

**UNIVERSIDADE ESTADUAL DO MARANHÃO
CENTRO DE CIÊNCIAS TECNOLÓGICAS
CURSO DE ENGENHARIA DE COMPUTAÇÃO**

STHEPHANE SILVA CORREA

**ESTUDO DE TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS BASEADAS EM
EXTRAÇÃO DE ATRIBUTOS DE TEXTURA**

**São Luís - MA
2017**

STEPHANE SILVA CORREA

**ESTUDO DE TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS BASEADAS EM
EXTRAÇÃO DE ATRIBUTOS DE TEXTURA**

Monografia apresentada ao Curso de Engenharia de Computação da Universidade Estadual do Maranhão, como registro para obtenção do grau de Bacharel em Engenharia de Computação.

Orientador: Dr. Lúcio Flávio de Albuquerque Campos

**São Luís - MA
2017**

Correa, Sthephane Silva

Estudo de técnicas de segmentação de imagens baseadas em extração de atributos de textura / Sthephane Silva Correa. – São Luís, 2017.

71 f.

Monografia (Graduação) – Curso de Engenharia da Computação, Universidade Estadual do Maranhão, 2017.

Orientador: Prof. Dr. Lúcio Flavio de Albuquerque Campos

1. Segmentação. 2. Textura. 3. K-means. 4. Filtros de Gabor. 5. Análise de Componentes Independentes. I. Título.

CDU:004.932.1:621.397

STHEPHANE SILVA CORREA

**ESTUDO DE TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS BASEADAS EM
EXTRAÇÃO DE ATRIBUTOS DE TEXTURA**

Monografia apresentada ao Curso de Engenharia de Computação da Universidade Estadual do Maranhão, como registro para obtenção do grau de Bacharel em Engenharia de Computação.

Trabalho aprovado.
São Luís - MA, 30 de janeiro de 2017.

**Dr. Lúcio Flávio de Albuquerque
Campos**
Orientador

Dr. Reinaldo de Jesus da Silva
Primeiro membro

Dr. Luís Carlos Costa Fonseca
Segundo membro

Dedicatória

Aos meus queridos e amados pais, que sempre acreditaram e investiram em mim; e com muito amor, incentivo e apoio, não mediram esforços para que eu concluísse mais uma linda e importante etapa na minha vida.

Agradecimentos

À Deus, por ter estado ao meu lado em todos os momentos, me sustentando e dando sabedoria para a conclusão deste trabalho.

Aos meus pais Walton e Nonalva, por terem me dado toda a educação e apoio necessários para que eu pudesse alcançar mais um objetivo na minha vida.

Às minhas irmãs Nicolly e Vitória, pelo companheirismo nesse e em tantos outros momentos da minha vida assim como à minha querida tia Lourdirene, pelo carinho e por participar da minha vida, sempre me apoiando nos estudos.

Aos professores, pelas discussões e idéias, fundamentais para a concepção do meu conhecimento na minha formação e na minha vida. Em especial ao professor Reinaldo, pela confiança depositada em mim durante minha vida acadêmica, meu projeto de iniciação científica e meu estágio e ao professor Lúcio, por toda sua disposição e orientação, além de comprometimento para o desenvolvimento deste trabalho.

Aos amigos que fiz até hoje através do colégio, da igreja, dança, universidade ou vida, pelos momentos de alegria dados por suas presenças em minha vida, pelos ensinamentos e conselhos em algum momento da minha história: levo comigo um pouco de cada um dentro de mim. Em especial quero agradecer aos meus amigos Joel e Paulo Gustavo por sempre terem acreditado no meu potencial e estarem ao meu lado me dando forças nessa reta final da minha graduação.

Por último, mas não menos importante, a todas as pessoas que contribuíram direta ou indiretamente para a minha formação acadêmica e pessoal, ou torcem por mim de alguma forma, meu *muito obrigado!*

"Nas grandes batalhas da vida, o primeiro passo para a vitória é o desejo de vencer."
(Mahatma Gandhi)

Resumo

A segmentação de imagens é um dos passos na tentativa de aproximar a Visão Computacional do Sistema Visual Humano pois a capacidade humana de extrair informações visuais de um objeto ou de uma cena é algo que, apesar dos inúmeros avanços na área de Visão Computacional, ainda não foi completamente repassado para os computadores. Já a textura é uma fonte importante de informações e constitui um dos principais atributos visuais presentes em uma imagem, sendo capaz de distinguir regiões e contribuir para o procedimento de segmentação. Entretanto, comparar duas ou mais regiões e definir sua semelhança é um dos grandes obstáculos no processo de análise e segmentação de imagens, logo, para ajudar a superar este obstáculo, faz-se necessário o uso de técnicas capazes de analisar os atributos das imagens e, através dessa análise, definir o quão parecidas são as regiões. Sendo assim, este trabalho tem como objetivo, realizar um estudo para definir as melhores técnicas para segmentar as regiões de interesse nas imagens a partir dos seus atributos de texturas, sendo aplicado três métodos para tal finalidade: o algoritmo clássico de segmentação chamado *K-means*, os Filtros de Gabor e a técnica de Análise de Componentes Independentes. Neste trabalho, também são apresentados os resultados, obtidos da aplicação desses métodos nas imagens compostas por texturas obtidas do álbum de Brodatz, e a análise comparativa entre essas técnicas que, geralmente, são apontadas pela comunidade científica como as mais usadas na área de segmentação de imagens. Como resultado, tem-se imagens segmentadas constatando a Análise de Componentes Independentes como o melhor método para segmentação de texturas em relação aos outros estudados nessa pesquisa, apresentando ótimos resultados analíticos e baixos índices de erros.

Palavras-chave: Segmentação. Textura. *K-means*. Filtros de Gabor. Análise de Componentes Independentes.

Abstract

The segmentation of images is one of the steps in the attempt to approximate the Computational Vision to the Human Visual System because the human capacity to extract visual information from an object or a scene is something that, despite the numerous advances in the field of Computer Vision, has not yet been completely passed on to computers. The texture is an important source of information and one of the main visual attributes present in an image, being able to distinguish regions and contribute to the procedure of segmentation. However, comparing two or more regions and defining their similarity is one of the major obstacles in the process of image analysis and segmentation, therefore, in order to help overcome this obstacle, it is necessary to use techniques capable of analyzing the attributes of the images and, through this analysis, define how similar the regions are. Thus, this work aims to perform a study to define the best technique to segment the regions of interest in the images from their texture attributes, and three methods are applied for this purpose: the classic segmentation algorithm called K-means, Gabor Filters the Independent Component Analysis technique. In this work, we also present the results, obtained from the application of these methods in the images composed by textures, obtained from the Brodatz album, and the comparative analysis between these techniques, which are generally pointed out by the scientific community as the most used in the area of image segmentation. As a result, we have segmented images showing Independent Component Analysis as the best method for segmenting textures in relation to the others studied in this research, presenting excellent analytical results and low error rates.

Keywords: *Segmentation. Texture. K-means. Gabor Filters. Independent Component Analysis.*

Lista de ilustrações

Figura 1 – Exemplo de uma imagem digitalizada	21
Figura 2 – Exemplo de uma imagem binária	23
Figura 3 – Exemplo de uma imagem em tons de cinza	24
Figura 4 – Exemplo de uma imagem colorida	25
Figura 5 – Exemplo da conectividade entre <i>pixels</i>	26
Figura 6 – Exemplo de histogramas	27
Figura 7 – Etapas típicas envolvidas no processamento de imagens	29
Figura 8 – Processo de segmentação de uma imagem digital	31
Figura 9 – Exemplos de texturas	33
Figura 10 – Exemplo de execução do algoritmo <i>K-Means</i>	35
Figura 11 – Exemplo de variação no valor de λ	37
Figura 12 – Exemplo de variação no valor de θ	37
Figura 13 – Exemplo de variação no valor de σ	38
Figura 14 – Exemplo de variação no valor de γ	38
Figura 15 – Modelo de mistura na análise de componentes independentes	40
Figura 16 – Distribuição de duas variáveis gaussianas independentes	41
Figura 17 – Fluxograma das etapas realizadas na pesquisa	42
Figura 18 – Banco de imagens utilizadas na pesquisa	44
Figura 19 – Programa utilizado para o pré-tratamento das imagens	45
Figura 20 – Tela inicial do MATLAB	46
Figura 21 – Configurações da máquina utilizada para execução dos testes	46
Figura 22 – Mosaico formado por 4 texturas distintas	47
Figura 23 – Mosaico formado por 5 texturas distintas	47
Figura 24 – Ilustração do algoritmo ICA no editor do MATLAB	49
Figura 25 – Ilustração do algoritmo <i>K-means</i> no editor do MATLAB	49
Figura 26 – Ilustração do algoritmo de Gabor no editor do MATLAB	50
Figura 27 – Objetivo da segmentação de texturas	51
Figura 28 – Resultado 1 (Gabor)	52
Figura 29 – Resultado 2 (Gabor)	52
Figura 30 – Resultado 3 (Gabor)	52
Figura 31 – Resultado 4 (Gabor)	52
Figura 32 – Resultado 5 (<i>K-means</i>)	52
Figura 33 – Resultado 6 (<i>K-means</i>)	52
Figura 34 – Resultado 7 (<i>K-means</i>)	53
Figura 35 – Resultado 8 (<i>K-means</i>)	53
Figura 36 – Resultado 9 (ICA)	53

Figura 37 – Resultado 10 (ICA)	53
Figura 38 – Resultado 11 (ICA)	53
Figura 39 – Resultado 12 (ICA)	53
Figura 40 – Resultado 13 (Gabor)	54
Figura 41 – Resultado 14 (Gabor)	54
Figura 42 – Resultado 15 (Gabor)	54
Figura 43 – Resultado 16 (Gabor)	54
Figura 44 – Resultado 17 (<i>K-means</i>)	54
Figura 45 – Resultado 18 (<i>K-means</i>)	54
Figura 46 – Resultado 19 (<i>K-means</i>)	55
Figura 47 – Resultado 20 (<i>K-means</i>)	55
Figura 48 – Resultado 21 (ICA)	55
Figura 49 – Resultado 22 (ICA)	55
Figura 50 – Resultado 23 (ICA)	55
Figura 51 – Resultado 24 (ICA)	55
Figura 52 – Resultado da segmentação com <i>K-means</i> em 4 texturas distintas	57
Figura 53 – Resultado da segmentação com <i>K-means</i> em 5 texturas distintas	57
Figura 54 – Resultado da segmentação com Gabor em 4 texturas distintas	58
Figura 55 – Resultado da segmentação com Gabor em 5 texturas distintas	58
Figura 56 – Resultado da segmentação com ICA em 4 texturas distintas	59
Figura 57 – Resultado da segmentação com ICA em 5 texturas distintas	59

Lista de tabelas

Tabela 1 – Síntese do processo	50
--	----

Lista de abreviaturas e siglas

2D	Segunda dimensão
3D	Terceira dimensão
BIT	Do inglês, <i>Binary Digit</i> - Dígito binário
BYTE	Do inglês, <i>Binary Term</i> - Tipo de dado integral em computação
CMY	Do inglês, <i>Cyan, Magenta e Yellow</i> - Modelo de cores secundárias
ICA	Do inglês, <i>Independent Component Analysis</i> - Técnica de segmentação
MATLAB	Do inglês, <i>Matrix Laboratory</i> - Ambiente computacional
RGB	Do inglês, <i>Red, Green e Blue</i> - Modelo de cores primárias
ROI	Do inglês, <i>Region of Interest</i> - Região de interesse da imagem
SVH	Sistema Visual Humano

Lista de símbolos

∞	Número infinito
λ	Comprimento de onda
θ	Ângulo de inclinação
σ	Largura da gaussiana
γ	Excentricidade do núcleo de Gabor

Sumário

1	INTRODUÇÃO	16
1.1	Considerações Iniciais	16
1.2	Motivação	18
1.3	Trabalhos Correlatos	19
1.4	Objetivos	19
1.4.1	Objetivo Geral	19
1.4.2	Objetivos Específicos	20
1.5	Organização do Trabalho	20
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Imagem Digital	21
2.1.1	Tipos de Imagem Digital	22
2.1.1.1	Imagens binárias	22
2.1.1.2	Imagens em tons de cinza	23
2.1.1.3	Imagens coloridas	24
2.1.2	Propriedades da Imagem Digital	25
2.1.2.1	Medidas de distância	25
2.1.2.2	Conectividade	26
2.1.2.3	Histograma da Imagem	26
2.2	Processamento de Imagens	27
2.3	Segmentação de Imagens	29
2.4	Atributos da Imagem	32
2.5	Técnicas de Segmentação	33
2.5.1	<i>K-means</i>	34
2.5.2	Filtros de Gabor	36
2.5.3	Análise de Componentes Independentes	39
2.5.3.1	Pressuposições	41
3	METODOLOGIA	42
3.1	Etapas do processo	43
3.1.1	Levantamento bibliográfico	43
3.1.2	Aquisição e seleção das imagens	43
3.1.3	Ferramentas de softwares utilizadas	44
3.1.4	Pré-tratamento da imagem	47
3.1.5	Aplicação dos métodos de segmentação	48
3.2	Síntese do Processo	50
4	RESULTADOS E DISCUSSÕES	51

4.1	Apresentação dos Resultados	51
4.2	Discussão dos Resultados	56
4.2.1	<i>K-means</i>	56
4.2.2	Filtros de Gabor	57
4.2.3	Análise de Componentes Independentes	58
5	CONCLUSÃO	60
5.1	Trabalhos futuros	61
	Referências	63
	APÊNDICE A – Imagens criadas e utilizadas na segmentação	68

1 INTRODUÇÃO

1.1 Considerações Iniciais

O Sistema Visual Humano é um dos mais importantes, senão o mais importante sistema de percepção do mundo exterior (PARKER, 1997). Um sistema de visão, isto é, um sistema que deve responder a todas as situações, como é o caso do SVH, é extremamente desenvolvido e complexo. O interesse em se compreender um tal sistema é fundamentalmente de orientar a pesquisa de uma máquina de reconhecimento genérica com as mesmas características do SVH. Atualmente algumas correntes científicas consideram o cérebro humano uma máquina com grande capacidade de explorar as informações sensoriais. Filosoficamente não se pretende, com estas linhas de pesquisas, retirar as qualidades humanas associadas ao cérebro ou aos homens. Mas devemos atentar para alguns pontos fundamentais: os computadores atuais são extremamente eficientes para trabalharem com base de dados, cálculos numéricos e formais, mas eles não conseguem realizar eficientemente algumas tarefas “simples” realizadas por animais e seres humanos. Eles são na prática, sistemas experimentais que nos ajudam a melhor compreender estas tarefas e conseqüentemente modelizá-las e reproduzi-las (ALBUQUERQUE; ALBUQUERQUE, 2001).

Segundo Wangenheim (2001), a Visão Computacional é “o conjunto de métodos e técnicas através dos quais sistemas computacionais podem ser capazes de interpretar imagens”. Para Wangenheim (2001), em Visão Computacional “não existe nenhum modelo genérico de percepção visual passível de ser aplicado na prática”. Na prática, o que ocorre é utilizar um conjunto de algoritmos bastante específicos na tarefa de interpretação de imagens, que são responsáveis por realizar subtarefas bastante limitadas dentro do processo de interpretação de imagens. O autor afirma ainda que os algoritmos são divididos em grupos, como: filtros de contraste, detectores de bordas, segmentadores de imagens em grupos, classificadores de texturas, dentre outras.

Atualmente, diversos campos da atividade humana têm recorrido às imagens para armazenar, exibir e fornecer informações sobre o mundo que nos rodeia. O desafio que fica para os pesquisadores, engenheiros e empresários, é extrair rapidamente informação valiosa a partir de dados brutos de imagens. Este é o objetivo primário do processamento de imagens, ou seja, converter imagens em informação. De forma geral, funções de processamento que incluam reconhecimento e interpretação estão associadas com aplicações de análise de imagens nas quais o objetivo é a extração automática – ou mesmo parcialmente automática – de informação a partir de uma imagem (GONZALEZ; WOODS, 1992). Logo, a Visão Computacional para solução de determinados problemas, aplica uma etapa sequenciada de procedimentos que são: aquisição da imagem, pré-processamento, segmentação, identificação do objeto e reconhecimento de padrões (MONGELO, 2012).

Segundo Mongelo (2012), as etapas citadas são "independentes e não se trata de uma regra para cada tipo de aplicação".

Uma questão central na extração de informações a partir de uma imagem digital é a redução das informações dessa imagem em regiões mais ou menos homogêneas, visando permitir uma análise mais apropriada da imagem. Isto consiste o problema da segmentação, e têm dado origem ao desenvolvimento de várias soluções. No início do século, os psicólogos alemães Knhler, Wertheimer e Kofftka introduziram o princípio da segmentação de imagens. Eles mostraram que o ser humano, ao nível da visão, efetua agrupamentos sobre o que ele percebe, baseados sobre a proximidade, a similaridade, e a continuidade (FACON, 2002). Em sistemas computacionais, um enorme esforço tem sido feito para aproximar sistemas artificiais do sistema visual humano. Como parte do processo de computação visual, a segmentação automática de imagens subdivide objetos ou regiões de imagem destacando-os do restante, ou seja, a segmentação assume que os *pixels* se organizam em grupos "semelhantes", e que esses grupos correspondem a classes. Outra forma de abordar a segmentação de imagem é caracterizar objetos de acordo com a sua textura. A textura é uma propriedade de uma determinada região da imagem, suficientemente grande para demonstrar sua natureza (PARKER, 1997). A textura depende do ponto de vista do observador, uma folha pode ser considerada um objeto, mas a folhagem de uma árvore pode ser vista como uma textura (FORSYTH; PONCE, 2002).

Métodos utilizando atributos de textura no processo de classificação de imagens, vem sendo objeto de estudo por vários pesquisadores. Uma visão bastante geral do atributo textura pode ser encontrada em Haralick (1979). Progressos recentes na área de tecnologia de computadores, tornaram possível a utilização prática de outros processos que até então tinham um interesse apenas teórico, por requererem um tempo computacional demasiadamente elevado. A textura possui um papel central na percepção humana, provendo dados para reconhecimento e interpretação e por isso é uma importante característica para a análise de imagens digitais. Em algumas tarefas de visão computacional, como inspeção de superfícies, classificação de cenas e determinação de formas, existe uma forte dependência da correta extração e compreensão das informações da textura. Em imagens digitais, a caracterização de uma textura pode ser percebida através de variações das intensidades ou cores capturadas e, embora não há informação quanto à causa das variações, as diferenças existentes nos *pixels* da imagem fornecem meios práticos de analisar as propriedades das texturas de um objeto. Apesar de ser uma propriedade importante, não há um consenso na descrição do que é, exatamente, uma textura (NASCIMENTO, 2010).

A textura é um aspecto que esta presente na maioria das imagens naturais, sendo fundamental para o reconhecimento pela visão humana, contribuindo, em muitos casos, na melhoria da exatidão do processo de reconhecimento, descrição e classificação de imagens. Mas na análise de imagens digitais, o reconhecimento de texturas, realizado intuitivamente pela visão humana, se reveste de grande complexidade. Para Faugeras e Pratt (1980),

textura é um “padrão local básico que é periodicamente ou quase periodicamente repetido em alguma área”. De forma semelhante, Jain, Murty e Flynn (1999) afirmam que "textura não é caracterizada apenas pela cor do *pixel*, mas também pelo padrão encontrado nos *pixels* que o cercam". Em casos em que o padrão é uma textura e não um objeto, ou ainda quando a textura do objeto é uma característica relevante para o seu reconhecimento, deve-se utilizar técnicas especiais de extração de características que permitam realizar o reconhecimento de texturas.

Embora existam inúmeras técnicas para solucionar os problemas de segmentação de texturas, as abordagens utilizadas neste trabalho foram: *K-means*, Filtro de Gabor e Análise de Componentes Independentes. Um dos algoritmos desenvolvidos para resolver o problema da segmentação de imagens é o *K-means*, também chamado de K-médias. A idéia do algoritmo é fornecer uma classificação de informações de acordo com os próprios dados, baseada em análises e comparações entre os seus valores numéricos (KOLOSSOSKI, 2007). Os Filtros de Gabor, por sua vez, são um conjunto de funções senoidais complexas e bidimensionais, que apresentam certas propriedades extremamente úteis para fins de classificação de imagens (BELUCO; ENGEL, 2003). Já em relação a técnica ICA, na literatura são encontradas várias definições de acordo com o modelo e aplicação a ser utilizada. De uma forma geral, pode-se dizer que a Análise de Componentes Independentes é um método matemático que procura determinar fatores ou componentes a partir de dados estatísticos multivariáveis. O que diferencia de outros métodos é que este método trata componentes estatisticamente independentes e não gaussianos. A independência entre os componentes implica que o valor de um componente não fornece nenhuma informação com relação a outros componentes (LEITE, 2004).

É nesse sentido que este trabalho foi desenvolvido. Primeiramente, se faz um estudo das características da imagem digital juntamente com as suas propriedades. Em seguida, é feito um estudo sobre as técnicas de segmentação de imagens percorridas no trabalho e, por fim, é apresentada a metodologia do processo juntamente com os resultados obtidos e a conclusão da pesquisa.

