



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS DE SOBRAL**  
**CURSO DE ENGENHARIA DA COMPUTAÇÃO**

**LUCAS ROCHA AGUIAR**

**ANÁLISE DE TECIDOS NORMAIS E ANORMAIS DE IMAGENS DE EXAMES DE  
PAPANICOLAU POR MEIO DE VISÃO COMPUTACIONAL**

**SOBRAL – CE**

**2014**

**LUCAS ROCHA AGUIAR**

**ANÁLISE DE TECIDOS NORMAIS E ANORMAIS DE IMAGENS DE EXAMES DE  
PAPANICOLAU POR MEIO DE VISÃO COMPUTACIONAL**

Monografia apresentada ao Curso de Engenharia da Computação da Universidade Federal do Ceará, como requisito parcial à obtenção do título de bacharel em Engenharia da Computação.

Orientador: Prof. Dr. Jarbas Joaci de Mesquita Sá Junior.

**SOBRAL – CE**

**2014**

**LUCAS ROCHA AGUIAR**

**ANÁLISE DE TECIDOS NORMAIS E ANORMAIS DE IMAGENS DE EXAMES DE  
PAPANICOLAU POR MEIO DE VISÃO COMPUTACIONAL**

Monografia apresentada ao Curso de Engenharia da Computação da Universidade Federal do Ceará, como requisito parcial à obtenção do título de bacharel em Engenharia da Computação.

Orientador: Prof. Dr. Jarbas Joaci de Mesquita Sá Junior.

Aprovada em: \_\_\_/\_\_\_/\_\_\_\_\_.

**BANCA EXAMINADORA**

---

Prof. Dr. Jarbas Joaci de Mesquita Sá Junior (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Esp. Edilson Rocha Porfírio Filho  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Iális Cavalcante de Paula Júnior  
Universidade Federal do Ceará (UFC)

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca do *Campus* de Sobral

---

A229a      Aguiar, Lucas Rocha.

Análise de tecidos normais e anormais de imagens de exames de Papanicolau por meio de  
visão computacional / Lucas Rocha Aguiar. – 2014.

44 f. : il., color, enc. ; 30 cm.

Monografia (graduação) – Universidade Federal do Ceará, *Campus* de Sobral, Curso de  
Engenharia da Computação, Sobral, 2014.

Orientação: Prof. Dr. Jarbas Joaci de Mesquita Sá Junior.

1. Engenharia da Computação - Análise de Texturas. 2. Células Sadias e Cancerosas - Visão  
Computacional. I. Título.

---

CDD 621.3

Dedico em primeiro lugar a Deus.

Em seguida, aos meus pais, Maria Inês de Aguiar e José Maria Aguiar e também à minha namorada Camylla Rocha da Silva pelo apoio.

## AGRADECIMENTOS

À UFC – Campus Sobral, pelo apoio e estrutura fornecida ao longo da minha formação acadêmica, oferecendo bolsas de todas as modalidades e também laboratórios para reforçar o aspecto prático do curso.

Ao Prof. Dr. Jarbas Joaci de Mesquita Sá Junior, pela excelente orientação neste trabalho.

Aos professores participantes da banca examinadora: meu orientador, Jarbas Joaci de Mesquita Sá Junior, ao coordenador do curso de Engenharia da Computação do Campus de Sobral, Iális Cavalcante de Paula Júnior, ao professor Edilson Rocha Porfírio Filho e também a coordenadora da vertente de Ciências da Computação, Andréa Carneiro Linhares pelo tempo e pelas valiosas colaborações e sugestões.

A todos os professores com os quais tive contato em todas as disciplinas que cursei e que me ensinaram sobre os mais variados assuntos ao longo do meu percurso.

A todos os colegas da Engenharia da Computação e Elétrica pelas reflexões, críticas e sugestões recebidas e pelo companheirismo ao longo de todos esses anos em que estou no curso.

Ao meu amigo Túlio Arruda da Ponte Lopes, que com seus conhecimentos aprofundados em inglês pôde me auxiliar na seção *Abstract*.

Ao meu amigo Alcides Andrade Neto pela valiosa contribuição na parte de programação no MATLAB.

À minha amiga Dalva Alana Aragão de Azevedo pela ajuda na revisão textual na seção de Resultados e Discussões.

“A simplicidade é a extrema sofisticação.”

(Leonardo da Vinci)

## RESUMO

A partir de imagens de células oriundas de exames de Papanicolau, deseja-se analisar e avaliar com o auxílio da Visão Computacional se elas são saudáveis ou cancerosas. A principal motivação por trás do desenvolvimento deste estudo é a dificuldade na identificação a olho nu de algumas particularidades desse tipo de célula, já que não é simples de diferir visualmente um tipo do outro. A partir da divisão dessas células em dois grupos, deseja-se verificar se o sistema é capaz de detectar e caracterizar células saudáveis e cancerosas. Neste projeto são utilizados alguns métodos de Análise de Texturas, como as Estatísticas de Primeira Ordem e as Matrizes de Co-ocorrência. Os vetores de características obtidos através desses métodos serão então classificados pelo método LDA (*Linear Discriminant Analysis*). Para a implementação do projeto foi utilizado o software MATLAB, por meio do qual foram realizados vários experimentos com o intuito de demonstrar a viabilidade deste projeto. O objetivo final foi conseguir um percentual de acerto o mais elevado possível, encontrando um resultado na faixa de 78,63% de acerto com o primeiro método e de 80,81% com o segundo.

**Palavras-chave:** Papanicolau. Células Saudáveis e Cancerosas. Visão Computacional. Texturas.



## **ABSTRACT**

By using cell images from Pap tests, this project aims to evaluate, with computer perspective aid, if these cells are healthy or cancerous. The main motivation behind the development of this study is the difficulty in identifying through naked eye some particularities of this type of cell, since it is not easy to distinguish one type from another. Dividing these cells into two groups, healthy and cancerous, this work verifies if the system is able to detect and characterize those different kinds of cells. This scientific exposition has used some analysis of texture methods, such as First Order Statistics and Co-occurrence Matrices. The feature vectors acquired from these methods will be then classified by the LDA method (Linear Discriminant Analysis). For the implementation of this project, the software MATLAB was used. By using this software, several experiments were performed in order to demonstrate the feasibility of this project. The final goal was to achieve the highest possible percentage of correct answers, finding a result in the range of 78.63% to hit with the first method, and approximately 80.81% with the latter.

**Keywords:** Pap Smear. Cancerous and Healthy Cells. Computer Vision. Textures.

## LISTA DE FIGURAS

Figura 1 – Útero, Vagina e visão frontal do Colo Uterino.....	5
Figura 2 – Amostra de Exame de Papanicolau diagnosticado como normal.....	6
Figura 3 – Infestação por <i>Trichomonas Vaginalis</i> .....	6
Figura 4 – Sete classes representadas por uma amostra cada.....	8
Figura 5 – Pixels de um Monitor LCD.....	9
Figura 6 – Subáreas da Computação Gráfica.....	10
Figura 7 – Fluxograma de um sistema de Visão Computacional.....	12
Figura 8 – Textura de um campo de pequenas pedras.....	13
Figura 9 – Imagem contendo 5 diferentes tipos de textura.....	14
Figura 10 – Orientação de profundidade representada pelos tijolos.....	14
Figura 11 – Imagem de ultrassom de um coração.....	15
Figura 12 – Imagem aérea utilizando sensores de radar de abertura sintética (SAR).....	15
Figura 13 – Matriz de Exemplo de uma Imagem.....	18
Figura 14 – Construção de uma Matriz de Co-ocorrência.....	18
Figura 15 – Matriz resultado para o número de ocorrências na horizontal.....	18
Figura 16 – Matriz resultado para número de ocorrências na vertical.....	19

## LISTA DE TABELAS

Tabela 1 – Utilizações comuns de um Sistema de Visão Computacional.....	11
Tabela 2 – Taxas de Acerto das Combinações 3x3 das Estatísticas de 1ª Ordem.....	25
Tabela 3 – Taxas de Acerto das Combinações 4x4 das Estatísticas de 1ª Ordem.....	26
Tabela 4 – Taxas de Acerto das Combinações 5x5 das Estatísticas de 1ª Ordem.....	27
Tabela 5 – Maiores e menores taxas de acerto para as Estatísticas de 1ª Ordem.....	27
Tabela 6 – Taxas de Acerto das Combinações 3x3 das Matrizes de Co-ocorrência.....	28
Tabela 7 – Taxas de Acerto das Combinações 4x4 das Matrizes de Co-ocorrência.....	29
Tabela 8 – Taxas de Acerto das Combinações 5x5 das Matrizes de Co-ocorrência.....	30
Tabela 9 – Maiores e menores taxas de acerto para as Matrizes de Co-Ocorrência.....	31

