

Estudo e implementação de técnicas para identificação de anuros em imagem

Angélica Larissa Marques Queiroz¹, César Alberto da Silva², Andrea Padovan Jubileu¹, Linnyer Beatrys Ruiz³,

¹ Instituto Federal de São Paulo (IFSP)
Departamento de Ciência da Computação
Rua José Ramos Júnior 27-50, 19470-000, Presidente Epitácio, SP, Brasil

² Universidade Federal de Minas Gerais (UFMG),
Programa de Pós-Graduação em Engenharia Elétrica
Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil

³ Universidade Estadual de Maringá (UEM)
Programa de Pós-Graduação em Ciência da Computação
Av. Colombo 5790, 87020-900, Maringá, PR, Brasil
laryssa_here@hotmail.com, casilva91@gmail.com, andreapjubileu@ifsp.edu.br,
linnyer@gmail.com

Abstract. This paper describes the process used in extracting characteristics of Anurans in pictures and it makes a comparison between J48, Random Tree and Random Forest classification algorithms. Two scenarios for evaluation were defined: in the first one we used two classes to represent objects in the image and in the second scenario five classes were used. The Random Forest algorithm obtained best result in the classification of data in relation to J48 algorithms and Random Tree.

Keywords: Frog, Pattern, Recognition, Segmentation, Image.

1 Introdução

Ao longo dos anos o ser humano tem causado danos à natureza, resultando na redução da biodiversidade e da qualidade de vida no mundo. Alguns animais têm sido usados como bioindicadores dessas mudanças [1], como por exemplo os anuros (sapos, rãs e pererecas). Estudar os costumes desses animais no seu ambiente natural é importante para a conservação da natureza. Por exemplo, as transformações no habitat são tão significativas que prejudicam a reprodução desses anfíbios, sendo notória a perda na população.

Atualmente, existem variadas soluções para monitoramento ambiental que utilizam tecnologias de comunicação sem fio. Dentre essas propostas, destaca-se a Rede de Sensores Sem Fios (RSSF), que é considerada pouco invasiva ao ambiente [2]. Essas redes são formadas por centenas ou milhares de nós sensores equipados com sensores para detecção de fenômenos tais como iluminação, umidade do ar, temperatura, etc [3]. As imagens utilizadas neste trabalho foram coletadas por uma Rede de Sensores Multimídia Sem Fios (RSMSF) formada por dispositivos que utilizam

microcontroladores Arduino equipado com câmera OV2640, shield ArduCAM e com o módulo XBee para a transferência das imagens até a estação base. As imagens capturadas possuem dimensão 320x240 pixels. Não faz parte deste trabalho descrever a implementação da RSMSF e sim o processo para identificação de anuros em imagens.

O principal objetivo desse trabalho é estudar técnicas de extração de características dos anuros para reconhecê-los nas imagens. A extração das características é uma etapa crucial no processo de reconhecimento. O reconhecimento de padrões é um processo pertinente à área de Aprendizado de Máquina [4].

Este artigo apresenta o processo para extração de características de anuros em imagens e compara o resultado dos algoritmos de classificação J48, *Random Tree* e *Random Forest* para extração de um padrão para identificar anuros em imagens.

O trabalho está dividido em 5 seções. Na seção 2, é descrita a metodologia de pesquisa utilizada. Na seção 3 são apresentados os trabalhos relacionados ao tema desta pesquisa. Os resultados obtidos são apresentados na seção 4. Por fim, na quinta seção contém as conclusões do trabalho.

2 Metodologia de Pesquisa

O método científico adotado neste trabalho é o indutivo porque a partir do estudo de diversas particularidades, deseja-se chegar a um resultado geral. A partir do estudo dos descritores locais invariantes, dos algoritmos de reconhecimento de objetos, das técnicas de reconhecimento de padrões, dos algoritmos e softwares para o reconhecimento de imagens, pretende-se reconhecer a existência ou não de anuros nas imagens.

Este trabalho pode ser classificado como uma pesquisa aplicada porque pretende implementar uma solução para um problema específico: o reconhecimento de anuros em imagens. Trata-se de uma pesquisa exploratória porque envolve o levantamento bibliográfico, realização de experimentos práticos e análise dos resultados para a compreensão do problema estudado. Além disso, este trabalho visa produzir conhecimentos, adquirir experiência, contribuir para a discussão da área ou fazer avançar o debate acerca dos assuntos abordados.

