

COMPUTAÇÃO AFETIVA EM CÃES UTILIZANDO PADRÕES DE TEXTURA PARA MINERAÇÃO DE DADOS

AFFECTIVE COMPUTING IN DOGS USING TEXTURE PATTERNS FOR DATA MINING

Heloisa Michelle Tech
Graduanda em Banco de Dados pela Fatec Bauru
E-mail: heloisa.tech@fatec.sp.gov.br

Nayara Cristina Tezza
Graduanda em Banco de Dados pela Fatec Bauru
E-mail: nayara.tezza@fatec.sp.gov.br

Patricia Bellin Ribeiro
Doutora em Ciências, Processamento de Sinais e Instrumentação. Docente na Fatec Bauru
E-mail: patricia.ribeiro5@fatec.sp.gov.br

RESUMO:

O aumento do comércio no setor *Pet* levou algumas empresas a trabalhar em questões tecnológicas para atender as demandas tanto de tutores quanto de animais, uma vez que esses bichos se tornaram-se parte da família. Este artigo tem como proposta identificar fisionomias faciais caninas com o intuito de verificar se um cão possui semblante de felicidade. Pretende-se que a diferenciação seja efetuada por meio dos atributos verificados nas texturas das imagens, utilizando-se o algoritmo de árvore de decisão e um sistema gerenciador de banco de dados. Espera-se com o estudo proposto conseguir distinguir expressões de felicidade em cães com uma boa taxa de sucesso.

Palavras-chave: mercado pet; emoções; imagens; atributos; árvore de decisão.

ABSTRACT:

The increase of commerce in the pet sector has led some companies to work on technological issues to meet the demands of both guardians and animals, since these animals have become part of the family. This paper aims to identify canine facial features in order to verify whether a dog has a semblance of happiness. The differentiation is intended to be made by means of attributes verified in the textures of the images, using the decision tree algorithm and a database management system. It is expected with the proposed study to be able to distinguish expressions of happiness in dogs with a good success rate.

Keywords: pet market; emotions; pictures; attributes; decision tree.

1. INTRODUÇÃO

Comumente estudada pela psicologia, as emoções encontraram na tecnologia da informação uma nova entusiasta. Com a finalidade de descobrir os sentimentos demonstrados na internet, mais precisamente aqueles revelados nas redes sociais, muitos estudos apareceram e, obviamente, o marketing empresarial utilizou-se deles para melhorar o seu desempenho.

Ao mesmo tempo verificou-se que houve uma transformação na relação de animais domesticados e seres humanos. Bichos antes utilizados para caça, proteção, meio de transporte e de trabalho passaram a ter uma atenção especial, demonstrando uma alteração na forma seu de tratamento no final do século XX e início do século XXI (SOUZA, 2018). Dessa forma, donos tornaram-se tutores e cães, gatos, pássaros, entre outros, tornaram-se família.

Com o amor aos novos membros da família, coleiras e rações receberam como companheiros de prateleira roupinhas, sapatinhos, petiscos e brinquedos. Sites direcionados para tutores, com um volumoso conjunto de produtos e serviços para pets também começaram a proliferar. Todavia, a tecnologia não parou por aí e novos e valiosos produtos e serviços continuam a surgir em um mercado que segundo Souza (2018), em 2015 representou, ao lado do setor de utilidades domésticas, 4% do Produto Interno Bruto (PIB).

Unindo marketing empresarial, tecnologia para reconhecimento de emoções e interação animais e humanos é que a empresa Petz lançou o Pet-commerce. Essa nova aplicação do site da empresa reconhece quando um animal está diante da câmera e por meio de artifícios como sons e imagens atrativas, verifica se o animal gosta ou não do produto. Caso o pet demonstre uma fisionomia de interesse o produto é colocado no carrinho do tutor, que poderá adquirir ou não o produto que seu bichinho escolheu.

Essa nova forma de venda tem como base a análise das imagens capturadas pelas câmeras dos computadores conectados ao site. Para isso é necessário classificar as imagens baseando-se em tonalidades de cinza, analisando suas texturas e retirando os principais atributos que para que as imagens possam ser classificadas (GONZALEZ; WOODS, 2002).

O objetivo do presente trabalho é a diferenciação das imagens de cães felizes e aqueles que não apresentam expressão de felicidade. Para isso será montado uma base de dados com os atributos observados nas texturas das imagens e será utilizado o algoritmo de árvore de decisão J48, com auxílio do software Weka.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Computação Afetiva

O termo Computação Afetiva disseminou-se com o livro *Affective Computing* de Rosalind W. Picard, publicado em 1997. Apesar do que possa parecer para um leigo, o termo Computação Afetiva não está associado a máquinas que possuem sentimentos e sim a computadores que possam perceber as emoções de seres humanos e baseado na análise desses sentimentos, auxiliar os seres humanos em todas as áreas possíveis e contribuir para tomada de decisões mais assertivas (PICARD, 1995).

