figura 48 – Resultados realce para Imagens DCC; mínimo, q1, mediana, q3 e máximo são respectivamente os percentis 2%, 25%, 50%, 75% e 98% e são referentes ao ganho em contraste;</i>	

<i>Ruído representa o ganho médio em Ruído para cada método. O prefixo "DN_" indica a aplicação prévia do algoritmo de redução de ruído baseado no FUNDO.</i>	98
<i>Figura 49 – Resultado Circularidade para imagens DCC.</i>	101
<i>Figura 50 – Imagem exemplo para o resultado dos diferentes métodos apresentados. a) Original; b) Simples; c) Threshold; d) Corr_Locais; e) Corr; f) Max_Locais; g) Cont</i>	102
<i>Figura 51 – Resultados realce para Imagens DDSM; mínimo, q1, mediana, q3 e máximo são respectivamente os percentis 2%, 25%, 50%, 75% e 98% e são referentes ao ganho em contraste; Ruído representa o ganho médio em Ruído para cada método</i>	103
<i>Figura 52 – Resultado Circularidade para imagens DDSM</i>	105
<i>Figura 53 – Resultados Visuais para imagens DDSM; a) original; b) Simples; c) DN_Simples; d) Threshold; e) DN_Threshold; f) Corr; g) DN_Corr; h) Corr_Locais; i) DN_Corr_Locais; j) Max_Locais; k) DN_Max_Locais; l) Cont; m) DN_Cont; o prefixo "DN_" indica a remoção prévia do ruído</i>	107

Índice de Tabelas

Tabela 1 - Categorias BI-RADS usadas no diagnósticos de imagens mamárias, Adaptado de [21] _ 42

Tabela 2 - Valor da SNR obtido para os diferentes testes dos algoritmos de remoção de ruído. ____ 92

Lista de Acrónimos

ACS	American Cancer Society
BI-RADS	Breast Imaging-Reporting and Data System
CAD	Computer aided Diagnosys
CC	Crânio Caudal
CCD	Charge-Coupled Device
CDIS	Carcinoma Ductal in Situ
CWT	Continuous Wavelet Transform
DDSM	Digital Database for Screening Mamography
DICOM	Digital Imaging and Communications in Medicine
DWT	Discret Wavelet Transform
ECG	Electrocardiograma
fMRI	Functional Magnetic Resonance Imaging
FT	Fourier Transform
JPEG2000	Joint Photographic Experts Group 2000
LRM	Local Range Modifcation
MIAS	Mammographic Image Analysis Society
MLO	Medio-lateral Obliqua
MRI	Magnetic Resonance Imaging
NC	Nivel cinzento
PET	Positron emition tomography
ROI	Region of interest
SI	Sistema Internacional
SNR	Signal to noise ratio
STFT	Short -Time Fourier Tranform
SWT	Static Wavelet Transform
TAC	Tomografia axial computadorizada
TIF	Tagged Image File
US	Ultrassons
WHO	World Health Organization
WT	Wavelet Transform

Capítulo I

Introdução

2012

Capítulo I – Introdução

Nos últimos séculos tem-se assistido a uma evolução extraordinária dos cuidados médicos. A aliança entre várias áreas de investigação (medicina, biologia, química, física, engenharia, etc) permitiu uma grande troca de conhecimentos, levando assim, ao aparecimento de novas técnicas de diagnóstico e tratamento [1]. Dentro das técnicas de diagnóstico tem-se os exemplos do ECG, Raio-X, TAC, MRI, fMRI, US e PET. Com elas, é possível visualizar o interior do corpo humano do ponto de vista estrutural e funcional sem a necessidade de fazer qualquer tipo de incisão no paciente. Estas ferramentas vieram melhorar o trabalho dos médicos, permitindo diagnosticar doenças que até aí eram impossíveis de detectar. Permite ainda diagnósticos mais precisos, mais precoces e com reduzido risco para os pacientes. Atualmente continua a apostar-se no desenvolvimento de novas técnicas e na melhoria das já existentes, procurando torná-las ainda mais fiáveis, reduzindo riscos, custos, efeitos secundários e aumentando a sua sensibilidade. [1]

A era digital impulsionou drasticamente o desenvolvimento dos cuidados médicos, sendo um facto que o aparecimento dos computadores veio revolucionar a medicina. A possibilidade de armazenamento e tratamento de dados digitais é fundamental para o funcionamento dos sistemas de saúde tal como os conhecemos hoje. Neste momento é possível guardar, em formato digital, todo o historial médico de um paciente. Esta informação está disponível aos médicos e pode ser acedida sempre que necessário, evitando-se, desta forma, falhas de comunicação ou perda de dados. Só depois do aparecimento dos computadores é que foi possível o aparecimento de equipamentos como o TAC e o MRI, capazes de fazer uma visualização 3D do interior do corpo humano. Estes implicam o processamento de uma grande quantidade de informação de forma a fazer a construção das imagens, que seriam impossíveis de fazer de outra forma [2]. Com a era digital começou-se também a apostar em ferramentas de apoio ao diagnóstico, os chamados sistemas CAD (*computer aided diagnosis*). Com estes sistemas é possível auxiliar os médicos na realização do diagnóstico, servindo como uma segunda opinião, dando apoio a nível de visualização, melhorando a imagem e emitindo alertas quando necessário.

É nos sistemas CAD que este trabalho encontra a sua base exploratória. O objectivo é a criação de um sistema de detecção e classificação (semi)automático de patologias em imagens de mamografia digital direta. Desta forma espera-se conseguir uma ferramenta que facilite, e acima de tudo melhore, a detecção de doenças. O trabalho será focado na componente de pré-processamento onde a Transformada Discreta de Wavelet (DWT) será utilizada de forma a evidenciar os indícios das patologias. No final espera-se que esta fase melhore significativamente o processo de identificação e classificação das lesões.

O foco nas imagens de mamografia digital direta deve-se ao facto deste tipo de imagem ser de difícil interpretação. O baixo contraste entre tecidos (glandular e eventuais lesões) leva a que se levantem frequentemente dúvidas acerca do diagnóstico. Além disso a quantidade de especialistas é muito inferior à procura [3], portanto um sistema desta natureza pode ajudar a aliviar estes problemas, descartando exames saudáveis e alertando para os mais problemáticos. Nas imagens de mamografia, as patologias menos evidentes são por vezes as mais letais (microcalcificações e distorção arquitetural, por exemplo), daí este esforço na criação de uma ferramenta que expanda as capacidades dos médicos e os auxilie ativa e/ou passivamente no diagnóstico.

1.1 Epidemiologia

Atendendo aos dados da WHO, é possível verificar que o cancro foi, em 2008, a segunda principal causa de morte nos países desenvolvidos. Responsável por cerca de 7,6 milhões de mortes, ficou somente atrás das doenças cardiovasculares, que tiraram a vida a mais de 17,0 milhões de pessoas, no mesmo período [4]. Olhando mais atentamente para os dados relativos ao cancro, percebe-se que entre as mulheres o cancro da Mama é o mais frequente, cerca de 22 casos a cada 100 mulheres diagnosticadas com cancro. Matando globalmente mais de 450 mil mulheres em 2008¹ [5].

A taxa de incidência do cancro da mama é superior nos países desenvolvidos. Este facto pode ser atribuído a uma melhor capacidade de diagnóstico e à maior esperança média de vida em relação aos países menos desenvolvidos. Sabe-se que a idade é um factor crítico, 95% dos casos ocorrem

¹ Dos cancros da pele só os melanomas fazem parte deste estudo

depois dos 40 anos e sobretudo durante a menopausa [6]. Evitar factores de risco, tais como o tabaco, álcool, obesidade, sedentarismo podem reduzir o risco de desenvolver um cancro. No entanto existem outras causas que não são evitáveis tais como factores hormonais, genéticos, hereditários e idade. [7]

A taxa de prevalência é bastante alta. Segundo a ACS, 89% dos doentes tratados com sucesso, não morre com doenças diretamente associadas ao cancro nos primeiros 5 anos depois do tratamento [6]. O sucesso no tratamento do cancro está intimamente ligado ao estágio da doença e o cancro da mama não é exceção. Quando este é diagnosticado num estado precoce a recuperação é quase certa, na ordem dos 99%, quando diagnosticado num estado intermédio esse valor decresce para 84% e em estados mais avançados têm-se uma taxa de sucesso de apenas 23%. Além de promover melhores taxas de sobrevivência, um diagnóstico precoce permite ainda utilizar métodos de tratamento menos agressivos. Estes passam pela utilização de fármacos, quimioterapia ou radioterapia. Quando estes tratamentos não resultam poderá ser necessária a remoção de uma parte ou da totalidade da mama, respectivamente lumpectomia e mastectomia. Estes dados provam a importância da realização de exames periódicos. A ACS recomenda que se faça uma mamografia anualmente em mulheres, sem sintomas, com idade superior a 40 anos como método de precaução [6].

1.2 Estrutura da Tese

No Capítulo I é feita a introdução ao trabalho, procurando dar a conhecer a motivação para a sua realização e objectivos ao qual se propõe.

No Capítulo II procura-se introduzir os conceitos importantes para a compreensão do trabalho. Nele constam informações sobre anatomia mamária, sistema de aquisição de imagens de mamografia e de sistemas CAD. São ainda referidos os *standards* para gestão de imagens médicas, DICOM, e para diagnóstico, BI-RADS.

No Capítulo III é explicada a Transformada de Wavelet. São abordadas as séries de Wavelet, transformada contínua, discreta para sinais 1D e 2D (imagens). Por fim é ainda apresentada a transformada de Wavelet estática.

No Capítulo IV constam os artigos estudados com o intuito de perceber as melhores abordagens a seguir no trabalho experimental. O objectivo é criar uma maior sensibilidade acerca das dificuldades esperadas na criação de um algoritmo de realce de imagens.

No Capítulo V é detalhado o trabalho experimental realizado. São apresentados os vários algoritmos aplicados, procurando-se justificar cada escolha e alteração feita em relação aos artigos base. Está dividido em duas partes, a primeira consiste em algoritmos de remoção de ruído, a segunda em algoritmos de realce/aumento de contraste.

No Capítulo VI são apresentados os resultados obtidos para cada um dos algoritmos explicados no capítulo anterior. É justificada a utilização de cada métrica e qual a sua relevância para o trabalho. São ainda avaliados os resultados e discutidos os seus valores.

Por fim, no Capítulo VII são feitas as conclusões acerca do trabalho realizado. É discutida a utilidade de cada método e apresentados trabalhos futuros onde se acredita haver potencial para melhorar.

Capítulo II

Enquadramento Teórico

2012

Capítulo II – Enquadramento Teórico

Neste capítulo são apresentadas as noções teóricas básicas e fundamentais para a compreensão da complexidade do tema e do trabalho desenvolvido. De forma a poder fazer juízos de valor sobre a eficiência dos métodos propostos é importante conhecer os objetos em estudo. Assim, será feita uma descrição do sistema mamário e de algumas doenças a ele associado. Falar-se-á também do sistema de aquisição de imagens de mamografia, mais propriamente da mamografia digital direta e por fim dos sistemas CAD.

2.1 - Mama

2.1.1 - Anatomia e Fisiologia

A mama é um órgão glandular característico e exclusivo dos mamíferos. Os humanos possuem duas que podem ser encontradas, simetricamente colocadas em relação ao externo, na parede do tórax, por cima do músculo peitoral, abaixo da clavícula, Figura 1.

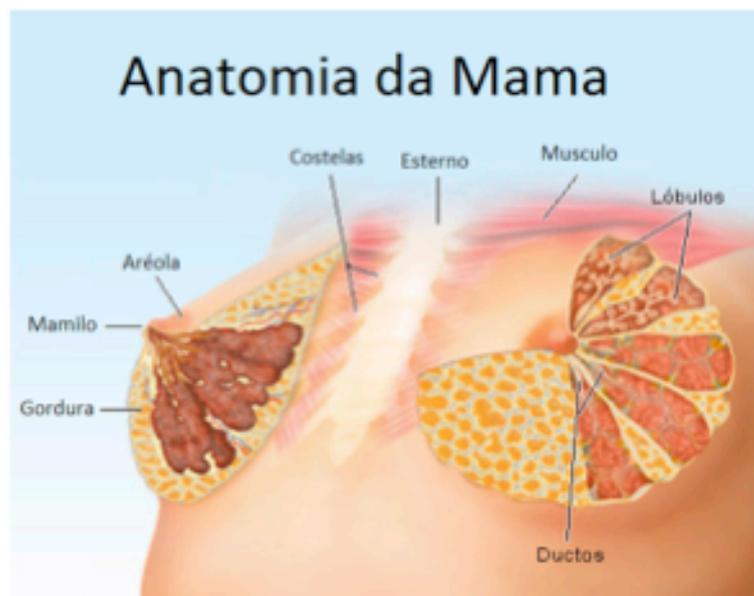


Figura 1 - Anatomia interna da mama humana, adaptado de [8]

Tornam-se funcionais, no sexo feminino durante a gravidez, permanecendo disfuncionais nos homens durante toda a sua vida. A sua função principal é a produção de leite após o parto, de forma a alimentar o recém-nascido nos seus primeiros meses de vida. Visualmente caracteriza-se por uma elevação na zona peitoral e pela presença de uma zona com pigmentação mais

intensa denominada mamilo e aréola. O mamilo é o local de saída do leite e a aréola é responsável pela produção de uma substância oleosa que protege o mamilo durante a amamentação. [9]

São maioritariamente constituídas por tecido adiposo, tecido conectivo e glândulas mamárias. As proporções destes tipos de tecidos variam muito de pessoa para pessoa, sendo que em mulheres mais velhas o tecido glandular tende a desaparecer. O tecido conectivo e adiposo são responsáveis por manter a estrutura do órgão enquanto o tecido glandular tem como finalidade a produção de leite. Encontram-se ainda vasos sanguíneos e linfáticos responsáveis por manter a homeostasia do órgão, fornecendo energia, transportando hormonas e retirando produtos tóxicos resultantes da bioatividade das células.

O tecido glandular consiste em cerca de 15 a 25 lóbulos individuais, separados por tecido adiposo e conjuntivo. Cada lóbulo pode ainda ser dividido por vários alvéolos, onde o leite é produzido. Para drenar o leite dos alvéolos até ao mamilo existem canais que se vão ligando até que formam um canal principal chamado ducto lactífero. Imediatamente antes do mamilo há ainda os sinos ou seios lactíferos responsáveis por acumular leite antes da amamentação.

O local mais propício ao surgimento de patologias malignas associadas a microcalcificações é nas unidades produtoras de leite, Figura 2, mais propriamente nos ductos, onde se encontra uma maior quantidade de células indiferenciadas. É disso exemplo o CDIS, carcinoma ductal in situ, um cancro maligno que ocorre dentro do ducto e que caso rompa a membrana basal se torna invasivo e portanto ainda mais difícil de tratar.

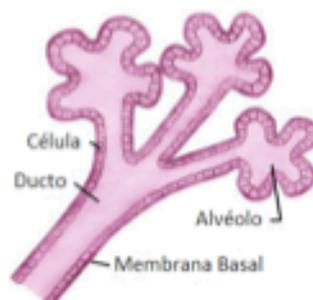


Figura 2 - Unidade terminal ducto-lóbular, TDLU

2.1.2 - Patologia

Existem inúmeras patologias associadas à mama. As mulheres são indiscutivelmente as mais afectadas, no entanto os homens também podem desenvolver este tipo de doença. Neste trabalho, o objecto de estudo são imagens de mamografias, portanto esta secção será orientada às patologias comumente detectadas neste tipo de exame.

Como já foi referido, o cancro da mama é uma patologia grave, mas que com os devidos cuidados se consegue evitar maiores complicações. Existem inúmeros achados mamográficos, optando-se por distingui-los segundo as suas características. Uma divisão possível é segundo o seu aspecto radiográfico, desta forma pode-se agrupar as lesões em assimétricas, massas e microcalcificações.

2.1.2.a - Assimétricas

Sabendo que constituem um par de glândulas colocadas simetricamente no corpo, é de esperar que as mamas sejam semelhantes entre si. Quando isto não se verifica, está-se perante uma anomalia, que deve ser estudada. Depois de identificada a assimetria, procura-se perceber se se trata de uma lesão maligna ou benigna. Esta despistagem é feita, numa primeira fase, atendendo ao historial clínico do paciente. No caso de intervenções cirúrgicas anteriores, é normal que a simetria seja perdida devido a cicatrizes ou remoção de uma parte do tecido mamário. A assimetria pode ter ainda origem numa má colocação e/ou compressão da mama durante a aquisição da imagem. Neste caso deve-se ter em conta que uma assimetria é provocada por estruturas tridimensionais e portanto visível nos dois planos, CC e MLO. A comparação com outros exames anteriores também é muito importante, o crescimento ou aparecimento de estruturas pode ser indicativa de patologia. No caso de a lesão não pertencer a nenhum dos casos anteriores, deve-se tentar perceber se a assimetria é provocada por tecido glandular, ou uma massa. Por norma, o tecido glandular apresenta contornos menos definidos e pode ter tecido adiposo no seu interior, Figura 3 [10].

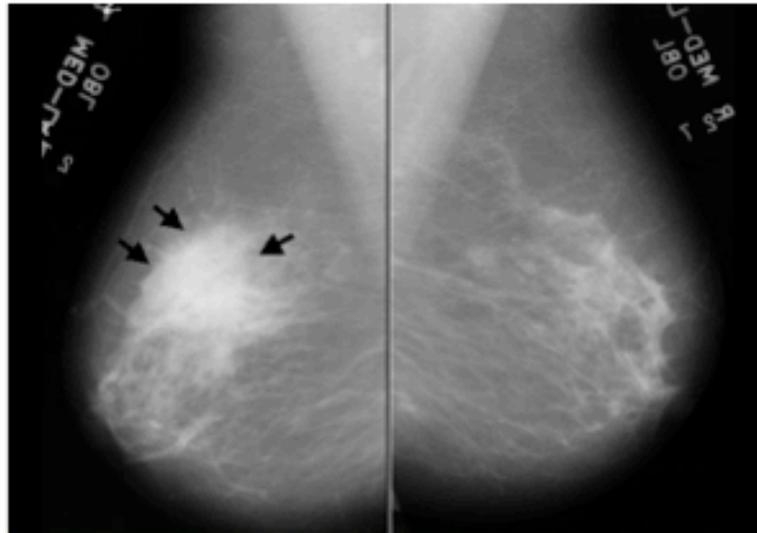


Figura 3 - Exemplo de uma Assimetria benigna numa vista MLO (setas) [10]

Por outro lado as massas apresentam-se como uma zona mais densa e concentrada, sem tecido adiposo e com bordas geralmente bem definidas, Figura 4.

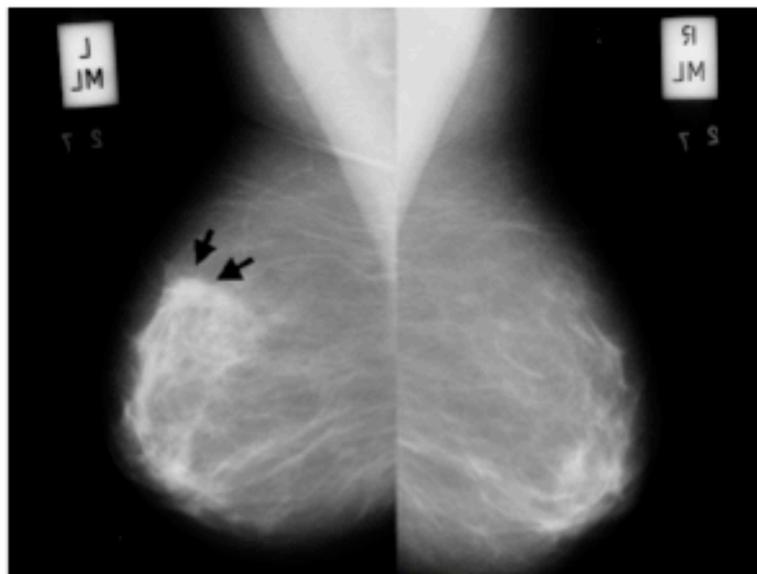


Figura 4 - Exemplo de uma Assimetria maligna numa vista MLO (setas) [10]

Se no final ainda houver dúvidas quanto ao diagnóstico poderá ser necessário recorrer a outros tipos de diagnóstico. São disso exemplo os ultrassons, uma segunda mamografia mais focada na lesão, tendo o cuidado de aumentar o contraste na zona de interesse, ou de se proceder a uma biopsia. [10]

2.1.2.b - Massas

As massas são lesões tridimensionais e portanto, em condições normais, visíveis nas direções CC e MLO. A diferenciação entre benigno e maligno é feita

atendendo às suas características. Depois de detectada uma potencial massa, deve-se ter em conta o seu tamanho, forma, contornos, aspecto radiográfico e o seu posicionamento na mama. Começando pelo aspecto radiográfico, sabe-se que as massas se apresentam como estruturas densas e portanto mais claras nas mamografias. A localização da massa pode ser obtida pelo cruzamento de informação entre a vista CC e MLO, indicando assim se ela se encontra numa zona glandular ou adiposa, o que é importante pois sabe-se que os cancros são mais comuns na zona periférica do tecido mamário. O tamanho só por si não permite fazer um diagnóstico concreto. A sua utilidade é fazer uma análise temporal da evolução da massa, isto é, pretende-se saber se ela cresceu ou se manteve estável de uma mamografia para outra. O crescimento de uma massa pode ser indicativo de malignidade, o aumento em volume pode ser indicativo do avanço da doença [11].

Atendendo à forma é possível fazer a distinção presente na Figura 5. Como regra geral, quanto mais arredondada maior a probabilidade desta ser benigna. Quando irregular as suspeitas de malignidade aumentam. A distorção Arquitectural não é considerada uma massa, no entanto pode aparecer associado a uma. Os contornos devem ser cuidadosamente inspecionados recorrendo, se necessário, a ferramentas de ampliação (lupas ou zoom), pois é uma das características mais importante na determinação da malignidade das massas.

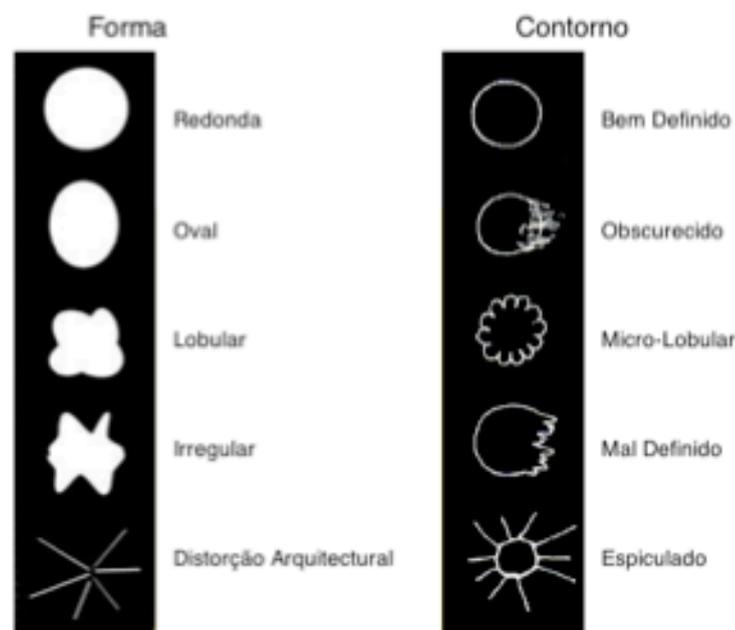


Figura 5 – Representação simplificada da forma e contornos das massas. Adaptado de [12]

Em termos gerais, contornos bem definidas são menos suspeitos, Figura 6-a. No entanto estes podem aparecer sobrepostos com tecidos glandular, ficando mais difícil o diagnóstico, Figura 6-c. Quando os contornos apresentam um contorno enrugado (micro-lobular) as suspeitas de malignidade aumentam, sendo que quanto maior o número de lóbulos, maior a suspeita de lesão maligna, Figura 6-b. Quando os contornos são mal definidos, pode-se estar perante uma lesão benigna com sobreposição de tecido mamário ou então perante uma lesão maligna com infiltração pelos tecidos, Figura 6-d. Nestes casos deve ser feita uma cuidadosa análise, pois o diagnóstico é bastante complexo, sendo por vezes necessário recorrer a ultrassons ou a biopsias para confirmação.

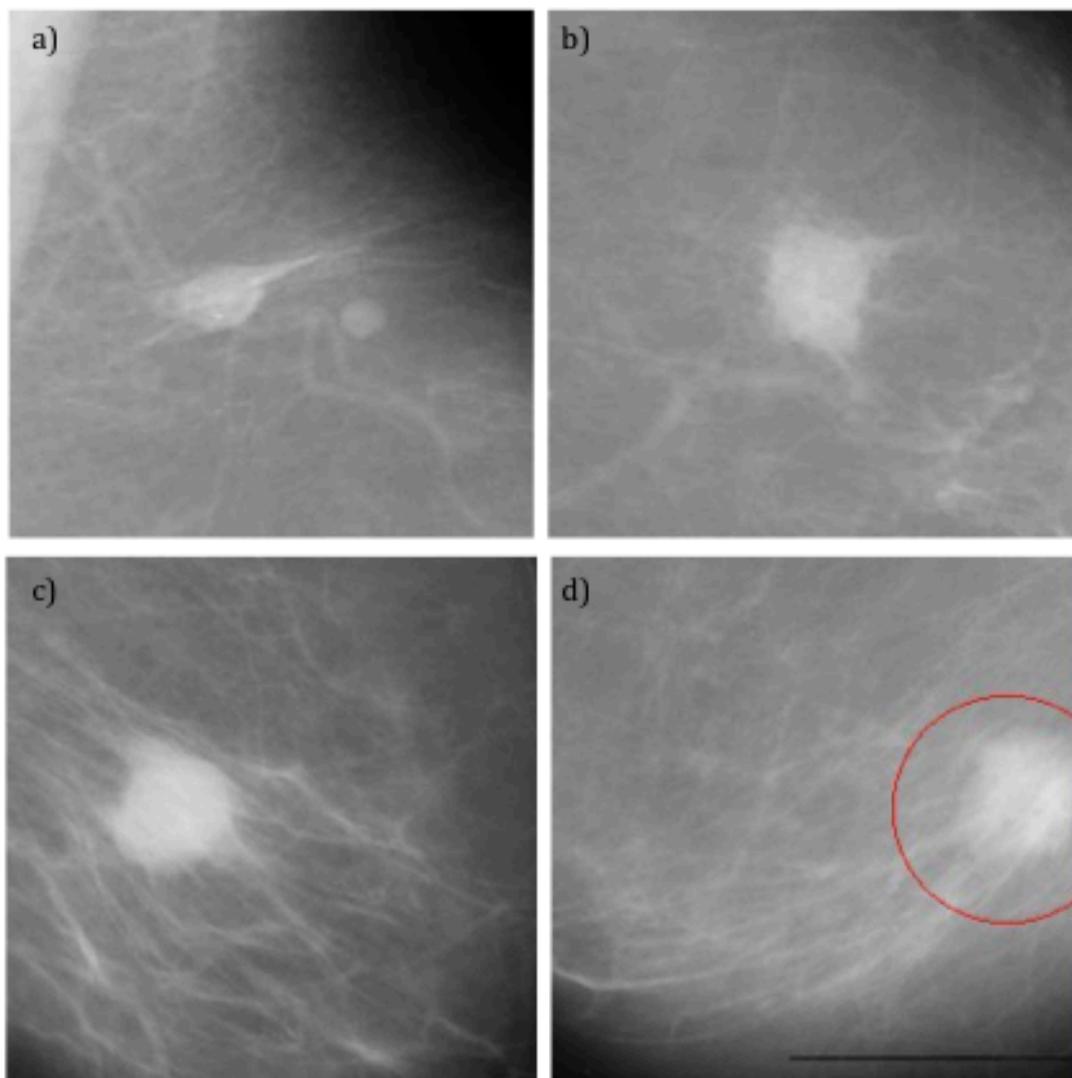


Figura 6 - a) massa oval e circular com contorno bem definido; b) massa lobular com contornos "enrugados"; c) massa com contornos bem definidos, encoberta por tecido mamário; d) massa com contornos mal definidos [11]

2.1.2.c - Calcificações

Surgem devido ao depósito de cálcio no tecido mamário, apresentando-se como zonas ou pontos brancos nas imagens de mamografia. São um achado comum, cerca de 50% das mulheres acima dos 50 anos tem calcificações mamárias e cerca de 10% quando se fala em mulheres mais jovens [13]. Geralmente não apresenta sintomas nem potencial maligno, no entanto a sua análise segue uma política preventiva, já que mesmo em caso de malignidade podem continuar a não existir sintomas até que a doença esteja num estado muito avançado. Podem ser encontradas por toda a mama, tendo origens e diagnósticos diferentes dependendo do seu aspecto e localização. Mais uma vez a utilização de duas vistas perpendiculares é importante para fazer um diagnóstico preciso, tanto para saber a sua localização como aspecto tridimensional. No tecido adiposo podem aparecer como resultado de necrose celular, traumas, infecções, quistos (Figura 7-a e 7-b), este tipo de calcificação, normalmente não é indicador de malignidade [14].

