

**UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
CURSO DE CIÊNCIA DA COMPUTAÇÃO**

WILLIAN FRANÇA RIBEIRO

**UMA METODOLOGIA PARA DETECTAR ANEMIA EM PEQUENOS
RUMINANTES**

**SÃO LUÍS-MA
2018**

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Ribeiro, Willian França.

UMA METODOLOGIA PARA DETECTAR ANEMIA EM PEQUENOS
RUMINANTES / Willian França Ribeiro. - 2018.

61 p.

Orientador(a): Tiago Bonini Borchartt.

Monografia (Graduação) - Curso de Ciência da
Computação, Universidade Federal do Maranhão, São Luís,
2018.

1. Anemia. 2. FAMACHA. 3. Ruminantes. I. Borchartt,
Tiago Bonini. II. Título.

Willian França Ribeiro

UMA METODOLOGIA PARA DETECTAR ANEMIA EM PEQUENOS RUMINANTES

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Tiago Bonini Borchartt

São Luís-MA

2018

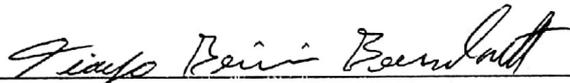
Willian França Ribeiro

UMA METODOLOGIA PARA DETECTAR ANEMIA EM PEQUENOS RUMINANTES

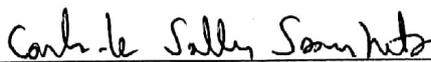
Monografia apresentada como requisito parcial para obtenção do grau de Bacharel em Curso de Ciência da Computação da Universidade Federal do Maranhão - UFMA, Centro de Ciências Exatas e Tecnológicas.

Data de Aprovação: 15/06/2018

Banca Examinadora



Prof. Dr. Tiago Bonini Borchart
Universidade Federal de Maranhão
Orientador



Prof. Dr. Carlos de Salles Soares Neto
Universidade Federal de Maranhão



Prof. Msc. Cláudio Manoel Pereira Aroucha
Universidade Federal de Maranhão

Este trabalho é dedicado a minha família e meus amigos que sempre me apoiaram.

AGRADECIMENTOS

Agradecimentos a minha família, pelo apoio e por acreditar em mim, a minha namorada pela imensa paciência.

Agradeço a Carolina e ao professor Lívio do Centro de Ciências Biológicas e da Saúde por sua orientação, apoio e pela base de dados.

Aos professores do Instituto Federal que gentilmente permitiram os testes em seus animais.

Ao professor Cláudio por seu suporte com o algoritmo SVM. Um agradecimento especial ao professor Zair que Deus o abençoe.

Ao orientador professor Tiago Bonini por seu apoio e paciência.

"Que os vossos esforços desafiem as impossibilidades, lembrai-vos de que as grandes coisas do homem foram conquistadas do que parecia impossível."

Charles Chaplin

RESUMO

Os rebanhos de caprinos e ovinos no país têm registrado crescimento ao longo das últimas décadas. No entanto a falta de manejo adequado tem causado severas perdas de produtividade no setor. A principal causa de perda é a infecção por Helmintos causadores de anemia, que enfraquece o animal chegando até causar sua morte. Para controlar a anemia nos animais, os produtores devem acompanhar, através de exames e de observação, o progresso da infecção e ministrar no momento correto a medicação adequada. Neste trabalho é apresentada uma metodologia para aplicação de exames de diagnóstico em animais que possuam suspeita de contaminação por parasitas. As análises foram feitas a partir de fotografias, extraindo características da coloração da conjuntiva dos animais e a classificando (saudável, intermediário e doente), utilizando os classificadores KNN e SVM.

Palavras-chave: Anemia, FAMACHA, Ruminantes.

ABSTRACT

The herds of goats and sheep in the country have registered growth over the last decades. However the lack of proper management has caused severe losses of productivity in the sector. The main cause of loss is Helminth infection causing anemia, which weakens the animal until it causes its death. To control anemia in animals, producers should monitor, through examination and observation, the progress of the infection and provide adequate medication at the right time. This work presents a methodology for the application of diagnostic tests in animals with suspected parasite contamination. The analyzes were made from photographs, extracting characteristics of the coloration of the conjunctiva of the animals and classifying it (healthy, intermediate and diseased), using the classifiers KNN and SVM.

Keywords:Anemia, FAMACHA, Ruminants.

LISTA DE FIGURAS

Figura 1 – Modelo da escala FAMACHA utilizada para comparar a cor da conjuntiva dos animais	17
Figura 2 – Capilar utilizado para o exame de hematócrito em caprinos.	18
Figura 3 – Método de avaliação hematócrito.	18
Figura 4 – As cores e seus respectivos comprimentos de onda dentro do espectro visível	19
Figura 5 – Diagrama do triestímulo	20
Figura 6 – Cubo representando o modelo de cores RGB	21
Figura 7 – Representação do espaço de cor L.A.B	22
Figura 8 – Cone de representação do modelo HSV	23
Figura 9 – Tipos de borda	26
Figura 10 – Curvas e tipos de Curtose	31
Figura 11 – Exemplos de Skewness	32
Figura 12 – Geração de um classificador	34
Figura 13 – Conjunto de treinamento com três hipóteses	35
Figura 14 – Hiperplano com tolerância (margem)	36
Figura 15 – Algoritmo KNN com valores distintos de K	40
Figura 16 – Procedimento de validação cruzada.	41
Figura 17 – Etapas da metodologia	42
Figura 18 – Exemplo de segmentação	43
Figura 19 – Resultado da segmentação	43
Figura 20 – Polígono de restrição	44
Figura 21 – Exemplo de imagem da base de exemplo	45
Figura 22 – Etapas da segmentação (Canal H)	46
Figura 23 – Etapas da segmentação (Limiarização e erosão)	46
Figura 24 – Etapas da segmentação (Recorte)	47
Figura 25 – Região de interesse segmentada	47
Figura 26 – Exemplo de arquivo de testes	48
Figura 27 – Etapas do aplicativo	50
Figura 28 – Imagem com conjuntiva parcialmente exposta	52
Figura 29 – Imagem com ruído	52
Figura 30 – Imagem com movimento	53

LISTA DE TABELAS

Tabela 1 – Distribuição da base de dados	51
Tabela 2 – Parâmetros de avaliação	52
Tabela 3 – Resultados para o algoritmo SVM em Caprinos	54
Tabela 4 – Resultados para o algoritmo SVM em Caprinos	54
Tabela 5 – Resultados para o algoritmo SVM em Ovinos	54
Tabela 6 – Resultados para o algoritmo SVM em Ovinos	54
Tabela 7 – Resultados para o algoritmo KNN em Caprinos	55
Tabela 8 – Resultados para o algoritmo KNN em Caprinos	55
Tabela 9 – Resultados para o algoritmo KNN em Ovinos	55
Tabela 10 – Resultados para o algoritmo KNN em Ovinos	55

LISTA DE ABREVIATURAS E SIGLAS

CIE	<i>Commission Internationale de l'Éclairage;</i>
FMC	<i>FAMACHA - Fafa Malan chart;</i>
HSV	Espaço de cor composto pelos canais <i>Hue, Saturation</i> e <i>Value</i> ;
KNN	<i>K - Nearest Neighbor</i> (k vizinhos mais próximos);
LAB	Espaço de cor composto pelos canais L (<i>Light</i>), A (variação entre o verde e o vermelho) e B (variação entre o azul e o amarelo);
OPG	Ovos de parasitas por grama de fezes;
OPENCV	<i>Open Source Computer Vision Libray</i> (Biblioteca de Computação Visual em Código Aberto);
RPM	Rotação por minuto;
RGB	Espaço de cor composto pelos canais R (<i>red</i>), G (<i>green</i>), B (<i>blue</i>);
SVM	<i>Support Vector Machine</i> (máquina de vetores de suporte);
SMOTE	<i>Synthetic Minority Over-sampling Technique.</i>

Sumário

1	Introdução	14
1.1	Objetivos	14
1.2	Trabalhos relacionados	14
1.3	Organização do trabalho	15
2	Fundamentação Teórica	16
2.1	FAMACHA	16
2.2	Hematócrito	16
2.3	Modelos de cores	19
2.3.1	Modelo de cores RGB	20
2.3.2	Modelo de cor LAB	21
2.3.3	Modelo de cor HSV	22
2.4	Segmentação de imagem	24
2.4.1	Pré-processamento	24
2.4.2	Limiarização	25
2.4.3	Detecção de bordas	26
2.4.4	Erosão	28
2.4.5	Dilatação	28
2.5	Extração de característica	29
2.5.1	Descritores de imagens	29
2.5.2	Border/Interior Classification (B.I.C).	30
2.5.3	Média	30
2.5.4	Variância	30
2.5.5	Desvio padrão	31
2.5.6	Kurtosis (curtose)	31
2.5.7	Skewness (Assimetria)	32
2.5.8	SMOTE - <i>Synthetic Minority Over-sampling Technique</i>	32
2.6	Aprendizado e classificação	33
2.6.1	Máquinas de Vetores de Suporte	35
2.6.2	<i>k-Nearest Neighbor</i>	38
2.6.3	Validação cruzada	40
3	Metodologia	42
3.1	Aquisição	42
3.2	Pré-processamento	43
3.2.1	Filtros	44
3.2.2	Recorte e redimensionamento	44
3.3	Segmentação	44
3.3.1	Base de exemplo	45
3.3.2	Etapas de segmentação	45

3.4	Extração de características	47
3.5	Classificação	48
4	Experimentos	50
4.1	Ambiente de teste	50
4.2	Base de dados	51
4.3	Resultados da segmentação	52
4.4	Resultados da classificação	53
4.4.1	SVM	54
4.4.2	KNN	54
4.4.3	Análise dos resultados	55
5	Conclusão	57
	REFERÊNCIAS	58

1 Introdução

Nos últimos anos os rebanhos de caprinos e ovinos no Brasil vêm crescendo de forma exponencial. O nordeste do país concentra cerca de 57,5% das cabeças de ovinos e 91,6% de caprinos do rebanho total, segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE). Demonstrando a importância dessa atividade para a economia da região e a necessidade de pesquisas para melhoria da produção (NOBREGA, 2016).

Um dos principais obstáculos encontrados por pequenos e médios produtores é manter o animal livre de parasitas gastrintestinais, o que tem dificultado o crescimento do setor e representa um grave problema sanitário. Assim, torna-se necessário a aplicação de métodos de diagnóstico de infecção e tratamento que sejam mais eficazes e acessíveis (VIEIRA, 2008).

O método FAMACHA (*Fafa Malan Chart*) tem destaque no combate a infecções de parasitas em pequenos ruminantes. No entanto sua aplicação depende de variáveis que somente profissionais experientes conseguem levar em consideração.

A aplicação deste método exige que o profissional tenha experiência e conhecimento para o trato dos animais, além de levar em consideração fatores como a luz do dia, idade do animal, sexo e período de lactação, em caso de fêmeas. O método FAMACHA depende também do tempo de exposição da conjuntiva e tem resultado variável para cada profissional (FERNANDES et al., 2015).

1.1 OBJETIVOS

Este trabalho tem como objetivo apresentar uma metodologia para detecção de anemia em pequenos ruminantes, que seja capaz de determinar o grau de infecção de um animal, utilizando técnicas de processamento de imagem aplicadas a fotografias da conjuntiva. Além de:

- estudar técnicas de segmentação de imagens que melhor se adequem às imagens de teste;
- estudar técnicas de extração de características que melhor resultem na classificação das imagens;
- estudar técnicas de classificação de características que tenham melhor tempo de resposta e acurácia;
- desenvolver um experimento para validar a metodologia encontrada.

1.2 Trabalhos relacionados

Em Fernandes et al. (2015), é discutido sobre a capacidade de identificação dos métodos de diagnóstico seletivo de anemia, como o FAMACHA e o OPG (Ovos de parasitas por grama de fezes). Assim como a eficácia desses métodos de evitar o aumento da resistência aos anti-helmínticos por parte dos animais, através da identificação positiva de indivíduos realmente

infectados (verdadeiro positivos) evitando medicar indivíduos que não estejam infectados e garantindo que, aqueles estejam infectados, sejam tratados corretamente. Ressalta-se também que, a interpretação dos níveis de FAMACHA é algo subjetivo e que é de suma importância o treinamento dos avaliadores dos testes.

Em Vieira (2008), é apontada a importância de pesquisas na área para o diagnóstico de anemia em ruminantes. Evidenciando, além do aspecto comercial, os riscos para a saúde humana causado pela ingestão de material contaminado por resíduos químicos do tratamento indiscriminado de anemia.

Em Molento et al. (2004), é feita uma avaliação mais detalhada levando em consideração os percentuais de helmintos e os níveis da escala FAMACHA. Avaliou-se vinte e dois animais distintos e validou-se o diagnóstico obtido pelo método FAMACHA comparando com o diagnóstico obtido pelo exame de hematócrito.

Em Alencar et al. (2010), é apresentado o perfil sanitário em uma região específica, no caso o sertão de Pernambuco. Registrando diversas falhas no manejo sanitário dos animais levando em consideração as estruturas dos criatórios. Outro fato importante foram as técnicas de vermifugação, em geral incorretas, além da falta de acesso a uma assistência técnica eficiente para auxiliar no controle do manejo.

1.3 ORGANIZAÇÃO DO TRABALHO

A partir deste ponto, o trabalho está estruturado do seguinte modo: o Capítulo 2 forma a base conceitual para os métodos abordados; no Capítulo 3 é apresentada a metodologia proposta; no Capítulo 4 serão apresentados os resultados obtidos, assim como uma breve análise dos mesmos e por fim, uma breve conclusão do trabalho e algumas ideias para trabalhos futuros estão presentes no Capítulo 5.

2 Fundamentação Teórica

Neste capítulo são apresentadas revisões conceituais para auxiliar no entendimento da metodologia que será apresentada, assim como trabalhos relacionados que demonstram a relevância do tema em questão. A Seção 2.1 descreve o método FAMACHA e sua aplicação; a Seção 2.2 descreve os conceitos do exame de hematócritos; a Seção 1.2 aborda trabalhos relacionados com o diagnóstico de anemia através do método FAMACHA e hematócrito; a Seção 2.3 apresenta os conceitos de espaços de cores; na Seção 2.4 são apresentados alguns conceitos de segmentação de imagens; na Seção 2.5 são apresentados os conceitos da técnica de extração de característica utilizada; na Seção 2.6 são apresentados conceitos de algoritmos e técnicas de aprendizado de máquina e classificação de características.

