

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
CURSO DE ENGENHARIA DE COMPUTAÇÃO

MARLON LUIS GRANDO

**CLASSIFICAÇÃO DE BOVINOS POR MEIO DA
CARACTERÍSTICA DO FOCINHO UTILIZANDO VISÃO
COMPUTACIONAL**

TRABALHO DE CONCLUSÃO DE CURSO

PATO BRANCO

2018

MARLON LUIS GRANDO

CLASSIFICAÇÃO DE BOVINOS POR MEIO DA CARACTERÍSTICA DO FOCINHO UTILIZANDO VISÃO COMPUTACIONAL

Trabalho de Conclusão de Curso 2, apresentado à disciplina de Trabalho de Conclusão de Curso 2, do Curso de Engenharia de Computação da Universidade Tecnológica Federal do Paraná - UTFPR, Câmpus Pato Branco, como requisito parcial para obtenção do título de Engenheiro da Computação.

Orientador: Prof. Dr. Dalcimar Casanova

PATO BRANCO

2018



TERMO DE APROVAÇÃO

Às 17 horas do dia 06 de dezembro de 2018, na sala V106, da Universidade Tecnológica Federal do Paraná, Câmpus Pato Branco, reuniu-se a banca examinadora composta pelos professores Dalcimar Casanova (orientador), Ives Rene Venturini Pola e Pablo Gauterio Cavalcanti para avaliar o trabalho de conclusão de curso com o título **Classificação de bovinos por meio da característica do focinho utilizando visão computacional**, do aluno **Marlon Luis Grandó**, matrícula 00949540, do curso de Engenharia de Computação. Após a apresentação o candidato foi arguido pela banca examinadora. Em seguida foi realizada a deliberação pela banca examinadora que considerou o trabalho aprovado.

Prof. Dalcimar Casanova
Orientador (UTFPR)

Prof. Ives Rene Venturini Pola
(UTFPR)

Prof. Pablo Gauterio Cavalcanti
(UTFPR)

Profa. Beatriz Terezinha Borsoi
Coordenador de TCC

Prof. Pablo Gauterio Cavalcanti
Coordenador do Curso de
Engenharia de Computação

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

RESUMO

Grando, Marlon Luis. Classificação de bovinos por meio da característica do focinho utilizando visão computacional. 2018. 38f. Monografia (Trabalho de Conclusão de Curso 2) - Curso de Engenharia de Computação, Universidade Tecnológica Federal do Paraná, Câmpus Pato Branco. Pato Branco, 2018.

O controle do rebanho bovino é um fator fundamental para agregar valor ao produto, tanto para produção leiteira, quanto para o gado de corte, sendo esse último, o que mais faz uso desse método, devido as exigências de países importadores. Por esse motivo, faz-se necessário uma melhor identificação, pois os métodos disponíveis atualmente, como identificação por radio frequência (RFID), brincos, marcação a ferro em brasa, possuem problemas, pois são sujeitos a fraude e causam sofrimento ao animal. Visando resolver as questões acima citadas, esse trabalho se propõe a utilizar métodos de classificação, para cada um dos animais e em diversos ambiente que se faça necessário. Nesse sentido, esse trabalho utiliza visão computacional, para classificação de bovinos por meio de características do focinho. São empregadas técnicas com matriz de co-ocorrência, algoritmos genéticos e classificador knn. Os resultados do estudo demonstram que a taxa de acerto desse método é de 96,75%, assim mostrando que o classificador pode ser empregado para a finalidade proposta.

Palavras-chave: GLCM, Matriz de Co-ocorrência, AG, Algoritmo Genético, KNN.

ABSTRACT

Grando, Marlon Luis. Classification of bovines through the characteristic of the muzzle using computer vision. 2018. 38f. Monografia (Trabalho de Conclusão de Curso 2) - Computer Engineering Course, Federal Technological University of Paraná, Câmpus Pato Branco. Pato Branco, 2018.

The control of the cattle herd is a fundamental factor to add value to the product, both for dairy production and for beef cattle. The one that makes the most use of this method is the beef cattle, due to the requirements of importing countries. For this reason, a better identification is necessary because the methods currently available, such as radio frequency identification (RFID), earrings, red-hot branding, have problems because they are subject to fraud and they cause suffering to the animal. In order to solve the issues mentioned above, this work proposes to use classification methods for each of the animals and in several environments that are necessary. In this way, this work uses computer vision to classify cattle by muzzle characteristics. Techniques with gray level co-occurrence matrix, genetic algorithms and knn classifier are used. The results of the study demonstrate that the hit rate of this method is 96.75%, thus showing that the classifier can be used for the proposed purpose.

Keywords: GLCM, Gray-Level Co-ocurrence Matrix, GA, Genetic Algorithm, KNN.

LISTA DE FIGURAS

Figura 1:	Aplicação do GLCM em uma imagem em escala cinza.	13
Figura 2:	Representação genética: (a) Binária, (b) Decimal	16
Figura 3:	Seleção por torneio.	17
Figura 4:	Exemplo da ação do operador de cruzamento.	18
Figura 5:	Atuação do operador de mutação.	19
Figura 6:	Distância Euclidiana no espaço bidimensional	20
Figura 7:	Exemplo de classificação de uma instância desconhecida	20
Figura 8:	Iterações do Leave One Out	22
Figura 9:	Matriz de confusão	23
Figura 10:	Imagem adquirida do focinho de um bovino	25
Figura 11:	Exemplo da qualidade da imagem obtida com o celular	26
Figura 12:	Imagem do focinho recortada	27
Figura 13:	Imagem resultante final	27
Figura 14:	Fluxograma do classificador	31
Figura 15:	Da esquerda para direita: os focinhos das classes 2 e 3	33
Figura 16:	Da esquerda para direita: os focinhos das classes 7 e 8	33

LISTA DE ACRÔNIMOS E SIGLAS

AGs	<i>Genetic Algorithm</i> ou Algoritmos Genéticos.
ANN	<i>Artificial Neural Network</i> ou Rede Neural Artificial.
GLCM	<i>Gray-Level Co-occurrence Matrix</i> ou Matriz de Co-ocorrência.
KNN	<i>K-Nearest Neighbor</i> ou K-Vizinhos Mais Próximos.
LOO	<i>Leave-One-Out</i> ou Deixe-Um-De-Fora.
MAPA	Ministério da Agricultura, Pecuária e Abastecimento.
RANSAC	<i>Random sample consensus</i> ou Consenso de Amostra Aleatória.
SFTA	<i>Segmentation based fractal texture analysis</i> ou Análise de textura Fractal Baseada em Segmentação.
SIFT	<i>Scale-Invariant Feature Transform</i> ou Transformação de Características Invariantes à Escala.
SISBOV	Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina.

SUMÁRIO

1 INTRODUÇÃO	8
1.1 CONSIDERAÇÕES INICIAIS	8
1.2 JUSTIFICATIVA	10
1.3 OBJETIVOS	10
1.3.1 Objetivo Geral	10
1.3.2 Objetivos Específicos	11
1.4 ESTRUTURA	11
2 REFERENCIAL TEÓRICO	12
2.1 VISÃO COMPUTACIONAL	12
2.2 MATRIZ DE CO-OCORRÊNCIA	12
2.2.1 Descritores de Haralick	14
2.3 ALGORITMOS GENÉTICOS	15
2.3.1 Representação Genética	16
2.3.2 Função de Avaliação	17
2.3.3 Métodos de Seleção	17
2.3.4 Operadores Genéticos	18
2.3.4.1 Operadores de Cruzamento	18
2.3.4.2 Operador de Mutação	18
2.4 CLASSIFICAÇÃO	19
2.4.1 KNN	19
2.4.2 Validação Cruzada	20
2.4.2.1 K-fold	21
2.4.2.2 Leave-One-Out	21
2.4.2.3 Hold-Out	22
2.4.3 Avaliação de Resultados	22
2.4.3.1 Taxa de Erro	22
2.4.4 Matriz de Confusão	23
3 RESULTADOS E AVALIAÇÃO	24

3.1 AQUISIÇÃO DA BASE DE DADOS	24
3.2 PRÉ-PROCESSAMENTO	26
3.3 EXTRAÇÃO DE CARACTERÍSTICAS.....	27
3.4 CLASSIFICAÇÃO E RESULTADOS PRELIMINARES	29
3.5 SELEÇÃO DE CARACTERÍSTICAS	30
4 CONCLUSÕES.....	34

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

No Século XXI, era da informação e da tecnologia, um dos setores que mais movimentou a economia é o agronegócio. Até o ano de 2015, esse setor colaborou com 23% do total do Produto Interno Bruto do Brasil (CNA, 2017), movimentando a economia através da união de vários segmentos, como o de insumos, primários e industriais, que por, sua vez, estão divididos em outros diversos segmentos.