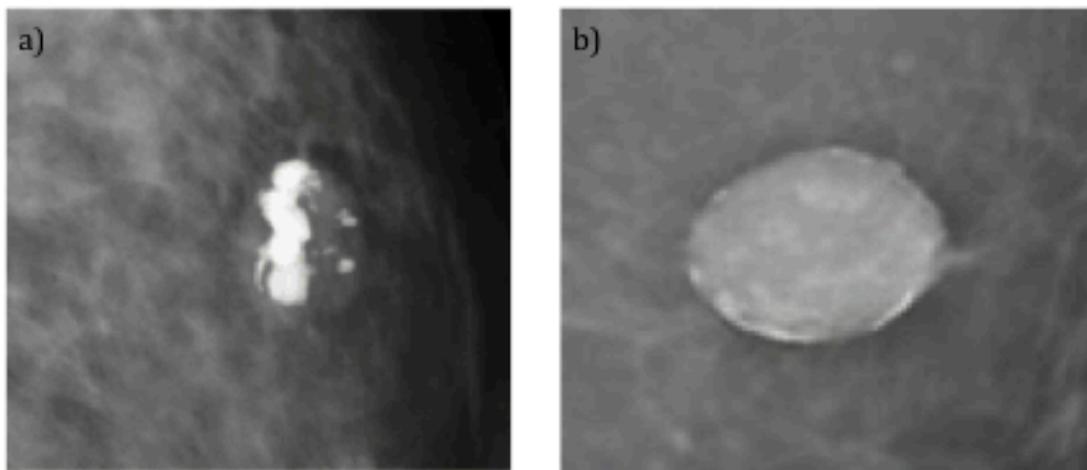


Figura 7 - Exemplos de achados benignos. a) calcificação tipo pipoca; b) casca de ovo [15]

Pode-se ainda encontrar calcificações na pele, Figura 8-a, e vasculares, Figura 8-b, no entanto, mais uma vez, este tipo de calcificação não levanta grandes suspeitas de patologia mamaria cancerígena.

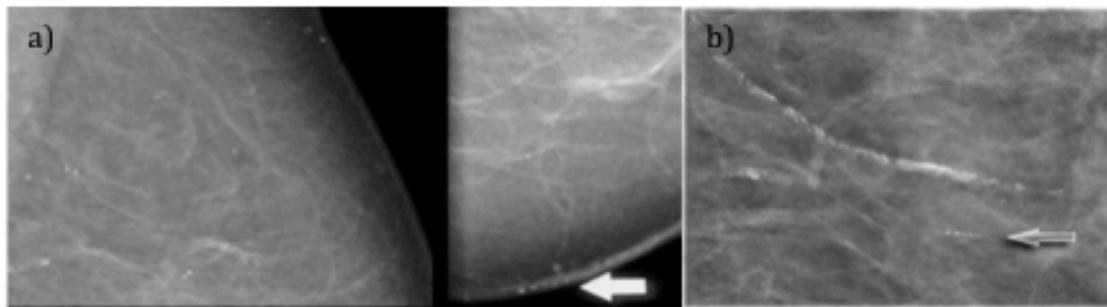


Figura 8 - Exemplo de Calcificações tipicamente benignas. a) vista CC e MLO a indicar microcalcificações cutâneas; b) calcificações vasculares; [15]

No tecido glandular as calcificações podem aparecer devido a depósitos de leite ou atividade celular anormal. Quando as calcificações são encontradas nos lóbulos, a suspeita de malignidade é menor, quando são encontradas nos ductos a suspeita aumenta, podendo-se estar perante um carcinoma ductal *in situ*, um tipo de cancro maligno [13].

As calcificações são caracterizadas pelo seu tamanho, forma, número e distribuição. Como regra geral, tem-se que calcificações (maiores que 2 mm), arredondadas ou ovais e uniformes apresentam menor risco de malignidade, enquanto que microcalcificações (menores que 1mm), irregulares, pleomórficas e agrupadas são tipicamente atribuídas a condições mais graves. O problema no diagnóstico está em fazer a correta distinção das características, o tamanho por exemplo, quando uma calcificação possui um diâmetro entre 1mm e 2mm torna-se difícil inferir se se trata de uma micro ou macro calcificação. O mesmo acontece com o número, não há consenso sobre o número exato que diferencie um grupo de calcificações entre maligno ou benigno (dependendo da referência esse valor pode ser de 4 ou 8). Estas características só por si são algo ambíguas, portanto deve-se ter em conta ainda a forma e a distribuição. A forma é a característica mais importante, contornos irregulares, são altamente indicativos de malignidade. Quanto à distribuição, quando as calcificações estão distribuídas uniformemente pela mama ou agrupadas regionalmente, Figuras 9-a e 9-b, a suspeita é menor. Quando é detectado um *cluster* local, com uma distribuição linear ou por segmentos, existe alguma suspeita de malignidade, Figuras 9-c e 9-d. Nestes casos é frequente realizar-se uma biopsia para confirmar as suspeitas [15] [14].

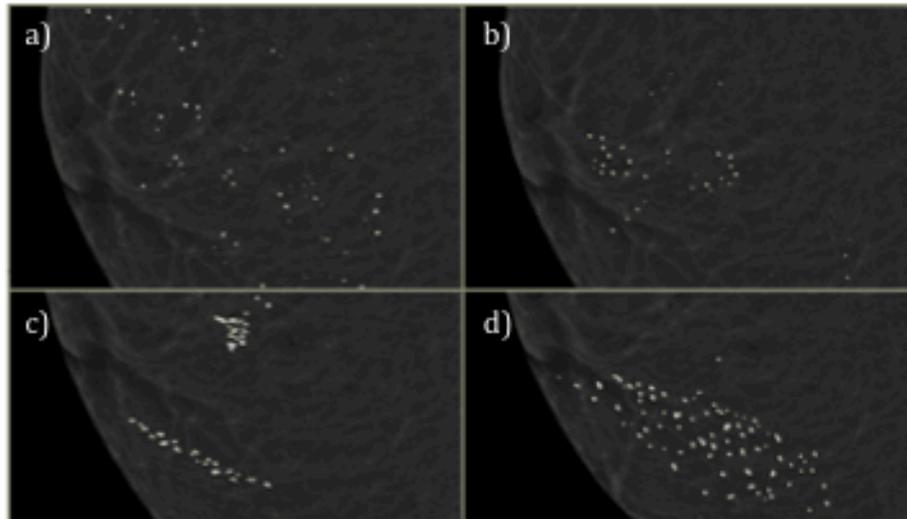


Figura 9 - Diferentes distribuições das microcalcificações; a) Difusa; b) Regional; c) Cluster local e Linear; d) Por Segmentos [15]

Por fim deve ser tida em conta o tamanho e forma relativa entre calcificações dentro do mesmo *cluster*. Um *cluster* que possua todas as calcificações do mesmo tamanho, ou semelhante (isomorfismo) não é tão suspeito como um cluster em que as calcificações apresentam tamanhos e formas distintas (pleomorfismo).

Na Figura 10 encontra-se um quadro resumo com os principais achados associados a microcalcificações, agrupados por grau de malignidade.

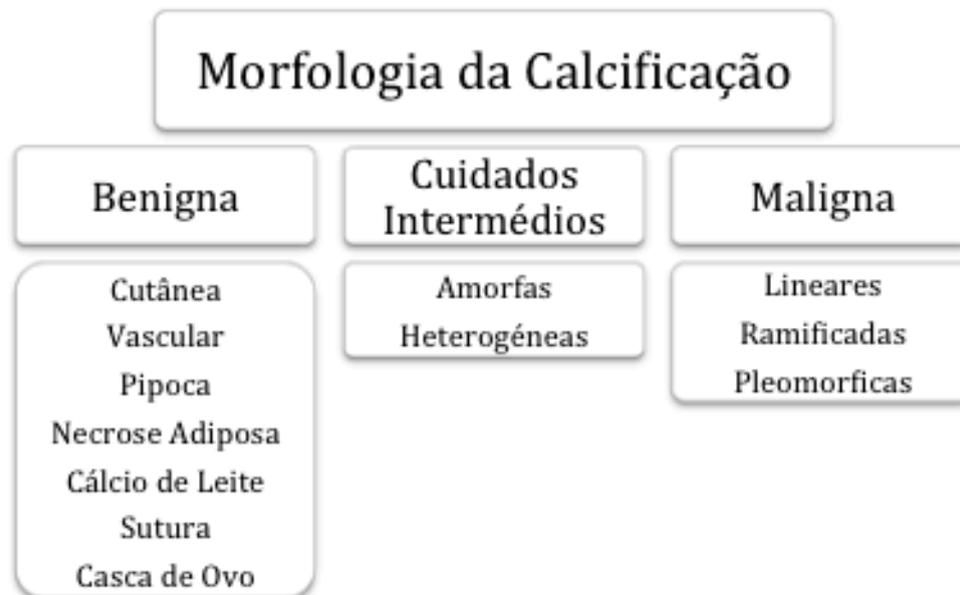


Figura 10 - Classificação das microcalcificações segundo a sua morfologia, adaptado de [15]

2.2 - Mamografia Digital Direta

A mamografia é o exame médico que consiste na aquisição de imagens mamárias com uma fonte de raios-X. É atualmente o exame mais eficiente na detecção das patologias referidas anteriormente [3]. O resultado é uma sombra produzida pela interação dos tecidos que constituem a mama com os Raio-X. Essa sombra é diferente para os vários tecidos, devido aos índices de atenuação específicos de cada um. O tecido adiposo é mais transparente enquanto calcificações são mais opacas, Figura 11.

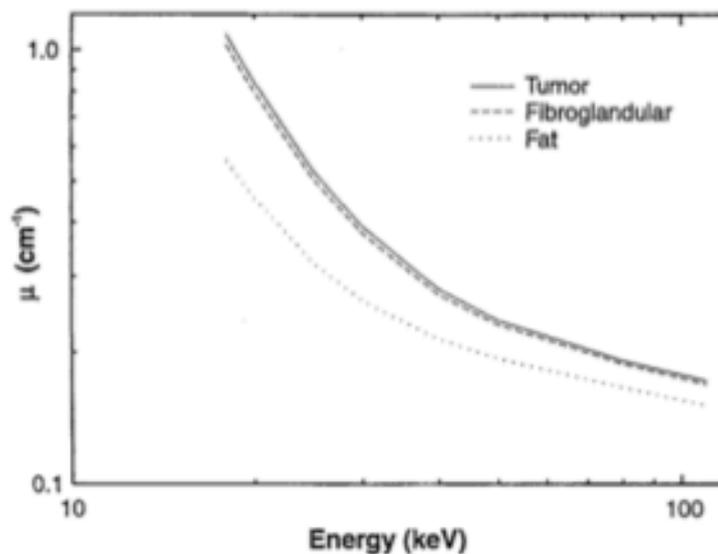


Figura 11 – Índice linear de atenuação para três tipos de tecido em função da energia emitida [1]

O resultado desta diferença é que na imagem o tecido adiposo aparece mais escuro, enquanto que as calcificações aparecem como estruturas mais claras, tal como demonstrado na Figura 12. Note-se que o quanto maior for a quantidade de Raio-X chegar a determinada zona mais escura será essa mesma zona.

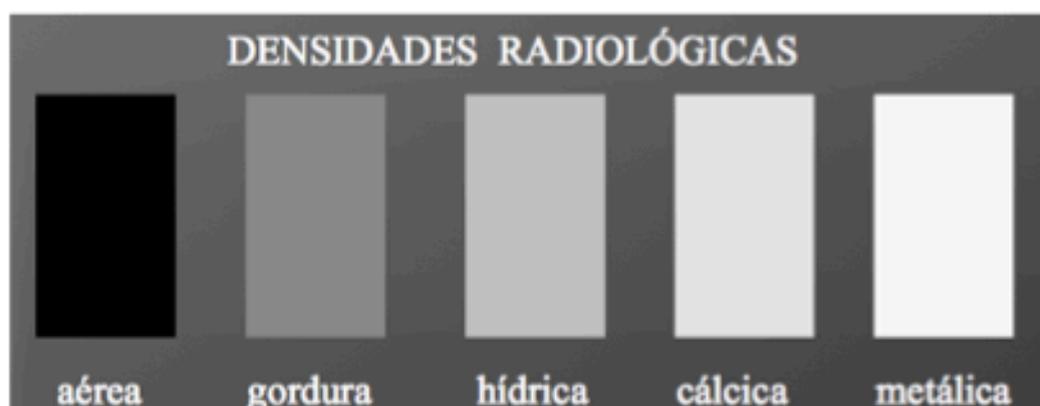


Figura 12 - Classificação em termos de densidades Radiológicas

A mamografia é o exame utilizado correntemente como método de rastreio do cancro da mama, mas pode também ser utilizado para localização de áreas suspeitas ou para orientar o médico durante uma biopsia [1]. O desafio neste tipo de exame é conseguir um bom contraste entre tecidos, boa resolução e a menor dose de radiação possível. O problema é que reduzir a dose leva a uma perda de contraste. Sendo assim, é necessário encontrar o ponto ótimo entre qualidade de imagem e a dose de radiação. Não faz sentido fazer um exame que não seja conclusivo, mas também o exame em si não pode ser a causa da patologia. Várias técnicas são usadas para tentar melhorar a qualidade da imagem sem aumentar a dose. Fazer a compressão da mama durante a aquisição melhora a qualidade da imagem sem aumentar a dose, no entanto tem a desvantagem de ser doloroso para o paciente. A compressão reduz a espessura de tecido atravessada pelos raios-X, ficando menos informação sobreposta. Uma correta colocação da fonte e do receptor de raio-X também influencia a qualidade da imagem, estes devem ser colocados de forma a que os raios-X incidam com o receptor o mais perpendicularmente possível, de forma a aumentar a sua eficiência.

O mamógrafo consiste numa fonte de raio-X, num suporte para a mama com uma placa de compressão e um receptor de raio-X. Tudo isto fica suportado por um braço que permite a rotação e elevação de todo o aparato electrónico de forma a facilitar o seu posicionamento aquando da aquisição, Figura 13

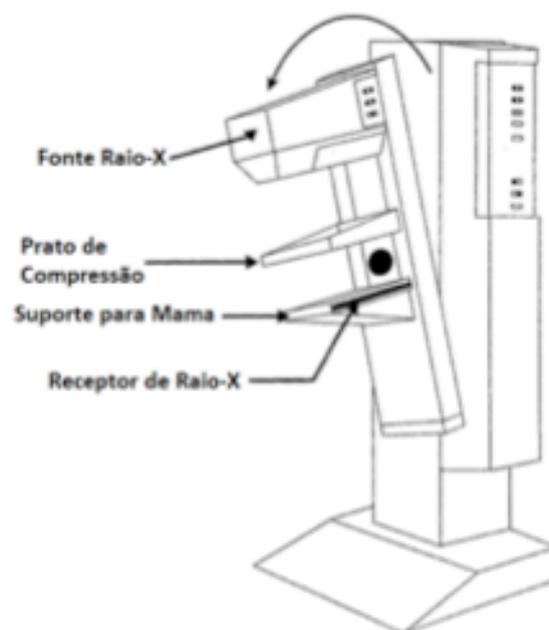


Figura 13 - Mamógrafo, adaptado de [1]

O principal componente que distingue a mamografia tradicional da digital direta é o receptor. Na mamografia tradicional utiliza-se uma cassete contendo um filme fluorescente, que faz a conversão dos raio-X para uma película física. Na mamografia digital direta o receptor consiste num array de CCD's². Estes recebem os Raio-X e fazem a sua conversão para um sinal digital. Ao juntar todos os sinais proveniente de cada CCD obtém-se a imagem digital final. As vantagens deste tipo de sistema são várias, a primeira e mais importante é que permite reduzir a dose aplicada nos pacientes, pois os CCD's são mais sensíveis que os filmes fluorescentes. Os receptores digitais são ainda reutilizáveis o que não acontece com os primeiros. Por fim, uma imagem digital é preferível a uma imagem impressa, pois permite o seu processamento e são mais fáceis de guardar e aceder.

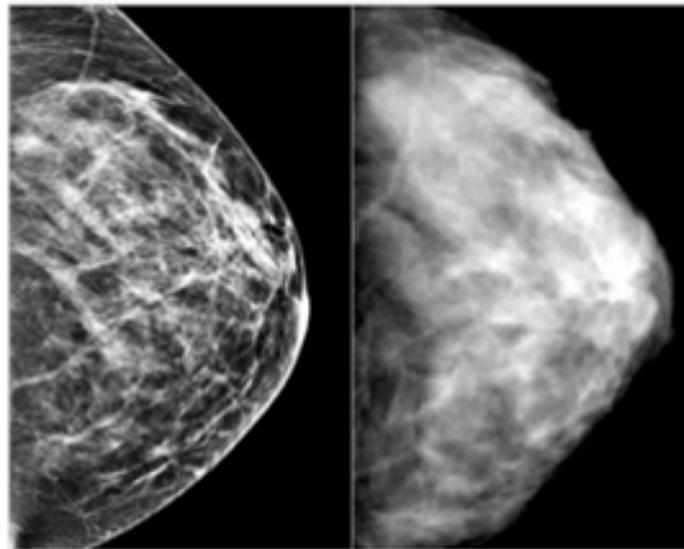


Figura 14 – Mamografia digital direta (esquerda) Vs convencional (direita) [16]

A aquisição das imagens de mamografia segue um conjunto de regras e protocolos. Para exames correntes o mais comum é obter duas imagens para cada mama. Essas imagens são obtidas utilizando duas vistas, denominadas Crânio-caudal (CC) e medio-lateral-oblíqua (MLO).

A vista CC é obtida fazendo a aquisição com o sensor paralelo ao chão, com o raio a incidir verticalmente na direção do chão, Figura 15-c. A segunda é feita ligeiramente na diagonal e quase perpendicular à vista CC, Figura 15-b. A utilização destas duas vistas permite aos médicos estudarem a natureza

² CCD -> Charge-coupled Device é um sensor de luz, capaz de produzir um sinal elétrico proporcional à intensidade luminosa recebida.

tridimensional das lesões e obter informação da localização das estruturas. A utilização da vista MLO em vez de uma vista perfeitamente perpendicular à CC, deve-se ao facto desta permitir analisar uma maior quantidade de tecido mamário.



Figura 15 - Ilustração do posicionamento do sensor e da mama nas vistas b) MLO c) CC.

A maior desvantagem das mamografias é a utilização de radiação ionizante (raio-X). Sabe-se que este tipo de radiação é prejudicial à saúde, podendo ter efeitos secundários graves quando a dose é muito elevada. No entanto, graças à optimização do processo, a dose de radiação aplicada em cada mamografia é bastante reduzida, na ordem dos 0,4 mSV³, o que, em termos práticos, representa a mesma dose que esta sujeito durante 7 semanas devido a causas naturais⁴ [17].

2.2.1 - DICOM

DICOM, *Digital Imaging and Communications in Medicine*, é um standard usado para gerir imagens medicas digitais. Trata-se de um formato de ficheiro e define um conjunto de regras a nível da estrutura das imagens assim como devem ser tratadas, armazenadas e transmitidas. O principal objectivo deste formato é garantir a compatibilidade entre equipamentos, desde o gerador de imagens ao visualizador, evitando assim perda de informação devido a conversões [18]. Garantindo que todos os equipamentos usam a mesma linguagem evitando-se perdas de informação e problemas de compatibilidade tornando o processo de diagnóstico muito mais fluído. [19]

³ Lê-se miliSievert – múltiplo da unidade SI de dose de radiação, Sievert

⁴ Este valor pode variar bastante de local para local, o valor apresentado refere-se aos Estados Unidos da América

Um ficheiro DICOM além de guardar a imagem ou um conjunto de sequências de imagens, guarda ainda toda a informação que levou à criação do ficheiro. É guardada a informação do equipamento de aquisição, parâmetros utilizados, informação do local onde foi realizado o exame, informação da imagem e do paciente, entre outros.

2.2.2 - BI-RADS

O diagnóstico está sujeito a um certo grau de subjetividade por parte do especialista que o realiza. Esta subjetividade pode ainda estender-se à interpretação que outros especialistas possam fazer do diagnóstico do primeiro. Para tornar os relatórios mais objetivos e mais simples de interpretar foram criadas regras/recomendações que os médicos devem seguir aquando da realização do relatório médico. De todos os protocolos criados, o atualmente mais aceite para imagens mamárias é o sistema BI-RADS⁵. Este sistema foi criado em 1992 pelo *American College of Radiology* e definiu um protocolo de diagnóstico, onde refere como deve ser escrito e quais as etapas a seguir na elaboração de um relatório médico. A informação presente num relatório médico deve ser agrupada seguindo a ordem presente na Figura 16.

ORGANIZAÇÃO DO RELATÓRIO

-
- Objetivo
 - Composição Mamária
 - Achados
 - Comparação com estudos anteriores
 - Avaliação Global & Recomendações

Figura 16 - Etapas recomendadas pelo sistema BI-RADS no diagnóstico de imagens de mamografia, adaptado de [20]

A primeira categoria é responsável por indicar o objectivo do estudo e qual foi a razão que levou o paciente a realizar o exame, como por exemplo

⁵ Breast Imaging Reporting and Data System

exame de rotina. A segunda define o tipo de mama que se está a analisar segundo a sua constituição. Definem-se 4 categorias, Figura 17: predominantemente adiposa quando o tecido fibroglandular representa menos de 25% de todo o tecido mamário; fibroglandular quando a proporção se encontra entre 26% e 50% do volume; heterogeneamente densa proporções entre 51% e 75%; e por fim quando a relação entre o volume de tecido fibroglandular e o volume total mamário é superior a 76% considera-se uma mama muito densa [20].

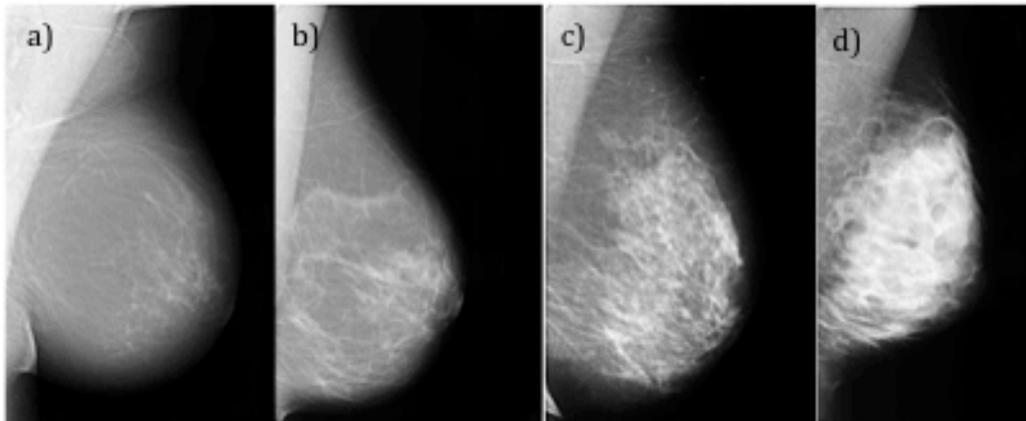


Figura 17 - Exemplo das diferentes categorias BI-RADS para o tipo de mama. a) predominantemente adiposa; b) fibroglandular; c) heterogeneamente densa e d) Densa

Esta divisão é extremamente importante pois o diagnóstico fica dificultado quando o tecido glandular se encontra numa quantidade elevada, como acontece nos tipos representados na figura 17 c) e d). Note-se que o tecido glandular pode encobrir patologias, por terem atenuações semelhantes ao raio-X. Depois de identificado o tipo de mama procede-se ao diagnóstico propriamente dito. Os achados são divididos, como já foi dito no ponto 2.1.2, em assimetrias, massas, calcificações e distorção arquitetural. Dentro destas categorias ainda existem várias subdivisões, as quais já foram referidas anteriormente. Por fim deve ser atribuída uma classificação final ao diagnóstico, segundo a sua gravidade.

O sistema BI-RAD divide o diagnóstico em 7 categorias distintas, presentes na Tabela 1.

Tabela 1 - Categorias BI-RADS usadas no diagnósticos de imagens mamárias, Adaptado de [21]

Breast Imaging Reporting and Database System (BI-RADS®)		
Categoria	Diagnóstico	Recomendações
a. Diagnóstico inconclusivo		
0	Necessária informação adicional, novo exame ou exame anterior	Sem recomendações até diagnóstico conclusivo
b. Diagnóstico conclusivo		
1	Negativo	Mamografia de rotina, anual (se > 40 anos)
2	Benigna	Mamografia de rotina, anual (se > 40 anos)
3	Provavelmente Benigna	Mamografia de seguimento após 6 meses
4	Anomalia suspeita: 4A - Leve 4B - Moderada 4C - Forte, mas não típica de cancro	Normalmente requer biopsia
5	Suspeita de malignidade elevada	Requer biopsia ou tratamento
6	Malignidade provada com biopsia	Proceder a tratamento adequado

2.3 - Sistemas CAD

O conceito de sistema CAD surgiu nos anos 60, mas só nos anos 80 quando os computadores se tornaram um ferramenta comum e mais simples é que se começou a apostar neste tipo de sistema. Atualmente, são usados de forma rotineira em hospitais no diagnóstico de várias doenças. O seu potencial tem vindo a ser provado com o passar do tempo, o que levou a um aumento na investigação nesta área. [22]

Podem ser utilizados em todo o tipo de imagens digitais, desde as mais simples como as imagens de raio-X até às mais complexas como as de MRI. Embora aplicável a informação muito diferente, a criação de um sistema deste tipo segue alguns pontos chave, Figura 18.



Figura 18 - Divisão por etapas de um Sistema CAD genérico

A aquisição da imagem é naturalmente a primeira etapa de um sistema CAD. No caso das imagens de Raio-X esta etapa consiste simplesmente na leitura de uma quantidade de radiação utilizando uma matriz de sensores. Noutros casos, como por exemplo TAC e MRI, é necessário a aplicação de algoritmos de reconstrução, pois o sistema de leitura não adquire diretamente a informação que é visualizada.

No pré-processamento, ou processamento de baixo-nível, são aplicados algoritmos com o objectivo de reduzir o ruído da imagem e evidenciar a informação importante. Pode ser necessário alinhar as imagens ou corrigir falhas da fase de aquisição, como por exemplo não uniformidades de iluminação. Por fim pode-se ainda tentar reduzir os dados, eliminando partes da imagem sem informação, seleccionando uma ROI (region of interest).

Na Segmentação é feita a diferenciação entre a informação da imagem. O objectivo é separar a informação de forma a poder processa-la individualmente. Pode ser uma separação simplesmente entre fundo e achados, ou então em várias estruturas distintas. É comum a utilização de *thresholds* nesta etapa, dada a sua simplicidade, no entanto podem também ser utilizadas outras abordagens nomeadamente métodos estatísticos e mapeamentos.

Por fim a informação retirada da imagem pela segmentação é classificada. São extraídas características, como por exemplo área, volume, perímetro, circularidade, intensidade média, entre outras. As características extraídas devem possuir significância na distinção dos achados. Com as características calculadas, passa a ser possível avaliar se determinado achado é realmente uma doença e, em caso afirmativo, determinar a sua importância e malignidade. Esta decisão é conseguida à base de classificadores, tais como redes neuronais, *K-means*, *SVM (Support Vector Machine)*, entre outras. Se o número de características for baixo, o que raramente acontece, pode ser usado simplesmente um *threshold* ou uma árvore de decisão.

A eficiência de um sistema desta natureza é vista atendendo à capacidade de detecção. Para problemas binários é frequentemente utilizada a Sensibilidade e Especificidade para fazer essa medição. A sensibilidade é a capacidade de o algoritmo detectar as doenças quando elas existem, enquanto a especificidade é a capacidade de detectar corretamente as amostras saudáveis. O ideal será atingir 100% de ambas as medidas ou próximo disso. São calculadas usando as seguintes equações:

$$\text{Sensibilidade} = \frac{TP}{TP + FN}$$
$$\text{Especificidade} = \frac{TN}{TN + FP}$$

Em que *TP* representa o número de resultados positivos confirmados como tal, *TN* são os resultados negativos confirmados, *FP* são os resultados erradamente classificados como positivos e os *FN* são os resultados negativos quando o resultado deveria ser positivo.

Este tipo de medida da fiabilidade dos algoritmos implica que se avalie uma quantidade significativa de exames médicos com os respectivos diagnósticos. De forma a fazer uma comparação realista entre algoritmos desenvolvidos por grupos diferentes de investigação foram criadas bases de dados de imagens médicas. Elas possuem um número considerável de imagens e estão disponíveis para *download*. No caso das imagens de mamografia existem várias, sendo as mais conhecidas a MIAS e a DDSM. Estas bases de dados trazem as imagens MLO e CC de ambas as mamas e o respectivo diagnóstico com localização das lesões quando existentes.

