

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DAINF - DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
CURSO DE BACHARELADO EM SISTEMAS DE INFORMAÇÃO

GUILHERME ALVES ROSA

**IDENTIFICAÇÃO BIOMÉTRICA DE BOVINOS BASEADA
NO PADRÃO DO ESPELHO NASAL ATRAVÉS DE
APRENDIZADO DE MÁQUINA**

TRABALHO DE CONCLUSÃO DE CURSO

CURITIBA
2019

GUILHERME ALVES ROSA

**IDENTIFICAÇÃO BIOMÉTRICA DE BOVINOS BASEADA
NO PADRÃO DO ESPELHO NASAL ATRAVÉS DE
APRENDIZADO DE MÁQUINA**

Proposta de Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Sistemas de Informação da Universidade Tecnológica Federal do Paraná, como requisito parcial para a obtenção do título de Bacharel.

Orientadora: Prof.^a Dra. Leyza Baldo Dorini
DAINF - Departamento Acadêmico de Informática -UTFPR

Orientador: Prof. Dr. Ricardo Dutra da Silva
DAINF - Departamento Acadêmico de Informática -UTFPR

CURITIBA
2019



Ministério da Educação
UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
Câmpus Curitiba
Diretoria de Graduação e Educação Profissional
Departamento Acadêmico de Informática
Coordenação do Curso de Bacharelado em Sistemas de
Informação



TERMO DE APROVAÇÃO

IDENTIFICAÇÃO BIOMÉTRICA DE BOVINOS BASEADA NO PADRÃO DO ESPELHO NASAL ATRAVÉS DE APRENDIZADO DE MÁQUINA

por

GUILHERME ALVES ROSA

Este Trabalho de Conclusão de Curso foi apresentado às _____ **hs** do dia **10 de Julho de 2019** como requisito parcial à obtenção do grau de Bacharel em Sistemas de Informação na Universidade Tecnológica Federal do Paraná - UTFPR - Câmpus Curitiba. O(a)s aluno(a)s foi(ram) arguido(a)s pelos membros da Banca de Avaliação abaixo assinados. Após deliberação a Banca de Avaliação considerou o trabalho _____.

<p>_____ Leyza Baldo Dorini (Presidente - UTFPR/Curitiba)</p>	<p>_____ Bogdan Tomoyuki Nassu (Avaliador 1 - UTFPR/Curitiba)</p>
<p>_____ Wyverson Bonasoli de Oliveira (Avaliador 2 - UTFPR/Curitiba)</p>	<p>_____ Profa. Leyza Baldo Dorini (Professor Responsável pelo TCC - UTFPR/Curitiba)</p>
<p>_____ Prof. Marcelo Mikosz Goncalves (Coordenador(a) do curso de Bacharelado em Sistemas de Informação - UTFPR/Curitiba)</p>	

"A Folha de Aprovação assinada encontra-se na Coordenação do Curso."

AGRADECIMENTOS

Primeiramente a professora Leyza e ao professor Ricardo pela orientação.

Aos colegas que fizeram a pesquisa em conjunto.

Ao IAPAR por fornecer as bases.

RESUMO

Alves Rosa, Guilherme. Identificação biométrica de bovinos baseada no padrão do espelho nasal através de aprendizado de máquina. 2019. 40 f. Trabalho de Conclusão de Curso – Curso de Bacharelado em Sistemas de Informação, Universidade Tecnológica Federal do Paraná. Curitiba, 2019.

A identificação e rastreabilidade de bovinos é crucial para o controle de políticas de segurança no âmbito de produção de alimentos. Por utilizar uma característica física única, inviolável e insubstituível, além de acompanhar o animal durante toda a vida e ter sua eficácia solidamente comprovada, a identificação biométrica mostra-se a mais confiável. Este trabalho propõe uma abordagem baseada em técnicas de processamento de imagens e aprendizado de máquina para identificação biométrica de bovinos com base em fotos do espelho nasal. Mais especificamente foi utilizado um classificador em cascata para encontrar a região de interesse. Com o espelho nasal detectado duas abordagens para extração de característica foram testadas, *bag-of-words* e o descritor local de Weber, e ao fim o classificador k-NN foi utilizado para se fazer a identificação biométrica. O detector atingiu bons valores de acurácia mas falhou em caso específicos. Ambas as abordagens para classificação mostraram-se adequadas para a identificação biométrica, atingindo valores altos de acurácia, sensibilidade e especificidade.

Palavras-chave: Identificação de Bovinos. Aprendizado de Máquina. Processamento de Imagens.

ABSTRACT

Alves Rosa, Guilherme. Título em inglês. 2019. 40 f. Trabalho de Conclusão de Curso – Curso de Bacharelado em Sistemas de Informação, Universidade Tecnológica Federal do Paraná. Curitiba, 2019.

The identification and traceability of cattle are crucial for the control of safety policies within the context of food production. By using a unique, inviolable and irreplaceable physical feature, in addition to accompanying the animal throughout its life and having its effectiveness proven, biometric identification proves to be the most reliable. This study presents an approach based on techniques of image processing and machine learning for biometric cattle identification, using muzzle print images. More specifically, a cascade classifier was used to find the region of interest. After the muzzle detection, two approaches for feature extraction were tested, the bag-of-words model and Weber's local descriptor. Lastly, the k-NN classifier was used to classify the biometric features. The detector achieved good accuracy but failed in specific scenarios. Both approaches for classification were adequate for biometric identification, reaching high values of accuracy, sensitivity, and specificity.

Keywords: Cattle Identification. Machine Learning. Image Processing.

LISTA DE FIGURAS

Figura 1 – Exemplo dos padrões do espelho nasal.	15
Figura 2 – Características de Haar.	16
Figura 3 – Imagem com os pontos-chave detectados.	18
Figura 4 – Cálculo do histograma.	19
Figura 5 – <i>Pipeline</i> do processo.	23
Figura 6 – Exemplos de imagens das bases.	24
Figura 7 – Espelho nasal selecionado para recorte.	25
Figura 8 – Exemplo de imagens a serem utilizadas no treinamento.	26
Figura 9 – Exemplo de imagens artificiais.	26
Figura 10 – Exemplo de região de interesse identificada.	27
Figura 11 – Exemplo do pré-processamento realizado: (a) negativo e (b) filtro Gaussiano.	28
Figura 12 – Cálculo do índice de Jaccard.	29
Figura 13 – Exemplo de imagem que o algoritmo teve dificuldade.	31
Figura 14 – Erros ocorridos na etapa de detecção: (a) Focinho identificado com as narinas cortadas e (b) Queixo do animal identificado no lugar do focinho.	32
Figura 15 – Exemplo de imagem com baixo índice de Jaccard.	32
Figura 16 – Exemplo de erro devido ao corte do focinho.	33
Figura 17 – Exemplo de erro devido ao ângulo/inclinação da imagem.	34
Figura 18 – Exemplo de imagens com baixa qualidade da base IAPAR 2.	34
Figura 19 – Exemplo de imagens desfocadas na base USP.	35
Figura 20 – Exemplo do pré-processamento utilizado.	36

LISTA DE TABELAS

Tabela 1 – Resultados da análise quantitativa da detecção da região de interesse. . .	31
Tabela 2 – Cenário 1: Resultados do k-NN, com $k = 1$	33
Tabela 3 – Cenário 2: Resultados do k-NN, com $k = 1$	35
Tabela 4 – Cenário 2: Resultados do k-NN utilizando imagem negativa, com $k = 1$.	36
Tabela 5 – Resultados do k-NN para ambos os cenários, com $k = 1$	36

LISTA DE ABREVIATURAS E SIGLAS

BOW	<i>Bag-of-Words</i>
IAPAR	Instituto Agronômico do Paraná
k-NN	<i>k-Nearest Neighbors</i>
SIFT	<i>Scale-Invariant Feature Transform</i>
SVM	<i>Support Vector Machine</i>
USP	Universidade de São Paulo
WLD	<i>Weber's Local Descriptor</i>

SUMÁRIO

1 – INTRODUÇÃO	12
2 – REVISÃO DE LITERATURA	14
2.1 Identificação Biométrica	14
2.1.1 Identificação Biométrica de Bovinos	14
2.2 Reconhecimento de Padrões	15
2.2.1 Classificação em Cascata utilizando Características de Haar	16
2.2.2 <i>Bag-of-words</i>	17
2.2.2.1 Extração de características	17
2.2.2.2 Construção do vocabulário e do histograma	17
2.2.3 Descritor Local de Weber	18
2.2.3.1 Excitação	19
2.2.3.2 Orientação	20
2.2.3.3 Histograma	20
2.3 Trabalhos Relacionados	21
3 – METODOLOGIA	23
3.1 Bases de Dados	23
3.2 Detecção da Região de Interesse	24
3.2.1 Treinamento classificador 01: focinho	25
3.2.2 Treinamento classificadores 02 e 03: narinas esquerda e direita	26
3.2.3 Detecção do espelho nasal	26
3.3 Classificação dos bovinos	27
3.4 Avaliação	28
3.4.1 Avaliação da detecção do espelho nasal	28
3.4.2 Avaliação da classificação	29
4 – RESULTADOS	30
4.1 Detecção da região de interesse	30
4.1.1 Avaliação quantitativa	30
4.1.2 Avaliação qualitativa	31
4.2 Classificação	32
4.2.1 Cenário 1: WLD	33
4.2.2 Cenário 2: Bag-of-Words com características SIFT	35
4.2.3 Discussão dos resultados	36
5 – CONSIDERAÇÕES FINAIS	37

Referências 38

1 INTRODUÇÃO

A identificação e rastreabilidade de bovinos é crucial para o controle de políticas de segurança no âmbito de produção de alimentos, dado que a atividade pecuária acontece em diversas regiões. Além disso, como normalmente os bovinos são vendidos antes do abate, pode haver uma falta de informação sobre a origem e a saúde do gado abatido, gerando um grande risco para a saúde dos consumidores de carne. A habilidade de identificar o gado viabiliza a coleta de dados sobre sua origem e saúde, facilitando o controle de vacinação, o conhecimento sobre a trajetória de doenças e limitando as perdas dos produtores (AWAD, 2016; GIMENEZ, 2015). Nesse contexto, muitas organizações reconhecem a importância do desenvolvimento de sistemas com esse propósito (GABER et al., 2016). Após a descoberta da Encefalopatia Espongiforme Bovina, ou doença da vaca louca, sistemas de identificação e rastreabilidade foram melhorados por grandes exportadoras de carne (SOFOS, 2008).