2.1 FAMACHA

A principal dificuldade de quem vive nos campos do país é obter suporte técnico para desenvolvimento de suas atividades rotineiras. Assim, tendo em vista que muitos produtores não terão acesso a dispositivos caros e complexos de análise clínica, opta-se por métodos de diagnósticos mais sucintos e de baixo custo.

O método FAMACHA é um dos métodos utilizados para diagnóstico rápido de anemia em pequenos ruminantes. Apresentando complicações quanto a sua aplicação, uma vez que o diagnóstico depende da interpretação do profissional e das condições de iluminação do local do exame.

O método de diagnóstico FAMACHA foi escolhido para ser usado como critério de avaliação neste trabalho por sua larga aceitação em diversos estudos, como mencionado por Fernandes et al. (2015), Wyk e Bath (2002), Kaplan et al. (2004), Beltrão et al. (2004), Depner et al. (2007) e Loria et al. (2009). O método é constituído de uma tabela (escala) de cores que demonstram os níveis de coloração da conjuntiva de um animal saudável com a de um animal com alto grau de infecção por parasitas. Para aplicar o método, um profissional com treinamento deve expor a conjuntiva (parte interna da pálpebra) e comparar com a escala, atribuindo assim um dos cinco níveis do FAMACHA ao animal analisado. Um modelo da escala utilizada pelo método FAMACHA pode ser observado na Figura 1.

Em que os níveis A(1) e B(2) correspondem a um animal considerado saudável, enquanto que o nível C(3) corresponde a um animal com status indefinido que fica a critério do profissional classificar. Os níveis D(4) e E(5) correspondem há um animal infectado, sendo que no nível E(5) é considerada uma infecção grave.

2.2 Hematócrito

O hematócrito (volume globular) é o exame da classe vermelha utilizado como parâmetro para avaliar as hemácias presentes no sangue. É definido como o volume relativo ocupado

Figura 1 – Modelo da escala FAMACHA utilizada para comparar a cor da conjuntiva dos animais



CHAGAS et al. (2007)

pelos eritrócitos ou glóbulos vermelhos em uma amostra de sangue, sendo representado como porcentagem de eritrócitos em uma quantidade de sangue, assim hematócrito de 25% significa 25 mililitros de eritrócitos sobre 100 mililitros de sangue (PORTALEDOCACAO, 2017).

Em caso de um animal, a partir do hematócrito é possível obter os valores de hematimetria e hemoglobinemias através de valores tabelados para cada espécie. A hematimetria refere-se aos parâmetros de avaliação das hemácias, no que tange ao tamanho das células e a distribuição de hemoglobina, enquanto que a hemoglobinemias simboliza a quantidade de hemoglobinas em 100 mililitros de sangue (PORTALEDOCACAO, 2018).

Este exame é solicitado em casos que se deseja acompanhar o progresso da anemia, sua recuperação ou a eficácia do tratamento aplicado, para monitorar casos de desidratação, sangramentos e sua severidade, além de indicar o momento correto para realizar uma transfusão de sangue.

Apesar de seu valor clínico, existem fatores que podem comprometer o resultado de um hematócrito, são eles:

- excesso de anticoagulante na amostra;
- falha na obtenção do sangue, com obtenção de líquido tecidual;
- erro no tempo ou na velocidade da centrifugação;
- homogeneização inadequada da amostra;
- falha na leitura, incluindo a camada de leucócitos;
- irregularidade no diâmetro do capilar, que deve ter um orifício uniforme de 1mm.

A aplicação da técnica de microhematócrito leva em consideração a espécie do indivíduo analisado, no caso de caprinos ou ovinos e deve seguir o procedimento abaixo (GAMA, 2017) :

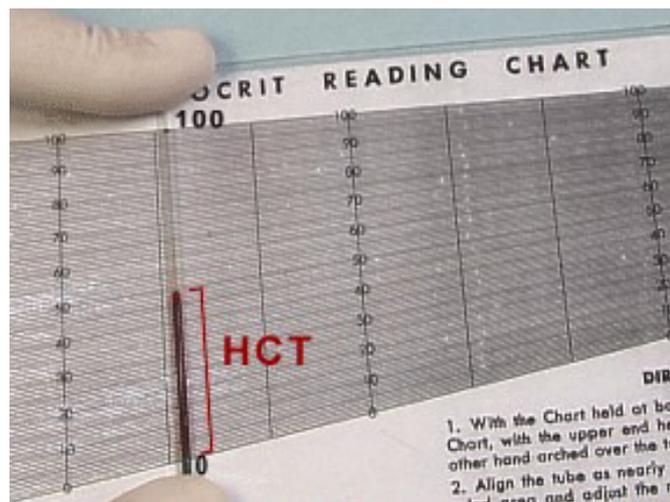
- preencher um tubo capilar com sangue até $\frac{3}{4}$ da sua altura. vide Figura 2;
- fechar as extremidades do capilar com a lamparina;
- colocar o capilar em uma centrífuga apropriada, com velocidade entre 10000 a 12000 rpm. Para caprinos a centrifugação é realizada por 15 minutos devido ao fato de que esta espécie apresenta menor volume globular médio, ou seja, menor volume eritrocitário.

Figura 2 – Capilar utilizado para o exame de hematócrito em caprinos.



Gama (2017)

Figura 3 – Método de avaliação hematócrito.



LabFisio (2017)

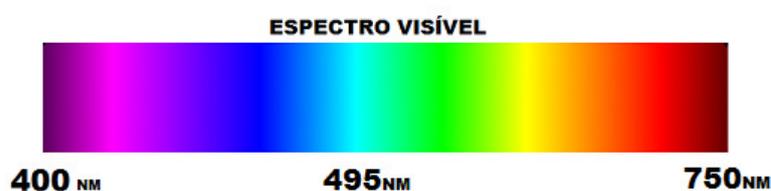
Na Figura 3 pode-se visualizar uma representação da técnica de micro hematócrito, para avaliar os níveis de hematócritos usa-se uma escala de milímetros e uma tabela de referência para a espécie avaliada.

2.3 Modelos de cores

O olho humano reage à luz através de três tipos de receptores sensíveis aos comprimentos de ondas eletromagnéticas distintos. Assim, cada um dos receptores reage a um espectro de comprimento de onda, e repassa ao cérebro a intensidade dessa reação, este por sua vez interpreta cada estímulo recebido como uma cor diferente, através de definições já aprendidas (FERNANDES, 2009).

Esse modelo tricromático foi proposto por Young-Helmholtz (OLIVEIRA; BAROLLI, 2009), é baseado no aspecto visível da luz e na reação dos receptores oculares existentes nos olhos de cada pessoa. Com essa informação em mãos, a *Commission Internationale de l'Éclairage* (CIE), organização criada para realizar estudos sobre a iluminação, definiu um modelo para representação das cores no espectro de comprimento de ondas eletromagnéticas visíveis. Esse modelo foi então chamado CIE-RGB, ou popularmente RGB (*RED*, *GREEN* e *BLUE*), e define que todas as cores nada mais são do que uma combinação das três cores primárias aditivas: vermelha, verde e azul, respectivamente. A Figura 4 representa as cores associadas ao respectivo comprimento de onda.

Figura 4 – As cores e seus respectivos comprimentos de onda dentro do espectro visível



Maciel (2017)

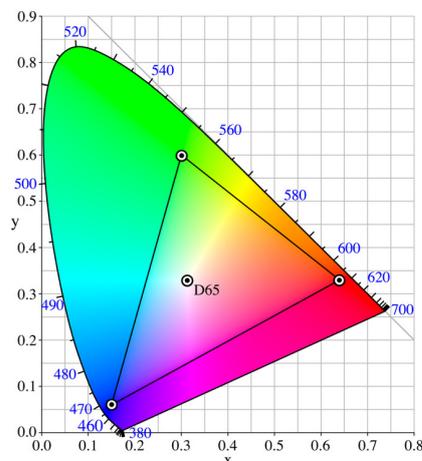
Um dos problemas dessa definição é a possibilidade de obter valores de pesos negativos para os componentes das cores, para resolver isto, foi definido pela CIE um novo modelo de cores primárias chamado de XYZ ou triestímulos.

Uma vez definida a base de cores primárias, é possível construir modelos de representação de cores em forma de sistemas de coordenadas de três dimensões, onde cada eixo representa uma cor primária (HUGHES; FOLEY, 2014).

Com essa definição, é possível mudar de sistemas de coordenadas e a representação das cores afim de auxiliar a construção de sistemas de computação com representação de cores eficiente.

Na Figura 5 o triângulo representa a região de cores que as três cores primárias aditivas podem representar.

Figura 5 – Diagrama do triestímulo



Souto (2000)

2.3.1 Modelo de cores RGB

O modelo de cores RGB é o mais utilizado para representação das cores em sistemas computacionais, estando presente nos mais diversos dispositivos. Como descrito anteriormente, o modelo é formado por três componentes de cores, sendo: o R (*RED*) vermelho, o G (*GREEN*) verde e o B (*BLUE*) azul (RIBEIRO, 2016).

Esse espaço de cor é dito aditivo, ou seja, a geração das cores é feita através da soma dos valores de suas componentes. A soma dos valores totais das componentes gera a cor branca enquanto a soma dos valores mínimos gera a cor preta. É necessário também usar um intervalo de valores pré-estabelecidos, em geral, este intervalo é fixado de 0 (valor mínimo) até 255 (valor máximo) para todas as componentes de cores.

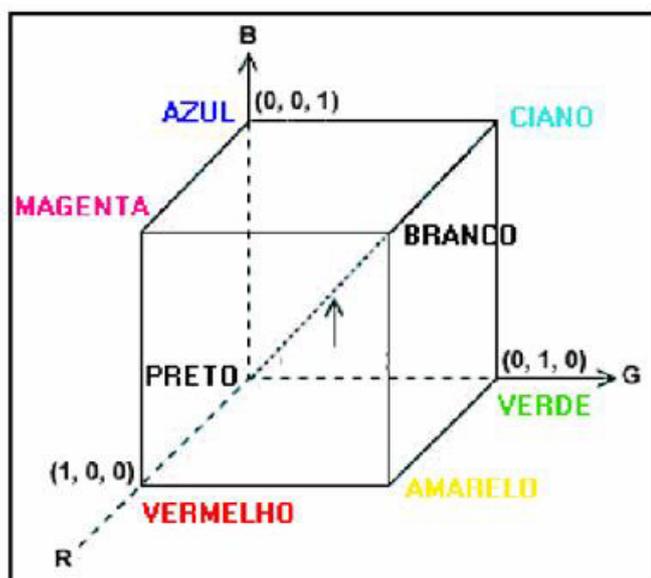
O espaço RGB pode ser ilustrado por um cubo, como pode ser visto na Figura 6, no qual as vértices contém as cores básicas (RIBEIRO, 2006).

Para a formação de imagens, cada pixel recebe o valor de uma tupla RGB, assim cada pixel é composto de três valores ou bytes. Como cada componente é armazenada em bytes, cada um pode representar até 256 intensidades diferentes e com isto até 16,7 milhões de cores. Quando um dispositivo alcança essa capacidade diz-se que ele é *truecolor* (RIBEIRO, 2006).

Vários espaços de cores foram derivados a partir do RGB, como o RGBA (*red, green, blue* e *alpha*) onde as três componentes são acompanhadas por um valor A que representa a *alpha* ou a intensidade daquela cor, e o sRGB que é padrão mais utilizado para fotografias e softwares editores de imagens.

Uma propriedade interessante do espaço RGB é sua normalização. A normalização consiste em gerar novos valores para cada componente entre a razão do seu valor e a soma dos valores das demais. Os componentes gerados podem ser chamados de cores puras, uma vez que a normalização reduz a dependência das cores quanto ao brilho e as torna robustas frente a posição

Figura 6 – Cubo representando o modelo de cores RGB



Souto (2000)

da fonte de luz em superfícies opacas (CABRAL, 2008).

$$r = R/(R + G + B) \quad (1)$$

$$g = G/(R + G + B) \quad (2)$$

$$b = B/(R + G + B) \quad (3)$$

Onde r , g e b serão as componentes normalizadas que irão compor os pixels da imagem resultante e R , G e B são as componentes do espaço RGB com variação de 0 a 255. Após a normalização os valores dos canais r , g e b são fixados dentro do intervalo que varia entre 0 e 1, como pode ser visto na Figura 6.

Neste trabalho o modelo de cores RGB foi utilizado para fornecer uma resposta amigável ao usuário nas etapas de seleção de imagens e no resultado da extração de características.

2.3.2 Modelo de cor LAB

O modelo de cor LAB é um espaço de cores uniformemente distribuídas e de cromaticidade uniforme. Tem uma distribuição perceptualmente uniforme, luminosidade separada da cromaticidade e é a representação dos contrastes cromáticos naturais do ser humano (ALVES, 2011).

O espaço de cor LAB é obtido através de operações no espaço XYZ resultando nas coordenadas (OLIVEIRA, 2006):

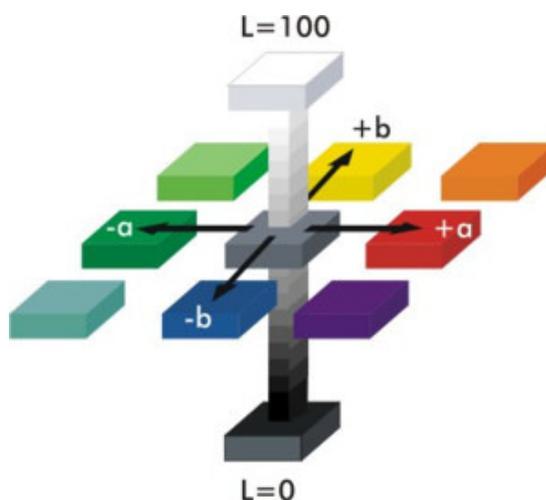
$$L^* = 116 \cdot (\sqrt[3]{Y/Y_n}) - 16 \quad (4)$$

$$a^* = 500 \cdot \left[(\sqrt[3]{X/X_n}) - (\sqrt[3]{Y/Y_n}) \right] \quad (5)$$

$$b^* = 200 \cdot \left[(\sqrt[3]{Y/Y_n}) - (\sqrt[3]{Z/Z_n}) \right] \quad (6)$$

onde L^* representa o componente de iluminação que varia entre 0 (totalmente escuro) e 100 (totalmente claro). A componente a^* varia entre -90 e 70 e representa a variação entre o verde (valores negativos) e o vermelho (valores positivos), enquanto a componente b^* varia entre -80 e 100 refere-se à escala de azul a amarelo respectivamente e Y , Y_n representam as coordenadas do eixo Y no modelo de cor XYZ e Y_n o valor do ponto neutro (sem cor) do espaço de cor. Enquanto X , X_n e Z, Z_n representam as coordenadas X e Z e as coordenadas no ponto neutro para as componentes X e Z respectivamente.