Capítulo III

Transformada De Wavelet

2012

Capítulo III – Transformada De Wavelet

Os primeiros passos da WT⁶ foram dados em 1909 por A. Haar. No entanto, posteriormente, na década de 80, graças ao trabalho desenvolvido por Alex Grossman, Jean Morlet, Ingrid Daubechies e Stéphane Mallat é que se percebeu o verdadeiro potencial desta ferramenta [23]. Stéphane Mallat teve um papel fundamental na aplicação prática das Wavelets no processamento digital de sinais, mais propriamente imagens. A WT tem inúmeras aplicações, e atualmente, é utilizada em filtragem, análise e compressão de imagens (JPEG 2000, por exemplo), astronomia, previsão de terremotos e maremotos entre outras aplicações [24]. Surgiu com o propósito de colmatar algumas limitações da FT e da STFT [25]. Tal como a FT e a STFT, procura alterar a representação dos sinais de forma a retirar informação que à partida não se encontra perceptível. A diferença essencial está no seu elemento base. Enquanto que a FT e a STFT procuram decompor os sinais na soma de Waves (senos/exponenciais complexas, $e^{-j\omega t}$) a WT decompõe os sinais na soma de Wavelets ($\psi_{a,b}$). Esta diferença induz potencialidades diferentes em cada uma. Enquanto a FT é mais eficiente na análise de sinais periódicos, invariantes no tempo ou estacionários (tal como as Waves), a WT consegue descrever melhor sinais transientes, não estacionários ou variantes no tempo [26]. Na Figura 19, é possível ter uma ideia das diferenças entre as transformadas.

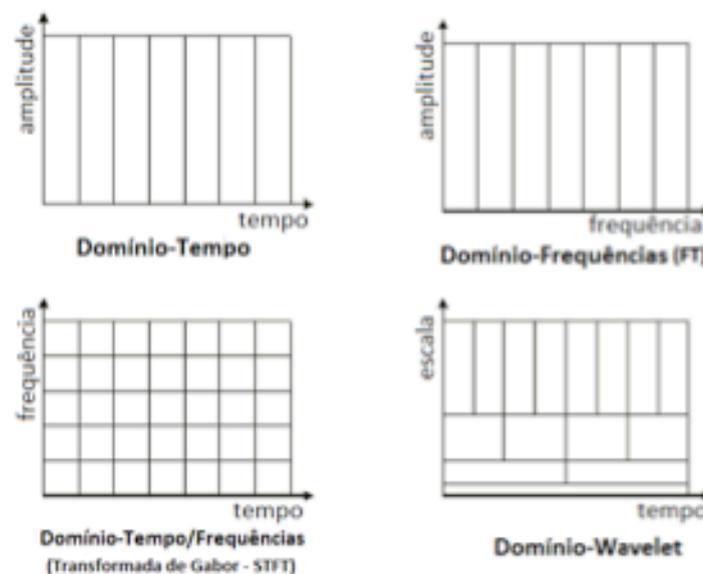


Figura 19 – Exemplo de grelhas espaço-espectrais para várias formas de representar sinais

⁶ WT, inclui a DWT e a CWT, transformada discreta e contínua, respectivamente.

Considerando um sinal como uma dada amplitude, $f(t)$, a cada instante de tempo, t , a amplitude poderá representar inúmeras grandezas, tais como força, posição, corrente. Com a FT (1) passamos a analisar o sinal no domínio das frequências, isto é, o sinal passa a ser visto em relação às suas variações. A grande desvantagem desta transformada é perder-se a noção do tempo/espaco, deixa-se de ter uma noção direta de onde é que altas ou baixas variações ocorrem, só se sabe quais existem e a sua importância (uma frequência importante tem uma amplitude relativamente elevada, enquanto que frequências que não existem ou pouco importantes tem amplitudes nulas ou próximo disso). Outra desvantagem da FT é que para ser calculada é necessário conhecer-se o sinal em todo o seu domínio, o que torna a sua implementação direta em sistemas reais impossível.

$$\mathcal{F}\{f(t)\} = F(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-j\omega t} dt \quad (1)$$

Na STFT (2), começa-se por definir uma janela temporal, $\omega(t - \tau)$, e calcula-se a FT nesse intervalo de tempo partindo do principio que o sinal visto por essa janela é completo. Desta forma consegue-se ter uma noção do local onde ocorrem as frequências através da posição da janela e passa a ser possível utilizar-se em sistemas reais.

$$STFT\{f(t)\}(\tau, \omega) = F(\tau, \omega) = \int_{-\infty}^{+\infty} f(t)\omega(t - \tau)e^{-j\omega t} dt \quad (2)$$

Note-se que esta abordagem introduz uma nova variável, τ , que representa a componente temporal/espacial que faltava na FT e a função $\omega(t)$ que representa a janela temporal. O problema está na determinação do tamanho da janela, note-se que dentro da janela continua a ser impossível determinar exatamente onde é que determinada variação ocorre. Portanto, se se usar uma janela muito larga a incerteza acerca da sua localização será maior. Sendo assim, perde-se resolução temporal e ganha-se em resolução espectral. Por outro lado, se for usada uma janela muito pequena perde-se resolução nas frequências e ganha-se em temporal, Figura 20. [27]

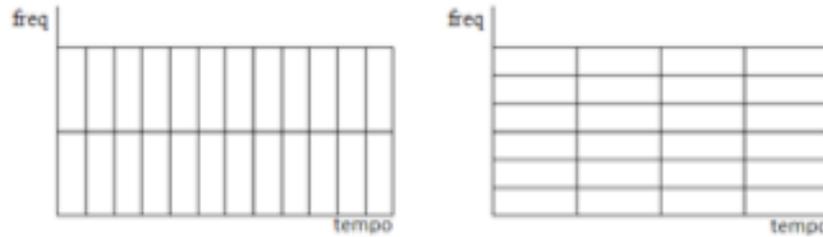


Figura 20 - Janela estreita (esquerda) e larga (direita) na STFT

Por fim a WT, analisa os sinais em diferentes resoluções, daí também se designar uma análise em multiresolução. [25]. Pela Figura 19, é possível verificar que para baixas frequências utilizam-se janelas temporais mais largas e para frequências maiores as janelas são mais estreitas. Desta forma a análise adapta-se ao sinal, conseguindo-se ter uma resolução temporal e espectral mais eficiente.

$$CWT(r, s) = \langle f(t), \psi_{r,s} \rangle = \int_{-\infty}^{+\infty} f(t) \psi_{r,s}^*(t) dt \quad (3)$$

De reparar que na CWT, não existem frequências, pois uma Wavelet não possui diretamente uma única frequência. No entanto, esta é substituída por uma variável de escala, r , que tal como a frequência, pode ser considerada uma medida da variação do sinal. Para fazer a localização das variações é utilizada a variável de posição, s .

3.1 - Teoria de Wavelets

Uma Wavelet é literalmente uma onda (Wave) pequena. Não tem uma forma definida, basicamente é uma função com média zero (5) e com energia finita, não nula (4) e concentrada numa vizinhança.

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt \neq \{0, \infty\} \quad (4)$$

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (5)$$

Na Figura 21 é possível ver, a título de exemplo, a representação gráfica de uma Wave e uma Wavelet.

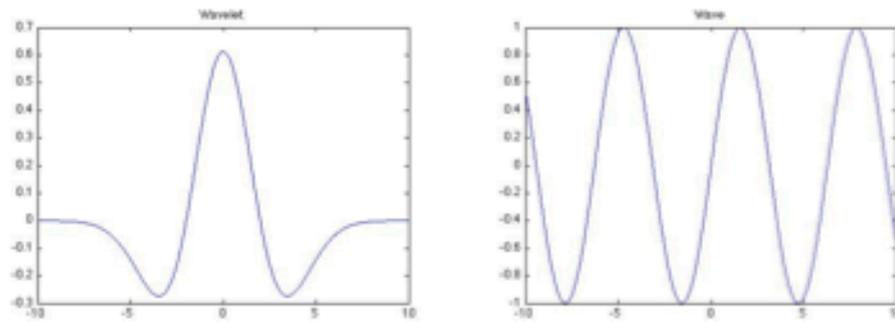


Figura 21 - Exemplo de uma Wavelet do tipo chapéu mexicano (esquerda) e de uma onda sinusoidal (direita)

Com uma Wavelet, recorrendo a translações e operações de escala é possível criar uma família de Wavelets, $\psi_{r,s}$.

$$\psi_{r,s}(x) = 2^{\frac{r}{2}}\psi(2^r x - s) \quad (6)$$

Em que ψ é designada como a função mãe, r é o factor de escala, s a posição e x a variável independente. Na 22, pode-se visualizar, a título de exemplo, algumas Wavelets com função mãe (ψ) Daubechies 2.

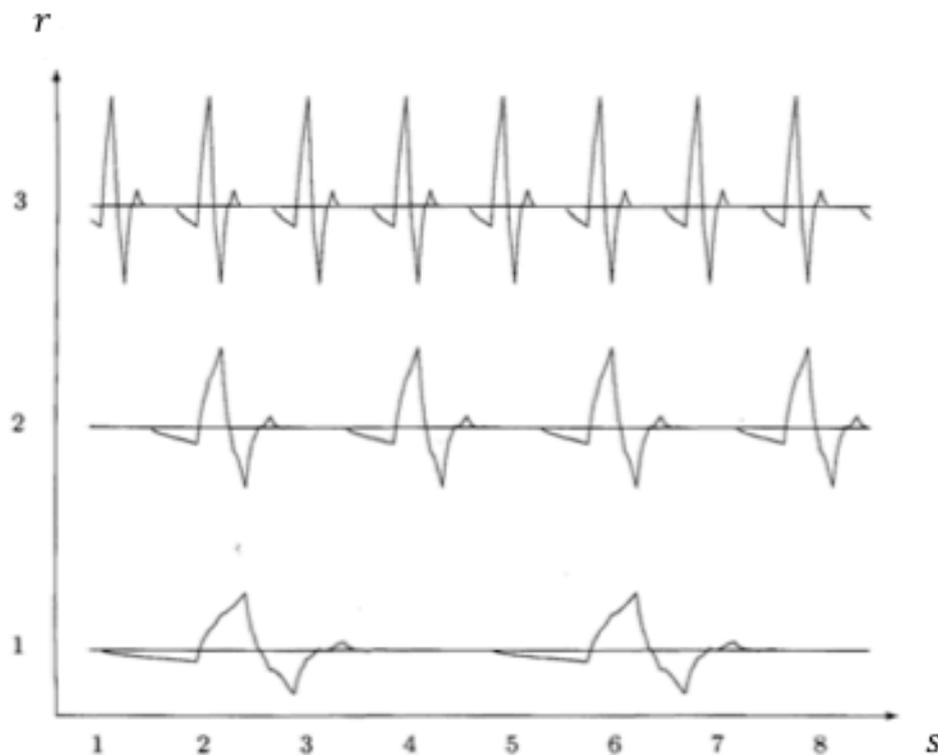


Figura 22 - Exemplo de Wavelets Daubechies 2 escaladas e deslocadas

Facilmente se percebe pela Figura 22, que um aumento em r leva à compressão da função mãe e que um aumento em s provoca um deslocamento positivo ao longo do eixo xx . É ainda possível provar que, com uma família de Wavelets, é possível representar qualquer função, $f(x) \in L^2(R)$ fazendo a soma

escalada de todas as Wavelet pertencentes a essa família. Esta é a ideia fundamental da CWT que será de seguida explicada em maior pormenor.

3.2 - CWT

Quando se calcula a CWT, o que se procura fazer na prática é obter o valor dos coeficientes para determinada escala e translação, $CWT(r, s)$ (á semelhança da transformada de Fourier para a frequência).

$$CWT(r, s) = \int_{-\infty}^{+\infty} f(t)\psi_{r,s}^*(t) dt \quad (7)$$

Com:

$$\psi_{r,s}^*(t) = 2^{\frac{r}{2}}\psi^*(2^r t - s) \quad (8)$$

Na Figura 23 é possível ver a CWT de um onda chirp⁷ usando uma Wavelet de Morlet.

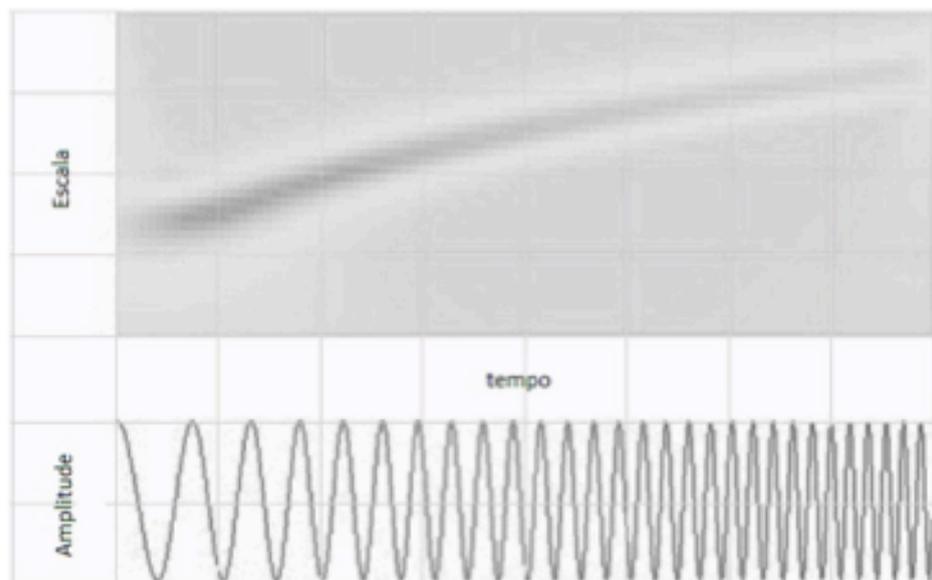


Figura 23 - Exemplo de CWT; onda Chirp (em baixo) e resultado (em cima)

O primeiro aspecto que se pode verificar é que a representação de um sinal 1D tem uma representação 2D na CWT. Este resultado é esperado pois o objectivo era mesmo ter-se uma localização espacial das frequências. Pela análise da imagem também se percebe que para tempos mais baixos são as escalas mais baixas que dominam (na imagem, quando mais escuro, maior o valor dos coeficientes), expressando as baixas variações do sinal para esses tempos.

⁷ Onda Chirp consiste numa função com frequência crescente ou decrescente ao longo do tempo

Conforme as oscilações aumentam, o mapeamento da CWT reflete essa alteração, ficando as escalas maiores com valores mais fortes de coeficientes.

A CWT, dentro de algumas restrições (10), admite inversa, sendo assim é possível utilizando os coeficientes obter a função original [25]. Esta capacidade é importante, pois permite atuar sobre os coeficientes de forma a fazer filtragem ou melhoramento de sinais.

$$f(t) = \frac{2}{C_\psi} \int_{-\infty}^{+\infty} \left[\int_{-\infty}^{+\infty} CWT(r, s) \psi_{r,s}(t) dr \right] \frac{ds}{s^2} \quad (9)$$

Com:

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\Psi(\zeta)|^2}{|\zeta|} d\zeta < +\infty \quad (10)$$

3.3 - Função de Escala

Para efeitos práticos uma Wavelet pode ser vista como um filtro passa-alto, em que uma alteração na escala provoca uma alteração na frequência de corte. Esta ideia é importante, pois de forma a incluir todo o espectro de um sinal, utilizando somente filtros passa-alto, implica a criação de um filtro passa-tudo. O problema é que obter um filtro passa-tudo recorrendo ao escalonamento da função wavelet só é conseguido para $r = -\infty$. É por este facto que para efeitos de análise multiresolução é comum definir-se um filtro passa-baixo que inclui todas as frequências não representadas pelas Wavelets com $r \leq r_0$ (r_0 normalmente toma o valor de 1) [28]. A função responsável por acoplar essa informação é a chamada função de escala, ϕ . Esta função tem as mesmas propriedades da função de Wavelet a nível de escalonamento e translação, a principal diferença assenta no facto de, por se tratar de uma função representativa de um filtro passa-baixo, possuir integral em \mathbb{R} igual a 1, tal como indicado na equação (11).

$$\int_{-\infty}^{+\infty} \phi(t) dt = 1 \quad (11)$$

É possível provar que através da função de escala é possível obter as funções de escala e de Wavelet de uma escala superior utilizando as equações (12 e 13). [24,25]

$$\phi(t) = \sqrt{2} \sum_{n \in \mathbb{Z}} h_\phi \phi(2t - n) \quad (12)$$

$$\psi(t) = \sqrt{2} \sum_{n \in \mathbb{Z}} h_\psi \phi(2t - n) \quad (13)$$

Em que h_ϕ e h_ψ são o vector de escala e de Wavelet respectivamente. Estas equações são as chamadas equações de refinamento e a sua importância vai ser mostrada mais à frente na DWT.

A construção dos filtros não é um conceito trivial, e foge ao objetivo do trabalho. Daí e pelo facto da aplicação prática da WT não depender da sua total compreensão não se vai aprofundar este tema. Aconselha-se (Oliveira, *Análise de Sinais para Engenheiros - Uma Abordagem Via WAVELETS*, 2007) para um estudo mais aprofundado. Na prática a escolha das funções é feita recorrendo a bases de filtros já existentes [29].

3.4 - Serie de Wavelet

Com a noção de wavelet e função de escala, passa a ser possível aplicar as séries de Wavelet de uma forma semelhante às séries de Fourier. Esta operação matemática decompõe o sinal como a soma de funções de escala e wavelets. A aproximação será tão melhor, quanto maior a escala analisada (devido aos efeitos explicados anteriormente). Desta forma, o sinal poderá ser representado como:

$$f(t) = \sum_s c_{r_0}(s) \phi_{r_0,s}(t) + \sum_{r=r_0}^{+\infty} \sum_s d_r(s) \psi_{r,s}(t) \quad (14)$$

Em que o primeiro somatório representa a aproximação do sinal e o segundo os detalhes. Os coeficientes c_{r_0} e d_r são calculados utilizando as equações (15) e (16):

$$c_{r_0}(s) = \int f(t) \phi_{r_0,s}(t) dt \quad (15)$$

$$d_r(s) = \int f(t) \psi_{r,s}(t) dt \quad (16)$$

De notar que nesta decomposição, existe uma clara distinção entre aproximação e detalhes. A aproximação só é calculada para uma escala (r_0), enquanto os detalhes são calculados de r_0 em diante, quantas vezes se intender necessário. O número de escalas a calcular será um compromisso entre a complexidade de computação/quantidade de coeficientes e o erro de aproximação, sabendo à partida que quantas mais escalas analisadas, menor será

o erro e maior o número de coeficientes/cálculos necessários. Note-se que teoricamente o erro de aproximação só é nulo para $r = +\infty$.

3.5 - DWT

Para a análise de sinais discretos, como são exemplo as imagens, foi criada a DWT. Esta, parte dos princípios da CWT e aplica-os no domínio discreto. As vantagens da DWT em relação à FT continuam a ser válidas. Por uma questão de simplicidade será inicialmente feito um enquadramento para a DWT a 1D. Depois disso será feita a aplicação prática em imagens (2D). Partindo de um sinal discreto, $f[n]$ com $n \in \{0,1,2, \dots, M-1\}$, calcula-se a transformada direta utilizando as equações (17) e (18):

$$W_\phi(r_0, s) = \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{r_0, s}[n] \quad (17)$$

$$W_\psi(r, s) = \frac{1}{\sqrt{M}} \sum_n f[n] \psi_{r, s}[n] \quad (18)$$

Note-se que a forma das equações é muito semelhante as equações (15 e 16), fazendo simplesmente a alteração da variável continua (x) para a variável discreta (n) e adicionando um termo de normalização ($\frac{1}{\sqrt{M}}$). A transformada inversa, é feita recorrendo à equação (19):

$$f[n] = \frac{1}{\sqrt{M}} \sum_s W_\phi(r_0, s) \phi_{r_0, s}[n] + \frac{1}{\sqrt{M}} \sum_{r=r_0}^{\infty} \sum_s W_\psi(r, s) \psi_{r, s}[n] \quad (19)$$

Por outro lado, existe uma forma mais prática de calcular a DWT. Esta abordagem foi apresentada pela primeira vez por Stephan Mallat em [30]. Partindo das equações (17 e 18), das equações de refinamento (12 e 13) e das que descrevem a translação e a escala (6) é possível obter uma relação entre os coeficientes de uma escala e da escala seguinte:

$$W_\phi(r, s) = h_\phi(-2s) * W_\phi(r+1, 2s) \quad (20)$$

$$W_\psi(r, s) = h_\psi(-2s) * W_\psi(r+1, 2s) \quad (21)$$

Através destas relações é possível decompor os sinal em várias sub-bandas, conhecendo os coeficientes de aproximação, os vectores de escala e de Wavelet. Os coeficientes de aproximação para a escala R , será o sinal original, e a cada iteração, os coeficientes de aproximação serão divididos numa componente wavelet e noutra de escala, tal como indicado na Figura 24.

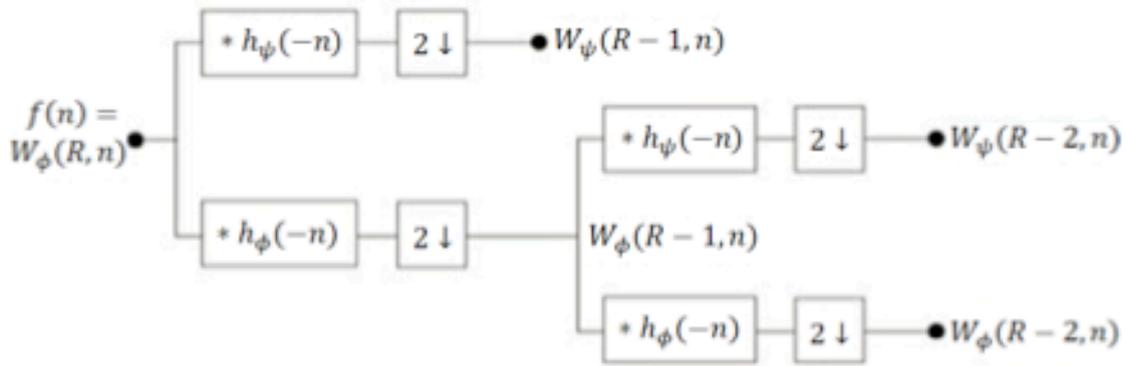


Figura 24 – Transformada de Wavelet 1D em duas escalas

A decomposição do sinal em duas sub-bandas é uma operação redundante, pois duplica a informação do sinal. Por este facto, depois da aplicação dos filtros faz-se uma decimação do sinal por um fator de 2, de forma a eliminar a informação redundante. Esta decimação está representada nas equações (20 e 21), na medida em que s na escala r aparece multiplicado por 2 na escala $r + 1$. Mais uma vez verifica-se que os vectores de escala e de Wavelet funcionam como dois filtros, em que o de escala pode ser visto como um passa-baixo e o de Wavelet como um passa-alto. Assim, é possível representar o resultado da DWT do ponto de vista das frequências. Na Figura 25, está representada a divisão em sub-bandas resultante da aplicação de ambos os filtros.

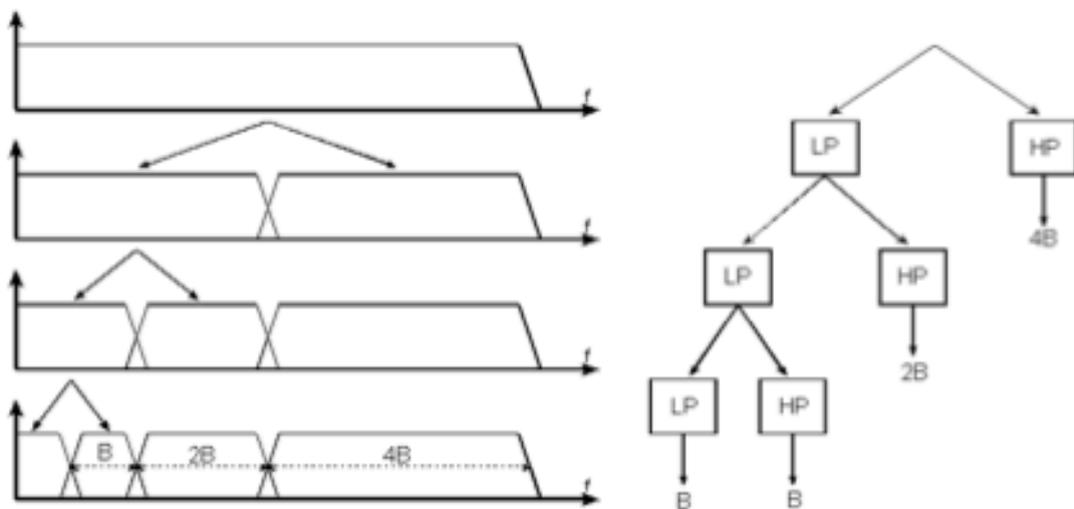


Figura 25 - Representação da transformada de wavelet em termos da divisão das frequências em sub-bandas

A cada nova escala analisada o espectro do sinal é dividido em metade, uma parte é resultado da função Wavelet (HP) e a outra da função de escala (LP).

Este passo é possível pois os filtros são desenhados de forma a acomodar todo o espectro de frequências. Desta forma torna-se possível atuar sobre cada banda individualmente. A quantidade de subdivisões dependerá do problema em questão, no limite poder-se-á fazer somente uma subdivisão, ou então (no caso discreto) até que só haja um único valor para analisar.

Depois de manipular os coeficientes será interessante voltar a obter o sinal com as alterações introduzidas. Para tal aplica-se a transformada inversa para voltar a juntar toda a informação num só sinal. A reconstrução é feita da forma inversa à decomposição do sinal, tal como é possível verificar na Figura 26.

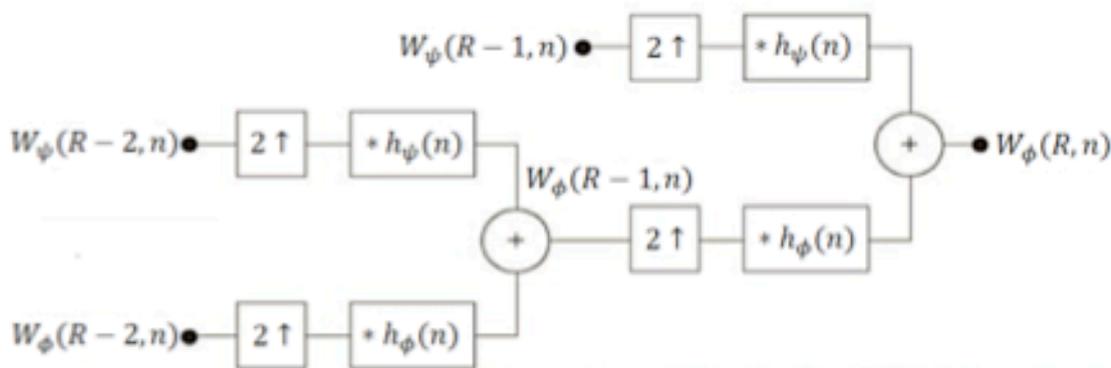


Figura 26 - Transformada inversa de Wavelet de um sinal discreto 1D

A aplicação das Wavelets em imagens vem no seguimento do trabalho desenvolvido por Mallat. Segundo ele, calcular a DWT de uma imagem, consiste em obter os coeficientes de aproximação (W_ϕ) e os de detalhe horizontal (W_ψ^H), vertical (W_ψ^V) e diagonal (W_ψ^D). Estes coeficientes são calculados à custa da função de escala e da função Wavelet 1D já referidas. Estas são aplicadas segundo xx e yy da seguinte forma:

$$\phi(x, y) = \phi(x)\phi(y) \tag{22. a}$$

$$\psi^H(x, y) = \psi(x)\phi(y) \tag{22. b}$$

$$\psi^V(x, y) = \phi(x)\psi(y) \tag{22. c}$$

$$\psi^D(x, y) = \psi(x)\psi(y) \tag{22. d}$$

Sabendo as funções de escala e Wavelet, o cálculo dos coeficientes segue a mesma linha de raciocínio dos sinais 1D.

$$W_\phi(r_0, s_m, s_n) = \frac{1}{\sqrt{MN}} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f[m, n] \phi_{r_0, s_m, s_n}[m, n] \tag{23}$$

$$W_{\psi}^k(r, s_m, s_n) = \frac{1}{\sqrt{MN}} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f[m, n] \psi_{r, s_m, s_n}^k[m, n] \quad (24)$$

com $k = \{H, V, D\}$

Também nos sinais 2D é possível simplificar o cálculo da DWT fazendo a mesma manipulação que levou às equações (20 e 21). Na Figura 27 é apresentado o esquema simplificado da aplicação da DWT para sinais 2D.