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>1</b>
<b>2</b>	<b>OBJETIVOS</b> .....	<b>3</b>
<b>3</b>	<b>JUSTIFICATIVA</b> .....	<b>4</b>
<b>4</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>5</b>
<b>4.1</b>	<i>Exame de Papanicolau</i> .....	<b>5</b>
<b>4.2</b>	<i>Base de imagens Pap Smear</i> .....	<b>8</b>
<b>4.3</b>	<i>Imagens Digitais</i> .....	<b>9</b>
<b>4.4</b>	<i>Visão Computacional</i> .....	<b>10</b>
<b>4.4.1</b>	<i>Etapas de um Sistema de Visão Computacional</i> .....	<b>11</b>
<b>4.5</b>	<i>Análise de Texturas</i> .....	<b>13</b>
<b>4.6</b>	<i>Métodos de Extração de Características das Imagens</i> .....	<b>16</b>
<b>4.6.1</b>	<i>Estatísticas de Primeira Ordem</i> .....	<b>16</b>
<b>4.6.2</b>	<i>Matrizes de Co-ocorrência</i> .....	<b>17</b>
<b>4.7</b>	<i>Classificando as Imagens</i> .....	<b>20</b>
<b>4.7.1</b>	<i>Método LDA</i> .....	<b>20</b>
<b>4.7.2</b>	<i>Estratégias de Validação Cruzada</i> .....	<b>21</b>
<b>5</b>	<b>METODOLOGIA</b> .....	<b>23</b>
<b>6</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>24</b>
<b>6.1</b>	<i>Taxas de Acerto das Estatísticas de Primeira Ordem</i> .....	<b>24</b>
<b>6.2</b>	<i>Taxas de Acerto das Matrizes de Co-ocorrência</i> .....	<b>28</b>
<b>7</b>	<b>CONCLUSÕES</b> .....	<b>32</b>
<b>8</b>	<b>REFERÊNCIAS</b> .....	<b>33</b>

## 1 – INTRODUÇÃO

Um importante aliado na detecção e prevenção de um tipo de câncer que tem afligido a muitas mulheres, o câncer de colo do útero, é o Exame de Papanicolau.

O câncer de colo do útero é o segundo tipo mais incidente na população feminina brasileira. Com cerca de 530 mil novos casos por ano no mundo, é responsável pelo óbito de 274 mil mulheres por ano (WHO, 2008a), o que impulsionou o Programa Viva Mulher, criado em 1996. Com ele, o controle do câncer de colo uterino foi dito ser uma prioridade na Política Nacional de Atenção Oncológica (INCA, 2005) e no Pacto pela Saúde (BRASIL, 2006).

O presente trabalho tem por finalidade auxiliar na análise de células retiradas de exames de Papanicolau com o intuito de investigar se essa célula pertence a uma mulher sadia ou portadora de câncer.

Para que o êxito do projeto seja alcançado, serão utilizados alguns conceitos da Visão Computacional e da Análise de Texturas para a averiguação e classificação das imagens das células supracitadas.

No transcorrer do trabalho será efetuada uma introdução teórica utilizando um mecanismo de raciocínio intuitivo, gradativamente apresentando o necessário para seguir à próxima etapa. Inicialmente será abordado o Exame de Papanicolau, pois este será o objeto de estudo do trabalho. Depois serão apresentados alguns conceitos importantes relacionados às imagens digitais. Em seguida, serão descritos brevemente os elementos essenciais de um sistema de Visão Computacional. Posteriormente, será explanado sobre a Análise de Texturas, que é uma subárea da Visão Computacional. Em seguida, serão mostrados os métodos para extração de características. Posteriormente, será apresentado o método para a classificação das imagens e a estratégia de validação cruzada utilizada para essa finalidade. Finalmente, serão discutidos os resultados dessa classificação.

O auxílio da Visão Computacional na área médica já é algo bastante comum. Existem várias aplicações na análise de imagens médicas. Como exemplo, podem-se citar os seguintes trabalhos encontrados na compilação “Avanços em Visão Computacional” (PEREIRA NEVES, VIEIRA NETO e GONZAGA, 2012):

- “Classificação estatística e predição da doença de Alzheimer por meio de imagens médicas do encéfalo humano” (FERNANDES *et al.*, 2011) que tem como objetivo identificar quais casos de Transtorno Cognitivo Leve poderão ser convertidos em Doença de Alzheimer;

- “Análise e caracterização de lesões de pele para auxílio ao diagnóstico médico” (ARAÚJO *et al.*, 2011), que visa detectar as áreas com lesões e extrair seus contornos;
- “Comparação de imagens tomográficas *cone-beam* e *multi-slice* através da entropia de Tsallis e da divergência de Kullback-Leibler” (SOBIECKI *et al.*, 2011), que analisa a distribuição de probabilidade de luminância entre imagens adquiridas de técnicas *cone-beam* e *multi-slice*, baseadas nos métodos citados;
- “Classificação e extração de características discriminantes de imagens 2D de ultrassonografia mamária” (XAVIER *et al.*, 2011), que utiliza métodos estatísticos univariados e multivariados com o objetivo de extrair informações discriminantes para fins de classificação de tumores mamários;
- “Auxílio ao diagnóstico do glaucoma utilizando processamento de imagens” (ANDERSSON e OLIVEIRA, 2011), que apresenta o desenvolvimento de um *software* para calcular termos inerentes ao diagnóstico do nervo óptico com impacto no campo visual;
- “Método para a obtenção de imagens coloridas com o uso de sensores monocromáticos” (VIEIRA e RODRIGUES, 2011), no qual é apresentada uma proposta para obtenção de imagens coloridas a partir de capturas monocromáticas com a cena iluminada em diferentes regiões do espectro visível. O sistema foi implementado em um retinógrafo digital e imagens do fundo do olho são mostradas como exemplo do funcionamento do sistema proposto.

## 2 – OBJETIVOS

O objetivo geral desse estudo é criar um sistema utilizando os conceitos de Visão Computacional e Análise de Texturas, que seja capaz de auxiliar um especialista no diagnóstico do Exame de Papanicolau.

Podemos descrever o problema em questão da seguinte forma: há dois grupos de imagens de células (normais e anormais), que já foram previamente classificadas por especialistas humanos na área. A meta é criar um sistema utilizando o MATLAB que consiga “aprender” o que caracteriza e diferencia uma célula sadia de uma com câncer. Posteriormente, esse sistema, através de um cálculo estimativo, deve ser capaz de predizer o grupo correto de uma nova imagem inserida no acervo.

Os objetivos específicos consistem em: aprender e reforçar conceitos importantes da Visão Computacional e da Análise de Texturas, bem como elaborar um estudo utilizando métodos estatísticos para maximizar a taxa de acertos do sistema em relação ao diagnóstico das imagens supracitadas.

### **3 – JUSTIFICATIVA**

A motivação deste projeto é a dificuldade dos especialistas humanos em reconhecer entre uma célula normal e uma anormal a olho nu. Para que eles efetuem essa distinção, há um longo período de treinamento dos profissionais da área.

Sem qualquer tipo de assistência por parte do computador, em alguns casos, fica muito difícil a identificação devido às similaridades que há entre essas células, uma vez que não apresentam diferenças muito acentuadas.

Nesse contexto, um sistema de Visão Computacional é uma ferramenta bastante poderosa e eficaz para dar uma segunda opinião para o especialista humano, o que reforçará ainda mais o seu diagnóstico. Não se almeja substituir o diagnóstico do especialista, mas sim, dar uma base para fazê-lo ter mais convicção nessa tarefa. Por exemplo, se o profissional disser que a paciente está com câncer e o sistema confirmar isso também, então se pode reforçar a veracidade do diagnóstico.



## 4 – REVISÃO BIBLIOGRÁFICA

### 4.1 – Exame de Papanicolau

O exame de Papanicolau é um teste ginecológico realizado como uma forma de prevenção ao câncer de colo uterino. Ele serve como um teste para saber se a mulher tem o câncer ou se tem grandes possibilidades de vir a desenvolvê-lo. Quando o câncer é detectado cedo, facilita todo o tratamento e o diagnóstico da paciente enferma, e assim, há mais chances de impedir o crescimento dele. O nome “Papanicolau” remete a seu criador, o grego George Nicholas Papanicolaou, que é considerado o pai da citopatologia (JANTZEN e DOUNIAS, 2006).

Na Figura 1 pode ser visualizado o sistema reprodutor feminino, mostrando a região do corpo e colo do útero e a vagina, bem como uma visão frontal do colo uterino.




Figura 1: Útero, vagina e visão frontal do colo uterino (MOREIRA, 2012).

O procedimento consiste na coleta de material do colo uterino com uma espátula especial, procedimento conhecido como esfregaço. Após ser feita essa retirada, esse material é colocado em uma lâmina, a qual posteriormente será analisada por um citopatologista no microscópio.

O esfregaço de Papanicolau é utilizado principalmente para diagnosticar estados pré-cancerosos e cancerosos da vulva, o que inclui a vagina e o colo uterino. Ele também é utilizado para avaliação hormonal e para diagnosticar doenças inflamatórias. Como o Exame de Papanicolau é de grande importância na detecção inicial de câncer, é recomendado para que mulheres acima de 20 anos façam o exame ao menos uma vez por ano (PEREYRA e PARELLADA, 1994).