O setor primário da agricultura e pecuária passa, hoje, por uma fase de informatização e automatização, que tem como objetivo trazer um melhor rendimento para o homem do campo, sendo conhecido esse segmento, pelo termo, agricultura de precisão. Aos poucos, a tecnologia vem ficando mais acessível, porém, no setor pecuarista de corte e leiteiro, é mais difícil de se perceber o avanço da informatização nas pequenas e médias propriedades, devido ao alto valor dos equipamentos disponíveis no mercado e à falta de conhecimento dos benefícios trazidos pela tecnologia ao produtor, assim como a precaução de alguns em evitar contrair uma dívida (BOTEGA *et al.*, 2008).

Para os produtores venderem seus produtos, em virtude da exigência dos compradores, geralmente agroindústrias ou cooperativas, é necessário que eles estejam em conformidade com padrões de exigência de seu mercado interno, externo ou ambos, exigências estas que têm como proposta evitar produtos com qualidade inferior, estragados ou fora dos padrões sanitários, além de serem necessárias para a classificação dos produtos de acordo com a finalidade de uso.

Devido à episódios ocorridos no passado no Brasil, como a incidência da doença encefalopatia espongiforme bovina (*bovine spongiform encephalopathy*), conhecida no Brasil como doença da vaca louca, e casos de Febre Aftosa, a primeira uma doença neurodegenerativa e a segunda uma doença viral, muitos países passaram a exigir rastreabilidade e certificações de origem das carnes aqui produzidas. Assim, foi necessário por exemplo, a regulamentação do Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina (SISBOV), que trata-se de um sistema de identificação dos animais realizado através de uma parceria entre o Ministério da Agricultura, Pecuária e Abastecimento (MAPA), e a iniciativa privada, por meio de entidades certificadoras credenciadas (CÓCARO; JESUS, 2007).

A propriedade rural que almeja que seus animais sejam rastreados, devem se inscrever em uma entidade certificadora credenciada, que encaminhará técnicos para

fazer o cadastro da propriedade e dos animais. Após isso, a entidade envia os dados para a base nacional de dados, solicitando os códigos de identificação ao SISBOV, que os encaminhará, geralmente utilizado o padrão de brinco com um código de barras, dispositivo eletrônico, tatuagem ou marca de fogo. A identificação é aplicada nos animais e a entidade credenciadora recebe os dados de cada animal, como data de nascimento, de compra, de chegada na propriedade e da inserção da identificação no animal, e também características físicas, como sexo e aptidão e composição racial. A partir deste momento, a movimentação dos animais é acompanhada junto com um documento de identificação animal (CÓCARO; JESUS, 2007).

Na mesma corrente da rastreabilidade dos animais e garantias do que está sendo vendido, entra a relação ao bem estar do animal, como efeito de um melhor discernimento da sociedade a respeito de como os animais são criados, fazendo com isso que exista um novo nicho de mercado, no qual os clientes preferem pagar mais por produtos oriundos de animais criados de forma mais humanizada (BOTEGA *et al.*, 2008).

Existem, atualmente, várias formas de se rastrear os bovinos, mas todas elas se utilizam de artifícios em que o proprietário precisa inserir no animal formas de classificação, o que pode gerar dor ou desconforto, por exemplo: inserção de colar no pescoço, brinco ou tatuagem na orelha, inserção de identificadores de radio frequência subcutâneos, ou da pior forma, a marcação com ferro em brasa.

No entanto, desde 1921, já é de conhecimento acadêmico que o focinho de algumas espécies de animais, incluindo nesse grupo os bovinos, possuem padrões que são como um identificador único do animal, da mesma forma que os humanos possuem a impressão digital (HADAD *et al.*, 2015). Nesse caso, a classificação de animais por meio do focinho, torna-se uma boa solução de identificação, devido as características do focinho de um animal, ser distinto à outros da mesma espécie. Possui a vantagem de ser um método oposto aos métodos tradicionais, não causando incômodo ao animal.

Utilizando os conceitos e contextos explanados, a visão computacional e aproveitando a evolução tecnológica e os avanços na aprendizagem de máquinas, insere-se a proposta deste trabalho, o qual consiste em utilizar o avanço no aprendizado de máquinas para efetuar a classificação de bovinos através de imagens obtidas de seus focinhos.

Nesse sentido alguns trabalhos já vem sendo redigido pelos seguintes autores que exploraram esse assunto, sendo eles (HADAD *et al.*, 2015) e (AWAD *et al.*, 2013).

O trabalho descrito por (HADAD *et al.*, 2015), faz uma comparação de dois métodos para classificação, o primeiro método faz, inicialmente a extração das características utilizando o algoritmo SFTA e, em seguida, utiliza uma rede neural artificial ANN para classifica-las. A segunda opção utiliza o método EM para fazer a segmentação, para, logo em seguida, fazer a classificação dos dados através do algoritmo KNN.

Na pesquisa de descrita por (AWAD *et al.*, 2013), é utilizado o método SIFT de visão computacional para extrair características da imagens, em seguida, os parâmetros são estimados com o algoritmo RANSAC, e, após essas etapas, é verificado a classificação do animal.

1.2 JUSTIFICATIVA

Como vantagem da classificação dos bovinos utilizando visão computacional, tem-se o fato de tratar-se de um método não invasivo, que não necessira da inserção de objetos no animal. Esses objetos podem trazer algum tipo de desconforto ou dor, como no caso de colocação de brinco na orelha e marcação com ferro quente, entre outros.

Além disso, por questão de segurança alimentar e também do rebanho, a classificação pelo focinho do animal dificulta a ocorrência de fraude por pessoas de má conduta. O brinco, por exemplo, pode ser retirado e inserido em outro animal, assim como também pode ocorrer de o animal enroscar em algo e perder o identificador.

A classificação utilizando visão computacional pode ainda identificar o úbere de uma vaca, entre outros, até mesmo uma pessoa pelo rosto, abrindo possibilidades para ser utilizada em outros projetos. A Visão computacional pode ser utilizada ainda em auditorias, através de um simples smartphone câmera fotográfica.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Identificar bovinos por meio das características do focinho, utilizando as técnicas de classificação e de visão computacional.

1.3.2 Objetivos Específicos

- Criar de um banco de imagens do focinho de bovinos para serem utilizando no trabalho;
- Extrair das características das imagens processadas;
- Classificar das imagens processadas;
- Avaliar os resultados obtidos após o processamento e classificação;

1.4 ESTRUTURA

Inicialmente, o presente trabalho apresentará no capítulo 2, as definições teóricas essenciais para o seu desenvolvimento, tais como, o conceito de Visão Computacional, utilizada para conceituar a Matriz de Co-ocorrência (*GLCM*). Nesta seção, será tratado também sobre os Descritores de Haralick e, na sequência, os conceitos sobre Algoritmo Genético e as etapas do seu funcionamento. Posteriormente, discute-se sobre classificação, para, então, tratar do método (KNN) e sobre as formas de Validação como *K-fold*, *Leave-One-Out* e *Hold-out*. Por último, no capítulo 3, será exposta a avaliação dos resultados, como, por exemplo, taxas de erro e acerto, assim como também matriz de confusão.