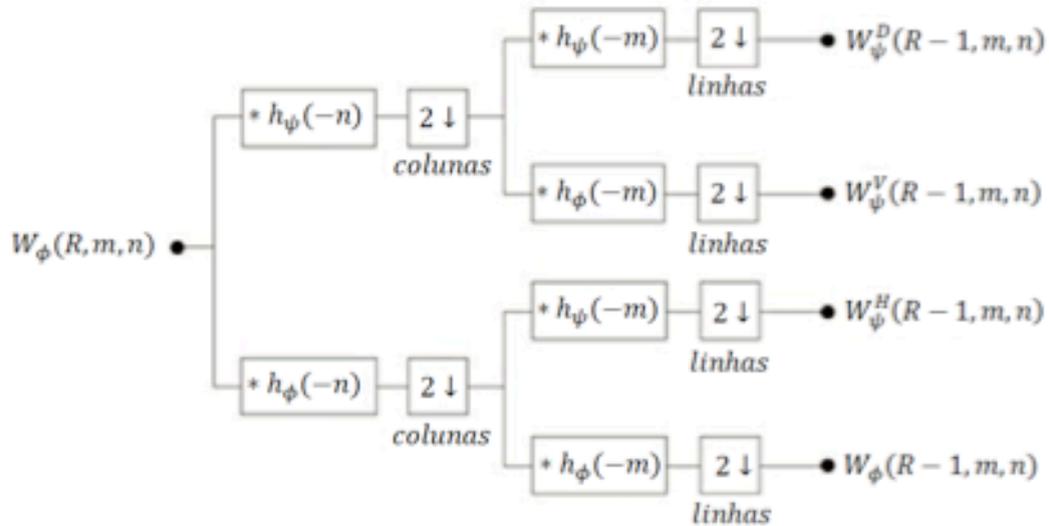


Figura 27 - Esquema da decomposição de uma imagem nos vários coeficientes de aproximação e detalhe

Mais uma vez, depois de se obter os coeficientes e de se fazer o seu processamento, poder-se-á reverter a transformação de forma a obter o sinal original. A representação esquemática da reconstrução é apresentada na Figura 28.

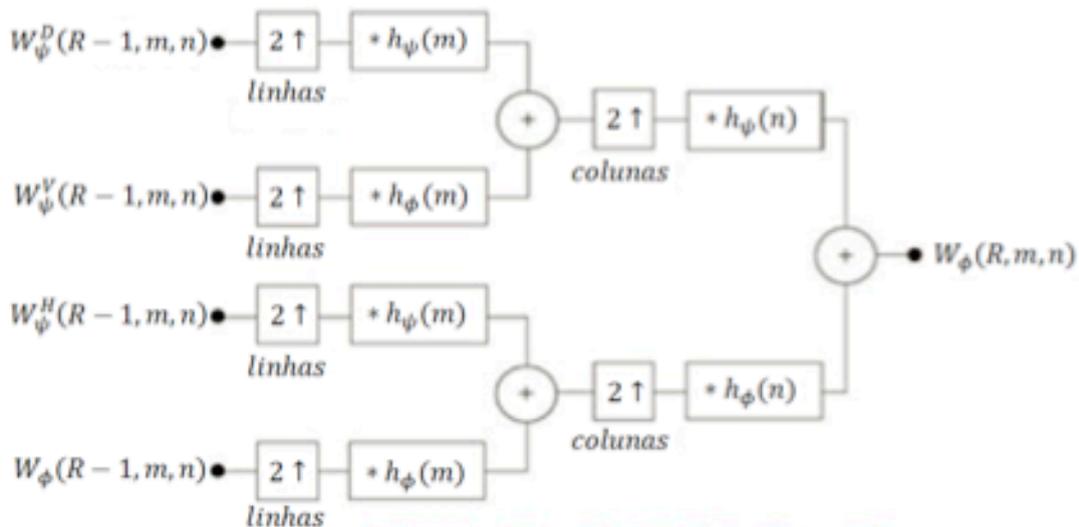


Figura 28 - Esquema da reconstrução de uma imagem partindo dos coeficientes de detalhe e aproximação

O resultado da aplicação da DWT numa imagem é apresentado na Figura 29. Aproveita-se para apresentar o resultado da FT para a mesma imagem de forma a perceber as diferenças já referidas.

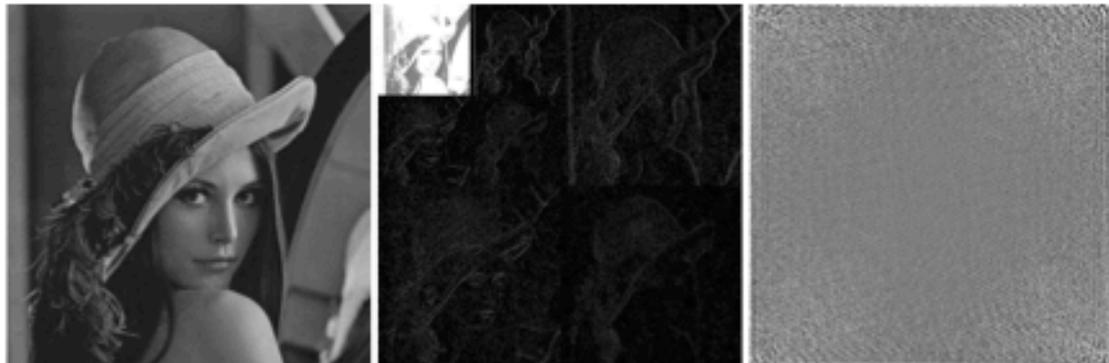


Figura 29 - Resultado da aplicação da DWT (meio) e da FFT (direita) numa imagem (esquerda)

Na figura 29 percebe-se claramente a potencialidade da WT em relação à FFT, enquanto que na WT se percebe que a imagem e a transformada estão relacionadas, na FFT parece não existir qualquer relação com a imagem original, isto fica a dever-se ao facto da FFT perder a noção espacial da imagem. Na prática a utilização da WT torna-se muito mais intuitiva que a FFT. Tanto pela capacidade de localizar facilmente as transições importantes, como pela flexibilidade na escolha dos filtros para fazer a decomposição.

3.6 - SWT

Como já foi referido o uso da decimação da DWT serve para reduzir a informação redundante que resulta da aplicação da transformada. Este passo é interessante para efeitos de compressão de imagens, pois reduz-se significativamente a quantidade de dados. No entanto a principal razão para a realização da decimação é permitir fazer uma análise multiresolução. Ao diminuir-se as dimensões da imagem para metade e aplicando os mesmos filtros faz com que a análise da imagem seja feita de uma forma mais global, isto é, com menor detalhe. O problema desta abordagem é que a decimação pode levar a distorções depois de alterados os coeficientes. Além disso, dificulta a comparação dos coeficientes em níveis diferentes, pois os mapas resultantes não têm a mesma dimensão. De forma a ultrapassar este problema, foi criada a SWT (Static Wavelet Transform). Nesta transformada em vez de se reduzir as dimensões da imagem para metade, duplica-se o tamanho dos filtros, mantendo o tamanho da

imagem constante. Na Figura 30 é apresentado o esquema da transformada para a decomposição em 3 níveis de um sinal 1D.

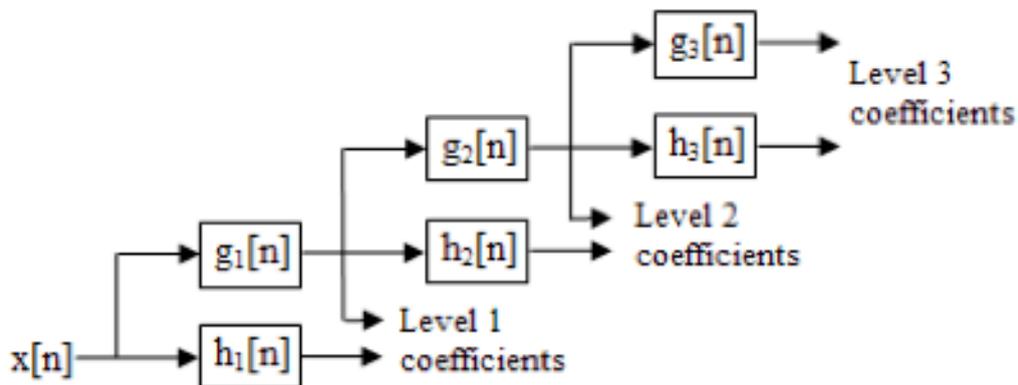


Figura 30 - Transformada de wavelet estática em 3 escalas

Pela análise da figura percebe-se que a cada novo nível analisado os filtros utilizados são alterados, enquanto que a imagem não sofre qualquer tipo de alteração nas suas dimensões. O esquema de transformação permanece o mesmo, na medida em que se continua a manipular os coeficientes de aproximação de uma escala para criar os coeficientes de detalhe e aproximação da escala seguinte. A alteração introduzida nos filtros é apresentada na Figura 31.



Figura 31 - Alteração dos filtros na SWT

Na prática a alteração provocada no filtro de uma escala para a seguinte é feita adicionando zeros entre cada coeficiente do filtro, daí também ser chamada “transformada à trous” (do francês com buracos).

Capítulo IV

**Estado da Arte – Aplicação da WT no
realce de imagens**

2012

Capítulo IV – Estado da Arte – Aplicação da WT no realce de imagens

Neste capítulo será feita uma revisão dos trabalhos já existentes, acerca do realce de imagens. Tem o objectivo de criar alguma sensibilidade sobre o tema, tentando perceber onde se deve apostar e quais as melhores abordagens a seguir. Será dividido em três partes: Processamento genérico de imagens usando Wavelets; Processamento de imagens de mamografia e por fim Processamento de imagens de mamografia usando Wavelets.

4.1 – Wavelets no realce de imagens

As Wavelets são uma ferramenta de processamento de sinais. Elas são usadas em inúmeras aplicações, portanto faz sentido investigar onde já são utilizadas com sucesso. Desta forma poder-se-á fazer analogias com outros sistemas e obter resultados igualmente sólidos na imagens de mamografia. A utilização de Wavelets no processamento de imagens geralmente consiste em 3 etapas. A primeira é a decomposição da imagem em coeficientes, a segunda é a atuação sobre os coeficientes e a final é a reconstrução da imagem com os novos coeficientes. Na primeira fase deve ser escolhida a Wavelet, o número de decomposições a aplicar à imagem e o tipo de transformada (DWT, SDWT por exemplo). Na segunda fase é onde se aplicam os algoritmos de melhoramento de imagens, sendo a este nível que onde a maioria dos algoritmos de melhoria de imagens difere. Dos inúmeros processamentos possíveis o mais comum é a utilização de *thresholds* [31,32,33]. O principio base é que coeficientes de baixo valor têm menor importância em relação aos coeficientes de maior valor. Com este pressuposto, define-se um *threshold* que separa os coeficientes com a informação importante da imagem dos que se considera não ter informação relevante. Desta forma é possível ao mesmo tempo fazer a redução do ruído e o realce dos detalhes importantes. Os desafios neste tipo de abordagem é como calcular o *threshold* e como o aplicar. Há trabalhos que calculam um *threshold* para cada nível de decomposição (global) e outros que mapeiam os coeficientes individualmente segundo a sua importância (localmente) [31,34]. A aplicação do *threshold* também pode seguir várias abordagens dependendo do objectivo final,

tal como redução do ruído, aumento do contraste ou as duas em simultâneo. Para a remoção de ruído é comum usar-se o *hard-threshold* e *soft-threshold*, Figura 32.

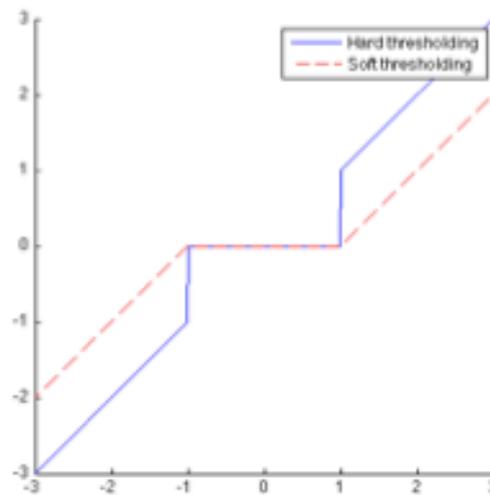


Figura 32 – *Soft* e *Hard Threshold* (vermelho e azul, respectivamente), *Threshold* =1, em xx valor de entrada e em yy valor de saída.

Estes dois métodos diferem simplesmente na forma como o *threshold* é aplicado. Enquanto no *hard-thresholding* se coloca todos os valores com modulo inferior ao *threshold* a zero (25), no *soft-thresholding* é ainda subtraído (ou adicionado para os coeficientes negativos) o valor do *threshold* aos valores de coeficientes fora do intervalo definido pelo *threshold* (26). Esta diferença faz com no *soft-thresholding* não haja descontinuidades nos valores dos coeficientes, provocando menores distorções na imagem.

$$\bar{D} = \begin{cases} 0 & \text{Se } |D| \leq T \\ D & \text{Se } |D| > T \end{cases} \quad (25)$$

$$\bar{D} = \begin{cases} 0 & \text{Se } |D| \leq T \\ D - T & \text{Se } D > T \\ D + T & \text{Se } D < -T \end{cases} \quad (26)$$

Para fazer o realce de imagens pode-se aplicar simplesmente um ganho aos valores acima e abaixo do *threshold* ou aplicar uma outra função, como por exemplo sigmoide, Figura 33

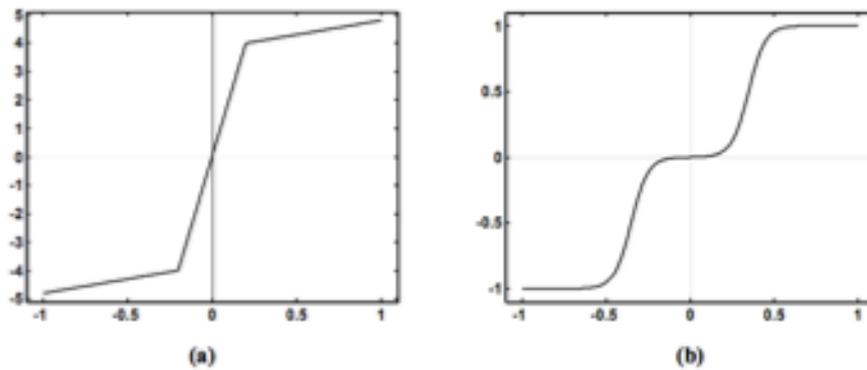


Figura 33 - Exemplo de Função de realce, dados normalizados para $[-1, 1]$; a) realce linear $T=0.2$ e $\text{ganho}=20$; b) Realce usando função Sigmoide [28]

Neste tipo de abordagem o cálculo do *threshold* é a fase crítica. Existem inúmeros métodos para o fazer, os mais comuns seguem abordagens estatísticas, modelando os coeficientes segundo uma distribuição normal e calculando o *threshold* em relação ao desvio padrão.

Outros métodos de realce de imagens consistem em utilizar informação do histograma e da DWT em simultâneo como em [35] e [36]. No primeiro é proposto um método onde manipulam o histograma das imagens, com o objectivo de aumentar o contraste. A manipulação é feita, ordenando os pixels por ordem crescente de intensidade. Para os pixels com o mesmo nível de intensidade são usados os coeficientes da DWT para fazer o desempate. A ideia é que quando os valores da DWT são maiores, esse pixel possui informação importante, logo deve-se ter o cuidado de aumentar o contraste de forma mais evidente nesta zona. Por outro lado se os coeficientes forem pequenos, isso significa que se trata de uma zona com pouco detalhe. Neste caso, não será necessário fazer uma melhoria tão acentuada, pois pode-se estar a aumentar ao mesmo tempo o ruído.

Em [37] é apresentado um algoritmo de melhoria de imagens de impressão digital. O objectivo é uniformizar as imagens de forma a reduzir os efeitos da aquisição, compensando a falta de informação e não uniformidades de iluminação. O algoritmo começa por uma normalização da imagem para uma média e um desvio padrão específicos. De seguida é feita a DWT da imagem normalizada e aplicado um filtro global de textura aos coeficientes. Cada coeficiente é associado a um valor de textura, calculado numa janela de 3×3 com

centro no próprio pixel. Esse mapeamento local, baseado em textura, é depois utilizado para uniformizar globalmente a textura da imagem.

4.2 – Realce de imagens de mamografia

As imagens de mamografia normalmente possuem pouco contraste. É portanto interessante desenvolver um sistema que faça o realce da informação presente nestas imagens. O realce pode ser conseguido manipulando a intensidade e o contraste das imagens, reduzindo o ruído, removendo o fundo, intensificando contornos, entre outras abordagens. Estas alterações introduzem melhorias na imagem que facilitam o clínico nos seus diagnósticos, pois a informação apresentada na imagem consegue ser mais facilmente distinguida. Pode ainda melhorar a eficiência de outros algoritmos, pois consegue-se uma separação mais marcada entre fundo e achados. Em [38] é indicado que com uma melhoria eficiente do contraste é possível reduzir a dose aplicada nos pacientes em cerca de 50%. Existe uma elevada diversidade de algoritmos, a principal preocupação em todos eles é garantir o melhor contraste possível, sem introduzir nem evidenciar ruído e preservando os contornos originais das estruturas.

Em [39] foi feito um levantamento dos avanços realizados até então na área dos sistemas CAD para detecção de patologias mamárias. No aumento do contraste das imagens de mamografia, é feita a distinção entre métodos diretos e indiretos. Os métodos diretos atuam diretamente no contraste da imagem, normalmente consistem em fazer a sua medição para de seguida aplicar uma transformação de forma a aumentá-lo. O contraste pode ser medido globalmente ou localmente, recorrendo a uma janela. Nos métodos diretos, salienta-se o trabalho de [40] onde é introduzida a lógica fuzzy, capaz de lidar com a aleatoriedade característica das imagens médicas. Os métodos indiretos, fazem a melhoria do contraste sem o chegar a medir. São disso exemplo algoritmos de Unsharp Masking, equalização de histograma e alguns métodos multi-escala como por exemplo Wavelet. De referir que este último, dada a sua versatilidade, pode também, em aplicações específicas, ser utilizado em métodos considerados diretos.

Em [41] é apresentado um algoritmo de realce de massas baseado em filtros morfológicos. Este algoritmo tem em conta a forma das massas, usando um elemento estruturante circular nesse processo. É proposta a realização de um *white top-hat*, isto é, a diferença entre a imagem original e o resultado do *opening* dessa mesma imagem. Depois disso é aplicada uma função de escala ao resultado do *white top-hat* e volta-se a subtrair este resultado à imagem original. Com estas operações o autor diz conseguir uma melhor segmentação. No entanto, este método apresenta-se pouco robusto, pois o tamanho do elemento estruturante influencia a detecção e o facto de ser específico para massas torna-o, em certa forma limitado. A utilização de filtros morfológicos pode também levar à perda de informação dos contornos das massas, o que não é de todo desejado.

Em [42] é proposto um método de melhoria de imagens de mamografia usando *Alpha Weighted Quadratic Filter*. O algoritmo consiste na utilização de uma extensão dos filtros quadráticos através da introdução de um novo parâmetro *Alpha*. Segundo os autores este algoritmo é mais versátil e flexível que os filtros quadráticos comuns, no entanto é mais complexo. Para reduzir a complexidade e tornar o método mais prático, são apresentadas algumas formas de o simplificar.

Em [43] é apresentado um método de melhoria de imagens de mamografia denominado NLUM (*Nonlinear Unsharp Masking*). Este algoritmo vem no seguimento do trabalho realizado em [42], tirando partido da flexibilidade dos filtros aí estudados. A ideia base é utilizar esses filtros (neste caso são usados unicamente os 3x3) para extrair a componente passa-alto da imagem. De seguida essa componente é processada e fundida na imagem original.

4.3 – Wavelets no realce de imagens de mamografia

O potencial das Wavelets no processamento de imagens é indiscutível. Elas podem ser usadas diretamente na melhoria das imagens, ou então como uma ferramenta para alterar a sua representação, possibilitando a aplicações de outros algoritmos. O seu potencial não passou despercebido, daí que hoje em dia, existe um número imenso de algoritmos baseados nesta transformada.

Os métodos baseados em *thresholds*, apresentados no ponto 3.1, foram aplicados em imagens de mamografia por [44,45,46,47,48], entre outros. A maioria segue abordagens estatísticas, obtendo o *threshold* de forma proporcional à média ou ao desvio padrão.

Em [49], é apresentado um algoritmo de realce de imagens de mamografia. É também um método baseado em *thresholds*. A diferença para a maioria dos algoritmos existentes é que o cálculo do mesmo é feito tendo em conta a informação do fundo. O princípio sugerido neste artigo é que o ruído é uniforme por toda a imagem (incluindo o fundo), portanto para quantificar o ruído basta medi-lo na zona do fundo. O algoritmo começa pela identificação do fundo, depois disso é calculado o ruído na zona identificada e usada essa informação para calcular o *threshold*. É ainda feito um aumento do contraste usando um filtro homomórfico, onde os ganhos são também calculados tendo em conta o ruído do fundo. De referir que a identificação do fundo não necessita de ser perfeita, sendo preferível fazer uma seleção por defeito, de forma a garantir que não se inclui informação da mama.

[50], apresentou um novo algoritmo que tira partido da relação entre os coeficientes vizinhos e os que se encontram em níveis seguintes da decomposição. É ainda utilizada a informação dos coeficientes de aproximação para fazer a melhoria visual da imagem realçada. O princípio base do artigo é que detalhes importantes são encontrados em vários níveis da transformada de Wavelet. Por outro lado coeficientes provenientes do ruído, devido à sua aleatoriedade, aparecem fundamentalmente no nível de maior detalhe e não se estendem para níveis de menor detalhe.

Em [51] é apresentado um algoritmo em duas fases, uma primeira de redução do ruído e outra de realce. A primeira fase é semelhante à de [49], na medida em que se mede o ruído no fundo e depois se procura subtrair esse ruído pela imagem toda. A segunda fase é baseada num algoritmo LRM (local range modification) onde a ideia é mudar localmente o valor dos coeficientes para que se obtenha um contraste uniforme por toda a imagem. Este algoritmo é interessante a evidenciar detalhes pouco visíveis, no entanto é bastante sensível ao ruído.

Capítulo V

Trabalho Experimental

2012

Capítulo V – Trabalho Experimental

Neste capítulo será apresentado o trabalho desenvolvido. Depois de uma pesquisa intensiva sobre os vários métodos até agora publicados, fez-se uma seleção dos mais interessantes e aplicaram-se às mesmas imagens de forma a fazer a sua comparação. Foram feitos ajustes nos parâmetros, e sempre que pertinente introduzidas alterações. As imagens de teste foram obtidas da base de dados DDSM e do Consultório de Imagiologia Médica Dr Campos Costa (DCC).

A implementação dos algoritmos foi feita em MATLAB® 7.9.0 (R2009b). Foi utilizada esta ferramenta dada a sua simplicidade e por já possuir algum código base de Wavelets e de processamento de imagem.

5.1 – Dados

Os dados utilizados consistem em imagens de mamografia digital. No caso da DDSM foi necessário fazer a descompressão das imagens do formato JPEG2000 para um formato compatível com o MatLab. O formato escolhido foi o TIF por garantir que se conserva toda a informação da imagem. Para fazer a descompressão foi utilizado o pacote de software fornecido pelos próprios criadores da base de dados [52]. Estas imagens são obtidas por digitalização de películas de raio-X, apresentando uma quantidade significativa de ruído e, por vezes, artefactos devido a anotações ou carimbos nas imagens. A resolução das imagens é variável, entre 42 e 51 micrómetros. Em termos de resolução tonal também não é constante, havendo imagens de 12 e outras de 16 bits. De forma a facilitar a comparação, foram escolhidas as imagens de 16bits e fixada a resolução para um valor de 42 micrómetros.

As imagens DCC foram obtidas com equipamento de mamografia digital direta. As imagens encontram-se no formato DICOM e possuem uma resolução de 94,1 micrómetros. Em termos de resolução tonal, estas imagens possuem 16 bits alocados, mas só 12 bits é que contém informação, sendo portanto o valor de 12 bits o representativo da resolução tonal. Devido ao modo de aquisição ser mais moderno, as imagens apresentam bastante menos ruído e os artefactos são inexistentes. Todas as amostras possuem no mínimo 4 vistas correspondentes ao standard de diagnóstico (MLO e CC, da mama direita e esquerda) assim como a

respectiva informação da aquisição, exceto o nome do paciente de forma a manter o seu anonimato.

5.2 - Pré-processamento

5.2.1- Redução do Ruído

A remoção do ruído da imagem foi feita inicialmente recorrendo ao algoritmo proposto por [53] e introduzindo posteriormente algumas alterações sugeridas em [51]. O algoritmo apresentado em [53] é genérico para qualquer tipo de imagem. O trabalho realizado foi no sentido de o tornar específico para imagens de mamografia, procurando assim aumentar a sua eficácia. O princípio base é calcular um valor global para o ruído e de seguida subtraí-lo da imagem, obtendo desta forma a imagem sem ruído. O cálculo do ruído é feito no domínio Wavelet e quando não se tem nenhuma informação acerca dele, é aproximado utilizando a equação (27):

$$\sigma_N = \frac{\text{Mediana}(|D_1^d|)}{0.6745} \quad (27)$$

Em que D_1^d é a sub-banda contendo os coeficientes de detalhe diagonais no primeiro nível da decomposição. Note-se que nesta abordagem só é calculado um valor de ruído, que é utilizado em todas as escalas e orientações. Embora este método seja robusto, e apresente resultados satisfatórios, no caso das imagens de mamografia pode-se tentar tirar partido de outras características para obter melhores resultados. Em [51] é sugerido que o cálculo do ruído da imagem pode ser feito atendendo à informação presente no fundo. A ideia é que o fundo de uma imagem de mamografia ideal (sem ruído) teria um valor constante e igual a zero, pois não existe qualquer tecido para atenuar os raio-X, logo a quantidade de que atingiria o leitor seria máxima nessa zona. Assim, qualquer informação encontrada no fundo de uma imagem real poderá ser considerada como ruído. Nesse mesmo artigo é também apresentada uma forma de obter esse valor. No entanto optou-se por outra abordagem, mais simples e, igualmente robusta.

O cálculo do ruído da imagem, aqui proposto, começa pela identificação do seu fundo. Esse algoritmo parte da informação do histograma de forma a obter um *threshold* global que divida a imagem entre fundo e objetos, sabendo à partida que o fundo possui um valor de intensidade inferior ao da mama.

Fazendo uma análise ao histograma das imagens de mamografia, é possível concluir que os pixels pertencentes ao fundo se concentram na maior gaussiana de menor média Figura 34.

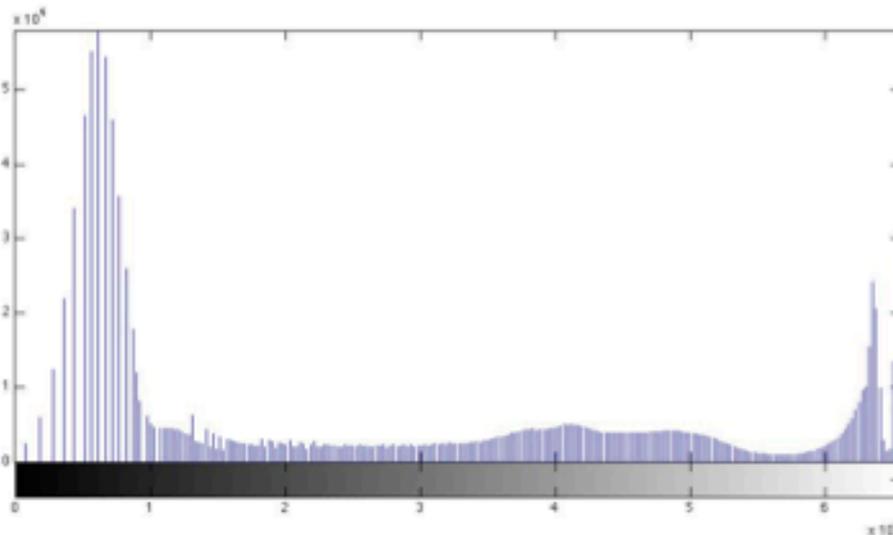


Figura 34 - Exemplo do histograma de uma imagem de mamografia digital direta (16 bits)

O *threshold* será definido como o valor da média (μ) dessa gaussiana mais o dobro do desvio padrão (σ). Os parâmetros da gaussiana relacionam-se segunda a equação (28):

$$f(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)} \quad (28)$$

Em que o valor da média corresponde ao valor do nível cinzento do pico da gaussiana e o desvio padrão é obtido por aproximação utilizando os valores na vizinhança do pico.

Depois de binarizada a imagem com o *threshold* calculado, é aplicado um algoritmo de remoção de buracos e feita uma erosão do fundo com um elemento estruturante circular com raio de 5 pixels de forma a eliminar artefactos Figura 35.