Segundo Bertch (2006), um computador pode ser habilitado com emoções de três formas: a primeira refere-se ao reconhecimento das emoções e possui a função de comunicação e identificação do estado sentimental do agente com o qual interage; a segunda seria a expressão, ato que iria além da comunicação e serviria para

influenciar as emoções dos agentes envolvidos na interação; a terceira refere-se a possuir emoções no sentido de dispor da capacidade de desempenhar análises de situações e eventos com estratégias que diminuem o tempo de tomada de decisão, atuando com base em padrões emocionais humanos, auxiliando decisões e soluções de problemas.

Para Duarte (2019), com a popularização da internet e das redes sociais surgiram trabalhos com a finalidade de classificar automaticamente as emoções de seus usuários, sendo uma esfera de estudo muito demandada e de interesse de várias áreas, uma vez que vivemos em uma era na qual categorizar os aspectos da vida são considerados progresso. Dessa forma, saber sobre as emoções contidas nos vídeos, áudios, fotos e textos que são disseminados nas redes sociais tornou-se importante para entender questões da vida de um grupo de pessoas ou de um indivíduo.

Para determinar os sentimentos contido em imagens, foi desenvolvido um sistema baseado na anatomia dos músculos da face que codifica as expressões utilizando os movimentos faciais (NUNES, 2012). Esse sistema inspirou a pesquisa de vários estudiosos que utilizaram o processamento de imagens de forma automática para procurar características fisionômicas e assim qualificar expressões distintas (NUNES, 2012).

2.2 Textura de imagens

2.2.1 Definição de Texturas

Texturas podem ser descritas como sendo um conjunto de determinados padrões que podem ocorrer na natureza, apresentando um formato que pode se repetir ou não necessariamente.

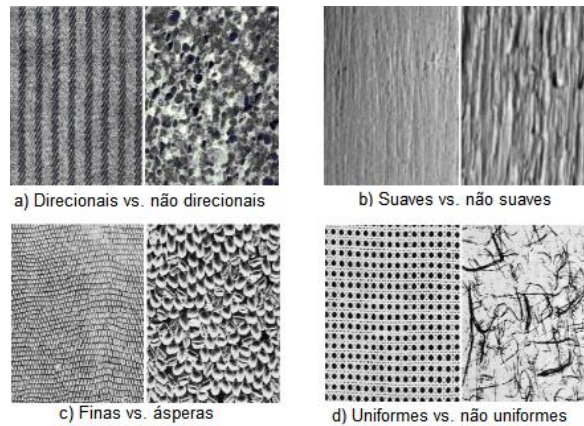
Em um exemplo de texturas que não se repetem, pode-se citar as estruturas geológicas, mostradas no estudo de Haralick et. al (1973), onde são capturadas as imagens de texturas de reservatórios rochosos, que são texturas que se diferem entre eles, podendo ter suas características diferenciadas ou classificadas.

Entre as várias definições de textura podem ser citadas:

- a) Como sendo uma característica relacionada com as propriedades físicas que um mesmo objeto representa. A textura descreve o padrão de variação de cinza em uma determinada região. (BACKES; BRUNO, 2006);
- b) É um conjunto de certos padrões que existem na superfície física, perceptível ao olho humano, e que trazem informações sobre a natureza da superfície em si, como a suavidade, rugosidade. (GONZALEZ; WOODS, 2002);
- c) É uma propriedade nativa de todas as superfícies, como por exemplo, o grão de madeira, a trama de um tecido, o padrão de culturas de um campo, entre outros. Possui informações sobre a estrutura dessas superfícies e a sua relação com o ambiente em sua volta. (HALARICK et. al, 1973);

A Figura 1 mostra os diversos tipos de texturas existentes na natureza.

Figura 1 – Exemplos de texturas.




Fonte: BRODATZ (2016)

2.2.3 Classificação de texturas

As texturas podem ser classificadas da seguinte forma, segundo Pratt (1991):

- a) Artificiais: são as texturas que são formadas por arranjos de símbolos, como segmentos de linhas, estrelas, pontos, entre outros, organizados sobre um fundo neutro. (HARALICK et.al, 1973). Em texturas artificiais, é possível observar alguns padrões que se repetem, como observados na Figura 2:


Figura 2 – Exemplos de texturas artificiais.



Fonte: Pratt (1991)

- b) Naturais: Texturas que são compostas por ambientes e cenários encontrados na natureza, e contém arranjos que pouco se repetem. Na Figura 3 é possível observar alguns exemplos:

Figura 3 – Exemplos de texturas naturais.



Fonte: Pratt (1991)

2.2.4 Descrição de texturas

Gonzales e Woods (2002), relatam a existência de três tipos de abordagens usadas para a descrição de texturas:

- a) Espectral: diz respeito às propriedades do espectro de Fourier, e são usadas na detecção de periodicidade global em uma imagem através da identificação de pontos de alta frequência do espectro. (KULKARNI, 1994);
- b) Estrutural: representa texturas que são formadas pela repetição de padrões que obedecem à alguma regra de posição para a sua geração. (BALLARD; BROWN, 1982);
- c) Estatística: descreve textura como sendo formada pela ordem de repetição de certos padrões estatísticos que obedecem a certa regra de posicionamento para a sua criação.