1.2 Motivação

A análise e segmentação de texturas possuem diversas aplicações, variando desde aplicações médicas até a classificação de plantas. Uma dessas aplicações médicas, por exemplo, visa detectar tumores em mamografias, melhorando a resposta do diagnóstico auxiliado por computador (MELLO; MASCARO, 2006). Em outra aplicação, desta vez na área de automação industrial, a análise de texturas é usada pra detectar automaticamente defeitos de fabricação e arranhões em peças de couro (LOVERGINE et al., 1997).

Dentro desta abordagem, este trabalho tem como motivo apresentar uma discussão a respeito de alguns fatores considerados relevantes para a conceituação e fundamentação da segmentação, bem como, realizar uma breve revisão dos algoritmos mais utilizados na

segmentação de imagens, executá-los e apresentar resultados que reforcem os conceitos estudados. Além desses fatores, essa pesquisa apresenta uma contribuição na área científica e acadêmica, realizando um enfoque na análise de um problema e possíveis soluções que podem ser utilizadas em outras situações do dia-a-dia.

1.3 Trabalhos Correlatos

O estudo relacionado à segmentação de texturas já se estende por mais de cinco décadas, entretanto, continua sendo tópico de enorme interesse (JULEZ, 1962). As pesquisas são motivadas em parte pela grande quantidade de texturas presentes em imagens e pela eficiência do Sistema Visual Humano em detectá-las e diferenciá-las. Na literatura, encontram-se vários trabalhos relacionados com a segmentação de texturas. Kruizinga e Petkov (1998) usaram a saída dos operadores de textura modificados biologicamente como características de textura e fizeram a comparação com as matrizes de concorrência e a energia de Gabor, que são as características de texturas mais usadas. A comparação foi feita com um método quantitativo, baseado no critério de Fisher. Junto com os resultados de classificação dos experimentos, a comparação mostrou a superioridade do novo operador para problemas de textura orientada.

Cruz (1998) apresentou uma nova metodologia para a segmentação de texturas. A metodologia é baseada nas características estatísticas de alta ordem (matriz de concorrência e momentos), técnicas de fusão de dados e o método de verossimilhança para encontrar clusters. As características isoladas, matriz de concorrência e momentos, tiveram sempre os mesmos resultados (87.88% e 87.87% respectivamente). Já as técnicas de fusão de dados aumentaram em 12% a performance em relação às técnicas isoladas. Mais recentemente, Zizzari et al. (2001) fez uso de texturas estatísticas, acompanhadas ou não de outras características, para análise e discriminação entre tecidos cerebrais saudáveis e tumor. Existe também cada vez mais uma tendência para unir diferentes técnicas. Metodologias híbridas têm ganhado atenção especial devido à sua habilidade para produzir resultados mais precisos, além de conseguir processar imagens mais complexas (DOKUR; OLMEZ, 2002). Logo, o presente trabalho propõe contribuir com os trabalhos supracitados uma vez que analisa outros métodos de segmentação de texturas, reforçando assim, a importância desse trabalho nessa área.

1.4 Objetivos

A seguir, são descritos os objetivos gerais e específicos da presente pesquisa monográfica.

1.4.1 Objetivo Geral

O objetivo central do trabalho proposto é realizar um estudo sobre técnicas de segmentação de imagens utilizando três métodos, sendo eles, o *K-means*, Filtro de Gabor

e Análise de Componentes Independentes, e fazer uma análise comparativa a partir dos resultados obtidos.

1.4.2 Objetivos Específicos

1. Fazer levantamento bibliográfico sobre as técnicas de segmentação;
2. Executar os algoritmos de segmentação de imagens, selecionados de acordo com sua aplicabilidade, em um banco de imagens previamente escolhido;
3. Segmentar e comparar imagens de acordo com seus atributos de textura;
4. Fazer uma análise de todos os resultados e, conseqüentemente, definir qual o melhor método para segmentação das imagens.

1.5 Organização do Trabalho

Esta pesquisa está organizada em 5 capítulos os quais, são dispostos da seguinte maneira, a saber:

- O **Capítulo 1** discorre sobre as considerações iniciais e o contexto no qual este trabalho está inserido, bem como a motivação que impulsionou seu desenvolvimento, os trabalhos correlatos, os objetivos geral e específicos que nortearam esse trabalho e por fim como esse trabalho foi organizado;
- O **Capítulo 2** traz alguns conceitos sobre a imagem digital e suas propriedades, mostra sobre as etapas do processamento de imagens, traz uma revisão bibliográfica na área de extração de atributos, mais especificamente sobre textura e sua importância na área de segmentação, além dos princípios gerais dos algoritmos usados nesse trabalho, que foram o *K-means*, Filtro de Gabor e a Análise de Componentes Independentes;
- O **Capítulo 3** descreve o método proposto, cuja idéia é a extração de atributos de textura das imagens, utilizando algoritmos para a segmentação, bem como a exibição da origem das imagens usadas e as ferramentas de trabalho para execução dos algoritmos e realização dos testes;
- O **Capítulo 4** apresenta os resultados finais obtidos bem como as discussões e análises realizadas durante o desenvolvimento do trabalho monográfico;
- O **Capítulo 5** finaliza essa pesquisa com as conclusões sobre os resultados obtidos, analisando as perspectivas de melhoria e extensão do método proposto.

Ao final, encontra-se o Apêndice, onde estão as imagens utilizadas no processo de segmentação neste trabalho.

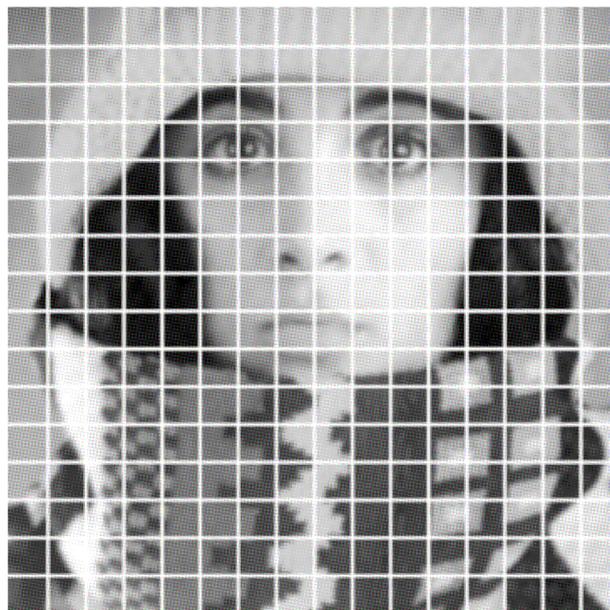
2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo discorre sobre a imagem digital e os tipos de imagens digitais, além de citar as etapas do processamento de imagens. Também é mencionado sobre a segmentação de imagens bem como seu objetivo e suas características. Em seguida, caracteriza-se a textura, destacando seus conceitos fundamentais e a importância dela na extração de características. Para finalizar, algumas concepções acerca da segmentação supervisionada e não supervisionada são definidas, assim como os algoritmos utilizados para obtenção da segmentação de imagens.

2.1 Imagem Digital

Uma imagem digital é uma matriz bidimensional onde os pontos de intersecção da matriz são chamados de *pixels* - uma abreviação de *picture element* que significa elemento de uma imagem (SCURI, 2002). O *pixel* é a menor parte de uma imagem digital e cada um destes pontos contém informações que determinam suas características. Ele é um elemento discreto e de tamanho finito, usado como unidade de medida para descrever a dimensão geométrica de uma imagem, ou seja, quanto mais *pixels* por polegada tiver uma imagem, melhor será a sua qualidade ou resolução. A imagem mostrada na Figura 1 foi dividida em $n = 16$ linhas e $m = 16$ colunas. O valor atribuído a cada *pixel* é o brilho médio no *pixel* arredondado para o valor inteiro mais próximo.

Figura 1: Exemplo de uma imagem digitalizada



Fonte: (BILLERBECK, 2014)

Segundo Gonzalez e Woods (2000), uma imagem digital é uma imagem $f(x, y)$ discretizada (fragmentada) tanto em coordenadas espaciais quanto em brilho, ou seja, é uma matriz cujos índices de linhas e colunas identificam um ponto na imagem e o valor correspondente do elemento da matriz identifica sua intensidade. De acordo com Marques e Vieira (1999), a função $f(x, y)$ é definida como sendo o produto da iteração entre a iluminância $i(x, y)$ - que exprime a quantidade de luz que incide sobre o objeto - e as propriedades de refletância próprias do objeto, que podem ser representadas pela função $r(x, y)$, cujo valor exprime a fração de luz incidente que o objeto vai transmitir ou refletir ao ponto (x, y) .

Matematicamente, temos que:

$$f(x, y) = i(x, y) * r(x, y) \quad (2.1)$$

Onde: $i(x, y)$ depende da fonte de luz, ($0 < i(x, y) < \infty$) e $r(x, y)$ depende do tipo de material que compõe o objeto, ($0 \leq r(x, y) \leq 1$). Verifica-se que $r(x, y)$ assume o valor 0 para absorção total e o valor 1 para reflexão total.

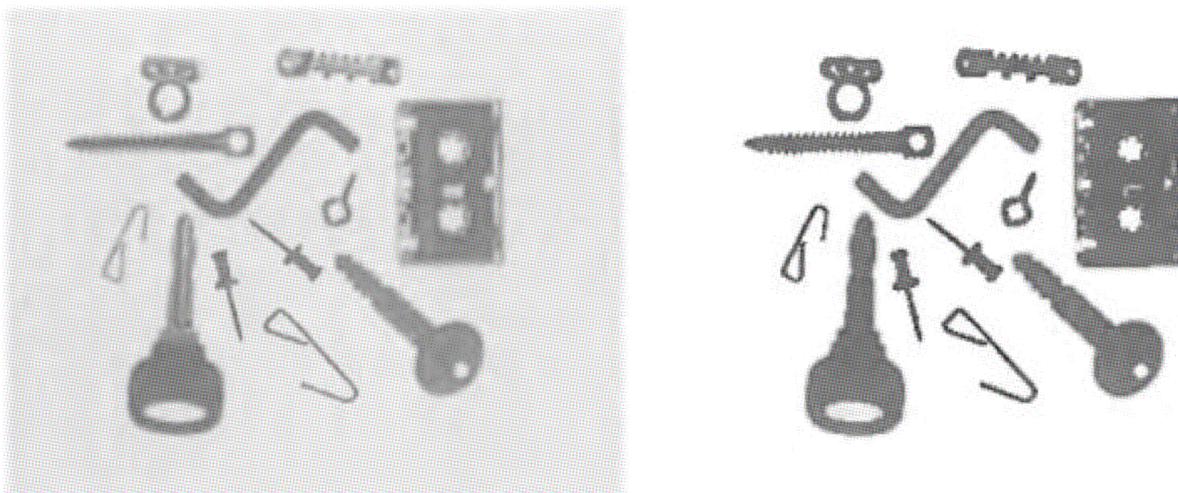
Ao contrário da imagem analógica que representa um conjunto contínuo e variável de valores, a imagem digital se apresenta como um conjunto não contínuo, finito e discreto de valores que correspondem a coordenadas espaciais limitadas e a intensidades finitas. O resultado da digitalização é sempre uma representação aproximada do objeto (DAMASIO, 2015). No que tange ao processamento, a imagem é convertida de contínua (real) para uma representação discreta, ou seja, digital. Somente dessa forma é possível fazer uso computacional da imagem, podendo ser armazenada na forma de arquivos (CONCI; AZEVEDO; LETA, 2008).

2.1.1 Tipos de Imagem Digital

2.1.1.1 Imagens binárias

Uma imagem digital é binária quando cada *pixel* que a compõe só pode representar duas informações ou cores diferentes, a cor preta e a cor branca. Na maioria das ferramentas de programação que aborda processamento de imagens digitais, no que se refere às imagens binárias, a cor preta é representada pelo valor zero, e a cor branca é atribuído o valor um. Uma imagem binária pode ser resultado da extração de alguma característica de uma imagem colorida ou de tons de cinza. Geralmente, após a filtragem ou extração de características de uma imagem, é necessário utilizar uma técnica de limiarização para segmentar uma imagem em dois grupos distintos, tendo como resultado uma imagem binarizada (LEITE, 2014).

Figura 2: Exemplo de uma imagem binária



Fonte: (SONKA; HLAVAC; BOYLE, 2008)

Na Figura 2 é possível ver um exemplo de uma imagem binária, que são imagens que representam duas informações.

2.1.1.2 *Imagens em tons de cinza*

Já uma imagem de tons de cinza é representada por uma matriz que possui valores decimais de 0 à 255, demonstrados por números binários, ou seja, uma imagem em tons de cinza é uma imagem onde cada *pixel* é representado pela intensidade da luz apenas e as diferentes intensidades, partindo do escuro em direção ao claro, são apresentadas com um valor crescente. Por conveniência, a maioria dos arquivos digitais atuais usam o número 0 para indicar a cor preta (ausência de intensidade) e o número 255 para indicar a cor branca (intensidade máxima), totalizando 256 tons de cinza diferentes. Imagens em tons de cinza são muito comuns, em parte porque muito do *hardware* de captura de tela e imagem de hoje só pode suportar imagens de 8 *bits* (GONZALEZ; WOODS, 2010).

Imagens em escala de cinza são aquelas formadas, como o nome sugere, exclusivamente por tons da referida cor. A razão pela qual se diferencia tais imagens de qualquer outro tipo de imagem é que, a quantidade de informação que cada *pixel* precisa, é inferior em relação aos outros tipos. Imagens em escala de cinza são muito comuns, em parte porque muitos dos displays de hoje assim como *hardware* de captura de imagem só podem suportar imagens de 8 *bits* (CONCI; AZEVEDO; LETA, 2008). Além disso, imagens em tons de cinza são suficientes para muitas tarefas, então, nesses casos, não é necessário o uso de imagens coloridas as quais são mais estruturalmente complicadas e mais difíceis de processar.

Figura 3: Exemplo de uma imagem em tons de cinza



Fonte: (GONZALEZ; WOODS, 2010)

Na Figura 3 podemos observar uma famosa imagem utilizada para exemplificar uma imagem em tons de cinza.

2.1.1.3 *Imagens coloridas*

Uma imagem digital é colorida quando a cada *pixel* é associado um conjunto de três valores para se representar uma cor. De acordo com Marques e Vieira (1999), os fatores que motivam o estudo de imagens coloridas, no processamento digital de imagens, levam em conta os seguintes aspectos: (1º) Na análise automática de imagens, a cor pode facilitar o processo de identificação e segmentação; (2º) Na análise de imagens com intervenção humana, o olho consegue discernir melhor imagem colorida do que imagem em tons de cinza.

Para permitir interpretar a cor usando os conceitos de percepção humana, bem como algumas variações, foram criados diversos modelos de representação de cores de uma imagem digital. Um modelo de cor é uma representação tridimensional onde cada cor é representada por um ponto no sistema de coordenadas 3D, tendo como objetivo a especificação de cores em um formato padronizado. O modelo RGB (R-*red*, G-*green*, B-*blue*), geralmente o mais utilizado, representa cada cor por seus componentes espectrais primários (vermelho, verde e azul) baseando-se em um sistema de coordenadas cartesianas. Já o modelo CMY (C-*cyan*, M-*magenta*, Y-*yellow*), representa cada cor por seus componentes espectrais secundários: ciano, magenta e amarelo (MARQUES; VIEIRA, 1999). A Figura 4 é um exemplo de uma imagem com cores do modelo RGB.

Figura 4: Exemplo de uma imagem colorida



Fonte: (CONCI; AZEVEDO; LETA, 2008)

É dispendiosa e muitas vezes não é necessário utilizar a imagem completa de 24 *bits* para armazenar a cor para cada *pixel*. Portanto, a cor de cada *pixel* é geralmente codificado num único *byte*, resultando numa imagem de cor de 8 *bits*. O processo de reduzir a representação de cor de 24 *bits* para 8 *bits*, conhecido como cor de quantização, restringe o número de cores possíveis a 256. No entanto, normalmente não existe diferença visível entre uma imagem a cores de 24 *bits* e a mesma imagem exibida com 8 *bits*. Um imagem a cores de 8 *bits* é baseada em mapas de cores, que são tabelas de consulta, tendo o valor de *pixel* de 8 *bits* como o índice e fornecendo um valor de saída para cada cor (GONZALEZ; WOODS, 2010).

2.1.2 Propriedades da Imagem Digital

Há algumas propriedades importantes de uma imagem digital, as quais não foram usadas aqui mas podem ser encontradas na bibliografia (GONZALEZ; WOODS, 2000), (MARQUES; VIEIRA, 1999).

2.1.2.1 Medidas de distância

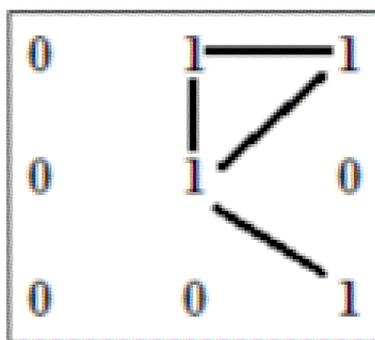
Quando trabalhamos com imagens digitais, é muito frequente medirmos distâncias entre *pixels*. Por exemplo, poderíamos saber se dois *pixels* com o mesmo nível de cinza estão distantes ou próximos. Uma pequena distância deve identificar alta similaridade, portanto a medida da distância pode ser usada para quantificar a dissimilaridade (COLE, 1998).

Em muitos casos, usamos a definição clássica de distância euclidiana entre dois pontos ou *pixels*. Cole (1998) identifica a distância Euclidiana como "a mais comum entre as medidas utilizadas" no entanto, existem outras medidas de distância que podem vir a ser úteis.

2.1.2.2 Conectividade

A conectividade é um conceito importante no estabelecimento de limites de objetos e de regiões de imagem. Para se estabelecer se *pixels* são conectados, estes devem ser vizinhos e obedecerem a um determinado critério de similaridade de níveis de cinza, ou seja, a diferença numérica entre seus atributos (níveis de cinza, por exemplo) deve estar dentro de um certo limiar. Desse modo podemos ter *pixels* vizinhos, mas que não são conectados (MARQUES; VIEIRA, 1999).

Figura 5: Exemplo da conectividade entre *pixels*



Fonte: (SIQUEIRA, 2014)

Na Figura 5 pode ser observado uma ilustração da conectividade entre *pixels*.

2.1.2.3 Histograma da Imagem

Segundo Gonzalez e Woods (2002), "o histograma de uma imagem traduz a distribuição estatística dos seus níveis de cinza". Trata-se, pois, de uma representação gráfica do número de *pixels* associado a cada nível de cinza presente em uma imagem, podendo também ser expressa em termos do percentual do número total de *pixels* na imagem. O histograma de uma imagem é simplesmente um conjunto de números indicando o percentual de *pixels* naquela imagem que apresentam um determinado nível de cinza (MARQUES; VIEIRA, 1999).

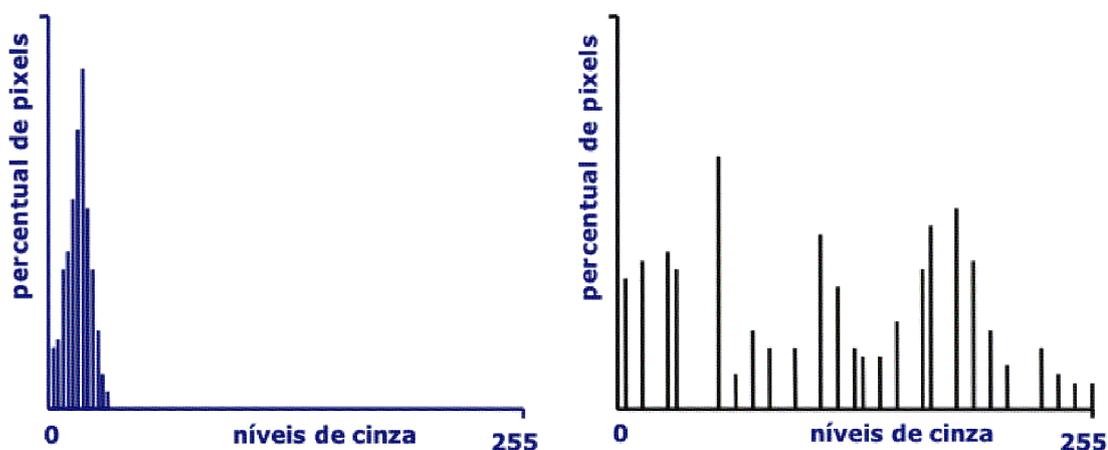
Em outras palavras, em processamento de imagens, o histograma de uma imagem digital é uma tabela que relaciona cada valor de nível de cinza com sua frequência de aparecimento na imagem digital. Geralmente, o histograma é apresentado através de um gráfico que mostra a relação entre os níveis de cinza (eixo x do gráfico) e a quantidade

de *pixels* com esses níveis de cinza (eixo y do gráfico). Assim sendo, de acordo com Queiroz e Gomes (2001), dada uma imagem digital $f(x, y)$ com M linhas e N colunas, seu histograma, $Hf(C)$, pode ser definido por:

$$Hf(C) = \frac{nC}{MN}, \quad (2.2)$$

Onde: nC é o número de vezes em que o nível de cinza C se apresenta na imagem. Os histogramas são uma ferramenta importante para inspecionar característica em imagens que muitas vezes não é possível ser visto apenas por observação.