Figura 7 – Representação do espaço de cor L.A.B



Alves (2011)

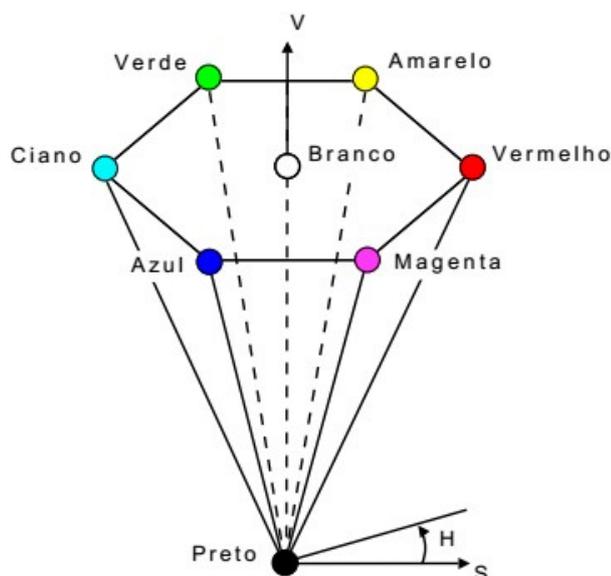
O modelo LAB é um espaço de cor absoluta. As cores aplicadas utilizando este modelo terão mesma intensidade, seja qual for o dispositivo de imagem que as apresente. Assim, o LAB define de forma mais exata as cores, o que possibilita classificá-las de forma mais precisa (MINOLTA, 2013), sendo utilizado neste trabalho na etapa de extração de características afim de definir as cores percebidas. A representação do modelo de cor LAB pode ser vista na Figura 7.

2.3.3 Modelo de cor HSV

O modelo HSV é definido como a composição de três componentes: H (*hue* ou matiz), S (*Saturação*) e V (*luminância*). A *Matiz* representa a pigmentação, em geral, cores primárias tem

maiores níveis de matiz. A *Saturação* descreve o quanto aquela cor é pura, ou seja, a quantidade de cor branca que é adicionada ao matiz. A *luminância*, ou valor, representa a quantidade de luz refletida por aquela cor (claro ou escuro) (AVILA, 2008). Neste trabalho foi utilizado a componente H pois, através de testes, foi constatado que essa componente distingue a região de interesse.

Figura 8 – Cone de representação do modelo HSV



Avila (2008)

Na representação do modelo HSV, Figura 8, pode-se ver que a componente H tem seu intervalo definido em graus, partindo de 0° até 360° . A componente S é definida como sendo a razão entre o nível de pureza de uma *matiz* e a pureza máxima conhecida, assim a variação do intervalo de S é entre 0 e 1. A componente V representa a luminância e pode ser definida como 0 para cor preta (pouca luz) e 1 para cor branca (muita luz).

Segundo Avila (2008), para se obter o espaço HSV a partir do espaço RGB normalizado, deve-se seguir as seguintes equações:

$$V = \max \quad (7)$$

$$S = (\max - \min) / \max; \quad (8)$$

$$H = \begin{cases} \frac{G-B}{\max-\min} \times 60, \max = R \\ 2 + \frac{B-R}{\max-\min} \times 60, \max = G \\ 4 + \frac{R-G}{\max-\min} \times 60, \max = B \end{cases} \quad (9)$$

Para *max* sendo o valor máximo entre os valores R,G e B e *min* o valor mínimo de cada pixel.

Assim como é possível determinar novos modelos de cores a partir do RGB, também é possível gerar uma imagem em tons de cinza. Para isso todas as componentes de cores primárias devem ter a mesma intensidade. Ou seja, é possível representar as cores através de apenas uma componente. Esta componente pode ser obtida através da média simples ou ponderada dos valores dos canais (SILVEIRA, 2008).

$$CINZA = (VERMELHO + VERDE + AZUL)/3 \quad (10)$$

A média ponderada pode ser definida como:

$$CINZA = (VERMELHO * 0,3 + VERDE * 0,59 + AZUL * 0,11) \quad (11)$$

A média simples produz uma imagem sem iluminação, enquanto a média ponderada gera uma imagem em que a iluminação pode ser melhor identificada. Os parâmetros para a média ponderada foram estipulados através da transmissão de imagens em monitores de fósforos e seu valor é dado pela extremidade do *gamut* do espaço RGB (MENEZES, 2010).

2.4 Segmentação de imagem

A segmentação de imagens pode ser descrita como o particionamento de uma imagem em seus objetos constituintes, para facilitar sua análise. No geral, este processo é o mais complexo da análise de imagem, podendo determinar o sucesso ou o fracasso do procedimento (NEVES et al., 2008).

Muitas das formas de segmentação são baseadas na utilização de imagens em escala de cinza, ou seja, aquelas que possuem uma única amostra do espaço de cor ou uma componente apenas. Existem duas abordagens para realizar segmentação desse tipo de imagens: a primeira analisa a similaridade dos pixels e sua localização; a segunda, a descontinuidade de uma característica da imagem.

Na abordagem por similaridade, utiliza-se técnicas como limiarização (*Thresholding*); corte e junção (*split & merge*); e crescimento de regiões (*region growing*). São técnicas que se baseiam nas propriedades conjuntas de objetos dentro da imagem, isolando assim aqueles com as características desejadas.

Na abordagem por descontinuidade, a ideia é identificar mudanças abruptas dos níveis de cinza (característica). Englobam técnicas utilizadas para detectar bordas, regiões isoladas e contornos.

2.4.1 Pré-processamento

Para maximizar a eficiência do processo de segmentação, utilizam-se técnicas de pré-processamento de imagens, como redução de ruídos com filtros de passa-baixa. Um dos principais

filtros de passa-baixa é o filtro gaussiano, que pode ser definido como (JESUS; JR, 2015):

$$G(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(\mu-x)^2}{2\sigma^2}} \quad (12)$$

onde σ simboliza o desvio padrão, x é o conjunto de valores das componentes de cada pixel e μ a média dos valores de x . Para aplicações em duas dimensões, o filtro tem a seguinte definição:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (13)$$

O desvio padrão define a largura da curva Gaussiana e essa largura define o poder de suavização do filtro, sendo o desvio padrão diretamente proporcional a largura e conseqüentemente ao poder de suavização.

O filtro Gaussiano tem o mesmo grau de suavização em todas as direções. A nova imagem é definida pela média ponderada (u) dos pixels em volta de um pixel central (x). O filtro funciona de forma que o peso dado a um vizinho decresça de forma monótona com relação a distância do pixel central suavizando os pixels mais próximos de forma mais aguda e os distantes de forma mais amena.

2.4.2 Limiarização

Pode-se definir a operação de limiarização como sendo uma função que recebe uma imagem com N níveis de cinzas, e retorna uma imagem limiarizada cujo os níveis de cinza são menores que N e estão dentro de um limiar T , isolando assim os níveis dos objetos de interesse. A equação abaixo ilustra o conceito.

$$G(x, y) = \begin{cases} 0, & F(x, y) \geq T \\ 1, & F(x, y) < T \end{cases} \quad (14)$$

em que $F(x,y)$ é uma imagem em níveis de cinza de entrada, e $G(x,y)$ é a imagem gerada pela limiarização utilizando um único limiar T . Como descrito na equação, os pixels rotulados como 1 pertencem a imagem de interesse enquanto o 0 representa o fundo.

Para utilizar dois limiares, a representação é definida na equação a seguir:

$$G(x, y) = \begin{cases} 1, & T1 \geq F(x, y) < T2 \\ 0, & \text{demais} \end{cases} \quad (15)$$

Um dos principais problemas da técnica de limiarização, é definir um limiar que identifique em todos os casos, a região de interesse de uma imagem. Uma das técnicas usadas para definir um limiar é a análise de histogramas (NEVES et al., 2008).

Um histograma para imagens, pode ser definido como sendo um conjunto de frequências que indicam o percentual de pixels naquela imagem que apresentam determinado nível de cor ou de cinza. Ele pode indicar a qualidade e o nível de contraste de uma imagem, bem como se ela é predominantemente clara ou escura. No geral, o histograma apresenta uma ideia total da imagem analisada.

Cada elemento do histograma pode ser obtido como:

$$P(r) = \frac{M}{N} \quad (16)$$

para M sendo os pixels com as características desejadas, N a quantidade total de pixels e P(r) é a probabilidade no r-ésimo nível de pixel.

Assim, definem-se os limiares com base nas representações da porcentagem dos níveis da imagem, independente dos valores dos pixels. Podendo abstrair os valores dos níveis de cinza e apenas isolar regiões conforme suas características predominantes. Neste trabalho a limiarização foi utilizada para isolar a região da conjuntiva, utilizando análise de histogramas para definição dos limiares.

2.4.3 Detecção de bordas

A detecção de bordas é uma técnica baseada na descontinuidade dos níveis de uma imagem, onde mudanças bruscas nesses níveis são definidos como borda ou parte externa, e as demais regiões como a parte interna ou centro.

Existem quatro modelos de bordas que descrevem a transição entre os níveis de cinza da imagem, Figura 9, caracterizando uma borda.

- (a) borda em degrau (*step*): caracteriza uma mudança aguda entre as duas regiões analisadas;
- (b) borda tipo linha (*spike*): ascende e descende numa estreita faixa de transição;
- (c) borda tipo telhado (*roof*): tem ponto máximo bem definido entre a ascensão e queda;
- (d) borda tipo rampa (*ramp*): com uma área de transição ascendente ou descendente.

Figura 9 – Tipos de borda



Savant (2014)

Operadores utilizados para detectar bordas usam derivadas de primeira ordem ou de segunda para determinar a taxa de variação dos níveis. Operadores de primeira ordem são denominados gradiente e os de segunda ordem laplacianos.

Um gradiente pode ser definido para uma função f da seguinte maneira:

$$\nabla f(x, y) = \frac{\partial f(x, y)}{\partial x} dx + \frac{\partial f(x, y)}{\partial y} dy \quad (17)$$

em que $\frac{\partial f(x,y)}{\partial x} dx$ e $\frac{\partial f(x,y)}{\partial y} dy$ representam a derivada parcial da função da imagem $f(x, y)$ nas direções x e y , respectivamente, e sua amplitude definida como:

$$\|\nabla f(x, y)\| = \sqrt{\left(\frac{\partial f(x, y)}{\partial x} dx\right)^2 + \left(\frac{\partial f(x, y)}{\partial y} dy\right)^2} \quad (18)$$

Em que $\|\nabla f(x, y)\|$ define a magnitude do vetor gradiente. A magnitude define a taxa de crescimento da função permitindo identificar o aparecimento de uma borda. Para calcular o valor das derivadas das direções utiliza-se a técnica de diferenças finitas definida abaixo:

$$\begin{cases} f_x = \frac{\partial f}{\partial x} \approx \lim_{h \rightarrow 0} \frac{f(x+h, y) - f(x, y)}{h} \\ f_y = \frac{\partial f}{\partial y} \approx \lim_{h \rightarrow 0} \frac{f(x, y+h) - f(x, y)}{h} \end{cases} \quad (19)$$

onde h define o tamanho do pixel e fixa-se seu valor como 1. A partir dessa aproximação chega-se as expressões:

$$\begin{cases} G_x = f(x + 1, y) - f(x, y) \\ G_y = f(x, y + 1) - f(x, y) \end{cases} \quad (20)$$

Com base nessa aproximação e a partir de operações básicas, o vetor gradiente pode ser definido como, em que G_x e G_y são valores das derivadas parciais da imagem:

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} \quad (21)$$

Operadores como *Sobel*, *Roberts* e *Prewitt* utilizam máscaras de convolução para calcular a primeira derivada de uma imagem, e para gerar efeitos de suavização de ruídos.

Para detecção de bordas, alguns filtros, após as operações com as máscaras de convolução, checam se o nível de cinza do pixel encontrado está acima ou abaixo de um limiar.

Um exemplo seria o filtro de *Sobel*, onde as máscaras:

$$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ 1 & 0 & -1 \end{bmatrix}$$

São multiplicadas com a imagem de entrada I_x , resultando nas representações de $\frac{\partial}{\partial x} I$ e $\frac{\partial}{\partial y} I$, de onde pode-se obter o valor do pixel em um ponto de I através da expressão:

$$\nabla = \sqrt{I_x^2(x, y) + I_y^2(x, y)} \quad (22)$$

O valor ∇ é finalmente comparado a um limiar T e de acordo com as regras:

$$I_{sobel}(x, y) = \begin{cases} 0 & \text{se } \nabla I \geq T \\ 1 & \text{se } \nabla I < T \end{cases} \quad (23)$$

São ditos 1 os pixels que definem a borda e 0 para o fundo. Neste trabalho a diferenciação entre borda e fundo foi utilizada para definir as bordas da região de interesse e possibilitar o recorte na imagem original.

2.4.4 Erosão

A operação erosão é um tipo de filtro morfológico que tem sua definição na equação abaixo:

$$A \ominus B = \{x | (B)x \subseteq A\} \quad (24)$$

A erosão de A por B é o conjunto de todos pontos x , tal que, B transladado por x , está contido em A. Onde A é o conjunto de pixels da imagem, B é o elemento estruturante usado na dilatação e x é o conjunto de pontos resultantes dessa operação (MELLO, 2008).

Define-se o elemento estruturante, ou *kernel*, como um conjunto definido e conhecido de pontos, forma e tamanho, que é contido inteiramente no conjunto da imagem e pode ter formatos variados.

Para se obter o conjunto resultado, composto por pixels x , é necessário que o conjunto representado pelo elemento estruturante esteja totalmente centrado e posicionado em um pixel x pertencente a A. Neste caso, esse pixel é considerado relevante e irá compor a imagem resultante.