Na Figura 2, pode ser visto um exemplo de amostra normal coletada de uma mulher sadia através do exame de Papanicolau.




Figura 2: Amostra de Exame de Papanicolau diagnosticado como normal (CAGLIOSTRO, 2005).

O exame de Papanicolau consegue reduzir aproximadamente em 80% a incidência de câncer nas mulheres submetidas frequentemente a esse rastreamento. A taxa média de falso-negativo é de cerca de 20% e a taxa de falso-positivo varia entre 10% a 30% (PEREYRA e PARELLADA, 1994).

Na Figura 3 é ilustrado um exemplo de amostra de Exame de Papanicolau diagnosticando que a paciente apresenta uma anomalia conhecida como “Infestação por *Trichomonas Vaginalis*”.




Figura 3: Infestação por *Trichomonas Vaginalis* (BROLLO, 2006).

A coloração de Papanicolau é considerada um padrão internacional de coloração cérvico-vaginal, e pode ser usada com diversos materiais (CLARK, 1973). O esfregaço cérvico-vaginal permite uma boa avaliação dos padrões inflamatórios, hormonais e oncológicos (GAMPEL e KOSS, 1997).

O diagnóstico de Papanicolau representa uma das tentativas de mais sucesso da ciência médica na prática de enfrentar a ameaça de câncer em humanos (JANTZEN e DOUNIAS, 2006).

#### 4.2 – Base de Imagens Pap Smear

A base de imagens de células de Papanicolau que foi utilizada neste estudo consiste em 917 amostras distribuídas em sete classes diferentes. Essas imagens foram coletadas no *Herley University Hospital* por meio de uma câmera digital e um microscópio. Cada uma dessas imagens foi analisada manualmente por dois cito-técnicos habilitados. As amostras que apresentavam certa dificuldade no diagnóstico foram também avaliadas por um especialista na área. No caso de haver não-concordância na opinião dos três, a amostra era descartada. Dessa forma, podemos concluir que essa base de dados representa diagnósticos confiáveis e precisos, relevando as restrições práticas e econômicas desse hospital, já que só permaneceram as imagens que foram ratificadas pelos três. (JANTZEN *et al.*, 2005).

As sete classes nas quais as 917 imagens foram divididas variam do estágio mais normal possível da célula ao mais canceroso. São elas: Epitelial Escamosa Superficial (74 imagens), Epitelial Escamosa Intermediária (70 imagens), Epitelial Colunar (98 imagens), Displasia Não-queratinizada Escamosa Branda (182 imagens), Displasia Não-queratinizada Escamosa Moderada (146 imagens), Displasia Não-queratinizada Escamosa Severa (197 imagens) e Carcinoma de Células Escamosas *in situ* Intermediário (150 imagens). As três primeiras classes citadas são consideradas como normais e possuem 242 imagens no acervo. Já as quatro últimas classes são consideradas como anormais e possuem as 675 imagens restantes da base de dados. Na Figura 4 são ilustradas cada uma dessas sete classes.




Figura 4: Sete classes representadas por uma amostra cada.

- (a) Epitelial Escamosa Superficial. (b) Epitelial Escamosa Intermediária. (c) Epitelial Colunar.  
 (d) Displasia Não-queratinizada Escamosa Branda. (e) Displasia Não-queratinizada Escamosa Moderada.  
 (f) Displasia Não-queratinizada Escamosa Severa. (g) Carcinoma de células escamosas *in situ* intermediário.

### 4.3 – *Imagens Digitais*

Uma imagem pode ser considerada como uma representação visual de objetos, podendo ser adquirida (fotos, filmes) ou gerada (pinturas, desenhos) (CONCI, AZEVEDO e LETA, 2008).

A imagem digital é uma representação de uma imagem em uma região discreta, que é limitada através de um conjunto finito de valores inteiros representando cada um dos seus pontos. Para facilitar o entendimento, pode-se visualizar que cada imagem pode ser considerada como uma função  $(x, y)$  num plano cartesiano. As imagens digitais podem ser classificadas de diversas formas. Por exemplo, quanto à dimensão elas podem ser unidimensionais, bidimensionais ou tridimensionais. Se forem analisadas quanto ao conteúdo de cada um de seus pontos, elas também podem classificar-se como binárias (preto e branco), em tons de cinza ou coloridas. Já quanto à forma de descrição, elas podem ser vetoriais ou matriciais (CONCI, AZEVEDO e LETA, 2008).

Atualmente, as imagens digitais encontram-se difundidas nas mais diversas aplicações. O aumento de sua utilização se deve ao fato de que grande parte das informações que o ser humano obtém do mundo a sua volta são adquiridas através de imagens, seja no cotidiano, lendo livros ou em aplicações científicas, em que muitos dados são analisados a partir de fotografias.

Cada ponto de uma imagem é chamado de pixel (*picture element*). O pixel é uma amostra da imagem quantizada em valores inteiros. Ele pode ser convertido em unidades secundárias como o megapixel ( $10^6$  pixels), ressaltado quando se refere ao nível de qualidade da fotografia em câmeras digitais. Em outras palavras, cada ponto da imagem tem um valor que corresponde ao seu tom ou cor. Pode-se entender uma imagem como uma matriz de duas dimensões, em que cada termo da matriz corresponde a um pixel. Na Figura 5, tem-se uma imagem granulada pelos pixels de um Monitor LCD.




Figura 5: Pixels de um Monitor LCD (KUPFERMAN, 2000).

#### 4.4 – Visão Computacional

Uma área da Computação que tem crescido bastante e atraído mais pesquisadores é a da Visão Computacional. Ela atua na construção de sistemas que obtêm informações a partir de imagens digitais. Ela utiliza conceitos de Inteligência Artificial para esse propósito. Como o próprio nome diz, podemos compreendê-la como a “Visão do Computador”, ou seja, um complemento da visão biológica dos seres humanos. Em outras palavras, uma visão auxiliada pelo computador.

A Visão Computacional tem como principal objetivo a Análise de Imagens, que por sua vez é uma área da Computação Gráfica, que engloba três grandes áreas: a Síntese de Imagens, a Análise de Imagens e o Processamento de Imagens.

Na Figura 6, pode-se visualizar essa subdivisão de forma clara para melhor compreensão.

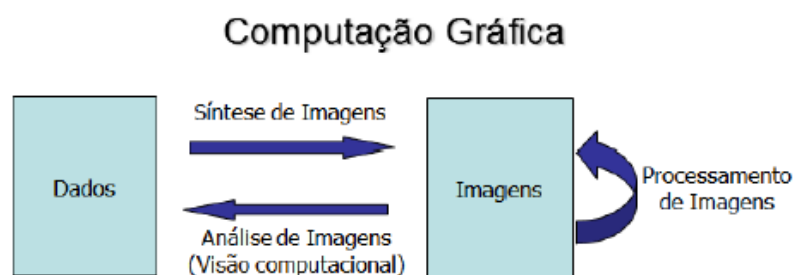


Figura 6: Subáreas da Computação Gráfica (GONÇALVES, 2013).

A diferença entre essas áreas está na relação que se faz entre o uso de dados e de imagens. Se os dados são usados para gerar as imagens, então a área considerada será a Síntese de Imagens. Se os dados forem resultado de informações adquiridas das imagens, então a área considerada será a Análise de Imagens. Se forem feitas transformações nas imagens, então a área considerada será o Processamento de Imagens (CONCI, AZEVEDO e LETA, 2008).

A Visão Computacional trata da extração de características das imagens e da identificação e classificação dos objetos presentes nessas imagens. Os sistemas de Visão Computacional vêm sendo utilizados em uma larga quantidade de aplicações. Se a imagem puder ser padronizada, a classificação será feita através do reconhecimento dessa imagem considerando um número de padrões possíveis (Reconhecimento de Padrões). Neste trabalho os padrões seriam “célula normal” e “célula anormal”.

Cada uma das áreas de aplicação da Visão Computacional descrita na Tabela 1 utiliza um conjunto de tarefas típicas.

Tabela 1: Utilizações comuns de um Sistema de Visão Computacional.

Tarefa	Função
Reconhecimento	Uma ou mais classes pré-definidas de objetos podem ser reconhecidas, geralmente em conjunto com sua posição em imagens bidimensionais ou tridimensionais.
Identificação	Uma instância individual de um objeto pode ser identificada, como, por exemplo, a identificação de uma face, de uma impressão digital, de um veículo, etc.
Detecção	A imagem é digitalizada para uma condição específica, como a detecção de células ou tecidos anormais.
Movimento	Uma sequência de imagens é processada para produzir uma estimativa da velocidade em cada ponto.
Reconstrução de Cena	Dadas duas ou mais imagens de um vídeo, visa-se computar um modelo tridimensional. Esse modelo consiste num conjunto de pontos tridimensionais, reconstrução de texturas e cores.
Restauração de Imagens	Remoção de ruídos.

#### ***4.4.1 – Etapas de um Sistema de Visão Computacional***

Nesta seção serão enumerados e aprofundados passo a passo todas as fases de um sistema típico de Visão Computacional.