Figura 6: Exemplo de histogramas



Fonte: (QUEIROZ; GOMES, 2001)

Na Figura 6 mostrado acima, é possível observar o número de *pixels* em cada caixa que é representado pela altura das barras, em relação aos níveis de cinza na imagem.

2.2 Processamento de Imagens

A área de processamento de imagens se refere à manipulação de *pixels* visando a melhoria na apresentação da imagem, o realce ou eliminação de certas características e a extração de informações (GONZALEZ; WOODS, 2000). A melhoria da imagem tem como objetivo enaltecer características específicas, visando uma interpretação mais perfeita do conteúdo.

Uma competente extração de informações da imagem só é possível se essa tiver sido submetida a um processamento prévio, visando a ampliação de características específicas. Esse processamento engloba as atividades de filtragem e/ou segmentação da imagem. A extração de informações de imagens digitais surgiu a partir da necessidade do aumento da

confiabilidade de tal ação, visto que a realização da ação por indivíduos humanos aumenta a probabilidade de erro (TAGLIAFERRO, 2007).

O processamento digital de imagens não é uma tarefa simples, na realidade envolve um conjunto de tarefas interconectadas. Sendo assim, de acordo com Gonzalez e Woods (2000), o processamento de imagens se divide em: aquisição de imagens, pré-processamento, segmentação, extração de características e interpretação e classificação.

Para converter uma cena real em uma imagem digitalizada, duas etapas são necessárias: a aquisição de imagem e sua digitalização. Define-se a aquisição de uma imagem como sendo o processo de conversão de uma cena real tridimensional em uma imagem analógica. Tudo se inicia com a captura de uma imagem, a qual, normalmente, corresponde à iluminação que é refletida na superfície dos objetos (QUEIROZ; GOMES, 2001). Após a captura, a imagem é convertida de contínua para uma representação discreta, ou seja, digital. Somente dessa forma é possível fazer uso computacional da imagem, podendo ser armazenada na forma de arquivos (CONCI; AZEVEDO; LETA, 2008).

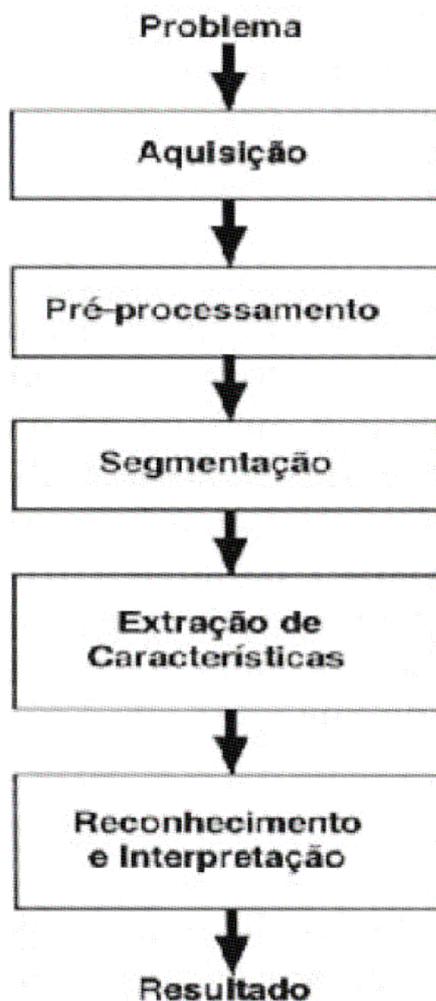
Após a obtenção de uma imagem digital, o próximo passo trata de pré-processar aquela imagem. A função chave no pré-processamento é melhorar a imagem de forma a aumentar as chances para o sucesso dos processos seguintes. O pré-processamento tipicamente envolve técnicas para o realce de contrastes, remoção de ruído ou isolamento de regiões. O estágio seguinte trata da segmentação que é o processo que subdivide uma imagem de entrada em partes ou objetos constituintes (GONZALEZ; WOODS, 2002).

De acordo com Scuri (2002), quando estamos no contexto de processamento de imagens, o mais comum é querermos obter dados relacionados com os objetos presentes na imagem. Então são necessárias as operações de segmentação que procurarão isolar regiões de *pixels*, e operações de extração de atributos que vão olhar para essas regiões e calcular uma série de parâmetros que as descreverão. Em seguida, o processo de seleção de características, procura extrair características que resultem em alguma informação quantitativa de interesse ou que sejam básicas para discriminação entre classes de objetos.

E por fim, o último estágio envolve reconhecimento e interpretação. Reconhecimento é o processo que atribui um rótulo a um objeto, baseado na informação fornecida pela característica extraída. A interpretação envolve a atribuição de significado a um conjunto de objetos reconhecidos (RIBEIRO, 2003).

O objetivo do reconhecimento é identificar objetos na cena a partir de um conjunto de medições. Cada objeto é um padrão e os valores medidos são as características desse padrão. Um conjunto de objetos similares, com uma ou mais características semelhantes, é considerado como pertencente à mesma classe de padrões (QUEIROZ; GOMES, 2001).

Figura 7: Etapas típicas envolvidas no processamento de imagens



Fonte: (MARQUES; VIEIRA, 1999)

Na Figura 7, pode ser visto um fluxograma mostrando todas as etapas supracitadas.

2.3 Segmentação de Imagens

A segmentação de imagens é uma das tarefas mais difíceis em processamento digital de imagens, além de ser um fator crucial para o sucesso de uma análise feita por computador (GONZALEZ; WOODS, 2002). Para Ballard e Brown (1982), uma "imagem segmentada, em visão computacional, é resultante do agrupamento de partes de uma imagem generalizada em unidades homogêneas considerando um ou mais aspectos".

A segmentação consiste na primeira etapa de processamento da imagem quando consideramos uma análise do ponto de vista da informação nela presente. O termo segmentação vem do termo em inglês *image segmentation*, criado durante os anos 80 (FU; MUI, 1980). Esta área representa até hoje uma linha de pesquisa importante do

processamento de imagens, principalmente por ela estar na base de todo o processamento da informação em uma imagem.

A transformação da imagem em escala reduzida de informações é o que se denomina segmentação. A segmentação consiste em dividir a imagem em regiões que correspondem a unidades estruturais da cena ou que distinguem os objetos de interesse separando-os das informações do fundo da imagem. Para Mongelo (2012), "a identificação e extração de objetos de imagens são necessárias em muitos casos". Frequentemente, ocorrem problemas tais como, um objeto estar parcialmente escondido atrás de outro ou mais objetos. Portanto, a identificação de objetos se faz necessário.

Na literatura, encontram-se várias técnicas de segmentação, mas não existe um método simples que seja bom para todos os tipos de imagens, e nem todos os métodos são igualmente bons para um tipo particular de imagem. As metodologias baseiam-se na textura (RUZON, 1997), cor (BRITTO, 1996), detecção de bordas (PELI; MALAH, 1982), técnicas de binarização (MATTANA, 1999), redes neurais (BLANZ; GISH, 1990), algoritmos genéticos (VISA, 1998), contornos ativos (KASS; WITKIN; TERZOPOULOS, 1987), morfologia matemática (OKADA; MALAYAPPAN, 1997), entre outros.

A tarefa de segmentar uma imagem é complexa porque tenta traduzir para o computador um processo cognitivo extremamente sofisticado realizado pela visão humana. A segmentação procura distinguir as partículas uma das outras e do fundo da imagem. Assim, permitirá interpretar *pixels* e agrupá-los em regiões. Não existe um modelo formal para a segmentação, o processo é essencialmente empírico e deverá se ajustar a diferentes tipos de imagens. Em geral, a segmentação é uma das tarefas mais difíceis no processamento de imagens digitais (RIBEIRO, 2003).

Talvez a característica mais importante de um método de segmentação seja a definição do que é uma região. Esta pode ser vista como um conjunto de *pixels* conectados envolvidos por uma borda de *pixels* criando um contorno ou, ainda, uma região pode ser definida como um conjunto de *pixels* conectados por meio de uma condição de uniformidade. De acordo com Albuquerque e Albuquerque (2001), entende-se como Região de Interesse (ROI) a "região definida automaticamente a partir de parâmetros obtidos na própria imagem (ou por um usuário) onde o processamento estará totalmente concentrado".

A saída do estágio de segmentação é constituída tipicamente por dados em forma de *pixels*, correspondendo a todos os pontos dentro de uma região. A representação por região é adequada quando o interesse se concentra em propriedades internas, tais como textura. Uma imagem pode conter diversos segmentos diferentes de textura e estas diferentes formas podem ser úteis na identificação de objetos ou regiões de interesse. A escolha dessa representação é apenas parte da solução para transformar os dados iniciais numa forma adequada para o subsequente processamento computacional (RIBEIRO, 2003).

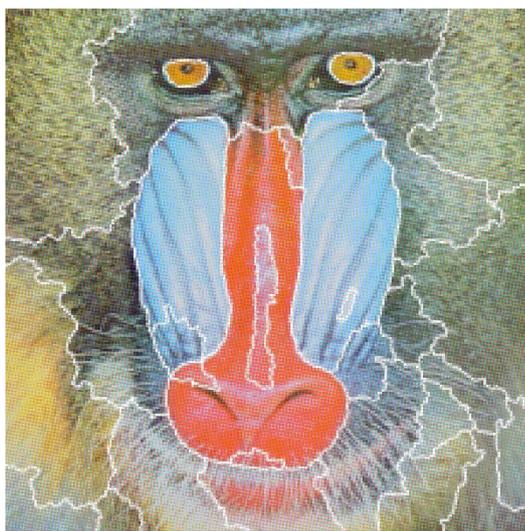
O processo de segmentação, portanto, procura obter uma determinada região da imagem, que possua características relevantes, maximizadas para o domínio de aplicação.

O ato de segmentar é feito buscando separar da imagem original regiões que possuam características em comum. A segmentação pode ser implementada visando a separação de cores, texturas, pontos, linhas, descontinuidades, bordas, dentre outros (GONZALEZ; WOODS, 2000).

Segundo Conci, Azevedo e Leta (2008), "estas novas porções da imagem contêm as características de interesse ressaltadas das demais, facilitando um processo de reconhecimento, análise ou interpretação". Podemos, por exemplo, definir uma região de interesse onde sabemos por antecedência que a iluminação de fundo é constante ou foi corrigida. Essas partes ou regiões geralmente são identificadas a partir da geometria, forma, topologia, textura, cor ou brilho, sendo escolhidas aquelas que possibilitam a melhor identificação.

Uma região pode ser representada em termos de suas características externas (fronteiras) ou em termos de suas características internas (os *pixels* que compõem a região). De modo geral, uma fronteira pode ser representada por suas características de forma, tais como comprimento ou número de concavidades, enquanto as características internas são representadas por suas propriedades de cor e textura por exemplo. É importante ressaltar que em ambos os casos, as características utilizadas devem ser as mais invariantes possíveis (GONZALEZ; WOODS, 2002). Na Figura 8 pode ser visto o exemplo do processo de segmentação de uma imagem de acordo com a região de interesse seleta.

Figura 8: Processo de segmentação de uma imagem digital



Fonte: (DENG; MANJUNATH, 2001)

O resultado final esperado de um processo de segmentação é um número finito de regiões homogêneas, que individualizam as diferentes regiões contidas numa imagem. Sendo assim, a imagem seria formada por um conjunto de regiões, que não se sobrepõe, de tal forma que cada *pixel* da imagem pertence unicamente a uma determinada região (ACHARYA; RAY, 2005).

2.4 Atributos da Imagem

Na segmentação da imagem o objeto a ser reconhecido é isolado do resto da imagem. Serão selecionados atributos significativos da imagem, formando um vetor de atributos, de forma que este possa representar simplificada a imagem, diminuindo a quantidade de informação necessária para classificá-la e, conseqüentemente, o tempo de processamento para executar a tarefa (CASTLEMAN, 1996).

Para Quinta et al. (2010), a extração de atributos visa "obter informações relacionadas com objetos presentes em uma imagem que facilitem a caracterização daqueles que pertencem a uma mesma classe". Já Pasquali (2007) faz observações importantes com relação à extração de atributos ao afirmar que "a extração de atributos é utilizada para a redução da grande quantidade de informações, para que os dados ou objetos possam ser processados e assim classificados". Na opinião de Santos (2007), o objetivo da extração de atributos é "caracterizar medidas associadas ao objeto que se deseja extrair, de forma que as medidas sejam similares para objetos similares e diferentes para objetos distintos".

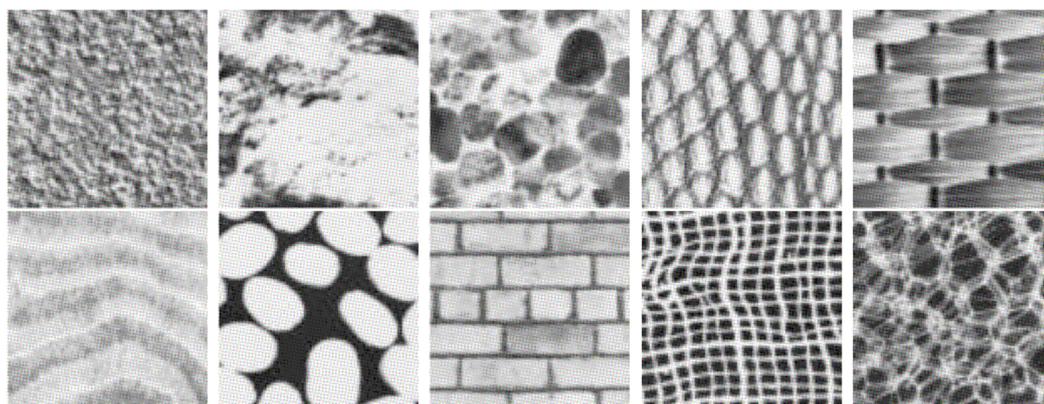
A extração de atributos é um fator importante para diminuir a quantidade de informações, mas é preciso identificar quais os tipos de atributos que melhor caracterizam determinados objetos (PASQUALI, 2007). Dentre as características visuais de uma imagem destacam-se a cor e a textura. Muito utilizada no processo de extração de atributos, a textura é uma característica muito importante na segmentação, reconhecimento e classificação de imagens. A textura é um componente que auxilia o Sistema Visual Humano na segmentação e no reconhecimento de objetos ou regiões de interesse (SANDLER; LINDENBAUM, 2006). As texturas podem ser facilmente reconhecidas visualmente, mas são bastante difíceis de serem caracterizadas matematicamente por isso, o reconhecimento de texturas, realizado intuitivamente pela visão humana, representa grande complexidade computacional (PARKER, 1997).

A textura é um termo intuitivo e de largo emprego, mas apesar de sua importância, não possui uma definição precisa (EBERT, 1994). Gonzalez e Woods (2002) descreve a textura por "medidas que quantificam suas propriedades de suavidade, rugosidade e regularidade". Ela refere-se a um padrão visual que possui algumas propriedades de homogeneidade que não resultam simplesmente de uma cor ou intensidade. Em (HARALICK, 1973), a definição de textura é relacionada com o uso de coeficientes de uniformidade, densidade, aspereza, regularidade, intensidade, dentre outras características da imagem. É uma expressão relacionada com as propriedades que representam a superfície de uma imagem.

Dentre as propriedades de uma imagem, a textura está entre as que proporcionam os melhores resultados no processo de segmentação. Ao contrário de outras características, como por exemplo o brilho, a textura não pode ser definida em um *pixel*, mas sim através de uma região ou conjunto de *pixels*. Para Ruzon (1997), a textura é "um ou mais padrões locais básicos que são repetidos periodicamente", ou seja, segmentar texturas é particionar uma imagem em regiões, onde cada região contém uma textura simples e distinta de

seus vizinhos. Além disso, (SKLANSKY, 1978) afirma que "uma região em uma imagem apresenta uma textura única se um conjunto de características estatísticas ou outras propriedades locais da imagem forem constantes, com pouca variação ou proximidade periódicas". Na Figura 9 é encontrado alguns exemplos de texturas.

Figura 9: Exemplos de texturas



Fonte: (BRODATZ, 1966)

De modo geral, uma textura é caracterizada pelas informações sobre a distribuição espacial e a variação de luminosidade contidas em um objeto ou imagem (PEDRINI; SCHWARTZ, 2008), e também descreve o arranjo estrutural das superfícies e relações entre regiões vizinhas, que na maioria das vezes, são constituídas por padrões repetitivos, cuja disposição pode ser periódica ou aleatória. Normalmente, texturas naturais são aleatórias, enquanto que texturas artificiais são frequentemente determinísticas ou periódicas. Além disso, termos como fina, grossa, suave, áspera, granulada, alongada, regular e irregular estão associados ao conceito de textura. Mais discussões sobre o que é textura podem ser encontradas em outros trabalhos e pesquisas relacionados (PARKER, 1997).

2.5 Técnicas de Segmentação

No processo de classificação de imagens onde se tem uma grande quantidade de atributos se faz necessária a separação dos atributos irrelevantes dos relevantes de forma a reduzir a quantidade de atributos necessários para a classificação das imagens (PASQUALI, 2007). A classificação parte da premissa que a similaridade entre objetos implica que eles possuam características similares, formando classes ou agrupamentos. De outra maneira, podemos considerar que a classificação consiste em reconhecer um objeto, uma forma ou, de modo geral, uma entidade particular da imagem. Segundo Gonzalez e Woods (2000), "dado um conjunto de classes e um padrão apresentado como entrada para o sistema, o problema consiste em decidir a que classe o padrão pertence".

Segmentação de texturas pode ser realizada por classificação a qual pode ser, basicamente, de duas formas: supervisionada ou não-supervisionada. Dizemos que a segmentação é supervisionada quando existem informações disponíveis sobre a imagem ou sobre a classe da textura, sendo assim, consiste basicamente em identificar regiões cujos parâmetros estão presentes em alguma textura usada durante o treinamento. Já na segmentação não supervisionada, o objetivo é agrupar um conjunto de padrões em classes (*clusters*) que compartilham alguma semelhança. Nesse caso, cada padrão também é atribuído a uma classe, mas estas são extraídas automaticamente dos padrões (NASCIMENTO, 2010).

Na segmentação supervisionada, existe um conjunto de padrões pré-classificados, utilizados para extração de atributos, em uma etapa denominada treinamento, e o objetivo é atribuir um novo padrão, cuja classe é desconhecida, a uma das classes de treinamento. Na forma mais ampla, esse método pode ser explicado como o procedimento que necessita de conhecimento prévio da área para produção do treinamento do algoritmo. No caso da segmentação não supervisionada, as classes são extraídas diretamente dos padrões. Uma vez que a informação disponível é menor, a classificação é menos precisa do que a obtida com os métodos supervisionados, contudo, esta é a única solução possível para problemas em que não se dispõe de informação acerca dos grupos que geraram os dados (REBOUCAS; SOUSA; PIRES, 2009).

2.5.1 *K-means*

K-means é um dos mais simples algoritmos de segmentação que resolvem o conhecido problema de clusterização (MACQUEEN, 1967). Clusterização é a classificação de dados, formando agrupamentos ou *clusters* e representa uma das principais etapas de processos de análise de dados, denominada análise de *clusters* (JAIN; MURTY; FLYNN, 1999).

O objetivo da clusterização é agrupar os elementos de um conjunto de tal forma que os grupos formados sejam constituídos por elementos que possuam maior similaridade com os elementos do mesmo grupo do que com qualquer dos elementos de outros grupos. A clusterização é uma ferramenta útil para o estudo e compreensão do comportamento de dados em diferentes situações e tem sido empregada na solução de diversos problemas nas mais variadas áreas do conhecimento e em especial na segmentação por textura. Existem diversos algoritmos para realizar a análise de *clusters*. Eles fornecem uma metodologia para explorar e verificar as estruturas presentes nos dados, organizando-os em diferentes grupos ou aglomerados. Essa organização é realizada com base em medidas de similaridades e dissimilaridades, de modo a agrupar objetos semelhantes segundo suas características (FRED, 2001).

O *K-means* é um dos algoritmos de clusterização mais utilizados pois o algoritmo segue uma maneira simples e fácil de classificar um determinado conjunto de dados através de um certo número de *clusters* (suponha K *clusters*) fixados a priori. Cada vetor do conjunto de dados pertence exclusivamente a um *cluster* e cada *cluster* é caracterizado

por um único ponto, seu centróide, calculado a partir da média de seus vetores. O vetor de características dos objetos é derivado dos valores do *pixel* em cada banda da imagem e os *clusters* representam regiões segmentadas (SANTANA, 2012).

Assim como todos os métodos particionais, o algoritmo *K-means* produz uma partição dos n objetos em K agrupamentos. Segundo Schalkoff (1992), o algoritmo *K-means*, também chamado de K-Médias, é um "método de partição baseado em recolocação que necessita da definição a priori do número de agrupamentos K e tem como objetivo particionar n registros em K agrupamentos, onde $K < n$ ". Esses aglomerados são formados com base em alguma medida de similaridade, sendo que o algoritmo ainda utiliza uma técnica de realocação iterativa de modo a encontrar um local ótimo para o aglomerado (DUDA; HART; STORK, 2001).