Por fim, serão expostos os Resultados e a Avaliação, sendo discutido como foram feitas a Aquisição da Base de Dados, o Pré-processamento, e Extração de Características desses dados, para então, ser abordado a Classificação e Resultados, além de Seleção de Características, terminando nas Conclusões.

2 REFERENCIAL TEÓRICO

2.1 VISÃO COMPUTACIONAL

O ser humano utiliza os olhos para perceber o mundo a sua volta, enxergando objetos com a forma tridimensional. Pode, ainda, ver em um foto antiga de um grupo de pessoas e contar quantas são e perceber, por meio de suas expressões faciais, quais emoções que elas estavam sentindo naquele momento. Durante várias décadas, estudiosos procuraram compreender como o sistema de visão humano obtém essas informações e as processa (SZELISKI, 2010).

A partir disso, pesquisadores em visão computacional vem desenvolvendo técnicas matemáticas para conseguir obter essas formas tridimensionais e a aparência dos objetos por meio de imagens. Atualmente, essas técnicas vêm sendo aperfeiçoadas, chegando ao patamar de conseguir obter as características 3D dos objetos através de suas imagens. Porém, ainda não foi atingido o objetivo de projetar um computador capaz de interpretar as informações de uma imagem da mesma maneira que os humanos. (SZELISKI, 2010).

Logo, a área de estudo da Visão Computacional tem como objetivo a obtenção de imagens por um computador ou outro equipamento que tenha um dispositivo de imagem, e que, a partir das imagens, possibilite a extração das características necessárias para se efetuar o processamento pretendido, que por sua vez será utilizado para se tomar uma decisão mais acertada. Por exemplo, em um braço robótico em uma linha de montagem (SZELISKI, 2010).

Um sistema de visão computacional é dividido em várias etapas, como: aquisição da imagem, pré-processamento, extração de características, detecção de segmentação e processamento de alto nível (FACON, 2006).

O presente trabalho fará uso de algumas dessas áreas, sendo elas: aquisição da imagem, pré-processamento e extração de características. Esta última será apresentada a seguir e será abordado o método matriz de co-ocorrência.

2.2 MATRIZ DE CO-OCORRÊNCIA

A matriz de co-ocorrência, também conhecida como *Gray-Level Co-occurrence Matrix* (GLCM) (HARALICK *et al.*, 1973), é um método estatístico utilizado para a análise de textura em imagens. Essa técnica descreve a distribuição dos pixels com tons de cinza de uma imagem, assim como também retrata a relação espacial desses pixels

(AZEVEDO; CONCI, 2003).

A citada matriz é formada por G tons de cinza, e calculada pelo operador p da Equação 1, sendo que cada elemento representa dois pixels (i, j) em uma imagem, onde cada um possui um nível qualquer de cinza. Esses dois componentes podem estar à distância d um do outro, na direção θ ou também estarem separados Δx colunas e Δy linhas, denotada pela equação (AZEVEDO; CONCI, 2003).

$$p(i, j, d, \theta) = P(i, j) \Delta x, \Delta y \quad (1)$$

A Figura 1 nos dá uma visão melhor sobre o método.

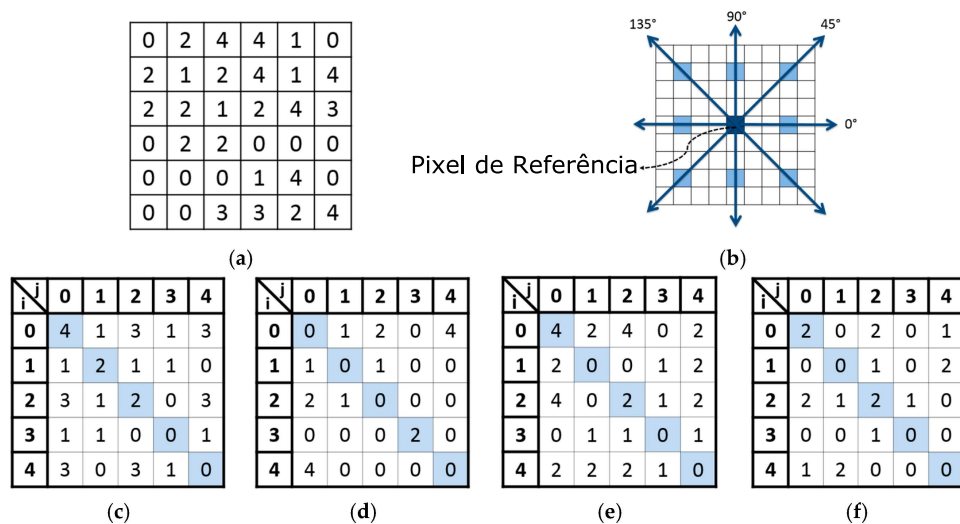


Figura 1 – Aplicação do GLCM em uma imagem em escala cinza.
Fonte: Adaptado de Youssef et al.(2017, p.714)

A matriz na Figura 1(a) é a imagem em escala de cinza que será empregada o método, tendo os pixels mais escuros valor 0 e os mais claros, valor 4. Esse vetor será percorrido e a cada iteração um pixel será utilizado como referência de comparação com seus vizinhos. No caso de (b), essa comparação é feita com os vizinhos das 4 direções, a uma distância $d = 3$ da referência.

Podemos verificar o resultado do método nas matrizes de (c) à (f), sendo que a matriz (c) é o resultado da comparação dos vizinhos na direção 0° , enquanto em (d) refere-se a 45° , (e) refere a 90° , e assim seguindo como está em (b).

Dependendo do autor ou da aplicação do método, a matriz de co-ocorrência pode ser simétrica, como na Figura 1(b), ou não. Pode ainda estar na forma de probabilidade, a qual é dividida pelo somatório de ocorrências(AZEVEDO; CONCI, 2003).

O GLCM, mesmo calculado para diferentes ângulos ou maneiras, não des-

creve a textura de uma imagem. Para isso, se faz necessário a utilização dos Descritores de Haralick (AZEVEDO; CONCI, 2003).

2.2.1 Descritores de Haralick

Os descritores de textura de Haralick são empregados na matriz de co-ocorrência para extração de valores numéricos, que possibilitam que se encontre padrões nas imagens da amostra, tornando possível, assim, quantificar-las conforme o aspecto que pretende-se determinar (AZEVEDO; CONCI, 2003). No trabalho de Haralick (HARALICK *et al.*, 1973), são sugeridos 14 descritores de textura, mas, para o presente trabalho, só serão apresentados 4 deles.

O primeiro descritor é a energia, conhecido também como segundo momento angular, esse descritor verifica a uniformidade de uma textura. Uma imagem com o mesmo tom de cinza, o valor resultante do descritor será igual a 1, caso não tenha uniformidade, o resultado será 0 (BARALDI; PARMIGGIANI, 1995).

$$\text{Energia} = \sum_i \sum_j p^2(i, j) \quad (2)$$

Em seguida, tem-se o contraste, que trata da mensuração da diferença entre a intensidade do pixel analisado e o do componente vizinho. Com esse descritor, um mesmo tom de cinza retornará um valor igual a 0 (AZEVEDO; CONCI, 2003).

$$\text{Contraste} = \sum_i \sum_j (i - j)^2 p(i, j) \quad (3)$$

Já a correlação mede o quão relacionado um pixel está com o seu vizinho (AZEVEDO; CONCI, 2003). Em outras palavras, avalia a dependência linear dos tons de cinza de uma imagem (BARALDI; PARMIGGIANI, 1995), sendo o intervalo de -1, para uma imagem descorrelacionada, e 1 se estiver totalmente correlacionada.

$$\text{Correlação} = \sum_i \sum_j \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (4)$$

Por fim, a homogeneidade descreve a proximidade da distribuição dos pixels em relação a diagonal da matriz do GLCM, ou seja, esse descritor tende a pegar pequenas variações nos tons de cinza, indicando assim, uma matriz de co-ocorrência diagonal, resultando em valores próximos a 1.

$$\text{Homogeneidade} = \sum_i \sum_j \frac{p(i, j)}{1 + |i - j|} \quad (5)$$

2.3 ALGORITMOS GENÉTICOS

Algoritmos Genéticos (AGs) é um tipo de método computacional que teve o desenvolvimento influenciado em como os seres vivos sobrevivem e como sua genética passa de geração em geração, seguindo assim, os princípios de seleção natural e evolução propostos por Charles Darwin. Esse método deve ser empregado em problemas que necessitem buscar ou localizar uma solução aproximada de um problema (IKEDA, 2009).