Considerando que é apresentado o resultado estatístico do percentual de imagens com anuros identificados corretamente com o uso dos algoritmos J48, *Random Tree* e *Random Forest*, esta pesquisa é classificada além de qualitativa também quantitativa.

Para atingir os objetivos, inicialmente foi realizada uma revisão bibliográfica sobre os principais assuntos desta pesquisa: Técnicas de Reconhecimento de Padrões, Visão Computacional, Segmentação de Imagens, Aprendizado de Máquina e Algoritmos de Classificação.

3 Trabalhos Relacionados

Pesquisas para detecção de animais têm sido realizadas a fim de monitorar e rastrear animais para compreender seu comportamento com o ambiente, prevenir

colisões em veículos em rodovias e prevenir a entrada de animais perigosos em área residencial [5]. Nesta seção são apresentados alguns trabalhos que fazem a identificação de outros animais em imagens, uma vez que não foram encontrados na literatura trabalhos que utilizem imagens coletadas por RSMSF para identificação de anuros.

[6] implementaram um algoritmo para segmentação e extração de características para representar as pegadas dos animais. Embora as espécies dos animais utilizadas no experimento não tenham sido divulgadas, os autores utilizaram um conjunto contendo 25 animais com um total de 150 pegadas foi obtido na internet. A identificação da espécie dos animais é baseada no cálculo das características morfológicas de cada pegada. O vetor de características da imagem é formado por: Sete Momentos invariantes de Hu, Proporção do aspecto, Retangularidade, Contraste, Uniformidade, Homogeneidade, Entropia, Proporção de componentes, Área da pegada, Diferença da área, Relação do tamanho do perímetro e *Narrow Factor*. Foram utilizados três fórmulas de distância para classificação das imagens: Distância Euclidiana, *City Block Distance* e *Canberra Distance*. No experimento realizado, além dessas três fórmulas, também foi usada uma combinação entre as três fórmulas. A distância euclidiana apresentou o pior resultado (86%) e as outras obtiveram 97% de taxa de precisão, como mostra a Tabela 1.

Table 1. Taxa de precisão obtida na classificação das espécies de animais [6].

| Métodos | Taxa de precisão |
|----------------------|------------------|
| Distância euclidiana | 86% |
| City Block Distance | 97% |
| Canberra Distance | 97% |
| Combinado | 97% |

Um sistema para detecção de cachorros em imagens é apresentado por [5]. Uma câmera captura o vídeo do ambiente monitorado que em seguida é convertido em frames (imagens). Na detecção do objeto é utilizado um método para a remoção do fundo da imagem. Os autores destacam dois desafios nesse processo: mudanças de iluminação e os objetos não estacionários, como por exemplo, chuva, folhas e sombras. De acordo com [7], normalmente, três métodos são utilizados para a detecção do fundo da imagem: *optical flow*, *background subtraction* e *frame differencing*. No trabalho apresentado por [5] foi utilizado o método *frame differencing* que utiliza a diferença de pixels entre frames consecutivos. O experimento foi realizado no Matlab e foram utilizadas 5000 imagens obtidas em várias posições. A eficiência do sistema proposto calculada e validada manualmente por quatro parâmetros: *true positive* (TP), *true negative* (TN), *false positive* (FP) e *false negative* (FN). *True positives* e *true negatives* são classificações corretas. *False positive* é quando o modelo prevê que o resultado deve ser positivo, mas, ao invés disso, o valor obtido é negativo. De modo inverso, *false negative* ocorre quando o modelo prevê um resultado negativo, mas o valor obtido é positivo. A eficiência do algoritmo foi calculada pela equação (1) e obteve 86,25% de taxa de sucesso na detecção do animal.

$$Efficiency = \frac{TN+TP}{TN+TP+FN+FP} \quad (1)$$

[8] desenvolveram um sistema para reconhecimento de espécies de animais baseado no método *eigenface*. Normalmente, este método é utilizado para reconhecimento de face de humanos a partir de um conjunto de características que são relevantes para diferenciar uma face de outra. Os experimentos foram realizados com três tipos de animais: gambás, gatos e doninhas. No primeiro experimento as imagens continham diferentes imagens de fundo e o sistema desenvolvido obteve taxa de sucesso de 55% para gambás, de 33% gatos e de 45% para doninhas. No segundo experimento a imagem de fundo foi retirada e a taxa de sucesso aumentou, obtendo 65%, 52% e 64%, respectivamente para cada espécie de animal.