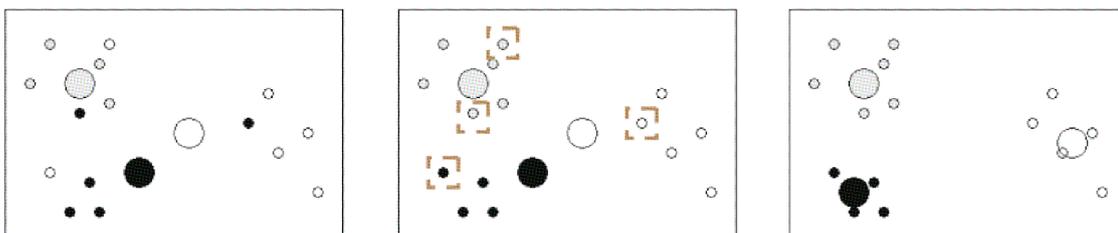
Basicamente o algoritmo de *K-means* define um conjunto de K centróides para os aglomerados. Cada amostra do conjunto de dados é então associada ao aglomerado com o centróide mais próximo. Em seguida os centróides são recalculados e a associação das amostras a um aglomerado é refeita. Esse processo é repetido até que os centróides não sejam mais alterados (DUDA; HART; STORK, 2001). Trata-se de um método que possui um grande poder de modelagem pois atinge o princípio de aglomeração de forma rápida e eficiente, utilizando um número fixo de classes iniciais, determinadas pelo usuário. A idéia é fornecer uma classificação de informações de acordo com os próprios dados, baseada em análises e comparações entre os seus valores numéricos. Assim, o algoritmo fornecerá uma classificação automática e a quantidade de classes desejadas deve ser fornecida pelo usuário (KOLOSSOSKI, 2007).

O critério de agrupamento do *K-means* pode ser descrito como sendo:

$$E = \sum_{k=1}^K \sum_{x_i \in C_k} d(x_i, x_{0k}) \quad (2.3)$$

Onde: x_{0k} é o centróide do aglomerado C_k e $d(x_i, x_{0k})$ é a distância entre os pontos x_i e x_{0k} . Em outras palavras, o objetivo do *K-means* é minimizar a distância entre cada ponto e o seu respectivo centróide. Na Figura 10 pode-se observar como ocorre o processo de clusterização realizado pelo *K-Means*.

Figura 10: Exemplo de execução do algoritmo *K-Means*



Fonte: (LINDEN, 2009)

Na primeira imagem, cada elemento foi designado para um dos três grupos aleatoriamente e os centróides (círculos maiores) de cada grupo foram calculados. Em seguida, os elementos foram designados agora para os grupos cujos centróides lhe estão mais próximos. E por fim, os centróides foram recalculados e os grupos já estão em sua forma final.

2.5.2 Filtros de Gabor

Os Filtros de Gabor têm sido utilizados em muitas aplicações, tais como segmentação de textura, detecção de bordas, identificação de retina, codificação de imagens e representação de imagens (WELDON; HIGGINS; DUNN, 1996). Eles receberam atenção considerável porque estes filtros de passagem de banda 2D demonstraram possuir propriedades de localização ótimas tanto no domínio espacial como no domínio da frequência e assim são bem adequados para extrair bordas ou características de uma imagem situada numa gama de frequência e orientação específicas. Geralmente, quando se trabalha com imagens, as funções utilizadas nos Filtros de Gabor são senóides complexas e bidimensionais modeladas por uma função gaussiana também bidimensional. Essas funções têm como objetivo extrair atributos para caracterizar diferentes tipos de texturas presentes na imagem, que são descritas pela frequência e orientação já definidas pelas funções senoidais (BELUCO; ENGEL, 2003).

A função de Gabor é um sinal de uma dimensão formado pela adição de uma gaussiana a um sinal harmônico de determinada frequência. Um sinal qualquer pode ser decomposto como a combinação de funções de Gabor de diferentes frequências. Dessa maneira, é possível determinar a intensidade de cada frequência em cada instante do sinal. A função de Gabor de duas dimensões é uma modificação da função unidimensional e assemelha-se a padrões biológicos existentes na visão de mamíferos (DAUGMAN, 1980).

A função de duas dimensões pode ser utilizada na extração de características de imagens, permitindo a identificação da intensidade de frequências em diferentes orientações. Filtros de Gabor são as funções de Gabor quando aplicadas em extração de características. Os Filtros de Gabor têm sido utilizados para a representação de imagens e através de um conjunto de classes de funções de Gabor é possível representar de forma completa qualquer tipo de imagem. Essas classes de funções são geradas a partir de uma função de Gabor principal (KRUIZINGA; PETKOV, 1999).

Desenvolvido por Dennis Gabor (1946), tem sido aplicado com sucesso na segmentação de imagens, reconhecimento de faces, reconhecimento de assinaturas e identificação de impressões digitais. A forma geral do filtro de Gabor é apresentada na equação a seguir:

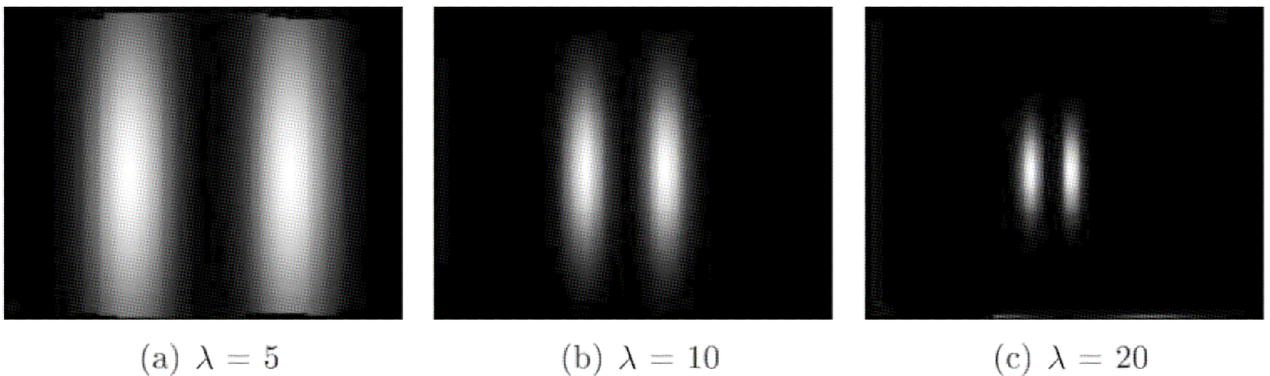
$$g(x, y, \sigma_x, \sigma_y, k_x, k_y) = \exp\left[-\frac{1}{2}\left[\left(\frac{x}{\sigma_x}\right)^2 + \left(\frac{y}{\sigma_y}\right)^2\right] + (2 * \pi * i * (k_x * x + k_y * y))\right] \quad (2.4)$$

Onde: (σ_x, σ_y) definem a extensão espacial da função de Gabor. (FONTE: RAGHU, 1995). A frequência da onda senoidal é dada por $k = (k_x, k_y)$, onde k_x e k_y são suas

componentes ao longo dos eixos x e y , respectivamente (SANTOS; ANGELO, 2007).

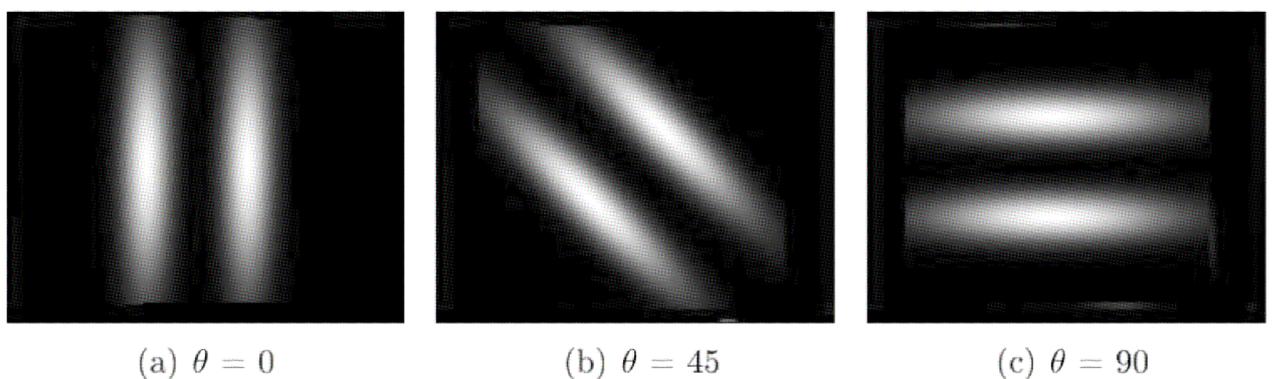
Os Filtros de Gabor permitem a manipulação de diversos parâmetros como frequência, orientação, excentricidade e simetria. Através dessas várias combinações são formados os bancos de Filtros de Gabor (JI; CHANG; HUNG, 2004). Os parâmetros dos Filtros de Gabor possuem as seguintes propriedades: λ determina o valor do comprimento de onda no núcleo; θ especifica o ângulo de inclinação das ondas paralelas do filtro; σ determina o desvio padrão da distribuição normal e está relacionado com a largura da gaussiana que modula o filtro e γ determina a excentricidade do núcleo (PASQUALI, 2007). As Figura 11, Figura 12, Figura 13 e Figura 14 mostram exemplos de variações nos valores de λ , θ , σ e γ .

Figura 11: Exemplo de variação no valor de λ

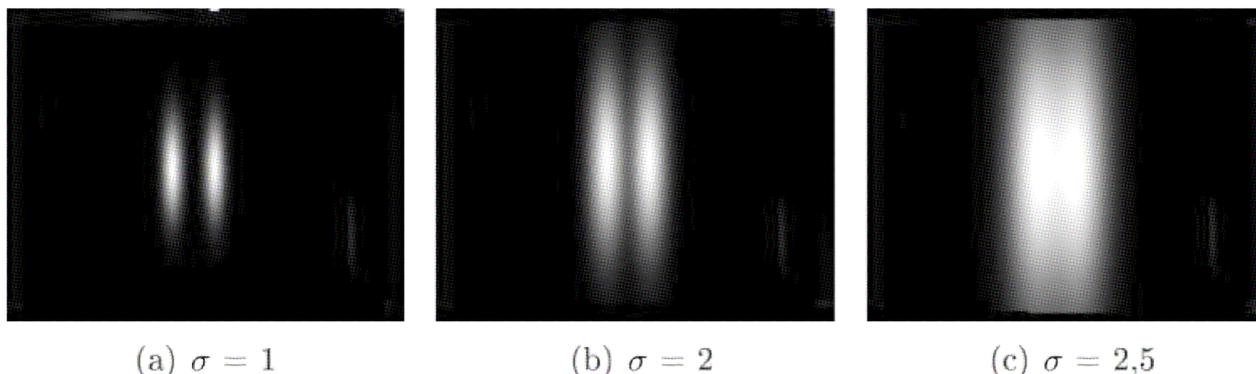


Fonte: (PASQUALI, 2007)

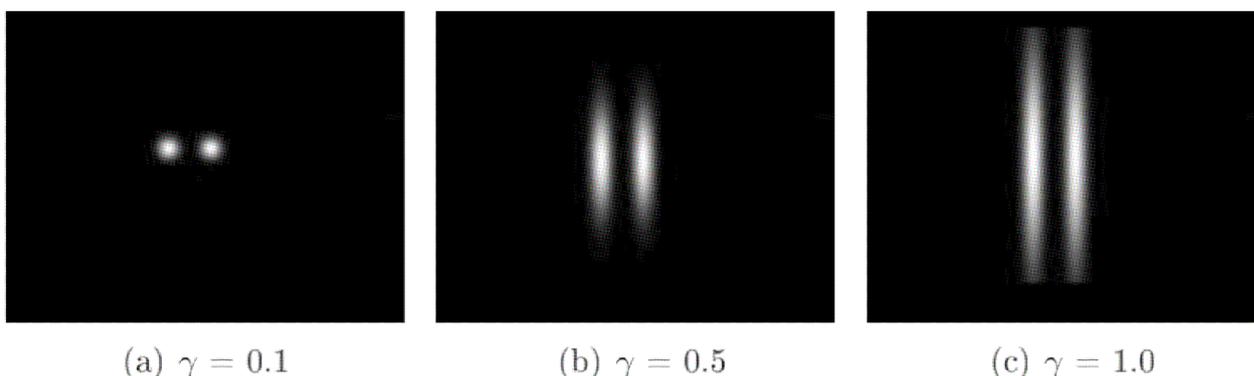
Figura 12: Exemplo de variação no valor de θ



Fonte: (PASQUALI, 2007)

Figura 13: Exemplo de variação no valor de σ 

Fonte: (PASQUALI, 2007)

Figura 14: Exemplo de variação no valor de γ 

Fonte: (PASQUALI, 2007)

Após a montagem da imagem mosaico e do banco de Filtros de Gabor, procede-se ao processo de convolução da imagem com cada um dos filtros montados anteriormente, tendo por resultado uma imagem filtrada para cada filtro. Estas imagens filtradas também são denominadas de “bandas texturais”. O processo de filtragem das imagens é dado através da convolução em duas dimensões da imagem $I(x, y)$ com um núcleo de Gabor $F(x, y)$. A imagem é convoluída com todo o banco de Gabor, onde se obtém uma resposta para cada núcleo. Assim são extraídas as características da imagem em cada um do filtros (JI; CHANG; HUNG, 2004).

O processo de convolução é um importante passo para realizar a extração de atributos utilizando Filtros de Gabor (PASQUALI, 2007). Filtros por convolução são muito utilizados em processamento de imagens. Matematicamente, a convolução é uma operação entre

duas matrizes, geralmente bidimensionais, uma das quais é a imagem e a outra é uma matriz chamada de matriz de convolução ou elemento estruturante. Segundo (GONZALEZ; WOODS, 2002), "a matriz de convolução representa uma função matemática qualquer, e é aplicada sobre cada pixel $A(x, y)$ da imagem original e sua vizinhança imediata, resultando em uma nova imagem $I(x, y)$, que reflete a relação da imagem original com a função matemática $g(x, y)$ dada pela matriz", ou seja,

$$I(x, y) = A(x, y) * g(x, y) \quad (2.5)$$

2.5.3 Análise de Componentes Independentes

A técnica conhecida como ICA, do inglês *Independent Component Analysis*, tem como premissa a hipótese de que as fontes são mutuamente independentes. Ela é capaz de encontrar fontes que originaram uma determinada mistura, somente a partir de uma mistura observada, supondo independência estatística entre elas. Ou seja, tendo observado um conjunto de dados e supondo que eles tenham sido gerados a partir de uma mistura de outros dados, a técnica é capaz de estimar as fontes que originaram a mistura e os pesos de cada fonte na mistura, a partir de análises estatísticas do sinal observado (LEITE, 2005).

A Análise de Componentes Independentes é uma técnica estatística e computacional que revela componentes ou fatores subjacentes a um conjunto de variáveis aleatórias, medições, ou sinais observados multivariados. Difere das técnicas tradicionais utilizadas na área de segmentação, porque tais componentes são estatisticamente independentes (ou têm dependência estatística minimizada) e são não gaussianos (HYVARINEN; KARHUNEN; OJA, 2001).

O método de Análise de Componentes Independentes, consiste em determinar vetores estatisticamente independentes chamados de componentes independentes, de uma mistura composta por vetores, misturados de fontes originais. Nesse modelo, apenas as variáveis aleatórias X_i são conhecidas. A partir delas, serão estimados os coeficientes da mistura A_{ij} e as componentes independentes S_j (FRANCO, 2008).

Seja o vetor aleatório $X = (X_1, X_2, \dots, X_n)$, cujos elementos (X_1, X_2, \dots, X_n) são gerados pela mistura de n componentes estatisticamente independentes entre si de um vetor aleatório $S = (S_1, S_2, \dots, S_n)$, cujos elementos são (S_1, S_2, \dots, S_n) . O modelo ICA expressa cada X_i como uma combinação linear de componentes independentes, dada por $X_i = A_{i1}S_1 + A_{i2}S_2 + \dots + A_{in}S_n$, para todo $i = 1, 2, \dots, n$, em que $A_{ij}, i, j = 1, 2, \dots, n$, são coeficientes reais. Dessa forma, como multiplicação de matrizes, o modelo ICA pode ser escrito como:

$$X = A * S, \quad (2.6)$$

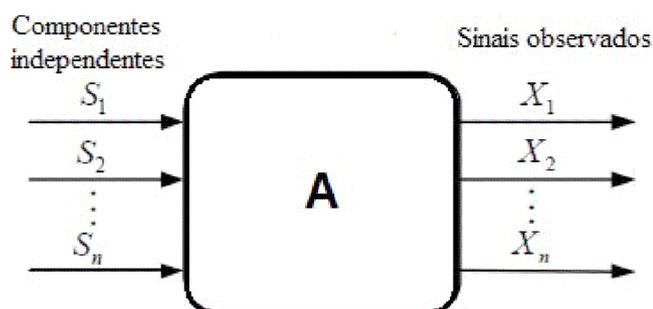
Onde: A é a matriz dos coeficientes A_{ij} das combinações lineares. Sendo A_{ij} um coeficiente que pondera a mistura dos componentes independentes (sinais ou fontes originais), a

matriz A é denominada matriz de mistura. Tanto os coeficientes A_{ij} como os componentes independentes S_j são desconhecidos e devem ser estimados a partir da observação dos sinais misturados X_i (LEITE, 2013).

Este é o modelo básico da ICA. O modelo é portanto, um modelo generativo, isto é, que descreve como os dados são gerados por um processo de mistura das variáveis S_j , denominadas de componentes independentes. Os únicos termos observáveis no modelo ICA são as variáveis aleatórias X_i , uma vez que as variáveis S_j são latentes, significando que elas não podem ser diretamente observadas. E os coeficientes da matriz A são assumidos desconhecidos também. Portanto, tanto as componentes independentes S_j quanto os coeficientes A_{ij} devem ser estimados utilizando somente os valores observados das variáveis aleatórias X_i (OLIVEIRA, 2004).

Na Figura 15 é descrito o caminho de estimação a partir da análise de componentes independentes.

Figura 15: Modelo de mistura na análise de componentes independentes



Fonte: Adaptado de Leite (2013)

Segundo Hyvarinen, Karhunen e Oja (2001), esta definição de modelo é uma das mais básicas pois omite a existência de ruído e considera a mistura linear. Estas considerações podem ser ampliadas definindo modelos ICA mais complexos. Também assume-se que o número de componentes independentes seja igual ao número de sinais observados, embora em várias aplicações seja mais realístico assumir que esses números sejam diferentes. Nos casos em que o número de sinais observados é maior que o número de componentes independentes a estimação pode ser realizada com o uso da inversa generalizada da matriz de mistura (LEITE, 2013).

Para que o modelo ICA esteja bem definido é necessário supor que os componentes S_i a serem estimados sejam estatisticamente independentes entre si e apresentem distribuição de probabilidade não gaussiana. Isto é, para que o método seja eficaz, algumas restrições nas variáveis são necessárias. Estas seriam, portanto, as pressuposições necessárias para garantir a convergência dos sinais observados em fontes originais (FRANCO, 2008).

2.5.3.1 Pressuposições

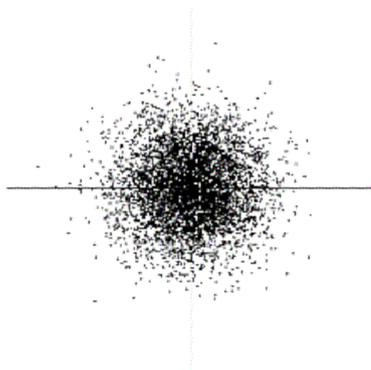
Por definição, o método pressupõe que as fontes sejam independentes. Variáveis aleatórias são consideradas independentes quando a informação de uma variável não fornece qualquer informação sobre a outra (FRANCO, 2008). Duas variáveis aleatórias Y_i e Y_j são ditas independentes se a informação contida na variável Y_i não fornece nenhuma informação sobre a probabilidade de ocorrência da variável Y_j , para $i \neq j$. De acordo com Hyvarinen, Karhunen e Oja (2001), sejam Y_1, Y_2, \dots, Y_n variáveis aleatórias com função de densidade conjunta $f(y_1, y_2, \dots, y_n)$, diz-se que as variáveis Y_i são estatisticamente independentes se a função de densidade conjunta pode ser fatorada na forma:

$$f(y_1, y_2, \dots, y_n) = f_1(y_1) * f_2(y_2) \dots f_n(y_n) \quad (2.7)$$

Onde: $f_i(y_i)$ denota a consistência de Y_i , para todo $i = 1, 2, \dots, n$.