No Brasil, em 2017, foram abatidas 30,83 milhões de cabeças de bovinos sob algum tipo de serviço de inspeção sanitária (IBGE, 2018). As exportações de carne bovina *in natura* chegaram a 1,53 milhões de toneladas (ABIEC, 2018), colocando o Brasil como o maior exportador de carne bovina no mundo (REUTERS, 2018). O Brasil ainda é suscetível a embargos de exportações, pois países concorrentes no mercado recorrem a barreiras não-tarifárias, como “ambientais”, “sociais” e “sanitárias” (GIMENEZ, 2015). Geralmente tais embargos surgem com a falha do gerenciamento de informações sobre o produto, causando falhas nas tomadas de decisões dos gestores e reduzindo a força do produto brasileiro. Para se garantir um mínimo de gerência, é necessário fazer o acompanhamento do animal desde o seu nascimento até o abate (LEICK, 2016), tornando necessário um sistema que identifique o animal de maneira robusta.

A identificação de animais pode ser realizada de diversas maneiras, que podem ser classificadas como mecânicas, eletrônicas e biométricas (GABER et al., 2016). Métodos como brincos, colares, tatuagens e marcações a ferro quente são classificados como mecânicos. Tais métodos comumente apresentam algumas problemáticas, como a necessidade de contenção do animal, problemas na leitura, erros de transcrição, possibilidade de duplicação, perdas de brincos e perda da identificação no abate ao ter chifre e peles removidos (GIMENEZ, 2011).

A identificação por rádio frequência, ou *Radio Frequency Identification* (RFID), é um método eletrônico que utiliza sinais de rádio para fazer uma identificação automática, utilizando etiquetas RFID colocadas no animal (WANT, 2006). A maior limitação do método eletrônico é a de que as etiquetas podem ser perdidas dentro do animal, removidas ou danificadas (GABER et al., 2016).

Com os problemas apresentados pelas identificações mecânicas e eletrônicas, a identificação biométrica surge como um modo de minimizar os mesmos. Por utilizar uma

característica física única, inviolável e insubstituível, a identificação biométrica se mostra mais confiável (GIMENEZ, 2015). Além disso, são características que acompanham o animal durante toda a vida e têm sua eficácia solidamente comprovada, conforme estudos sendo realizados desde 1921 (NOVIYANTO; ARYMURTHY, 2013). Diversos trabalhos mostram que os padrões formados pela distribuição de cumes e vales sobre a superfície do espelho nasal são capazes de identificar os bovinos unicamente, assim como a digital humana (BARANOV et al., 1993; NOVIYANTO; ARYMURTHY, 2013; GIMENEZ, 2015).

Este trabalho tem como objetivo desenvolver uma abordagem baseada em técnicas de processamento de imagens e aprendizado de máquina para identificação biométrica de bovinos com base em fotos do espelho nasal. Mais especificamente será utilizado um classificador em cascata para encontrar a região de interesse. Com o espelho nasal detectado duas abordagens para extração de característica serão testadas, *bag-of-words* e o descritor local de Weber, e ao fim o classificador k-NN será utilizado para se fazer a identificação biométrica.

Este trabalho está organizado como segue. O Capítulo 2 descreve brevemente os conceitos necessários ao entendimento do texto, bem como os trabalhos relacionados. No Capítulo 3 são descritas as bases de imagens utilizadas, detalhes sobre a implementação dos algoritmos e a realização dos experimentos. No Capítulo 4 são discutidos os resultados experimentais e no Capítulo 5 são apresentadas as conclusões do estudo e sugestões para trabalhos futuros.

2 REVISÃO DE LITERATURA

2.1 Identificação Biométrica

A biometria é a ciência que estuda a identificação de um indivíduo através de seus atributos físicos, químicos ou comportamentais (JAIN; FLYNN; ROSS, 2007). Os seres humanos identificam outros utilizando intuitivamente alguns mecanismos biométricos, como a voz, a face e características comportamentais (AWAD, 2016). A tecnologia biométrica é considerada o meio mais seguro de identificação e autenticação de pessoas (GIMENEZ, 2011), pois ela evita algumas fraquezas dos meios tradicionais ao substituir “algo que você possui” ou “algo que você sabe”, por “algo que você é” (AWAD, 2016).

Sistemas biométricos possuem duas modalidades, verificação e identificação. Na verificação, o sistema valida a identidade de um indivíduo ao comparar as características biométricas extraídas no momento, com suas próprias características salvas no banco de dados do sistema, ou seja, é uma comparação um para um. Já a identificação valida a identidade de um indivíduo ao comparar as características extraídas no momento com todas aquelas no banco de dados, com o intuito de encontrar os dados do indivíduo, sendo assim uma comparação um para muitos (JAIN; FLYNN; ROSS, 2007).

2.1.1 Identificação Biométrica de Bovinos

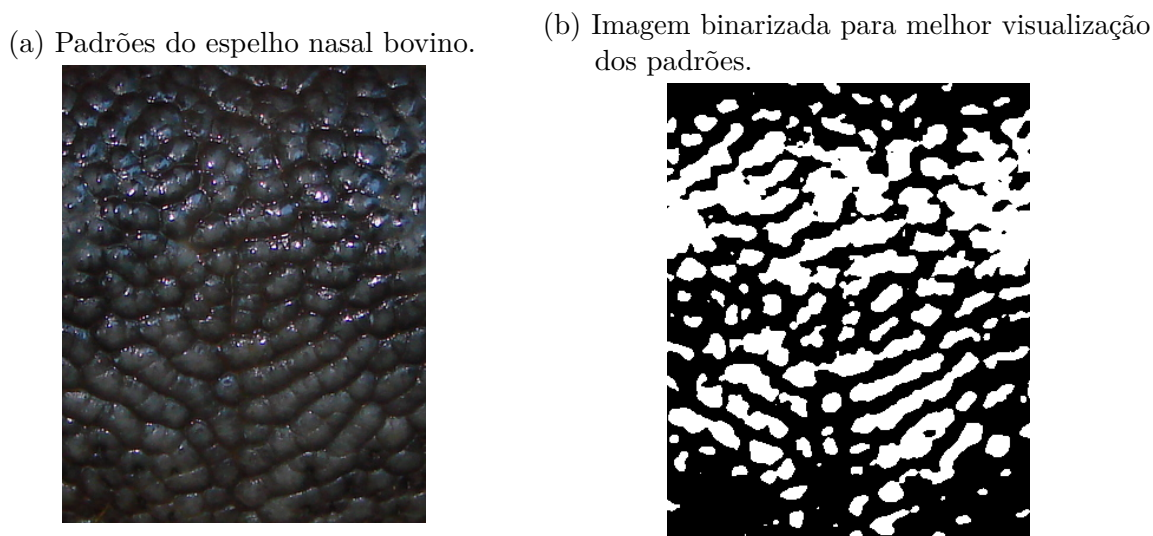
Em seu estudo sobre a face como identificador biométrico de ovelhas, Corkery et al. (2007) levantou alguns critérios que deveriam ser alcançados por um identificador animal: ser à prova de falhas, ser baseado em uma medida biométrica, ter aquisição rápida, barata e precisa, e o método de aquisição deve ser humano e não invasivo.

Com os problemas apresentados pelas identificações mecânicas e eletrônicas de bovinos, foram propostos identificadores biométricos para os mesmos, tais como a utilização da íris (MUSGRAVE; CAMBIER, 2002), do espelho nasal (BARRY et al., 2007) e da retina (AWAD, 2016). Dentre as abordagens propostas, este trabalho foca no espelho nasal dos bovinos, que vem sendo estudado desde 1921 (NOVIYANTO; ARYMURTHY, 2013). A identificação do animal pelo espelho nasal possui a vantagem de não ser invasiva, prevenindo o estresse sofrido pelo animal durante e após o processo e garantindo o seu bem-estar (BARRY et al., 2007).

O espelho nasal dos bovinos possui padrões como a distribuição de cumes e vales sobre sua superfície (GIMENEZ, 2015), conforme ilustrado na Figura 1. Foi mostrado que esses padrões são capazes de identificar os bovinos unicamente, tendo as mesmas propriedades da digital humana (BARANOV et al., 1993; NOVIYANTO; ARYMURTHY, 2013).

