

ANÁLISES DE IMAGENS CLASSIFICAÇÃO DE GÊNERO EM PERFIS DE REDES SOCIAIS

Tatiane Vieira Alves (IC) e Leandro Augusto da Silva (Orientador)

Apoio: PIBIC Mackenzie

RESUMO: A geração de dados tem chamado a atenção de pesquisadores não apenas pelo volume, mas também pela variedade. Nas redes sociais, tecnologia responsável pelo aumento significativo na produção de dados no mundo, tem-se uma variedade no formato da informação disponível, principalmente, em texto e imagens. No entanto, outras informações importantes para análises em um contexto mais amplo de aplicação, não estão disponíveis, por exemplo, o gênero do participante da rede social. Nessa ausência de informação que este trabalho de pesquisa se insere, através da representação dos dados por características que descrevem cor, forma e textura da foto do perfil, o objetivo do trabalho é reconhecer o gênero do usuário da rede social.

Palavras-chave: Análise de imagem, classificação de dados.

ABSTRACT: The data generation has attracted the attention of researchers not only because the volume, but also by the data variety. In social networks, which is responsible for the significant increase in data production in the world, has a variety of information available in the format, mainly, of text and images. However, other important information for social network analysis are not available, for example, the gender of person. This lack of information is where this research is inserted, which the purposes are the data representation for characteristics that describe the text by the author's writing style; and characteristics that describe color, shape and texture for profile author photo. The objective is to recognize the user's gender social network.

Keywords: Image analysis, gender in social networks.

1 INTRODUÇÃO

A quantidade de dados disponível para análise e interpretação é muito maior que o uso efetivo dos mesmos em processos decisórios ou geração de conhecimento (FAYYAD et. al., 1996; CARDOSO et. al., 2008).

Uma das dificuldades para análise e interpretação pode ser a ausência de informações, principalmente de dados disponíveis em redes sociais. Adicionalmente, os dados disponíveis em redes sociais são passíveis de alguns problemas como veracidade de informações do tipo nome, gênero, idade etc. (CHENG et al., 2011). Sendo assim, problemas como estes de ausência ou veracidade de informações geram dificuldades na utilização dos dados em análises e abrem caminhos para diferentes abordagens de pesquisas. Exemplos de trabalhos possíveis nesse contexto relacionam-se à segurança de informação através do combate aos crimes cibernéticos, ao apoio em marketing para apresentar campanhas publicitárias aderente ao usuário, à temas relacionados com recuperação de informação para permitir explorações sobre os dados multimídia (texto, imagem e vídeo) e muitas outras aplicações (CHENG et al., 2011).

Tendo em vista os problemas acima apresentados e a abrangência de aplicações possíveis usando dados de redes sociais, este trabalho tem como objetivo principal a classificação de gênero de usuários da rede social *LinkedIn*, através da foto do perfil e texto descritivo de experiências profissionais. Como objetivo específico do trabalho, propõe-se verificar a eficiência da representação dos dados multimídia, neste caso de imagens, através de características visuais para o reconhecimento do gênero. A representação visual será feita usando técnicas capazes de descrever as imagens por cor, forma e textura. Os resultados deste trabalho, além do uso em classificação de gênero, ainda podem ser úteis como sistema de apoio a crimes cibernéticos, buscas por gêneros em redes sociais, sugestão de anúncios exclusivos para cada tipo gênero entre outros.

Além da introdução que tem como objetivo contextualizar o leitor, na seção 2, apresenta-se o embasamento teórico necessário para aprofundar o leitor no tema. A seção 3 informa ao leitor as metodologias usadas na pesquisa. Os resultados e análises experimentais do presente trabalho estão dispostos na seção 4 e a análise dos resultados na seção 5, a conclusão na seção 6 e por fim, na seção 7 estão as referências bibliográficas utilizadas para a construção do trabalho.