Para realizar a descrição de texturas, Haralick et. al (1973), projetaram 14 tipos de medidas estatísticas que são calculadas a partir de uma matriz de co-ocorrência. Este método apontado aplica uma metodologia para descrição de texturas que se baseia na descrição de estatísticas de segunda ordem.

Este tipo de descrição de texturas considera o posicionamento espacial relativo da ocorrência de níveis de cinza presentes em uma imagem. Portanto, uma imagem pode conter uma mesma quantidade de diferentes níveis de cinza que outra, diferenciando-se pela posição deles, que irá apresentar, como apontado na estatística de primeira ordem, um mesmo histograma, ou seja, as imagens são avaliadas como ela, porque o histograma de primeira ordem das duas é idêntica. Em estatísticas de segunda ordem permitem realizar tal diferenciação de imagens.


Na descrição estatística de segunda ordem, as duas imagens podem ser diferenciadas, mesmo que possuam histogramas de primeira ordem iguais, porque neste caso, o posicionamento relativo dos pixels são levados em consideração para a obtenção das medidas estatísticas vistas nesta abordagem. (HARALICK et. al, 1973; PRATT, 1991).

2.2.5 Matriz de Co-ocorrência

A matriz de co-ocorrência (GLCM – *Gray Level Cooccurrence Matrix*) é uma matriz de probabilidade de ocorrências $P(i,j)$, de um par de pixels específico, onde i é o nível de cinza do pixel de interesse da matriz e j é o nível de cinza do pixel vizinho de i . As distâncias do cálculo da matriz de co-ocorrência variam de acordo com o espaçamento a serem analisados entre os pares de pixels. (MEDEIROS, 2001).

Os cálculos são feitos utilizando os ângulos 0° , 45° , 90° e 135° , para os dois sentidos da matriz, vertical ou horizontal, mostrado na Figura 4

Figura 4 – Cálculos feitos na matriz de co-ocorrência utilizando diferentes ângulos.



Fonte: Costa (2010)

Após a realização do cálculo em todos os ângulos descritos, é feita a normalização se calcula a média das quatro matrizes, transformando-as assim em uma única matriz, para representar a região. Através desta matriz, é possível calcular os descritores de características.

Na Figura 5, é possível ilustrar o funcionamento da matriz de co-ocorrência. Uma matriz de tamanho 4x4 pixels representa uma imagem digital. Através da matriz principal é montada a matriz de co-ocorrência para a distância 1 e direção 0°. A formação das outras matrizes presentes na imagem demonstra o cálculo para cada distância e direção a ser analisada.

Figura 5 – Funcionamento da matriz de co-ocorrência.

$$\begin{array}{ccc}
 \begin{array}{c} \text{Matr} \\ \text{iza} \\ \text{de} \\ \text{Im} \\ \text{agem} \end{array} = \begin{pmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{pmatrix} & \begin{pmatrix} (0,0) & (1,0) & (2,0) & (3,0) \\ (0,1) & (1,1) & (2,1) & (3,1) \\ (0,2) & (1,2) & (2,2) & (3,2) \\ (0,3) & (1,3) & (2,3) & (3,3) \end{pmatrix} & \text{GLCM}(0^\circ) = \begin{pmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{pmatrix} \\
 \text{GLCM}(45^\circ) = \begin{pmatrix} 4 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 0 & 2 & 4 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix} & \text{GLCM}(90^\circ) = \begin{pmatrix} 6 & 0 & 2 & 0 \\ 0 & 4 & 2 & 0 \\ 2 & 2 & 2 & 2 \\ 0 & 0 & 2 & 0 \end{pmatrix} & \text{GLCM}(135^\circ) = \begin{pmatrix} 2 & 1 & 3 & 0 \\ 1 & 2 & 1 & 0 \\ 3 & 1 & 0 & 1 \\ 0 & 0 & 2 & 0 \end{pmatrix} \\
 \text{(a)} & \text{(b)} & \text{(c)} \\
 \text{(d)} & \text{(e)} & \text{(f)}
 \end{array}$$

Fonte: Trindade (2009).

2.2.6 Características de Haralick

Haralick et. al (1973), abordam um método usado para extração de características de texturas, baseado na relação espacial que existe entre os níveis de cinza, realizando o cálculo das matrizes de co-ocorrência e, com o resultado obtido, determinam 14 parâmetros estatísticos que definem as texturas.

Um descritor de Haralick é um valor calculado a partir da matriz de co-ocorrência de uma imagem, que determina a quantidade de algumas características (uniformidade, densidade, aspereza, regularidade, intensidade, entre outras) da variação dos níveis de cinza de uma imagem.

