

Seleção de Atributos para a Segmentação do Couro Bovino.

Lia Nara Balta Quinta
Grupo de Pesquisa em Engenharia e Computação
Universidade Católica Dom Bosco
Av. Tamandaré, 6000, Jardim Seminário
79117-900 Campo Grande, MS
lianaraq@gmail.com

Hemerson Pistori
pistori@ucdb.br

Resumo

O projeto DTCOURO¹ tem como objetivo desenvolver um sistema que realize a detecção das imperfeições do couro bovino usando técnicas de visão computacional baseadas em textura. No couro bovino a variação de textura é muito grande, por esse motivo técnicas de extração de atributos foram implementadas neste projeto. Este trabalho tem como objetivo realizar experimentos com a fusão de características dos algoritmos de extração de atributos presentes no projeto DTCOURO, selecionar os atributos extraídos e segmentar a peça de couro usando as informações selecionadas. Após segmentar a imagem estimar a área do couro bovino. Os experimentos realizados usaram imagens no estágio couro cru e wet-blue, com fundo branco e madeirado. Os resultados foram satisfatórios, tanto na seleção de atributos e na segmentação de imagens quanto na estimativa da área da peça de couro.

1. Introdução

No setor coureiro Brasileiro, uma parte significativa das peças de couro produzidas são de baixa qualidade. As maiores causas dos defeitos presentes no couro bovino são oriundas do manejo incorreto dos animais no meio rural. Dentre as principais causas, destacam-se os riscos ocasionados por pregos e parafusos e marcas de ferrões, usados no manejo do gado. Esses defeitos depreciam o material, ocasionando um menor retorno financeiro à essas peças de couro, quando comparadas à peças de boa qualidade[3].

A classificação do couro bovino é realizada por um especialista que analisa a peça de couro e atribui a esta uma classificação. Discordâncias em relação à classificação são

comuns devido ao fato desta tarefa estar sujeita a subjetividade humana[3].

Diante dessa situação surgiu o projeto DTCOURO que está sendo desenvolvido pelo Grupo de Pesquisa de Engenharia e Computação (GPEC) na Universidade Católica Dom Bosco (UCDB) em parceria com a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) Gado de Corte. Esse projeto almeja um sistema capaz de capturar e processar imagens de couro bovino, realizando tanto a detecção dos defeitos quanto a classificação dessas peças. Com a criação desse sistema, a classificação tornar-se-á mais segura e imparcial, aumentando sua precisão.

O couro bovino apresenta uma variação de texturas, tonalidades e espessuras muito grande. Devido a esses fatores, algoritmos de extração de atributos foram implementados afim de obter a extração mais adequada para cada tipo de ambiente e estágio da peça de couro. Nesse trabalho foram utilizados os estágio couro cru, exemplificado nas Figuras 1 (a) e (b) e wet-blue (c) e (d). Os métodos de extração de atributos usados nesse trabalho foram: Padrões Binários Locais (*Local Binary Pattern*), Mapas de Interação, Matriz de Co-ocorrência e Filtros de Gabor, esses métodos estão implementados no projeto DTCOURO. Este trabalho teve a finalidade de realizar experimentos com a fusão dos atributos obtidos com estes métodos através de diferentes algoritmos de seleção de atributos presentes no WEKA e usar essas informações para segmentar uma imagem em duas classes, couro e fundo, com o objetivo de evidenciar somente a peça de couro. Para realizar o cálculo da imagem, o sistema foi calibrado através de uma moeda, com essa referência a área da imagem foi estimada.

A seção 2 apresenta as técnicas de extração de atributos utilizadas neste trabalho, as seções 3 e 4 tratam de seleção de atributos e segmentação, respectivamente. A seção 5 relata os experimentos, as seções 6 e 7 apresentam, respectivamente, a conclusão e os trabalhos futuros.

¹ Detecção Automática de Defeitos em Pele e Couro Bovino, <http://www.gpec.ucdb.br/projetos/dtcouro/>

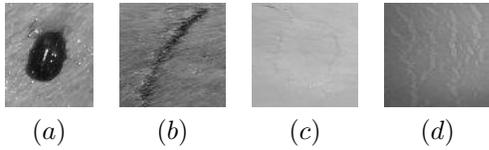


Figura 1. (a) carrapato e (b) risco fechado no estágio couro cru, (c) marca a fogo e (d) estria no estágio *wet-blue*.

2. Extração de Atributos

O objetivo da extração de atributos (características) é evidenciar diferenças e semelhanças entre objetos. As características podem ser analisadas levando em consideração cor, brilho, textura, dentre outros. Existem várias maneiras de extrair atributos de uma imagem. A forma de apresentação desses atributos pode ocorrer de maneira numérica, como centro de massa ou de maneira descritiva como no caso da diferenciação de gestos[7]. Neste trabalho a extração de atributos é aplicada com o objetivo de encontrar a distinção entre as classes (couro e fundo), para a realização dessa tarefa pode-se extrair características de formas, cores, ângulos, regiões, entre outras. Essa seção apresenta algumas técnicas de extração de atributos, essas técnicas fazem parte do projeto DTCOURO. Somente Padrões Binários Locais e Mapas de Interação serão descritas nesta seção pelo fato de serem técnicas menos clássicas como Matriz de Co-ocorrência[4] e Filtrros de Gabor[9].