Quando disse-se que os Algoritmos Genéticos (HOLLAND, 1992), fazem parte do grupo dos algoritmos evolutivos, inclui-os naqueles empregados na resolução de problemas computacionais que baseam-se em Genética, que descreve que os filhos herdam características dos pais, e na Teoria da Evolução, que explica que organismos mais aptos tem maior probabilidade de reproduzir suas característica em uma nova geração e, assim, perpetuar-se (FACELI *et al.*, 2011).

Os AGs são uma metaheurística, ou seja, trata-se de um método que busca uma solução para um problema e em que, a cada iteração, são realizados procedimentos para a melhoria local, além de formas para escapar-se de resultados que atinjam ótimos locais (GENDREAU; POTVIN, 2010).

O emprego desses conceitos nos AGs segue os seguintes passos: inicialmente, é criada uma população de indivíduos (cromossomos) que possam ser possíveis solução do problema. Por meio dos melhores indivíduos da população atual, busca-se, através da evolução desses cromossomos, encontrar uma solução adequada, através da avaliação da função de aptidão (*fitness*), que determina a qualidade de cada solução. A partir das possíveis soluções definidas, é possível conceber uma nova população através de três operadores genéticos: seleção (elitismo), cruzamento (*crossover*) e mutação (FACELI *et al.*, 2011).

Assim, a busca por uma boa solução é executado por várias gerações, até atingir o critério de parada. Ou seja, a cada geração são selecionados os indivíduos mais apropriados e, na sequência, os operadores de reprodução produzem uma população de novos indivíduos. Para cada individuo, faz-se uso de uma função de aptidão, onde o individuo será avaliado quanto a sua importância perante ao problema em

questão. No Algoritmo 1, temos o funcionamento básico dos AGs (FACELI *et al.*, 2011).

Algoritmo 1: Algoritmo Genético

Entrada: Uma função objetivo capaz de avaliar cada solução

Saída: Um conjunto de soluções otimizadas

início

repita

para Cada indivíduo da população **faça**

 Avaliar sua aptidão para resolver o problema

fim

 Selecionar indivíduos que participarão da próxima geração

 Aplicar operadores genéticos aos indivíduos selecionados

até Critério de parada for satisfeito;

fim

2.3.1 Representação Genética

A representação de um indivíduo em um problema esta sempre vinculada a um cromossomo (p), que encontra-se na forma vetorial, contendo m genes x_m , os quais representam uma variável da solução.

$$p = (x_1, x_2, \dots, x_m) \quad (6)$$

A representação do cromossomo depende de qual for mais adequada ao problema. A mais usual é a binária, mas também é possível o uso de valores inteiros ou reais. No caso da representação binária, o valor 1 representa a presença de uma característica, e, por consequência, o 0 indica a falta dessa característica (SOUZA, 2008).

População		População	
Individuo 1	011010110101	Individuo 1	17.1 7.9
Individuo 2	010100110101	Individuo 2	21.3 8.1
•	•	•	•
•	•	•	•
•	•	•	•
Individuo N	001000111011	Individuo N	15.7 6.8

a)

b)

Figura 2 – Representação genética: (a) Binária, (b) Decimal
 Fonte: Autor Desconhecido.

2.3.2 Função de Avaliação

A função de avaliação ou aptidão (*Fitness*) faz uso dos genes do indivíduo para calcular um valor numérico e, através desse valor, é possível mensurar se os parâmetros do cromossomo correspondem ao que se espera de uma provável solução. Esta função, dependendo do caso, torna-se o único elo entre o programa e o problema real, por isso é importante que o *fitness* seja bem definido para que retrate as metas a serem atingidas (LINDEN, 2005).

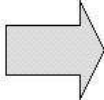
2.3.3 Métodos de Seleção

No processo de seleção, os indivíduos da população atual mais aptos definidos na função de avaliação, são, de forma probabilística, selecionados por seu valor de aptidão por um método de seleção. Assim, vão ficando, a cada geração, apenas os melhores indivíduos. Existem vários métodos de seleção, os mais conhecidos são o da roleta e o do torneio (FACELI *et al.*, 2011).

Na seleção por torneio, são selecionados n indivíduos da população, onde k desses cromossomos são aleatoriamente eleitos para disputarem entre si, sendo que a cada torneio um desses indivíduos é selecionado para fase de reprodução, havendo a possibilidade de um elemento participar e até mesmo ganhar mais de uma vez (LINDEN, 2005).

A disputa entre os elementos é definida pelo tamanho do torneio (k), que define quantos indivíduos serão aleatoriamente escolhidos, sendo ($k \geq 2$). Caso contrário, não ocorre torneio. Desses k elementos, aquele que possuir melhor aptidão passa para fase de reprodução, como está exemplificado na Figura 3 (LINDEN, 2005).

Indivíduo	Fitness
x_1	200
x_2	100
x_3	9500
x_4	100
x_5	100
x_6	10000
x_7	1
x_8	40



Torneios		
x_1	x_7	x_8
x_2	x_3	x_5
x_6	x_4	x_4
x_2	x_7	x_1
x_5	x_5	x_5
x_3	x_4	x_2
x_4	x_2	x_6
x_4	x_6	x_5

Figura 3 – Seleção por torneio.
Fonte: Linden(2012, p.205)

Na Figura 3, temos 8 indivíduos e suas aptidões e, ao lado, a tabela com o resultados dos torneios realizados sequencialmente, iniciando-se do topo. Por exemplo, na primeira disputa foram selecionados os elementos cromossomos x_1 , x_7 e x_8 ,

sendo o indivíduo x_1 escolhido por possuir maior aptidão que os outros dois. Assim, o processo segue até definir os 8 indivíduos.

2.3.4 Operadores Genéticos

2.3.4.1 Operadores de Cruzamento

O chamado operador de cruzamento (*Crossover*) tem a finalidade de efetuar de maneira probabilística a troca genética de partes dos genes de dois indivíduos, assemelhando-se, assim, a reprodução sexuada, porém, no caso do *Crossover*, a troca genética entre os pais da origem a dois "filhos", onde cada um partilha das qualidades genéticas de seus genitores (LINDEN, 2005).

O operador de cruzamento de um ponto é o mais simples entre os operadores. Nesse método, é estabelecido um ponto de corte, que dividirá cada um dos pais em duas partes. O fragmento de cada um desses pais dará origem a um novo indivíduo, que terá as características dos dois, como demonstrado na Figura 4, assim permitindo que cada um dos filhos possam passar essas características para uma nova geração, e assim por diante (FACELI *et al.*, 2011).

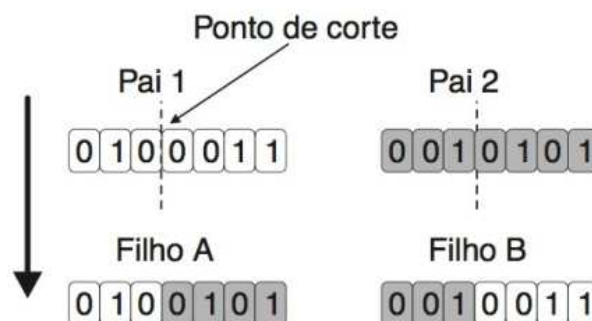


Figura 4 – Exemplo da ação do operador de cruzamento.
Fonte: Faceli et al.(2011, p.312)

2.3.4.2 Operador de Mutação

Já o operador de mutação, garante a variabilidade genética da população, alterando de forma arbitrária um ou mais genes de um indivíduo. Essa alteração permite a busca de uma solução em um universo de possibilidades, como demonstrado na Figura 5. Os cromossomos gerados na fase de cruzamento são utilizados pelo operador de mutação, que, maneira probabilística, determinará se irá alterar os genes de um indivíduo por meio da taxa de mutação (FACELI *et al.*, 2011).