Algumas características de Haralick são descritas a seguir:

- Contraste ou Variância: é a medida de quantidade da variação local de níveis de cinza. Segundo Rosenfeld e Kak (1982), se o valor de variação for pequeno, os níveis de cinza vão possuir a maioria dos valores na horizontal. Caso contrário, e o valor do contraste for mais alto, a imagem irá ter uma quantidade

distribuída dos níveis de cinza em seu histograma. A fórmula que descreve este descritor é:

$$\text{Contraste} = \sum_{i,j=0}^{N-1} (i-j)^2 p(i,j)$$

- b) Segundo Momento Angular (SMA): medida de uniformidade local de níveis de cinza em uma imagem. Em um tipo de imagem como este, não existem muitas transições de cinza. A fórmula que descreve o Segundo Momento Angular é:

$$\text{SMA} = \sum_{i,j=0}^{N-1} p(i,j)^2$$


Existem outras características de Haralick que são utilizadas para a extração tais como: Correlação, Soma dos Quadrados - Variância, Momento de Diferença Inverso, Média da Soma, Entropia da Soma, Entropia, Variância da Diferença, Entropia da Diferença, Medidas de Informação da Correlação (2), Coeficiente de Correlação Máximo. (HARALICK et. al, 1973).

2.3 Árvore de decisão

As árvores de decisão são uma forma de realizar a classificação de dados usadas na Mineração de Dados (Data Mining). Segundo Quinlan (1993), as árvores de decisão utilizam o método dividir para conquistar, ou seja, são feitas várias divisões do conjunto selecionado de exemplos para o treino. Para o autor, posteriormente o conjunto é subdividido, até que os subconjuntos formados pertençam a uma mesma classe, ou até que essa classe seja predominante, não necessitando de mais divisões entre os conjuntos de exemplos.

Na interpretação de Camilo e Silva (2009), uma árvore de decisão possui o funcionamento semelhante a um fluxograma, na forma de uma árvore, que possui nós que indicam um teste feito sobre um valor específico. As conexões feitas entre os nós representam os possíveis valores do teste do nó acima, e as folhas indicam em que categoria o registro pertence. Após a árvore de decisão ser construída, para se classificar um novo registro, é necessário seguir o fluxo na árvore, começando pela raiz até encontrar uma folha. Um exemplo de árvore de decisão é representado na figura 6:

Figura 6 – Exemplo de uma árvore de decisão.



Fonte: Camilo e Silva (2009).

Um problema representa o início de uma árvore, que é composta por ramos, nós e folhas. Para cada nó definido, deve ser determinado o próximo critério da ramificação, como uma decisão. Os ramos de uma árvore simbolizam as decisões a serem tomadas, os cenários e as folhas são possibilidades de seleção de uma melhor e única opção. Para cada dado novo que a árvore recebe, a árvore é modificada para a geração de uma nova decisão otimizada. (SILVA et. al, 2008).

Para Alvarenga (2014), nas árvores de decisão são permitidas derivar certas regras, como de decisão ou de classificação, e que a partir dessas regras, a árvore é gerada. As regras descritas são os caminhos de um nó (conjunto de elementos que armazenam informações), que vão a outro nó da árvore, saindo de sua raiz (o atributo de maior relevância) até os nós folha (os atributos de interesse da pesquisa). Para verificar os padrões que foram obtidos pelo conjunto de exemplos da árvore de decisão, é necessário percorrer o trajeto do nó da raiz até o nó folha.

2.3.1 J48

Segundo Almeida et. al (2003), o algoritmo de código aberto J.48, gera uma árvore de decisão e é considerado o mais popular algoritmo usado no software Weka.

Neste tipo de algoritmo, é construído um modelo de árvore de decisão que é baseado em um conjunto de dados de treinamento, e este modelo é utilizado para classificação das instâncias do conjunto de teste.

O J48 é um algoritmo que é capaz de lidar tanto com atributos contínuos e discretos, e também com valores categóricos e ausentes. O tratamento de atributos envolve a considerações de todos os valores que estão no conjunto de treinamento, e estes são ordenados de forma crescente, considerando todos os valores presentes no conjunto de treinamento. Após a ordenação, é selecionado o valor que irá favorecer a redução da variação. (CAMARGO et.al, 2016; RAMYA et.al, 2015).

2.3.2 Criação de uma árvore de decisão

O processo de criação de uma árvore de decisão é iniciado a partir de um conjunto de treinamentos, que são exemplos de dados previamente conhecidos.

Para a geração de uma árvore de decisão com alto índice de previsão, é preciso selecionar corretamente os atributos que serão usados como teste nos casos propostos. Estes casos devem gerar uma outra árvore com o menor número de subconjuntos, para que cada folha possua um número alto (considerável) de casos. (STEINER et. al, 2004).