A aquisição dos padrões do espelho nasal pode ser realizada de duas maneiras,

Figura 1 – Exemplo dos padrões do espelho nasal.



Fonte: Autoria própria.

utilizando-se tinta para carimbar o padrão em papel e então digitalizá-lo, ou através de fotografias (AWAD, 2016). O primeiro possui algumas dificuldades como, por exemplo, ter que preparar o focinho do animal para receber a tinta e ter que segurá-lo para que o carimbo não saia manchado. Devido a tais fatores, conseguir imagens legíveis pode demorar (AWAD, 2016). O segundo, caso da aquisição da base de imagens utilizada neste trabalho, tem a vantagem de poder explorar a grande quantidade de dispositivos de aquisição (como câmeras de celulares, por exemplo) e a facilidade de armazenamento (viabilizando a aquisição de mais imagens) (GIMENEZ, 2015).

2.2 Reconhecimento de Padrões

O problema de procurar padrões em dados é fundamental e tem um longo histórico (CHRISTOPHER, 2016). Um padrão pode ser, por exemplo, uma imagem de uma digital, uma palavra escrita à mão, uma face humana, ou um sinal de fala (JAIN; DUIN; MAO, 2000). Dado um padrão, seu reconhecimento/classificação pode consistir em uma das seguintes tarefas: classificação supervisionada ou não-supervisionada. Na classificação supervisionada o padrão é identificado como parte de uma classe pré-definida, enquanto na não-supervisionada ele é identificado como uma classe desconhecida até o momento (JAIN; DUIN; MAO, 2000; CHRISTOPHER, 2016). O aprendizado a partir de um conjunto de exemplos (conjunto de treinamento) é um atributo importante para a maioria dos sistemas de reconhecimento de padrões (JAIN; DUIN; MAO, 2000).

O projeto de um sistema de reconhecimento de padrões essencialmente envolve os seguintes aspectos: aquisição dos dados, pré-processamento, extração de características e reconhecimento. O domínio do problema dita as escolhas das técnicas utilizadas durante


o processo - por exemplo, o pré-processamento em um sistema de análise de imagens pode incluir a redução de ruídos nas imagens (JAIN; DUIN; MAO, 2000; GONZALEZ; WOODS, 2012). A extração de características trata da tarefa de extração e caracterização de componentes dos dados pré-processados como, por exemplo, a extração de regiões de uma imagem (GONZALEZ; WOODS, 2012). A partir do conjunto de características o processo de reconhecimento tem como objetivo classificar corretamente um dado objeto.

2.2.1 Classificação em Cascata utilizando Características de Haar

Proposto por Viola e Jones (2001) para detecção de objetos em uma imagem, a abordagem tem como objetivo utilizar uma cascata de classificadores com N estágios para otimizar o reconhecimento de objetos. Cada estágio de uma cascata é criado através da combinação de funções de classificação (no caso do algoritmo proposto por Viola e Jones (2001) é utilizado o AdaBoost (FREUND; SCHAPIRE, 1997)).

Dado que os estágios tem como objetivo diminuir o número de regiões sendo analisadas na imagem, os iniciais descartam regiões que não possuem o objeto e, caso uma região passe pelo último estágio da cascata, é porque ela contém o objeto. Esse algoritmo treina os classificadores de cada estágio utilizando as características de Haar (VIOLA; JONES, 2001; LIENHART; MAYDT, 2002), as quais podem ser vistas na Figura 2.

Figura 2 – Características de Haar.



Fonte: Adaptado de (LIENHART; MAYDT, 2002).

Essas características são utilizadas como um *kernel*, normalmente criado com uma janela de tamanho 24×24 , que é utilizado para se fazer uma convolução. Cada uma dessas características é o valor obtido após a convolução com a imagem, onde é feita a soma dos *pixels* da região em branco e a soma dos *pixels* da região em preto, a soma da região em preto é então subtraída pela soma da região em branco.

Cada estágio é treinado com uma parcela das características, para não ser necessário fazer a convolução de todos os *kernels* com a imagem inteira. Ou seja, no primeiro estágio é feita a convolução de alguns *kernels*, as regiões que forem classificadas como positivas (talvez possuam o objeto) são então passadas para o próximo estágio, onde são utilizados outros *kernels*. As regiões que passarem pelo último estágio são retornadas como regiões que possuem o objeto sendo detectado.

2.2.2 *Bag-of-words*

O modelo de *bag-of-words* surgiu na área de recuperação de informação para representar documentos. Um documento pode ser representado como uma coleção de palavras (*words*), não importando sua ordem, com isso é fácil comparar documentos através da frequência de suas palavras.

Esse modelo foi adaptado para área de visão computacional por Fei-Fei e Perona (2005). Uma imagem pode ser tratada como um documento enquanto características extraídas de pequenas janelas da imagem podem ser tratadas como “palavras”. Um vocabulário, contendo as “palavras”, deve ser montado para descrever as imagens como uma frequência de suas “palavras”. A construção do modelo de *bag-of-words* para imagens consiste em três passos: extração de características, construção do vocabulário e construção do histograma.


2.2.2.1 Extração de características

As características da imagem são extraídas de pequenas janelas. O modo como as janelas são escolhidas pode variar, sendo comum usar pontos-chave. O *Scale-Invariant Feature Transform* (SIFT) (LOWE, 2004) é um descritor de imagens invariante à translações, rotações e transformações de escala, e é normalmente utilizado nesta etapa do processo tanto para encontrar os pontos-chave quanto para descrevê-los. A Figura 3 ilustra os pontos-chave encontrados em uma imagem.

2.2.2.2 Construção do vocabulário e do histograma

A construção do vocabulário é realizada utilizando-se um algoritmo de clusterização, por exemplo o K-Means (LLOYD, 1982). As características são extraídas de imagens que compõem uma base de treinamento, cada imagem da base tem suas características extraídas utilizando o processo descrito anteriormente. A clusterização é feita utilizando

Figura 3 – Imagem com os pontos-chave detectados.



Fonte: Autoria própria.

as características extraídas, essa clusterização visa representar todas as características encontradas nas imagens de treino. Os K centroides são tratados como as “palavras” do vocabulário e após o treinamento não são alterados, sendo K escolhido empiricamente ou com a assistência de técnicas como o Método Cotovelo.

O histograma (descriptor) de uma imagem é construído seguindo os seguintes passos:

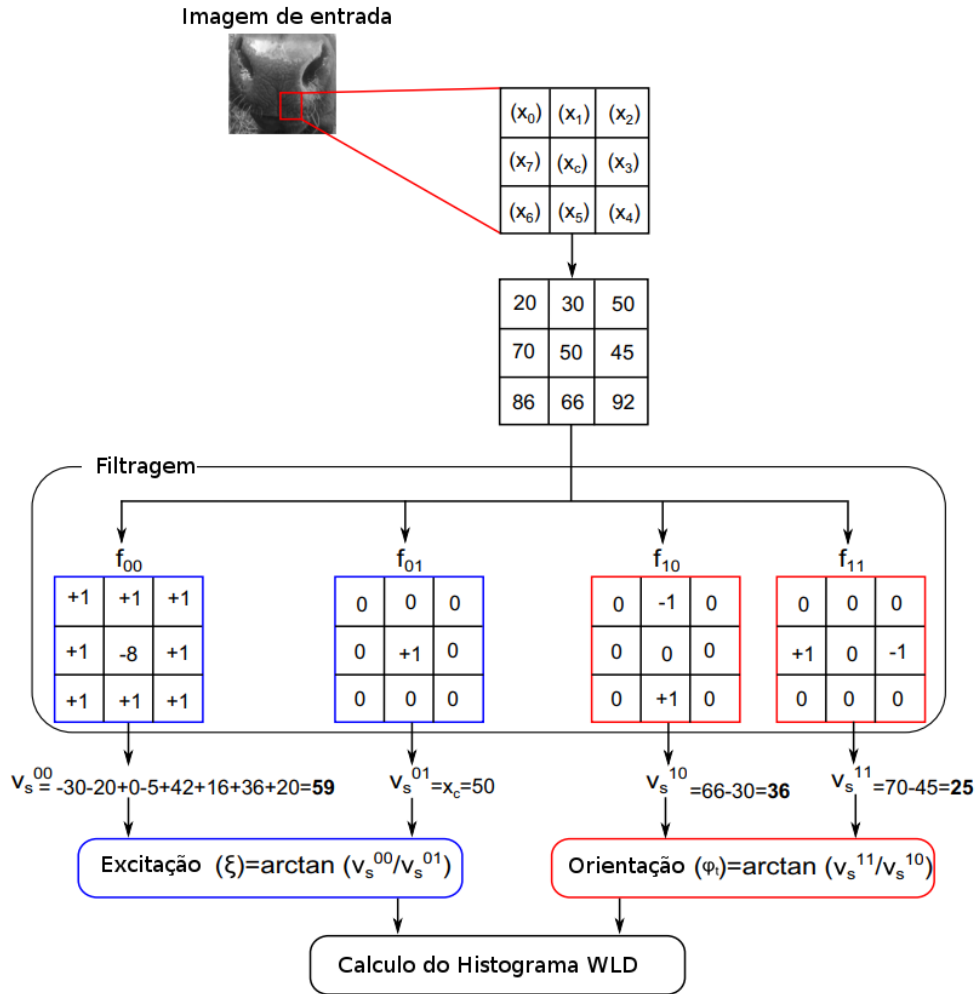
1. São extraídas as características da imagem, como descrito anteriormente.
2. Um histograma de zeros de tamanho K é criado.
3. Para cada ponto-chave é encontrado o centroide mais próximo no K -means.
4. A posição relativa ao vizinho mais próximo no histograma é acrescida de um.