Figura 5 – Atuação do operador de mutação.
Fonte: Faceli et al.(2011, p.312)

2.4 CLASSIFICAÇÃO

2.4.1 KNN

O método K-vizinhos mais próximos (*K-Nearest Neighbor* - (KNN)), é um classificador supervisionado, simples e de fácil implementação, que possui ainda a vantagem de obter bons resultados dependendo da utilização.

Esse método utiliza uma base de dados conhecida, pela qual é possível rotular os novos objetos. O aprendizado ocorre quando é feita a categorização de um novo dado, por isso, é conhecido como sendo um classificador de aprendizagem preguiçosa (*Lazy Learn*) (CAMILO; SILVA, 2009).

O método em questão possui o nome de K-vizinhos mais próximo, por se definir como um número inteiro de K elementos que pode ser utilizado para fazer a comparação entre um objeto desconhecido e os outros dados já categorizados. Se um determinado objeto não conhecido estiver próximo de um grupo X que possua um maior número de elementos que o agrupamento Y , por consequência, esse objeto será denominado como sendo do grupo X (CAMILO; SILVA, 2009).

Sendo assim, um dado desconhecido é categorizado por uma base de dados já classificada, verificando a distância entre os pontos do grupo e o dado. Para efetuar essa métrica, existem várias formas, porém a mais simples utilizada no KNN é a distância Euclidiana, que permite aferir a distância de um ponto em qualquer espaço n-dimensional (FERRERO, 2009). Nesse espaço, a distância entre dois pontos $p = (p_1, p_2, \dots, p_n)$ e $q = (q_1, q_2, \dots, q_n)$, é definida pela Equação 7. Já na Figura 6, temos um exemplo da distância euclidiana em um espaço bidimensional.

$$d(q, p) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2} \quad (7)$$




Figura 6 – Distância Euclidiana no espaço bidimensional
 Fonte: Autoria própria

Na Figura 7, tem-se uma instância desconhecida, representada pela estrela, que é comparada com as classes 1 e 2. O número de vizinhos escolhidos para essa classificação é igual a $K=5$. Portanto, a classe desconhecida é comparada com k elementos próximos. Para esse exemplo, a instância seria classificada como sendo da classe 2.

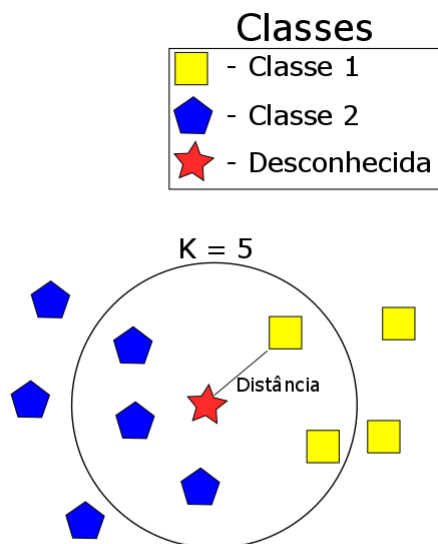


Figura 7 – Exemplo de classificação de uma instância desconhecida
 Fonte: Autoria Própria

2.4.2 Validação Cruzada

A Validação Cruzada é uma técnica estatística utilizada para validar um modelo de um conjunto de dados, dividindo um universo de dados aleatoriamente em dois conjuntos, sendo um para teste e o outro para treinamento. O conjunto de treinamento é subdividido em outros dois grupos, um usado para a escolha de um modelo

e o outro usado para validação, sendo usado para teste ou confirmação do modelo (HAYKIN, 2001).

Essa divisão tem como objetivo verificar um novo paradigma, utilizando um agrupamento de dados que seja diferente daquele do que foi usado para estimar os parâmetros. Assim, pode-se utilizar uma base de treinamento para a escolha entre vários candidatos para um novo paradigma. Entretanto, essa escolha dos melhores dados pode resultar em um efeito contrário, ajustando exageradamente o conjunto de validação. Para ter uma boa generalização, o novo paradigma selecionado é medido em um conjunto de teste que é diferente do subconjunto de validação (HAYKIN, 2001).

2.4.2.1 K-fold

K-fold é uma técnica de validação cruzada que é utilizada quando há um baixo número de dados classificados. Para essa situação, é possível a utilização da validação cruzada múltipla, que divide um conjunto de objetos de N exemplos em K subconjuntos, onde $K > 1$, supondo-se que K seja divisível por N . Nesse método de validação, o novo paradigma é treinado com todos os subconjuntos, com exceção de um, que é utilizado para verificar o erro de validação. Este método é usado para um total de K tentativas e a cada iteração um subconjunto diferente é usado para fazer a validação do modelo (HAYKIN, 2001).

A medida de desempenho desse método é qualificar a média do erro quadrado que é encontrado na validação de todas as tentativas do experimento. Esse procedimento possui a desvantagem de requerer uma quantidade excessiva de cálculos, devido à necessidade do modelo ser treinado K vezes, onde $1 < K \leq N$ (HAYKIN, 2001).

2.4.2.2 Leave-One-Out

O método deixe um de fora (*Leave-one-out* - LOO), é um procedimento *K-fold*, utilizado para a situação em que o número de grupos rotulados já disponível é severamente limitado. Esta técnica faz uso de $N-1$ exemplos, utilizados para treinar o modelo, e o objeto é validado com aquele elemento que foi deixado de fora. Esse experimento é repetido para as N vezes, e a cada iteração, um objeto é deixado de fora para a fazer a validação, assim como ilustrado na Figura 8. Assim como *K-fold*, o LOO faz uso da média do erro quadrático sobre as N tentativas, ao contrário das K tentativas do processo anterior (HAYKIN, 2001).




Figura 8 – Iterações do Leave One Out
 Fonte: Chlis(2013, p.27)

2.4.2.3 Hold-Out

No método *hold-out*, o agrupamento de dados é dividido em dois, um para conjunto de treinamento e outro para teste. Geralmente o particionamento dos dois grupos é feito na seguinte proporção: a base de treinamento usa um terço dos dados, e a de teste, o restante. Devido ao esse particionamento, pode ocorrer de a taxa de acerto ser subestimada, caso a base de dados for pequena, pois uma validação feita sobre todos os objetos de um conjunto terá maior taxa de acerto, ao contrário daquele foi pego só de uma parte da base de dados (FACELI *et al.*, 2011).

2.4.3 Avaliação de Resultados

2.4.3.1 Taxa de Erro

Taxa de Erro é um método para avaliar o desempenho de um classificador, onde sua taxa de erro é dada por f , definida na Equação 8, a qual $I(a)$ retorna 0 se não ocorrer erro, y_i seja diferente de $f(x_i)$. Caso contrário, o valor será 1. Nesse método, a avaliação de desempenho do agrupamento de dados é calculada efetuando a soma dos resultados encontrados dos erros dos objetos e dividindo pelo número total dos elementos, ou seja, trata-se de uma média ponderada. O resultado da taxa de erro será entre 0 e 1, sendo melhor quanto mais próximo de zero o valor (FACELI *et al.*, 2011).

$$erro(f) = \frac{1}{n} \sum_{i=1}^n I(y_i \neq f(x_i)) \quad (8)$$

A taxa de acerto é o oposto, mas pode ser utilizada como sendo um acréscimo

do método de medida anterior, e nesse caso os melhores indicadores estarão próximo a 1 (FACELI *et al.*, 2011), sendo assim:

$$acerto(f) = 1 - erro(f) \quad (9)$$

2.4.4 Matriz de Confusão

A chamada Matriz de Confusão é uma forma de avaliação de desempenho classificador mais completa que as taxas anteriores (erro e acerto), pois ela dá um prognóstico sobre os números certos ou erros de cada classe. Essa matriz mostra a informação das classes onde o classificador possui mais dificuldade (FACELI *et al.*, 2011).