2 REFERENCIAL TEÓRICO

A classificação de dados é uma tarefa da mineração de dados em que, a partir de um modelo preditivo treinado, pode-se reconhecer automaticamente a classe do objeto em estudo

(TAN et. al., 2005). É uma tarefa intuitiva ao ser humano, pois é natural a tentativa de classificar os objetos ou informações disponíveis com base no conhecimento que está intrínseco ou que foi constituído ao longo da vida (CARVALHO, 2005).

Um dos principais algoritmos de classificação de dados disponíveis na literatura é o *k*-NN (em inglês, *Nearest Neighbors*), que recebe um objeto descrito por um conjunto de atributos (ou características) sem a variável classificatória e, o algoritmo, através de medida de similaridade, compara esse objeto sem classe com os atributos de um conjunto de dados classificado. E assim, encontra-se o *k* (valor inteiro maior ou igual a 1) vizinho mais semelhante, atribuindo ao objeto em análise, a classe do *k* mais próximo (para $k > 1$ a decisão é pela classe majoritária) (COVER; HART, 1967).

Árvore de decisão é outra da técnica de classificação de dados que é gerada por um processo de estruturação dos atributos do conjunto de dados para algum critério, como por exemplo pelo ganho de informação. Nessa árvore os nós são atributos, os ramos os valores possíveis e as folhas são as classes. Em um processo de classificação, um caminho da árvore é traçado, a partir do nó raiz, até o nó folha (ou terminal) que resulta na previsão de classe (SAFAVIAN; LANDGREBEL, 1991). Para a classificação dos dados multimídias utilizados neste trabalho, como imagens, é necessário transformá-las em instâncias numéricas estruturadas com base em suas características para que as dimensões, formatos e outros detalhes que as tornam diferentes entre si auxiliem no reconhecimento de objetos. (HARZALLAH et. al., 2009). Sendo assim, o algoritmo de classificação irá atuar com base nestas características que são extraídas da imagem. Portanto, é importante que as características extraídas sejam invariantes à posição de um objeto na cena e ou ao ângulo da incidência da luz sobre o mesmo (JAIN et al., 1995).

Nas seções seguintes serão apresentados mais detalhes sobre as técnicas de extração de características para imagem abordadas neste trabalho.

2.1. Extração de características


O cérebro, ao ser exposto a uma determinada cena ou imagem por meio do sentido da visão, ele observa o ambiente, reconhece o objeto e eventualmente toma alguma decisão.

A visão computacional tem como uma das suas tarefas reproduzir esse encadeamento de eventos para a máquina (BESL; JAIN, 1985). Há diversas aplicações que envolvem tomada de decisões a partir da análise de imagens (HU; RAUNHEITTE, 2004). Nesse contexto, uma imagem pode ser definida como um conjunto de *pixels* capaz de representar um objeto em um espaço (HARALICK; SHAPIRO, 1991).

Dentre as diversas características invariantes da imagem que podem ser utilizadas no reconhecimento de objetos é possível citar a textura, cuja definição não está relacionada a um único *pixel* e sim a padrões formados por ele e seus vizinhos, sendo assim, um padrão formado pelos níveis de cinza de um conjunto de *pixels* em uma determinada região é a textura da mesma (BALLARD; BROWN, 1982; JAIN et. al., 1995).

A Figura 1 representa um objeto que tem como característica invariante o formato, o qual independe da iluminação e da posição deste objeto na cena.

Figura 1 - Características invariantes da imagem.



Fonte: Elaborada pelos autores

Além da textura, o reconhecimento do objeto pode ser feito com base em sua borda. A borda delimita uma região da imagem (JAIN et. al., 1995). No reconhecimento de imagens com pessoas, a borda pode representar as linhas que formam a face, bem como outras partes do corpo que também podem ser considerados objetos, por exemplo, os lábios. A classificação de gêneros por meio da análise de imagens pode utilizar o reconhecimento de objeto na cena (MÄKINEN; RAISAMO, 2008).