2.2.3 Descritor Local de Weber

Baseando-se na lei de Weber (de que dado um estímulo inicial I e um estímulo final ΔI , o acréscimo necessário para que seja percebida a diferença entre eles é uma proporção constante do estímulo inicial), Chen et al. (2010) desenvolveram um descritor para representação de textura.

O cálculo do descritor local de Weber (*Weber's Local Descriptor* - WLD) envolve os seguintes passos: primeiro é calculada a excitação e a orientação dos pixels, depois é criado um histograma baseado nessas informações. A Figura 4 ilustra esse processo e apresenta os *kernels* utilizados no processo.

Figura 4 – Cálculo do histograma.



Fonte: Adaptado de (GABER et al., 2016).

2.2.3.1 Excitação

O primeiro passo para o cálculo da excitação dos pixels de uma imagem é realizado ao se pegar cada pixel x_c da imagem e se fazer a soma das diferenças entre ele e seus p vizinhos. Após cada pixel ter sua soma das diferenças calculada é feita a razão dessa soma pelos respectivos pixels x_c . Utilizando a lei de Weber como inspiração, ao se pegar essa soma de diferenças, que é o estímulo inicial menos o acréscimo, e fazer a divisão por x_c , que é o estímulo inicial, estaria sendo feita uma simulação de como a diferença entre dois estímulos é percebida pelos humanos. Com essa razão calculada então é aplicada a função arco tangente sobre os resultados, como mostra a Equação 1.

$$\xi(x_c) = \arctan \left(\sum_{i=0}^{p-1} \left[\frac{x_i - x_c}{x_c} \right] \right). \quad (1)$$

Intuitivamente, se $\xi(x_c)$ é positivo os arredores de x_c possuem pixels com uma intensidade maior que x_c , se $\xi(x_c)$ é negativo os arredores de x_c possuem pixels de menor

intensidade. Um exemplo do processo de cálculo da excitação em um pixel pode ser visto a esquerda da Figura 4.

2.2.3.2 Orientação

Para se realizar o cálculo das orientações dos pixels é inicialmente calculado o gradiente da imagem. Aplicando-se os kernels f^{10} e f^{11} , descritos na Figura 4, sobre a imagem são gerados os resultados v_s^{10} e v_s^{11} , que são utilizados para o cálculo da orientação, como mostra a Equação 2.

$$\theta(x_c) = \left(\frac{v_s^{11}}{v_s^{10}} \right). \quad (2)$$

Após obter as orientações da imagem é então feita a sua quantização, iniciando pelo mapeamento de θ para θ' como descrito na Equação 3

$$\theta'(x_c) = \arctan 2 \left(v_s^{11}, v_s^{10} \right) + \pi, \quad (3)$$

em que

$$\arctan 2(v_s^{11}, v_s^{10}) = \begin{cases} \theta, & \text{se } v_s^{11} > 0 \text{ e } v_s^{10} > 0 \\ \pi - \theta, & \text{se } v_s^{11} > 0 \text{ e } v_s^{10} < 0 \\ \theta - \pi, & \text{se } v_s^{11} < 0 \text{ e } v_s^{10} < 0 \\ -\theta, & \text{se } v_s^{11} < 0 \text{ e } v_s^{10} > 0 \end{cases}$$

Após este mapeamento, aplica-se a função de quantização descrita na Equação 4.

$$\psi(x_c) = \frac{2t}{T}\pi, \quad (4)$$

em que T é o número de orientações desejadas e t é dado pela Equação 5.

$$t = \left\lfloor \frac{\theta'}{2\pi/T} + \frac{1}{2} \right\rfloor. \quad (5)$$

2.2.3.3 Histograma

Para se construir o histograma é necessário primeiro definir alguns valores, como o número de orientações (T), em quantos segmentos cada orientação será dividida (M) e quantos elementos teremos por segmento (S). Com esses valores definidos é construída uma matriz H de duas dimensões, preenchida com zeros, com T colunas e C linhas, onde C é dado pela Equação 6.

$$C = M * S. \quad (6)$$

Os valores da matriz de excitação são normalizados para o intervalo de 0 a $C - 1$. Para cada pixel (i, j) da matriz original é verificada a sua excitação y e sua orientação x e então na matriz H a posição (y, x) é acrescentada no valor de 1.

Por último, o histograma WLD é montado ao se concatenar os segmentos da seguinte maneira: inicia-se com o segmento 0 da orientação 0, depois é então concatenado o segmento 0 da orientação 1, o processo é repetido T vezes até termos todos os segmentos 0. Com todos os segmentos 0 concatenados é feito o mesmo processo com os outros $M - 1$ segmentos, nos dando no fim um vetor de tamanhos $C * T$.

2.3 Trabalhos Relacionados

Existem vários métodos para a identificação de bovinos utilizando o espelho nasal (MINAGAWA et al., 2002; BARRY et al., 2007; NOVIYANTO; ARYMURTHY, 2013; THARWAT; GABER; HASSANIEN, 2014; GABER et al., 2016). Tais métodos utilizam diferentes técnicas para a extração das características biométricas do espelho nasal. O método proposto por Minagawa et al. (2002) utiliza imagens do espelho nasal carimbadas em um papel A-5. Um conjunto de pixels da superfície do focinho foi extraído da imagem utilizando esqueletonização, para ser utilizado como características. Cada bovino tem seu conjunto de pixels comparado com os conjuntos extraídos de todos os bovinos, com o intuito de fazer a identificação. Os experimentos foram conduzidos em um banco de dados com 170 imagens de focinho, de 43 animais. Devido a falha na extração de características, 13 animais não foram considerados. A acurácia na identificação ficou perto dos 30%.

Diferente de Minagawa et al. (2002), Barry et al. (2007) utilizou os cumes do focinho como características. Primeiramente é feita uma normalização da orientação da imagem, seguida por sua segmentação. Os dados são guardados em uma matriz com tamanho $ns \times ds$, onde ns é o número de cumes e ds são as propriedades desses cumes, como área, posição, orientação, etc. A comparação é feita em três passos, sendo o primeiro uma comparação pixel a pixel da imagem binarizada. O segundo passo utiliza uma árvore de decisão para comparar os 6 primeiros cumes através de suas propriedades. Por último, 3 cumes são aleatoriamente escolhidos, então é utilizado o centroide de cada cume para formar um triângulo, se o perímetro do triângulo for menor que um certo limiar, a imagem pertence ao mesmo animal.

Utilizando 160 imagens do espelho nasal de 20 bovinos, Noviyanto e Arymurthy (2013) aplicaram o *Scale Invariant Feature Transform* (SIFT) para detectar pontos de interesse na imagem. Foi proposta uma técnica para refinar os pontos baseada na informação de sua orientação. Ao ser testado na base de dados, a utilização do SIFT com a técnica de refinamento alcançou uma Taxa de Erros Iguais (*Equal Error Rate - EER*) de 0.0028.

Tharwat, Gaber e Hassanien (2014) testou dois métodos, um utilizando fusão de características e outro utilizando fusão de classificadores. No primeiro método foi aplicado

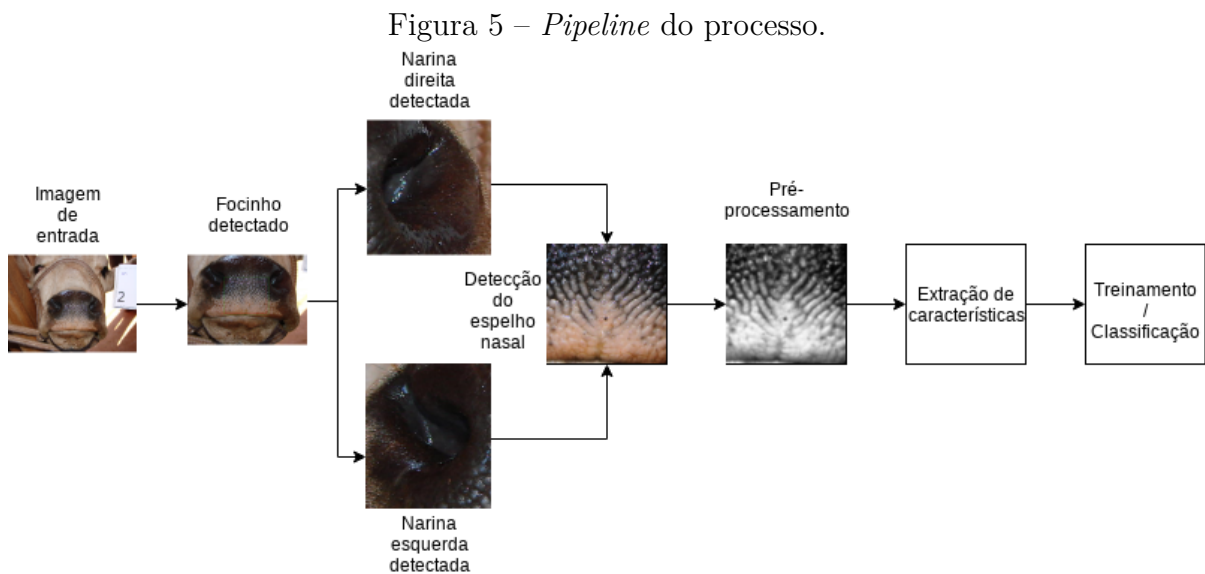
o filtro de Gabor em três escalas diferentes da mesma imagem, logo após foi feita a fusão das características extraídas de cada escala. Com o vetor de características gerado pela fusão, foi usada a análise de discriminantes lineares (*Linear Discriminant Analysis* - LDA) para diminuir a dimensão do mesmo. Uma máquina de vetores de suporte (*Support Vector Machine* - SVM) foi utilizada para fazer a classificação das características, foram testados vários kernels (Gaussiano, Polinomial, Linear e Sigmoide). O segundo método consistiu em pegar as características extraídas de cada escala e então classificar cada uma delas com o SVM. Tendo os três classificadores gerados pela etapa anterior foi feita a fusão dos mesmos, obtendo o resultado é através do voto dos classificadores. Ao se testar em uma base com 217 imagens de 31 bovinos diferentes, o primeiro método foi melhor que o segundo, alcançando uma acurácia de 99.5%.