A matriz de confusão atua da seguinte maneira: as linhas são as classes verdadeiras e as colunas as classe previstas pelo classificador. Assim, cada elemento m_{ij} representa o valor da classe i , sendo classificados classe j . A diagonal principal da matriz representa o número de acerto do classificador, enquanto os elementos restantes representam o erro. Assim, se existem K classes, a matriz irá ser configurada na forma de $K \times K$ (FACELI *et al.*, 2011).

Na Figura 9, a matriz de confusão mostra o parecer referente a 3 classes. Para a classe 1, foram classificados 15 elementos, dos quais 11 foram identificados de forma correta. Já os outros 4 elementos foram rotulados como sendo de outra classe, sendo 1 elemento classificado como pertencente a classe 2 e os outros 3 indivíduos, como sendo da classe 3.

		Classe predita		
		1	2	3
Classe verdadeira	1	11	1	3
	2	1	4	0
	3	2	1	6

Figura 9 – Matriz de confusão
Fonte: Faceli(2011, p.162)

3 RESULTADOS E AVALIAÇÃO

Para verificar a possibilidade de identificação via imagens do focinho de bovinos, primeiramente, foi montada uma base de imagens, de modo a criar o conhecimento necessário ao treinamento dos métodos inteligentes.

Em seguida, descreve-se a metodologia de coleta das imagens dos focinhos, e, nas próximas seções, são apresentados os métodos empregados nessas imagens de modo a obter as características dos animais. Por último, são apresentados os resultados pós-treinamento do método de classificação.

3.1 AQUISIÇÃO DA BASE DE DADOS

A realização desse trabalho foi efetivada montando-se uma base de dados com imagens de focinhos bovinos, obtendo-se várias classes e amostras, considerando que um número considerável de amostras favorece o refinamento das características que definem as classes, que, por sua vez, têm o propósito de verificar se os métodos utilizados na classificação possuem bom desempenho para distinguir diferentes classes.

A base de dados foi constituída utilizando oito animais, sendo dez imagens de cada um, as quais encontram-se demonstrado na Tabela 1.

Tabela 1 – Bovinos e número de fotos por bovinos

Classes	Imagens por Classe
1	10
2	10
3	10
4	10
5	10
6	10
7	10
8	10

A aquisição das imagens foi feita conforme a Figura 10, de maneira a evidenciar os sulcos do focinho de cada bovino. Portanto, foi necessário que as imagens fossem feitas próximas ao focinho dos animais. Além disso, essa etapa exigiu cuidados para que, no local do retrato, não houvesse falta ou excesso de claridade.



Figura 10 – Imagem adquirida do focinho de um bovino
Fonte: Autoria própria.

As primeiras seções para obtenção das fotos foram feitas em uma propriedade rural que possui gado leiteiro criado em regime de confinamento, em um grande galpão coberto, mas com as laterais abertas. Essa escolha deu-se, primeiramente, por permitir uma maior proximidade dos animais e, também, por não haver iluminação excessiva se comparado a um local aberto.

As primeiras fotos foram feitas a partir de um celular com câmera de 5 megapixels, porém os resultados não foram satisfatórios, pois as imagens não possuíam nitidez, como podemos ver na Figura 11.

, não evidenciando as características dos focinhos dos animais.

Nessa ocasião, ocorreram, também, outros problemas. O fato do local ser coberto, porém externamente ser mais iluminado, atrapalhou na obtenção das imagens, pois, dependendo da posição, a claridade externa interferia na qualidade. Já na ausência de iluminação adequada, os sulcos dos focinhos dos bovinhos não apareciam claramente e ocorria a reflexão da luz do ambiente externo ao galpão. Outros fatores que influenciaram foram o fato do focinho estar com sujeira, suor ou coriza, além da inquietude dos animais com uma pessoa desconhecida.



Figura 11 – Exemplo da qualidade da imagem obtida com o celular
Fonte: Autoria própria

Em um segundo momento, uma nova seção de fotos foi realizada no mesmo local, porém, desta vez, foi utilizada uma câmera digital Canon PowerShot SX50 HS, que possui um foco que permite uma aproximação de 50 vezes do objeto de interesse. Os resultados foram melhores, como mostra a Figura 10, mas ainda tanto a iluminação quanto o movimento dos animais não possibilitaram obter imagens com a qualidade necessária.

Finalmente, as imagens utilizadas neste trabalho foram obtidas em um local aberto, de modo a diminuir a inquietude dos animais. A maior parte das fotos foram feitas numa distância de até dois metros, utilizando o recurso de aproximação da câmera. Outra parte das imagens foi feita em um cercado utilizado na vacinação e tratamento dos animais, também fazendo-se o uso da aproximação com o foco da câmera.

Formada à base de dados, passou-se para a próxima etapa do trabalho, o pré-processamento das imagens que seriam utilizadas.

3.2 PRÉ-PROCESSAMENTO

O pré-processamento das imagens foi realizado em duas etapas. Primeiramente, as imagens foram recortadas de modo a separar somente a parte central do focinho, local dos sulcos característicos. O resultado do pré-processamento pode ser visto na Figura 12.



Figura 12 – Imagem do focinho recortada
Fonte: Autoria própria.

Após todas as imagens serem recortadas, converteu-se as imagens de coloridas para imagens em escala de tons de cinza, como pode ser visto na Figura 13.




Figura 13 – Imagem resultante final
Fonte: Autoria própria.

Esse processo foi efetuado logo após o carregamento da imagem no ambiente de desenvolvimento e pouco antes de ser passada para o método de extração de características, que será descrito na sequência.

3.3 EXTRAÇÃO DE CARACTERÍSTICAS

Pré-processadas as imagens, aplicou-se o método de GLCM em cada uma delas, fazendo uso dos seguintes parâmetros:

- **Tons de cinza:** 8 tons de cinza, os quais, são resultantes da aglutinação dos 255 tons de cinza.
- **Simetria:** Comparação entre tons de forma simétrica.

- **Ajuste de Distância:** GLCM ajustado para comparar inicialmente, os vizinhos localizados a 1 unidade de distância do pixel de referência.

Aplicando o GLCM à Figura 13, teve-se como resultado as seguintes matrizes de co-ocorrência, sendo cada uma referente a um ângulo diferente:

Tabela 2 – Resultado do GLCM calculado para o ângulo de 0°

Tons de Cinza	1	2	3	4	5	6	7	8
1	0	0	0	0	0	0	0	0
2	0	56416	16603	0	0	0	0	0
3	0	16603	2360252	133103	4	0	0	0
4	0	0	133103	2864694	77241	20	0	0
5	0	0	4	77241	1117470	42222	5	0
6	0	0	0	20	42222	1058150	36254	0
7	0	0	0	0	5	36254	285084	2580
8	0	0	0	0	0	0	2580	16984

Tabela 3 – Resultado do GLCM calculado para o ângulo de 45°

Tons de Cinza	1	2	3	4	5	6	7	8
1	0	0	0	0	0	0	0	0
2	0	50942	22077	0	0	0	0	0
3	0	22077	2303404	183868	88	0	0	0
4	0	0	183868	2776020	113509	258	2	0
5	0	0	88	113509	1054868	67684	316	2
6	0	0	0	258	67684	1011132	56685	70
7	0	0	0	2	316	56685	261650	4713
8	0	0	0	0	2	70	4713	14728

Tabela 4 – Resultado do GLCM calculado para o ângulo de 90°

Tons de Cinza	1	2	3	4	5	6	7	8
1	0	0	0	0	0	0	0	0
2	0	55392	17632	0	0	0	0	0
3	0	17632	2344104	148908	35	0	0	0
4	0	0	148908	2836060	90389	107	0	0
5	0	0	35	90389	1093000	53568	121	0
6	0	0	0	107	53568	1036472	45979	17
7	0	0	0	0	121	45979	273758	3842
8	0	0	0	0	0	17	3842	15682

Tabela 5 – Resultado do GLCM calculado para o ângulo de 135°

Tons de Cinza	1	2	3	4	5	6	7	8
1	0	0	0	0	0	0	0	0
2	0	51220	21798	1	0	0	0	0
3	0	21798	2305344	182236	59	0	0	0
4	0	1	182236	2784032	107248	140	0	0
5	0	0	59	107248	1066860	62181	120	0
6	0	0	0	140	62181	1020254	53230	24
7	0	0	0	0	120	53230	266024	3991
8	0	0	0	0	0	24	3991	15498

Então, com as matrizes de co-ocorrência, as mesmas foram normalizadas, e, na sequência, seguiram sendo calculados os descritores de Haralick: Contraste, Correlação, Energia e Homogeneidade. Assim, o resultado foi um número de 16 características:

Por fim, o resultado dos descritores da Figura 13, podem ser conferidos na Tabela 6.