4 Identificação de anuros em imagens

Os bioindicadores da natureza estão ganhando cada vez mais importância devido ao aumento de trabalhos relacionados com a preservação do meio ambiente e ao grande investimento para monitorar as áreas de conservação [1]. O que pode afetar os estudos nessa área é a limitação ao formular soluções para o problema da visão computacional.

O campo da visão computacional estuda técnicas de extração de características dos objetos de uma imagem, considerando suas formas e outras informações relevantes. Sua diferença em relação ao processamento de imagens é que, enquanto esse refere-se à mudança de uma determinada figura em outras figuras, a partir de modificações inseridas na mesma, a visão computacional trata da obtenção e manipulação das informações de uma imagem e do uso desses dados para diversos fins [9].

Diferentes áreas do conhecimento estão relacionadas à visão computacional. Por exemplo a visão biológica, campo no qual a visão computacional se baseia. Enquanto a biologia estuda as atividades neurais envolvidas na formação e percepção das imagens pelos seres vivos, a visão computacional analisa todos os processos e algoritmos usados pelas máquinas para reconhecer o que os humanos reconhecem [9].

O processo de reconhecimento de um objeto é facilmente realizado pelos humanos porque faz parte das suas atividades cotidianas, como encontrar o automóvel no estacionamento, por exemplo. A partir do momento que o conceito carro é agregado ao universo de aprendizagem de uma pessoa, ela saberá reconhecer a vasta variedade de modelos de veículos, que diferenciam-se em cor, tamanho, entre outras características. Entretanto, é uma tarefa desafiadora em visão computacional [10].

De acordo com [11], algoritmos usados para reconhecer objetos nas imagens, não alcançaram os níveis de acertos de uma criança de dois anos. Segundo [12], para dez mil categorias de imagens, o melhor resultado de um algoritmo até hoje é menor que 5% quando comparado com o desempenho de um humano.

Geralmente, na imagem digital encontra-se um fundo, em companhia de um ou vários objetos. Portanto, os objetos podem ser definidos como regiões que diferenciam-se do fundo. Um caractere, uma silhueta, um animal, uma casa; são exemplos de objetos em uma imagem [13].

A complexidade está em reconhecer os objetos em diferentes cenas, posições e em todas as condições possíveis. A iluminação, por exemplo, afeta a aparência do objeto, dificultando muitas vezes a tarefa de identificá-lo [11].

O principal objetivo do reconhecimento de padrões (ou objetos) é separar os objetos em classes ou categoria, normalmente o sistema de reconhecimento de padrões pode ser dividido basicamente em cinco sub-sistemas: sensoriamento, segmentação, extração de características, classificação e pós-processamento [4].

No entanto, vale ressaltar que são etapas típicas, podendo ser acrescentadas outras no sistema. Neste trabalho, por exemplo, foi efetuado um pré-processamento nas imagens do cenário 1. Na edição, foram adicionados mais brilho e contraste. No cenário 2 foram usadas as imagens originais. A seguir, a Fig. 1 apresenta as etapas do sistema de reconhecimento de padrões realizadas neste trabalho.

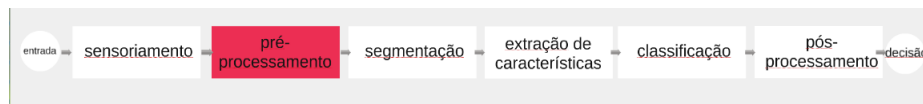


Fig. 1. Etapas realizadas neste trabalho para Identificar Anuros nas Imagens.

No estágio de sensoriamento, um sensor converte um fenômeno físico em um conjunto de dados [4]. Os dados coletados formam as imagens. A Fig. 2 mostra uma imagem de um ranário que foi capturada por uma RSMSF.



Fig. 2. Imagem de Anuros capturada por uma RSMSF.

Segundo [14], a segmentação, ou a etapa de detecção como também é chamada, é um processo importante para um reconhecimento bem sucedido, pois uma falha nesse momento pode comprometer todo o sistema de análise de imagens. A segmentação agrupa os pixels de maneira lógica para simplificar o problema da extração de informações a partir de imagens [15].