Com a mesma base de dados utilizada por Tharwat, Gaber e Hassanien (2014), Gaber et al. (2016) utilizou o descritor local de Weber (*Weber's Local Descriptor* - WLD) (CHEN et al., 2010) para extrair as características do espelho nasal, seguido pela LDA para diminuir a dimensão do vetor de características. Três classificadores foram utilizados para identificação, AdaBoost, k -NN e Fk-NN, sendo que o AdaBoost se saiu melhor, com uma acurácia de 99.5%. Esses resultados foram alcançados com 200 iterações no AdaBoost e taxa de aprendizado igual a 0.1, os melhores resultados dos classificadores k -NN e Fk-NN foram alcançados com $k = 5$ para ambos.

3 METODOLOGIA

Este trabalho tem como objetivo utilizar técnicas de processamento de imagens e aprendizado de máquina para a identificação biométrica de bovinos utilizando imagens do espelho nasal. Para alcançar tal objetivo, a metodologia empregada neste trabalho consistiu na execução dos seguintes passos: aquisição da base de dados, detecção da região de interesse (espelho nasal) utilizando um classificador em cascata, pré-processamento das imagens, extração de características utilizando-se a técnica *bag-of-words* com características SIFT (LOWE, 2004) e o descritor WLD (CHEN et al., 2010), treinamento do classificador k-NN (COVER; HART, 2006) para identificação de bovinos e avaliação dos resultados.

Os passos necessários para o treinamento/classificação estão ilustrados na Figura 5.



Fonte: Autoria própria.

A explicação da metodologia irá considerar as seguintes etapas principais: bases de dados (Seção 3.1), detecção da região de interesse (Seção 3.2), classificação (Seção 3.3) e avaliação dos resultados (Seção 3.4).

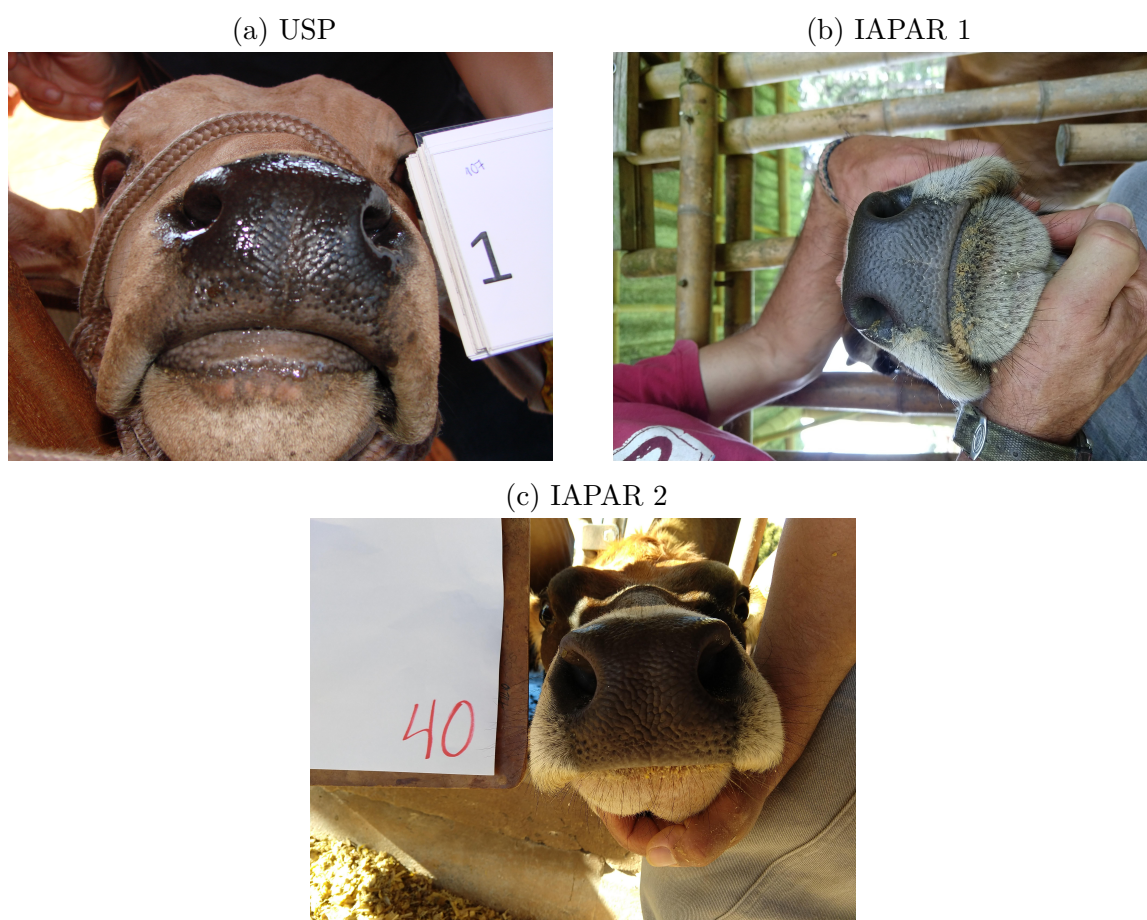
3.1 Bases de Dados

Para o treinamento eficaz de métodos de reconhecimento de padrões, faz-se necessária a digitalização do espelho nasal de um conjunto de bovinos. Nos testes experimentais serão utilizadas três bases de dados, a primeira disponibilizada pela Universidade de São Paulo (USP) (LEICK, 2016) e as outras duas coletadas e disponibilizadas pelo Instituto Agrônomo do Paraná (IAPAR). As bases estão descritas abaixo:

- USP: base composta por 1007 imagens de 51 bovinos diferentes. Cada animal possui entre 10 e 23 imagens de dimensão 2048×1536 pixels.
- IAPAR 1: base composta por 1942 imagens, pertencentes a 17 animais diferentes. Foi usada apenas para o treinamento do detector devido a qualidade das imagens.
- IAPAR 2: base composta por 987 imagens de 51 bovinos diferentes. Cada animal possui entre 12 e 31 imagens de dimensão 4032×3024 pixels.

Exemplos de imagens das bases podem ser vistas na Figura 6.

Figura 6 – Exemplos de imagens das bases.



Fonte: USP e IAPAR.

Como pode ser observado, elas são relativamente complexas, contendo um fundo não controlado e variações de iluminação e escala.

3.2 Detecção da Região de Interesse

Para a detecção da região de interesse, mais especificamente a área entre as narinas do bovino, foram aplicados três classificadores em cascata utilizando características de Haar (Seção 2.2.1). O primeiro busca encontrar o focinho do animal, enquanto cada um dos outros dois classificadores busca encontrar a narina direita e a narina esquerda.


Nas sequências serão descritos o treinamento dos classificadores e o método utilizado para detecção da região de interesse.

3.2.1 Treinamento classificador 01: focinho

Para o treinamento do classificador são necessários exemplos positivos e negativos do que se deseja identificar. No contexto deste trabalho, um exemplo positivo consiste em uma imagem do focinho (ou das narinas, como é o caso do próximo classificador). Analogamente, um exemplo negativo é qualquer imagem que não contenha um focinho.

A separação de tais exemplos foi feita manualmente utilizando-se imagens das bases de dados. A região de interesse é recortada da imagem original, conforme ilustrado na Figura 7, resultando em uma imagem do focinho e outra sem o focinho. O vazio deixado pelo recorte do focinho na imagem original é preenchido utilizando o algoritmo de *inpainting* descrito em Telea (2004).

Figura 7 – Espelho nasal selecionado para recorte.



Fonte: Autoria própria.

A Figura 8(a) ilustra um exemplo de imagem positiva e a Figura 8(b) de imagem negativa. Observe que a imagem negativa consiste na imagem original com a região do focinho distorcida, visando manter informações do cenário de aquisição.


Devido ao alto número de imagens necessárias para o treinamento do classificador cerca de 4000 imagens artificiais foram criadas a partir dos exemplos recortados manualmente. Foram consideradas alterações de escala e rotação, por exemplo. A Figura 9 ilustra exemplos de imagens artificiais criadas.

Figura 8 – Exemplo de imagens a serem utilizadas no treinamento.