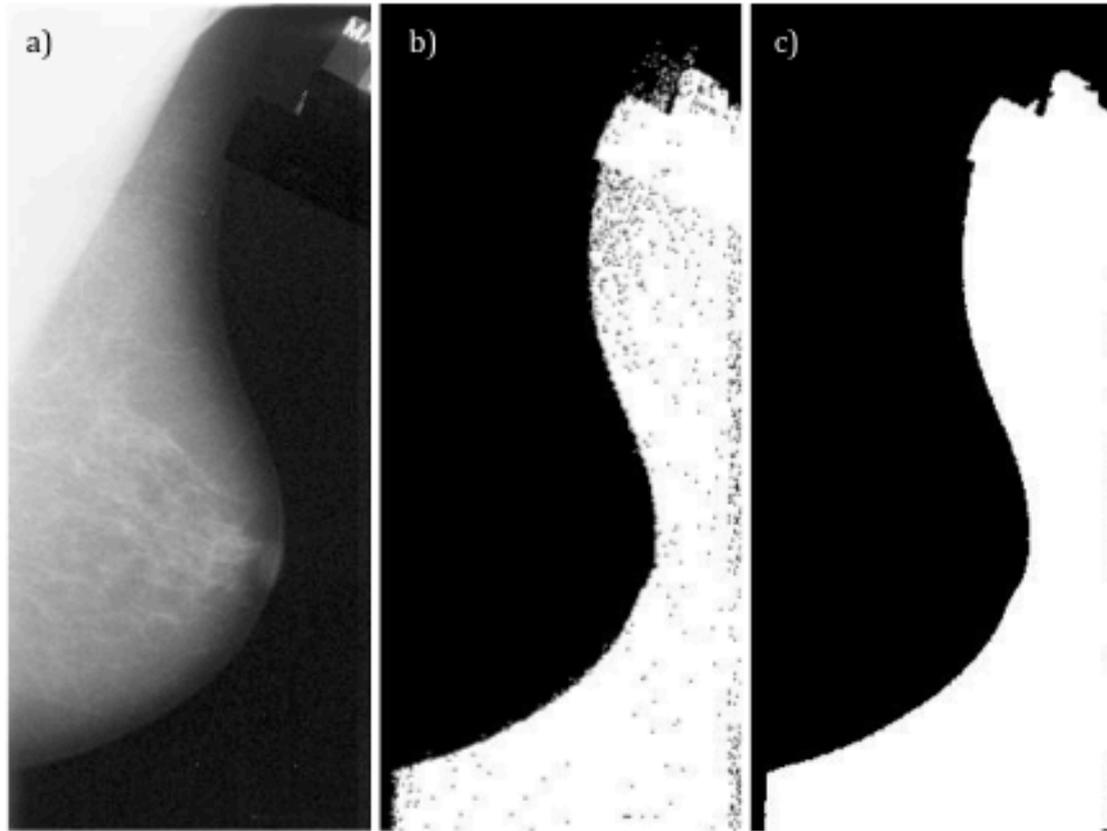


Figura 35 - Resultado do algoritmo de identificação do fundo. a) Imagem DDSM Original; b) Resultado da aplicação do *threshold* obtido do histograma; c) Mascara final, depois de algoritmo de enchimento e erosão

O algoritmo não é perfeito, havendo uma tendência para fazer uma identificação do fundo por defeito. Este resultado já era esperado, pois sabe-se à partida que não influencia decisivamente o algoritmo de remoção de ruído. De facto é preferível uma segmentação por defeito, pois o único objectivo deste passo é obter uma amostra significativa do fundo da imagem e não o fundo na sua totalidade.

A partir deste ponto os algoritmos são semelhantes. A única diferença é no valor do ruído, equação (29):

$$\sigma_{N,s}^k = \begin{cases} \sigma_N & \text{Se Robusto} \\ \sigma_{N,s}^k & \text{Se Fundo} \end{cases} \quad (29)$$

Depois de determinado o valor do ruído é calculado um *threshold* local para cada escala e orientação usando a equação (30):

$$T_s^k(m,n) = \frac{(\sigma_{N,s}^k)^2}{\sigma_s^k(m,n)} \quad (30)$$

Onde $\sigma_{N,s}^k$ é o desvio padrão do ruído e $\sigma_s^k(m,n)$ é o desvio padrão da imagem na escala s e orientação k numa janela com centro no ponto (m,n) . O calculo de σ_s^k é feito recorrendo à equação (31):

$$\sigma_s^k(m,n) = \sqrt{\max\left(10^{-9}, \frac{1}{2L+1} \sum_{i=-L}^L \sum_{j=-L}^L D_s^k(m,n)^2 - (\sigma_{N,s}^k)^2\right)} \quad (31)$$

Com o valor do *threshold* é então possível proceder-se à remoção do ruído da imagem. Nesta abordagem optou-se pela utilização da técnica de *soft-thresholding*, segundo a seguinte equação (32):

$$\bar{D}_s^k(m,n) = \begin{cases} 0 & \text{Se } |D_s^k(m,n)| \leq T_s^k(m,n) \\ D_s^k(m,n) - T_s^k(m,n) & \text{Se } D_s^k(m,n) > T_s^k(m,n) \\ D_s^k(m,n) + T_s^k(m,n) & \text{Se } D_s^k(m,n) < -T_s^k(m,n) \end{cases} \quad (32)$$

Note-se que nesta abordagem o *threshold* é tão maior quanto maior for o ruído do fundo, pois imagens ruidosas necessitam que seja removida mais informação. Por outro lado é menor quando na imagem se apresenta um desvio padrão local elevado, pois esse valor indica a presença de um detalhe que deve ser preservado. O tamanho da janela foi obtido empiricamente e optou-se por um valor de 7x7 pixels ($L=3$).

5.2.2 - Realce da Imagem

5.2.2.a – Simples

Para a primeira abordagem, optou-se pela utilização do método mais simples possível. A ideia base utilizada foi isolar os detalhes da imagem para de seguida salientá-los. Sabendo que os detalhes consistem em altas frequências e que as altas frequências são isoladas nos primeiros níveis da transformada de Wavelet, bastou selecionar os primeiros níveis da transformada e aplicar-lhes um ganho, tal como apresentado na equação (33):

$$\bar{D}_s^k(m,n) = G * D_s^k(m,n) \quad \text{com } k \in \{h, v, d\} \text{ e } s \in \{1, \dots, S\} \quad (33)$$

No final é feita a transformação inversa usando os novos coeficientes. Este método não é sensível a nenhuma característica da imagem, faz-se simplesmente um realce linear e indiferenciado dos detalhes mais finos da imagem. Em termos de parâmetros existem três, o número de níveis a analisar, (S), o ganho, (G), e a Wavelet usada na decomposição. Os valores de S e G , foram obtidos

empiricamente, chegando-se a um valor de 3 e 4 para as imagens DCC e de 4 e 4 para as imagens DDSM, respectivamente. A transformada utilizada nesta abordagem foi a SWT e a Wavelet escolhida foi a Daubechies 2 (DB2) pois os contornos são melhor preservados em relação à utilização da DWT, como se pode verificar pela Figura 36.



Figura 36 – Resultado da aplicação do algoritmo *SIMPLES* com $S=3$ e $G=2$; a) imagem original; b) realce com DWT; c) realce com SWT

5.2.2.b – *Threshold*

Foi testado o algoritmo baseado em *thresholds* desenvolvido em [54]. A expressão matemática que descreve o processo de realce é apresentada em (34):

$$\overline{D_s^k}(m, n) = \begin{cases} D_s^k(m, n) & \text{se } e_s(m, n) \leq T_s^k \\ G_s^k * D_s^k(m, n) & \text{se } e_s(m, n) > T_s^k \end{cases} \quad (34)$$

Em que T_s^k e G_s^k são, respectivamente o valor do *threshold* e do ganho para uma dada escala e orientação, $e_s(m, n)$ é o mapeamento dos contornos numa dada escala e como o nome indica nele constam os valores dos contornos da imagem. O princípio deste método é fazer uma distinção entre os pixels com informação importante dos pixels sem informação, fazendo o realce dos primeiros e mantendo os segundos inalterados. De seguida será explicado como se obtém cada uma das variáveis apresentadas.

O algoritmo começa pela decomposição da imagem em S escalas. De seguida, partindo do princípio que o ruído é global e uniforme, é calculado um *threshold* único para cada escala e orientação, T_s^k . O seu valor é proporcional ao desvio padrão, tal como indicado na equação (35):

$$T_s^k = 3 * \sqrt{\frac{1}{N * M} \sum_{n=1}^N \sum_{m=1}^M (D_s^k(m, n) - m_y)^2} \quad (35)$$

Em que m_y é a média dos coeficientes de detalhe, D_s^k , e N e M são as dimensões da imagem.

O mapeamento dos contornos é feito convertendo os coeficientes horizontais e verticais para coordenadas polares, equações (36, 37). Este passo é possível dada a perpendicularidade entre eles.

$$M_s(m, n) = \sqrt{D_s^H(m, n) * D_s^H(m, n) + D_s^V(m, n) * D_s^V(m, n)} \quad (36)$$

$$\theta_s(m, n) = \arctan\left(\frac{D_s^V(m, n)}{D_s^H(m, n)}\right) \quad (37)$$

Esta representação permite, facilmente, saber a orientação de cada contorno, através de $\theta_s(m, n)$, e a sua importância, através de $M_s(m, n)$. Com esta ideia em mente, é proposta a utilização da informação de θ_s para filtrar os valores da magnitude, M_s . Essa filtragem é feita selecionando somente os valores de magnitudes que são máximos numa vizinhança com tamanho igual à Wavelet utilizada, segundo uma orientação definida por θ_s , tal como indicado na equação (38).

$$e_s(m, n) = \begin{cases} M_s(m, n) & \text{se } M_s(m, n) \text{ maximo na direcção } \theta_s(m, n) \\ 0 & \text{senão} \end{cases} \quad (38)$$

Neste caso foi utilizada a Wavelet de Haar, portanto a vizinhança utilizada foi 2 (o próprio pixel e o um pixel antes e outro depois na orientação definida por θ_s). Na prática, de forma a simplificar a filtragem, os valores de θ_s são manipulados de forma a representarem as orientações verticais, horizontais e diagonais, esta operação é conseguida aproximando os ângulos para os valores múltiplos de $\frac{\pi}{4}$ mais próximos. Na Figura 37 é apresentado, a título de exemplo, o resultado da operação aplicada numa imagem artificial.

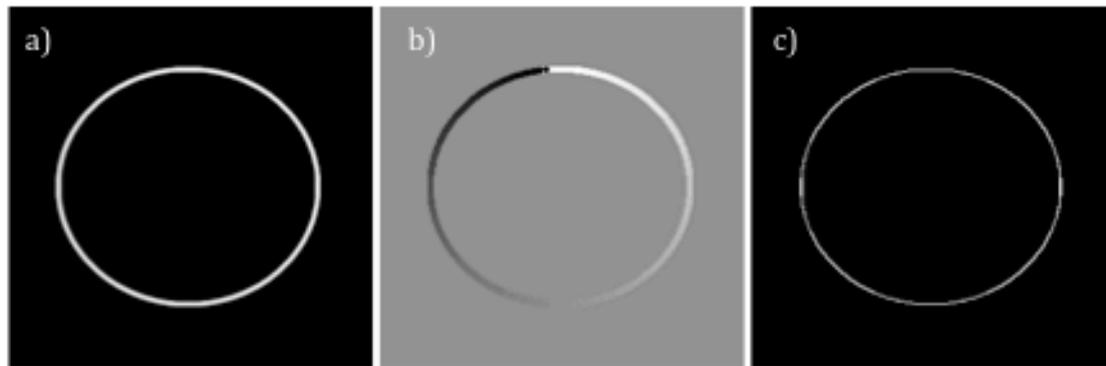


Figura 37 - Imagens intervenientes na obtenção de e_s ; a) $M_s, [0, \max(M_s)]$; b) $\theta_s, [-pl, pl]$; c) $e_s, [0, \max(M_s)]^8$

Pela Figura 37 verifica-se que de M_s para e_s houve uma redução dos valores, só os seus significativos para efeitos de representação dos contornos foram preservados.

No artigo [54] era apresentado um método automático para fazer o cálculo do ganho, no entanto os resultados práticos não eram satisfatórios. Optando-se por omitir este passo, fixando o valor do ganho para 5.

5.2.2.c – Correlação

Usando o trabalho desenvolvido em [55], fez-se a aplicação direta das teorias aí exploradas. O princípio é semelhante ao de [50], na medida em que também cruza a informação dos coeficientes em níveis diferentes, neste caso para medir a probabilidade de cada pixel ser ruído. Para tal, é utilizada a SWT, desta forma mantem-se a dimensão das imagens de um nível de decomposição para o seguinte, evitando-se desfasamentos e facilitando a comparação entre pixéis.

O algoritmo propriamente dito começa pela decomposição da imagem. De seguida é calculada a correlação entre cada pixel de um nível com o seu pixel correspondente num nível inferior de detalhe, tal como representado na equação (39):

$$C_s^k(m, n) = D_s^k(m, n) * D_{s+1}^k(m, n) \quad (39)$$

Com $k \in \{h, v, d\}$ e $s \in \{1, \dots, S - 1\}$. O princípio neste passo é que detalhes importantes terão coeficientes elevados em ambos os níveis de decomposição,

⁸ $[x, y]$ -> representa o valor mínimo e máximo na imagem, sendo que o mínimo aparece a preto e o máximo a branco, os restantes valores são níveis cinzentos intermédios

logo terão correlações elevadas. Por outro lado o ruído como tem coeficientes mais baixos e uma natureza aleatória terá correlações mais baixas.

Para ser possível fazer uma comparação entre o mapa de correlações, C_s^k , e os coeficientes de detalhe é necessário fazer um escalonamento dos valores das correlações utilizando a energia de ambas as imagens, tal como indicado nas equações (40, 41).

$$\overline{C_s^k}(m, n) = C_s^k(m, n) \sqrt{\frac{E_{D_s^k}}{E_{C_s^k}}} \quad (40)$$

Com:

$$E_X = \sum_{m,n} (|X(m, n)|)^2 \quad (41)$$

Com a correlação calculada e normalizada em relação aos coeficientes é então possível fazer uma comparação entre eles, de forma a mapear a probabilidade de cada pixel ser ruído. O calculo é feito recorrendo às equações (42, 43):

$$P_s^k(m, n) = 0 \text{ se } \overline{C_s^k}(m, n) \geq D_s^k(m, n) \quad (42)$$

$$P_s^k(m, n) = \frac{|D_s^k(m, n)| - |\overline{C_s^k}(m, n)|}{|D_s^k(m, n)| - \min(\overline{C_s^k}(m, n))} \text{ se } \overline{C_s^k}(m, n) < D_s^k(m, n) \quad (43)$$

Basicamente nestas equações é feita a descrição matemática das ideias já apresentadas. Quando a correlação é elevada, a probabilidade de ser ruído é nula, por outro lado, quando a correlação é baixa, (segunda) esse valor tende para 1.

Na Figura 38 é possível visualizar as diferentes imagens intervenientes no calculo do mapa de correlações.

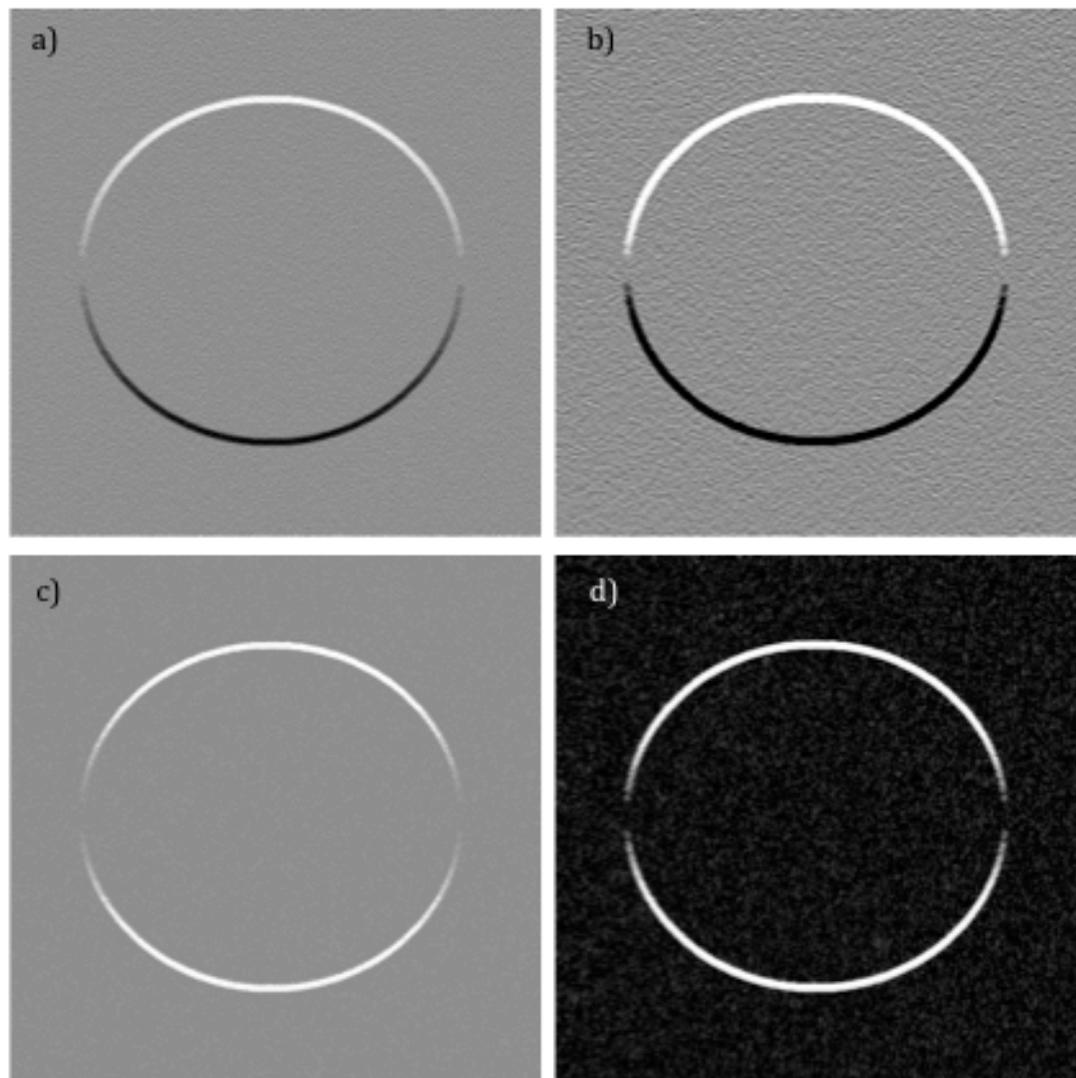


Figura 38 - Imagens intervenientes no cálculo do mapa de probabilidades. a) D_1^H ; b) D_2^H ; c) $\overline{C_1^H}$; d) $1 - P_1^H$;

Nesta etapa já se possui a informação necessária sobre cada pixel. Podendo ser usada tanto para remover ruído como para realce. A abordagem usada neste caso foi fazer o realce da imagem ao menos tempo que se reduz a quantidade de ruído, usando a equação (44):

$$\overline{D_s^k}(m, n) = G * \left(1 - P_s^k(m, n)\right) * D_s^k(m, n) \quad (44)$$

Em que G é o parâmetro que define o ganho máximo. Note-se que coeficientes com 0% de probabilidade de ser ruído são realçados ao máximo, enquanto pixels com 100% de probabilidade de serem ruído são eliminados. Por fim é feita a transformada inversa com os novos coeficientes, obtendo assim a imagem realçada. O valor do ganho foi escolhido empiricamente com um valor de 5. De referir que este valor de ganho também tem um comportamento de

threshold, pois os pixels com probabilidade superior a $(1 - \frac{1}{\sigma})$ serão mantidos ou reduzidos, enquanto valores inferiores serão realçados. Neste caso a probabilidade que faz esta divisão é 80%.

Em termos de parâmetros da transformada de Wavelet, optou-se por decompor a imagem em 4 níveis utilizando a Wavelet Daubechies 2 em ambas as bases de dados, DCC e DDSM.

5.2.2.d – Correlação Local

Verificou-se nos testes que a abordagem proposta anteriormente apresentava uma fragilidade. As probabilidades calculadas apresentam uma grande dependência da energia global dos coeficientes. Esta limitação leva a que se for introduzido um detalhe numa imagem, todas as probabilidades da imagem sejam alteradas. Este efeito não é desejado, pois a probabilidade de um pixel ser ou não ruído é independente deste detalhe introduzido. De forma a aliviar este problema foi introduzida uma alteração a nível do escalonamento das correlações. Em vez de um escalonamento global, passa-se a fazer um escalonamento local. Tal como indicado nas equações (45, 46 e 47).

$$\overline{C}_s^k(m, n) = C_s^k(m, n) \sqrt{\frac{E_{D_s^k}(m, n, L)}{\frac{1}{M * N} * E_{C_s^k}}} \quad (45)$$

Com:

$$E_{C_s^k} = \sum_{m, n} (|C_s^k(m, n)|)^2 \quad (46)$$

$$E_{D_s^k}(m, n, L) = \frac{1}{(2L + 1)^2} * \sum_{i=-L}^L \sum_{j=-L}^L (|D_s^k(m + i, n + j)|)^2 \quad (47)$$

Note-se que a energia da correlação continua a ser global, mas passa a ser utilizada a energia média em vez da total de forma a manter a relação com o novo cálculo da energia de D_s^k que agora é feito localmente. Esta alteração evita que locais de energia baixa (como por exemplo o fundo) sejam tratados da mesma forma que locais de energia alta (achados). O tamanho das janelas foi obtido empiricamente e fixado num valor de 5x5 ($L=3$). Esta alteração torna o algoritmo mais sensível e as probabilidades deixam de ser tão dependentes da energia dos achados, como é possível verificar na Figura 39.

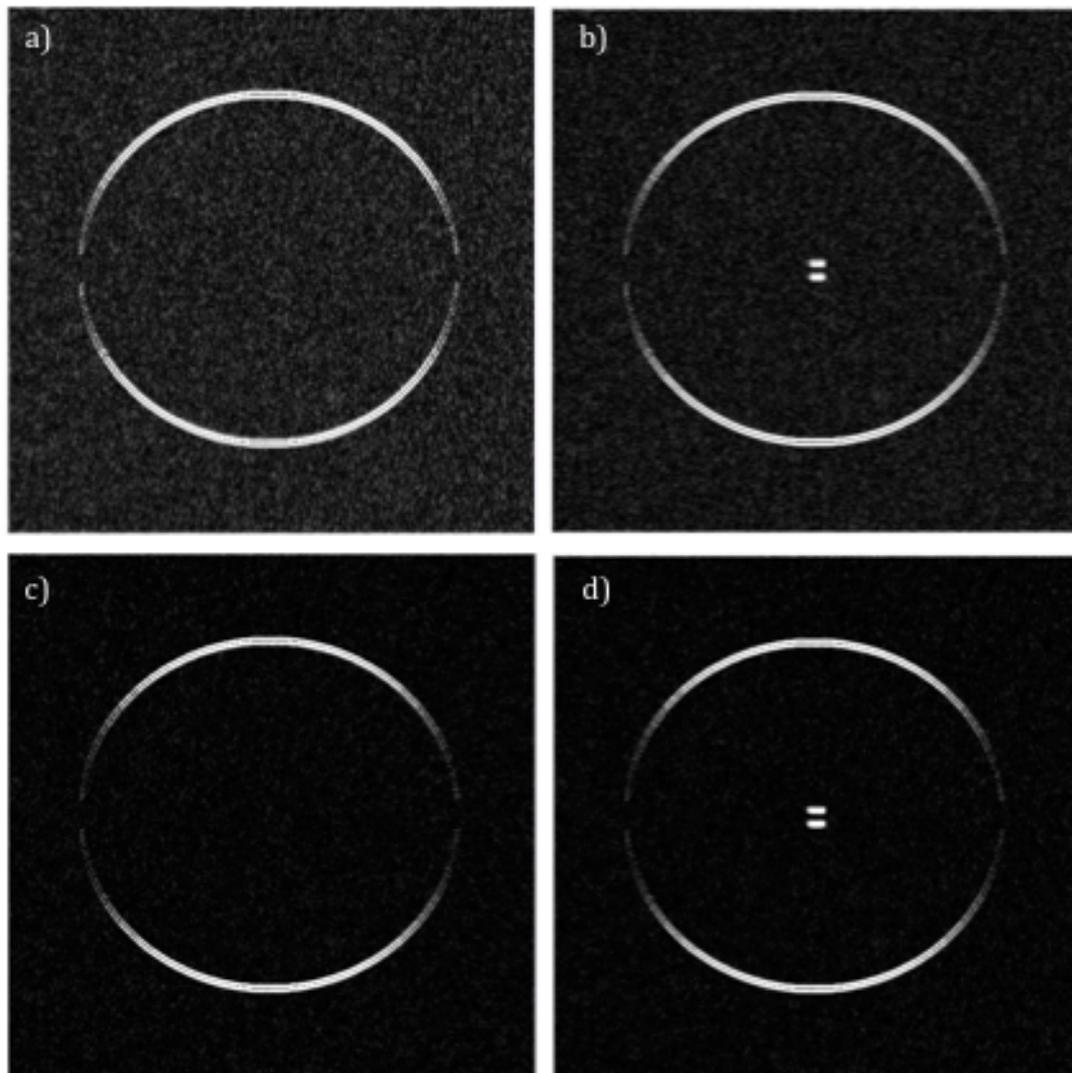


Figura 39 - Comparação entre mapeamento obtido pelo método Correlações, a) e b) e pelo método correlações locais, c) e d)

5.2.2.e – Máximos Locais

Em [51] é apresentado um método de realce de imagens. O algoritmo é baseado numa técnica denominada LRM (*Local Range Modification*). Faz um mapeamento dos pixéis em todas as escalas de forma a obter um valor de ganho local. O cálculo da matriz com os ganhos locais é feito recorrendo à equação (48):

$$G_{L,s}(m, n) = \begin{cases} M_{s,max} / M_{s,max}(m, n) & se < L \\ L & se \geq L \end{cases} \quad (48)$$

Em que $M_{s,max}$ é o valor máximo da magnitude da escala s e $M_{s,max}(m, n)$ é o valor máximo local da magnitude numa janela de 9×9 pixéis na escala s . L representa o valor máximo do ganho e foi escolhido empiricamente com o valor de 15. A variável L serve como um limitador do ganho e foi introduzida de forma a evitar o realce excessivo dos pixéis menos evidentes que poderia levar a

distorção da imagem. No algoritmo é feita a limitação dos valores de magnitudes pertencentes aos 2% maiores valores. Este passo tem como objectivo eliminar o efeito de possíveis magnitudes anormalmente elevados no ganho. Esse ganho é então aplicado à magnitude como representado na equação (49):

$$M_s^g(m, n) = \left(\frac{M_s(m, n)}{M_{s,max}(m, n)} \right)^g * G_{L,s}(m, n) * M_{s,max}(m, n) \quad (49)$$

Note-se que neste algoritmo o cálculo do ganho é feito de modo a que detalhes menos evidentes sejam realçados. Por outro lado é introduzida a variável g , que controla a linearidade do realce e pode ser usada para regular quais os detalhes que serão mais evidenciados. Para um valor de $g = 1$ tem-se realce linear, para valores superiores favorece-se os detalhes mais intensos e para valores inferiores os detalhes menos intensos. No artigo base é utilizado o realce linear, no entanto nos testes realizados conseguiu-se melhores resultados para um valor de $g = 2$, portanto optou-se por utilizar o valor de 2. Esta escolha alivia ligeiramente o problema do realce indevido do ruído, no entanto vai um pouco contra o objectivo do algoritmo, mas atendendo aos resultados, optou-se por esta abordagem. De referir que um problema deste algoritmo é que o ruído é facilmente interpretado como um detalhe menos evidente, sendo muitas vezes indevidamente realçado. Devido a este problema é proposto em [51] a aplicação prévia de um algoritmo de redução do ruído.

Na Figura 40, é possível verificar o efeito da aplicação deste algoritmo.