Neste trabalho, foi efetuada a segmentação por meio do Software Superpixel. Ele captura a redundância na imagem e reduz significativamente a complexidade das

tarefas subsequentes de processamento de imagens. Têm-se revelado cada vez mais útil para aplicações tais como estimativa de profundidade e segmentação de imagens. Os seus principais benefícios são: sua rapidez, a facilidade na usabilidade e a produção de produtos de alta qualidade de segmentação [16].

A abordagem do algoritmo *Simple Linear Iterative Clustering* (SLIC) é gerar superpixels agrupando pixels com base em sua semelhança de cor e proximidade do plano da imagem. Isto é feito em 5D [labxy], onde [lab] é o vetor de cor do pixel no espaço de cor CIELAB, e xy é a posição de cada pixel [16].

A Fig. 3 apresenta a segmentação através do software Superpixel. Foram usados valores padrões para os parâmetros do algoritmo de geração de superpixel SLIC.

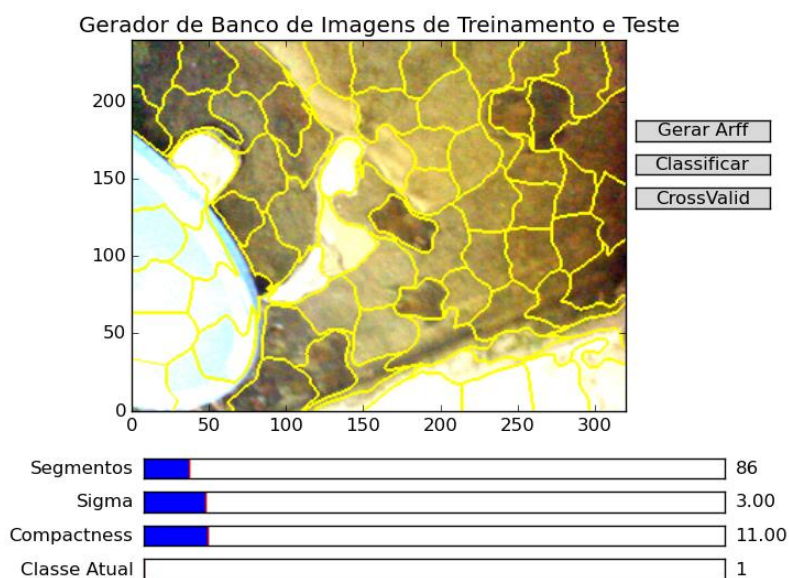


Fig. 3. Segmentação da Imagem através do Software Superpixel.

A possibilidade de compreender e interpretar o conteúdo das imagens é possível através da organização da grande quantidade de informações que a englobam. Normalmente, efetua-se uma análise geral da imagem para extrair uma informação (característica). A maior parte dos extratores de características, no entanto, não interpretam graficamente essas imagens, mas capturam informações numéricas e relevantes para distinguir e dividir os objetos (imagens de interesse), para indicar qual grupo de imagens pertencem à mesma classe [17].

Em cada cenário de teste, foram usadas trinta imagens para a seleção de características. Para classificar, em ambos os casos, foram utilizadas dez imagens.

Neste trabalho, os atributos extraídos dos superpixels foram separados por suas classes. No cenário 2, os atributos, foram separados em cinco classes: a primeira equivalente aos anuros, a segunda a bacia, a terceira ao chão, a quarta a parede e a quinta aos outros atributos que não se encaixam nos anteriores.

A imagem a seguir refere-se ao cenário de Teste 1. A Fig. 4 apresenta a extração de características da classe 1, os anuros, os objetos em questão.