A primeira etapa é adquirir e digitalizar a imagem. Como já foi dito na Seção 4.1, a imagem é previamente adquirida de uma lâmina de microscopia. Para que se possa trabalhar com essa imagem, ela tem de ser repassada para um computador. A esse processo de transpor a imagem do mundo real para dentro de um computador é o que se chama de “Digitalização”. Isso pode ser feito, por exemplo, através de um scanner. Pode-se então representar essa imagem em tons de cinza ou colorida no padrão RGB (*Red, Green, Blue*).

Depois da imagem digitalizada, o próximo passo é realçá-la, etapa denominada “Realce”. Nela, é necessário atribuir quais os objetos presentes na imagem que se deseja

avaliar com maior clareza e destacá-los em relação ao restante da imagem. Caso a imagem não esteja muito nítida, precisa-se primeiramente restaurar seus pontos importantes antes de passar à etapa de Realce.

A próxima etapa é de suma importância para o sistema. Trata-se de segmentar a imagem. “Segmentação” é a divisão de uma imagem digital em múltiplas regiões, com o objetivo de simplificar sua representação e facilitar sua análise. Segmentação de imagens é tipicamente usada para localizar objetos e formas em imagens (CONCI, AZEVEDO e LETA, 2008). Por exemplo, através da técnica de “Limiarização” separa-se cada objeto da imagem do fundo para se poder trabalhar com aquele objeto isoladamente, uma vez que eles apresentem um contraste suficiente com o fundo. Há inúmeras técnicas de segmentação, sendo que a natureza do problema define qual delas é a mais adequada (SÁ JUNIOR, 2008). Alguns tipos de segmentação comuns são: baseada em pixel, em detecção de bordas e em regiões.

Depois de segmentar a imagem, ou seja, separar todos os objetos dela, o próximo passo é extrair o que de fato se quer estudar da imagem. A essa etapa chama-se de “Extração de Características”. Nela que serão obtidos todos os dados relevantes das imagens, tais como os atributos que serão necessários. As características principais de análise são: cor, forma e textura. No caso do presente trabalho, irão ser analisados basicamente os tipos de textura das imagens.

Depois de extraídas as características, é preciso classificar as imagens e reconhecer os padrões que existem nelas, ou seja, a etapa de “Classificação”. Isso é feito através dos atributos obtidos na fase anterior. Com eles, é possível montar o vetor de atributos que será usado para classificar as imagens.

Um esboço esquemático, em ordem crescente, representando todas as etapas de um sistema de Visão Computacional que foram abordadas nesta seção, pode ser visualizado na Figura 7.



Figura 7: Fluxograma de um Sistema de Visão Computacional.



#### 4.5 – Análise de Texturas

Nesta seção é abordado o atributo que será analisado pelo sistema, ou seja, a textura da imagem.

Mesmo para os principais pesquisadores do tema, é muito difícil definir exatamente o que é de fato a textura da imagem. Em geral, as pessoas conseguem distinguir facilmente diferentes padrões de textura, mas o conceito de textura é de difícil definição.

Seja a seguinte analogia: A imagem da superfície de uma madeira não é uniforme, mas contém variações de intensidades que de certa forma repetem padrões chamados de textura visual. Por mais heterogênea e distinta que seja uma região retratada em uma imagem, em geral, pode-se observar um padrão que se repete ao longo dessa região (TUCERYAN e JAIN, 1998).

Como mais um exemplo didático, pode-se citar um azulejo áspero de um piso. Por mais áspero que ele seja, aquele conjunto de pontos em formato de grãos segue mais ou menos um padrão e isso é o que caracteriza a textura daquele piso. De fato, muitos autores têm a sua própria definição de textura. Em geral, essa definição é formulada dependendo da aplicação em particular e não há um consenso geral.

Como exemplo ilustrativo, nota-se a textura presente numa imagem de um campo de pequenas pedras presente na Figura 8.



Figura 8: Textura de um campo de pequenas pedras (TUCERYAN e JAIN, 1998).

Seja a seguinte definição: “a textura da imagem pode ser qualitativamente avaliada como tendo uma ou mais das propriedades de fineza, aspereza, suavidade, granulação, aleatoriedade, linearização, ou ser mosqueada, irregular ou acidentada” (HARALICK, 1979). Pode-se conferir um pouco dessas descrições acerca de textura analisando a imagem presente na Figura 9.



Figura 9: Imagem contendo 5 diferentes tipos de textura (TUCERYAN e JAIN, 1998).

Pelas formas apresentadas nos objetos da imagem da Figura 9, é possível ter uma noção da ideia de textura exposta. Em cada quadrante e no centro percebem-se as diferenças entre todos esses tipos de texturas, cada qual com seu formato particular. Outro exemplo pode ser visto na Figura 10, permitindo se ter uma boa noção de profundidade e superfície. Esse efeito é proporcionado através da textura dos tijolos e da forma como eles estão dispostos na imagem.



Figura 10: Orientação de profundidade representada pelos tijolos (TUCERYAN e JAIN, 1998).

A análise de texturas geralmente envolve quatro tipos distintos de classes de problemas: “Segmentação de Texturas”, “Classificação de Texturas”, “Síntese de Texturas” e “Formato de Texturas”. Através da análise de texturas, é possível construir vários tipos de aplicações nas mais variadas áreas, como a Medicina e a Astronomia. Exemplos disso são ilustrados nas Figuras 11 e 12.



Figura 11: Imagem de ultrassom de um coração (TUCERYAN e JAIN, 1998).



Figura 12: Imagem aérea utilizando sensores de radar de abertura sintética (SAR) (TUCERYAN e JAIN, 1998).

#### 4.6 – Métodos de Extração de Características das Imagens

Nas seções subsequentes os componentes práticos do projeto serão descritos, abordando-se os métodos que serão utilizados nas imagens para extrair as características delas (Estatísticas de Primeira Ordem e Matrizes de Co-ocorrência), bem como o método que será usado para classificar e reconhecer essas imagens depois de extraídos os atributos (Método LDA) e a estratégia de validação cruzada que será utilizada para a classificação (*Leave-One-Out*).

##### 4.6.1 – Estatísticas de Primeira Ordem

Assumindo que uma imagem digital pode ser vista como uma função  $f(x,y)$  de duas variáveis espaciais  $x$  e  $y$ , em que  $x = 0, 1, \dots, N-1$  e  $y = 0, 1, \dots, M-1$ . A função  $f(x,y)$  só pode assumir valores discretos de intensidade, com  $i = 0, 1, \dots, G-1$ , onde  $G$  é o maior valor dos níveis de intensidade de uma imagem.

O histograma de níveis de intensidade é uma função que mostra para cada nível de intensidade o número de pixels na imagem inteira, conforme mostra a equação (4.1):

$$h(i) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \delta(f(x,y), i), \quad (4.1)$$

em que  $\delta(j, i)$  é a função de Kronecker, dada pela relação (4.2):

$$\delta(j, i) = \begin{cases} 1, & j = i \\ 0, & j \neq i \end{cases} \quad (4.2)$$

O histograma de níveis de intensidade de uma imagem é um simples e resumido sumário da informação estatística contida na imagem (MATERKA e STRZELECKI, 1998). O cálculo do histograma de tons de cinza de uma imagem envolve apenas pixels simples. O histograma contém informação estatística de primeira ordem sobre a imagem ou parte dela.

Dividindo os valores do histograma pelo número total de pixels de uma imagem, se obtém a densidade de probabilidade aproximada de ocorrência dos níveis de intensidade, ou seja, o histograma mede a frequência de ocorrência daqueles determinados pixels na imagem (MATERKA e STRZELECKI, 1998).

Essa relação pode ser vista na equação (4.3):

$$P(i) = h(i)/NM \quad i = 0, 1, \dots, G - 1. \quad (4.3)$$

O histograma fornece muitas pistas das características da imagem. Diferentes parâmetros úteis podem ser adquiridos dele para descrição quantitativa das propriedades estatísticas de primeira ordem de uma imagem em relação à textura da mesma, tais como: média, variância, obliquidade, curtose, energia e entropia. Tais grandezas podem ser representadas pelas equações (4.4) a (4.9), respectivamente.

$$\mu = \sum_{i=0}^{G-1} iP(i) \quad (4.4)$$

$$\sigma^2 = \sum_{i=0}^{G-1} (i - \mu)^2 P(i) \quad (4.5)$$

$$\mu_3 = \sigma^{-3} \sum_{i=0}^{G-1} (i - \mu)^3 P(i) \quad (4.6)$$

$$\mu_4 = \sigma^{-4} \sum_{i=0}^{G-1} (i - \mu)^4 P(i) - 3 \quad (4.7)$$

$$E = \sum_{i=0}^{G-1} [P(i)]^2 \quad (4.8)$$

$$H = - \sum_{i=0}^{G-1} P(i) \log_2 [P(i)] \quad (4.9)$$

Esses parâmetros em questão foram selecionados por eles serem bastante utilizados por grande parte dos problemas dessa natureza e apresentarem uma boa taxa de acerto para o sistema, o que os torna bem confiáveis.