Dessa maneira, a classificação de gêneros por meio dos objetos encontrados nas imagens pode ser feita usando os métodos de extração de características como borda e textura utilizando o algoritmo de *Canny* para a detecção de bordas (CANNY, 1986). Uma de suas principais características é atender as condições de baixa taxa de erro, os pontos de borda devem estar bem localizados e resposta de um único *pixel*, fazendo com que elas sejam bem finas (GONZALEZ; WOODS, 2009), trazendo mais detalhes que podem ser relevantes na classificação

Para a extração de textura, o método *Local Binary Pattern*, ou LBP, é utilizado inclusive no auxílio de reconhecimento facial como mostra muitas pesquisas disponíveis na literatura.

Esse método é basicamente a decomposição da imagem em pequenas partes, onde cada *pixel* é comparado aos seus vizinhos, gerando um valor de textura para cada *pixel* (WANG; HE, 1990).

Outras técnicas são capazes de auxiliar no reconhecimento de objetos considerando as características invariantes. O histograma ou diagrama de frequências acumuladas, além de ser um método que permite visualização com maior facilidade (CHRISTMANN, 1978) é um método simples e rápido para a detecção de padrões dentro de um conjunto de dados (SCHIELE; CROWLEY, 1997).

Existem outras medidas para descrever um conjunto de dados quando este é composto de muitos valores, que podem ser utilizadas num conjunto de imagens, sendo a média, uma medida de tendência central, uma das mais utilizadas, bem como a mediana. As medidas de dispersão podem auxiliar a média a representar melhor o conjunto de dados, sendo elas, o desvio padrão e a variância, que tem o papel de estabelecer a relação entre um dado do conjunto e a média do mesmo. Valores mínimos e máximos também podem auxiliar na análise devido a representação dos valores extremos da base de dados (CHRISTMANN, 1978).

2.1.1. Canny

Para extração de característica da borda, a técnica de *Canny*, também chamada de detecção de bordas, as imagens devem ser convertidas para escala de cinza e após esse processo as principais tarefas são:

- i. Suavização das cores de *pixel*, para auxiliar no cálculo dos gradientes e sua inclinação;
- ii. Cálculo dos gradientes, para calcular a direção de maior inclinação;
- iii. Supressão de não-máximos, que por essência determina o número de orientações da borda;
- iv. Limiarização por Histerese, reduzindo os falsos pontos da borda.

O resultado dessas etapas são as bordas bem detalhadas, pois possuem a espessura de um *pixel* (GONZALEZ; WOODS, 2009). A Figura 2 mostra o resultado da aplicação do método em uma imagem.

Figura 2 - Resultado da aplicação de Canny.



Fonte: Elaborada pelos autores


2.1.2. Local Binary Pattern

Para a extração de textura, o método *Local Binary Pattern* (LBP) tem as seguintes etapas:

- i. Seleciona um *pixel* e um raio que determina a quantidade de vizinhos. Por exemplo, se o raio for igual a um, serão analisados seus oito vizinhos.
- ii. Cria uma nova matriz e, atribui zero para os vizinhos menores que o *pixel* analisado e um para os vizinhos com valores iguais ou maiores;
- iii. A matriz binária gerada é multiplicada por uma outra matriz de pesos;
- iv. O valor LBP é resultante da soma dos oito *pixels* da matriz de resultado da multiplicação (WANG; HE, 1990).
- v.

A Figura 3 mostra o resultado da aplicação do método *Local Binary Pattern* em uma imagem.

Figura 3 - Resultado da aplicação de *Local Binary Pattern*.



Fonte: Elaborada pelos autores

3 METODOLOGIA

Para verificar a eficiência da representação dos dados por descritores visuais em um processo de classificação de gêneros, será necessária uma base de dados que tenha

imagens. O resultado dos descritores será submetido a dois classificadores, sendo eles árvore de decisão e *k-NN*, gerando os resultados de classificação para uma análise posterior. Nas sessões seguintes, o processo será explicado em maiores detalhes.