Tabela 6 – Resultados dos descritores de Haralick

Ângulos	0°	45°	90°	135°
Contraste	0,0736	0,1079	0,0863	0,1032
Correlação	0,9729	0,9603	0,9682	0,9620
Energia	0,2322	0,2187	0,2275	0,2201
Homogeneidade	0,9632	0,9463	0,9569	0,9485

3.4 CLASSIFICAÇÃO E RESULTADOS PRELIMINARES

Com os vetores de características obtidos conforme demonstrados na seção anterior, já é possível a aplicação do método de classificação (KNN). No entanto, para realizar o processo de classificação, foi necessário determinar um valor de K -vizinhos apropriado, de modo a efetuar a comparação entre as classes conhecidas e a que deseja-se categorizar.

A forma para determinar o melhor K foi realizada empiricamente, iniciando-se com o valor igual a 1, até encontrar o melhor valor. Efetuando os testes, determinou-se que o melhor parâmetro a ser utilizado para classificar é fazendo uso do $K = 5$, valores acima desse, iniciou-se um decréscimo nos resultados.

Determinado o valor de K antes de iniciar a classificação, foi necessário incorporar o método de validação cruzada, para legitimar o conjunto de dados. Devido as circunstâncias de ter um número limitado de classes, o procedimento utilizado foi o LOO, portanto a cada iteração, uma das 80 amostras é utilizada para teste, as outras são utilizadas para o treino do classificador.

Os resultados obtidos da classificação encontram-se na Tabela 7. Na sequência, situa-se o resultado da taxa de acerto.

Tabela 7 – Matriz de confusão da classificação

Classes	1	2	3	4	5	6	7	8
1	3	5	0	0	0	2	0	0
2	5	4	0	0	0	0	0	1
3	0	0	10	0	0	0	0	0
4	0	0	0	10	0	0	0	0
5	0	0	0	0	9	0	1	0
6	2	1	0	0	0	6	0	1
7	1	0	1	0	0	0	7	1
8	0	0	2	0	0	0	0	8

$$\text{Taxa de Acerto} = 71,25\%$$

Observando-se que a taxa de acerto obtida foi insatisfatória, possivelmente devido a uma má configuração dos parâmetros, optou-se por aplicar um método de escolha dos parâmetros de distância do GLCM baseado no AGs. Tal método é apresentado na seção seguinte.

3.5 SELEÇÃO DE CARACTERÍSTICAS

O método GLCM possui, como já exposto, diversos parâmetros. Todavia, não é possível saber de antemão qual é a combinação adequada desses parâmetros de modo a obter os melhores resultados. Portanto, o objetivo do algoritmo genético nessa aplicação foi selecionar o melhor parâmetro de distância de comparação entre os pixels do método GLCM.

A escolha para a alteração somente do parâmetro de distância GLCM deu-se, primeiramente, devido ao fato de que algumas pequenas alterações, empiricamente,

ocasionaram uma mudança significativa no resultado, enquanto, com os outros parâmetros, não ocorreu o mesmo. Outro motivo a influenciar foi as características do focinho de cada animal, pois, além dos desenhos dos sulcos que diferem, os animais também podem ter como diferencial, a coloração e pintas diversas

Para tal, empregou-se um AGs com seleção por torneio com o limite de execução fixado em 50 épocas e critério de parada ajustado para 10 gerações, caso haja uma estagnação nos valores encontrados. A população inicial foi configurada para [1, 1, 1, 1, 1, 1]. A cada nova geração, cinco novos indivíduos foram gerados, sendo que 0,8 deles originaram-se do processo de crossover. O fluxo de execução do classificador segue os passos do fluxograma da Figura 14.

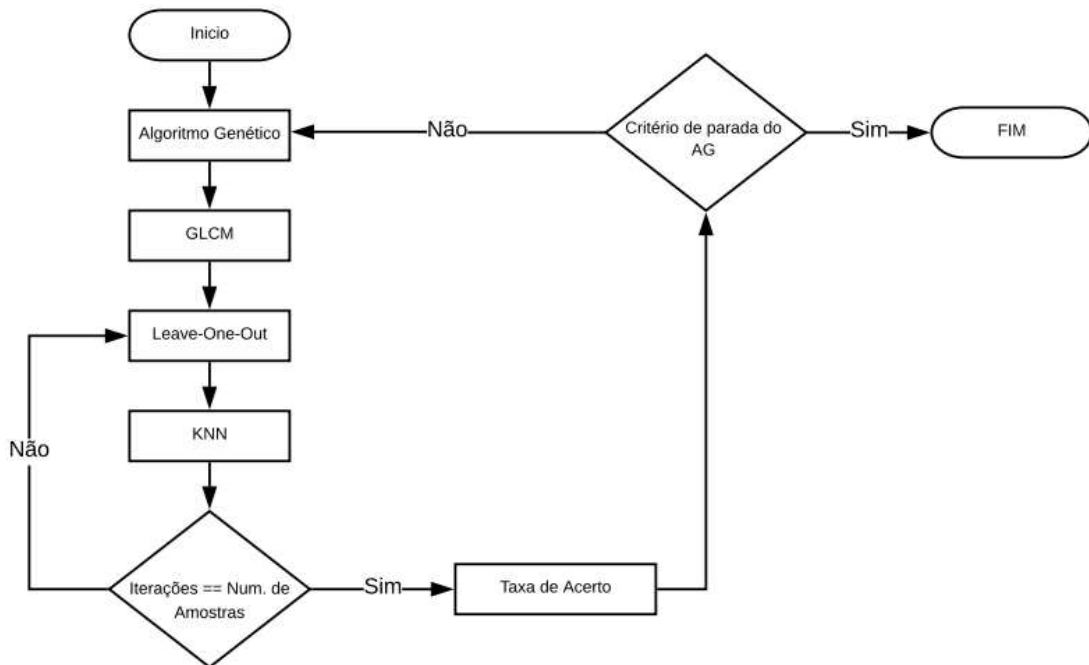


Figura 14 – Fluxograma do classificador

O algoritmo foi executado durante 10 épocas, sendo interrompido devido ao critério de parada, por não ocorrer uma melhora nos valores encontrados. Para esse caso, a função de avaliação usada foi a taxa de erro, oriunda do classificador. Os resultados são apresentados na Tabela 9, cujo parâmetro para distância encontra-se na Tabela 8.

Tabela 8 – Parâmetros de distância final

Ângulo	Distância (y,x)	
0	0	41
45	35	45
90	-15	0
135	18	6

Tabela 9 – Matriz de Confusão Final

Classe	1	2	3	4	5	6	7	8
1	10	0	0	0	0	0	0	0
2	0	9	1	0	0	0	0	0
3	0	0	10	0	0	0	0	0
4	0	0	0	10	0	0	0	0
5	0	0	0	0	10	0	0	0
6	0	0	0	0	0	10	0	0
7	0	0	0	0	0	0	8	2
8	0	0	0	0	0	0	0	10

$$\text{Taxa de acerto} = 96,75\% \quad (10)$$

O processo de classificação sem o emprego do algoritmo genético mostrou-se bom, porém não tanto quanto o esperado. Assim, tentou-se, de forma empírica, ajustar o parâmetro do GLCM. Porém, nesse caso, também não foi possível atingir um resultado próximo do que o AG.