#### 4.6.2 – Matrizes de Co-ocorrência

A maior vantagem de se usar os parâmetros descritos na seção 4.6.1 para descrever a textura de uma imagem é sua simplicidade. Porém, esses parâmetros não conseguem caracterizar uma textura de forma completa. Para esse fim, são necessárias não apenas as estatísticas de primeira ordem, mas também as de segunda ordem, através das “Matrizes de Co-ocorrência” (MATERKA e STRZELECKI, 1998).

Supondo que uma imagem seja representada pela seguinte matriz mostrada na Figura 13.

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

Figura 13: Matriz de Exemplo de uma Imagem (MATERKA e STRZELECKI, 1998).

Para construir a Matriz de Co-ocorrência de uma imagem qualquer, deve-se enumerar a frequência de ocorrência dos valores da forma como é mostrada na Figura 14.

São dois parâmetros que serão levados em consideração: a distância e o ângulo. Será utilizada a distância  $d = 1$ , ou seja, valores posicionados de forma adjacente na matriz da imagem. Os ângulos possíveis são quatro:  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ .

$i \setminus j$	0	1	2	3
0	#(0,0)	#(0,1)	#(0,2)	#(0,3)
1	#(1,0)	#(1,1)	#(1,2)	#(1,3)
2	#(2,0)	#(2,1)	#(2,2)	#(2,3)
3	#(3,0)	#(3,1)	#(3,2)	#(3,3)

Figura 14: Construção de uma Matriz de Co-ocorrência (MATERKA e STRZELECKI, 1998).

Caso se queira a quantidade de ocorrências dos valores da matriz da Figura 13 na horizontal (ângulo  $0^\circ$ ), temos como resultado a matriz mostrada na Figura 15.

4	2	1	0
2	4	0	0
1	0	6	1
0	0	1	2

$b_{1,0^\circ}$

Figura 15: Matriz resultado para o número de ocorrências na horizontal (MATERKA e STRZELECKI, 1998).

Já a quantidade de ocorrências dos valores da matriz de exemplo representada pela Figura 13 na vertical (ângulo  $90^\circ$ ), tem como resultado a matriz mostrada na Figura 16.

6	0	2	0
0	4	2	0
2	2	2	2
0	0	2	0

$$b_{1,90^\circ}$$

Figura 16: Matriz resultado para número de ocorrências na vertical (MATERKA e STRZELECKI, 1998).

A partir das Matrizes de Co-ocorrência, podemos efetuar o cálculo de algumas características úteis para o propósito de discriminação das imagens. Essas características são chamadas de “Estatísticas de Segunda Ordem” para a descrição da textura em imagens digitais representadas por matrizes, tais como: “Segundo Momento Angular” (Energia), “Correlação”, “Inércia” (Contraste), “Diferença Inversa”, “Entropia” e “Máxima Probabilidade”. Tais grandezas podem ser representadas pelas equações (4.10) a (4.15), respectivamente.

$$\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} [P(i,j)]^2 \quad (4.10)$$

$$\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{ijP(i,j) - \mu_x\mu_y}{\sigma_x\sigma_y} \quad (4.11)$$

$$\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i-j)^2 P(i,j) \quad (4.12)$$

$$\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{P(i,j)}{1 + (i-j)^2} \quad (4.13)$$

$$- \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i,j) \log_2[P(i,j)] \quad (4.14)$$

$$\max_{i,j} P(i,j) \quad (4.15)$$

A escolha dessas grandezas acima citadas também foi devido à confiabilidade e na alta taxa de acerto que elas possuem em problemas dessa natureza. Essa escolha foi feita baseada em outros trabalhos na área que apresentaram bons resultados.

## 4.7 – Classificando as Imagens

Depois da discussão sobre os métodos que serão utilizados na análise das imagens digitais, é necessário classificar as informações obtidas. Para esse fim, será utilizado o Método LDA. Posteriormente, será discutida a estratégia de validação cruzada necessária para efetuar essa classificação.

### 4.7.1 – Método LDA

LDA (Análise Linear Discriminante) é um método estatístico supervisionado que pode classificar amostras por análise de um conjunto de descritores (FUKUNAGA, 1990). Ele é utilizado em Estatística, Reconhecimento de Padrões e Aprendizagem de Máquina e tem como função expressar uma variável como uma combinação linear de descritores (variáveis independentes) da amostra que resulta em sua classe (variável dependente). A combinação de resultado deve ser usada como um classificador linear (McLACHLAN, 2004). O principal objetivo do LDA é minimizar o erro inerente a este processo de classificação. Ele segue a Regra de Bayes, a qual diz que uma amostra  $x$  deve ser atribuída à classe  $i$  com a maior probabilidade condicional, tal como em (4.16):

$$P(i|x) > P(j|x), \forall j \neq i, \quad (4.16)$$

em que  $P(i|x)$  é a probabilidade condicional de  $i$  dado que  $x$  ocorreu.

A probabilidade de  $P(i|x)$  é geralmente desconhecida, mas se  $P(i|x)$  é conhecida, ela pode ser obtida como segue em (4.17):

$$P(i|x) = \frac{P(x|i)P(i)}{\sum P(x|j)P(j)}. \quad (4.17)$$

Considerando  $P(i|x)$  como tendo uma única matriz de covariância para todas as classes, a fórmula principal para o método LDA é definida na equação (4.18):

$$f_i = \mu_i C^{-1} x_k^T - \frac{1}{2} \mu_i C^{-1} \mu_i^T + \ln(\rho_i), \quad (4.18)$$

em que  $C$  é a matriz de covariância do conjunto de dados e  $\mu_i$  e  $\rho_i$  são a média da matriz das características e a probabilidade a priori da classe  $i$ , respectivamente. A amostra analisada é atribuída à classe  $i$ , que fornece o valor mais alto para  $f_i$ .



#### 4.7.2 – Estratégias de Validação Cruzada

A validação cruzada é uma técnica utilizada para avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados (KOHAVI, 1995).

Esta técnica é amplamente empregada em problemas nos quais o objetivo da modelagem é a classificação. Busca-se então estimar o quão preciso é este classificador na prática, ou seja, o seu desempenho para um novo conjunto de dados.

O conceito central das técnicas de validação cruzada é o particionamento do conjunto de dados em subconjuntos mutuamente exclusivos, e posteriormente, utilizam-se alguns destes subconjuntos para a estimação dos parâmetros do classificador (dados de treinamento) e o restante dos subconjuntos (dados de validação ou de teste) são empregados na sua validação.

Diversas formas de realizar o particionamento dos dados foram sugeridas, sendo as três mais utilizadas: *Hold-Out*, *K-Fold* e *Leave-One-Out* (KOHAVI, 1995).

O método *Hold-Out* consiste em dividir o conjunto total de dados em dois subconjuntos mutuamente exclusivos, um para treinamento (estimação dos parâmetros) e outro para teste (validação). O conjunto de dados pode ser separado em quantidades iguais ou não. Uma proporção muito comum é considerar 2/3 dos dados para treinamento e o 1/3 restante para teste. Após o particionamento, a estimação dos parâmetros do classificador é realizada e, posteriormente, os dados de teste são aplicados e a taxa de classificação é calculada. Esta abordagem é indicada quando está disponível uma grande quantidade de dados.

O método *K-Fold* consiste em dividir o conjunto total de dados em  $K$  subconjuntos mutuamente exclusivos do mesmo tamanho e, a partir disto, um subconjunto é utilizado para teste e os  $K-1$  restantes são utilizados para estimação dos parâmetros e calcula-se a acurácia do classificador. Este processo é realizado  $K$  vezes alternando de forma circular o subconjunto de teste. Ao final das  $K$  iterações, calcula-se a acurácia das médias das taxas de acerto encontradas, obtendo assim uma medida mais confiável sobre a capacidade do classificador em atribuir os dados de validação às suas classes corretas.

O método *Leave-One-Out* é um caso específico do *K-Fold*, com  $K$  igual ao número total de dados  $N$ . Nesta abordagem são realizados  $N$  cálculos de classificação, um para cada dado. Apesar de apresentar uma investigação completa sobre a robustez do

classificador em relação aos dados utilizados, este método possui um alto custo computacional, sendo indicado para situações onde poucos dados estão disponíveis.

O conceito central da estratégia *Leave-One-Out* é particionar o conjunto de  $N$  amostras em  $N-1$  amostras para treinamento e uma amostra para validação. O experimento é realizado  $N$  vezes, cada vez com uma amostra de validação diferente. O resultado final é a média das  $N$  acurácias obtidas. Esta foi a estratégia de validação cruzada que foi utilizada neste trabalho.

## 5 – METODOLOGIA

O trabalho foi desenvolvido, testado e implementado no software MATLAB em sua versão R2013b.