3.1. Captura de dados

A base de treinamento utilizada nesse trabalho foi montada pelos próprios autores devido a dificuldade de encontrar uma base de dados pronta que esteja de acordo com os seguintes requisitos necessários para o objetivo da pesquisa:

- a) As imagens devem ser de pessoas físicas com apenas um rosto na foto;
- b) As imagens devem ser visíveis, principalmente a face e não devem apresentar muita incidência de luz e nem serem muito escuras.

A partir da definição dos requisitos para a base de treinamento, foram extraídos dados do *LinkedIn*¹, sendo as imagens necessárias para a análise extraídas das fotos dos perfis, todas com dimensões 400 x 400. O conjunto é composto por 17 perfis de gênero feminino e 35 perfis de gênero masculino totalizando em 52 perfis.

3.2. Estruturação dos dados


Para alcançar o objetivo deste trabalho, foi utilizada a linguagem Python que possui bibliotecas padrões de processamento de imagens e outras que podem ser importadas ao código para estruturação da base de treinamento. Os resultados obtidos foram analisados posteriormente.

A leitura da base de imagens foi realizada utilizando as bibliotecas *Image* e *OpenCV* (BRADSKI, 2000) em momentos diferentes devido a interação com as outras bibliotecas. Após o processo de leitura das imagens ser concluído por meio da biblioteca *OpenCV* (BRADSKI, 2000) em escala de cinza, foi realizada a extração de características de textura, com a aplicação da técnica *Local Binary Pattern* em cada uma delas. A biblioteca *Scikit-Image* (WALT et. al., 2014) forneceu os métodos necessários para a extração da textura com a

¹ <https://www.linkedin.com/>

aplicação desta técnica. O resultado da aplicação da técnica em uma imagem original está representado na Figura 4.

Figura 4 - Exemplo da extração da textura de uma imagem em forma de dado estruturado.




Fonte: Elaborada pelos autores


O mesmo processo de leitura de imagens foi feito utilizando a biblioteca *Image*. Após a conclusão, foi utilizada a biblioteca *CV2* para aplicação do método de *Canny* para extração de borda. O retorno do método é a imagem em preto e branco, sendo os pontos brancos a borda como mostra a Figura 5.

Em seguida os valores da matriz da borda correspondentes aos pontos brancos (255 em escala de cinza) foram substituídos pelo valor 1, gerando assim uma matriz binária. A matriz binária é multiplicada pela matriz transposta da imagem original em escala de cinza, para que seja possível obter a borda com os níveis de cinza da imagem original e não somente formada por pontos brancos como mostra a Figura 6.

Figura 5 - Exemplo da extração da borda de uma imagem em forma de dado estruturado.



Fonte: Elaborada pelos autores

Figura 6 - Obtenção da matriz binária a partir da matriz da borda.

Fonte: Elaborada pelos autores

Com os dados da textura e da borda disponíveis, para cada imagem foi extraído o histograma de ambas as características utilizando a biblioteca *SciPy*. Esse método é aplicado para a base de dados do gênero masculino e feminino separadamente. Além disso, foram extraídas outras informações das imagens, como valores mínimo e máximo, desvio padrão, variância, mediana e média para cada imagem da imagem em escala de cinza conforme a Tabela 2.

Tabela 2 - Exemplo de extração das medidas de tendência central, dispersão, valores máximo e mínimo.

Imagem	Média	Mediana	Valor Máximo	Valor Mínimo	Desvio Padrão	Variância
	120.1098828	127	255	0	70.65680973	4992.384762

Fonte: Elaborada pelos autores

O conjunto de dados gerados foi armazenado em um arquivo *Comma-separated values* (CSV) por meio das bibliotecas OS e CSV. Tendo enfim, os atributos estruturados, o arquivo foi submetido aos classificadores.