Outra implicação, segundo Hyvarinen, Karhunen e Oja (2001), é que as componentes independentes tenham distribuições não gaussianas. O motivo deve-se ao fato de que a distribuição de duas variáveis gaussianas gera uma figura de densidade completamente simétrica, conforme pode ser visto na Figura 16:

Figura 16: Distribuição de duas variáveis gaussianas independentes



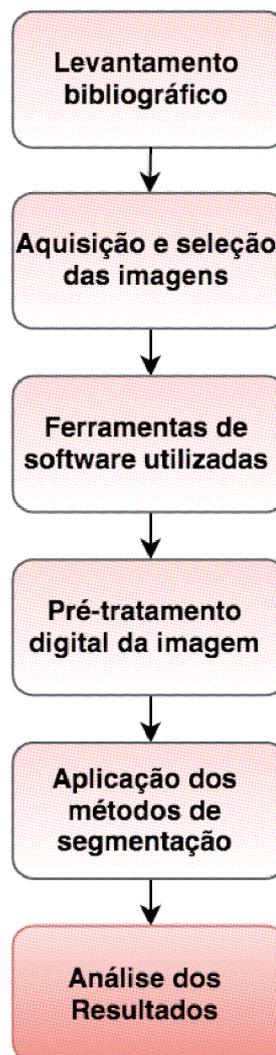
Fonte: (HYVARINEN; KARHUNEN; OJA, 2001)

Variáveis gaussianas possuem a particularidade de que as propriedades de não correlação e independência são equivalentes. Seus cumulantes de ordem mais alta são nulos, mas as informações contidas nessas medidas são essenciais na estimativa do modelo ICA. Por outro lado, para variáveis não gaussianas, a independência estatística é a principal garantia de que as fontes estimadas serão distintas e com base neste critério, são definidas a maioria das estratégias para a segmentação utilizando ICA. Apesar desta restrição para variáveis gaussianas, é importante notar que o modelo não exige qualquer prévio conhecimento sobre as distribuições de probabilidade dos componentes independentes (LEITE, 2013).

3 METODOLOGIA

A metodologia proposta neste trabalho tem como objetivo mostrar como foi o desenvolvimento da aplicação das técnicas para segmentação das imagens. Primeiramente, descreve-se sobre cada etapa do universo de estudo dessa pesquisa. Em seguida, mostra-se o software que foi utilizado e são comentadas as suas principais funcionalidades. Por conseguinte, são relatados os tipos de características da imagem que foram levados em conta nesse trabalho, como foram obtidas e como foi o processo de pré-processamento e segmentação (como as imagens foram pré-tratadas e segmentadas). E por último, é apresentado a análise sobre os métodos assim como os aspectos importantes sobre os mesmos. A imagem da Figura 17 traz o fluxograma da pesquisa.

Figura 17: Fluxograma das etapas realizadas na pesquisa



Fonte: Própria do Autor

3.1 Etapas do processo

Conforme observado no fluxograma, o processo foi dividido nas seguintes etapas: *levantamento bibliográfico, aquisição e seleção das imagens, ferramentas de software utilizadas, pré-tratamento digital da imagem e aplicação do métodos de segmentação.*

No **levantamento bibliográfico**, é mostrado o que foi estudado para que o presente trabalho fosse feito. Na **aquisição e seleção das imagens**, é explicado como foi realizada a seleção das imagens, disponíveis em um banco de dados online. Na **ferramentas de software utilizadas** é descrito sobre os *softwares* utilizados para que fossem alcançados os objetivos do trabalho. No **pré-tratamento da imagem** é explicado como foi feito e o que foi utilizado para melhorar o aspecto das imagens para uma melhor análise visual e para uma melhor execução dos métodos de segmentação. E por fim, na **aplicação dos métodos de segmentação**, é apresentada as técnicas utilizadas nesse trabalho para a segmentação das imagens.

3.1.1 Levantamento bibliográfico

O primeiro passo na execução do método proposto foi o levantamento bibliográfico. Foi feito um estudo aprofundado de tópicos relevantes, tais como imagem digital e os tipos de imagens assim como, sobre o processamento digital de imagens, focando principalmente no processo de segmentação e extração de atributos e suas aplicações. A realização do levantamento bibliográfico é uma etapa importante pois o estudo foi potencializado com as pesquisas encontradas na comunidade científica, a fim de: evitar a duplicação de pesquisas, reaproveitar e contestar pesquisas em diferentes escalas e contextos, observar possíveis desvios nos estudos realizados, conhecer os recursos necessários para a construção de um estudo com características específicas, desenvolver estudo que cubra lacunas na literatura trazendo real contribuição para a área de conhecimento, propor temas, problemas, hipóteses e metodologias inovadoras no campo do estudo, além de otimizar recursos disponíveis em prol da sociedade, do campo científico e das instituições que apoiam a pesquisa. A partir desse estudo bibliográfico, foi que se buscou executar, analisar e tirar conclusões acerca dos métodos no campo de segmentação das imagens no presente trabalho.

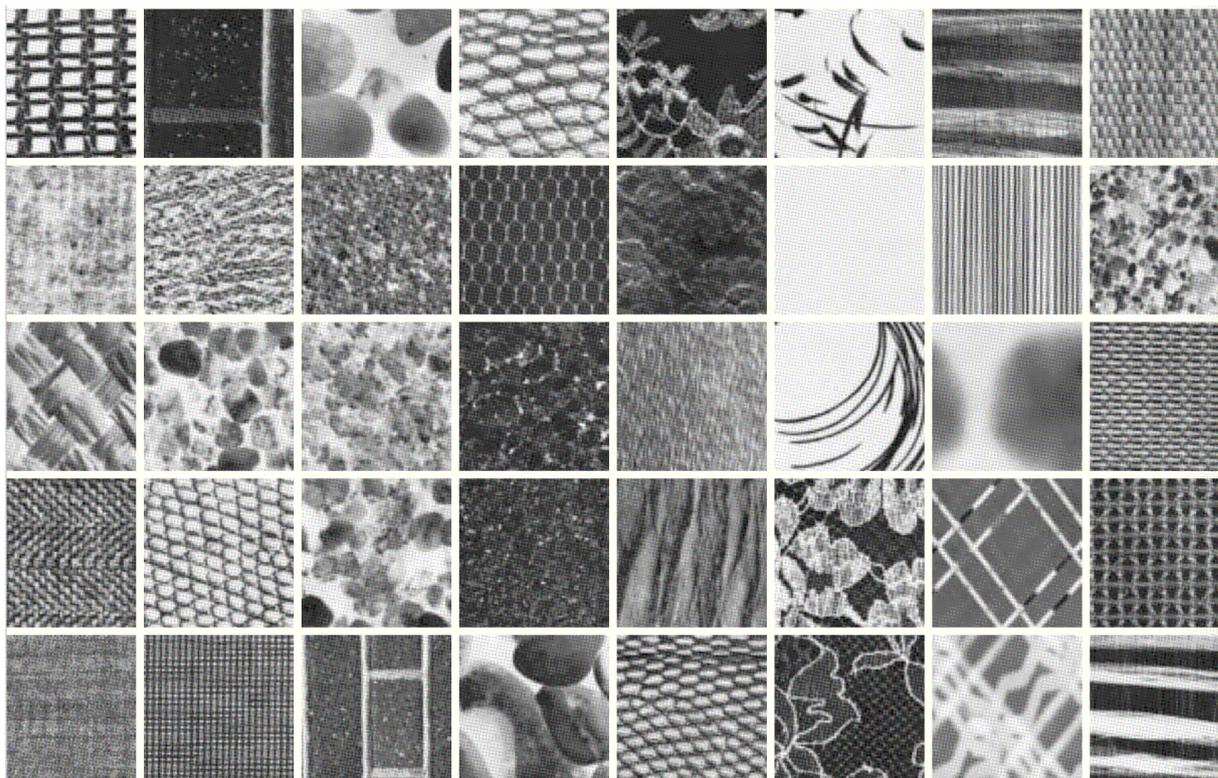
3.1.2 Aquisição e seleção das imagens

O próximo passo foi a aquisição e seleção das imagens digitais. Neste trabalho fez-se o uso de imagens constituídas por texturas naturais disponibilizadas no álbum de Brodatz (1966) com a finalidade de testar a metodologia proposta. Um dos pontos que determinaram a escolha desse banco foi a sua utilização prévia em outros projetos de pesquisa para outros fins, juntamente com a ferramenta de *software* MATLAB.

Foram utilizadas até 100 imagens do banco na criação das montagens e 12 imagens para o treinamento do algoritmo da Análise de Componentes Independentes. Foi adotada

essa quantidade como amostra porque não achou-se interessante um banco de imagens finais com poucas imagens segmentadas para serem analisadas, uma vez que o método de análise se baseia nos melhores resultados das segmentações feitas pelos métodos propostos. A seguir, tem-se a Figura 18 que exibe o banco de imagens de Brodatz (1966) com algumas texturas que foram utilizadas no estudo.

Figura 18: Banco de imagens utilizadas na pesquisa

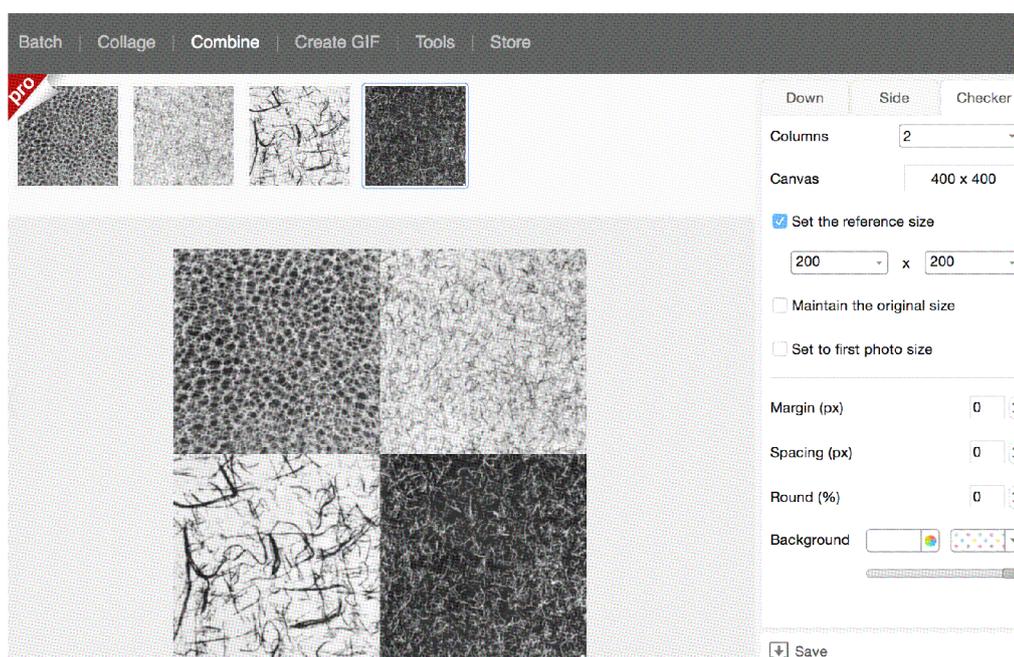


Fonte: (BRODATZ, 1966)

3.1.3 Ferramentas de softwares utilizadas

Foram utilizados dois *softwares* no presente trabalho: PhotoScapeX e MATLAB. O PhotoScapeX foi usado para o pré-tratamento das imagens digitais. Os recursos disponíveis no programa são bastantes simples e ideais para tratamento de imagens de forma efetiva e descomplicada. O PhotoScapeX oferece ainda diversos meios para editar imagens que permitem ajustar ou realçar contrastes, correção de plano de fundo e redimensionamento. Além disso, é possível também inserir filtros, fazer mosaico e suavizar as imagens, entre outros recursos. Essa ferramenta é muito eficiente para quem precisa editar várias imagens com o mesmo padrão, fazendo montagens com duas ou mais imagens, como foi o caso deste trabalho. O programa é extremamente eficaz e fácil de ser utilizado, por isso a escolha de sua aplicação. A Figura 19 mostra a tela de edição da ferramenta.

Figura 19: Programa utilizado para o pré-tratamento das imagens



Fonte: Própria do Autor

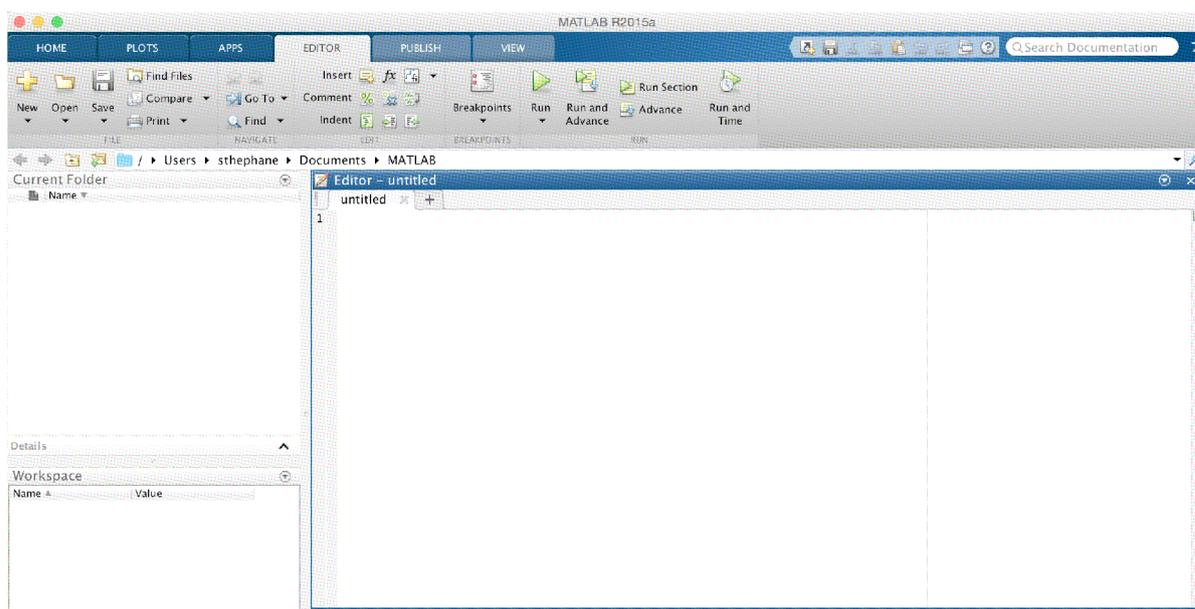
Já na questão da execução dos algoritmos, adotou-se como *software*, o MATLAB da MathWorksTM. A linguagem MATLAB permite implementar e resolver problemas matemáticos muito mais rápido e eficientemente do que através de outras linguagens como C, Basic, Pascal ou Fortran (CBPF, 2002). É um ambiente que permite a criação, execução e manutenção dos códigos e é especializado em cálculos computacionais, estatística, filtragem, otimização e integração numérica.

O nome MATLAB significa *Matrix Laboratory* e representa bem o funcionamento deste *software*, pois todas as variáveis definidas em seu ambiente estão na forma de matrizes. Por causa dessa característica, esse programa é adequado quando se necessita trabalhar com uma grande coleção de dados. As principais janelas da aplicação são a *Command Window*, *Current Directory Window*, *Command History Window*, *Editor* e *Figure*. A *Command Window* é a janela principal pois inicializa variáveis e executa comandos. A janela *Current Directory Window* exhibe os arquivos presentes no diretório ou pasta atual. A *Command History Window* apresenta a lista dos comandos mais recentes digitados. Já o *Editor* permite a edição e depuração de rotinas, também chamadas de arquivos de *script*, e funções. Os arquivos no formato próprio do MATLAB são abertos no *Editor*. Por fim, as janelas *Figure* são as que mostram os resultados de comandos gráficos (GILAT, 2006).

O MATLAB consegue executar uma sequência de ações através de arquivos chamados de *M-files*, que possuem a extensão *.m. Os *M-files* são de 2 tipos, os *scripts files*, que são uma seqüência normal de passos do MATLAB e os *function files*, que são funções criadas para necessidades específicas (GONZALES; WOODS; EDDINS, 2004). A versão utilizada

para este trabalho foi a versão R2015a e a Figura 20 mostra a tela inicial da aplicação.

Figura 20: Tela inicial do MATLAB



Fonte: Própria do Autor

O *software* possui também uma facilidade na construção e análise de gráficos e devido a sua capacidade de processamento matemático, a linguagem é amplamente utilizada por diversas áreas. Em decorrência de todos esses fatores, esse ambiente foi escolhido para o processamento das imagens nesse estudo. Os testes foram realizados em uma máquina MacBook Pro, 2.4 GHz Intel Core i5, 4 GB de RAM executando no sistema operacional Mac OS X Yosemite, versão 10.10.1, ilustrado na Figura 21 logo a seguir.

Figura 21: Configurações da máquina utilizada para execução dos testes

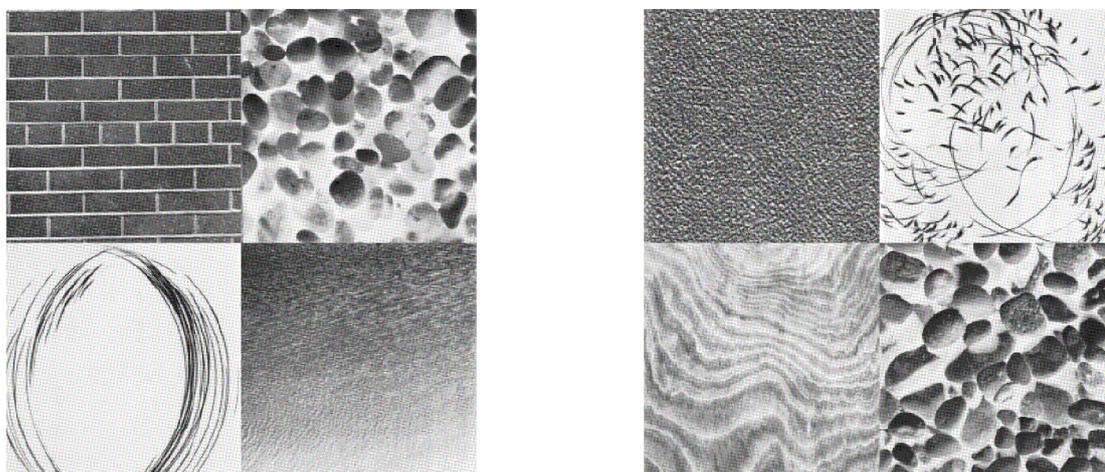


Fonte: Própria do Autor

3.1.4 Pré-tratamento da imagem

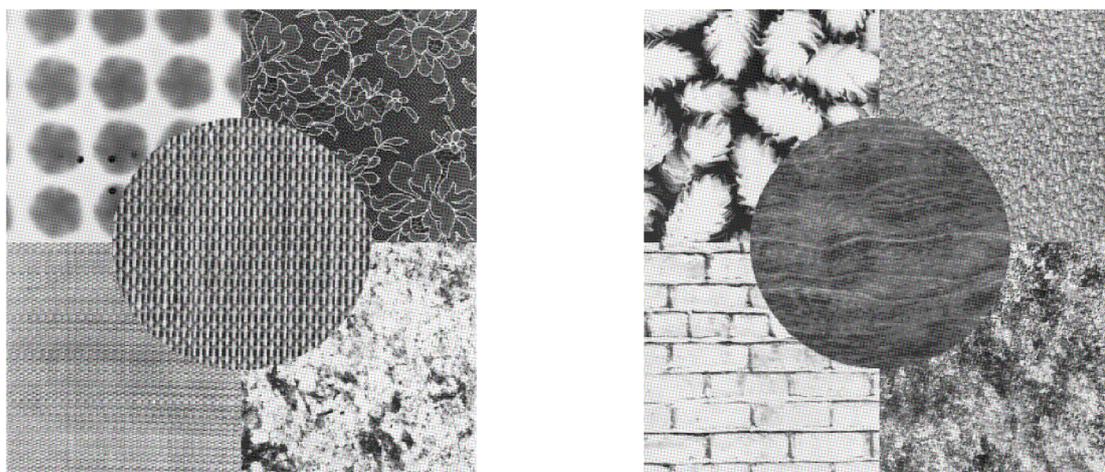
Após a obtenção e seleção das imagens, a etapa seguinte tratou de melhorá-las. A função chave no pré-processamento é melhorar a imagem de forma a aumentar as chances para o sucesso dos processos seguintes. O pré-tratamento tipicamente envolve técnicas para o realce de contrastes, remoção de ruído, suavização e etc. Neste trabalho foi aplicado o realce de contrastes em algumas imagens e a suavização em outras. Também foi feita uma montagem das texturas para que os resultados fossem melhor executados e posteriormente, melhor analisados. A seguir, estão alguns exemplos das montagens feitas a partir das imagens escolhidas para o estudo.

Figura 22: Mosaico formado por 4 texturas distintas



Fonte: Própria do Autor

Figura 23: Mosaico formado por 5 texturas distintas



Fonte: Própria do Autor

3.1.5 Aplicação dos métodos de segmentação

Como já foi visto, imagens apresentam atributos e dentre eles, se destacam as texturas. Segundo Tribuj e Waisbaum (2006), "o processo de segmentação de imagens com textura, consiste em realizar uma partição da imagem de entrada em um conjunto de regiões disjuntas, fazendo com que cada região seja homogênea em relação a característica de textura". Muitos trabalhos têm sido realizados utilizando vários métodos para resolver o problema, os quais podem ser resumidos em duas categorias principais:

- Os métodos que consideram as informações disponíveis sobre a imagem ou sobre a classe da textura, para assim, identificarem regiões cujos parâmetros estão presentes em alguma textura usada durante o treinamento;
- Os métodos que agrupam um conjunto de padrões em classes que compartilham alguma semelhança. Nesse caso, cada padrão é atribuído a uma classe, mas estas são extraídas automaticamente dos padrões.