No estudo em questão, foi trabalhado com somente duas das sete classes de imagens de células provenientes de Exames de Papanicolau mostradas na Seção 4.2. Um grupo formado por células normais, e outro, formado por células anormais. Essa escolha foi feita para facilitar a classificação, uma vez que usar todas as sete classes apresentadas na Seção 4.2 aumentaria bastante a complexidade do problema. Então foi adaptado que as três classes de células saudáveis (epitelial escamosa superficial, epitelial escamosa intermediária e epitelial colunar) pertencem à classe “normais” e as quatro classes de células cancerosas (displasia não-queratinizada escamosa branda, displasia não-queratinizada escamosa moderada, displasia não-queratinizada escamosa severa e carcinoma de células escamosas *in situ* intermediário) pertencem à classe “anormais”.

Para a obtenção da textura presente nas imagens serão utilizadas as seis medidas das Estatísticas de Primeira Ordem mostradas na Seção 4.6.1 e das Matrizes de Co-ocorrência apresentadas na Seção 4.6.2. Após isso, o método LDA (Seção 4.7.1) e a estratégia *Leave-One-Out* (Seção 4.7.2) serão utilizados para o processo de classificação das assinaturas obtidas. A estratégia *Leave-One-Out* foi escolhida devido ao fato dela ser uma boa ferramenta para testes por causa das divisões em agrupamentos que foram realizadas.

Esse classificador será treinado pelo sistema para “aprender” o máximo possível sobre os padrões recorrentes das imagens e esse aprendizado será testado posteriormente. Ele poderá prever segundo uma taxa de acerto considerável, se uma dada imagem pertencente a um dos grupos relatados anteriormente é de uma célula normal ou anormal, ou então, caso seja inserida uma nova imagem ao acervo, ele também deverá ser capaz de prever a qual dessas duas classes pertencerá essa imagem.

Como as imagens digitais dos Exames de Papanicolau disponíveis já foram analisadas por especialistas e já lhes foi dado o devido diagnóstico, já se sabe com exatidão se são de mulheres com saúde ou com câncer. Por isso, a tarefa é melhorar ao máximo o percentual de acerto do sistema em relação a essas células.

## 6 – RESULTADOS E DISCUSSÕES

Depois de terem sido feitos todos os testes e experimentos do projeto no software MATLAB, chega-se aos resultados mostrados nas duas subseções seguintes. Os dados serão expostos e posteriormente analisados e discutidos.

O objetivo principal deste estudo foi de maximizar a taxa de acerto do sistema em relação à predição que ele irá fazer acerca das imagens para informar se elas são de mulheres sadias ou portadoras de câncer, ou seja, há duas classes possíveis para a classificação. Obviamente, quanto maior for o percentual de acerto, maior será o grau de confiabilidade do sistema no diagnóstico.

Existem várias grandezas relativas aos dois métodos que foram apresentadas nas Seções 4.6.1 e 4.6.2, seis delas foram selecionadas para o projeto para cada método, porém os resultados demonstram que não é necessariamente preciso utilizar todas as seis grandezas escolhidas. Pode haver grandezas que se adequem melhor ao problema proposto do que outras. Em prol de tentar aumentar a taxa de acerto do sistema, pode-se combinar essas grandezas em agrupamentos de três em três, quatro em quatro e cinco em cinco. Para tal tarefa, foi utilizada a estratégia *Leave-One-Out*, abordada anteriormente na Seção 4.7.1.

### 6.1 - Taxas de Acerto das Estatísticas de Primeira Ordem

Nessa subseção será apresentado o levantamento dos dados obtidos para o primeiro método empregado no projeto para extração de características, as Estatísticas de Primeira Ordem.

Primariamente, as seis grandezas das Estatísticas de 1ª Ordem foram combinadas em subconjuntos de três a três, conforme a estratégia *Leave-One-Out*. Com isso, obtiveram-se as seguintes taxas de acerto mostradas na Tabela 2.

Relembrando que as grandezas selecionadas para esse método bem como as fórmulas para calculá-las foram apresentadas na Seção 4.6.1. As medidas são: Média, Variância, Obliquidade, Curtose, Energia e Entropia.

Tabela 2: Taxas de Acerto das Combinações 3x3 das Estatísticas de 1ª Ordem

<b>Combinação das Grandezas de 3 a 3</b>	<b>Taxa de Acerto</b>
Média, Variância e Obliquidade	<b>0.732824*</b>
Média, Variância e Curtose	0.779716
Média, Variância e Energia	0.767721
Média, Variância e Entropia	0.777535
Média, Obliquidade e Curtose	0.780807
Média, Obliquidade e Energia	0.753544
Média, Obliquidade e Entropia	0.779716
Média, Curtose e Energia	0.779716
Média, Curtose e Entropia	0.781897
Média, Energia e Entropia	0.779716
Variância, Obliquidade e Curtose	0.765540
Variância, Obliquidade e Energia	0.767721
Variância, Obliquidade e Entropia	0.769902
Variância, Curtose e Energia	0.780807
Variância, Curtose e Entropia	0.781897
Variância, Energia e Entropia	0.761178
Obliquidade, Curtose e Energia	0.776445
Obliquidade, Curtose e Entropia	0.775354
Obliquidade, Energia e Entropia	0.767721
Curtose, Energia e Entropia	<b>0.782988*</b>

\*Os valores em negrito representam a maior e a menor porcentagem obtida.

A taxa de acerto varia entre 0 e 1. Analisando os dados relativos a essas vinte possibilidades de combinações de três a três, como pode ser visto na Tabela 2, percebe-se que a taxa de acerto do sistema utilizando somente três das grandezas selecionadas varia entre 73% a pouco mais de 78%. Com isso, a escolha dos três parâmetros “Média, Variância e Obliquidade” não seria satisfatória, visto que apresenta somente 73,2824%. A escolha mais confiável seria os três parâmetros “Curtose, Energia e Entropia” que apresenta 78,2988%. Outras escolhas satisfatórias são os dados que obtiveram uma taxa de acerto acima de 78%.

A execução das grandezas combinadas em subconjuntos de quatro a quatro, conforme a estratégia *Leave-One-Out* demonstram as taxas de acerto contidas na Tabela 3.

Tabela 3: Taxas de Acerto das Combinações 4x4 das Estatísticas de 1ª Ordem

<b>Combinação das Grandezas de 4 a 4</b>	<b>Taxa de Acerto</b>
Média, Variância, Obliquidade e Curtose	0.782988
Média, Variância, Obliquidade e Energia	<b>0.768811*</b>
Média, Variância, Obliquidade e Entropia	0.772083
Média, Variância, Curtose e Energia	0.778626
Média, Variância, Curtose e Entropia	<b>0.785169*</b>
Média, Variância, Energia e Entropia	0.779716
Média, Obliquidade, Curtose e Energia	0.779716
Média, Obliquidade, Curtose e Entropia	0.782988
Média, Obliquidade, Energia e Entropia	0.774264
Média, Curtose, Energia e Entropia	0.782988
Variância, Obliquidade, Curtose e Energia	0.775354
Variância, Obliquidade, Curtose e Entropia	0.776445
Variância, Obliquidade, Energia e Entropia	0.769902
Variância, Curtose, Energia e Entropia	0.780807
Obliquidade, Curtose, Energia e Entropia	0.774264

\*Os valores em negrito representam a maior e a menor porcentagem obtida.

Analisando os dados relativos às quinze possibilidades de combinações de quatro a quatro, como pode ser visto na Tabela 3, percebe-se que a taxa de acerto do sistema utilizando somente quatro das grandezas selecionadas varia entre mais de 76% a mais de 78%. Sendo a pior escolha o quarteto “Média, Variância, Obliquidade e Energia” que apresenta somente 76,8811% e a escolha mais confiável seria o quarteto “Média, Variância, Curtose e Entropia” que apresenta 78,5169%. Outros resultados que se destacam são as combinações que apresentam resultados acima de 78%.

Quando as combinações das grandezas selecionadas são executadas em subconjuntos de cinco a cinco, conforme a estratégia *Leave-One-Out*, obtém-se as taxas de acerto contidas na Tabela 4.

Tabela 4: Taxas de Acerto das Combinações 5x5 das Estatísticas de 1ª Ordem

<b>Combinação das Grandezas de 5 a 5</b>	<b>Taxa de Acerto</b>
Média, Variância, Obliquidade, Curtose e Energia	0.781897
Média, Variância, Obliquidade, Curtose e Entropia	<b>0.786260*</b>
Média, Variância, Obliquidade, Energia e Entropia	0.774264
Média, Variância, Curtose, Energia e Entropia	<b>0.786260*</b>
Média, Obliquidade, Curtose, Energia e Entropia	<b>0.786260*</b>
Variância, Obliquidade, Curtose, Energia e Entropia	<b>0.773173*</b>

\*Os valores em negrito representam a maior e a menor porcentagem obtida.

Analisando os dados relativos às seis possibilidades de combinações de cinco a cinco, como pode ser visto na Tabela 4, percebe-se que a taxa de acerto do sistema utilizando cinco grandezas varia entre mais de 77% a mais de 78%, próximo a 79%. Sendo o resultado menos confiável o quinteto “Variância, Obliquidade, Curtose, Energia e Entropia” que apresenta 77,3173% e as melhores porcentagens seriam os quintetos que apresentaram taxa de 78,6260%. O grupo “Média, Variância, Obliquidade, Curtose e Energia” também possui uma porcentagem elevada, contando com 78,1897%.