Assim, comparando os resultados antes e depois do emprego do método Algoritmo Genético, houve uma melhoria significativa no resultado, pois de forma empírica a taxa de acerto era de 71,25%, enquanto com o AGs a taxa passou para 96,75% ou passado para taxa de erro 3,25%.

O fato da base de dados ser reduzida não interferiu na obtenção de um bom resultado. Um dos motivos, possivelmente, foi o fato que cada uma das 8 classes utilizadas possui particularidades que a diferenciavam das outras, a cor do focinho, pintas e disposição dos sulcos. No caso dos bovinos 4 e 6, por possuírem cor do focinho quase iguais, além de disposição semelhante dos sulcos da parte superior

do focinho, poderia ocorrer uma interferência no resultado, mas como pode-se ver na Tabela 9, isso não ocorreu.

Por outro lado, as duas classes 2 e 7, não obtiveram um resultado de 100% de acerto. Nas Figuras 15 e 16, temos os focinhos dispostos lado-a-lado, para comparação.



Figura 15 – Da esquerda para direita: os focinhos das classes 2 e 3



Figura 16 – Da esquerda para direita: os focinhos das classes 7 e 8

Observando a Figura 15, podemos notar que nenhum dos focinhos se assemelham. Ainda para diferenciar, a classe 2 possui uma parte do focinho albino. Assim, como a imagem anterior, se olharmos a Figura 16, como um todo, contando as pintas, vemos que as duas não possuem semelhanças. A única exceção seria se olharmos do centro da imagem para baixo, onde os sulco aparentam se assemelhar.

4 CONCLUSÕES

Em um primeiro momento, o proposto nesse trabalho aparentava simplicidade de aplicação, resumindo-se em coletar as imagens e inseri-las nos métodos que resultariam na classificação final de cada animal. Porém, durante o desenvolvimento, mostrou-se mais difícil, como relatado na seção 3.1. Mesmo com uma câmera adequada e de qualidade, foi necessário a obtenção de várias imagens, de modo a garantir um mínimo de 10 imagens de qualidade por classe.

O desenvolvimento do classificador, por outro lado, não apresentou tantos problemas como a obtenção da base de dados. Nesse caso, as dificuldades encontradas foram os ajustes dos parâmetros e a inserção do algoritmo genético, configurações que, ao final, colaboraram para o resultado desse trabalho.

Assim, podemos concluir que o sistema encontra-se preparado para exercer o proposto, porém, por cautela, seria interessante avaliar-lo com um número maior de classes, preferencialmente com características semelhantes, por exemplo, um focinho com sulcos de linhas horizontais, conforme a Figura 10, mas com desenhos distintos, como o caso das Figuras 15 e 16, além de averiguar o comportamento do GLCM com um número superior de classes.

Já, no emprego efetivo desse trabalho em um sistema de identificação real, há a possibilidade que o sistema apresente os empecilhos citados no trabalho, dependendo de como será utilizado. Se tratar-se de um processo automatizado, seria necessário um estudo mais abrangente antes de colocar-se em prática, pois, como será relatado na sequência, alguns pontos terão que ser levados em consideração.

O primeiro ponto é a escolha de um local estratégico para a obtenção das imagens, preferivelmente um local onde os animais fiquem parados, como, por exemplo, na ordenha da vaca, no cocho de alimentação, antes de alimenta-los, ou em passarelas onde os animais tenham passagem controlada.

O local também deve possuir uma iluminação controlada, para que tanto a falta ou excesso dela não atrapalhe o processo. Ainda, devemos levar em consideração que as condições climáticas podem atrapalhar, pois, no inverno, os animais apresentam coriza, enquanto, no verão, o problema é o suor.

A sujeira no focinho é outro ponto importante que deve ser levado em consideração. Dependendo do local de obtenção das imagens ou onde os animais se encontravam anteriormente, pode ser que os focinhos encontrem-se com resquícios de alimento ou, então, sujeira. Uma possível solução seria criar um dispositivos que

limpe o nariz dos animais.

Por fim, é necessário a escolha de um bom dispositivo de imagem, pois o mesmo deve ter definição suficiente para a captura dos detalhes do focinho do animal, de modo a pegar todas as características, um fator decisivo para o processo de classificação.

REFERÊNCIAS

- AWAD, Ali Ismail; ZAWBAA, Hossam M; MAHMOUD, Hamdi A; NABI, Eman Hany Hassan Abdel; FAYED, Rabie Hassan; HASSANIEN, Aboul Ella. A robust cattle identification scheme using muzzle print images. In: IEEE. **Computer Science and Information Systems (FedCSIS), 2013 Federated Conference on**. [S.l.], 2013. p. 529–534.
- AZEVEDO, Eduardo; CONCI, Aura. **Computação gráfica: teoria e prática**. [S.l.]: Elsevier, 2003.
- BARALDI, Andrea; PARMIGGIANI, Flavio. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 2, p. 293–304, 1995.
- BOTEGA, Juliana Vilela Lourençoni; JÚNIOR, Roberto Alves Braga; LOPES, Marcos Aurélio; RABELO, Giovanni Francisco. Diagnóstico da automação na produção leiteira. **Ciência e Agrotecnologia**, Editora da Universidade Federal de Lavras, v. 32, n. 2, p. 635–639, 2008.
- CAMILO, Cássio Oliveira; SILVA, João Carlos da. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. **Universidade Federal de Goiás (UFG)**, p. 1–29, 2009.
- CÓCARO, Henri; JESUS, José Carlos dos Santos. Impactos da implantação da rastreabilidade bovina em empresas rurais informatizadas: estudos de caso. **JISTEM: Journal of Information Systems and Technology Management**, Universidade de São Paulo, v. 4, n. 3, 2007.
- CONFEDERAÇÃO NACIONAL AGRÍCOLA E PECUÁRIA DO BRASIL. **PIB e performance do agronegócio**. 2017. Disponível em: <http://www.cnabrazil.org.br/sites/default/files/sites/default/files/uploads/02_pib.pdf>. Acesso em: 21 ago. 2017.
- FACELI, Katti; LORENA, Ana Carolina; GAMA, João; CARVALHO, ACPLF. Inteligência artificial: Uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC**, v. 2, p. 192, 2011.
- FACON, Jacques. Técnicas de processamento digital de imagens aplicadas à área da saúde. xiii escola regional de informática da sbc-paraná. 2006.
- FERRERO, Carlos Andres. **Algoritmo kNN para previsão de dados temporais: funções de previsão e critérios de seleção de vizinhos próximos aplicados a variáveis ambientais em limnologia**. Tese (Doutorado) — Universidade de São Paulo, 2009.
- GENDREAU, Michel; POTVIN, Jean-Yves. **Handbook of metaheuristics**. [S.l.]: Springer, 2010.

HADAD, Hagar M El; MAHMOUD, Hamdi A; MOUSA, Farid Ali. Bovines muzzle classification based on machine learning techniques. **Procedia Computer Science**, Elsevier, v. 65, p. 864–871, 2015.

HARALICK, Robert M; SHANMUGAM, Karthikeyan *et al.* Textural features for image classification. **IEEE Transactions on systems, man, and cybernetics**, IEEE, n. 6, p. 610–621, 1973.

HAYKIN, Simon. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001.

HOLLAND, John Henry. **Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence**. [S.l.]: MIT press, 1992.

IKEDA, Patrícia Akemi. Introdução aos algoritmos genéticos. 2009.

LINDEN, Ricardo. **Algoritmos Genéticos: Teoria e Implementação**. [S.l.: s.n.], 2005.

SOUZA, MJF. Inteligência computacional para otimização (notas de aula). **Ouro Preto: UFOP. Disponível em:** < <http://www.iceb.ufop.br/prof/marcone>>. Acesso em: 21 de Agosto de 2018, v. 22, 2008.

SZELISKI, Richard. **Computer vision: algorithms and applications**. [S.l.]: Springer Science & Business Media, 2010.