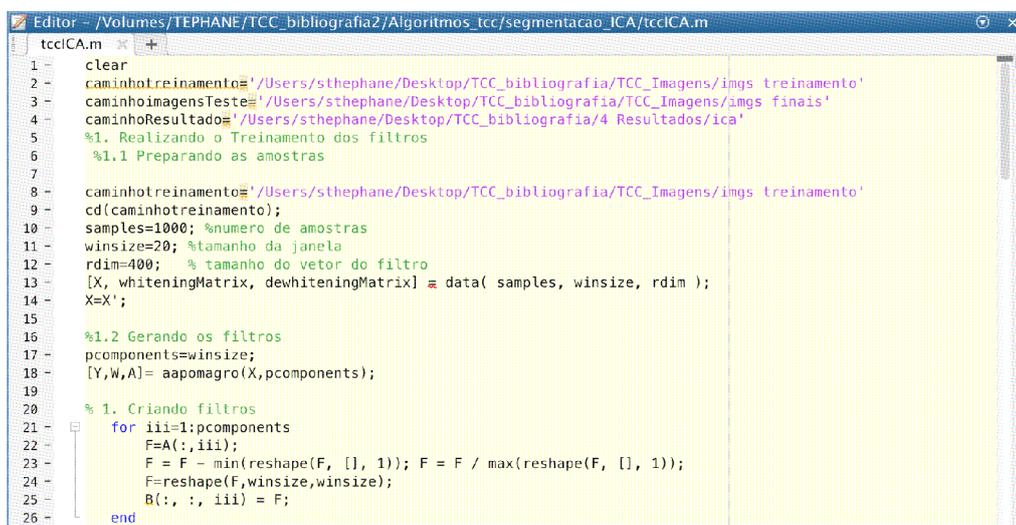
Isto é, os métodos de segmentação podem ser supervisionados ou não supervisionados, dependendo dos requisitos de informação a priori da imagem que a compõem. Neste trabalho consideramos as informações baseadas na textura e distingui-las e segmentá-las é o foco desse trabalho. Sendo assim, o objetivo final é o de execução e análise de diferentes métodos que representam cada uma dessas abordagens supracitadas.

Este trabalho aplica e analisa métodos de segmentação supervisionada usando a Análise de Componentes Independentes. Já para os métodos de segmentação não supervisionada, foi utilizado o Filtro de Gabor e o algoritmo clássico de clusterização *K-means*. Para concluir, foi comparado e analisado os resultados obtidos nas diferentes aplicações. Esta seção tem como função mostrar como todo esse processo foi feito.

Na segmentação supervisionada, temos a Análise de Componentes Independentes (ICA), que é o método capaz de determinar as fontes que originaram uma determinada mistura a partir de um treinamento, supondo que essas fontes são mutuamente independentes. Logo, primeiramente foram selecionadas as 12 imagens dentro de um conjunto de imagens para serem as fontes do treinamento e depois foram definidos os parâmetros relevantes a serem observados.

Após a obtenção da função discriminante pelo algoritmo, os parâmetros não relevantes foram eliminados e assim, os testes com as imagens fora do conjunto de treinamento puderam ser feitos, resultando então nas imagens finais a serem analisadas pelo pesquisador. Na Figura 24, tem-se a ilustração do algoritmo supervisionado no editor do MATLAB.

Figura 24: Ilustração do algoritmo ICA no editor do MATLAB



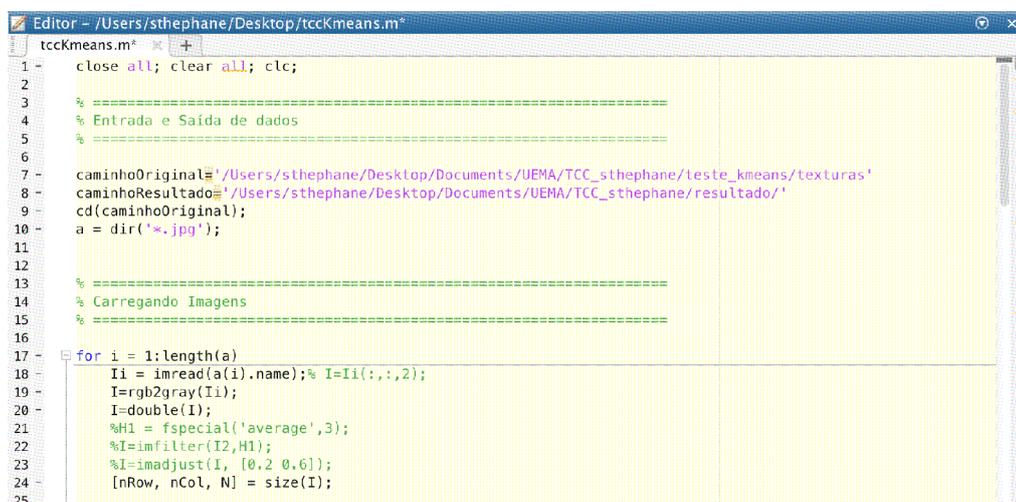
```

1 - clear
2 - caminhoTreinamento='/Users/sthephane/Desktop/TCC_bibliografia/TCC_Imagens/imgs treinamento'
3 - caminhoImagensTeste='/Users/sthephane/Desktop/TCC_bibliografia/TCC_Imagens/imgs finais'
4 - caminhoResultado='/Users/sthephane/Desktop/TCC_bibliografia/4 Resultados/ica'
5 - %1. Realizando o Treinamento dos filtros
6 - %1.1 Preparando as amostras
7 -
8 - caminhoTreinamento='/Users/sthephane/Desktop/TCC_bibliografia/TCC_Imagens/imgs treinamento'
9 - cd(caminhoTreinamento);
10 - samples=1000; %numero de amostras
11 - winsize=20; %tamanho da janela
12 - rdim=400; % tamanho do vetor do filtro
13 - [X, whiteningMatrix, dewhiteningMatrix] = data( samples, winsize, rdim );
14 - X=X';
15 -
16 - %1.2 Gerando os filtros
17 - pcomponents=winsize;
18 - [Y,W,A]= aapomagro(X,pcomponents);
19 -
20 - % 1. Criando filtros
21 - for iii=1:pcomponents
22 -     F=A(:,iii);
23 -     F = F - min(reshape(F, [], 1)); F = F / max(reshape(F, [], 1));
24 -     F=reshape(F,winsize,winsize);
25 -     B(:, :, iii) = F;
26 - end

```

Fonte: Própria do Autor

Na segmentação não supervisionada, temos o algoritmo *K-means*, método esse em que o algoritmo seleciona grupos de dados pela sua proximidade, detectando um número ótimo de classes, e os Filtros de Gabor, onde a imagem é convoluída a partir das funções utilizadas pelos filtros de Gabor, extraindo assim os atributos de texturas presentes na imagem. Como são algoritmos não supervisionados, não foi preciso selecionar imagens para treinamento, logo os testes com as imagens selecionadas foram diretamente realizados. Nas Figura 25 e Figura 26, tem-se a ilustração dos algoritmos não supervisionados no editor do MATLAB.

Figura 25: Ilustração do algoritmo *K-means* no editor do MATLAB


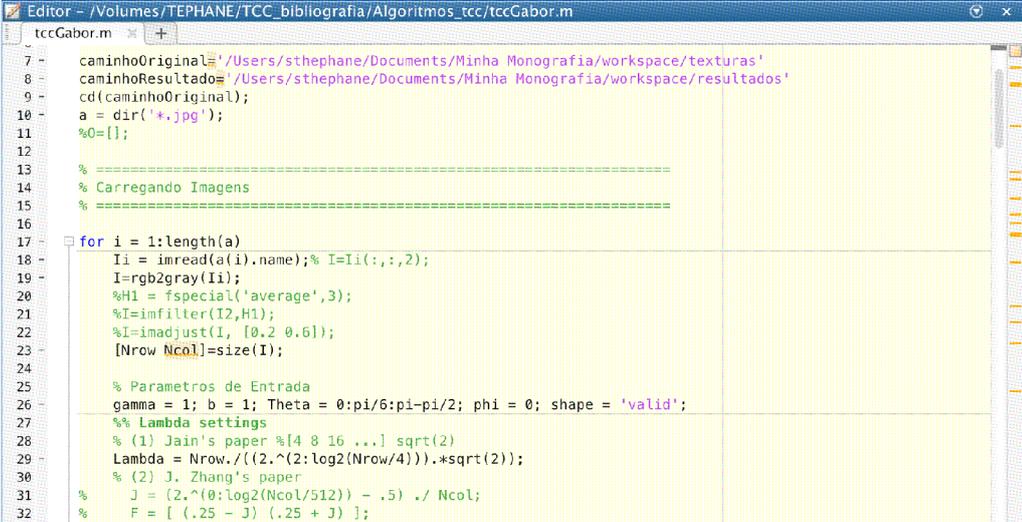
```

1 - close all; clear all; clc;
2 -
3 - % =====
4 - % Entrada e Saída de dados
5 - % =====
6 -
7 - caminhoOriginal='/Users/sthephane/Desktop/Documents/UEMA/TCC_sthephane/teste_kmeans/texturas'
8 - caminhoResultado='/Users/sthephane/Desktop/Documents/UEMA/TCC_sthephane/resultado/'
9 - cd(caminhoOriginal);
10 - a = dir('*.jpg');
11 -
12 -
13 - % =====
14 - % Carregando Imagens
15 - % =====
16 -
17 - for i = 1:length(a)
18 -     Ii = imread(a(i).name); % I=Ii(:,:,2);
19 -     I=rgb2gray(Ii);
20 -     I=double(I);
21 -     %H1 = fspecial('average',3);
22 -     %I=imfilter(I2,H1);
23 -     %I=imadjust(I, [0.2 0.6]);
24 -     [nRow, nCol, N] = size(I);
25 -

```

Fonte: Própria do Autor

Figura 26: Ilustração do algoritmo de Gabor no editor do MATLAB



```

7 - caminhoOriginal='/Users/sthephane/Documents/Minha Monografia/workspace/texturas'
8 - caminhoResultado='/Users/sthephane/Documents/Minha Monografia/workspace/resultados'
9 - cd(caminhoOriginal);
10 - a = dir('*.jpg');
11 - %0=[];
12
13 % =====
14 % Carregando Imagens
15 % =====
16
17 for i = 1:length(a)
18     Ii = imread(a(i).name);% I=Ii(:, :,2);
19     I=rgb2gray(Ii);
20     %H1 = fspecial('average',3);
21     %I=imfilter(I2,H1);
22     %I=imadjust(I, [0.2 0.6]);
23     [Nrow Ncol]=size(I);
24
25     % Parametros de Entrada
26     gamma = 1; b = 1; Theta = 0:pi/6:pi-pi/2; phi = 0; shape = 'valid';
27     %% Lambda settings
28     % (1) Jain's paper %[4 8 16 ...] sqrt(2)
29     Lambda = Nrow./((2.^(2:log2(Nrow/4))).*sqrt(2));
30     % (2) J. Zhang's paper
31     J = (2.^(0:log2(Ncol/512)) - .5) ./ Ncol;
32     F = [ (.25 - J) (.25 + J) ];

```

Fonte: Própria do Autor

3.2 Síntese do Processo

Com a finalidade de melhor esclarecer como ocorreu toda a metodologia aplicada nessa pesquisa, foi desenvolvido um resumo de todo o processo, como mostra a Tabela 1.

Tabela 1: Síntese do processo

Item	Quantidade ou Sigla
Total texturas usadas nos testes	até 100
Total imagens utilizadas no treinamento	12
Total imagens selecionadas do banco de Brodatz	112
Total de métodos aplicados	3
Total de imagens com 4 texturas distintas	20
Total de imagens com 5 texturas distintas	20
Total de imagens obtidas para análise	120
Softwares utilizados	MATLAB e PhotoScapeX

Fonte: Própria do Autor

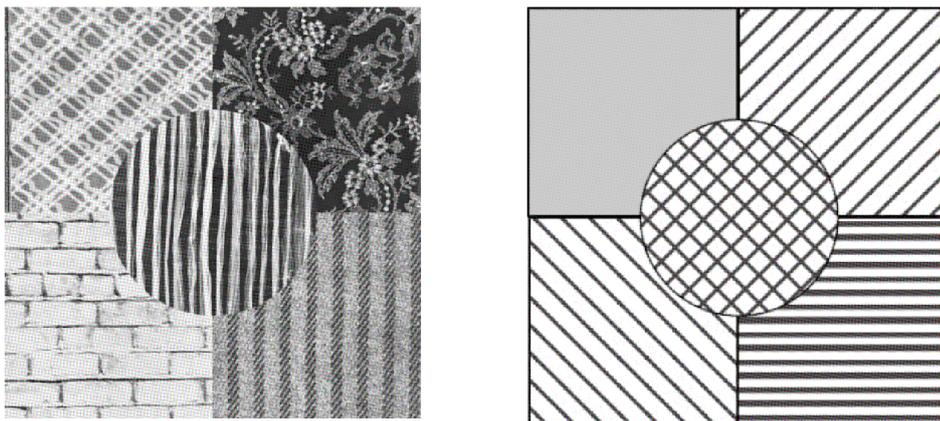
4 RESULTADOS E DISCUSSÕES

A proposta do trabalho está centrada em analisar as técnicas de segmentação utilizadas nas imagens. Este capítulo apresenta os resultados da aplicação do processo de segmentação sobre as imagens constituídas por diferentes texturas disponíveis no banco de imagens de Brodatz (1966) e, por consequência, discute qual dos métodos, nas configurações estabelecidas, apresentou melhor performance. Todas as imagens utilizadas no processo de segmentação situam-se no final do trabalho e ao final deste capítulo encontra-se a discussão dos resultados.

4.1 Apresentação dos Resultados

Os resultados obtidos com a aplicação dos métodos de segmentação são apresentados nesta seção. As imagens que foram usadas no processo de cada método apresentado neste trabalho, demonstram o efeito de cada uma das técnicas estudadas. Posteriormente, propõe-se uma discussão relatando as principais diferenças entre os resultados observados das técnicas executadas. As informações relevantes serviram como dados para análise dos resultados. Na Figura 27 abaixo são mostrados o exemplo de uma imagem composta por cinco texturas distintas e o resultado de uma segmentação ideal da imagem.

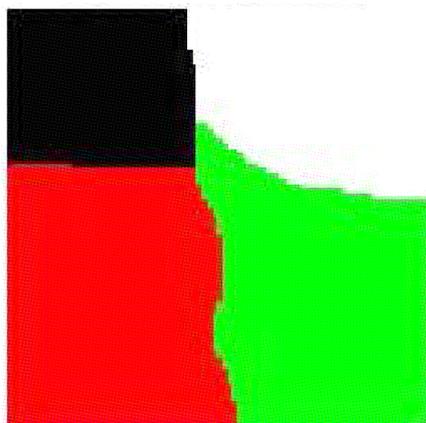
Figura 27: Objetivo da segmentação de texturas



Fonte: (JAIN; TUCERYAN, 1993)

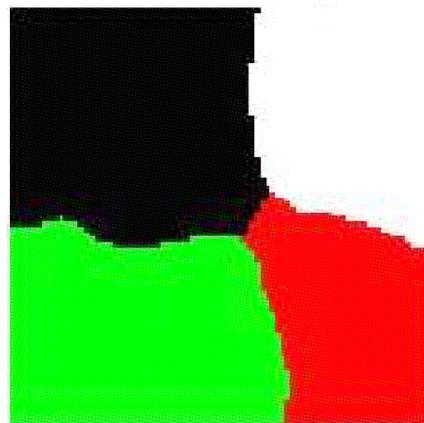
Foi gerado um total de 120 imagens resultantes da aplicação dos 3 métodos sobre as 20 imagens compostas por 5 tipos diferentes de textura e sobre 20 imagens constituídas por 4 combinações diferentes das texturas selecionadas. Da Figura 28 até a Figura 51 são exibidos alguns exemplos da performance dos métodos de segmentação aplicados sobre as imagens.

Figura 28: Resultado 1 (Gabor)



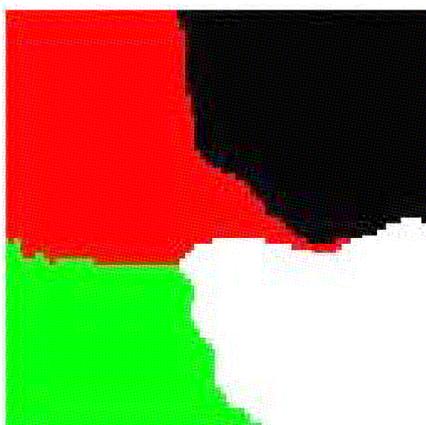
Fonte: Própria do Autor

Figura 29: Resultado 2 (Gabor)



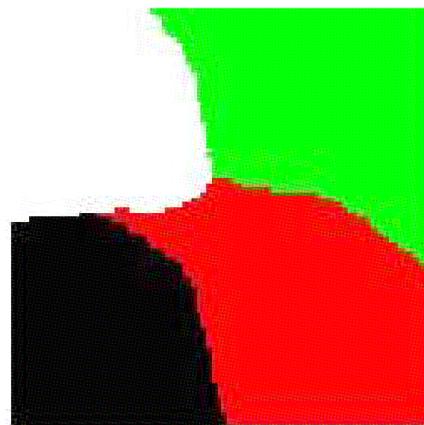
Fonte: Própria do Autor

Figura 30: Resultado 3 (Gabor)



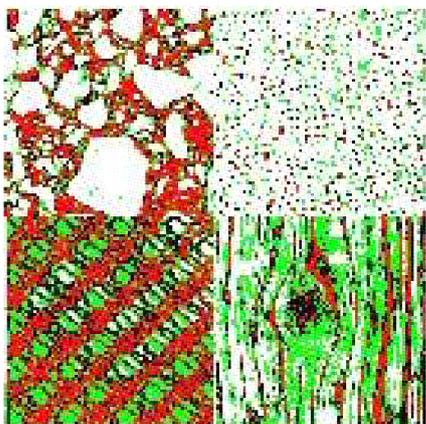
Fonte: Própria do Autor

Figura 31: Resultado 4 (Gabor)



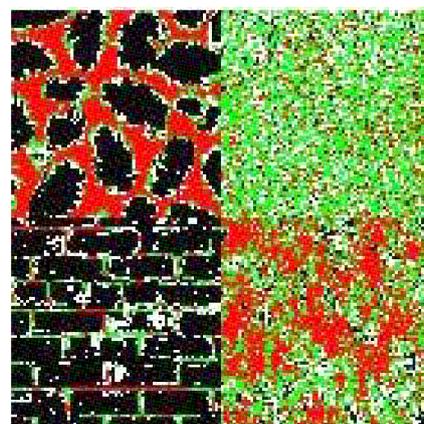
Fonte: Própria do Autor

Figura 32: Resultado 5 (*K-means*)



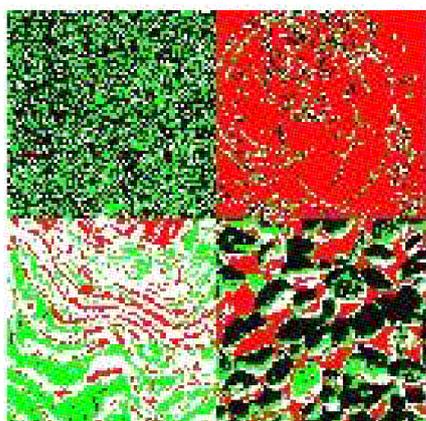
Fonte: Própria do Autor

Figura 33: Resultado 6 (*K-means*)



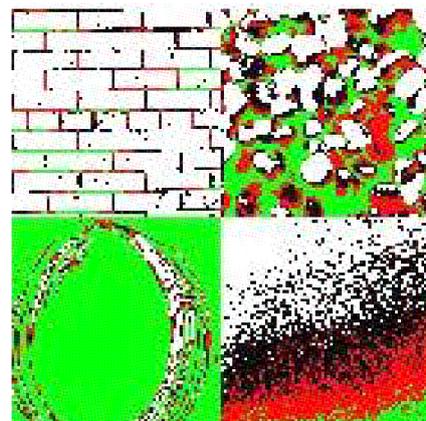
Fonte: Própria do Autor

Figura 34: Resultado 7 (*K-means*)



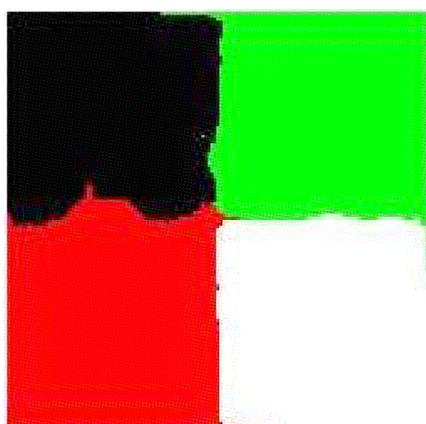
Fonte: Própria do Autor

Figura 35: Resultado 8 (*K-means*)