A aplicação da erosão em imagens tem como efeitos:

- diminuir partículas (remover ruídos);
- eliminar componentes menores que o elemento estruturante;
- aumentar buracos;
- desconectar componentes.

Neste trabalho foi utilizado o elemento estruturante em formato de cruz, para reduzir a área dos objetos e remover ruídos.

2.4.5 Dilatação

A operação dilatação é um tipo de filtro morfológico e sua definição é dada pela equação abaixo:

$$A \oplus B = \{z | (B \cap A \neq 0)\} \quad (25)$$

Onde A representa a imagem de entrada, B o elemento estruturante (ou *kernel*) e z o ponto resultante da operação. A dilatação consiste em percorrer a matriz de pontos do elemento estruturante checando junto ao conjunto da imagem aquele que atinge, na imagem, um elemento não nulo, como a regra definida abaixo demonstra (MELLO, 2008):

$$g(x, y) \begin{cases} 1 & \text{se } b \text{ encontra } a \\ 0 & \text{caso contrario} \end{cases} \quad (26)$$

Caso o elemento seja nulo, o valor atribuído ao novo pixel será zero.

A operação de dilatação é utilizada para aumentar os contornos de um objeto preenchendo espaços em branco em áreas contínuas.

Neste trabalho a dilatação foi utilizada com um elemento estruturante totalmente positivo, para eliminar espaços em brancos nas regiões contínuas, ou seja, manter a região da conjuntiva íntegra sem ruídos ou pontos de descontinuidade.

2.5 Extração de característica

Um método de extração de características é definido como o conjunto de operações que geram um subespaço apropriado de dimensionalidade M , tal que, M representa o número de características que é obtido a partir de um espaço de dimensionalidade D (objeto) com M contido em D .

A escolha correta do método de extração de características é uma etapa particularmente importante na criação de sistemas de reconhecimento de padrões. As características de um objeto devem descrevê-lo de forma eficiente com relação a objetos semelhantes ou distintos, influenciando diretamente a capacidade de classificação de um sistema de reconhecimento de padrões (QUINTA; PISTORI, 2008).

Para imagens, as características podem ser definidas de acordo com a cor, brilho, textura, forma e etc, e podem ser apresentadas de forma numérica ou descritiva. Os tipos principais de características que podem ser obtidos em imagens, podem ser classificados como:

- características globais:
 - são características que definem a imagem como um todo: área, intensidade, histogramas, entre outros;
- características locais:
 - normalmente calculada de acordo com um contorno ou região isolada da imagem (região de interesse);
- características Relacionais:
 - posições relativas de objetos com relação a um objeto distinto: contornos fechados, transições de níveis, entre outras.

2.5.1 Descritores de imagens

Um descritor é responsável por capturar informações de uma imagem e compará-las com uma base conhecida, para que possa estabelecer semelhanças entre classes de imagens.

Um descritor é composto por dois componentes principais: um extrator de características, e a função de reconhecimento da imagem. O primeiro componente extrai as características da imagem, enquanto o segundo calcula a similaridade, usando algoritmos classificadores (SILVA, 2014).

2.5.2 Border/Interior Classification (B.I.C).

Segundo Picon et al. (2011), o descritor BIC ou *Border/Interior Classification* é um descritor de cores que utiliza o espaço de cores RGB, quantizado em 64 cores, para gerar uma representação compacta da imagem utilizando dois histogramas, um para os pixels internos outro para pixels de borda. Um pixel é considerado interno caso possua a mesma cor que sua vizinhança, caso contrário, de borda.

A vizinhança da análise pode ser feita considerando 4 ou 8 pixels nas proximidades do pixel atual. Uma vez que os pixels são analisados, os histogramas resultantes são concatenados e um novo vetor é gerado, esse vetor representa as características extraídas pelo BIC.

Ainda segundo Picon et al. (2011), caso a proporção de pixels de uma cor em relação aos pixels internos seja menor que os pixels de borda, então pelo menos uma das seguintes características é verdadeira:

- a cor é distribuída em regiões relativamente grandes e com formato irregular;
- a cor é distribuída em pequenas regiões conectadas tais que a borda de cada região é maior que seu interior;
- a cor é parte de uma região rica em informações de textura.

Caso o número de pixels de borda de uma cor seja menor que os interiores, então a cor é distribuída de forma homogênea.

2.5.3 Média

Média aritmética é definida como o valor que mostra a concentração dos dados de uma distribuição como, por exemplo, o ponto de equilíbrio das frequências de um histograma. Abaixo é apresentada a definição matemática de média (PORTALACTION, 2017):

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i \quad (27)$$

Para a equação acima $x_1 + x_2 + \dots + x_n$ representam cada elemento da população de dados, enquanto que n define o tamanho total da população. Em imagens, a média é feita utilizando os valores dos pixels em cada canal e depois a média total é feita entre a soma das médias de cada canal e a quantidade de canais da imagem.

2.5.4 Variância

A variância é definida como uma medida de dispersão, que verifica o quão um elemento está distante da média da população, ou seja, o quanto ele se diferencia do restante da população analisada. A equação abaixo ilustra como obter a variância (PORTALACTION, 2017):

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (28)$$

Onde temos x_i como elemento da população, \bar{x} representa a média aritmética e por fim n o tamanho da população total.

2.5.5 Desvio padrão

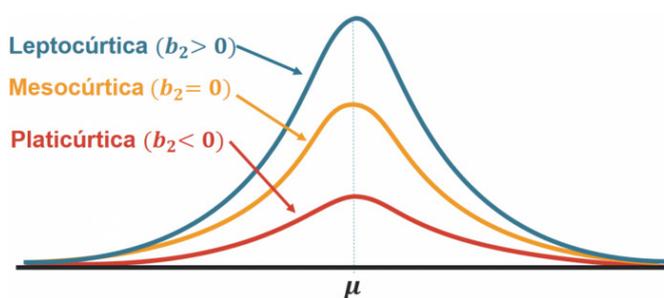
O desvio padrão é definido como σ ou, simplesmente, como o resultado da raiz quadrada da variância. O desvio padrão indica o erro obtido na substituição de um indivíduo da população, pelo valor da média. Pode ser obtido pela expressão (PORTALACTION, 2017):

$$\alpha = \frac{\sum_{i=1}^n |x - \bar{x}|^2}{n} \text{ tal que } \sigma = \sqrt{\alpha} \quad (29)$$

2.5.6 Kurtosis (curtose)

Esta medida de dispersão é definida como o fator de achatamento de uma curva com relação a curva de gauss. A curtose indica quão distante da curva normal os dados da distribuição estão, assim aplicada aos histogramas das imagens, pode-se saber qual curva se aproxima mais ou se afasta de uma distribuição homogênea (PORTALACTION, 2017). A Figura 10 apresenta a análise realizada através da curtose.

Figura 10 – Curvas e tipos de Curtose



Portalaction (2017)

A curtose é obtida da seguinte forma:

$$k = \frac{m_4}{s^4} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^2} \quad (30)$$

onde: M é o momento estatístico de ordem 4, e S é o desvio padrão.

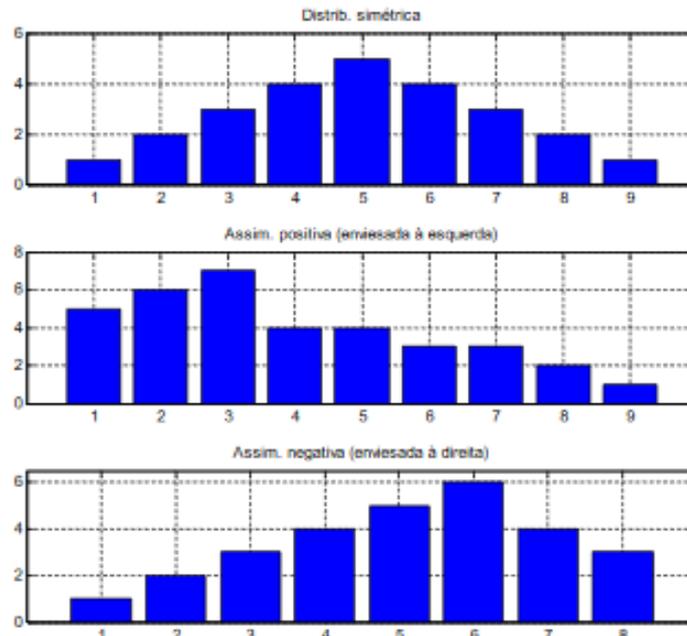
Existem três tipos de curtose:

- mesocúrtica ou curtose média é equivalente a Curva Normal ou Curva de Gauss;
- platicúrtica significa que a curva está mais achatada ou com "base pesada";
- leptocúrtica significa que a curva é mais intensa e com o pico superior á curva normal.

2.5.7 Skewness (Assimetria)

Consiste no grau de inclinação da distribuição do seu eixo de simetria, podendo estar inclinada pela direita ou pela esquerda, caracterizando um afastamento negativo ou positivo respectivamente (PORTALACTION, 2017). A Figura 11 demonstra a análise da assimetria.

Figura 11 – Exemplos de Skewness



Mendes (2011)

A definição da Assimetria é dada pela equação:

$$s_k = \frac{m_3}{s^3} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\sqrt{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^3}} \quad (31)$$

onde: M é o momento estatístico de ordem 3, e S é o desvio padrão.

2.5.8 SMOTE - *Synthetic Minority Over-sampling Technique*

A técnica SMOTE ou *Synthetic Minority Over-sampling Technique* consiste em gerar instâncias sintéticas com base em uma vizinhança de k elementos. Em geral, são utilizados vizinhos pertencentes à classe com a menor quantidade de elementos, ou minoritária, da base com o intuito de aumentar sua representação no processo de aprendizado. Para cada vizinho próximo de um elemento *pivot*, pertencente à vizinhança, é calculada uma nova instância através da interpolação, segundo a Equação 32 apresentada abaixo (VARASSIN et al., 2012).

$$X_{novo} = X_{pivot} + \lambda(X_{vizinho} - X_{pivot}) \quad (32)$$

Onde λ é um número aleatório compreendido entre $[0, 1]$, X_{novo} é a nova instância gerada entre o $X_{vizinho}$ e o X_{pivot} . Para este trabalho foi escolhido um k de valor 2, o que significa que a classe minoritária da base foi duplicada.

2.6 Aprendizado e classificação

O aprendizado de máquinas é feito através de indução, ou seja, a partir de exemplos de dados anteriores, obtém-se uma solução para uma classe de problemas com características semelhantes. O aprendizado pode ser realizado de forma supervisionada ou não supervisionada (LORENA; CARVALHO, 2007).

No aprendizado supervisionado, a forma de representação de conhecimento é feita através da inserção de exemplos que contenham os conjuntos de entradas rotuladas em classes definidas. O algoritmo de aprendizado de máquina extrai a representação de conhecimento a partir dos exemplos e seus rótulos. A representação gerada tem como finalidade gerar saídas satisfatórias para um conjunto de entradas, não representadas anteriormente nos exemplos, e com rótulos desconhecidos.

O aprendizado não supervisionado não é feito através de exemplos rotulados, como o supervisionado. As entradas do algoritmo são representadas através de uma medida de similaridade, onde a população de entrada é rotulada de acordo com essa medida, e o processo de aprendizagem se encarrega de calcular a similaridade entre os indivíduos dessa população. O aprendizado de máquina não supervisionado é comumente utilizado na busca de padrões, agrupamentos ou hierarquias, para o entendimento de grandes massas de dados das quais não se tem uma ideia prévia de seus rótulos (classes).

Alguns passos são fundamentais no processo de aprendizado não supervisionado:

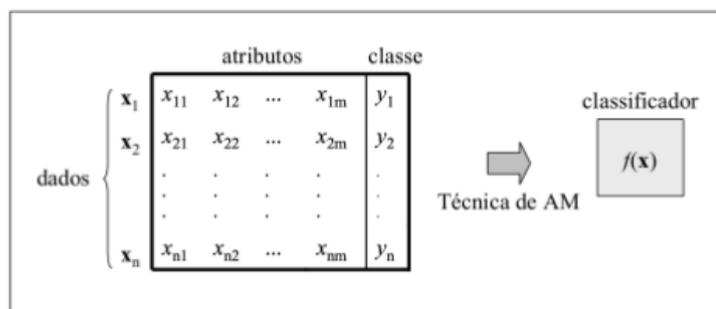
- seleção de características;
- medida de similaridade ou otimização da função de proximidade;
- critérios de *cluster* ou agrupamento;
- validação de resultados;
- entendimento de dados.

Neste trabalho o modelo de aprendizado utilizado foi o supervisionado, uma vez que os dados utilizados dispõem de rótulos bem definidos na população de entrada e o foco será em reconhecer cada rótulo de forma eficaz.

O aprendizado supervisionado tem seus conjuntos rotulados da forma (X_i, y_i) , em que X_i representa um exemplo ou um conjunto de treinamento e y_i o rótulo (fenômeno) sobre o qual se deseja prever algo. Para induzir qual o rótulo dos novos dados de entrada a partir dos exemplos, utiliza-se um classificador (ou modelo preditor). A forma de indução usando um

classificador pode ser definida como f recebe X como população e fornece y como predição, essa indução pode ser denominada como *treinamento* (LORENA; CARVALHO, 2007).

Figura 12 – Geração de um classificador



Lorena e Carvalho (2007)

Pela Figura 12 tem-se um conjunto de dados de tamanho n e para cada x_i possui m atributos, e um conjunto de classes tal que cada y_i simboliza um rótulo para determinado conjunto X .

O processo de escolha de classificadores, a partir de um conjunto de dados, em um processo de aprendizado de máquina, pode ser definido como uma atividade de busca, onde procura-se entre todas as hipóteses geradas pelo algoritmo aquela que mais descreve o domínio de aprendizado.

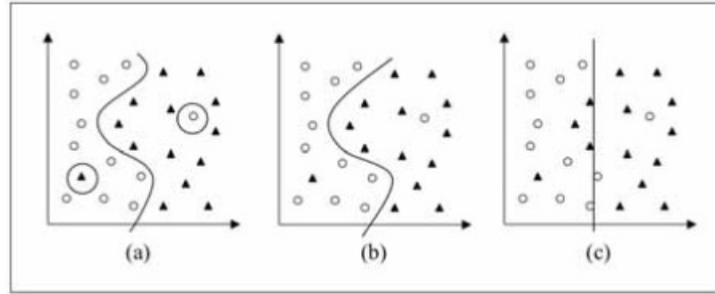
Um classificador deve ter grande abrangência de hipóteses, ou seja, deve ser capaz de responder corretamente a predição de novos dados. Caso negativo, e dependendo do tamanho e variabilidade dos dados de treinamento, diz-se que o classificador sofreu um dos seguintes tipos de eventos: *overfitting* ou *underfitting*.