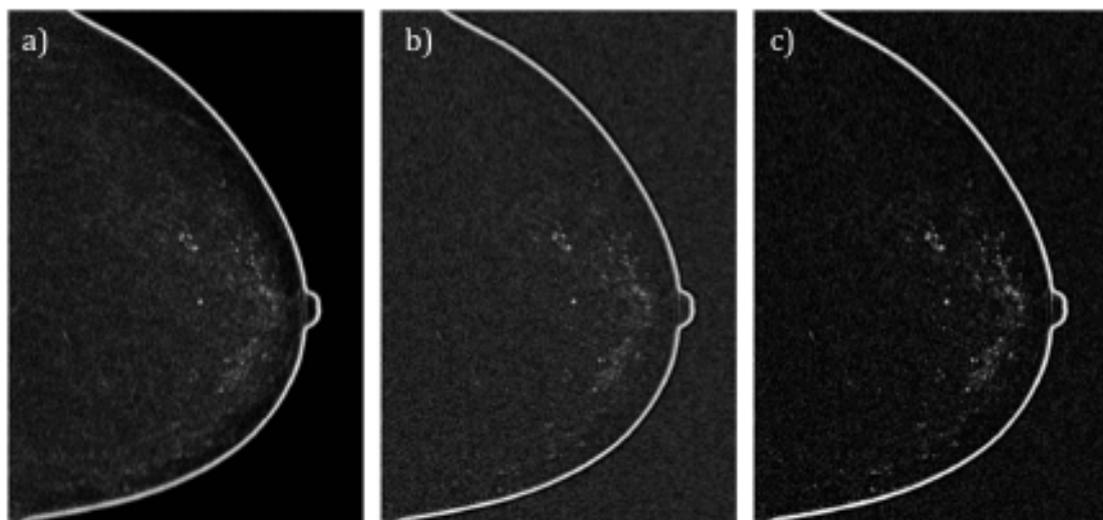


Figura 40 - Magnitudes resultantes da aplicação do método de realce. a) Original; b) realce linear, $g=1$; c) realce não linear, $g=2$

Na Figura 40-b) e c) é possível verificar o efeito da alteração da realce de linear para não linear. O ruído do fundo é menos realçado enquanto que os detalhes permanecem igualmente evidentes.

Por fim, de forma a obter de volta os valores dos coeficientes e feita a reconstrução da imagem realçada com os novos coeficientes obtidos são utilizadas as equações (50 e 51).

$$D_s^H(m, n) = M_s(m, n) * \cos(\theta_s(m, n)) \quad (50)$$

$$D_s^V(m, n) = M_s(m, n) * \sin(\theta_s(m, n)) \quad (51)$$

Em termos de número de escalas analisadas optou-se 3 níveis para DCC e em 4 níveis para DDSM a transformada utilizada foi a SWT e a Wavelet utilizada foi a Daubechies 2.

5.2.2.f - Contraste

Outro algoritmo testado, partiu do trabalho realizado em [56]. Neste trabalho utiliza-se a informação do contraste no domínio Wavelet para fazer o realce da imagem. O autor define o contraste como a razão entre os coeficientes de detalhe e os coeficientes de aproximação na mesma escala, segundo a equação (52).

$$c_s^k(m, n) = \frac{D_s^k(m, n)}{A_s(m, n)} \text{ com } k \in \{h, v, d\} \quad (52)$$

O contraste é realçado localmente através da aplicação de um ganho, tal como expresso na equação (53):

$$\overline{c_s^k}(m, n) = G_s^k(m, n) * c_s^k(m, n) \quad (53)$$

Em que $G_s^k(m, n)$ é o ganho aplicado ao contraste. Juntando a informação das equação anteriores obtêm-se a relação entre os valores de contraste realçados e os coeficientes de detalhe e aproximação para uma dada escala (54).

$$\overline{c_s^k}(m, n) = G_s^k(m, n) * \frac{D_s^k(m, n)}{A_s(m, n)} \quad (54)$$

Por sua vez, $\overline{c_s^k}$ pode ser definido como a relação entre os coeficientes de detalhe e aproximação realçados (55).

$$\overline{c_s^k}(m, n) = \frac{\overline{D_s^k}(m, n)}{\overline{A_s}(m, n)} \quad (55)$$

Juntando as equações (54 e 55), de forma a eliminar a variável de contraste, $\overline{c_s^k}(m, n)$, obtêm-se a equação final de realce (56):

$$\overline{D_s^k}(m, n) = G_s^k(m, n) * \frac{\overline{A_s}(m, n)}{A_s(m, n)} * D_s^k(m, n) \quad (56)$$

Em que $\overline{D_s^k}$ e $\overline{A_s}$ são, respectivamente, os coeficientes de detalhe e os coeficientes de aproximação realçados da escala s . Em termos práticos, o algoritmo parte da escala de menor detalhe, S , e vai melhorando cada escala até chegar à de maior detalhe, $s = 1$. Os valores de $\overline{A_s}$ são obtidos fazendo a transformada de wavelet inversa da escala S para a escala s utilizando os coeficientes de detalhe realçados, $\overline{D_s^k}$. (Note-se que quando $s = S$, $\overline{A_s}$ toma simplesmente o valor de A_s). A imagem final melhorada corresponderá a $\overline{A_0}$.

A função de ganho $G_s^k(m, n)$ foi simplificada para um ganho constante, G , desta forma o realce não depende de mais nenhuma variável além do contraste. Depois de alguns testes, conclui-se que um valor de ganho igual a 4 leva aos melhores resultados. Em termos de níveis de decomposição analisados, para as imagens DCC utilizaram-se 3 níveis e para a base de dados DDSM foram usados 4.

Capítulo VI

Resultados e Discussão

2012

Capítulo VI – Resultados e Discussão

Neste capítulo serão apresentados os resultados obtidos para os diferentes métodos explicados no capítulo anterior. Inicialmente será feita uma contextualização sobre os algoritmos de comparação utilizados, justificando a utilização destes e não de outros. De seguida serão apresentados os resultados para a remoção do ruído e por fim os resultados para o realce das imagens DCC e DDSM.

6.1 - Algoritmos de comparação

O melhoramento de imagens não é uma característica fácil de medir. Vários métodos foram propostos ao longo dos artigos analisados. Uma forma é fazendo uma análise visual da imagem. Como é óbvio, esta abordagem não é fiável, dada a sua subjetividade, dependente muito de quem faz a análise. No entanto é um teste expedito e foi usado ao longo do trabalho durante a realização de testes preliminares.

Para testar os algoritmos de remoção de ruído foram feitos três testes distintos. No primeiro foram usadas as imagens artificiais às quais foi adicionado ruído Gaussiano. Este teste serve de validação dos algoritmos, garantindo que as amostras são controladas, não possuindo qualquer tipo de ruído. No segundo teste foram utilizadas as imagens do DCC, às quais foi igualmente adicionado ruído Gaussiano. No terceiro e último teste, foram aplicados os algoritmos de realce com e sem a aplicação prévia dos algoritmos de remoção de ruído de forma a perceber o seu efeito prático no realce das imagens.

A eficiência dos algoritmos de remoção de ruído foi medida recorrendo à relação sinal ruído, SNR, que é calculada utilizando a equação (57):

$$SNR = 10 * \log_{10} \left(\frac{\sum_{x,y} [R(x,y)]^2}{\sum_{x,y} [R(x,y) - T(x,y)]^2} \right) \quad (57)$$

Em que $R(x,y)$ é a imagem de referência sem ruído e $T(x,y)$ é a imagem de teste à qual foi adicionado o ruído e de seguida retirado com um dos algoritmos propostos. O termo em denominador representa a Potência do ruído não eliminado e o numerador a Potência do sinal original. Quanto maior for o valor da SNR, maior a semelhança entre R e T , logo maior será a quantidade de ruído eliminado e portanto melhor o método. As imagens da DDSM não foram

utilizadas neste teste, pois apresentam bastante ruído, tornando a medição da SNR inconclusiva. Quando o ruído intrínseco da imagem é elevado, não se tem a certeza da quantidade de ruído artificial eliminado em relação ao já existente, portanto este calculo não apresenta resultados válidos.

Para o análise da eficiência dos métodos de realce, foram estudados vários métodos. Dentro dos métodos quantitativos, a medição do contraste apresenta-se como um método simples e que torna a comparação mais coerente. No entanto uma medição global do contraste pode não ser totalmente indicativa da eficiência dos algoritmos. Alguns algoritmos podem reduzir o contraste em zonas não suspeitas e aumentar significativamente o contraste em zonas chave, portanto os algoritmos devem ter esta capacidade de diferenciação. Optou-se então por uma métrica que consiste em medir o realce individual conseguido para cada potencial microcalcificação. Para tal foram localizadas todos os achados com provável origem cálcica (pontos brancos). Teve-se o cuidado de identificar o mais precisamente possível todos os pixéis pertencentes à calcificação sem incluir fundo. Depois de saber a localização exata de cada calcificação e aplicados todos os métodos de realce às imagens, procedeu-se à medição do contraste local para cada calcificação. A métrica utilizada para quantificar o contraste foi o desvio padrão. O utilização desta medida deveu-se a não entrar em conta com a percepção visual. Note-se que ao contrário dos humanos um computador tem sensibilidade constante para toda a gama dos cinzentos. Além disso tem em conta todos os pixéis pertencentes à zona em questão, ao contrario de outros métodos que só entram em conta com o valor máximo e mínimo dessa mesma zona, sendo por isso menos sensível a *outliers*.

No final o contraste obtido para cada calcificação foi dividido pelo contraste original de forma a obter o valor do ganho em contraste. (58)

$$G_{contrast} = \frac{Contraste Realce}{Contraste Original} \quad (58)$$

A medição do ganho em contraste só por si continua a ser uma medição incompleta, pois um aumento de contraste pode vir associado a um aumento de ruído ou a distorções nas imagens. Por este motivo foi ainda introduzida a medição do ganho em ruído de cada imagem. Esta medição é feita por toda a

imagem e usa a mesma métrica para medição do ruído do método de remoção de ruído proposto por [50], equação (59).

$$Ruído = \frac{\text{Mediana}(|D_1^d|)}{0.6745} \quad (59)$$

Em que D_1^d representa os coeficientes diagonais da WT na escala 1, utilizando a Wavelet de Haar da imagem a estudar. Foi utilizada esta medição, pois esta infere o ruído presente em toda a imagem e não o do fundo. Neste caso em específico é mais interessante medir o ruído na globalidade da imagem pois há métodos que não processam o fundo da imagem, portanto caso eles aumentassem o ruído na zona da mama esse efeito não seria contabilizado. Mais uma vez era calculado o ganho em ruído fazendo a razão entre o ruído da imagem melhorada sobre o ruído da imagem original, equação (60).

$$G_{ruído} = \frac{\text{Ruído Realce}}{\text{Ruído Original}} \quad (60)$$

Por fim foi ainda feito um teste controlado de segmentação. De forma a perceber se os algoritmos introduzem distorções ou alterações indesejáveis nas imagens. Este teste foi feito isolando uma microcalcificação conhecida e representativa de todo o conjunto, fazendo de seguida a sua segmentação. Depois disso foi medida a circularidade da microcalcificação recorrendo à equação (61):

$$\text{Circularidade} = \frac{4 * \pi * A}{p^2} \quad (61)$$

Em que A representa a área da calcificação e P o perímetro dessa mesma calcificação. Como à partida se sabe que uma microcalcificação é circular, é de esperar que se obtenham valores de circularidade muito próximos de 1 ou próximo do valor da calcificação original quando esta não é circular. Qualquer valor que se desvie significativamente do esperado pode ser indicativo de um mau realce da imagem.

A segmentação será obtida pela seleção dos A (área ou número de pixéis) maiores valores da região escolhida. Este método procura ser ao mesmo tempo simples e eficiente já que algoritmos mais complexos poderiam interferir nos resultados.

6.2 – Remoção de Ruído

Para testar a eficiência dos algoritmos de remoção de ruído, começou-se por adicionar ruído gaussiano à imagem artificial da Figura 41.



Figura 41 - Mama artificial, 1024x1024 de 12bits

Foram testadas diferentes quantidade de ruído, a sua quantidade era controlada através do aumento da largura (desvio padrão) da gaussiana. Os resultados correspondentes à aplicação dos dois algoritmos e de um filtro mediana com uma janela de 3x3 pixels encontram-se na tabela 2:

Tabela 2 - Valor da SNR obtido para os diferentes testes dos algoritmos de remoção de ruído.

Amplitude (Ncs)	Imagem com Ruído	Filtro Mediana	Wavelet Robusto	Wavelet Fundo
40	53.04	33.67	67.35	67.32
80	46.87	33.66	61.81	61.83
160	40.75	33.58	53.90	53.89
320	34.98	33.21	47.98	48.00
640	28.56	31.85	43.00	42.95
1280	22.58	28.17	34.27	34.28

Os resultados para as imagens artificiais, provaram a eficiência dos algoritmos propostos. Em ambos os casos houve uma redução significativa da quantidade de ruído na imagem. A prova encontra-se no maior valor de SNR conseguido depois da remoção do ruído. Tiveram inclusive resultados bastante melhores que o filtro mediana, um filtro comumente utilizado neste tipo de abordagem. Em termos visuais, também existe uma melhoria significativa em ambos os algoritmos Figura 41.

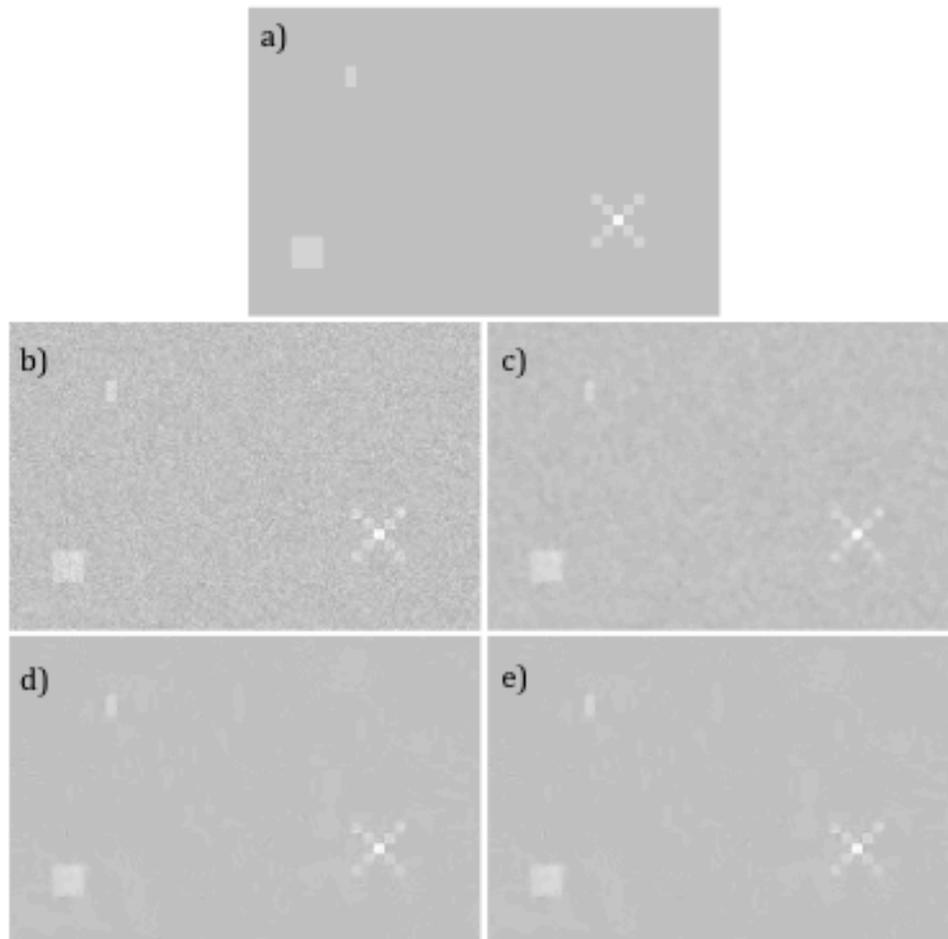


Figura 42 – Resultados dos algoritmos de Denoise para um ruído de 1280 a)Imagem original; b)imagem com ruído; c) Mediana; d) ROBUSTO; e) FUNDO

Fazendo uma análise comparativa entre os dois métodos, não é evidente qual apresenta melhores resultados. Em termos de SNR os resultados são praticamente os mesmos (Tabela 2). Em termos visuais também não é evidente que um se sobressaia em relação ao outro. Mais uma vez o filtro mediana apresenta o pior resultado, além de não conseguir lidar com pequenas quantidades de ruído, tende a provocar distorções nas bordas dos objetos, principalmente esquinas, o que é de evitar neste tipo de imagens. Este teste, embora não seja indicativo de uma melhor eficiência do algoritmo proposto,

serve para provar o conceito de que é possível utilizar a informação do fundo para fazer a quantificação do ruído.

Os testes em imagens reais seguiram a mesma ideia dos testes na imagem artificial. Os resultados são apresentados nos seguintes gráficos:

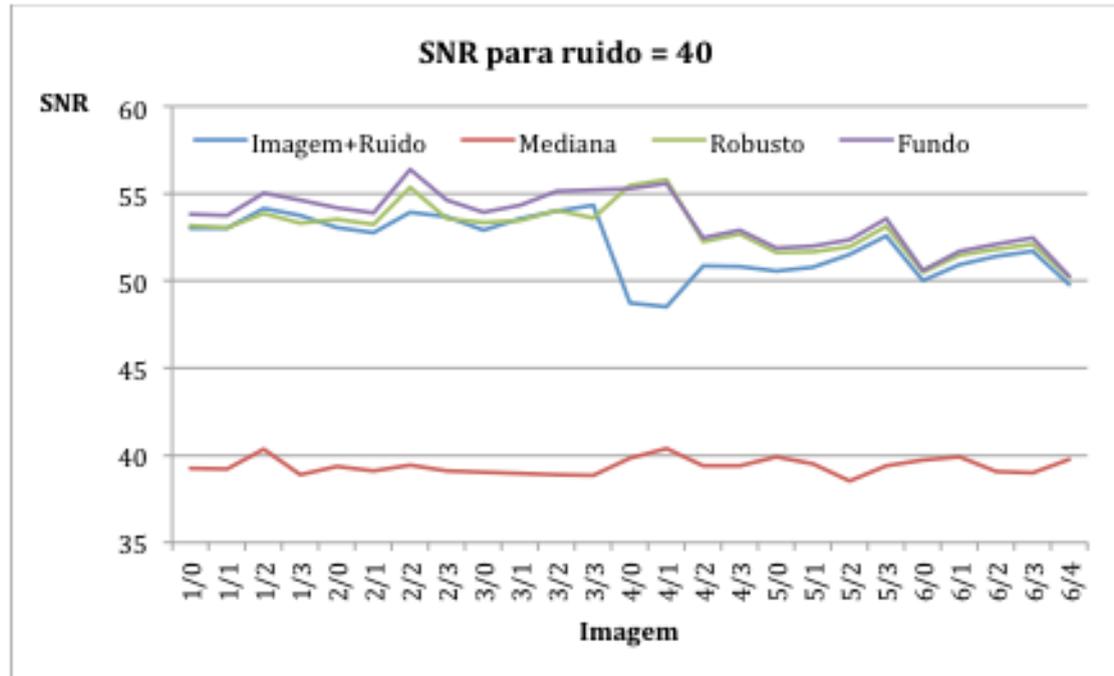


Figura 43 - Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=40 Níveis Cinzentos

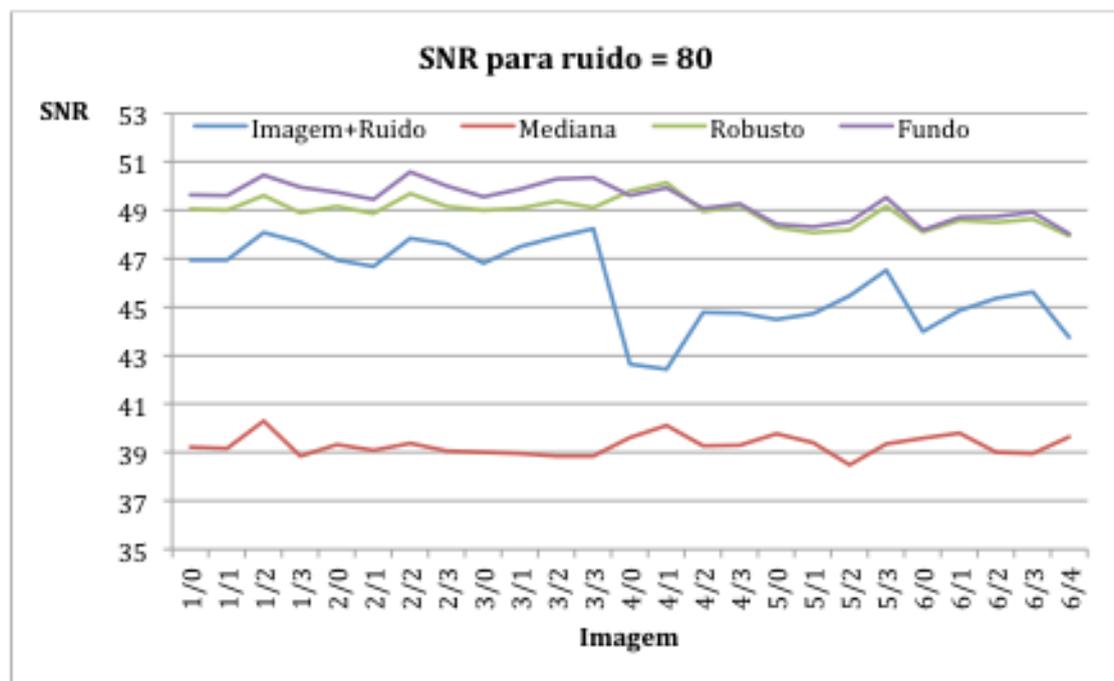


Figura 44 - Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=80 Níveis Cinzentos

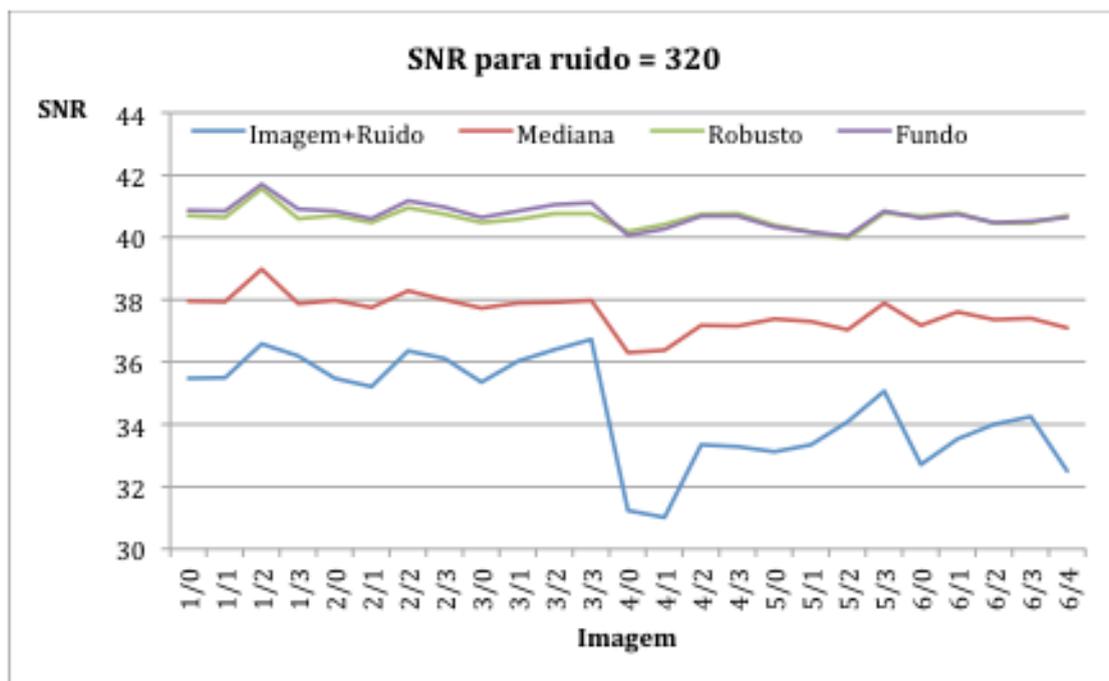


Figura 45 - Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=320 Níveis Cinzentos

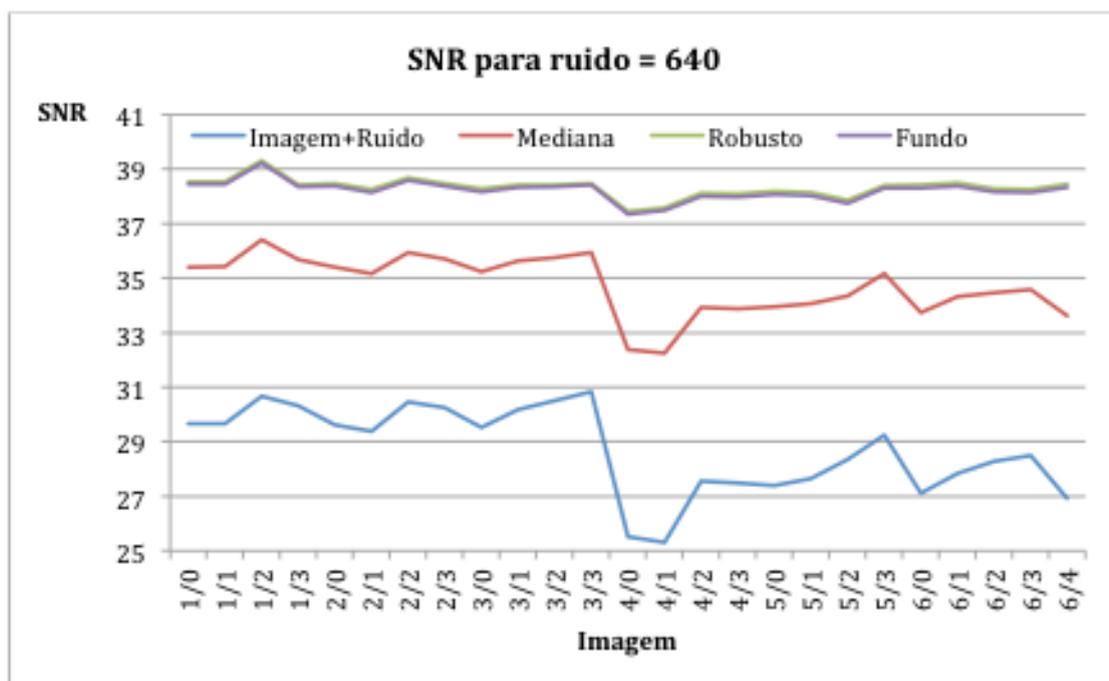


Figura 46 - Gráfico da SNR para 3 métodos de remoção de ruído, aplicados a diferentes imagens corrompidas com ruído Gaussiano artificial. Ruído=640 Níveis Cinzentos

Analisando os valores obtidos para a imagem com ruído, percebe-se que houve uma diminuição da SNR com o aumento da quantidade de ruído adicionada. Os métodos e remoção de ruído seguiram esta mesma tendência, indo de encontro ao esperado.

Pela análise dos gráficos é possível concluir que os métodos de remoção de ruído baseados em Wavelet foram capazes de remover o ruído adicionado. É possível verificar que para quantidades inferiores de ruído o método FUNDO se destacou em relação ao método ROBUSTO. Para valores superiores de ruído os resultados foram praticamente os mesmos, indicando que nesta situação apresentam a mesma eficiência. Este resultado aponta para que a utilização da informação do fundo consegue determinar com maior precisão a quantidade de ruído presente na imagem, daí o conseguir remover mais eficazmente quando a quantidade é baixa.

A eficiência do filtro mediana só é satisfatório para níveis de ruído elevados. Quando a quantidade de ruído é pequena a aplicação deste filtro elimina alguns detalhes da imagem juntamente com o ruído. Não apresentando qualquer tipo de sensibilidade quanto à zona da imagem nem à quantidade de ruído, já eram espectáveis tais resultados. Na Figura 47 é possível ter uma noção do resultado visual da aplicação dos diferentes filtros.

Verifica-se pela análise da Figura 47 que a adição do ruído a 40NCs não introduziu uma alteração visual significativa (note-se que as imagens tem uma profundidade de 12bits – 4096 NCs), por outro lado o ruído a 640NCs já é visível a alteração. Verifica-se que o filtro mediana eliminou alguns pequenos detalhes tanto para pequenas como para grandes quantidades de ruído. Este efeito é de evitar pois eventuais microcalcificações teriam sido eliminadas utilizando este método. Os métodos baseados em wavelets são de difícil distinção visual. No entanto é possível perceber que mesmo para quantidades superiores de ruído conseguiu-se preservar os detalhes importantes.