2.4 Mineração de Dados e Weka

Um enorme volume de dados é armazenado diariamente, esses dados podem ter grande significância quando tratados, pois tem potencial para revelar informações valiosas a um determinado negócio (DAMASCENO, 2015). Para extrair e analisar as informações uteis a mineração de dados é fundamental, pois possui critérios para o encontro de padrões e correspondência entre os dados (ARAÚJO; CRUZ, 2017).

Para minerar dados a suíte WEKA é comumente utilizada em meio acadêmico. O WEKA é um software livre, desenvolvido em Java, fato que torna possível sua utilização em diversos sistemas operacionais (DAMASCENO, 2015). A interface gráfica permite a realização de processos de mineração de dados em pequenas

bases, comparando algoritmos e verificando a avaliação dos resultados (ARAÚJO E CRUZ, 2017).

Conforme Damasceno (2015) os dados para aplicação de técnicas de mineração de dados devem estar organizados, sendo que o WEKA possui o formato ARFF para a estruturação dos dados, neste arquivo deve estar informações sobre os atributos como domínio, valores e classe.

3. MATERIAIS E MÉTODOS

Para a confecção do trabalho proposto, primeiramente, utilizou-se as bases públicas de imagens Pexels, Unsplash e Pixabay, das quais foram selecionadas 400 fotos separadas em duas classes, sendo 200 fotos de cachorros felizes e 200 fotos de cachorros tristes. As fotos selecionadas foram recortadas e editadas para que apenas a face dos animais ficasse visível.

Utilizou-se também a biblioteca ImageJ – *Image Processing and Analysis in Java* (Ij.jar), um programa de domínio público de imagem feito na linguagem Java para a exibição, análise, processamento de imagens. Podendo ler e salvar as imagens em vários formatos. (IMAGEJ, 2018). Neste programa todas as imagens foram colocadas em 8 bits e salvas com o formato TIFF.

Com os valores das texturas das 400 imagens de ambas as classes foi formado um documento no formato *Attribute-Relation File Format* (ARFF), que é o formato aceito pelo WEKA. A Figura 7 mostra quais são todos os atributos usados para a criação do cabeçalho no WEKA.

Figura 7 – Cabeçalho no WEKA.

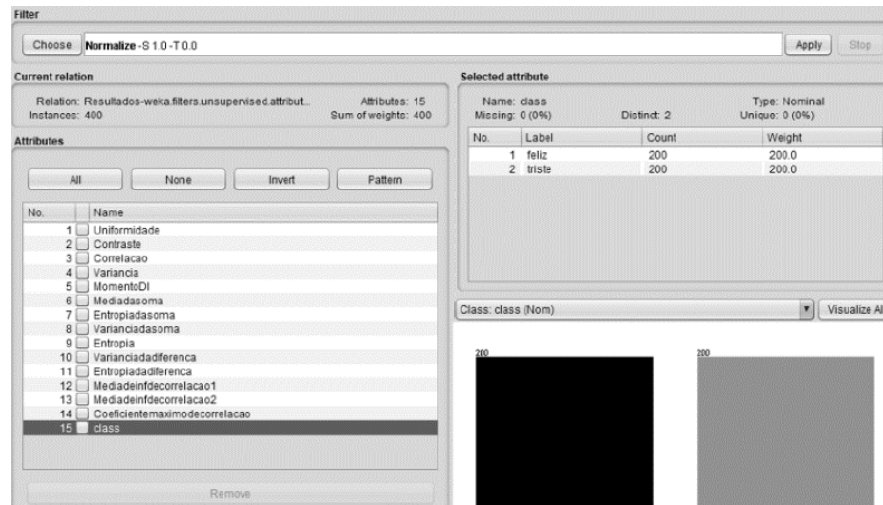
```
@RELATION Resultados

@ATTRIBUTE Uniformidade REAL
@ATTRIBUTE Contraste REAL
@ATTRIBUTE Correlacao REAL
@ATTRIBUTE Variancia REAL
@ATTRIBUTE MomentoDI REAL
@ATTRIBUTE Mediadasoma REAL
@ATTRIBUTE Entropiadasoma REAL
@ATTRIBUTE Varianciadasoma REAL
@ATTRIBUTE Entropia REAL
@ATTRIBUTE Varianciadiferenca REAL
@ATTRIBUTE Entropiadiferenca REAL
@ATTRIBUTE Mediadeinfdecorrelacao1 REAL
@ATTRIBUTE Mediadeinfdecorrelacao2 REAL
@ATTRIBUTE Coeficientemaximodecorrelacao REAL
@ATTRIBUTE class {feliz, triste}
```

Fonte: Os autores (2021).

Ao realizar a abertura do arquivo no formato ARFF no aplicativo WEKA, houve a normalização dos atributos, ficando seus valores entre zero e um. A Figura 8 mostra esta representação.

Figura 8 – Atributos e normalização no WEKA.