Overfitting simboliza uma especialização do classificador aos dados de treinamento, ou seja, o classificador é apenas capaz de classificar os valores do conjunto de treinamento e, em dados de entrada novos, o classificador tem uma baixa taxa de acerto. Enquanto que *underfitting* ocorre quando os exemplos de treinamento são pouco representativos, o que dificulta a predição de novos dados. Ambos os eventos devem ser evitados e para isso uma base de dados com uma quantidade relativamente alta de exemplos deve ser utilizada para treinamento.

Para estimar as taxas de acerto e de erro, o conjunto de entrada é dividido em dois subconjuntos distintos: um de treinamento que será utilizado na criação do modelo de predição (aprendizado do conceito) e o de teste que será utilizado para medir a efetividade do aprendizado do conceito.

A Figura 13 apresenta no caso (a) um exemplo de *overfitting* em que o classificador consegue classificar corretamente todo o conjunto de teste incluindo os ruídos. Neste caso, o classificador terá uma baixa taxa de acerto para novos dados. No caso (c) houve uma desconsideração de dados em classes opostas que estão muito próximas entre si. Essa abordagem causa diversos erros tanto de treinamento quanto de classificação. Portanto, o classificador não consegue se

Figura 13 – Conjunto de treinamento com três hipóteses



Schölkopf e Smola (2002)

adaptar aos exemplos de treinamento e a dados novos de teste, caracterizando *underfitting*. No caso (b) temos um meio termo dos classificadores anteriores, que possui complexidade intermediária e classifica satisfatoriamente os dados do conjunto de teste sem se fixar em pontos individuais.

2.6.1 Máquinas de Vetores de Suporte

O SVM ou *Support Vector Machine* é uma técnica de aprendizado de máquina largamente aplicada em problemas de reconhecimento de padrões. O método SVM é essencialmente uma abordagem geométrica para classificação, onde cada instância (imagem) será representada como um ponto em espaço, e o aprendizado consiste em saber diferenciar elementos através de um hiperplano ótimo.

Máquinas de vetores de suporte (SVM) podem ser divididas entre lineares e não-lineares. Para SVMs lineares podemos considerar um conjunto de treinamento formado pela tupla X_i, y , tal que, X_i representa um conjunto de treinamento e y define a classe do conjunto de treinamento em questão. Supondo ainda que se possa traçar um hiperplano entre as classes delimitando o espaço positivo e negativo, esse hiperplano seria definido por $x \cdot w + b = 0$, tal que x são os pontos que estão sobre o hiperplano, enquanto $|b| \|w\|$ é a distância perpendicular do hiperplano a origem (LORENA; CARVALHO, 2007).

Dadas d^+ e d^- , como sendo as distâncias entre o hiperplano e os exemplos positivos e os negativos, respectivamente, pode-se definir uma tolerância como $d^+ + d^-$. Caso o conjunto de treinamento seja linearmente separável, os algoritmos de vetor de suporte deve tentar encontrar um hiperplano que maximize essa tolerância.

Para formular um modelo de classificação utilizando SVM, deve-se levar em consideração as restrições:

$$x_i \cdot w + b \geq +1 \quad \text{para} \quad y_i = +1 \quad (33)$$

$$x_i \cdot w + b \leq -1 \quad \text{para} \quad y_i = -1 \quad (34)$$

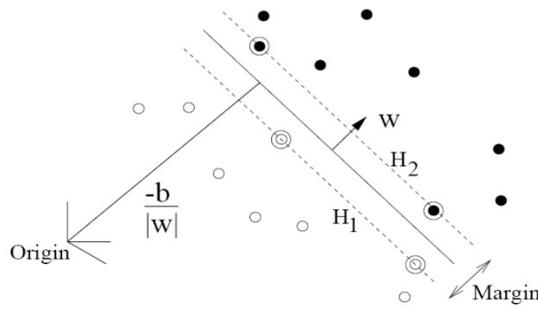
e a combinação:

$$y_i(x_i \cdot w + b) - 1 \geq 0, \quad i = 1, 2, \dots, D \quad (35)$$

Considerando que os exemplos que satisfazem a equação (33) são pontos sobre o hiperplano $x_i \cdot w + b = 1$, com normal w e distância perpendicular a origem de $\frac{|1-b|}{\|w\|}$. Simetricamente para a equação (34), os exemplos que a satisfazem são pontos abaixo do hiperplano $x_i \cdot w + b = -1$, com normal w e distância perpendicular a origem $\frac{|-1-b|}{\|w\|}$.

Assim, a largura da margem possui o valor $d^+ = d^- = \frac{1}{\|w\|}$ que pode ser compreendida como $\frac{2}{\|w\|}$, então pode-se encontrar dois hiperplanos que geram margem máxima através da minimização de $\|w\|^2$, levando em consideração as restrições definidas por (35). A Figura 14 dá uma noção da formalização do hiperplano.

Figura 14 – Hiperplano com tolerância (margem)



Santos (2012)

Deste modo, as margens (tolerâncias) podem ser definidas como:

$$\min \frac{1}{2} \|w\|^2 \quad (36)$$

Os pontos de treinamento para os quais a igualdade definida pela equação (35) é válida, são denominados como vetores de suporte, pertencendo a fronteira da tolerância (margem).

Para reduzir o trabalho de minimização da equação (35), introduz-se os multiplicadores de lagrangianos, evitando o produto cartesiano entre w e x . Os multiplicadores lagrangianos também permitem que os vetores de suporte sejam usados em problemas não linearmente separáveis, porém a introdução dos multiplicadores gera um problema de otimização dual.

A formulação lagrangiana consiste em aplicar multiplicadores lagrangianos a equação definida em (35), subtraindo da equação definida em (36), obtendo a expressão lagrangiana:

$$L(\alpha, \omega, b) = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^D \alpha_i [y_i(x_i \cdot \omega_i + b) - 1] \quad (37)$$

A otimização dual consistem dois passos: no primeiro tenta-se minimizar os valores da equação (35), utilizando ω e b ; o segundo passo consiste em minimizar o resultado do primeiro passo, com relação $\alpha \geq 0$. No ponto ótimo tem-se as seguintes equações para os pontos de cela.

$$\frac{\partial L}{\partial b} = 0 \quad e \quad \frac{\partial L}{\partial \omega} = 0 \quad (38)$$

Essas equações podem ser traduzidas como:

$$\sum_{i=1}^D \alpha_i y_i = 0 \quad e \quad \omega = \sum_{i=1}^D \alpha_i y_i x_i \quad (39)$$

Substituindo na equação (37), temos:

$$\max W(a) = \sum_{i=1}^D \alpha_i - \frac{1}{2} \sum_{i,j=1}^D \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (40)$$

$$\text{sujeito a } \alpha_i \geq 0, \quad i = 1, 2, 3, \dots, D \quad (41)$$

$$\sum_{i=1}^D \alpha_i y_i = 0 \quad (42)$$

Essa equação pode ser descrita como o segundo passo da otimização dual, por onde resolve-se este problema de maximização, usando o método de gradiente descendente, porém este método demora para convergir e é muito trabalhoso. Outros algoritmos como *Osuna* e otimização minimal sequencial possuem um resultado mais satisfatório.

Em uma iteração $K + 1$, pode-se definir α pela expressão:

$$\alpha_i(k + 1) = \alpha_i(k) + \eta \frac{\partial W}{\partial \alpha_i} \quad (43)$$

Onde $\eta > 0$ é a taxa de aprendizado. Uma vez concluída a otimização tem-se todos os coeficientes $\alpha, 1, 2, 3, \dots, D$. para expressar a função de decisão.

$$l(z) = \text{sign} \left[\sum_{i=1}^D y_i \alpha_i (z \cdot x_i) + b \right] \quad (44)$$

Onde $l(z)$ é a classe a qual z pertence e x_i são os vetores de suporte, tais que $\alpha > 0$.

Para determinados problemas de classificação, não é possível que os conjuntos de exemplos sejam separados linearmente. Nesses casos é necessário adaptar a definição dos vetores de suporte para que as restrições contenham variáveis de folga. Assim diz-se que as SVMs são não lineares.

$$\max W(a) = \sum_{i=1}^D \alpha_i - \frac{1}{2} \sum_{i,j=1}^D \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (45)$$

$$\text{sujeito a } 0 \leq \alpha_i \leq C, \quad i = 1, 2, 3, \dots, D \quad (46)$$

$$\sum_{i=1}^D \alpha_i y_i = 0 \quad (47)$$

Portanto, a única diferença entre vetores de suporte lineares e não lineares é a restrição nos multiplicadores lagrangianos. A função de decisão definida em (44) se mantém sem alteração (LORENA; CARVALHO, 2007).

Assim, para cada x_i , temos um valor de α_i associado, tal que $0 \leq \alpha_i \leq C$. Os vetores $x_i, i \in I := \{i : 0 < \alpha_i < C\}$ são validos para a igualdade:

$$\max W(a) = \sum_{i=1}^D \alpha_i - \frac{1}{2} \sum_{i,j=1}^D \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (48)$$

$$\text{sujeito a } 0 \leq \alpha_i \leq C, \quad i = 1, 2, 3, \dots, D \quad (49)$$

$$\sum_{i=1}^D \alpha_i y_i = 0 \quad (50)$$

2.6.2 *k*-Nearest Neighbor

Uma forma de identificar a classe de um exemplo, é apenas comparar as características desse exemplo, com outros cuja classe ou rótulo seja conhecido. O algoritmo KNN ou (*k*-Nearest Neighbor) consiste em encontrar os *k* vizinhos mais próximos do exemplo não classificado e, a partir desse conjunto de vizinhos, definir a classe do exemplo desconhecido.

Para classificar um novo exemplo utilizando o KNN, deve-se:

- calcular a distância entre o novo exemplo e a base de treinamento;
- identificar segundo o parâmetro *k*, os *k* vizinhos mais próximos;
- votar qual rótulo da base de treinamento será utilizado no novo exemplo, dando preferência ao rótulo mais dominante entre os *k* vizinhos encontrados no passo anterior.

A principal consequência da forma como o KNN seleciona exemplos similares, deve-se ao fato de que haverá um baixo consumo de recursos computacionais para o treinamento do algoritmo. Porém, para classificar um novo exemplo haverá um custo computacional elevado. O que significa, no pior caso, que o exemplo a ser classificado deverá ser comparado a todos os elementos dos conjuntos de treino.

O algoritmo depende de três parâmetros básicos para execução:

- exemplos de treinamento;
- qual a medida que identifica a similaridade dos itens do conjunto de treinamento e o novo exemplo;
- quantos ou quais vizinhos mais próximos devem ser considerados.

Exemplos de treinamento definem a capacidade do algoritmo de identificar o rótulo ou classe de um exemplo. Esses exemplos englobam todas as classes do problema e definem as características de cada uma. No entanto, o tamanho do conjunto de treinamento implica diretamente no consumo de recursos do algoritmo. Dessa forma, um conjunto de treinamento

muito extenso causa um consumo de recursos muito alto e não necessariamente significa um aumento da precisão da classificação, enquanto que um conjunto muito pequeno, apesar do baixo consumo de recursos, também pode não classificar corretamente o exemplo (FERRERO, 2009).

Uma boa forma de definir um conjunto de treinamento é utilizar uma quantidade de exemplos mais representativos de cada classe como exemplos mais definidos e com características que definam cada classe da forma mais inequívoca possível, reduzindo a informação a um conjunto pequeno de exemplos, porém mais significativos.

Uma medida de similaridade indica quão próximo um exemplo está do outro, ou o quão um exemplo é similar a outro. Diversas medidas podem ser utilizadas, sendo mais utilizadas as medidas de distância e de correlação.

Quando um exemplo é descrito por valores numéricos, as medidas de distância podem ser aplicadas para representar a similaridade de um exemplo a outro. Um exemplo é dito similar, caso a distância entre eles seja a menor distância do conjunto de entrada, assim os índices que definem a similaridade de um exemplo devem satisfazer as seguintes condições (FERRERO, 2009):

1. $dist(E_i, E_j) \geq 0, \forall(i, j)$
2. $dist(E_i, E_j) = 0$ se e somente se $E_i = E_j$ (identidade)
3. $dist(E_i, E_j) = dist(E_j, E_i)$ (simetria)

Para que um índice de similaridade seja usado como métrica, ele deve respeitar, além das propriedades acima, a propriedade de desigualdade triangular:

1. $dist(E_i, E_j) \leq dist(E_i, E_q) + dist(E_q, E_j), \forall(i, j, q)$

A distância entre exemplos n -dimensionais pode ser obtida através da expressão:

$$dist(E_i, E_j) = \left(\sum_{l=1}^n |x_{il} - x_{jl}|^d \right)^{\frac{1}{d}} \quad (51)$$

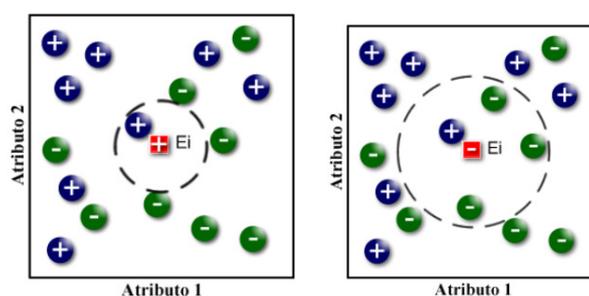
Tal que o valor de d define o tipo de distância utilizado entre os exemplos E_i (exemplo atual) e E_j (demais exemplos), assim se $d = 1$ tem-se a distância Manhattan/city-block, e quando $d = 2$ temos a distância euclidiana.

O algoritmo KNN classifica os exemplos em conjuntos de K elementos que possuem a classe correspondente ao exemplo a ser classificado. Portanto, para $K=1$, o exemplo terá a classe do exemplo mais próximo de acordo com a medida de similaridade escolhida. Para um $K > 1$, os exemplos serão classificados de acordo com a classe mais predominante do conjunto de exemplos mais próximos ao exemplo a ser classificado (FERRERO, 2009).