Utilizando todas as seis grandezas, o resultado obtido foi a taxa de 78,6260%, que é um resultado similar aos resultados obtidos nas combinações de cinco a cinco.

Na Tabela 5, pode ser observado um comparativo entre todos os maiores e os menores percentuais obtidos utilizando as Estatísticas de 1ª Ordem.

Tabela 5: Maiores e menores taxas de acerto para as Estatísticas de 1ª Ordem

<b>Combinações</b>	<b>Menor Taxa de Acerto</b>	<b>Maior Taxa de Acerto</b>
3x3	<b>0.732824*</b>	0.782988
4x4	0.768811	0.785169
5x5	0.773173	<b>0.786260*</b>
Todas as grandezas	0.786260	<b>0.786260*</b>

\*Os valores em negrito representam a maior e a menor porcentagem obtida.

Percebe-se que para esse método, será obtida a máxima taxa de acerto utilizando somente cinco das grandezas ou todas, e a taxa de sucesso no diagnóstico será de 78,6260%.

## 6.2 - Taxas de Acerto das Matrizes de Co-ocorrência

Nesta subseção serão apresentados, analisados e discutidos os dados referentes ao segundo método de extração de características empregado no projeto.

Quando as seis Estatísticas de 2ª Ordem são combinadas em subconjuntos de três em três, serão obtidos os percentuais de acerto ilustrados na Tabela 6.

Vale ressaltar que as grandezas selecionadas para esse método foram apresentadas na Seção 4.6.2: Energia (Segundo Momento Angular), Correlação, Contraste (Inércia), Diferença Inversa, Entropia e Máxima Probabilidade.

Tabela 6: Taxas de Acerto das Combinações 3x3 das Matrizes de Co-ocorrência

<b>Combinação das Grandezas de 3 a 3</b>	<b>Taxa de Acerto</b>
Energia, Correlação e Contraste	0.794984
Energia, Correlação e Diferença Inversa	0.793893
Energia, Correlação e Entropia	0.777535
Energia, Correlação e Máxima Probabilidade	0.786260
Energia, Contraste e Diferença Inversa	0.778626
Energia, Contraste e Entropia	0.760087
Energia, Contraste e Máxima Probabilidade	0.763359
Energia, Diferença Inversa e Entropia	0.791712
Energia, Diferença Inversa e Máxima Probabilidade	0.754635
Energia, Entropia e Máxima Probabilidade	0.758997
Correlação, Contraste e Diferença Inversa	<b>0.804798*</b>
Correlação, Contraste e Entropia	0.801527
Correlação, Contraste e Máxima Probabilidade	0.799346
Correlação, Diferença Inversa e Entropia	0.796074
Correlação, Diferença Inversa e Máxima Probabilidade	0.792803
Correlação, Entropia e Máxima Probabilidade	0.791712
Contraste, Diferença Inversa e Entropia	0.785169
Contraste, Diferença Inversa e Máxima Probabilidade	<b>0.749182*</b>
Contraste, Entropia e Máxima Probabilidade	0.750273
Diferença Inversa, Entropia e Máxima Probabilidade	0.767721

\*Os valores em negrito representam a maior e a menor porcentagem obtida.



Com uma análise preliminar e superficial dos dados da Tabela 6 já nota-se um ligeiro aumento nas porcentagens em relação ao método anterior que oscilava de 73% a 78%. No presente método as porcentagens apresentam-se maiores, em torno de 74,9% a 80,5%.

Examinando as taxas de acerto das vinte combinações possíveis na Tabela 6, percebe-se que a taxa com o maior percentual é da combinação “Correlação, Contraste e Diferença Inversa” com 80,4798%, sendo a melhor opção. Já a menor taxa obtida foi com a combinação “Contraste, Diferença Inversa e Máxima Probabilidade” com 74,9182%. Outra possibilidade interessante e que merece destaque é a da combinação “Correlação, Contraste e Entropia” com 80,1527%.

As combinações das grandezas escolhidas executadas em subconjuntos de quatro a quatro, apresentou as taxas de acerto demonstradas na Tabela 7.

Tabela 7: Taxas de Acerto das Combinações 4x4 das Matrizes de Co-ocorrência

<b>Combinação das Grandezas de 4 a 4</b>	<b>Taxa de Acerto</b>
Energia, Correlação, Contraste e Diferença Inversa	0.803708
Energia, Correlação, Contraste e Entropia	0.802617
Energia, Correlação, Contraste e Máxima Probabilidade	0.797165
Energia, Correlação, Diferença Inversa e Entropia	0.798255
Energia, Correlação, Diferença Inversa e Máxima Probabilidade	0.790622
Energia, Correlação, Entropia e Máxima Probabilidade	0.796074
Energia, Contraste, Diferença Inversa e Entropia	0.797165
Energia, Contraste, Diferença Inversa e Máxima Probabilidade	0.766630
Energia, Contraste, Entropia e Máxima Probabilidade	<b>0.758997*</b>
Energia, Diferença Inversa, Entropia e Máxima Probabilidade	0.788441
Correlação, Contraste, Diferença Inversa e Entropia	0.803708
Correlação, Contraste, Diferença Inversa e Máxima Probabilidade	0.802617
Correlação, Contraste, Entropia e Máxima Probabilidade	0.800436
Correlação, Diferença Inversa, Entropia e Máxima Probabilidade	<b>0.804798*</b>
Contraste, Diferença Inversa, Entropia e Máxima Probabilidade	0.777535

\*Os valores em negrito representam a maior e a menor porcentagem obtida.

As taxas das quinze possibilidades de combinação de quatro em quatro das grandezas variam em torno de 75% a 80%, valores superiores aos obtidos com o método anterior, no qual se tinham taxas na faixa de 76% a 78%.

A combinação contemplada com a melhor taxa de sucesso foi a de “Correlação, Diferença Inversa, Entropia e Máxima Probabilidade” com um total de 80,4798%. A combinação que obteve menor sucesso foi a de “Energia, Contraste, Entropia e Máxima Probabilidade” com somente 75,8997%. Como pode-se observar na Tabela 7, há várias taxas interessantes com mais de 80%

Relacionando as grandezas selecionadas em subconjuntos de cinco em cinco, foram obtidas as taxas de acerto demonstradas na Tabela 8.

Tabela 8: Taxas de Acerto das Combinações 5x5 das Matrizes de Co-ocorrência

<b>Combinação das Grandezas de 5 a 5</b>	<b>Taxa de Acerto</b>
Energia, Correlação, Contraste, Diferença Inversa e Entropia	<b>0.808070*</b>
Energia, Correlação, Contraste, Diferença Inversa e Máxima Probabilidade	0.803708
Energia, Correlação, Contraste, Entropia e Máxima Probabilidade	0.799346
Energia, Correlação, Diferença Inversa, Entropia e Máxima Probabilidade	0.801527
Energia, Contraste, Diferença Inversa, Entropia e Máxima Probabilidade	<b>0.790622*</b>
Correlação, Contraste, Diferença Inversa, Entropia e Máxima Probabilidade	0.806979

\*Os valores em negrito representam a maior e a menor porcentagem obtida.

Os percentuais de acerto das seis possibilidades de combinação cinco em cinco das grandezas de segunda ordem foram muito próximos, com pouca variação, em torno de 79% a 80%. Foi obtida uma taxa satisfatória com a combinação “Energia, Correlação, Contraste, Diferença Inversa e Entropia” com 80,8070% e a menos satisfatória foi a combinação “Energia, Contraste, Diferença Inversa, Entropia e Máxima Probabilidade” com 79,0622%. Todas as outras combinações apresentaram bons resultados, no intervalo de 80% a 81%. Pode-se inferir que a confiabilidade do sistema é de 80% para esse cenário, pois os valores obtidos apresentaram pequena variação.

Comparando os resultados atuais com os resultados do método anterior, as taxas que variavam no intervalo entre 77% a 78%, chegaram a ultrapassar os 80%, revelando uma maior confiabilidade para o sucesso do diagnóstico.

Utilizando as seis grandezas de segunda ordem escolhidas foi obtida a taxa de 80,3708%. Na Tabela 9, é feito um comparativo entre todos os percentuais de acertos mínimo e máximo de cada combinação, utilizando as Matrizes de Co-ocorrência.

Tabela 9: Maiores e menores taxas de acerto para as Matrizes de Co-Ocorrência

<b>Combinações</b>	<b>Menor Taxa de Acerto</b>	<b>Maior Taxa de Acerto</b>
3x3	<b>0.749182*</b>	0.804798
4x4	0.758997	0.804798
5x5	0.790622	<b>0.808070*</b>
Todas as grandezas	0.803708	0.803708

\*Os valores em negrito representam a maior e a menor porcentagem obtida.