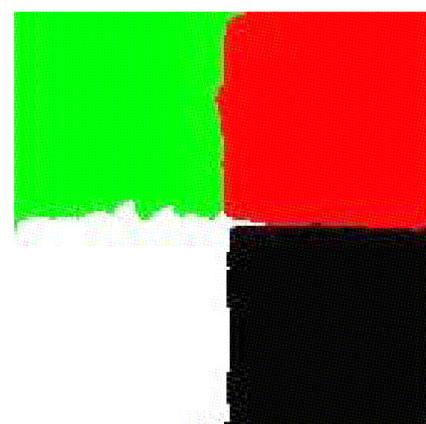
Fonte: Própria do Autor

Figura 36: Resultado 9 (ICA)



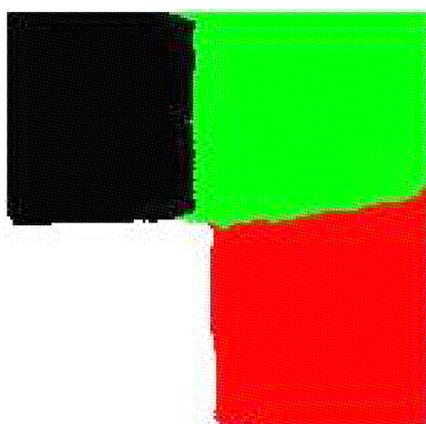
Fonte: Própria do Autor

Figura 37: Resultado 10 (ICA)



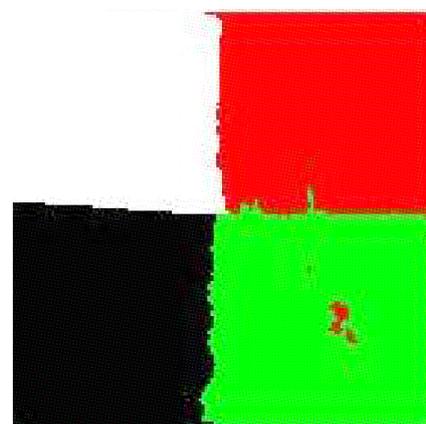
Fonte: Própria do Autor

Figura 38: Resultado 11 (ICA)



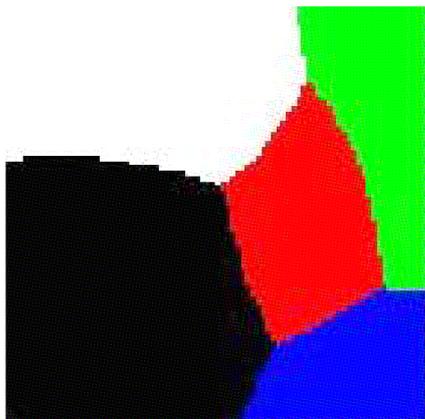
Fonte: Própria do Autor

Figura 39: Resultado 12 (ICA)



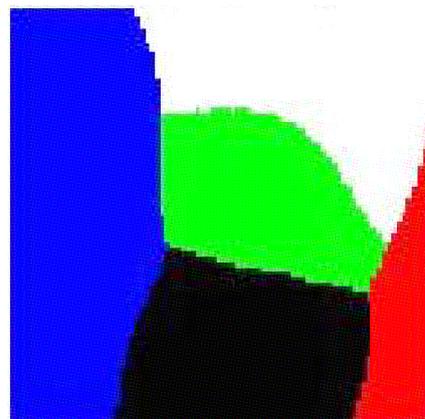
Fonte: Própria do Autor

Figura 40: Resultado 13 (Gabor)



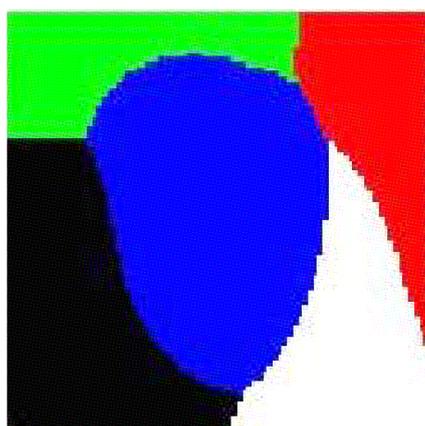
Fonte: Própria do Autor

Figura 41: Resultado 14 (Gabor)



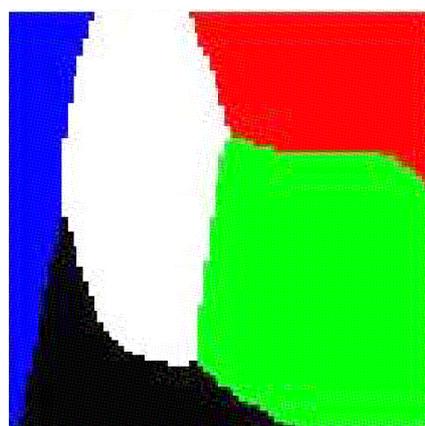
Fonte: Própria do Autor

Figura 42: Resultado 15 (Gabor)



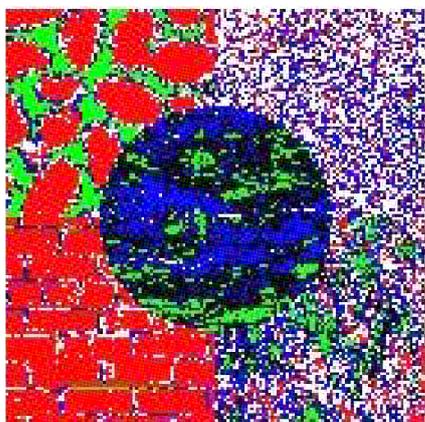
Fonte: Própria do Autor

Figura 43: Resultado 16 (Gabor)



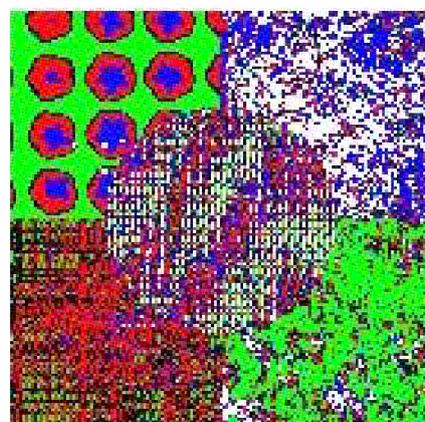
Fonte: Própria do Autor

Figura 44: Resultado 17 (*K-means*)



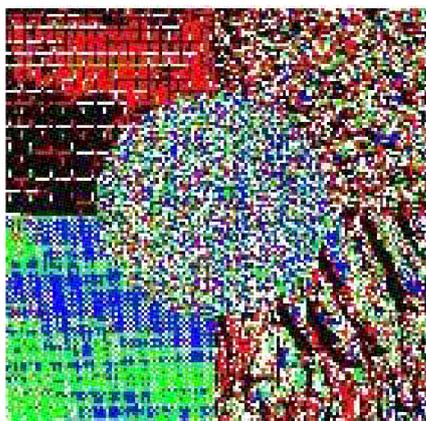
Fonte: Própria do Autor

Figura 45: Resultado 18 (*K-means*)



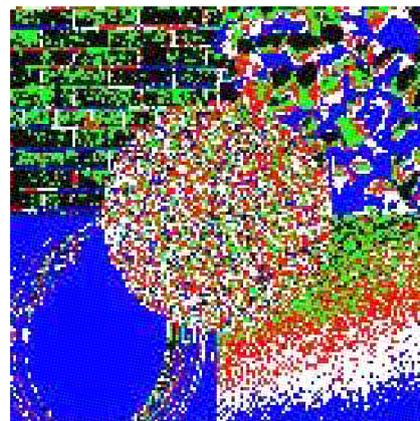
Fonte: Própria do Autor

Figura 46: Resultado 19 (*K-means*)



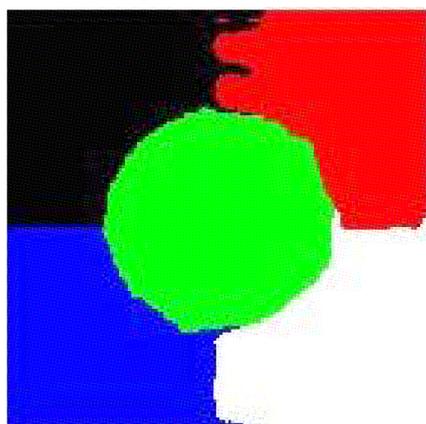
Fonte: Própria do Autor

Figura 47: Resultado 20 (*K-means*)



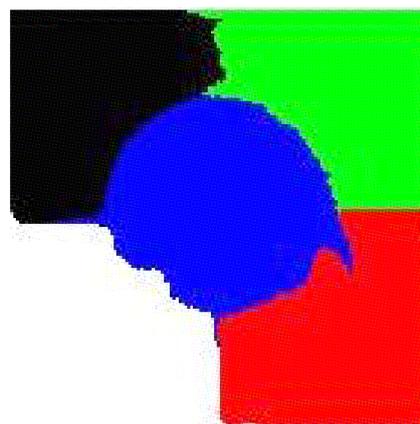
Fonte: Própria do Autor

Figura 48: Resultado 21 (ICA)



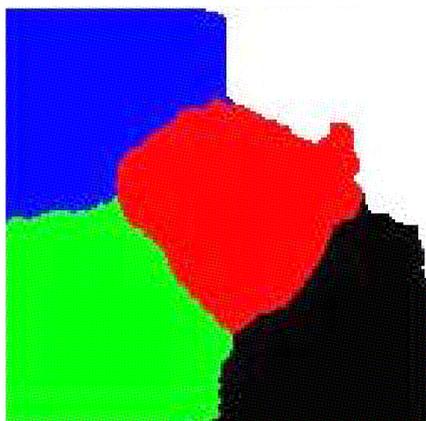
Fonte: Própria do Autor

Figura 49: Resultado 22 (ICA)



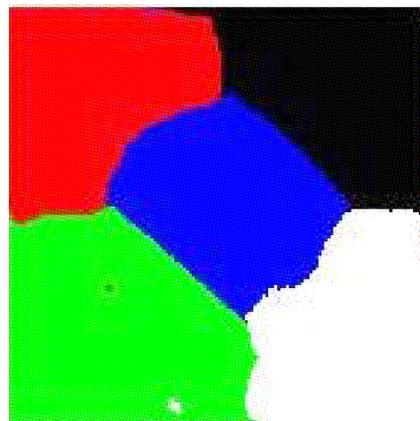
Fonte: Própria do Autor

Figura 50: Resultado 23 (ICA)



Fonte: Própria do Autor

Figura 51: Resultado 24 (ICA)



Fonte: Própria do Autor

4.2 Discussão dos Resultados

O processo de análise apesar de ser aparentemente simples, envolve muitas variáveis (GONZAGA, 2007). Analisar é uma tarefa complexa, onde o homem busca sempre avaliar as situações em termos dos padrões das circunstâncias que as constituem e descobrir relações existentes no meio, para melhor entendê-lo e adaptar-se. Já a interpretação envolve a fixação de significado a um grupo de objetos reconhecidos, em outras palavras, estamos interessados em dar significados a imagem (GONZALEZ; WOODS, 2010).

Ainda segundo Gonzalez e Woods (2010), "quando uma imagem é processada para a interpretação visual, o observador é o juiz em relação ao desempenho de um método particular". Baseado nisso, ponderou-se a opinião do pesquisador na análise dos resultados obtidos no processo de segmentação. Logo, fez-se uma análise prática e visual dos resultados e definiu-se como o melhor método de segmentação, aquele que apresentou desempenho superior em relação aos demais.

Mas antes, alguns aspectos foram levados em consideração para que a análise pudesse de fato ser realizada, expostos a seguir:

- Definição prévia do modo de aquisição e seleção das imagens e das ferramentas a serem utilizadas;
- Tratamento da imagem, para que os resultados não sofressem interferências que prejudicassem ou impossibilitassem a análise;
- Segmentação das imagens, diminuindo assim a área de dados a ser analisada, assim como o tempo gasto para a análise.

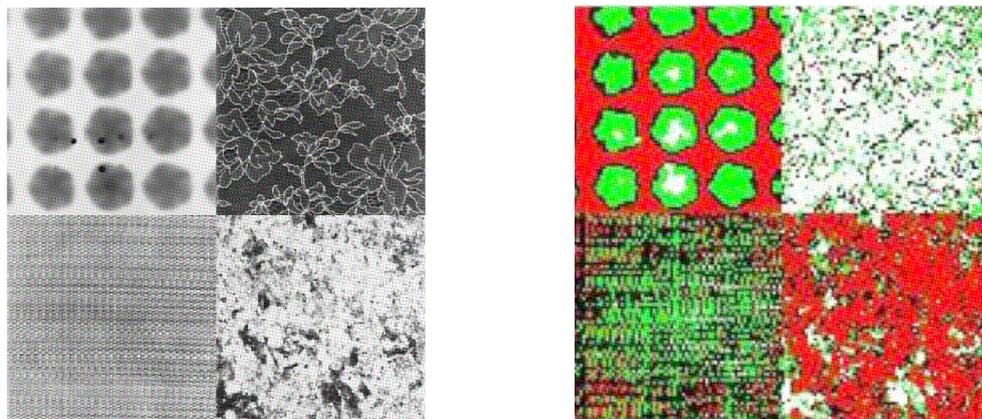
Somente após estas etapas foi feito a análise das imagens, para que assim, pudessem ser minimizados possíveis erros no resultado final da pesquisa. Desse modo, comenta-se sobre os três métodos (*K-means*, Filtro de Gabor e Análise de Componentes Independentes) a seguir e sobre os resultados obtidos, tendo em vista que o trabalho mostra técnicas de segmentação diferentes, mas com o mesmo objetivo.

4.2.1 *K-means*

Em relação à performance, o algoritmo foi o que retornou a solução menos satisfatória. Acredita-se que o algoritmo funciona muito bem somente quando muitos elementos estão disponíveis na imagem original ou quando esse algoritmo é combinado com outras técnicas. Uma tentativa que foi feita para contornar esse problema foi executá-lo várias vezes, levando-se em consideração que ele é o algoritmo mais rápido em relação aos outros, porém a resposta retornada ainda não foi bem-sucedida. Se a imagem não for bem segmentada, pode-se conseguir resultados estranhos, que foi o que aconteceu nesse caso. Por fim, percebeu-se que vários atributos texturais e bem delimitados são necessários para uma

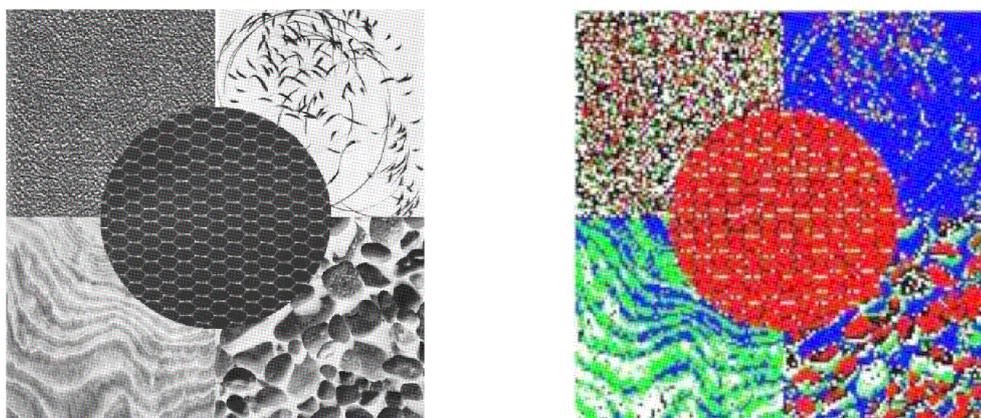
correta segmentação. Porém, quanto mais atributos, mais complexo se tornaria o problema. Abaixo, nas Figura 52 e Figura 53, estão os resultados das imagens segmentadas pelo algoritmo *K-means*.

Figura 52: Resultado da segmentação com *K-means* em 4 texturas distintas



Fonte: Própria do Autor

Figura 53: Resultado da segmentação com *K-means* em 5 texturas distintas



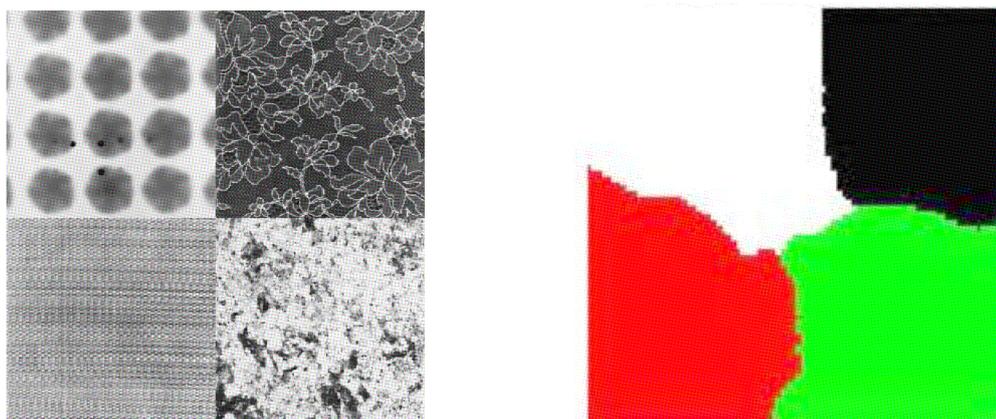
Fonte: Própria do Autor

4.2.2 Filtros de Gabor

Para o desenvolvimento do método de segmentação utilizando os Filtros de Gabor, foram estudados alguns conceitos sobre textura, convolução e extração de atributos. Em seguida foi realizado um estudo mais aprofundado sobre os filtros de Gabor, como forma de melhorar o entendimento sobre o assunto para a execução da técnica. Nesse método, a imagem é convoluída com todo o banco de filtros pois o processo de convolução da imagem é realizado com cada um dos filtros de Gabor, tendo por resultado uma imagem filtrada para

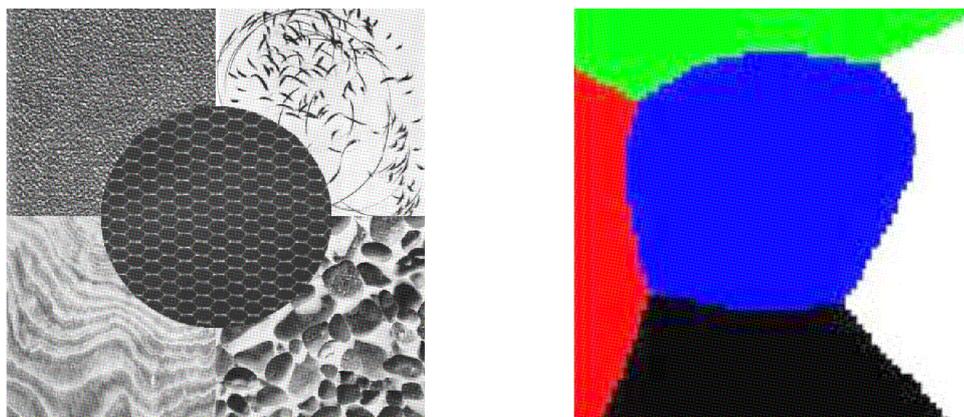
cada filtro. Através dos resultados obtidos foi possível verificar que o método utilizando os filtros de Gabor não apresentou o melhor desempenho entre os métodos de extração utilizados, pois não conseguiu preservar as bordas da imagem original. Entretanto, ele conseguiu efetuar bem a extração das características texturais, como mostra as Figura 54 e Figura 55 abaixo:

Figura 54: Resultado da segmentação com Gabor em 4 texturas distintas



Fonte: Própria do Autor

Figura 55: Resultado da segmentação com Gabor em 5 texturas distintas



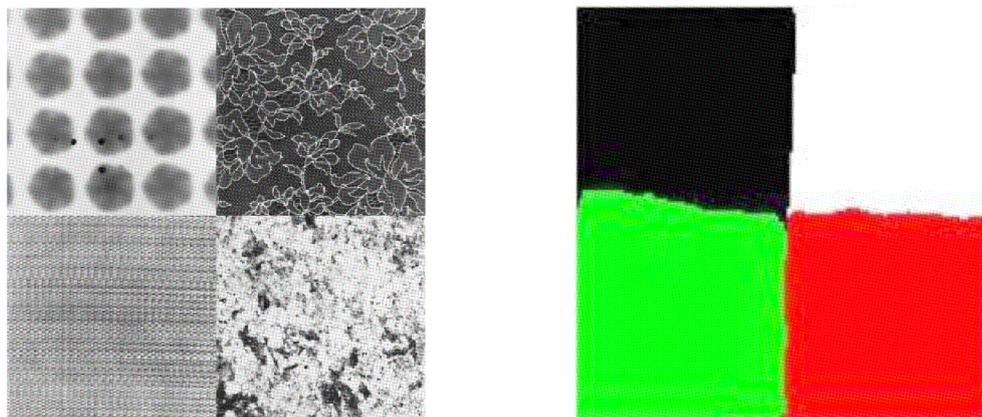
Fonte: Própria do Autor

4.2.3 Análise de Componentes Independentes

A última técnica analisada consistiu em aproximar uma região de interesse, extraída de uma imagem digital por uma soma ordenada de imagens-base mutuamente independentes, obtidas a partir de um grupo de imagens selecionadas para o treinamento. Esse treinamento foi efetuado utilizando 12 imagens, previamente selecionadas para a execução do método.