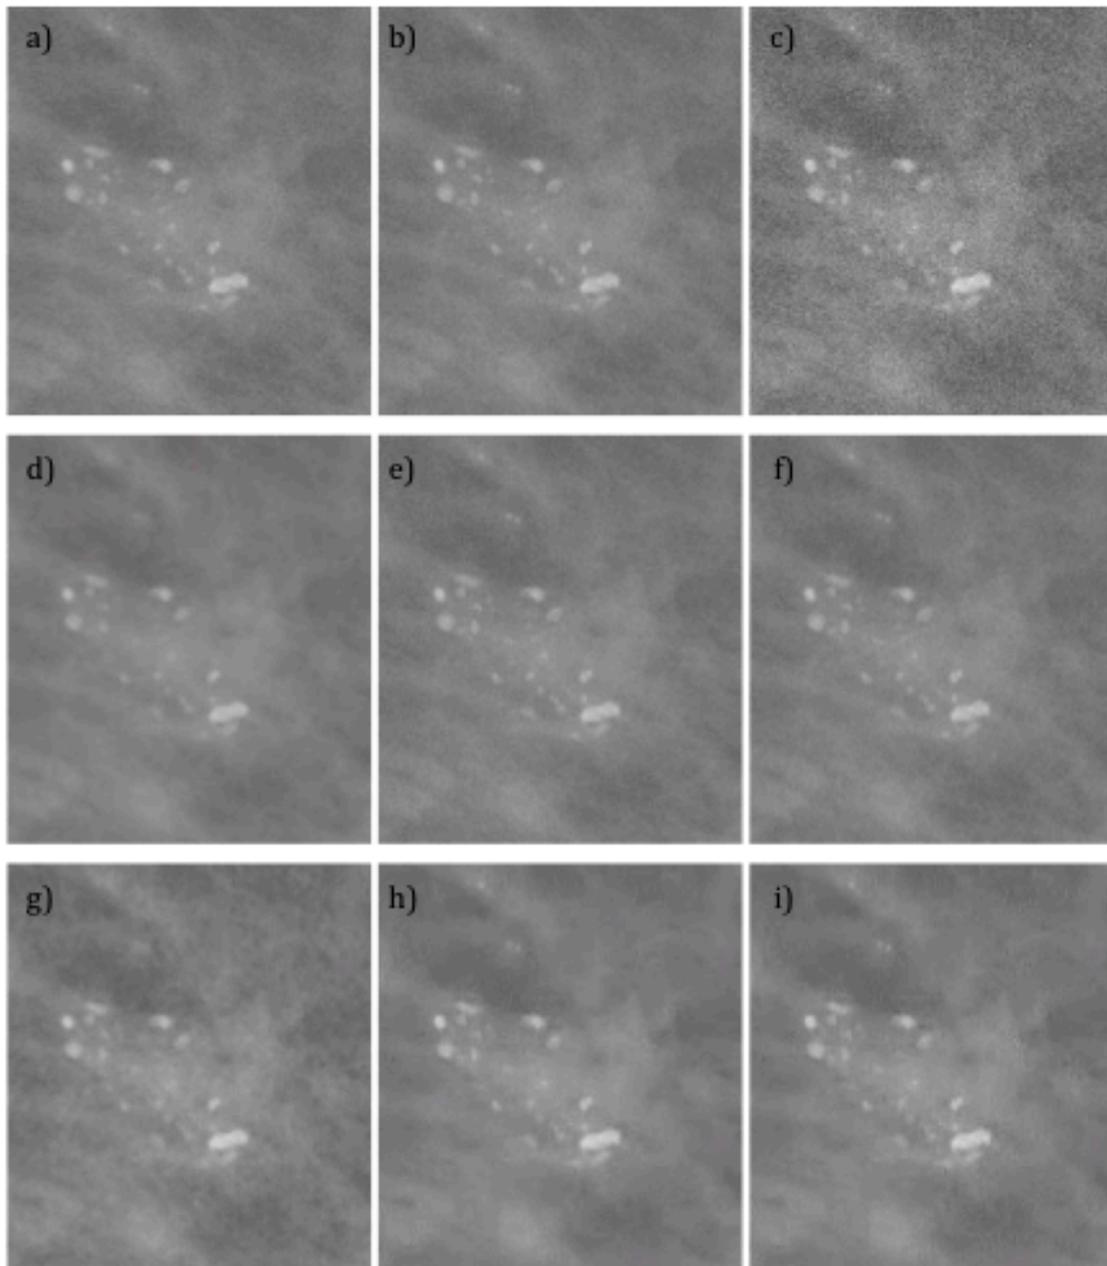


Figura 47 - Resultado visual do teste dos algoritmos de remoção de ruído em imagens reais. a) Imagem Original; b) Imagem Corrompida com ruído a 40 NCs; c) Imagem Corrompida com ruído a 640 NCs; d) Mediana com ruído = 40NCs; e) Robusto com ruído = 40NCs; f) Fundo com ruído = 40NCs; g) Mediana com ruído = 640NCs; h) Robusto com ruído = 640NCs; i) Fundo com ruído = 640NCs;

Em suma, tanto os resultados obtidos para a SNR e visualmente apontam para que os dois métodos baseados em Wavelets têm potencial para aplicação prática. Comparando os dois existe uma ligeira vantagem para o método baseado na informação do fundo, dados os seus melhores resultados para pequenas quantidades de ruído.

6.3 – Realce

Os algoritmos de realce estudados foram aplicados às imagens da base de dados DDSM e às imagens cedidas pelo consultório de imagiologia médica Dr. Campos Costa (DCC). Optou-se por testar os algoritmos de realce com e sem a aplicação prévia do algoritmo de redução de ruído baseado no Fundo. Devido ao enorme volume dos dados, optou-se por representá-los utilizando um diagrama de extremos e quartis (caixa de bigodes). Foi ainda avaliado o comportamento dos algoritmos em relação ao realce do ruído e em termos de distorções indesejadas nas bordas das microcalcificações.

6.3.1 – Imagens da Base de Dados Dr. Campos Costa

Os resultados para o ganho em contraste e para o ganho em ruído para as imagens DCC são apresentados na Figura 48.

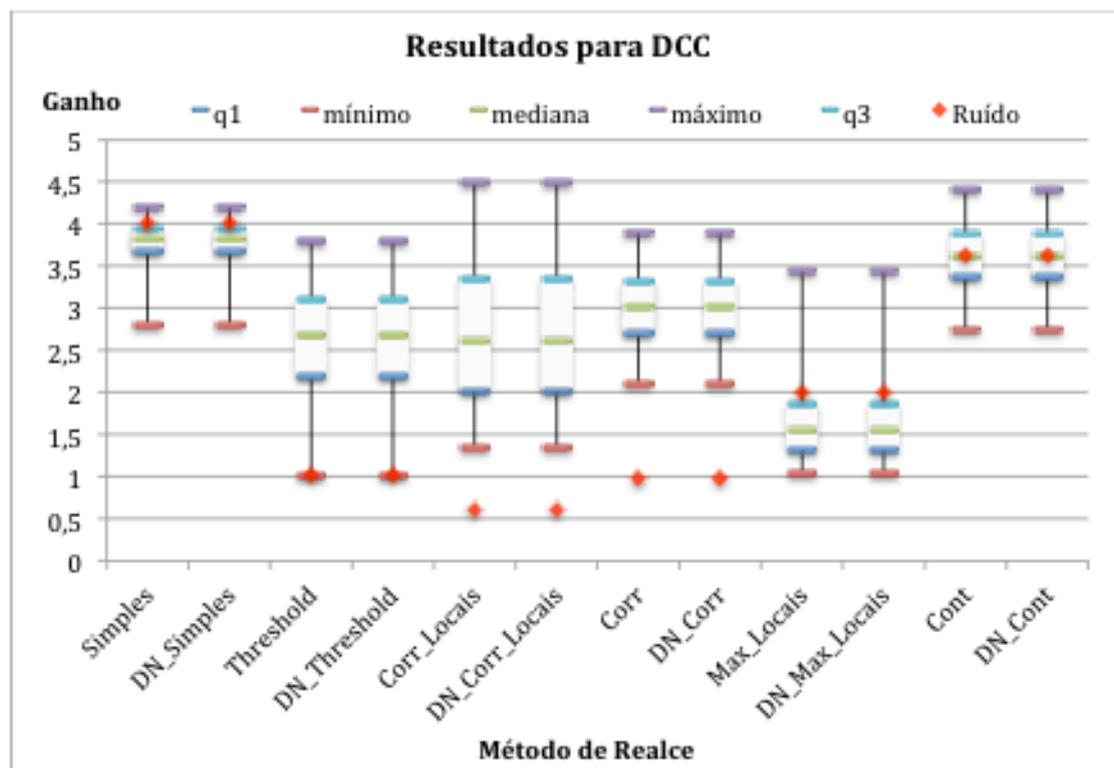


Figura 48 – Resultados realce para Imagens DCC; mínimo, q1, mediana, q3 e máximo são respectivamente os percentis 2%, 25%, 50%, 75% e 98% e são referentes ao ganho em contraste; Ruído representa o ganho médio em Ruído para cada método. O prefixo "DN_" indica a aplicação prévia do algoritmo de redução de ruído baseado no FUNDO.

Começando por analisar a eficiência dos métodos com e sem a aplicação prévia de um algoritmo de remoção de ruído, percebe-se que esta etapa não introduziu qualquer tipo de alteração nos resultados para nenhum método. O

resultado já era esperado pois este conjunto de imagens tem uma quantidade de ruído bastante baixa. Portanto as imagens originais acabam por praticamente coincidir com as imagens sem ruído.

Pela análise do gráfico da Figura 48 conclui-se que os métodos, na sua globalidade, conseguiram fazer o realce do contraste dos achados. Em termos de ruído, o método *Simples*, *Cont* e *Max_Locais* obtiveram um realce do ruído ao mesmo nível do realce dos achados, demonstrando uma certa insensibilidade a este nível. Note-se que este resultado não é problemático para este conjunto de imagens, já que o ruído é praticamente desprezável, no entanto para outro tipo de imagens este resultado pode não ser tolerável. Os métodos *Corr* e *Threshold* fizeram o realce mantendo o ruído praticamente inalterado, tal como esperado. O método *Corr_Locais* obteve valores de ganho em contraste superior à unidade, provando conseguir salientar os achados. Em termos de ganho em ruído, obteve-se um valor inferior a 1, indicando que incorpora uma componente de remoção de ruído, já que no final a quantificação do ruído deu um valor praticamente igual a metade do valor do ruído original.

Em termos individuais, o método *Simples*, obteve a menor variância nos ganhos, tal resultados fica a dever-se ao facto de não possuir sensibilidade a qualquer tipo de característica da imagem, fazendo sim um realce linear global. De reparar que o ganho em contraste toma um valor próximo do ganho parametrizado para este método, o que indica que existe uma forte relação entre eles. Os restantes métodos por apresentarem algum tipo de sensibilidade, possuem também uma variação maior nos ganhos. O método *Cont* foi o que, a seguir ao *Simples*, apresentou os maiores ganhos, na ordem dos 3,5. Este método já possuiu alguma sensibilidade aos detalhes, no entanto por ser um método geral e não unicamente orientado para o realce de microcalcificações continua a fazer o realce por toda a imagem. Este facto leva a que o ganho em ruído seja também elevado tal como no método *Simples*. De seguida, com ganhos ligeiramente inferiores, por volta de 3, está o método *Corr*, ainda com uma variação relativamente baixa nos ganhos foi possível fazer um realce da imagem mantendo o ruído constante. Embora os ganhos sejam mais baixos que os dois métodos anteriores, continua a haver um ganho claro em termos de contraste. A alteração introduzida no método *Corr* que deu origem ao método *Corr_Locais*

levou a que na prática os ganhos tomassem valores mais dispersos e que o ruído fosse reduzido. Tal resultado leva a concluir que a alteração introduzida neste método tende a tornar a classificação dos pixéis menos difusa. Os valores de probabilidades tomam valores mais próximos de 1 ou 0, daí também haver mais valores de ganhos mais próximos do ganho máximo e de 1. Isto fez com que algumas calcificações tenham sido menos realçadas, no entanto pelo facto de nenhum achado apresentar um ganho em contraste inferior a 1, permite-nos concluir que este método conseguiu fazer uma boa distinção entre achados e fundo, salientando os primeiros e suavizando o segundo. O método *Threshold* obteve valores de ganhos aceitáveis, no entanto existem valores de ganho em contraste igual a 1, o que leva a concluir que o cálculo do *threshold* não foi suficiente para diferenciar as calcificações do fundo. Por fim o método *Max_Locais* foi o que obteve o valores mais baixos de ganhos, apresenta também uma variação acentuada para os ganhos pertencentes ao percentil superior. Este resultado pode dever-se à alteração no parâmetro de linearidade para um valor de 2, lembre-se que esta alteração tende a realçar detalhes mais evidentes em relação aos menos evidentes, competindo com o calculo da matriz de ganhos que procura evidenciar os detalhes menos evidentes. Em termos de ganho em ruído obteve-se um valor superior ao realce em contraste, tal já era esperado e mais uma vez pouco preocupante para este conjunto de imagens.

Depois de analisados os dados acerca dos ganhos em contraste e em ruído, é também interessante fazer uma análise em termos de alterações introduzidas nas bordas das microcalcificações. Nesse sentido, será apresentado a título de exemplo a Figura 49 onde constam os valores da circularidade de uma microcalcificações segmentada depois da aplicação dos vários métodos apresentados.

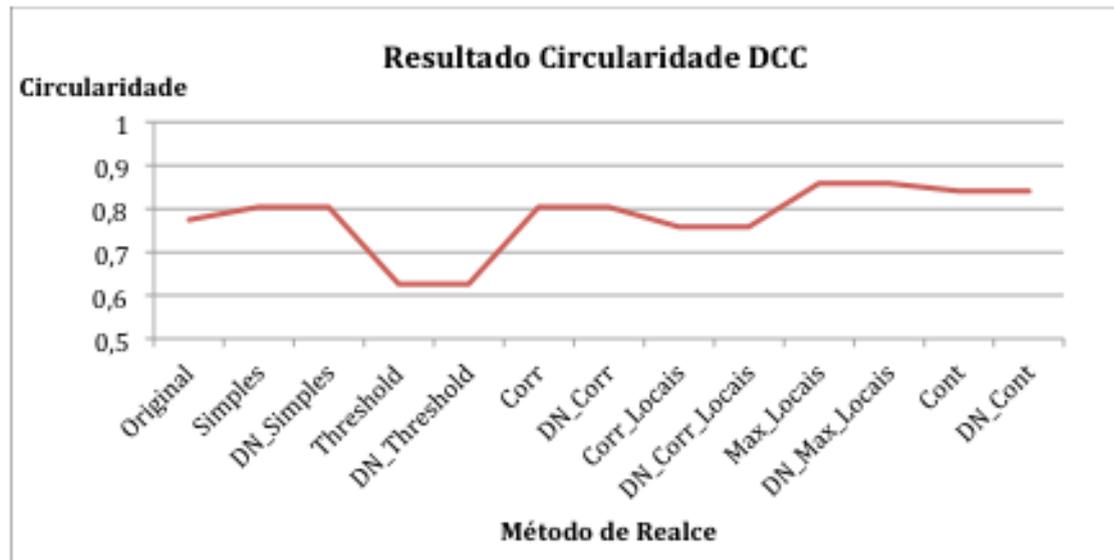


Figura 49 –Resultado Circularidade para imagens DCC.

Pela análise do gráfico da Figura 49, é possível verificar que mais um vez a remoção de ruído não provocou qualquer alteração nos resultados. Analisando os valores das circularidades dos métodos *Simples*, *Corr*, *Corr_Locais* é possível concluir que preservaram eficazmente os contornos da calcificação. O método *Cont* teve um ligeiro desvio positivo, indicando que teve um efeito de alisamento dos contornos. O mesmo acontece, mas de forma mais intensa com o método *Max_Locais* que obteve o maior valor de circularidade. Por outro lado, o método *Threshold* obteve o menor valor de circularidade e também o mais afastado do original, indicando que se trata do método com menor capacidade de preservar as bordas das calcificações. O facto da circularidade ser inferior indica que a calcificação neste caso aparecerá menos circular e com fronteiras mais irregulares.

Na figura 50 é apresentado, a título de exemplo, o resultado visual para um grupo de classificações de diferentes dimensões.

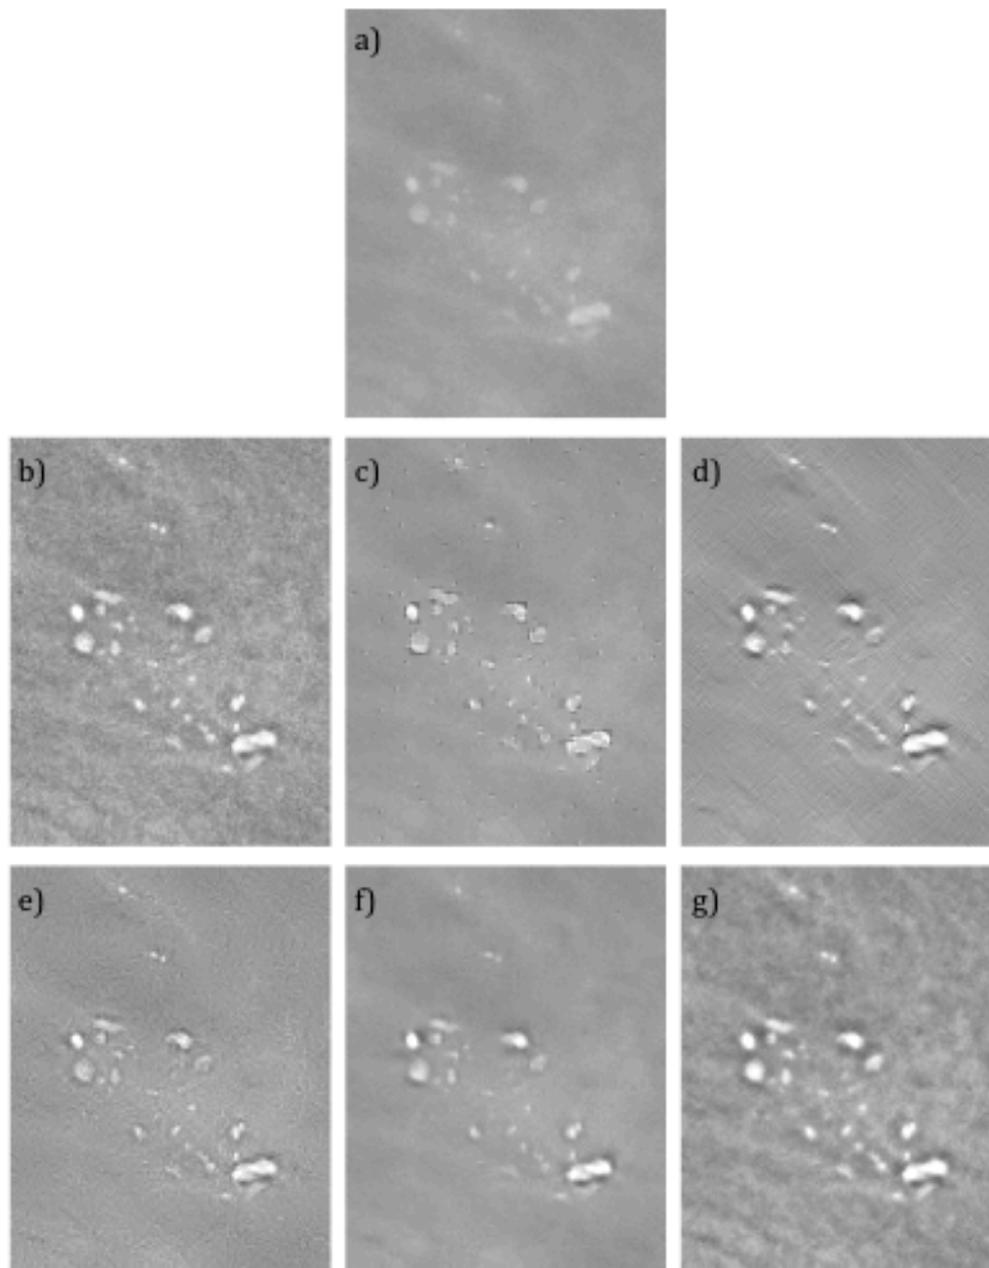


Figura 50 - Imagem exemplo para o resultado dos diferentes métodos apresentados. a) Original; b) Simple; c) Threshold; d) Corr_Locais; e) Corr; f) Max_Locais; g) Cont

Analisando a figura é possível confirmar que nas imagens 50-b até 50-g, as microcalcificações se encontram mais visíveis que em 50-a. Visualmente também é notório que todos os métodos apresentam resultados diferentes, demonstrando que as abordagens utilizadas são distintas. O realce global dos métodos *Simple* e *Cont* também se verifica já que o fundo das imagens se apresenta realçado, daí se poder entender que houve um certo aumento do ruído. O método *Threshold* apresenta distorções tanto nas microcalcificações

como no fundo, tal como foi apontado com os resultados da distorção. Este resultado pode dever-se ao problema já referido anteriormente na determinação do *threshold* ótimo, não permitindo fazer a correta distinção entre os pixéis a salientar e os pixéis a manter. A aproximação aplicada aos ângulos na criação do mapa de contornos também pode ter levado à eliminação de coeficientes importantes. O método *Max_Locais* foi o que teve o resultado mais próximo da imagem original, fazendo o realce menos intenso, tal como já tinha sido demonstrado pelos valores de ganho em contraste inferiores aos restantes métodos. Os métodos *Corr* e *Corr_Locais* também apresentam um realce evidentes, tal como indicado pelos ganhos em contraste. Comparando os dois métodos é possível afirmar que o método *Corr_Locais* conseguiu salientar de forma mais evidente as calcificações, o que era esperado dado que a alteração introduzida levou a que a classificação dos pixéis fosse menos dispersa e portanto mais precisa.

6.3.2 – DDSM

Os resultados para o ganho em contraste e para o ganho em ruído para as imagens da base de dados DDSM são apresentados na Figura 51.

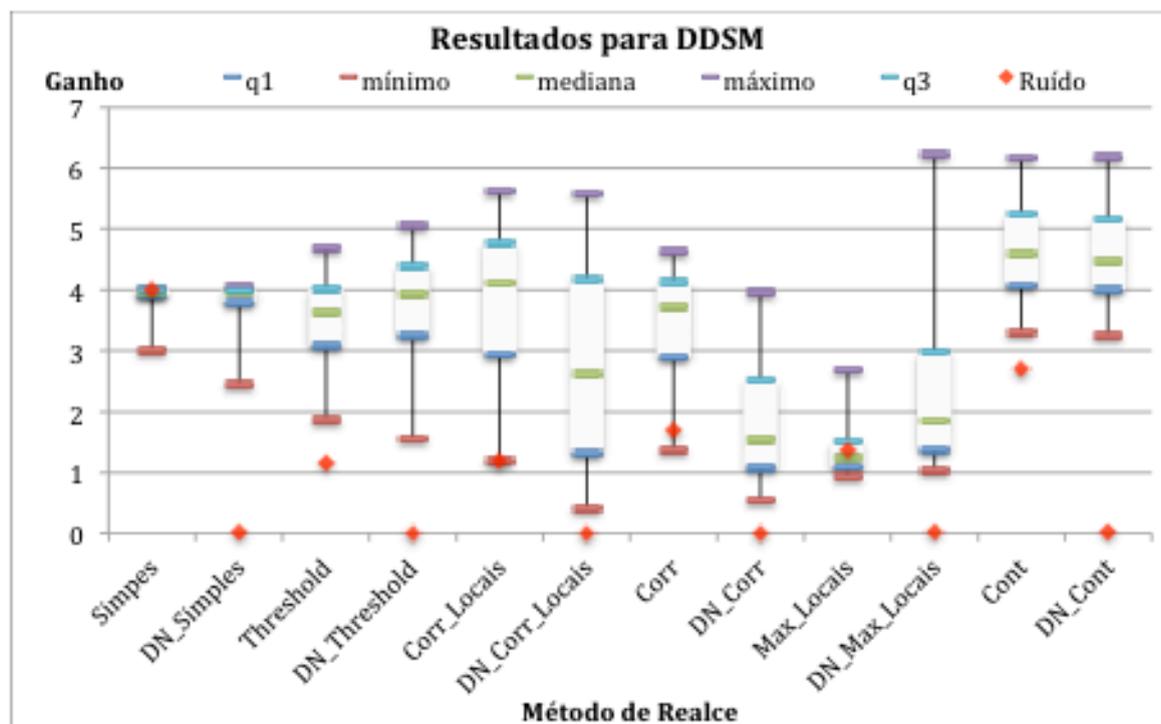


Figura 51 – Resultados realce para Imagens DDSM; mínimo, q1, mediana, q3 e máximo são respectivamente os percentis 2%, 25%, 50%, 75% e 98% e são referentes ao ganho em contraste; Ruído representa o ganho médio em Ruído para cada método

Pela análise dos resultados presentes na figura, é possível verificar que, ao contrário dos resultados obtidos para o conjunto de imagens DCC, a aplicação prévia de um método de remoção de ruído altera significativamente os resultados dos ganhos. É visível que os ganhos em contraste depois da remoção do ruído tomam, no geral, valores mais dispersos. Os métodos onde essa alteração é menos sentida é nos métodos *Simples* e *Cont*. Este resultado fica a dever-se à sua insensibilidade ao ruído. Os restantes métodos ao procurarem ruído que já não se encontra na imagem acabam por ver os seus resultados alterados de forma mais evidente. Em termos de ganho em ruído, depois de feita a sua remoção, obteve-se em todos os casos um valor próximo de zero, indicando que este foi praticamente eliminado, tal como esperado.

Focando nos resultados sem remoção prévia de ruído obtiveram-se resultados, em termos de distribuição dos ganhos, semelhantes aos obtidos nas imagens DCC para os métodos *Simples*, *Threshold* e *Cont*. Estes resultados demonstram uma certa robustez por parte dos métodos apresentados, já que com pequenos ajustes nos parâmetros se obteve resultados semelhantes. A maior alteração foi no método *Max_Locais*, apresentando uma variação nos ganhos bastante superior ao esperado, quando aplicado a uma imagem à qual foi removido o ruído. Tal pode dever-se ao passo onde são removidos os pixels pertencentes ao percentil com os 2% maiores valores de coeficientes. Note-se que este passo procura reduzir a sensibilidade do método ao ruído, nomeadamente o impulsional, daí que depois deste ser removido o algoritmo necessite de se adaptar, o que não se verificou. O método *Simples* mais uma vez apresentou um ganho em Ruído na mesma ordem do ganho em contraste e do ganho parametrizado, já o método *Cont*, conseguiu um resultado ligeiramente melhor para este conjunto de imagens, provando que mais um vez a sensibilidade introduzida teve um efeito benéfico no realce das imagens. O aumento no ganho em contraste não foi acompanhado pelo ganho em ruído, tal está relacionado com o aumento no número de escalas analisadas de 3 para 4 em relação à base de dados DCC. Note-se que ao realçar a quarta escala de detalhe já não se altera os valores do ruído pois este concentra-se no primeiro e segundo nível de detalhe.

Os métodos *Corr* e *Corr_Locais* obtiveram alguns ganhos próximos de 1, depois de uma análise às calcificações que deram origem a estes ganhos, percebeu-se que foram fundamentalmente devido a calcificações de baixo contraste, com valores próximos do ruído, evidenciando alguma fragilidade nesta identificação. Os métodos *DN_Corr* e *DN_Corr_Locais* obtiveram alguns ganhos em contraste inferior a 1, indicando que o realce não foi atingido para todas os achados identificados. Tal ficou a dever-se à componente de remoção de ruído intrínseca destes dois métodos, que mesmo na ausência de ruído forçam a sua existência, acabando por classificar indevidamente alguns pixéis como ruído, daí a perda de contraste. Em termos de ganho em ruído ambos os métodos cumpriram com os objectivos aos quais se propunham inicialmente, realçar as imagens sem aumentar o ruído, portanto nada há a comentar neste aspecto. Em termos de distribuição dos ganhos para estes dois métodos os resultados foram semelhantes aos obtidos para as imagens DCC, reforçando a ideia de que a matriz de probabilidades no método *Corr_Locais* toma valores menos dispersos.

Mais uma vez, da mesma forma que para a base de dados DCC, foi testada a capacidade de preservar os contornos das imagens. Os resultados da circularidade para os vários métodos são apresentados na Figura 52.