3.3. Classificação dos Dados

Os arquivos CSV contendo os resultados dos descritores visuais e das expressões regulares foram submetidos a dois métodos de classificação, sendo eles o *k-NN* e a árvore

de decisão. Foram escolhidos dois métodos para fins comparativos de ambos os resultados. Os arquivos foram processados na linguagem *R*, que possui bibliotecas nativas com os métodos de classificação utilizados. O código gerado retorna uma matriz de confusão e a acurácia, resultantes da aplicação da técnica *leave-one-out*.

A técnica *leave-one-out* é uma das muitas que existem para realizar a avaliação dos modelos de classificação. Ela consiste em retirar um exemplar da base de treinamento e aplicar o modelo de classificação a ele e finalmente comparar o resultado obtido com o esperado. O processo é repetido para toda a base (TAN et. al., 2005).

Os resultados do método *leave-one-out* são compilados em uma matriz denominada matriz de confusão. A matriz de confusão é o encontro dos valores verdadeiros para os exemplares, que são expressos pelas linhas, e dos resultados que foram obtidos através do modelo de classificação, sendo estes as colunas, conforme a Tabela 3. O encontro das colunas e das linhas resultam nos seguintes coeficientes (SILVA, 2015):

- a) Verdadeiro Positivo (VP): Quando o classificador encontra a classe correta para a classe positivo;
- b) Verdadeiro Negativo (VN): Quando o classificador encontra a classe errada, ou seja, classifica como negativo a classe positivo;
- c) Falso Positivo (FP): Quando o classificador encontra a classe correta para a classe negativo;
- d) Falso Negativo (FN): Quando o classificador encontra a classe errada, ou seja, classifica como positivo a classe negativo;

Neste trabalho, a classe denominada como positivo, representa o gênero masculino e a classe negativo, o gênero feminino.

Tabela 3 - Matriz de Confusão.

		Classe Prevista	
		positivo	negativo
Classe Verdadeira	positivo	VP	FN
	negativo	FP	VN

Fonte: SILVA (2015)

A partir dos resultados da matriz de confusão é possível extrair outras medidas com base em seus resultados, como a sensibilidade e especificidade:

$$\text{Sensibilidade} = \frac{VP}{VP + FN}$$

$$\text{Especificidade} = \frac{VN}{FP + VN}$$

Uma das características da matriz de confusão é permitir que seus resultados sejam expressos pela acurácia. A acurácia de um classificador é a taxa de acerto na classificação de uma linha escolhida aleatoriamente em um conjunto de dados pela qual foi juntamente treinada (KOHAVI, 1995). A acurácia é medida por meio da matriz de confusão a partir da seguinte fórmula (SILVA, 2015):

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}$$


1 RESULTADOS E ANÁLISES EXPERIMENTAIS

Após a obtenção dos arquivos CSV com os dados visuais estruturados, o conjunto foi submetido a uma análise exploratória antes de iniciar o processo de classificação.

O objetivo desta análise é verificar se os descritores estudados têm características que são capazes de discernir gênero feminino de masculino. Isso será possível através da comparação das figuras de cada gênero, analisando se há regiões que diferenciam cada classe.


A análise foi feita para cada um dos descritores visuais utilizados na pesquisa, o Gráfico 1 e Gráfico 2 trazem os histogramas para os gêneros masculino e feminino. Nesses resultados pode se perceber que os gráficos possuem picos que podem ser capazes de reconhecer os gêneros. Com mais detalhes de discernimento, as regiões entre 46 e 146 (eixo x dos gráficos) são predominantes para o feminino, assim como entre as regiões 186 e 211 há predominância de picos nas imagens de homens.

Gráfico 1 - Visualização do conjunto de dados do histograma masculino com 251 níveis de cinza de toda a imagem.



Fonte: Elaborada pelos autores


Gráfico 2 - Visualização do conjunto de dados do histograma feminino com 251 níveis de cinza de toda a imagem.



Fonte: Elaborada pelos autores


O mesmo processo foi aplicado para o conjunto de dados da borda como mostra o Gráfico 3 e o Gráfico 4.