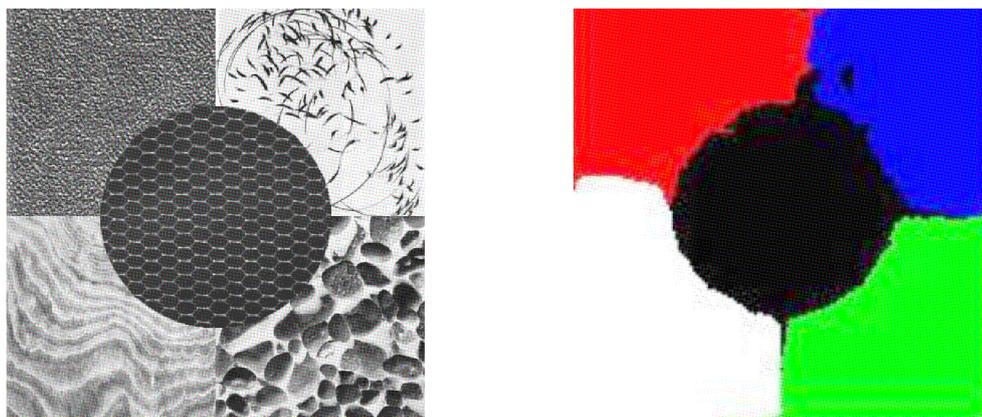
Considerando os resultados atingidos, o método obteve uma taxa notável de imagens segmentadas corretamente. Quer dizer, essa técnica apresentou uma correlação positiva entre o objetivo e os resultados observados, pois os erros encontrados foram considerados muito baixos em relação aos outros métodos estudados, como pode se observar nas Figura 56 e Figura 57 abaixo:

Figura 56: Resultado da segmentação com ICA em 4 texturas distintas



Fonte: Própria do Autor

Figura 57: Resultado da segmentação com ICA em 5 texturas distintas



Fonte: Própria do Autor

Sintetizando, para desenvolver o trabalho, analisou-se os métodos *K-means*, Filtro de Gabor e Análise de Componentes Independentes com o objetivo de segmentar imagens a partir da extração de suas características texturais e, por meio dos resultados, percebeu-se que a Análise de Componentes Independentes foi a técnica que apresentou melhores resultados.

5 CONCLUSÃO

Quando estamos no contexto de processamento de imagens científicas, são necessárias as operações de segmentação que procurarão isolar regiões e as operações de extração de atributos que vão olhar para essas regiões e calcular uma série de parâmetros previamente estabelecidos. Uma vez com esses parâmetros coletados, as regiões na imagem são distinguidas e agrupadas de acordo com suas características semelhantes encontradas para cada região. Feito isso, as regiões segmentadas serão analisadas e pode-se então relatar fatos relacionados aos resultados. Desta forma, é muito importante realizar uma seleção adequada dos atributos disponíveis, visando otimizar o processo.

No entanto, as definições encontradas explicam muito pouco sobre as dificuldades inerentes e limitações práticas envolvidas neste problema. Uma imagem consiste de um array de *pixels* e o objetivo da segmentação é dar um nome a cada um deles de forma que possamos agrupá-los em regiões. Uma região é formada por um grupo de *pixels* que possui o mesmo nome, mas nem sempre é possível definir claramente a fronteira que separa duas amostras de texturas diferentes. Por isso é importante perceber que, para a segmentação propriamente dita, não é necessário identificar quais texturas foram usadas e sim, onde ficam as fronteiras entre as texturas diferentes.

Sendo assim, essa pesquisa trabalhou com o objetivo de segmentar uma imagem de acordo com seus atributos de textura. Esse trabalho foi desenvolvido a partir de informações pesquisadas em outros trabalhos referentes a essa área, além das análises feitas de acordo com os resultados, a partir de imagens constituídas por diferentes texturas que foram selecionadas do banco de imagens de Brodatz e com a utilização de referidas ferramentas de *software* nos dias atuais.

Na etapa de preparação, foi necessário pré-tratar a imagem de acordo com as necessidades da pesquisa isso porque a segmentação é uma das tarefas mais difíceis em processamento de imagens. Para gerar os resultados, usou-se 3 métodos de segmentação de imagens: *Kmeans*, Gabor e ICA. Pode-se notar que as técnicas de segmentação apresentadas, são técnicas tradicionais no cenário do processamento digital e produziram um resultado satisfatório para o objeto de estudo desse trabalho. Uns métodos funcionaram de acordo com o proposto no trabalho mas outros nem tanto e partindo dessa análise, foi desenvolvida uma conclusão como forma de explicar sobre os resultados alcançados pelo uso da aplicação dessas técnicas de segmentação.

Como conclusão, as texturas apresentadas nas imagens foram melhor segmentadas pela técnica de Análise de Componentes Independentes, pois esta preservou bem as bordas e manteve aspectos importantes das imagens originais. Por sua vez, o método de Gabor conseguiu extrair bem as texturas, mas não preservou adequadamente as fronteiras das texturas. Já o método clássico *K-means*, extraiu muito pouco as texturas e deixou a

imagem muito embaçada, não conseguindo segmentar a imagem de forma satisfatória. No geral, o método da Análise de Componentes Independentes foi o que obteve melhor resultado, o Filtro de Gabor não foi muito eficiente e o *K-means* não efetuou de modo preciso a segmentação.

Então, pode-se concluir que a Análise de Componentes Independentes apresentou os resultados mais satisfatórios se comparado aos demais na segmentação de imagens baseada em atributos de textura, e que essa técnica foi a mais eficiente entre os demais métodos apresentados nesse trabalho, pela forma como dividiu a imagem em regiões, manteve os aspectos originais da imagem, preservou bem as bordas e não apresentou muitas distorções. Apesar de esse método ter apresentado bons resultados, é preciso testá-lo em outros contextos para determinar a sua eficiência em outras situações.

O estudo foi importante pois pode-se analisar os métodos com a melhor performance na área de segmentação. Porém não é aconselhável que esse trabalho seja a única referência para os trabalhos futuros. No entanto, ele pode e deve ser utilizado como ferramenta de apoio para os pesquisadores nas suas futuras pesquisas.

5.1 Trabalhos futuros

Existem muitas outras possibilidades de testes e implementações a serem feitas com os métodos de segmentação de texturas. Como sugestões para trabalhos futuros, recomenda-se, por exemplo, algumas modificações e realização de mais testes, visando avaliar de forma mais completa o resultado final dessa pesquisa. Algumas outras sugestões seriam:

- Utilização das técnicas de segmentação propostas neste trabalho porém envolvendo diferentes tipos de imagens: imagens monocromáticas, imagens médicas, imagens de satélite, imagens de paisagens, entre outras opções. Esta sugestão envolve situações reais onde a Análise de Componentes Independentes poderia ser comparada com outros modelos;
- Analisar outros algoritmos de segmentação de imagens e fazer um estudo aprofundado de outras técnicas, como por exemplo, o *Watershed*;
- Além disso, é possível realizar permutações para combinar atributos ou técnicas para comparar algoritmos de segmentação. Por exemplo, poderia ser aplicado um método geométrico para extrair texturas, compará-las através de redes neurais e segmentá-las usando Filtros de Gabor;
- Implementar um programa que receba e trate as imagens de forma que o pesquisador tenha um acesso mais rápido à imagem melhorada de acordo com as suas necessidades ou preferências.

O estudo de segmentação de imagens, seja ele por métodos supervisionados ou não supervisionados, é imprescindível nos tempos atuais levando em consideração a importância que esse tema possui para a área de processamento digital, visão computacional e todos os seus segmentos. Este trabalho contribuiu para mostrar que é possível segmentar de maneira significativa as imagens digitais e a partir disso, outros pesquisadores poderiam estar testando esses métodos em imagens de mamografias para detecção de melanomas, ou então em ultrassonografias, raio x e outras imagens médicas, por exemplo. Além disso, a seguinte pesquisa foi importante para analisar e comparar os métodos de segmentação por uma perspectiva diferente da tradicionalmente abordada, mostrando que os modelos clássicos podem estar sendo melhorados para que haja uma melhor performance nos trabalhos futuros. Por fim, é interessante que se tenha dado esse passo no estudo de técnicas de segmentação baseada em atributos de textura na Universidade Estadual do Maranhão, tendo em vista a importância desse tipo de segmento nos mais variados tipos de situações no dia-a-dia.

Referências

- ACHARYA, T.; RAY, A. K. *Image processing, principles and applications*. [S.l.]: John Wiley and Sons Inc., 2005.
- ALBUQUERQUE, M. P. de; ALBUQUERQUE, M. P. de. *Processamento de imagens: métodos e análises*. [S.l.: s.n.], 2001.
- BALLARD, D.; BROWN, C. *Computer Vision*. [S.l.]: Prentice-Hall Inc., 1982.
- BELUCO, A.; ENGEL, P. M. Classificação de imagens de sensoriamento remoto baseada em textura por redes neurais. In: *Anais XI SBSR*. [S.l.: s.n.], 2003. p. 1999 – 2006.
- BILLERBECK, D. G. *CMOS Fundamentals*. 2014. Disponível em: <http://www.siliconimaging.com/cmos_fundamentals.htm>. Acesso em: 12 out 2016.
- BLANZ, W.; GISH, S. A connectionist classifier architecture applied to image segmentation. In: *Proc. 10 th ICPR*. [S.l.: s.n.], 1990. p. 272–277.
- BRITTO, A. S. J. *Segmentação por cor utilizando a transformada de Karhunen Loève*. Dissertação (Mestrado), 1996.
- BRODATZ, P. *Textures: a Photographic Album for Artists and Designers*. [S.l.]: Dover, 1966.
- CASTLEMAN, K. R. *Digital Image Processing*. [S.l.]: Prentice Hall Inc., 1996.
- CBPF, C. B. de P. F. *Matlab: Curso Introdotório*. 2002. Disponível em: <http://mesonpi.cat.cbpf.br/e2002/cursos/NotasAula/Tutorial_matlab.pdf>. Acesso em: 25 ago 2016.
- COLE, R. M. *Clustering with Genetic Algorithms*. 110 p. Dissertação (Mestrado), 1998.
- CONCI, A.; AZEVEDO, E.; LETA, F. *Computação Gráfica: Teoria e Prática*. [S.l.]: Elsevier, 2008. v. 2.
- CRUZ, C. Unsupervised texture segmentation using stochastic version of the em algorithm and data fusion. 1998.
- DAMASIO, M. J. *Imagem digital*. 2015. Disponível em: <<http://www.arte-coa.pt/index.php?Language=pt&Page=Saberes&SubPage=ComunicacaoELinguagemImagem&Menu2=ImagemVirtual>>. Acesso em: 02 set 2016.
- DAUGMAN, J. G. *Two-Dimensional Spectral Analysis of Cortical Receptive Field Profile*. [S.l.]: Vision Research, 1980. v. 20. 847-856 p.
- DENG, Y.; MANJUNATH, B. S. Unsupervised segmentation of color-texture regions in images and video. 2001.
- DOKUR, Z.; OLMEZ, T. *Segmentation of ultrasound images by using a hybrid neural network*. [S.l.]: Pattern Recognition Letters , 2002. v. 23:14. 1825-1836 p.
- DUDA, R.; HART, P.; STORK, D. *Pattern Classification*. [S.l.]: John Wiley & Sons, 2001.

- EBERT, D. S. *Texturing and Modeling: A Procedural Approach*. [S.l.]: Cambridge: Academic Press, 1994.
- FACON, J. *Estudo sobre Fractal*. Dissertação (Mestrado), 2002.
- FAUGERAS, O. D.; PRATT, W. K. *Decorrelation methods of texture feature extraction*. [S.l.]: IEEE Transactions on Pattern Analysis and Machine Intelligence, 1980. v. 2. 323–332 p.
- FORSYTH, D.; PONCE, J. *Computer Vision – A modern approach*. 2. ed. [S.l.]: Prentice Hall, 2002.
- FRANCO, A. *Aplicação da análise de componentes independentes em estudo de eventos em finanças*. Tese (Doutorado), 2008.
- FRED, A. L. N. Finding consistent clusters in data partitions. In: *Proceedings of the 2nd International Workshop on multiple Classifier Systems*. [S.l.: s.n.], 2001. v. 2096, p. 209–318.
- FU, K. S.; MUI, J. K. *A survey on image segmentation*. [S.l.]: Pattern Recognition, 1980. v. 13. 3-16 p.
- GILAT, A. *MATLAB com aplicações em engenharia*. 2. ed. [S.l.]: Bookman, 2006.
- GONZAGA, A. *Reconhecimento e interpretação de imagens*. 2007. Disponível em: <<http://iris.sel.eesc.sc.usp.br/sel886>>. Acesso em: 17 ago 2016.
- GONZALES, R. C.; WOODS, R. E.; EDDINS, S. L. *Digital Image Processing using MATLAB*. [S.l.]: Pearson Education Inc., 2004.
- GONZALEZ, R. C.; WOODS, R. C. *Digital Image Processing*. [S.l.]: University of Tennessee Perceptics Corporation, Knoxville, Tennessee, 1992.
- GONZALEZ, R. C.; WOODS, R. C. *Processamento de imagens digitais*. [S.l.]: Edigard Blücher LTDA, 2000.
- GONZALEZ, R. C.; WOODS, R. C. *Digital Image Processing*. 2. ed. [S.l.]: Prentice Hall, 2002.
- GONZALEZ, R. C.; WOODS, R. C. *Processamento Digital de Imagens*. 3. ed. [S.l.]: Pearson Prentice Hall, 2010.
- HARALICK, R. *Statistical and Structural Approaches to Texture*. [S.l.]: Proceedings of the IEEE, 1979. v. 67, No. 5. 786-803 p.
- HARALICK, R. M. Texture features for image classification. n. 6, p. 610 – 621, 1973.
- HYVARINEN, A.; KARHUNEN, J.; OJA, E. *Independent Component Analysis*. [S.l.]: John Wiley & Sons Inc., 2001.
- JAIN, A.; MURTY, M.; FLYNN, P. J. *Data Clustering: A Review*. 3. ed. [S.l.]: ACM Computing Surveys, 1999. v. 31. 264-323 p.
- JAIN, A. K.; TUCERYAN, M. Texture analysis. p. 235–276, 1993.

- JI, Y.; CHANG, K. H.; HUNG, C.-C. Efficient edge detection and object segmentation using gabor filters. In: *Proceedings of the 42nd annual Southeast Regional Conference*. [S.l.: s.n.], 2004. p. 454–459.
- JULEZ, B. *Visual Pattern Discrimination*. [S.l.]: IRE Transactions on Information Theory, 1962. 84–92 p.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: active contour models. In: *First International Conference on Computer Vision*. [S.l.: s.n.], 1987. p. 259–268.
- KOLOSSOSKI, G. *Segmentação de imagens e algoritmo K-means*. Trabalho de Conclusão de Curso, 2007.
- KRUIZINGA, P.; PETKOV, N. Grating cell operator features for oriented texture segmentation. In: *Proceeding of the 14th International Conference on Pattern Recognition*. [S.l.: s.n.], 1998. p. 1010–1014.
- KRUIZINGA, P.; PETKOV, N. Comparison of texture features based on gabor filters. In: *Proceedings of the 10th International Conference on Image Analysis and Processing*. [S.l.: s.n.], 1999. p. 142.
- LEITE, I. C. *Análise de componentes independentes aplicada a avaliação de imagem radiográfica de sementes*. Tese (Doutorado), 2013.
- LEITE, L. *Análise de Componentes Independentes aplicada à identificação de regiões lesionadas em mamografias*. Tese (Doutorado), 2005.
- LEITE, R. *Aplicação de Estereoscopia em Imagens Digitais*. Trabalho de Conclusão de Curso, 2014.
- LEITE, V. *Separação cega de sinais: análise comparativa entre algoritmos*. Dissertação (Mestrado), 2004.
- LINDEN, R. Técnicas de agrupamento. n. 4, p. 18–36, 2009.
- LOVERGINE, F. et al. Leather inspection by oriented texture analysis with a morphological approach. In: *International Conference on Image Processing*. [S.l.: s.n.], 1997. v. 2, p. 669.
- MACQUEEN, J. B. Some methods for classification and analysis of multivariate observations. In: *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*. [S.l.: s.n.], 1967. v. 1, p. 281–297.
- MARQUES, O.; VIEIRA, H. *Processamento Digital de Imagens*. [S.l.]: Brasport, 1999. ISBN 8574520098.
- MATTANA, M. F. *Avaliação da Qualidade da Segmentação por Binarização de Cheques Bancários a partir do Processo de Reconhecimento*. Dissertação (Mestrado), 1999.
- MELLO, C.; MASCARO, A. Image fidelity index applied to digital mamography texture segmentation. In: *Conferência Latino Americana de Informática*. [S.l.: s.n.], 2006.

- MONGELO, A. I. *Validação de método baseado em visão computacional para automação da contagem de viabilidade de leveduras em indústria alcooleiras*. Dissertação (Mestrado), 2012.
- NASCIMENTO, T. *Segmentação não supervisionada de texturas baseada no algoritmo PPM*. Dissertação (Mestrado), 2010.
- OKADA, M.; MALAYAPPAN, S. Extraction of user entered components from a personal bankcheck using morphological subtraction. v. 11, n. 5, p. 699–715, 1997.
- OLIVEIRA, P. *Métodos auto organizáveis para segmentação de imagens*. Tese (Doutorado), 2004.
- PARKER, J. R. *Algorithms for Image Processing and Computer Vision*. [S.l.]: John Wiley & Sons, 1997.
- PASQUALI, A. L. *Extração de características utilizando filtro Gabor aplicado à identificação de defeitos no couro bovino*. Trabalho de Conclusão de Curso (Engenharia de Computação), 2007.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*. [S.l.]: Thomson Learning, 2008.
- PELI, T.; MALAH, D. *A Study of Edge Detection Algorithms*. [S.l.]: Computer Graphics Image Process, 1982. 121 p.
- QUEIROZ, J.; GOMES, H. Introdução ao processamento digital de imagens. VIII, n. 1, 2001.
- QUINTA, L. et al. Classificação de leveduras para o controle microbiano em processos de produção de etanol. In: *VI Workshop de Visão Computacional (VI WCV)*. [S.l.: s.n.], 2010.
- REBOUCAS, S.; SOUSA, L.; PIRES, A. *Metodologias de classificação supervisionada para análise de dados de microarrays*. Tese (Doutorado), 2009.
- RIBEIRO, G. *Reconhecimento de imagens de doenças da maçã com redes neurais artificiais*. Trabalho de Conclusão de Curso, 2003.
- RUZON, M. *Texture Segmentation: an Introduction Primer*. 1997. Disponível em: <http://robotics.stanford.edu/~ruzon/tex_seg/>. Acesso em: 25 nov 2016.
- SANDLER, R.; LINDENBAUM, M. Gabor filter analysis for texture segmentation. In: *Computer Vision and Pattern Recognition Workshop*. [S.l.: s.n.], 2006.
- SANTANA, E. *Segmentação não supervisionada de Imagens de Sensoriamento Remoto por minimização da Entropia Cruzada*. Dissertação (Mestrado), 2012.
- SANTOS, J. C. Extração de atributos de forma e seleção de atributos usando algoritmos genéticos para classificação de regiões. 2007.
- SANTOS, M.; ANGELO, N. *Aplicação do Filtro de Gabor associado ao Classificador de Máxima Verossimilhança Gaussiana na segmentação de imagens baseadas em características texturais*. Trabalho de Conclusão de Curso (Ciências da Computação), 2007.

- SCHALKOFF, R. J. *Pattern Recognition: Statistical, Structural and Neural Approaches*. [S.l.]: John Wiley & Sons, 1992.
- SCURI, A. E. *Fundamentos da Imagem Digital*. [S.l.: s.n.], 2002.
- SIQUEIRA, H. *SCD: UMA FERRAMENTA PARA EXTRAÇÃO DE INFORMAÇÃO DE SINAIS NA PELE PARA IDENTIFICAÇÃO DE MELANOMA*. Trabalho de Conclusão de Curso (Engenharia da Computação), 2014.
- SKLANSKY, J. Image segmentation and feature extraction. v. 13, n. 5, 1978.
- SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, Analysis and Machine Vision*. [S.l.]: Thomson, 2008.
- TAGLIAFERRO, F. A. *Técnicas de reconhecimento automatizado de padrões baseados em imagens digitais*. 44 p. Trabalho de Conclusão de Curso (Ciência da Computação), 2007.
- TRIBUJ, M.; WAISBAUM, A. *Segmentación de imágenes texturadas*. Tesis de Licenciatura en Ciencias de la Computación, 2006.
- VISA, A. A genetic algorithm based method to improve image segmentation. In: *Proceeding of the 14th International Conference on Pattern Recognition*. [S.l.: s.n.], 1998. p. 1015–1017.
- WANGENHEIN, A. V. Introdução à visão computacional. In: *Universidade Federal de Santa Catarina - UFSC*. [S.l.: s.n.], 2001.
- WELDON, T. P.; HIGGINS, W. E.; DUNN, D. F. Gabor filter design for multiple texture segmentation. In: *Optical Engineering*. [S.l.: s.n.], 1996.
- ZIZZARI, A. et al. Detection of tumor in digital images of the brain. In: *Proceeding of the IASTED*. [S.l.: s.n.], 2001.

APÊNDICE A – Imagens criadas e utilizadas na segmentação