O número de vizinhos próximos a serem classificados influencia diretamente no resultado da classificação, portanto cada problema demanda um estudo apropriado sobre qual valor de K usar.

Para exemplos em que o valor de K seja maior que um é recomendado utilizar um K ímpar para evitar empates, em outros casos pode ser necessário atribuir pesos para cada um dos K exemplos mais próximos, de acordo com a medida de similaridade considerada. Os K vizinhos são ordenados por similaridade, aqueles mais próximos aos casos de exemplos ganham um peso maior, enquanto os exemplos menos similares ganham um peso menor. A Figura 15 representa o funcionamento do algoritmo knn.

Figura 15 – Algoritmo KNN com valores distintos de K



Ferrero (2009)

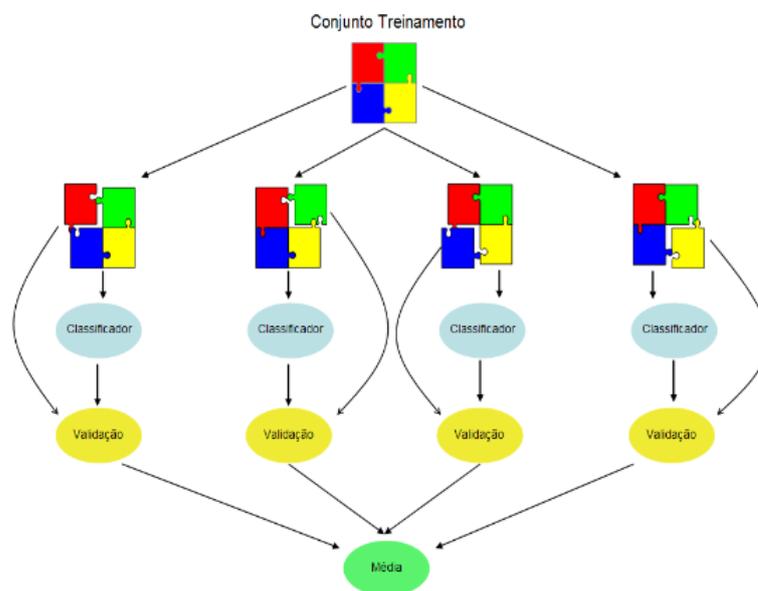
2.6.3 Validação cruzada

A validação cruzada consiste em dividir um conjunto de dados em K subconjuntos ou *folds*. A partir desses subconjuntos serão definidos $K-1$ como subconjuntos de treinamento, enquanto que o subconjunto restante será destinado aos testes. Todos os subconjuntos serão utilizados para gerar um modelo de classificação e validá-lo através do uso do classificador.

A operação de treinamento e validação do classificador é repetida K vezes, utilizando um subconjunto diferente para teste em cada iteração. Sendo esse subconjunto escolhido entre os subconjuntos de treinamento utilizados na iteração anterior, desse modo todos os subconjuntos serão utilizados tanto para teste quanto para treinamento (MELONI, 2009).

No final, é calculada a média dos resultados de cada iteração, obtendo-se assim as estimativas de qualidade do modelo gerado.

Figura 16 – Procedimento de validação cruzada.



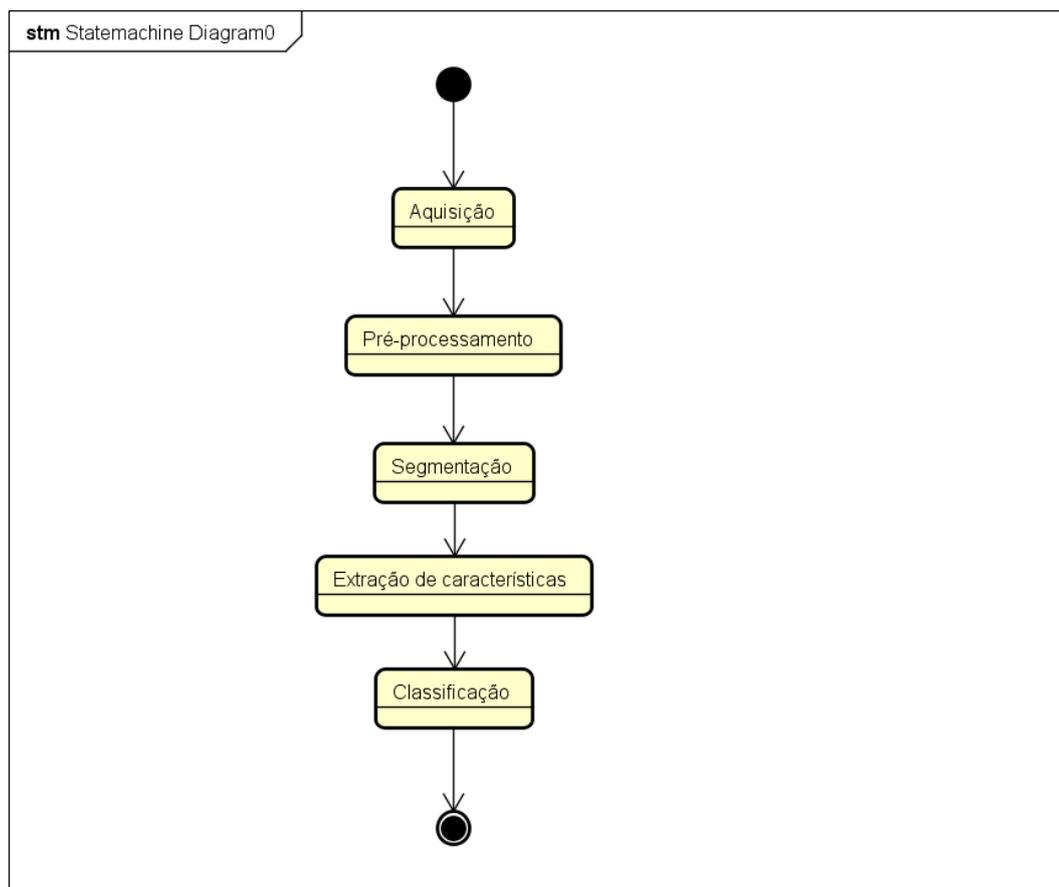
Meloni (2009)

Na Figura 16 é demonstrado o processo de validação cruzada, seguindo a lógica de divisão de subconjuntos e da utilização de partes em treinamento e teste (validação).

3 Metodologia

Este capítulo descreve a metodologia desenvolvida para a detecção de anemia em pequenos ruminantes. Em cada seção serão descritas as técnicas utilizadas e como foram empregadas no aplicativo experimental. A Figura 17 apresenta um esquema das etapas da metodologia desenvolvida. Sendo todas as etapas executadas pelo aplicativo.

Figura 17 – Etapas da metodologia

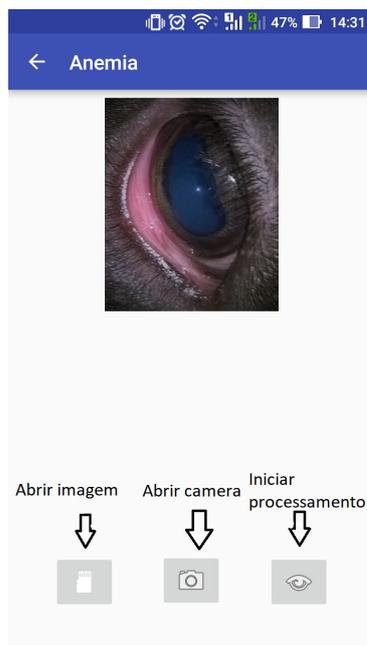


Acervo do autor

3.1 Aquisição

A sequência de métodos aplicados foi implementada em um aplicativo para dispositivos móveis, e para realizar os testes, cada imagem foi carregada previamente para a memória do dispositivo. Através da interface é selecionada a imagem a ser analisada e o resultado é apresentado ao usuário, como na Figura 18. Com o procedimento concluído a região segmentada da imagem era comparada com a imagem original para checar se houve perda de informação e identificar a presença de ruídos, Figura 19.

Figura 18 – Exemplo de segmentação



Fonte: Acervo do autor

Figura 19 – Resultado da segmentação



Fonte: Acervo do autor

3.2 Pré-processamento

Nesta etapa a imagem será preparada para a segmentação através de filtros de suavização de detalhes e com redimensionamento. Uma vez que as imagens são capturadas em BGR pela biblioteca de captura de imagens através da câmera do dispositivo móvel sendo necessário nessa

etapa a conversão da imagem do espaço BGR (*blue, green e red*) para o espaço de cor RGB logo em seguida é feita a conversão da imagem do espaço BGR (*blue, green e red*) para o espaço de cor RGB.

3.2.1 Filtros

O primeiro tratamento aplicado na imagem obtida pela câmera do aparelho é o filtro de suavização (filtro gaussiano). Essa prática auxilia nos processos de segmentação e consequentemente na classificação, visto que suaviza grande parte dos detalhes da imagem, tornando as mudanças de cores e texturas mais amenas.

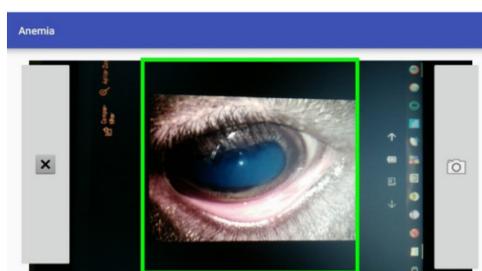
Uma vez que a imagem tem seus detalhes suavizados, ela parte para a fase de recorte e redimensionamento. Tal fase é necessária para reduzir o custo computacional dos algoritmos de extração de características.

3.2.2 Recorte e redimensionamento

Foi constatado que um redimensionamento prévio da imagem auxilia no tempo de segmentação e extração de características. A imagem não sofre qualquer tipo de distorção, uma vez que seu aspecto é mantido.

Outro ajuste realizado, foi quanto a região a ser utilizada de cada foto, como a câmera registra toda a cena em volta da cabeça do animal, foi necessário recortar apenas a parte referente ao olho analisado. Para sinalizar corretamente a área que deve ser fotografada, foi demarcado na visualização da câmera um polígono de restrição, como na Figura 20.

Figura 20 – Polígono de restrição



Acervo do autor

3.3 Segmentação

Nesta seção serão descritos os métodos utilizados na segmentação das imagens. Para a implementação dos algoritmos foi utilizada a biblioteca OpenCV (*Open Source Computer Vision Library*) com otimizações para dispositivos Android.

3.3.1 Base de exemplo

Foram selecionadas dez imagens com as seguintes características.

- animal com pelo claro (branco ou marrom);
- animal com pelo escuro;
- foto com desfoque;
- conjuntiva exposta de forma clara;
- conjuntiva com baixa exposição.

Cada imagem passou pela fase de pré-processamento e foi enviada para a etapa de segmentação. Na Figura 21 temos um exemplo de imagem utilizada.

Figura 21 – Exemplo de imagem da base de exemplo



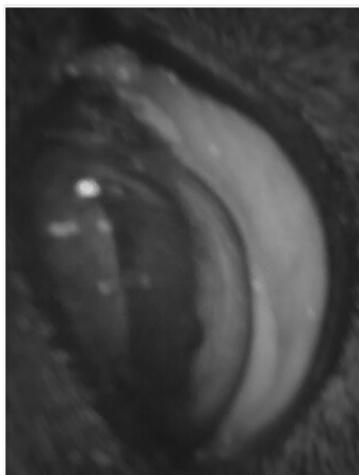
Acervo do autor

3.3.2 Etapas de segmentação

Após testes com a base de exemplo, a combinação de métodos de processamento com melhor resultado consiste em:

- conversão do espaço de cor da imagem de RGB para o espaço de cor HSV;
- separação dos canais da imagem e utilização do canal H (Hue), por este deixar em mais evidência a conjuntiva na maior parte dos casos, como pode ser observado na Figura 22;

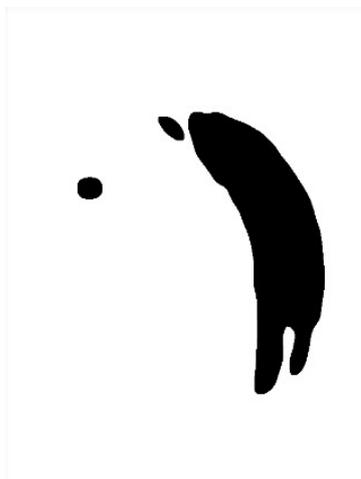
Figura 22 – Etapas da segmentação (Canal H)



Fonte: Acervo do autor

- aplicação da limiarização (thresholding) na imagem resultante do passo anterior;
- aplicar a erosão na imagem resultante da operação de limiarização para remover possíveis ruídos, como apresentado na Figura 23;

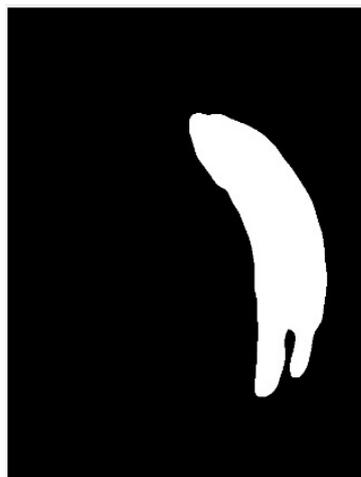
Figura 23 – Etapas da segmentação (Limiarização e erosão)



Fonte: Acervo do autor

- gerar máscara para recorte, com base na detecção de bordas da imagem anterior, como visto na Figura 24;

Figura 24 – Etapas da segmentação (Recorte)



Fonte: Acervo do autor

- aplicar a máscara para recortar a imagem original, a imagem resultante dessa operação será analisada para extração de características, como exemplificado na Figura 25;

Figura 25 – Região de interesse segmentada



Fonte: Acervo do autor

3.4 Extração de características

Para cada imagem são calculadas as características descritas na Seção 2.5, utilizando o espaço de cor LAB, eliminado a luminosidade e considerando apenas a cromaticidade de cada cor.

Cada vez que uma imagem é processada, gera-se uma entrada em um arquivo de características. Cada entrada possui uma linha para cada tipo de característica utilizado, Figura 26.

O parâmetro C , que será utilizado pelo *kernel*, define a quantidade de *outliers* (valores que não correspondem a realidade ou muito acima dos valores esperados em uma classe) que serão descartados, caso C seja zero ele define o problema como linearmente separável, ou seja, que não há curvas na faixa de seleção.