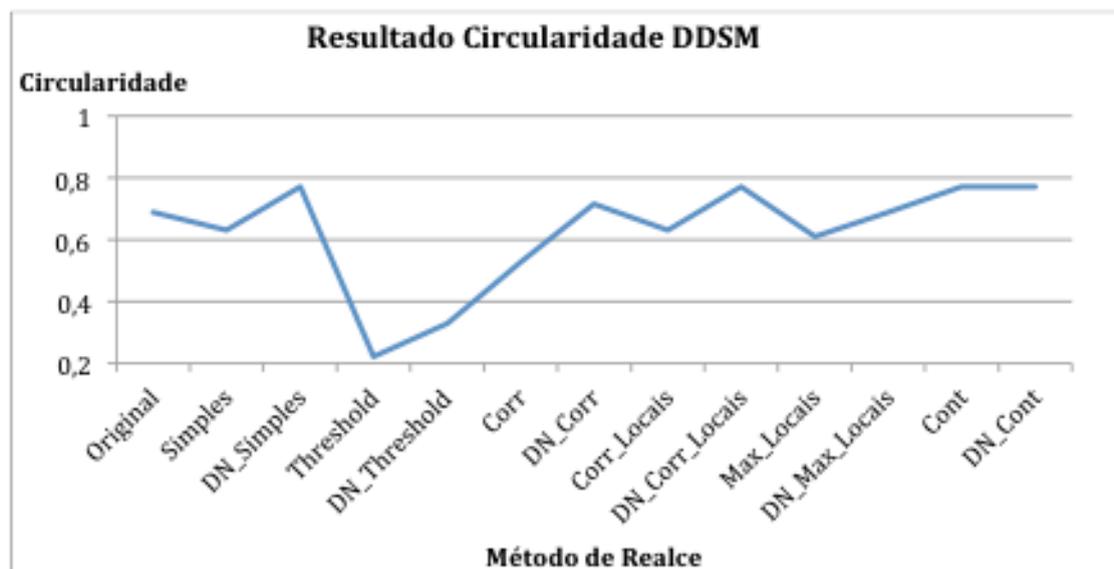
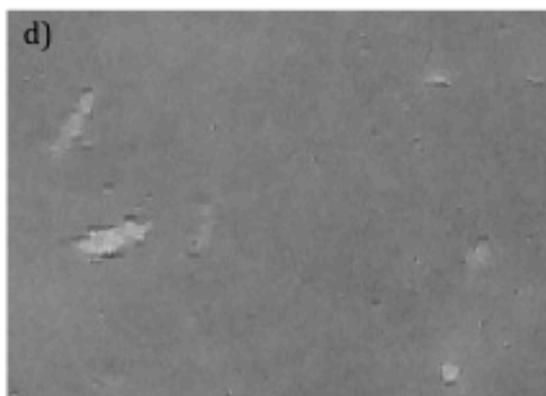
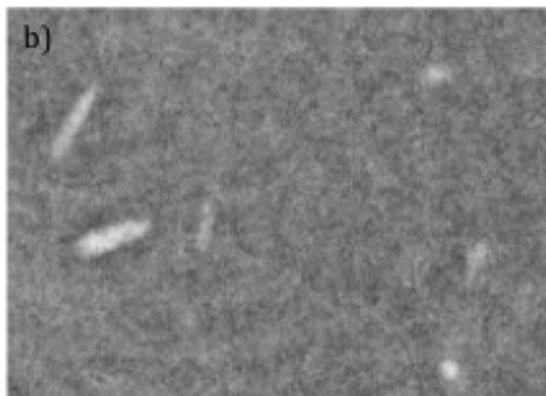
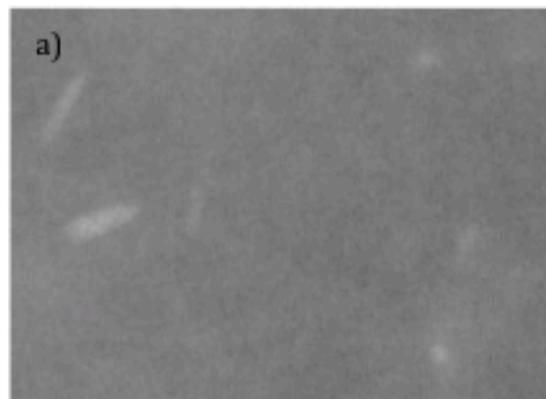


Figura 52 - Resultado Circularidade para imagens DDSM

Fazendo a análise da figura é perceptível que, para esta base de dados, os valores da circularidade foram afectados pela remoção do ruído, tal como esperado. Outro resultado que se verificou e era espectável foi obter valores de

circularidade superiores depois de removido o ruído. Os desvios em relação à circularidade original nesta base de dados foram superiores aos da base de dados DCC, tal pode ter ficado a dever-se à maior quantidade de ruído na base de dados DDSM. Mais uma vez o método *Threshold* destaca-se pela negativa, obtendo o valor mais baixo de circularidade tanto para o método com e sem remoção prévia de ruído. O método *Corr* também apresentou um valor de circularidade ligeiramente abaixo do esperado, tal pode ter ficado a dever-se a um erro pontual do realce dado que depois de removido o ruído o valor voltou ao esperado. Dos restantes métodos todos ficaram dentro de uma gama esperada, salientando o método *Cont* que obteve resultados semelhantes para o método com e sem a remoção de ruído.



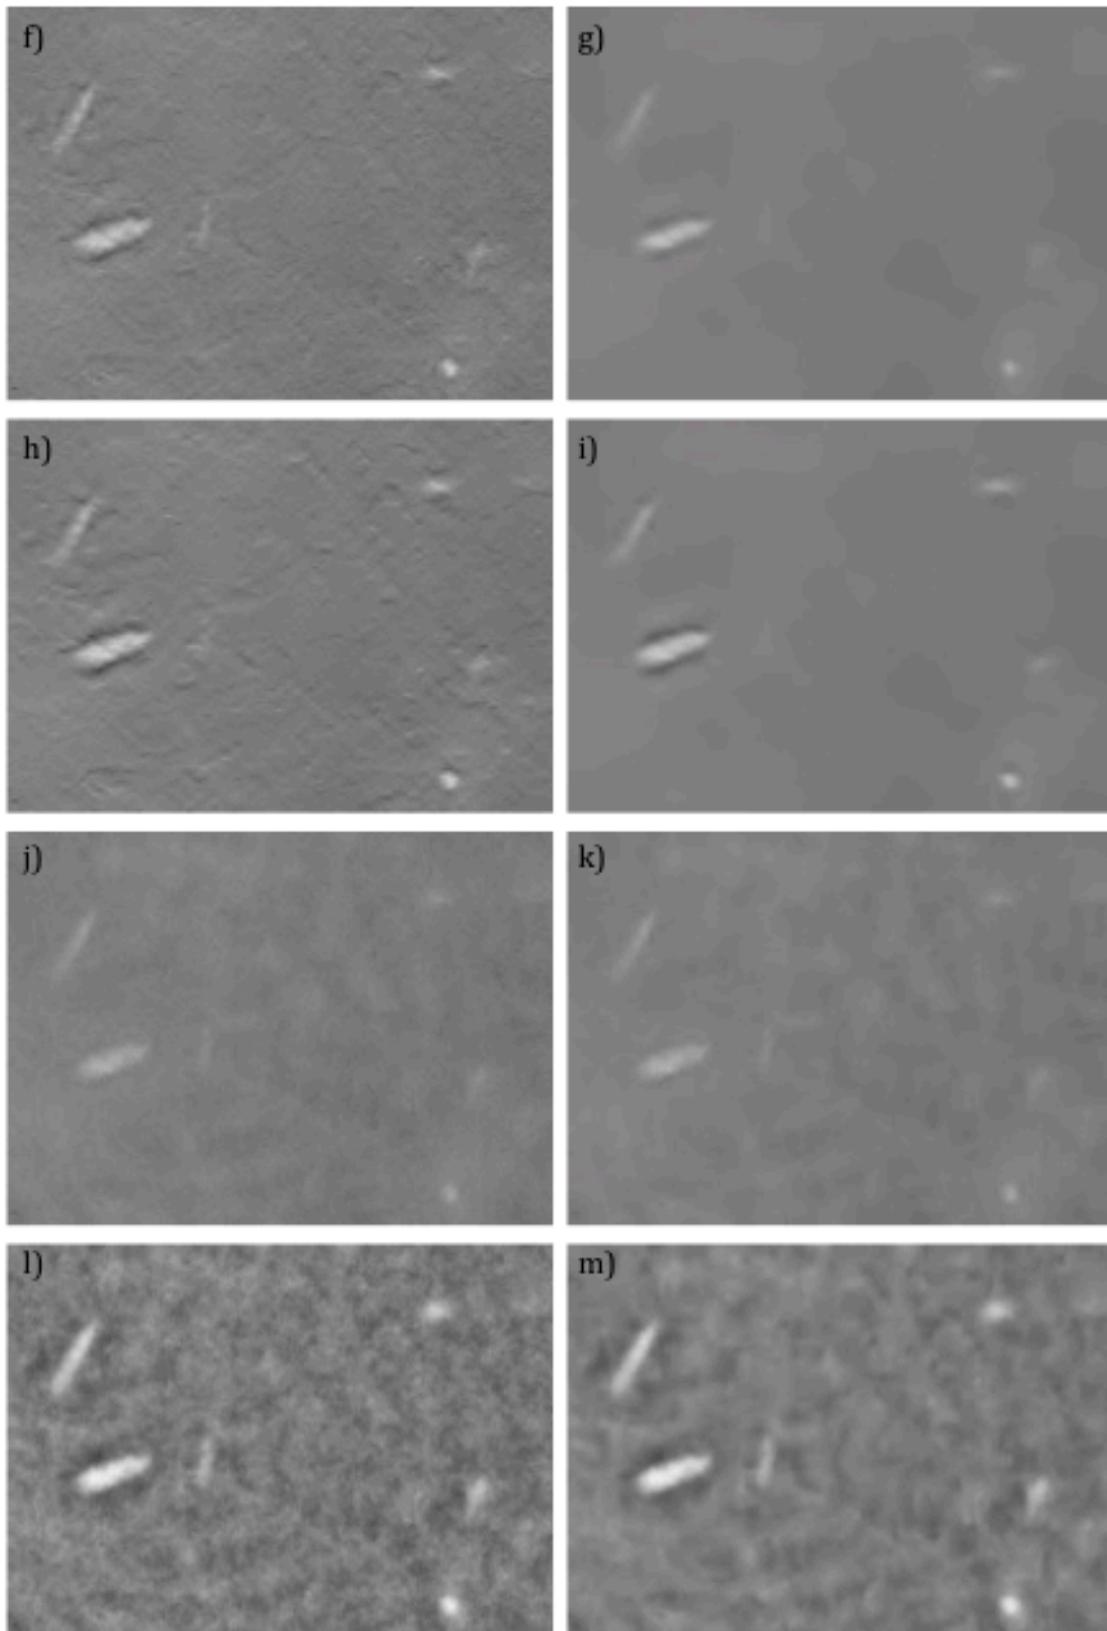


Figura 53 - Resultados Visuais para imagens DDSM; a) original; b) Simple; c) DN_Simple; d) Threshold; e) DN_Threshold; f) Corr; g) DN_Corr; h) Corr_Locais; i) DN_Corr_Locais; j) Max_Locais; k) DN_Max_Locais; l) Cont; m) DN_Cont; o prefixo "DN_" indica a remoção prévia do ruído

Atendendo à figura 53 é possível visualizar que a aplicação do método de remoção de ruído alterou os resultados dos vários métodos tal como era espectável pelos diferentes valores de ganhos em contraste e em ruído obtidos.

Mais uma vez, da mesma forma que para as imagens da base de dados DCC, verifica-se que o método *Simples* e *Cont* fazem o realce do fundo da imagem, tal como esperado. Com a remoção do ruído passa a ser também visível que o fundo se apresenta mais suave, indicando uma menor quantidade de ruído, provada pelo valor de ganho em ruído próximo de zero. No método *Threshold* é possível verificar a deformações provocadas nas calcificações, estas foram estudadas e apresentadas na Figura 52 e pode-se verificar que essa distorção teve efeitos negativos na visualização. A remoção do ruído não melhorou o resultado deste método tal como apontado pelos mesmos resultados da circularidade.

Para os métodos *Corr* e *Corr_Locais* é possível verificar o realce sem afectar demasiado o fundo da imagem. É ainda visível o efeito da remoção de ruído que leva a que o ganho em contraste seja menor e por vezes inferior à unidade, perdendo-se alguns detalhes de achados em conjunto com detalhes do fundo da imagem. Conclui-se então que estes dois métodos resultam melhor quando aplicados às imagens originais, pois não têm capacidade de se adaptar quando a quantidade de ruído é muito baixa.

No método *Max_Locais*, é visível que os ganhos mais baixos se refletiram num realce visual menor em relação aos restantes métodos. Estes resultados são piores em relação aos obtidos para as imagens DCC. Esta diferença estará relacionada com a escolha do valor do percentil 98%. Nas imagens DCC este valor levou a melhores resultados porque as imagens não apresentam artefactos, já nas imagens DDSM existem inúmeros artefactos difíceis de quantificar, portanto o valor de 98% deveria ser reduzido, ou idealmente ser obtido dinamicamente, de forma a que menos artefactos interfiram com o calculo dos ganhos. Conclui-se então que este método não apresenta robustez suficiente para uma aplicação a grande escala, devendo-se fazer alterações de forma a que os resultados se aproximem dos esperados.

Capítulo VII

Conclusão

2012

Capítulo VII – Conclusão

Neste trabalho foram abordadas os princípios fundamentais para a criação de um sistema CAD de detecção de microcalcificações em imagens de mamografia. Foram dados a conhecer as patologias comumente encontradas neste tipo de exames. Foi ainda feita uma explicação da Transformada de Wavelet, que embora bastante resumida, apresenta os conceitos fundamentais para a sua aplicação num contexto mais prático. A investigação destas duas componentes foi fundamental para o desenvolvimento do restante trabalho aqui proposto, podendo também servir de ponto de partida para outros do mesmo género ou que usem os mesmos conceitos.

Os algoritmos aqui apresentados foram seleccionados depois de uma pesquisa sobre os trabalhos realizados até então. O critério de aplicação prática dos algoritmos foi fundamentalmente escolher aqueles que se distinguiam por alguma razão. A ideia foi procurar os melhores resultados utilizando abordagens mais distintas possíveis, tirando partida da flexibilidade da Transformada de Wavelet. Neste sentido o trabalho cumpriu com o proposto, na medida em que se conseguiu realçar as imagens utilizando os diferentes métodos e obtendo também resultados distintos.

A remoção de Ruído foi estudada fundamentalmente devido à utilização inicial da base de dados DDSM. Os dois algoritmos apresentados provaram possuir a sensibilidade necessária para aplicação neste tipo de imagens. Os resultados apontam para que a utilização do método FUNDO seja preferível ao método ROBUSTO já que o primeiro obteve melhores resultados para menores quantidades de Ruído e iguais para maiores. De referir que é espectável que a quantidade de ruído numa imagem de mamografia digital direta seja baixa e que tenda a diminuir ainda mais. Portanto de futuro a preferência poderá cair sobre o método FUNDO ou possivelmente nenhum, caso o sistema de aquisição assim o permita, como por exemplo o utilizado para adquirir as imagens DCC. A remoção de ruído nas imagens a processar fará, naturalmente, sentido nos casos deste existir de forma significativa, portanto aconselha-se a utilização de um método de quantificação de ruído como forma de decisão.

Os resultados obtidos indicam que o realce ao qual este trabalho se propôs foi alcançado. Vários métodos foram estudados e aplicados a imagens

com características diferentes de forma a testar a sua robustez. Foi ainda utilizada uma métrica independente de outros algoritmos complexos que poderiam introduzir desvios indesejados nos resultados. Em termos de resultados do realce do contraste, tem de haver um compromisso entre o realce das microcalcificações contra o realce em excesso do ruído. Este compromisso foi alcançado na maioria dos métodos, o único que se pode dizer inferior aos restantes foi o método *Threshold*. No entanto este método será alvo de uma análise mais cuidada pois existe potencial para se obter resultados melhores, nomeadamente pela alteração do cálculo do *threshold* utilizado e pela reformulação da filtragem utilizando coordenadas polares. Métodos de carácter global, tal como o *Simples* e *Cont*, apresentam melhores resultados quando realçando imagens em que o ruído não é significativo. São também interessantes para evidenciar estruturas não cálcicas, o que foge um pouco ao objectivo do trabalho, no entanto fica a referência, pois trata-se de um resultado válido e possivelmente interessante para outros trabalhos. O método *Corr* e *Corr_Locais* obtiveram bons resultados quando se procura realçar unicamente as calcificações não tendo como limitação a perda dos detalhes do fundo. A aplicação conjunta com métodos de remoção de ruído deve ser feita com cuidado ou mesmo evitada, pois estes métodos pressupõem a existência de algum ruído, não conseguindo se adaptar caso ele não exista. O método *Max_Locais*, deverá também ser alvo de uma reformulação, já os resultados foram inferiores aos restantes em termos de ganho em contraste e robustez.

Como trabalho futuro, além de testar as alterações propostas dos algoritmos já apresentados, pretende-se aplicar os algoritmos a uma maior quantidade de dados, tentando processar imagens com características e/ou doenças distintas. A utilização diária deste métodos por parte de um especialista seria importante, pois o feedback por ele dado seria certamente importante. No seguimento deste trabalho existe ainda toda a componente de segmentação e classificação que deverá ser alvo de estudo de forma a conseguir a ferramenta de detecção automática da qual este trabalho faz parte.

Bibliografia

2012

Bibliografia

Bibliografia

- [1] Joseph D. Bronzino, , Joseph D. Bronzino, Ed.: CRC Press, 2000, vol. 1.
- [2] Manali Oak. (2011, Dec.) Importance of Computers in Medicine. [Online].
 HYPERLINK "<http://www.buzzle.com/articles/importance-of-computers-in-medicine.html>"
<http://www.buzzle.com/articles/importance-of-computers-in-medicine.html>
- [3] Rangaraj M. Rangayyan, "A review of computer-aided diagnosis of breast cancer: Toward the detection of subtle signs," *Journal of The Franklin Institute*, pp. 312-348, 2007.
- [4] World Health Organisation. (2008) World Health Organisation Web site. [Online]. HYPERLINK
 "http://www.who.int/gho/ncd/mortality_morbidity/en/index.html"
http://www.who.int/gho/ncd/mortality_morbidity/en/index.html
- [5] International Agency for Research on Cancer (IARC). (2010) Cancer Incidence, Mortality and Prevalence Worldwide in 2008. [Online].
 HYPERLINK "<http://globocan.iarc.fr/>" <http://globocan.iarc.fr/>
- [6] American Cancer Society,. Atlanta: <http://www.cancer.org/>, 2011, pp. 9-17.
- [7] American Cancer Society (website). (2011, April) Breast cancer: Early Detection. [Online]. HYPERLINK
 "http://www.cancer.org/Cancer/BreastCancer/MoreInformation/BreastCancerEarlyDetection/breast-cancer-early-detection-risk-factors-you-cannot-change"
<http://www.cancer.org/Cancer/BreastCancer/MoreInformation/BreastCancerEarlyDetection/breast-cancer-early-detection-risk-factors-you-cannot-change>
- [8] MD Melissa Conrad Stöppler. (2009) Medicinenet. [Online]. HYPERLINK
 "http://www.medicinenet.com/breast/article.htm"
<http://www.medicinenet.com/breast/article.htm>
- [9] Patricia Brady Wilhelm Elaine N. Marieb, "Human Anatomy," in *The*

Bibliografia

- Reproductive System*, Sixth Edition ed.: PEARSON, 2010, pp. 754,755,762,763.
- [10] McGill Faculty of Medicine. (2002) Interactive Mammography Analysis Web Tutorial. [Online]. HYPERLINK
"http://sprojects.mmi.mcgill.ca/mammography/asymmetry.htm"
<http://sprojects.mmi.mcgill.ca/mammography/asymmetry.htm>
- [11] McGill Faculty of Medicine. (2002) Interactive Mammography Analysis Web Tutorial. [Online]. HYPERLINK
"http://sprojects.mmi.mcgill.ca/mammography/masses.htm"
<http://sprojects.mmi.mcgill.ca/mammography/masses.htm>
- [12] BB Kopans, *Breast Imaging*. Philadelphia: J.B. Lippincott Co., 1989. [Online]. HYPERLINK
"http://sprojects.mmi.mcgill.ca/mammography/masses.htm"
<http://sprojects.mmi.mcgill.ca/mammography/masses.htm>
- [13] Harvard Medical School, "Calcium beyond the bones," *Harvard Women's Health Watch*, vol. 17, no. 7, pp. 1-2, March 2010.
- [14] McGill Faculty of Medicine. (2002) Interactive Mammography Analysis Web Tutorial. [Online]. HYPERLINK
"http://sprojects.mmi.mcgill.ca/mammography/calcifications.htm"
<http://sprojects.mmi.mcgill.ca/mammography/calcifications.htm>
- [15] Robin Smithuis and Ruud Pijnappel. (2008, Maio) Breast Calcifications - Differential diagnosis and BIRADS. [Online]. HYPERLINK
"http://www.radiologyassistant.nl/images/thmb_47e6b7d6aafbaTEK-distribution2.png"
http://www.radiologyassistant.nl/images/thmb_47e6b7d6aafbaTEK-distribution2.png
- [16] UMM. (2008, Maio) All-Digital Mammography. [Online]. HYPERLINK
"http://www.umm.edu/breastcenter/digital_mammography.htm"
http://www.umm.edu/breastcenter/digital_mammography.htm
- [17] Radiologyinfo.org, "Radiation Exposure in X-ray and CT Examinations," Radiological Society of North America, 2012.

- [18] Saravanan Subramanian. (2010, Feb.) Introduction to the DICOM Standard (using OsiriX). [Online]. HYPERLINK "http://www.saravanansubramanian.com/Saravanan/Articles_On_Software/Entries/2010/2/10_Introduction_to_the_DICOM_Standard.html" http://www.saravanansubramanian.com/Saravanan/Articles_On_Software/Entries/2010/2/10_Introduction_to_the_DICOM_Standard.html
- [19] Damian Brunold. DICOM PS 3.1 2008 - Introduction and Overview. [Online]. HYPERLINK "http://www.dabsoft.ch/dicom/1/" <http://www.dabsoft.ch/dicom/1/>
- [20] Harmien Zonderland. (2006) BI-RADS Introduction to the Breast Imaging Reporting and Data System. [Online]. HYPERLINK "http://www.radiologyassistant.nl/en/4349108442109" <http://www.radiologyassistant.nl/en/4349108442109>
- [21] BI-RADS®, "BI-RADS® ATLAS and MQSA: FAQs," The American College of Radiology, 2011.
- [22] Kunio Doi, "Computer-aided diagnosis in medical imaging: Historical review, current status and future potential," *Computerized Medical Imaging and Graphics*, vol. 31, pp. 198-211, 2007.
- [23] Paulo Cupertino de Lima, "Wavelets: uma introdução," Departamento de Matemática, ICES - UFMG, 2003.
- [24] Hélio Magalhães de Oliveira, *Análise de Fourier e Wavelets: Sinais Estacionários e não Estacionários*. Recife: Editora Universitária da UFPE, 2007.
- [25] Hélio Magalhães de Oliveira, *Análise de Sinais para Engenheiros - Uma Abordagem Via WAVELETS*, Sergio Oliveira, Ed. Rio de Janeiro, Brasil: BRASPORT, 2007.
- [26] C. Sidney Burrus, Ramesh A. Gopinath, and Haitao Guo, *Introduction to Wavelets and Wavelet Transforms - A Primer*. Houston, Texas: Prentice Hall, 1998.
- [27] Jean-Luc Starck, "Image processing and data analysis - The multiscale approach," Centre d'Études de Saclay,.

- [28] Elsa Angelini, Andrew Laine Yinpeng Jin, "Wavelets in Medical Image Processing: De-noising, Segmentation and Registration," Department of Biomedical Engineering, Columbia University, New York, NY, USA, 2005.
- [29] PYWAVELETS. (2008) WAVELET BROWSER BY PYWAVELETS. [Online]. HYPERLINK "http://wavelets.pybytes.com/"
<http://wavelets.pybytes.com/>
- [30] Stephane G. Mallat, "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation," *Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674-693, July 1989.
- [31] Nash Borges V. Balakrishnan, "Wavelet Denoising and Speech Enhancement," Department of Electrical and Computer Engineering, The Johns Hopkins University, Baltimore, 2005.
- [32] Ronald A. DeVore Antonin Chambolle, "Nonlinear Wavelet Image Processing: Variational Problems, Compression, and Noise Removal through Wavelet Shrinkage," *Transactions on Image Processing*, vol. 7, no. 3, pp. 319-335, 1998.
- [33] Ali Zifan and Mohammad Hassan Moradi, "Microarray image enhancement by denoising using decimated and undecimated multiwavelet transforms," *SIViP*, pp. 177-185, February 2009.
- [34] Du-Yih Tsai and Yongbum Lee, "A Method of medical Image Enhancement Using Wavelet-Coefficient Mapping Functions," in *Int Conf Neural Networks & Signal Processing*, Nanjing, 2003, pp. 14-17.
- [35] Yi Wan and Dongbin Shi, "Joint Exact Histogram Specification and Image Enhancement Through the Wavelet Transform," *Transaction on Image Processing*, vol. 16, pp. 2245-2250, September 2007.
- [36] Li Jin, Wang Yan Wei, and Wang Lei, "Industrial X-Ray Image Enhancement Algorithm based on Adaptive Histogram and Wavelet," in *The 6th International Forum on Strategic Technology*, 2011.
- [37] Eugene lai Ching-Tang Hsieh, "An Effective algorithm for fingerprint image enhancement based on wavelet transform," *PATTERN RECOGNITION*, vol. 36, pp. 303-312, 2003.

- [38] G. Ram, "Optimization of ionizing radiation usage in medical imaging by means of image enhancement techniques," *Med. Phys.*, pp. 733-737, 1982.
- [39] Jinshan Tang and Rangaraj M. Rangayyan, "Computer-Aided Detection and Diagnosis of Breast Cancer With Mammography: Recent Advances," *Transactions on Information Technology in Biomedicine*, vol. 13, no. 2, pp. 236-251, March 2009.
- [40] H.D. Cheng and Huijuan Xu, "A novel fuzzy logic approach to mammogram contrast enhancement," *Information Sciences*, vol. 148, pp. 167-184, 2002.
- [41] Huai Li, K. J. Ray Liu, and Yue Wang, "Nonlinear Filtering enhancement and histogram modeling segmentation of masses for Digital Mammograms," in *18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Amsterdam, 1996, pp. 1045-1046.
- [42] Yicong Zhou, "Mammogram Enhancement Using Alpha Weighted Quadratic Filter," in *31st Annual International Conference of the IEEE EMBS*, Minnesota, 2009, pp. 3681-3684.
- [43] Karen Panetta and Yicong Zhou, "Nonlinear Unsharp Masking for Mammogram Enhancement," *Transactions on Information Technology in Biomedicine*, vol. 15, no. 6, pp. 918-928, November 2011.
- [44] Maria Rizzi and Matteo D'Aloia, "Computer aided detection of microcalcifications in digital mammograms adopting a wavelet decomposition," *Integrated Computer-Aided Engineering*, vol. 16, pp. 91-103, 2009.
- [45] A. Papadopoulos, "Improvement of microcalcification cluster detection in mammography utilizing image enhancement techniques," *Computers in Biology and Medicine*, vol. 38, pp. 1045-1055, 2008.
- [46] Amutha S and D.R. Ramesh Babu, "Mammographic Image Enhancement using Modified Mathematical Morphology and Bi-Orthogonal Wavelet," Dept. of CSE, DSCE, Bengaluru, 2011.
- [47] Arianna Mencattini, "Mammographic Images Enhancement and

Bibliografia

- Denoising for Breast Cancer Detection Using Dyadic Wavelet Processing," *Transactions on Instrumentation and Measurement*, vol. 57, no. 7, pp. 1422-1430, July 2008.
- [48] Hong-Dun Lin, "Statistical-Based Sub-Bnad Filtering Technique for Digital Mammogram Enhancement," *Biomedical Engineering-Applications, Basis & Communications*, vol. 15, pp. 150-156, August 2003.
- [49] Nguyen N. Thanh Ho-Kyung Kang, "Robust Contrast Enhancement for Microcalcification in Mammography," Department of Biomedical Engineering, KonKuk University, Korea,.
- [50] Lulin Chen, "Adaptive feature enhancement for mammographic images with wavelet multiresolution analysis," *Journal of Electronic Imaging*, pp. 467-478, Outubro 1997.
- [51] P Sakellaropoulos and L Costaridou, "A wavelet-based spatially adaptive method for mammographic contrast enhancement," *Physics in Medicine and Biology*, vol. 48, pp. 787-803, March 2003.
- [52] Michael Heath. (2000, Agosto) Mammography software by Michael Heath. [Online]. HYPERLINK
"http://marathon.csee.usf.edu/Mammography/software/heathusf_v1.1.0.html"
http://marathon.csee.usf.edu/Mammography/software/heathusf_v1.1.0.html
- [53] S.Grace Chang and Bin Yu, "Spatially Adaptive Wavelet Thresholding with Context Modeling for Image Denoising," *TRANSACTIONS ON IMAGE PROCESSING*, vol. 9, no. 9, pp. 1522-1531, September 2000.
- [54] Andrew F.Laine and Sergio Schuler, "Mammographic Feature Enhancement by Multiscale Analysis," *Transaction on Medical Imaging*, vol. 13, no. 4, pp. 725-740, December 1994.
- [55] S. Kakouros H. Stepanou, "Wavelet-based Mammographic Enhancement," Department of Computer Science, University of Crete, Greece, Crete, 2005.
- [56] Jinshan Tang and Qingling Sun, "An Image Enhancement Algorithm Based

on a Contrast Measure in the Wavelet Domain for Screening Mammograms," *ICIP 2007*, pp. 29-32, 2007.