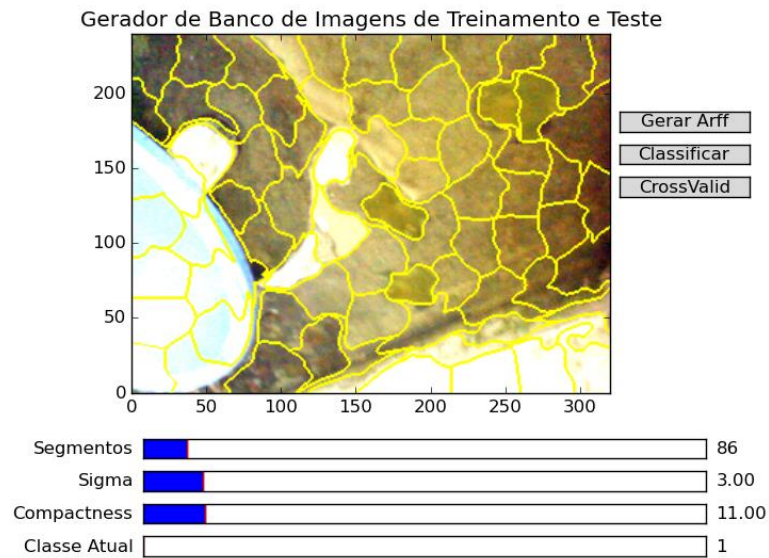


Fig. 4. Extração de Características da Classe 1- Cenário de Teste 1.

A Fig. 5 refere-se ao treinamento do cenário de Teste 2, a extração das características da classe 5.

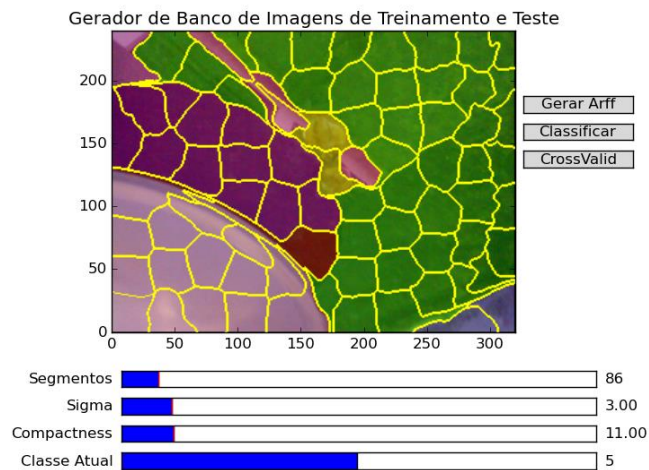


Fig. 5. Extração de Características da Classe 5- Cenário de Teste 2.

Por padrão, o algoritmo de aprendizagem usado pelo Superpixel é o J48. Na Fig. 6 encontra-se uma imagem do conjunto de teste sendo classificada. As características de

cada segmento são armazenadas em um arquivo ARFF que posteriormente é utilizado pelos algoritmos de classificação J48, *Random Tree* e *Random Forest*. Os algoritmos de classificação definem um padrão para classificação dos dados.




Fig. 6. Classificação pelo Algoritmo J48- Cenário de Teste 1.

No pós-processamento foi realizada a avaliação de desempenho dos diferentes classificadores para tomar a decisão final.

4 Resultados

Os algoritmos de aprendizagem foram construídos a partir dos atributos extraídos dos superpixels separados por suas classes.

No cenário 1, como pode ser observado na Tabela 2, o algoritmo de aprendizagem automática que obteve melhor resultado foi o *Random Forest*, seguido pelo J48 e por fim o *Random Tree*.

Table 2. Métricas de Desempenho para os algoritmos utilizados no Cenário 1.

| Algoritmos | Instâncias classificadas corretamente | Instâncias classificadas incorretamente |
|---------------|---------------------------------------|---|
| Random Forest | 93,9749% | 6,0251% |
| J48 | 90,9826% | 9,0174% |
| Random Tree | 90,1739% | 9,8261% |

No cenário 2, podemos notar através da Tabela 3, que o algoritmo de aprendizagem automática que obteve o melhor resultado foi novamente o *Random Forest*, seguido pelo J48 e por fim o *Random Tree*.

Table 3. Métricas de Desempenho para os algoritmos utilizados no Cenário 2.

| Algoritmos | Instâncias classificadas corretamente | Instâncias classificadas incorretamente |
|---------------|---------------------------------------|---|
| Random Forest | 71,6381% | 28,3619% |
| J48 | 61,8741% | 38,1259% |
| Random Tree | 57,2246% | 42,7754% |

5 Conclusões

Nota-se que o primeiro cenário comparado ao segundo, obteve maior êxito nas classificações corretas, concluindo-se que para a identificação do objeto, a divisão da imagem em poucas classes obteve melhor resultado. Ao observar os algoritmos *Random Forest* e J48, pode ser visto que estes, em comparação com o *Random Tree*, conseguiram classificar uma boa porcentagem dos anuros corretamente, porém, o restante da imagem está sendo classificado erroneamente, resultando assim com que áreas da imagem que não são anuros sejam classificadas como tais.