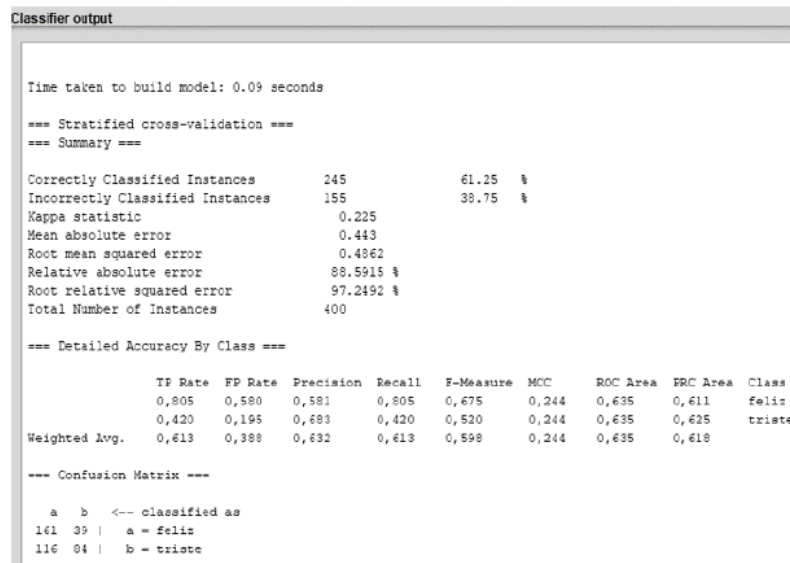
Fonte: Os autores (2021).

Em seguida, foi feita a classificação com a utilização do algoritmo de árvore de decisão J48 usando o *Cross-validation*. Nesta modalidade de teste um conjunto inicial é subdividido em 10, sendo um desses subconjuntos utilizado para treinamento e os demais para teste, e nesse caso, cada subconjunto de treinamento é comparado com o conjunto de teste (PIMENTA et. al., 2009).

4. RESULTADOS E DISCUSSÕES

Aplicando o algoritmo de árvore de decisão J48, verificou-se uma taxa de acerto de 61,25%, sendo que as imagens de cães felizes tiveram maiores acertos que as imagens de cães tristes. No primeiro caso houve 161 acertos e 39 erros, no segundo caso houve 116 acertos e 84 erros. A Figura 9 representa o resultado da extração das texturas.

Figura 9 – Resultado da extração das texturas.



Fonte: Os autores (2021).

A Figura 10 mostra quais tipos de atributos possuíram maior relevância na classificação com a árvore de decisão J48.

Figura 10 – Atributos com maior relevância na classificação.

```
J48 pruned tree
-----
Entropiadasoma <= 0.997516
|  Contraste <= 0.003669: triste (19.0/3.0)
|  Contraste > 0.003669
|  |  MomentoDI <= 0.003238: feliz (29.0/4.0)
|  |  MomentoDI > 0.003238
|  |  |  Mediadasoma <= 0.006
|  |  |  |  Uniformidade <= 0.007726
|  |  |  |  |  Contraste <= 0.013739
|  |  |  |  |  |  Uniformidade <= 0.007551: triste (11.0/1.0)
|  |  |  |  |  |  Uniformidade > 0.007551: feliz (2.0)
|  |  |  |  |  |  Contraste > 0.013739: feliz (6.0/1.0)
|  |  |  |  |  |  Uniformidade > 0.007726: triste (13.0)
|  |  |  |  |  Mediadasoma > 0.006: feliz (266.0/109.0)
Entropiadasoma > 0.997516: triste (54.0/7.0)

Number of Leaves :      8
Size of the tree :     15
```

Fonte: Os autores (2021).

5. CONCLUSÃO

Uma taxa de acerto inferior a 70% não é considerada um percentual de alta relevância, desta forma verificou-se que por conta da complexidade das imagens trabalhadas, apenas a utilização das texturas das imagens não se comprovou eficaz. Dessa forma, na continuidade deste trabalho, haverá a necessidade de inclusão de outros atributos ou técnicas além das texturas, com a finalidade de melhorar a taxa de acerto entre as classificações.

6. REFERÊNCIAS

ALECRIM, E. **O que são bits e bytes?**. Disponível em <https://www.infowester.com/bit.php#:~:text=Um%20conjunto%20de%208%20bits,os%20bytes%20possuem%208%20bits..> Acesso em 26 mar. 2021.

ALMEIDA, L. M. et al. **Uma Ferramenta para Extração de Padrões**. CEULP – Centro Universitário Luterano de Palmas/ULBRA, [s. l.], 2003. Disponível em: <https://www.cin.ufpe.br/~lma3/UmaFerramentaParaExtracaoDePadroes.pdf>. Acesso em: 19 jun. 2021.