(a) Exemplo de imagem positiva.



(b) Exemplo de imagem negativa.



Fonte: Autoria própria.

Figura 9 – Exemplo de imagens artificiais.

(a)



(b)



Fonte: Autoria própria.

3.2.2 Treinamento classificadores 02 e 03: narinas esquerda e direita

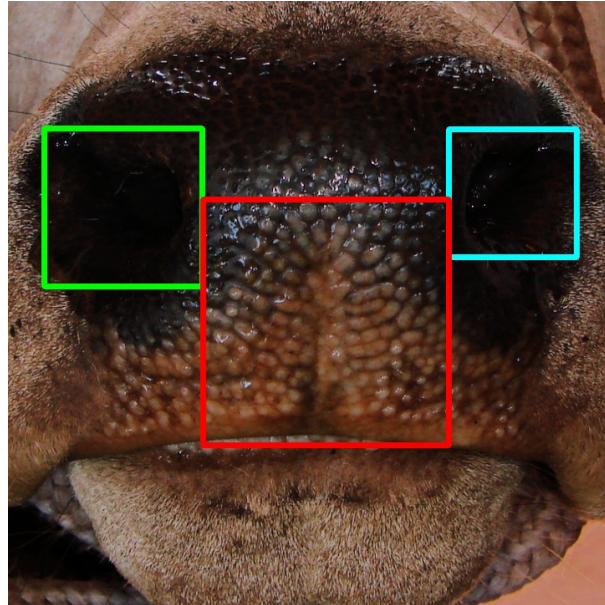
O treinamento dos outros dois classificadores segue o mesmo processo descrito na seção anterior, apenas substituindo a imagem original pela imagem do focinho já identificado e a região de interesse (anteriormente o focinho) pela narina que se deseja identificar.

3.2.3 Detecção do espelho nasal

Utilizando-se os classificadores treinados é detectado primeiro o focinho do animal. A partir do focinho detectado são então detectadas as duas narinas. A região correspondente ao espelho nasal é definida com base na localização das narinas, criando-se um quadrado utilizando a distância entre as narinas, conforme ilustrado na Figura 10. Este quadrado é

a região de interesse que será utilizada para o treinamento dos algoritmos nas próximas etapas.

Figura 10 – Exemplo de região de interesse identificada.



Fonte: Autoria própria.

3.3 Classificação dos bovinos

O desenvolvimento desta etapa envolve pesquisar, avaliar e comparar diferentes características extraídas dos espelhos nasais, visando produzir descritores que conduzam a uma classificação precisa e robusta a variações encontradas no processo de aquisição, como as descritas na Seção 3.1.


Primeiramente é feito um pré-processamento nas imagens de entrada. Foram testados dois pré-processamentos, descritos a seguir:

- Pré-processamento 1: Equalização do histograma seguido pela aplicação de um filtro gaussiano.
- Pré-processamento 2: Equalização do histograma, negativo da imagem e aplicação de um filtro gaussiano.

A equalização do histograma foi feita visando melhorar o contraste e a aplicação do filtro gaussiano foi utilizada para diminuir o ruído. O negativo da imagem, feito no pré-processamento 2, foi utilizado para tentar destacar os cumes e vales. A Figura 11 ilustra o resultado da aplicação dos dois pré-processamentos.

Foram testadas duas técnicas para a extração de características, sendo elas o modelo *bag-of-words* utilizando características SIFT e o descritor WLD. O modelo *bag-of-words* foi escolhido por ser um método clássico e amplamente utilizado na área de reconhecimento de padrões em imagens. Já o WLD foi escolhido por ser robusto a

Figura 11 – Exemplo do pré-processamento realizado: (a) negativo e (b) filtro Gaussiano.



Fonte: Autoria própria.

alterações de rotação, iluminação e ruídos, além de já ter sido considerado em trabalhos anteriores para identificação biométrica de bovinos (mais detalhes podem ser vistos na Seção 2.2.3). Nesta etapa, o k-NN foi utilizado para classificação.

3.4 Avaliação

Os resultados serão avaliados em duas etapas. Primeiro será feita a avaliação da detecção do espelho nasal e depois a avaliação da classificação.

3.4.1 Avaliação da detecção do espelho nasal

Para realizar a avaliação desta etapa serão utilizadas duas métricas: acurácia e índice de Jaccard. A acurácia mede a porcentagem de classificações corretas:


$$\text{Acurácia} = \frac{n}{N}, \quad (7)$$

em que N é o número de amostras de teste e n o número de amostras classificadas corretamente. No contexto deste trabalho, o número de classificações corretas é o número de imagens que tiveram o espelho nasal detectado.

A acurácia nos ajuda a avaliar o resultado quantitativamente, mas também é desejável fazer uma avaliação qualitativa. O índice de Jaccard nos ajuda a calcular o quanto dois conjuntos são parecidos. Neste trabalho, os conjuntos são as coordenadas dos *pixels* da imagem em que o espelho nasal foi encontrado pela etapa de detecção e a

localização real do espelho nasal na imagem marcada à mão. A Figura 12 ilustra o cálculo deste índice, cujos valores resultantes estão entre 0 e 1 (sendo quanto mais próximo de 1 mais parecidas são as áreas).

Figura 12 – Cálculo do índice de Jaccard.

$$\text{Jaccard} = \frac{\text{Área de intersecção}}{\text{Área de união}}$$


Fonte: Adaptado de <https://www.pyimagesearch.com/>.

3.4.2 Avaliação da classificação

A avaliação dessa etapa será realizada utilizando três métricas: acurácia, sensibilidade e especificidade. Para cada bovino, uma imagem positiva é o seu espelho nasal e uma imagem negativa é o espelho nasal de qualquer outro. Um verdadeiro positivo é uma imagem positiva que foi classificada como positiva, um falso positivo é uma imagem negativa que foi classificada como positiva, verdadeiro negativo e falso negativo são análogos.

A sensibilidade é dada pela divisão da quantidade de verdadeiros positivos pela quantidade de positivos de um bovino. Essa medida nos diz o quanto conseguimos classificar corretamente as imagens positivas daquele bovino. Já a especificidade é dada pela divisão dos verdadeiros negativos pelos negativos de um bovino. Quanto mais alto esse índice menos imagens negativas estão sendo classificadas como positivas.

Para cada um dos bovinos será calculada a sua sensibilidade e especificidade, ao fim será utilizada a média desses resultados para avaliação, juntamente com a acurácia, explicada anteriormente. Visando facilitar a interpretação dos resultados, os testes serão divididos nos seguintes cenários:

Cenário 01 : base USP e IAPAR 2 com o descritor WLD.

Cenário 02 : base USP e IAPAR 2 com a técnica *bag-of-words* utilizando o descritor SIFT.

4 RESULTADOS

Os resultados dos testes experimentais serão discutidos visando avaliar o desempenho das seguintes etapas:

1. Detecção da região de interesse: análises quantitativa e qualitativa da detecção do espelho nasal - ou seja, do focinho, da narina esquerda e da narina direita.
2. Classificação: considerando-se diferentes descritores (mais especificamente WLD e técnica *bag-of-words* utilizando o descritor SIFT), é avaliado o desempenho do classificador k-NN na identificação de bovinos.

Além de possibilitar uma análise quantitativa sobre os resultados obtidos, esta avaliação permite também tentar identificar alguns padrões em que determinados resultados ocorrem. Por exemplo, há um padrão nas imagens em que o espelho nasal não é encontrado? Os focinhos classificados erroneamente possuem características em comum? A qualidade das imagens das bases teve impacto no resultado final? Com essas perguntas em mente os resultados foram analisados.

4.1 Detecção da região de interesse

Para o treinamento dos detectores, foram utilizadas 350 imagens da base USP e 350 imagens da base IAPAR 1. Seguindo o procedimento descrito na Seção 3.2, foram recortadas as narinas e o focinho das imagens para gerar 700 exemplos positivos (e 700 negativos) de cada um destes elementos. Com os exemplos criados, foram treinados os três classificadores em cascata para a detecção do focinho e das narinas direita e esquerda.

Os resultados foram avaliados quantitativamente e qualitativamente, sendo a avaliação qualitativa feita com base em cortes manuais do espelho nasal para a base IAPAR 2 e a quantitativa utilizando imagens das bases USP e IAPAR 2.

4.1.1 Avaliação quantitativa

Na base da USP foram detectados corretamente 944 espelhos nasais de 1007 imagens, obtendo-se uma acurácia de 93,7%. Em apenas uma das imagens que não tiveram o espelho nasal encontrado o erro foi ao tentar encontrar o focinho. Em todas as outras ele aconteceu ao se identificar uma das narinas.

Já na base IAPAR 2 foram detectados 763 espelhos nasais de 987 imagens, obtendo uma acurácia de 77,3%. Muitos dos erros ocorreram por variação do ângulo de captura da imagem ou diferença de iluminação, como é o caso do bovino da Figura 13 da base USP, que obteve 6% de sucesso na detecção automática. Note que a iluminação sobre sua narina direita dificulta a visualização.

Figura 13 – Exemplo de imagem que o algoritmo teve dificuldade.



Fonte: USP.

A Tabela 1 sumariza os resultados.

Tabela 1 – Resultados da análise quantitativa da detecção da região de interesse.