Agradecimento. Os autores agradecem o apoio do IFSP e do INCT NAMITEC pelo apoio no desenvolvimento desta pesquisa.

Referências

- Oliveira, M.A.d., Gomes, C.F.F., Pires, E.M., Marinho, C.A.G.S., Della Lucia, T.M.C.: Bioindicadores ambientais: insetos como um instrumento desta avaliação. *Revista Ceres* 61, 800-807 (2014), http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0034-737X2014000700005&nrm=iso
- Rivero, I.A.S.: Rede de Sensores sem Fio para Monitoramento de Equipamentos Eletrônicos. Master's thesis, Curso de Pós-graduação em Informática, Pontifícia Universidade Católica de Minas Gerais, Belo Horizonte, MG (2011)
- Dasgupta, R., Mukherjee, R., Gupta, A.: Congestion avoidance topology in wireless sensor network using karnaugh map. In: *Applications and Innovations in Mobile Computing (AIMoC)*, 2015. pp. 89-96 (Feb 2015)
- Araujo, G.M.: Algoritmo para Reconhecimento de Características Faciais Baseado em Filtros de Correlação. Master's thesis, Curso de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro (2010)
- Sharma, S.; Shah, D.; Bhavsar, R.; Jaiswal, B.; Bamniya, K. Automated detection of animals in context to indian scenario. In: *2014 5th International Conference on Intelligent Systems, Modelling and Simulation*, p. 334–338, Jan (2014)
- Alli, M.N.; Viriri, S. Animal identification based on footprint recognition. In: *2013 International Conference on Adaptive Science and Technology*, p. 1–4, Nov (2013)

7. Fei, M.; Li, J.; Liu, H. Visual tracking based on improved foreground detection and perceptual hashing. In: *Neurocomput.*, v. 152, n. C, p. 413–428, March (2015)
8. Lampert, C.H.; Nickisch, H.; Harmeling, S. Attribute-based classification for zero-shot visual object categorization. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 36, n. 3, p. 453–465, March (2014)
9. Rios, L.R.S.: *Visão computacional*. Universidade Federal da Bahia, Salvador, BA (2011)
10. Graciano, A.B.V.: *Modelagem e reconhecimento de objetos estruturados: uma abordagem estatístico-estrutural*. Ph.D. thesis, Curso de Ciência da Computação, Instituto de Matemática e Estatística da Universidade de São Paulo, São Paulo, SP (2012)
11. Lara, A.C.: *Descritor de bordas e quantização espacial flexível aplicados a categorização de objetos*. Ph.D. thesis, Curso de Ciência da Computação, Instituto de Matemática e Estatística da Universidade de São Paulo, São Paulo, SP (2013)
12. Deng, J., Berg, A.C., Li, K., Fei-Fei, L.: *What Does Classifying More Than 10,000 Image Categories Tell Us?*, pp. 71-84. Springer Berlin Heidelberg, Berlin, Heidelberg (2010), http://dx.doi.org/10.1007/978-3-642-15555-0_6
13. López, G.A.P.: *Aforapro: Reconhecimento de Objetos Invariante sob transformações afins*. Master's thesis, Curso de Engenharia Elétrica, Escola Politécnica da Universidade de São Paulo, São Paulo, SP (2011)
14. Farina, A.M.: *BioMobile: Sistema de Identificação de Usuários em Dispositivos Móveis na Plataforma Android Utilizando Reconhecimento de Faces a Partir de Vídeo*. Master's thesis, Curso de Ciências de Computação. Universidade Estadual Paulista Júlio de Mesquita Filho, São José do Rio Preto, SP (2012)
15. Jussiani, V.B.: *Combinação de Atributos de Textura e Cor para Avaliação Automática de Estrias Atróficas*. Master's thesis, Curso de Engenharia de Computação, Universidade Católica Dom Bosco, Campo Grande, MS (2015)
16. Achanta, R., Shaji, A., Smith, K., Lucchi, A, Fua, P., Susstrunk, S.: *Slic superpixels*. Tech. rep., École Polytechnique Fédérale de Lausanne (2010)
17. Mamani, G.E.H.: *Seleção supervisionada de características por ranking para processor consultas por similaridade em imagens médica*. Master's thesis, Curso de Ciência de Computação e Matemática Computacional, Instituto de Ciências Matemáticas e de Computação, São Carlos, SP (2012)