ALVARENGA, M. T. **UTILIZAÇÃO DA FERRAMENTA J48 PARA DESCOBERTA DO CONHECIMENTO EM BASES DE DADOS FITOSSANITÁRIOS, CLIMÁTICOS E ESPECTRAIS**. 2014. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Universidade Federal de Lavras, Lavras, 2014. Disponível em: http://www.epamig.ufla.br/geosolos/publicacoes/teses/Monografia_Miguel%20Thiago%20Alvarenga.pdf. Acesso em: 19 nov. 2020.

ARAÚJO, M. M.; CRUZ, E. A. **Análise e Mineração de Dados Sociais com a Ferramenta WEKA**. Disponível em: <https://doity.com.br/media/doity/submissoes/artigo-4e72d92934b70c1d370e3725bf6f8d020f9dcc1e-arquivo.pdf>. Acesso em 14 mai. 2021.

BACKES, A. R.; BRUNO, O. M. **Segmentação de Texturas por Análise de Complexidade**. ICMC - Instituto de Ciências Matemáticas e de Computação. 2006. Artigo (ICMC - Instituto de Ciências Matemáticas e de Computação) - Universidade de São Paulo, 2006. Disponível em: https://www.researchgate.net/publication/228987626_Segmentacao_de_texturas_por_analise_de_complexidade. Acesso em: 27 abr. 2021.

BALLARD, B. **Computer Vision**. New Jersey: Prentice Hall, 1982.

BERCHT, M. **Computação Afetiva : Vínculos com a Psicologia e Aplicações na Educação**. In: CONSETINO, L.; FORTIN, I.; PRADO, O. Z. (Org). *Psicologia e Informática*. São Paulo: Conselho Regional de Psicologia, 2006. Disponível em: orkut-na-clinica-e-a-relacao-terapeuta-paciente.pdf (researchgate.net). Acesso em: 02 abr. 2021.

BRAVO, M. J. A. **Análise do Descritor de Padrões Mapeados Localmente em Multiescala para Classificação de Textura em Imagens Digitais**. 2016. 157 f. Dissertação (Mestrado em Matemática) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Biociências, Letras e Ciências Exatas, São José do Rio Preto. Disponível em: [46481052.pdf](http://docplayer.com.br/46481052.pdf) (docplayer.com.br). Acesso em: 27 abr. 2021.

BRAZDIL, P. **Construção de Modelos de Decisão a partir de Dados**. 1999. Disponível em: <http://www.ncc.up.pt/~pbrazdil/Ensino/ML/DecTrees.html>. Acesso em 27 abr. 2021.

BRODATZ, P. **Texture: A photographic album for artists and designers**. New York: Dover Publications, 1966.

CABENA, P. et al. **Discovering Data Mining from Concept to Implementation**. Upper Saddle River, New Jersey: Prentice Hall, 1997.

CAMARGO, A. et. al. (2016). **Mineração de dados eleitorais**: descoberta de padrões de candidatos a vereador na região da campanha do Rio Grande do Sul. Revista Brasileira de Computação Aplicada.

CAMILO, C. O.; SILVA, J. C. **Mineração de Dados**: Conceitos, Tarefas, Métodos e Ferramentas. 2009. Mestrado (Ciências da Computação) - Instituto de Informática Universidade Federal de Goiás, [S. l.], 2009. Disponível em: http://ww2.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-09.pdf. Acesso em: 19 nov. 2020.

COSTA, J. M. P. **Análise de Imagem: Medição de Área Edificada**. 2010. Trabalho de Conclusão de Curso (Licenciatura em Engenharia Informática) - Universidade da Beira Interior, Covilhã, Portugal., 2010. Disponível em: <http://www.di.ubi.pt/~hugomcp/doc/JoseCosta.pdf>. Acesso em: 29 abr. 2021.

DAMASCENO, M. **Introdução a Mineração de Dados Utilizando o WEKA**. Disponível em <http://connepi.ifal.edu.br/ocs/anais/conteudo/anais/files/conferences/1/schedConfs/1/papers/258/public/258-4653-1-PB.pdf>. Acesso em 14 mai. 2021.

DUARTE, L. C. F. **Reconhecimento Automático de Emoções em Texto com recurso a emojis**. 2019. 110 f. Dissertação (Mestrado em Engenharia Informática) – Faculdade de Ciências e Tecnologia de Coimbra, Coimbra. Disponível em https://estudogeral.sib.uc.pt/bitstream/10316/88059/1/Tese_LuisDuarteFinal.pdf. Acesso em: 02 abr. 2021.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 2. ed. New Jersey: Prentice Hall, 2002. Disponível em: GONZFM-i-xxii. (bsu.edu.eg). Acesso em: 09 abr. 2021.

HARALICK, R. M. et al. **Textural Features for Image Classification**. Institute of Electrical and Electronics Engineers, Inc., [S. l.], v. 6, November 1973. Disponível em: <http://haralick.org/journals/TexturalFeatures.pdf>. Acesso em: 26 abr. 2021

IMAGEJ. **Introduction**. [S. l.], 2018. Disponível em: <https://imagej.nih.gov/ij/docs/intro.html>. Acesso em: 19 set. 2021.