Base	Acurácia
IAPAR 2	77,3%
USP	93,7%


A maioria dos erros na base IAPAR 2 ocorreram ao se tentar encontrar as narinas, pois o passo anterior acabou gerando várias imagens onde as mesmas aparecem apenas parcialmente, como pode ser visto na Figura 14(a). Alguns erros durante a primeira parte do algoritmo, encontrar o focinho, aconteceram ao se identificar o queixo do animal como focinho, conforme exemplificado na Figura 14(b).

4.1.2 Avaliação qualitativa

Utilizando o índice Jaccard foi possível avaliar qualitativamente os espelhos nasais detectados pelo classificador em cascata. Foi obtido um índice de 0.71 em média para todas as 763 imagens da base IAPAR 2 que tiveram seu espelho nasal detectado, o que é um resultado razoável dado a complexidade das imagens.


As imagens com os menores índices são tipicamente aquelas com baixa iluminação na região das narinas, aquelas que tiveram as narinas cortadas na etapa de detecção do focinho ou aquelas em que o bovino está com o focinho mais de lado (pois esses casos fazem com que o detector não encontre as narinas corretamente). Um exemplo dessas imagens pode ser visto na Figura 15 - note que outra região é detectada como uma narina fazendo com que a área detectada como espelho nasal seja muito menor que o real.

Figura 14 – Erros ocorridos na etapa de detecção: (a) Focinho identificado com as narinas cortadas e (b) Queixo do animal identificado no lugar do focinho.



Fonte: Autoria própria.

Figura 15 – Exemplo de imagem com baixo índice de Jaccard.



Fonte: Autoria própria.

4.2 Classificação

Tiveram a região de interesse corretamente detectada 763 imagens da base IAPAR 2 (de 49 bovinos diferentes) e 944 imagens da base USP (de 50 bovinos diferentes). O treinamento do classificador k-NN foi realizado utilizando 5 imagens de treino para cada animal, tanto para a base IAPAR 2 quanto para a base USP. Para os testes foram usadas entre 2 e 23 imagens para cada animal na base IAPAR 2 e entre 4 e 26 imagens para cada animal na base USP.

As próximas seções apresentam os resultados dos cenários descritos na Seção 3.4,

utilizando como descritores (1) a técnica de *bag-of-words* com SIFT e (2) WLD.

4.2.1 Cenário 1: WLD

Os resultados para o Cenário 1 podem ser vistos na Tabela 2. Olhando apenas a especificidade, é possível notar que o WLD foi robusto contra falsos positivos, o que é desejável em sistemas biométricos. Ao olharmos para os valores da sensibilidade e acurácia, observa-se uma alta taxa de acerto. O resultado apresentado considera apenas um único vizinho no k-NN, dado que nos testes experimentais o aumento do número de vizinhos comprometia o desempenho.


Tabela 2 – Cenário 1: Resultados do k-NN, com $k = 1$.

	Acurácia	Sensibilidade	Especificidade
WLD - IAPAR 2	92,33%	91,24%	99,84%
WLD - USP	91,35%	91,37%	99,82%

Ao analisar as imagens da base IAPAR 2 classificadas erroneamente, foi possível identificar alguns padrões nos erros. O recorte feito pelo passo de detecção em alguns casos gerou imagens que cobrem regiões diferentes de um mesmo espelho nasal. Por exemplo, considerando as detecções para um mesmo animal mostradas na Figura 16, é possível notar que primeira imagem cobre uma região menor do que a segunda.

Figura 16 – Exemplo de erro devido ao corte do focinho.

(a) Corte inadequado.



(b) Corte adequado.

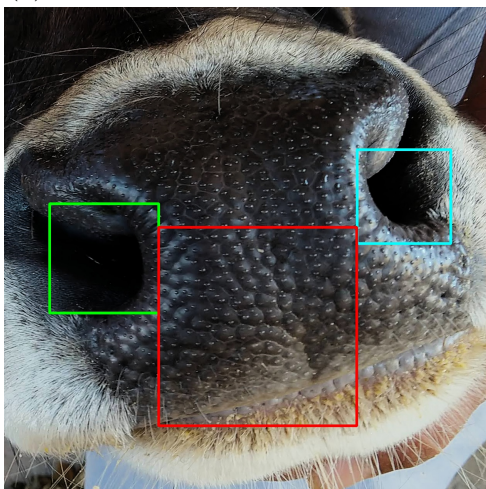


Fonte: Autoria própria.

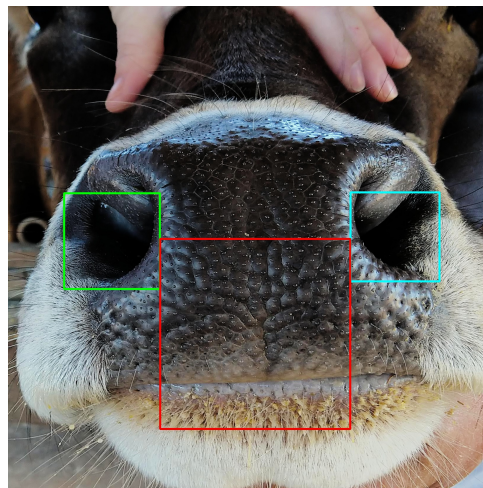
Ainda observando os cortes, percebe-se que a variação nas posições em que as fotos foram tiradas também impactaram negativamente nos resultados, pois alteram a inclinação e/ou o ângulo do espelho nasal. Um exemplo dessa situação é mostrado na Figura 17. A imagem da Figura 17(a) não foi classificada corretamente. Por outro lado, a classificação da imagem da Figura 17(b) foi correta.

Figura 17 – Exemplo de erro devido ao ângulo/inclinação da imagem.

(a) Imagem com angulação diferente.




(b) Imagem com angulação semelhante à das demais imagens da base.



Fonte: Autoria própria.

O maior problema da base IAPAR 2 foi a qualidade das fotos. Apesar de se ter alcançado uma alta taxa de acerto, muitas fotos da base possuem baixa qualidade na região do focinho, como desfoque e baixa iluminação, o que acaba por atrapalhar a visualização dos padrões no focinho do animal. Alguns exemplos podem ser vistos na Figura 18.

Figura 18 – Exemplo de imagens com baixa qualidade da base IAPAR 2.




Fonte: Autoria própria.


A base USP não teve grandes problemas em relação a sua qualidade, pois os padrões dos focinhos são bem mais visíveis (em sua maioria, as fotos foram adquiridas usando um protocolo mais rígido). Os erros de classificação que ocorreram na base USP, praticamente em sua totalidade, foram devido às poucas imagens borradas que a mesma possuía. A Figura 19 ilustra o tipo de imagem que tipicamente foi classificada errada.

Figura 19 – Exemplo de imagens desfocadas na base USP.

(a) Imagem borrada.



(b) Imagem borrada.



Fonte: Autoria própria.

4.2.2 Cenário 2: Bag-of-Words com características SIFT

No Cenário 2 foi realizado um treinamento com *K-Means* considerando 500 *words* (*clusters*), esse valor foi escolhido empiricamente. Os resultados podem ser vistos na Tabela 3. Assim como o WLD, o BOW obteve uma especificidade alta em ambas as bases, mas a sensibilidade e a acurácia foram baixas na base IAPAR 2. Durante a etapa de localização dos pontos-chaves, cerca de 62 imagens da base IAPAR 2 não tiveram nenhum ponto localizado, o que indica uma dificuldade do algoritmo com essa base.

Tabela 3 – Cenário 2: Resultados do k-NN, com $k = 1$.


	Acurácia	Sensibilidade	Especificidade
SIFT - IAPAR 2	61,31%	57,88%	99,19%
SIFT - USP	81,12%	79,68%	99,61%

Buscando melhorar o resultado foi feita uma alteração no pré-processamento. Antes de utilizar o filtro gaussiano foi computado o negativo da imagem, o que ajuda a destacar os cumes e vales. Essa alteração fez com os SIFT encontrasse pontos-chaves em todas as imagens. A Figura 20 ilustra a diferença entre os dois pré-processamentos.

O resultado obtido ao utilizar o negativo da imagem pode ser visto na Tabela 4. Observa-se um ganho considerável em relação ao resultado anterior. O resultado para a base IAPAR 2 é muito semelhante ao do WLD e o resultado da base da USP é superior ao WLD.

Analisando as imagens classificadas erroneamente, percebe-se que o SIFT teve os mesmos problemas que o WLD. Espelhos nasais borrados acabaram por não ter os pontos-chaves encontrados, ao utilizar o pré-processamento 1, ou por ter muitos poucos

Figura 20 – Exemplo do pré-processamento utilizado.



Fonte: Autoria própria.

Tabela 4 – Cenário 2: Resultados do k-NN utilizando imagem negativa, com $k = 1$.

	Acurácia	Sensibilidade	Especificidade
SIFT - IAPAR 2	92,32%	91,39%	99,84%
SIFT - USP	95,67%	95,51%	99,91%

pontos encontrados ao utilizar o pré-processamento 2. Assim como no WLD os recortes que cobrem diferentes áreas do espelho nasal também foram um problema.

4.2.3 Discussão dos resultados

Os experimentos realizados revelam que ambas as abordagens são adequadas para a identificação biométrica dos bovinos. É observada uma alta robustez contra falsos positivos e uma alta taxa de acertos em ambas as técnicas, sendo que a técnica de *bag-of-words* com SIFT obteve uma pequena vantagem sobre o WLD. A Tabela 5 traz os resultados finais para ambas as técnicas.