Gráfico 3 - Visualização do conjunto de dados da borda masculino com 251 níveis de cinza de toda a imagem.



Fonte: Elaborada pelos autores


Gráfico 4 - Visualização do conjunto de dados da borda feminino com 251 níveis de cinza de toda a imagem.



Fonte: Elaborada pelos autores


O Gráfico 5 e o Gráfico 6 mostram os resultados das classes de textura encontradas no conjunto de dados.

Gráfico 5 - Visualização do conjunto de dados da textura masculino.



Fonte: Elaborada pelos autores


Gráfico 6 - Visualização do conjunto de dados da textura feminino.



Fonte: Elaborada pelos autores


O Gráfico 7 e o Gráfico 8 mostram as medidas de tendência central e de dispersão além dos valores máximos e mínimos para ambos os gêneros.

Gráfico 7 - Medidas de tendência central e dispersão, valores máximos e mínimos para o gênero masculino



Fonte: Elaborada pelos autores

Gráfico 8 - Medidas de tendência central e dispersão, valores máximos e mínimos para o gênero feminino



Fonte: Elaborada pelos autores

Após a análise exploratória dos gráficos, os arquivos foram submetidos aos classificadores para os testes finais, incluindo os resultados de classificação para cada um

dos descritores e depois, todos os descritores juntos em um único arquivo. A Tabela 4 traz os resultados da classificação utilizando os métodos *k-NN* e árvore de decisão.

Tabela 4 - Resultados finais dos descritores visuais.

		Acurácia	Sensitividade	Especificidade
Histograma	k-NN	55,77%	68,57%	29,41%
	AD	59,62%	80,00%	17,65%
Borda	k-NN	55,77%	68,57%	29,41%
	AD	55,62%	80,00%	17,65%
Textura	k-NN	56,60%	65,71%	38,89%
	AD	56,60%	68,57%	33,33%
Medidas	k-NN	63,46%	71,43%	47,06%
	AD	65,38%	74,29%	47,06%
Combinação	k-NN	80,39%	88,57%	62,50%
	AD	98,04%	100,00%	93,75%

ANÁLISE DOS RESULTADOS

Com os resultados obtidos através dos experimentos, para esta base de dados, utilizando os gráficos, é possível notar que há picos diferentes entre os gêneros feminino e masculino, mostrando a diferença entre os atributos e quais analisar.

Nos resultados de classificação, a árvore de decisão foi o classificador que gerou maior acurácia em grande parte dos descritores analisados separadamente. Além disso, dentre os descritores, as medidas de tendência central e de dispersão, valor mínimo e máximo tiveram maior acurácia, seguidas do histograma.

Nota-se que pelos valores de sensibilidade e especificidade que os classificadores tiveram maior probabilidade em reconhecer o gênero masculino do que o gênero feminino, pois em todos os resultados o valor da sensibilidade é maior do que a especificidade.

A combinação de todos os descritores visuais teve uma acurácia muito alta, sendo que a capacidade da árvore de decisão classificar o gênero masculino foi de 100,00% para esta base de dados, nas condições apresentadas nesse trabalho.

CONCLUSÃO E TRABALHOS FUTUROS

Os descritores visuais utilizados neste trabalho, apesar de serem técnicas não tão recentes, tem uma capacidade de reconhecimento com baixo custo computacional. A

classificação de imagens abre caminho para pesquisas como identificação de pessoas e busca de imagens por conteúdo. Além de ser possível filtrar uma base de dados por gênero, por exemplo, diminuindo o custo de busca.

REFERÊNCIAS

BALLARD, Dana H.; BROWN, Christopher M.. **Computer Vision**. Nova Jersey: Prentice-hall, 1982.

BESL, PAUL J.; JAIN, RAMESH C.. In: **Computer Vision and Pattern Recognition Conference**, 1985, São Francisco, California. Proceedings. IEEE 1985. P 430-451.

CANNY, John. A Computational Approach to Edge Detection. **Ieee Transactions On Pattern Analysis And Machine Intelligence**. Cambridge, p. 679-698. nov. 1986.