INGARGIOLA, G. **Building Classification Models**: ID3 and C4.5, 1996. Disponível em: <http://www.cis.temple.edu/~ingargio/cis587/readings/id3-c45.html>. Acesso em: 19 jun. 2021.

KULKANI. **Artificial Neural Networks for Image Understanding**. New York: 1994.

MEDEIROS, G. C. F. **Uso de texturas para o acompanhamento da evolução do tratamento de úlceras dermatológicas**. 2001. Dissertação de Mestrado (Engenharia Elétrica) - Universidade de São Paulo, São Carlos, 2001. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18133/tde-26042001-125441/pt-br.php>. Acesso em: 27 abr. 2021.

MILANI, A. **MySQL Guia do Programador**. São Paulo: Novatec, 2006.

NUNES, M. A. S. N. **Computação Afetiva personalizando interfaces, interações e recomendações de produtos, serviços e pessoas em ambientes computacionais**. Disponível em <http://almanaquesdacomputacao.com.br/gutanunes/publications/NunesDCOMP2012.pdf> Acesso em: 16 abr. 2021.

PICARD, R. W.; **Affective Computing**. Disponível em <https://affect.media.mit.edu/pdfs/95.picard.pdf>. Acesso em: 27 abr. 2021.

PIMENTA, A. et al. **WEKA-G**: Mineração de dados paralela em grades computacionais. Revista de Sistemas de Informação da FSMA, [s. l.], ed. 4, 2009. Disponível em: http://www.fsma.edu.br/si/edicao4/FSMA_SI_2009_2_Estudantil_1.pdf. Acesso em: 19 set. 2021.

PRATT. **Digital Image Processing**. Wiley Interscience, Second Edition, 1991.

QUINLAN, J. **C45**: Programs for machine learning. San Mateo: Morgan Kaufmann, 1993. 302p.

RAMYA, M., LOKESH, et. al. **A predictive model Construction for Mulberry Crop Productivity**. Procedia Computer Science, 2015.

ROCHA, A. R. **Classificação de texturas a partir de vetores de atributos e função de distribuição de probabilidades**. Monografia (Instituto de Computação) - Universidade Estadual de Campinas (Unicamp), [S. l.]. Disponível em: https://www.ic.unicamp.br/~rocha/msc/ipdi/texture_classification.pdf. Acesso em: 26 abr. 2021.

ROSENFELD, A. e KAK, A. C. **Digital picture processing**. 2.ed. London: Academic Press., 1982.

SCURI, A. E. **Fundamentos da Imagem Digital**. [S. l.]: Tecgraf/PUC-Rio, 2002. Disponível em: <https://web.tecgraf.puc-rio.br/~scuri/download/fid.pdf>. Acesso em: 27 abr. 2021.

SILVA, W. V. et al. **AVALIAÇÃO DA ESCOLHA DE UM FORNECEDOR SOB CONDIÇÃO DE RISCOS A PARTIR DO MÉTODO DE ÁRVORE DE DECISÃO**. Revista de Gestão: USP, São Paulo, v. 15, ed. 3, 12 ago. 2008. Disponível em: <https://www.revistas.usp.br/rege/article/download/36648/39369/43185>. Acesso em: 19 nov. 2020.

SOUZA, A. F. B. **O Mercado Pet Brasileiro**: uma Análise de 2012 a 2017. 2018. 59 f. Trabalho de Conclusão de curso (Bacharelado em Ciências Econômicas) - Centro Universitário Municipal de Franca. Disponível em: <http://periodicos.unifacef.com.br/index.php/rede/article/download/1708/1232>. Acesso em: 9 mar. 2021.

STEINER, M. T. A. et al. **REDES NEURAIS E ÁRVORES DE DECISÃO NA ANÁLISE DO CRÉDITO BANCÁRIO**. XXXVI - SBPO, São João Del Rei, 2004. Disponível em: <http://www.din.uem.br/sbpo/sbpo2004/pdf/arq0035.pdf>. Acesso em: 18 nov. 2020.

TRINDADE, F. R. **DESENVOLVIMENTO DE UMA METODOLOGIA DE CLASSIFICAÇÃO DE PADRÕES EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO PULMÃO**. 2009. Trabalho de Conclusão De Curso (Bacharel em Física Médica) - Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2009. Disponível em: https://www.researchgate.net/publication/330343854_PONTIFICIA_UNIVERSIDADE_CATOLICA_DO_RIO_GRANDE_DO_SUL_FACULDADE_DE_FISICA_CLASSIFICACAO_DE_PADROES_EM_IMAGENS_DE_TOMOGRAFIA_COMPUTADORIZADA_DO_PULMAO. Acesso em: 29 abr. 2021.

WEISS S. M, KULIŁOWSKI C. A. **Computer systems that learn**: Classification and prediction methods from statistics, neural nets, machine learning, and expert systems. Morgan Kaufmann Publishers, Inc. 1991.