O *kernel* projeta os valores de um conjunto de entrada no espaço de características de um problema, para valores de C linearmente separáveis isso ocorre naturalmente. No entanto, para valores que não são linearmente separáveis é necessário a utilização de operadores lagrangianos, como explicados na Subseção 2.6.1 (SCHÖLKOPF; SMOLA, 2002).

Para o algoritmo KNN foram utilizados os parâmetros: distância euclidiana, número de vizinhos (K) como 1 e validação cruzada com 9 *folds* estimados através de testes.

Para a realização dos testes foram criados três grupos de imagens, sendo o primeiro para treino dos algoritmos de aprendizado de máquina, o segundo para teste destes algoritmos e o terceiro para validação do modelo gerado pelos algoritmos nas etapas de treino e teste.

Uma vez que o modelo gerado pela etapa de treino e teste for obtido, ele deverá ser validado. Para isso uma base de imagens do terceiro grupo, que não participaram do treino e teste, será utilizada. Com base nas classificações realizadas no terceiro grupo, serão retiradas as métricas para quantizar a precisão do processo de diagnóstico.

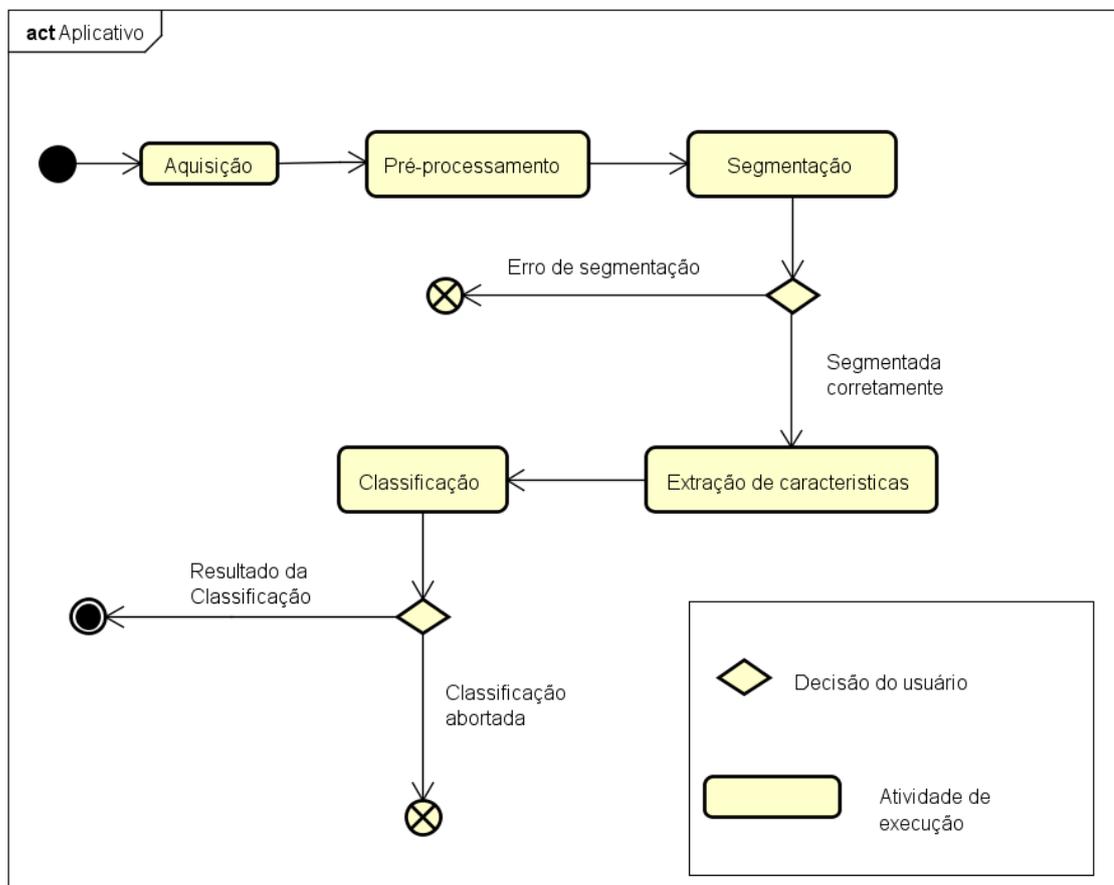
Para o teste dos classificadores foi utilizada a ferramenta Weka. Essa ferramenta possui implementações em Java de diversos classificadores, incluindo o SVM e o KNN. No mesmo pacote é fornecida uma API para implementação personalizada, que permitiu sua utilização em aplicativos Android (HALL et al., 2009).

Cada classificador recebeu uma base para cada espécie e para cada base foi feita a classificação, de acordo com cada característica e metodologia de extração (cor dominante e região completa). Os dados gerados pela classificação foram comparados com os exames de sangue (hematócrito) e com a classificação FAMACHA para validar a precisão do diagnóstico fornecido.

4 Experimentos

Neste capítulo são descritos os experimentos realizados para a metodologia proposta. A Seção 4.1 descreve o ambiente utilizado para testes. Na Seção 4.2 é descrita a base de dados utilizada para a realização dos testes. Na Seção 4.3 será mostrado o resultado do procedimento de segmentação. Na Seção 4.4 serão apresentados os resultados da classificação, métricas e uma análise comparativa. A Figura 27 demonstra esquematicamente o funcionamento do aplicativo, incluindo as decisões do usuário e as etapas de execução.

Figura 27 – Etapas do aplicativo



powered by Astah

Acervo do autor

4.1 Ambiente de teste

Para os testes, foram utilizados quatro celulares possuindo as seguintes características de hardware:

- Asus Zenfone GO zb500kg, com 2 GB de memória RAM, câmera de 8 megapixels e processador de 1.3 GHZ com 16GB de armazenamento;

- Samsung Galaxy J5 Metal, com 2 GB de memória RAM, câmera de 13 megapixels e processador 1.2 GHZ com 16GB de armazenamento;
- Motorola Moto G segunda geração, com 1 GB de memória RAM, câmera de 8 megapixels e processador de 1.3 GHZ com 8GB de armazenamento;
- Motorola Moto G primeira geração, com 1 GB de memória RAM, câmera de 5 megapixels e processador de 1.2 GHZ com 8GB de armazenamento.

Todos os aparelhos utilizam a plataforma *android* entre as versões 5.0 *lollipop* e a 6.0 *marshmallow*. Para testes de segmentação foram feitos *scripts* em *python*¹ e em java, além do uso da ferramenta de *Imagej*² para teste de parâmetros do algoritmo de segmentação. Para a aplicação da metodologia em campo foi desenvolvido um aplicativo para a plataforma Android, com o uso da biblioteca OpenCV³, seu objetivo é aplicar a metodologia proposta em uma situação real para que seja possível obter e avaliar os resultados.

4.2 Base de dados

A base de dados utilizada nesse trabalho foi obtida através de fotografias retiradas de animais reais, cada animal foi avaliado de acordo com a escala FAMACHA e teve amostras de sangue retiradas pra avaliação do nível do hematócrito. Essa base é constituída por animais de ambas as espécies (caprinos e ovinos) em diferentes estágios de infecção e com pelagem distintas. Ao todo foram analisadas 114 imagens divididas entre ambas as espécies, sendo 67 ovinos e 47 caprinos.

Tabela 1 – Distribuição da base de dados

	Saudável	Médio	Doente	Total
Caprinos	13	16	18	47
Ovinos	20	19	28	67

Como descrito na Seção 3.4, os níveis de infecção dos animais foram divididos em três classes (S, M e D) com cada classe correspondendo a um intervalo de níveis do FAMACHA. A classe saudável (S) corresponde aos níveis 1 e 2; a média (M) corresponde ao nível 3 e a Doente (D) corresponde aos níveis 4 e 5.

Os níveis de Hematócritos de cada classe foram definidos da seguinte forma: a classe D entre 13 (ou inferior) e 17%; a classe M entre 18 e 22% e a classe S fica entre 23 e 27% (ou superior). Como pode ser visto na Tabela 2.

¹ <<https://www.python.org/>>

² <<https://imagej.nih.gov/ij/>>

³ <<https://opencv.org/>>

Tabela 2 – Parâmetros de avaliação

Classes	Níveis FAMACHA	Hematócrito(%)
S	1 e 2	23 e 27 (+)
M	3	18 e 22
D	4 e 5	(-) 13 e 17

4.3 Resultados da segmentação

Na etapa de segmentação obteve-se 86% de acerto quanto a classificação correta da conjuntiva. Observou-se que a técnica de segmentação tem dificuldades em animais com a conjuntiva parcialmente exposta, gerando sensibilidade a ruídos e falha. Como pode ser visto na Figura 28.

Figura 28 – Imagem com conjuntiva parcialmente exposta



Fonte: Acervo do autor

Outra dificuldade encontrada pela técnica para o processo de segmentação, foi quanto a iluminação do pelo, sendo que em pelos com muito reflexo houve dificuldade em segmentar as imagens, devido a inclusão de ruídos em diversos casos. O que não resultou em falha do algoritmo em si, uma vez que os ruídos não representavam região contínua e nem uma grande porcentagem da imagem, sendo possível desprezá-los durante as operações de erosão e dilatação. Como apresentado na Figura 29.

Figura 29 – Imagem com ruído



Fonte: Acervo do autor

Uma limitação da aplicação do método é a dificuldade em manter o animal na mesma posição por um curto período de tempo. Diversas imagens da base sofreram com o movimento da câmera e conseqüentemente com desfoque, no entanto isso não foi observado como fator para falha do algoritmo, uma vez que a conjuntiva foi segmentada. Como exemplificado na Figura 30.

Figura 30 – Imagem com movimento



Fonte: Acervo do autor

4.4 Resultados da classificação

Nesta seção serão apresentados os testes dos classificadores utilizados comparando os resultados de cada grupo de características, utilizando métricas de avaliação e o consumo de recursos como parâmetros de qualidade.

Como métricas para o desempenho de cada classificador foram utilizadas a precisão, a revocação (*recall*) e a acurácia. Sendo a precisão responsável por medir os elementos que foram classificados como positivos (verdadeiros ou falsos), enquanto a revocação ou *recall* determina quais elementos são de fato positivos (verdadeiros) e por fim a acurácia que determina a taxa de classificação correta, ou seja, a proximidade entre o valor real da classificação e o obtido nos testes.

Para a etapa de classificação dos dados obtidos nas etapas anteriores foram consideradas apenas imagens que foram segmentadas de forma satisfatória. Os testes foram aplicados de acordo com o tipo de característica e espécie.

Foram utilizadas 17 amostras no grupo de validação para ovinos, enquanto que os caprinos tiveram 10 amostras. O restante (50 amostras de ovinos e 37 amostras de caprinos) foi utilizado para geração de instâncias artificiais através da aplicação da técnica SMOTE. Os conjuntos de cada espécie foram duplicados e, após a geração de instâncias sintéticas, foram utilizados na etapa de treino e teste para geração do modelo de classificação. Cada modelo foi gerado utilizando validação cruzada, ou seja, o conjunto de amostras para treino e teste foi dividido em 10 *folds*, atribuindo um para teste e os demais para treino.

4.4.1 SVM

Nesta seção serão descritos os resultados para o algoritmo SVM em ambas as espécies estudadas, para cada tipo de característica aplicada e nas diferentes etapas do processo de aprendizagem.

- caprinos para a etapa de validação;

Tabela 3 – Resultados para o algoritmo SVM em Caprinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,573	0,520	0,571
COR Dominante	0,714	0,714	0,714
COR Região	0,571	0,486	0,571

- caprinos para a etapa de treino e teste;

Tabela 4 – Resultados para o algoritmo SVM em Caprinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,779	0,779	0,801
COR Dominante	0,750	0,765	0,761
COR Região	0,787	0,750	0,760

- ovinos para a etapa de validação;

Tabela 5 – Resultados para o algoritmo SVM em Ovinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,733	0,750	0,733
COR Dominante	0,500	0,517	0,688
COR Região	0,733	0,744	0,733

- ovinos para a etapa de treino e teste;

Tabela 6 – Resultados para o algoritmo SVM em Ovinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,745	0,745	0,745
COR Dominante	0,600	0,610	0,640
COR Região	0,862	0,862	0,862

4.4.2 KNN

Nesta seção serão descritos os resultados para o algoritmo KNN em ambas as espécies estudadas, para cada tipo de característica aplicada e nas diferentes etapas do processo de aprendizagem.

- caprinos para a validação;

Tabela 7 – Resultados para o algoritmo KNN em Caprinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,571	0,524	0,571
COR Dominante	0,714	0,743	0,714
COR Região	0,571	0,571	0,571

- caprinos para a etapa de treino e testes;

Tabela 8 – Resultados para o algoritmo KNN em Caprinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,750	0,750	0,759
COR Dominante	0,783	0,727	0,763
COR Região	0,897	0,879	0,897

- ovinos para a validação;

Tabela 9 – Resultados para o algoritmo KNN em Ovinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,666	0,711	0,66
COR Dominante	0,750	0,775	0,75
COR Região	0,733	0,753	0,743

- ovinos para a etapa de treino e testes;

Tabela 10 – Resultados para o algoritmo KNN em Ovinos

Características	Acurácia	Recall(médio)	Precisão(média)
BIC	0,723	0,724	0,710
COR Dominante	0,767	0,768	0,768
COR Região	0,825	0,825	0,824

4.4.3 Análise dos resultados

Com base nas Tabelas 3 e 5, observa-se que para o classificador SVM as características com melhor resultado foram BIC, análise de cor dominante para caprinos e BIC, cor na região total para ovinos. Com valores de acurácia, respectivamente, 0,573 e 0,714 para a etapa de validação e 0,779 e 0,780 (Tabela 4), para a etapa de treino e teste para caprinos; 0,733 e 0,733 para a etapa de validação, 0,745 e 0,862 (Tabela 6), para a etapa de treino e teste para ovinos. Encontrando dificuldades para classificar exemplos para as características estatísticas extraídas da região segmentada por completo para caprinos e análise de cor dominante para ovinos.

O algoritmo SVM teve baixo desempenho inicialmente para classificar os exemplos do grupo de validação. No quadro geral seus resultados foram inferiores ao uso do algoritmo KNN,

e seu processamento precisou mais tempo de computação (entre 6 e 8 segundos contra 1.5 e 2 segundos) e portanto exigia demais dos dispositivos utilizados.