CARDOSO, O.; MACHADO, R. Gestão do conhecimento usando data mining: estudo de caso na Universidade Federal de Lavras. **Revista de administração Pública**, Rio de Janeiro, Vol 42, 495-528, Junho. 2008.

CARVALHO, Luís Alfredo Vidal de. **Datamining – A Mineração de Dados no**

Marketing, Medicina, Economia, Engenharia e Administração. Rio de Janeiro: Editora Ciência Moderna LTDA, 2005.

CHRISTMANN, Raul Udo. **Estatística aplicada**. São Paulo: Edgard Blucher, 1978. 135p.

COVER, T. M.; HART, P. E.. Nearest Neighbor Pattern Classification. **Ieee Transactions On Information Theory**, New Jersey, v. 13, n. 1, p.21-27, dez. 1967.

Fayyad, U.; Piatetsky-Shapiro, G.; Smyth P.. The KDD Process for Extracting Useful Knowledge from Volumes of Data ,**COMMUNICATIONS OF THE ACM**. [S. l.] Novembro de 1996/Vol. 39, No. 11.

GONZALEZ, Rafael C.; WOODS, Richard E.. **Processamento Digital de imagens**. 3. ed. São Paulo: Pearson, 2009. 624 p.

HARZALLAH, Hedi; JURIE, Frédéric; SCHMID, Cordelie. **Combining efficient object localization and image classification**. In: International Conference Computer Vision, 12, 2009, Kyoto. Proceedings. Granobra: IEEE, 2009. p. 237 – 244.

HU, Osvaldo Ramos Tsan; RAUNHEITTE, Luís Tadeu Mendes. **Processamento e Compressão Digital de Imagens**. São Paulo: Editora Mackenzie, 2004.

JAIN, Ramesh; KASTURI, Rangachar; SCHUNCK, Brian G.. **Machine Vision**. Nova Iorque: Mcgraw-hill, 1995.

KOHAVI, Ron, 1995. **Study of a cross-validation and bootstrap for accuracy estimation and model selection**. Disponível em: <<http://web.cs.iastate.edu/~jtian/cs573/Papers/Kohavi-IJCAI-95.pdf>>. Acesso realizado em 18/10/2013.

MÄKINEN, Erno; RAISAMO, Roope. An experimental comparison of gender classification methods. **Pattern Recognition Letters**. Tampere, p. 1544-1556. abr. 2008.

O'Hara, S. & Draper, B.A., 2011. **Introduction to the Bag of Features Paradigm for Image Classification and Retrieval**. Disponível em: <<http://arxiv.org/abs/1101.3354>>. Acesso realizado em 08/06/2013.

SAFAVIAN SR, Landgrebe D. **A survey of decision tree classifier methodology**. Maio de 1991.

SCHIELE, Bernt; CROWLEY, James L.. Object recognition using multidimensional receptive field histograms. In: ECCV '96 PROCEEDINGS OF THE 4TH EUROPEAN CONFERENCE ON COMPUTER VISION, 4., 1996, Grenobla. **Proceedings...**. Grenobla: Springer Berlin Heidelberg, 1996. v. 1, p. 610 - 619.

SILVA, Leandro Augusto da. **Mineração de Dados: Uma abordagem introdutória e ilustrada**. São Paulo: Mackenzie, 2015. 153 p.

TAN, Pang-ning; STEINBACH, Michael; KUMAR, Vipin. **Introduction to Data Mining**. Boston: Pearson, 2005.

WANG, Li; HE, Dong-chen. TEXTURE CLASSIFICATION USING TEXTURE SPECTRUM. **Pattern Recognition**. Grã-bretanha, p. 905-910. 1 jun. 1989.

W3C.**JavaScript RegExp Reference**. 2015. Disponível em: <http://www.w3schools.com/jsref/jsref_obj_regexp.asp>. Acesso em: 16 jan. 2015.