Tabela 5 – Resultados do k-NN para ambos os cenários, com $k = 1$.

	Acurácia	Sensibilidade	Especificidade
SIFT - IAPAR 2	92,32%	91,39%	99,84%
SIFT - USP	95,67%	95,51%	99,91%
WLD - IAPAR 2	92,33%	91,24%	99,84%
WLD - USP	91,35%	91,37%	99,82%

Além dos resultados apresentados também foram testados outros classificadores, como o SVM e o AdaBoost, mas eles obtiveram um resultado abaixo dos do k-NN. A técnica de pré-processamento 2 utilizada com o SIFT também foi testada com o WLD, mas o mesmo não obteve ganhos significativos.

5 CONSIDERAÇÕES FINAIS

A identificação biométrica de bovinos surgiu como um modo de minimizar os problemas apresentados pelas identificações mecânicas e eletrônicas. Por utilizar uma característica única e que acompanha o animal durante toda sua vida, a identificação biométrica se mostra mais confiável do que outros tipo de identificação. Neste trabalho foram desenvolvidas duas abordagens para a identificação biométrica de imagens do espelho nasal bovino, uma utilizando o modelo *bag-of-words* e a outra utilizando o descritor WLD.

A detecção da região do espelho nasal é um passo inicial para que a identificação biométrica possa ser realizada. Neste trabalho foram utilizados classificadores em cascata para detectar a região do espelho nasal. O método atingiu bons valores de acurácia mas falhou em caso específicos, geralmente quando a captura da imagem divergia da captura padrão, apresentando diferente iluminação ou orientação dos focinhos. Este é um ponto de melhoria que deve ser explorado. Métodos invariantes à iluminação e métodos para corrigir a orientação podem ser usados para melhorar a detecção.

A partir dos espelhos nasais detectados foram testados dois métodos para identificação de indivíduos: um baseado em *bag-of-words* com características SIFT e um baseado no descritor WLD. Ambas as abordagens mostraram-se adequadas para a identificação biométrica, atingindo valores altos de acurácia, sensibilidade e especificidade. Além dos problemas relacionados ao corte, comentados anteriormente, há problemas nessa etapa relacionados à qualidade das imagens de entrada, tais como imagens desfocadas e com iluminação baixa. Visando melhorar a qualidade das imagens pode ser realizada futuramente a padronização do método de aquisição. Além dessa padronização outros detectores podem ser testados, como os baseados em redes profundas.

Referências

ABIEC, B. Exportações brasileiras de carne bovina 2017. 2017. **Disponível na internet por http em:** <<<http://www.abiec.com.br/download/Anual-jan-dez-2017.pdf>>>. **Acesso em 2018**, 2018. Citado na página 12.

AWAD, A. I. From classical methods to animal biometrics: a review on cattle identification and tracking. **Computers and Electronics in Agriculture**, Elsevier, v. 123, p. 423–435, 2016. Citado 3 vezes nas páginas 12, 14 e 15.

BARANOV, A. et al. Breed differences and intra-breed genetic variability of dermatoglyphic pattern of cattle. **Journal of animal breeding and genetics**, Wiley Online Library, v. 110, n. 1-6, p. 385–392, 1993. Citado 2 vezes nas páginas 13 e 14.

BARRY, B. et al. Using muzzle pattern recognition as a biometric approach for cattle identification. **Transactions of the ASABE**, American Society of Agricultural and Biological Engineers, v. 50, n. 3, p. 1073–1080, 2007. Citado 2 vezes nas páginas 14 e 21.

CHEN, J. et al. WLD: A robust local image descriptor. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 32, n. 9, p. 1705–1720, 2010. Citado 3 vezes nas páginas 18, 22 e 23.

CHRISTOPHER, M. B. **PATTERN RECOGNITION AND MACHINE LEARNING**. [S.l.]: Springer-Verlag New York, 2016. Citado na página 15.

CORKERY, G. et al. A preliminary investigation on face recognition as a biometric identifier of sheep. **Transactions of the ASABE**, American Society of Agricultural and Biological Engineers, v. 50, n. 1, p. 313–320, 2007. Citado na página 14.

COVER, T.; HART, P. Nearest neighbor pattern classification. **IEEE Trans. Inf. Theor.**, IEEE Press, Piscataway, NJ, USA, v. 13, n. 1, p. 21–27, set. 2006. ISSN 0018-9448. Disponível em: <<https://doi.org/10.1109/TIT.1967.1053964>>. Citado na página 23.

FEI-FEI, L.; PERONA, P. A bayesian hierarchical model for learning natural scene categories. In: IEEE. **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**. [S.l.], 2005. v. 2, p. 524–531. Citado na página 17.

FREUND, Y.; SCHAPIRE, R. E. A decision-theoretic generalization of on-line learning and an application to boosting. **Journal of computer and system sciences**, Elsevier, v. 55, n. 1, p. 119–139, 1997. Citado na página 16.

GABER, T. et al. Biometric cattle identification approach based on weber's local descriptor and adaboost classifier. **Computers and Electronics in Agriculture**, Elsevier, v. 122, p. 55–66, 2016. Citado 4 vezes nas páginas 12, 19, 21 e 22.

GIMENEZ, C. M. **Identificação de bovinos através de reconhecimento de padrões do espelho nasal utilizando redes neurais artificiais**. Dissertação (Mestrado) — Universidade de São Paulo, 2011. Citado 2 vezes nas páginas 12 e 14.

- GIMENEZ, C. M. **Identificação biométrica de bovinos utilizando imagens do espelho nasal**. Tese (Doutorado) — Universidade de São Paulo, 2015. Citado 4 vezes nas páginas 12, 13, 14 e 15.
- GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. [S.l.]: Upper Saddle River, NJ: Prentice Hall, 2012. Citado na página 16.
- IBGE, B. Indicadores ibge: Estatística da produção pecuária março de 2018. 2018. **Disponível na internet por http em:** <<https://biblioteca.ibge.gov.br/visualizacao/periodicos/2380/epp_2018_mar.pdf>>. Acesso em 2018, 2018. Citado na página 12.
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: A review. **IEEE Transactions on pattern analysis and machine intelligence**, Ieee, v. 22, n. 1, p. 4–37, 2000. Citado 2 vezes nas páginas 15 e 16.
- JAIN, A. K.; FLYNN, P.; ROSS, A. A. **Handbook of biometrics**. [S.l.]: Springer Science & Business Media, 2007. Citado na página 14.
- LEICK, W. d. S. **Tecnologia computacional de apoio a rastreabilidade biométrica de bovinos**. Dissertação (Mestrado) — Universidade de São Paulo, 2016. Citado 2 vezes nas páginas 12 e 23.
- LIENHART, R.; MAYDT, J. An extended set of haar-like features for rapid object detection. In: **IEEE. Image Processing. 2002. Proceedings. 2002 International Conference on**. [S.l.], 2002. v. 1, p. I–I. Citado na página 16.
- LLOYD, S. Least squares quantization in PCM. **IEEE transactions on information theory**, IEEE, v. 28, n. 2, p. 129–137, 1982. Citado na página 17.
- LOWE, D. G. Distinctive image features from scale-invariant keypoints. **Int. J. Comput. Vision**, Kluwer Academic Publishers, Norwell, MA, USA, v. 60, n. 2, p. 91–110, nov. 2004. ISSN 0920-5691. Disponível em: <<https://doi.org/10.1023/B:VISI.0000029664.99615.94>>. Citado 2 vezes nas páginas 17 e 23.
- MINAGAWA, H. et al. Identification of beef cattle by analyzing images of their muzzle patterns lifted on paper. **Publications of the Japanese Society of Agricultural Informatics**, v. 8, p. 596–600, 2002. Citado na página 21.
- MUSGRAVE, C.; CAMBIER, J. L. **System and method of animal identification and animal transaction authorization using iris patterns**. [S.l.]: Google Patents, 2002. US Patent 6,424,727. Citado na página 14.
- NOVIYANTO, A.; ARYMURTHY, A. M. Beef cattle identification based on muzzle pattern using a matching refinement technique in the sift method. **Computers and electronics in agriculture**, Elsevier, v. 99, p. 77–84, 2013. Citado 3 vezes nas páginas 13, 14 e 21.
- REUTERS. Produção de carne bovina e suína do brasil deve aumentar em 2018. **EXAME**, 2018. Citado na página 12.
- SOFOS, J. N. Challenges to meat safety in the 21st century. **Meat science**, Elsevier, v. 78, n. 1-2, p. 3–13, 2008. Citado na página 12.

TELEA, A. An image inpainting technique based on the fast marching method. **Journal of graphics tools**, Taylor & Francis, v. 9, n. 1, p. 23–34, 2004. Citado na página 25.

THARWAT, A.; GABER, T.; HASSANIEN, A. E. Cattle identification based on muzzle images using Gabor features and SVM classifier. In: SPRINGER. **International Conference on Advanced Machine Learning Technologies and Applications**. [S.l.], 2014. p. 236–247. Citado 2 vezes nas páginas 21 e 22.

VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. In: IEEE. **Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on**. [S.l.], 2001. v. 1, p. I–I. Citado na página 16.

WANT, R. An introduction to RFID technology. **IEEE pervasive computing**, IEEE, v. 5, n. 1, p. 25–33, 2006. Citado na página 12.