Nas Tabelas 7 e 9, são demonstrados os resultados do algoritmo KNN. As características estatísticas aplicadas a cor dominante e a cor pela região total obtiveram os melhores resultados para ambas as espécies com, respectivamente, 0,714 e 0,571 de acurácia na etapa de validação e 0,783 e 0,897 (Tabela 8), na etapa de treino e teste para caprinos; 0,750 e 0,733 de acurácia na etapa de validação e 0,767 e 0,825 (Tabela 10), para a etapa de treino e teste para ovinos. O algoritmo apresenta o menor tempo de classificação e baixo consumo de recursos computacionais com relação ao SVM. O algoritmo KNN teve problemas de classificação com características BIC, porém saiu-se melhor com características estatísticas.

A metodologia mais adequada para o uso no aplicativo de teste foi a extração de característica utilizando as características estatísticas aplicadas na cor mais predominante na região segmentada (conjuntiva), utilizando como classificador o KNN com distância euclidiana.

5 Conclusão

Este trabalho apresenta uma metodologia para detecção de anemia em ruminantes. O método proposto utiliza algoritmos de segmentação, extração de características e os procedimentos de classificação para determinar a partir da coloração da conjuntiva do animal seu grau de anemia, classificando-os de acordo com classes definidas tendo como base os níveis da escala do FAMACHA.

Para a segmentação, foi proposta uma sequência de filtros e operadores sobre as imagens extraídas de animais reais e em condições distintas, obtendo resultados satisfatórios, ou seja isolando a conjuntiva do restante da imagem e com níveis de ruídos baixo o suficiente para ser desconsiderados.

Para a extração de características foram considerados dois tipos: o BIC e as características estatísticas. Ambas as técnicas foram utilizadas na etapa de classificação, sendo que as características estatísticas aplicada à cor dominante obtiveram os melhores resultados em ambas as espécies com a utilização do classificador KNN, sendo esta combinação a mais aceita, pois, além de melhores resultados, também resultou em um custo computacional mais aceitável.

Como trabalhos futuros, sugere-se um estudo para a otimização da etapa de segmentação, pois esta consome muito processamento dos dispositivos. Recomenda-se explorar as características de cor como auto-correlograma de cores e histogramas. Para a etapa de classificação recomenda-se explorar variantes do algoritmo KNN.

Sugere-se também o uso de computação em nuvem para realizar a classificação das imagens com ambos os classificadores e um sistema de tomada de decisão para eleger a classificação mais precisa. Sugere-se, para pesquisas futuras, uma base em nuvem de imagens de conjuntivas para facilitar o acesso as informações.

REFERÊNCIAS

- ALENCAR, S. P.; MOTA, R. A.; COELHO, M. C. O. C.; NASCIMENTO, S. A.; ABREU, S. R. de O.; CASTRO, R. S. Perfil sanitário dos rebanhos caprinos e ovinos no sertão de pernambucano. **Ciência Animal Brasileira**, v. 11, n. 1, p. 131–140, 2010.
- ALVES, T. T. **Espaço de cor Lab**. 2011. <<http://corisectelmo.blogspot.com.br/2011/01/aula-21-espaco-de-cor-lab.html>>.
- AVILA, S. E. F. d. **Uma abordagem baseada em características de cor para a elaboração automática e avaliação subjetiva de resumos estáticos de vídeos**. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte, 2008.
- BELTRÃO, M. M.; TASCA, C.; GALLO, A.; FERREIRA, M.; BONONI, R.; STECCA, E. Método famacha como parâmetro clínico individual de infecção por *haemonchus contortus* em pequenos ruminantes. **Ciência Rural**, Universidade Federal de Santa Maria, v. 34, n. 4, 2004.
- CABRAL, E. L. L. **Visão Computacional - Espaços de cores**. 2008. Aula.
- CHAGAS, A. d. S.; CARVALHO, C. de; MOLENTO, M. Método famacha: um recurso para o controle da verminose em ovinos. **Embrapa Pecuária Sudeste-Circular Técnica (INFOTECA-E)**, São Carlos, SP: Embrapa Pecuária Sudeste, 2007., 2007.
- COSTA, V. M.; SIMÕES, S. V.; RIET-CORREA, F. Controle das parasitoses gastrintestinais em ovinos e caprinos na região semiárida do nordeste do brasil. **Pesq. Vet. Bras**, v. 31, n. 1, 2011.
- DARTORA, A. **Análise de Extratores de Características para a Classificação de Tecidos Pulmonares e Não-Pulmonares em Imagens de Tomografia Computadorizada de Alta Resolução**. 2015. Slides.
- DEPNER, R.; ROCHA, R.; CECIM, M.; GAVIÃO, A.; MOLENTO, M. Growth performance in naturally infected lambs with gastrointestinal nematodes under selective treatment with famacha method and preventive treatment. **Archives of Veterinary Science**, v. 12, n. 3, p. 32–37, 2007.
- FERNANDES, B. J. T. Segmentação e classificação de padrões visuais baseadas em campos receptivos e inibitórios. Universidade Federal de Pernambuco, 2009.
- FERNANDES, M. A. M.; GILAVERTTE, S.; BUZATTI, A.; SPRENGER, L. K.; SILVA, C. J.; PERES, M. T.; MOLENTO, M. B.; MONTEIRO, A. L. Método famacha para detectar anemia clínica causada por *haemonchus contortus* em cordeiros lactentes e ovelhas em lactação. **Pesq. Vet. Bras.**, v. 35, n. 6, 2015.
- FERRERO, C. A. **Algoritmo kNN para previsão de dados temporais: funções de previsão e critérios de seleção de vizinhos próximos aplicados a variáveis ambientais em limnologia**. Dissertação (Mestrado) — Instituto de Ciências Matemáticas e Computação, 1 2009.
- GAMA, A. P. **microhematócrito**. 2017. <http://adamogama.blogspot.com.br/2011/08/microhematocrito_12.html>. Acessado em : 29-06-2017.
- GOMES, K. R.; SANTOS, M. G. C.; FRANCO, D. F.; PIRES, R. B.; SILVA, M. G. d.; NEVES, M. F.; BASSANI-SILVA, S. Avaliação do hematócrito e da proteína plasmática em sangues hemodiluídos. **Revista científica eletrônica de medicina veterinária, Ano III**, n. 7, 2006.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, ACM, v. 11, n. 1, p. 10–18, 2009.

HUGHES, J. F.; FOLEY, J. D. **Computer graphics: principles and practice**. [S.l.]: Pearson Education, 2014.

JESUS, E. O.; JR, R. C. A utilização de filtros gaussianos na análise de imagens digitais. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 3, n. 1, 2015.

JÚNIOR, L. A. d. S. Interface para classificação de dados por máquinas de vetores de suporte. Universidade Estadual Paulista (UNESP), 2014.

KAPLAN, R.; BURKE, J.; TERRILL, T.; MILLER, J.; GETZ, W.; MOBINI, S.; VALENCIA, E.; WILLIAMS, M.; WILLIAMSON, L.; LARSEN, M. et al. Validation of the famacha© eye color chart for detecting clinical anemia in sheep and goats on farms in the southern united states. **Veterinary parasitology**, Elsevier, v. 123, n. 1-2, p. 105–120, 2004.

LABFISIO. **Estudio de las determinaciones hematológicas en sangre**. 2017. <http://www.ub.edu/LabFisio/index.php?option=com_content&view=article&id=119&Itemid=155>. Acessado em : 29-06-2017.

LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007.

LORIA, A. D.; VENEZIANO, V.; PIANTEDOSI, D.; RINALDI, L.; CORTESE, L.; MEZZINO, L.; CRINGOLI, G.; CIARAMELLA, P. Evaluation of the famacha system for detecting the severity of anaemia in sheep from southern italy. **Veterinary parasitology**, Elsevier, v. 161, n. 1-2, p. 53–59, 2009.

MACIEL, P. **Guia Definitivo sobre Luz Azul**. 2017. <<https://www.blogdopaulus.com/2017/03/guiabluelight.html>>. Acessado em : 19-05-2018.

MEDEIROS, R. S. Detecção de pele humana utilizando modelos estocásticos multi-escala de textura. 2013.

MELLO, C. **Morfologia Matemática, Notas de aula na Graduação em Engenharia da Computação**. 2008. Aula.

MELONI, R. B. d. S. **Classificação de Imagens de Sensoriamento Remoto usando SVM**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro, 3 2009.

MENDES, D. A. **Conceitos Básicos de Estatística**. 2011. Disponível em: <<http://cm.de.iscte.pt/Aula2Vi.pdf>>.

MENEZES, L. F. J. Processamento de imagens digitais para visão robótica. **Intellectus**, p. 39–40, 03 2010.

MINHO, A.; MOLENTO, M. Método famacha: uma técnica para prevenir o aparecimento da resistência parasitária. **Embrapa Pecuária Sul-Circular Técnica (INFOTECA-E)**, Bagé: Embrapa Pecuária Sul, 2014., 2014.

MINOLTA, k. 2013. Disponível em: <<http://sensing.konicaminolta.com.br/2013/11/entendendo-o-espaco-de-cor-lab/>>.

- MOLENTO, M. B.; TASCA, C.; GALLO, A.; FERREIRA, M.; BONONI, R.; STECCA, E. Método famacha como parâmetro clínico individual de infecção por *haemonchus contortus* em pequenos ruminantes. **Ciência Rural**, v. 34, n. 4, 2004.
- NEVES, S. C. M.; PELAES, E. G.; SINAIS, L. d. P. de. Estudo e implementação de técnicas de segmentação de imagens. **Revista Virtual de Iniciação Acadêmica da UFPA-Universidade Federal do Pará-Departamento de Engenharia Elétrica e de Computação**, v. 1, n. 2, 2008.
- NOBREGA, A. **Estudo aponta tendências para caprinocultura e ovinocultura nos cenários nacional e internacional**. 2016. <<https://www.embrapa.br/busca-de-noticias/-/noticia/8698648/estudo-aponta-tendencias-para-caprinocultura-e-ovinocultura-nos-cenarios-nacional-e-internacional>>.
- OLIVEIRA, D. F. d. **Confiabilidade Metrológica e Validação de Procedimentos Espectroradiométricos para Medição de Fontes Luminosas**. Tese (Doutorado) — PUC-Rio, 2006.
- OLIVEIRA, J. M. de L.; BAROLLI, E. Relatório final. Unicamp, 2009.
- PICON, C. T.; ROSSI, I.; JR, M. P. P. Análise da classificação de imagens por descritores de cor utilizando várias resoluções. **Icmc. Usp. Br, no. Icmc**, 2011.
- PORTALACTION. **PORTALACTION**. 2017. <<http://www.portalaction.com.br/estatistica-basica/26-curtose>>. Acessado em : 29-06-2017.
- PORTALEDUCACAO. **Hematócrito (Ht) ou Volume Globular (VG)**. 2017. <<https://www.portaleducacao.com.br/conteudo/artigos/educacao/hematocrito-ht-ou-volume-globular-vg/29426>>. Acessado em : 29-06-2017.
- PORTALEDUCACAO. **Hemoglobinemia (Hb)**. 2018. <<https://www.portaleducacao.com.br/conteudo/artigos/psicologia/hemoglobinemia-hb/29429>>. Acessado em : 31-01-2018.
- QUINTA, L. N. B.; PISTORI, H. Seleç ao de atributos para a segmentaç ao do couro bovino. 2008.
- RIBEIRO, H. L. **Reconhecimento de gestos usando segmentação de imagens dinâmicas de mãos baseada no modelo de mistura de gaussianas e cor de pele**. Tese (Doutorado) — Universidade de São Paulo, 2006.
- RIBEIRO, S. S. **Métodos computacionais aplicados à agricultura: Python & Weka**. [S.l.]: Novaterra Editora e Distribuidora LTDA, 2016.
- SANTOS, C. **Análise de Características para Detecção de Nudez em Imagens**. Dissertação (Mestrado) — Universidade Federal do Amazonas, 3 2012.
- SANTOS, J. A. dos; PENATTI, O. A. B.; TORRES, R. da S. Evaluating the potential of texture and color descriptors for remote sensing image retrieval and classification. In: **VISAPP (2)**. [S.l.: s.n.], 2010. p. 203–208.
- SAVANT, S. A review on edge detection techniques for image segmentation. **International Journal of Computer Science and Information Technologies**, v. 5, n. 4, p. 5898–5900, 2014.
- SCHÖLKOPF, B.; SMOLA, A. J. **Learning with kernels: support vector machines, regularization, optimization, and beyond**. [S.l.]: MIT press, 2002.

SILVA, A. T. d. **Descritores de Imagem**. 2014. Notas de aula.

SILVEIRA, M. T. Rgb to gray. 6 2008.

SIMÕES, A. d. S. **Segmentação de imagens por classificação de cores: uma abordagem neural**. Tese (Doutorado) — Universidade de São Paulo, 2000.

SOUTO, R. P. Segmentação de imagem multiespectral utilizando-se o atributo matiz. **São José dos Campos: INPE**, 2000.

TABASSUM, M. R.; GIAS, A. U.; KAMAL, M.; MUCTADIR, H. M.; IBRAHIM, M.; SHAKIR, A. K.; IMRAN, A.; ISLAMM, S.; RABBANI, M.; KHALED, S. M. et al. Comparative study of statistical skin detection algorithms for sub-continental human images. **arXiv preprint arXiv:1008.4206**, 2010.

VARASSIN, C. G.; PLASTINO, A.; ZADROZNY, B.; LEITÃO, H. G. Impacto de estratégias de balanceamento no problema de classificação de sítios de splice. 2012.

VIEIRA E.A.; MELO, R. **Granulometria: Uma Aplicação para Contagem e Medição de Grãos em Imagens Digitais**. 2004. Monografia apresentada ao Departamento de Ciência da Computação da Universidade Federal Fluminense.

VIEIRA, L. d. S. **Endoparasitoses Gastrintestinais de Caprinos e Ovinos:Aternativas de Controle**. 2008. Periodico.

WYK, J. A. V.; BATH, G. F. The famacha system for managing haemonchosis in sheep and goats by clinically identifying individual animals for treatment. **Veterinary research**, EDP Sciences, v. 33, n. 5, p. 509–529, 2002.