Percebe-se que para esse segundo método, a taxa de sucesso no diagnóstico será maximizada utilizando cinco grandezas e será de 80,8070%, observa-se a superioridade do resultado obtido quando comparado com a taxa máxima do método anterior, que foi de 78,6260%.

Esse resultado era esperado, uma vez que as Matrizes de Co-Ocorrência são mais robustas para expressar esses percentuais do que as Estatísticas de 1ª Ordem. Isso se deve ao fato de que as Estatísticas de 1ª Ordem utilizam como parâmetro o histograma que é um vetor de 256 posições, que varia de 0 a 255, uma para cada nível de cinza da imagem. O problema do histograma é que imagens diferentes podem apresentar histogramas iguais se os níveis de cinza representarem os mesmos valores, mas estiverem em posições distintas na imagem.

Já as Estatísticas de 2ª Ordem utilizam as Matrizes de Co-Ocorrência como parâmetro para extrair as características. Esse tipo específico de estrutura é uma matriz quadrada de ordem 256, ou seja, de 256 linhas e 256 colunas (256 x 256). Dessa forma, não há como imagens diferentes apresentarem as mesmas matrizes de co-ocorrência, tornando-a um método mais complexo e mais confiável.

## 7 – CONCLUSÕES

Não há o que contestar em relação à parte interdisciplinar e multidisciplinar no contexto no qual este estudo foi inserido, já que é bastante frutífero mesclar duas áreas do conhecimento tão distintas (Engenharia da Computação e Medicina) em prol de algo que pode vir a beneficiar a comunidade como um todo. Isso agrega valor ao trabalho e unifica o conhecimento. Esse intercâmbio de informações de diferentes ramificações faz com que o aprendizado seja gratificante, saindo da esfera quantitativa para ingressar na qualitativa, uma vez que este projeto pode auxiliar na detecção do câncer e auxiliar especialistas médicos.

Através dos resultados obtidos, pode-se concluir que é bastante viável utilizar um sistema no software MATLAB para a diferenciação de células saudáveis e cancerosas. Os dados demonstraram que a confiabilidade no sistema utilizando as Estatísticas de 1ª Ordem variam de 73% a 78%, já utilizando as Matrizes de Co-ocorrência variam entre 74% a 80%, que são taxas relativamente bem confiáveis.

Trabalhos futuros que podem vir a ser desempenhados seriam o aprimoramento do sistema com a finalidade de aumentar ainda mais a taxa de acerto no diagnóstico das imagens médicas, não só de Papanicolau, mas também de outras enfermidades. Poderiam também ser utilizadas mais classes para análise, além de duas. Como por exemplo, as sete classes que variam entre a célula mais saudável para a mais cancerosa, dentre outras aplicações. Poderiam também ser utilizados outros métodos diferentes do LDA que são interessantes para a classificação como, por exemplo, as Redes Neurais Artificiais. Poderiam também ser utilizados outros métodos para a extração de características diferentes das Estatísticas de 1ª Ordem e das Matrizes de Co-ocorrência, ou mesmo utilizar esses métodos, mas selecionando grandezas diferentes como parâmetros. Enfim, as possibilidades de customização deste estudo são consideravelmente elevadas.

## 8 – REFERÊNCIAS

ANDERSSON, Virginia Ortiz e OLIVEIRA, Lucas Ferrari – **Auxílio ao Diagnóstico do Glaucoma Utilizando Processamento de Imagens** (2011). VII Workshop de Visão Computacional (WVC 2011).

ARAUJO, Alex Fernando de; TAVARES, João Manuel R. S.; OLIVEIRA, Roberta Barbosa; ROSSETTI, Ricardo Baccaro; MARRANGHELLO, Norian e PEREIRA, Aledir Silveira – **Análise e Caracterização de Lesões de Pele para Auxílio ao Diagnóstico Médico** (2011). VII Workshop de Visão Computacional (WVC 2011).

BRASIL. Ministério da Saúde. Secretaria Executiva. Departamento de Apoio à Descentralização. Coordenação - Geral de Apoio à Gestão Descentralizada. **Diretrizes operacionais dos Pactos pela Vida, em Defesa do SUS e de Gestão**. Brasília, (2006)a. 76p.

BROLLO, Alex – **Pap test, Papanicolau stain, 400x. Infestation by Trichomonas vaginalis**. Slide files from Hospital of Monfalcone (Italy), October, 2006.

CAGLIOSTRO – **Pap Test: Normal Cervicovaginal Cytology**. Health, PD-self, Pap test cytology. October, (2005).

CLARK, George – **Staining Procedures**. William & Wilkins Co, 3ª ed., (1973).

CONCI, Aura; AZEVEDO, Eduardo; LETA R. Fabiana. **Computação Gráfica – Teoria e Prática Volume 2** – Elsevier Editora Ltda., Rio de Janeiro (2008).

FERNANDES, Michel Pereira; SATO, Ricardo João; BUSATTO FILHO, Geraldo e THOMAZ, Carlos Eduardo – **Classificação Estatística e Predição da Doença de Alzheimer por meio de Imagens Médicas do Encéfalo Humano** (2011). VII Workshop de Visão Computacional (WVC 2011).

FUKUNAGA, K. 1990. **Introduction to statistical pattern recognition**. Academic Press, London, U.K.

GAMPEL, C.; e KOSS, L. G. **Citologia Ginecológica e suas Bases Anatomoclínicas**. Ed. Manole, 1ª Ed., (1997).

GONÇALVES, Júnior – **Introdução à Computação Gráfica** (2013).

HARALICK, Robert M. **Statistical and Structural Approaches to Texture**, Proceedings of the IEEE, v. 67, n. 5, pp. 786-804, (1979).

INCA – INSTITUTO NACIONAL DE CÂNCER (Brasil). Portaria 2439. **Política Nacional de Atenção Oncológica**, (2005).

JANTZEN, J. e DOUNIAS, G. – **The Pap Smear Benchmark: Intelligent and Nature-Inspired Approaches in Pap Smear Diagnosis**. Special Session Proceedings of the NISIS – 2006 Symposium. Puerto de La Cruz, Tenerife, Spain, November 29 – December 1, (2006).

JANTZEN, Jan; NORUP, Jonas; DOUNIAS, Georgios; BJERREGAARD, Beth. **Pap-smear benchmark data for pattern classification**. In: Proc. NiSIS 2005. Albufeira, Portugal: NiSIS, 2005. P. 1–9.

KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection**. In: International joint Conference on artificial intelligence, 1995. v. 14, p. 1137–1145.

KUPFERMAN, Raz – **Pixels on the LCD monitor** (2000). Disponível em: <<http://www.math.toronto.edu/drorbn/Gallery/Symmetry/Tilings/So/DSC-S70Pixels.html>>

MATERKA A., STRZELECKI M., **Texture Analysis Methods – A Review**, Technical University of Lodz, Institute of Electronics, Cost B11 Report, Brussels, (1998).

McLACHLAN, G. J. – **Discriminant Analysis and Statistical Pattern Recognition** (2004). Wiley Interscience. ISBN 0-471-69115-1. MR 1190469, (2004)

MOREIRA, Leandro - **Exame Papanicolau – Preventivo: Função, Como é feito, Importância** (2012).

PEREIRA NEVES, Luiz Antônio; VIEIRA NETO, Hugo e GONZAGA, Adilson – **Avanços em Visão Computacional** (2012).

PEREYRA, Elsa Aida Gay de; e PARELLADA, Cíntia Irene – **HPV nas Mulheres** (1994).

SÁ JUNIOR, Jarbas Joaci de Mesquita – **Identificação de Espécies Vegetais por meio de Análise de Imagens Microscópicas de Folhas** (2008). Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, (2008).

SOBIECKI, André; GALLÃO, Celso Denis; COSME, Daniel Cardoso e RODRIGUES, Paulo Sérgio Silva – **Comparação de Imagens Tomográficas Cone-Beam e Multi-Slice Através da Entropia de Tsallis e da Divergência de Kullback-Leibler** (2011). VII Workshop de Visão Computacional (WVC 2011).

TUCERYAN, Mihran e JAIN, Anil K. – **Texture Analysis** (1998). The Handbook of Pattern Recognition and Computer Vision (2nd Edition), by C. H. Chen, L. F. Pau, P. S. P. Wang (eds.), pp. 207-248, World Scientific Publishing Co., (1998).

VIEIRA, Flávio Pascoal e RODRIGUES, Evandro Luis Linhari – **Método para a Obtenção de Imagens Coloridas com o Uso de Sensores Monocromáticos** (2011). VII Workshop de Visão Computacional (WVC 2011).

WHO (WORLD HEALTH ORGANIZATION). **International Agency for Research on Cancer**. Globocan (2008). Lyon, 2008a. Disponível em: <<http://globocan.iarc.fr/>>.

XAVIER, Albert da Costa; SATO, João Ricardo; GIRALDI, Gilson Antônio; RODRIGUES, Paulo Sérgio e THOMAZ, Carlos Eduardo – **Classificação e Extração de Características Discriminantes de Imagens 2D de Ultrassonografia Mamária** (2011). VII Workshop de Visão Computacional (WVC 2011).