2.1. LBP - Padrões Binários Locais

O LBP é um método de extração de atributos em tons de cinza. Consiste em atribuir um valor a cada *pixel* de uma imagem de acordo com a variação na intensidade do *pixel* em relação aos seus vizinhos. Várias aplicações utilizam o método LBP, dentre elas podemos destacar o reconhecimento de faces e texturas[6][13][8].

A Figura 2 (a) representa uma imagem na forma de matriz. Cada posição dessa matriz representa um *pixel* da imagem. O método realiza uma varredura na imagem e para cada *pixel* calcula sua vizinhança através de um número de vizinhos v e um raio r . Por exemplo, o *pixel* (2,3) da matriz da Figura 2 (a), com $r=1$ e $v=8$, terá a vizinhança conforme ilustrado na Figura 2 (b). Posteriormente ocorre uma comparação do valor da intensidade do *pixel* central, no caso (2,3), com cada *pixel* vizinho. Os vizinhos que possuem valor maior ou igual ao *pixel* central recebem 1 e os menores 0, conforme ilustração presente na Figura 2 (c). Os valores binários são convertidos para decimais e a soma destes é o valor do LBP para o *pixel* (2,3).

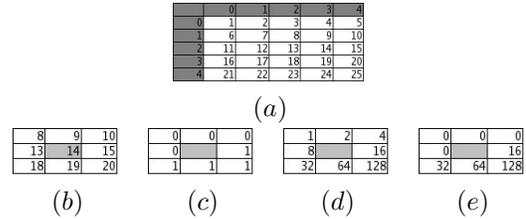


Figura 2. Exemplo do método LBP.

2.2. Padrões Binários Locais Invariantes à Rotação

Com o intuito de aprimorar o método LBP, surgiu o LBPROT, Padrões Binários Locais Invariantes à Rotação. O LBPROT realiza uma rotação, “*shift*” circular à direita, na cadeia de binários ilustrada na Figura 2 (c), afim de encontrar um atributo que seja invariante à rotação. O número de rotações realizadas é igual ao tamanho da cadeia em questão. A cada rotação na cadeia de binários o valor decimal dessa cadeia é calculado, após realizada todas as rotações, o menor valor é escolhido[10] [5][8].

2.3. Mapas de Interação

O método baseado em mapas de interação analisa os pares de tons de cinza de uma imagem. Permite a análise de atributos como entropia, dissimilaridade, contraste, momento da diferença inversa, segundo momento angular e diferença inversa de uma imagem.

O método percorre a imagem e a cada *pixel*, dado um valor do ângulo a e uma distância d , encontra um outro *pixel*. Com a informação dos dois *pixels* calcula o módulo da diferença entre os pares de tons de cinza e armazena este valor em uma matriz. Esta matriz, chamada de mapa polar de interação, terá dimensões iguais às variações de distâncias e ângulos. O valor da diferença entre os tons de cinza é armazenado na posição referente ao valor do ângulo e da distância respectivamente. Os valores seguintes são somados às suas respectivas posições até que a varredura da imagem seja concluída[1]. Nesses experimentos foram usados as distâncias de 1, 2 e 3 *pixels* e ângulos de 0° à 180° com incremento de 45° .

3. Seleção de atributos

O objetivo da seleção de atributos é encontrar um subconjunto que represente, de forma mais relevante, as classes em um determinado problema de classificação. Esse subconjunto deve possuir a mesma porcentagem de acerto com a menor quantidade de atributos possíveis. Neste trabalho, o conjunto inicial é representado pelo resultado da extração

de atributos, das classes couro e fundo, de todos os métodos usados nesse trabalho. Em seguida são apresentados os algoritmos de seleção de atributos usados nesse trabalho, esses algoritmos fazem parte do WEKA.

3.1. Subida da encosta

O objetivo deste algoritmo é encontrar o melhor valor local. Para a escolha deste valor, todas as possibilidades de escolha são consideradas, porém o sentido sempre segue em direção do valor crescente, por este motivo, alguns autores o conhecem como algoritmo de busca gulosa local[12].

Porém este algoritmo apresenta alguns problemas, como os platôs que são regiões planas encontradas no caminho da subida. Diante dessa situação o algoritmo da subida da encosta apresenta certa dificuldade na solução, pelo fato de “enxergar” apenas os valores vizinhos dos nós analisados. Os máximos locais, representam o valor máximo encontrado dentre os vizinhos, porém menor que o máximo global²[12].

3.1.1. Best-First search O método best-first search tem como objetivo selecionar o nó mais promissor dentre os gerados. Para a escolha desse nó é usada uma função de avaliação. Se não houver nó a ser expandido, uma mensagem de falha é retornada, caso contrário a expansão ocorrerá. A parada ocorre quando o estado “meta” é encontrado, nesse caso a solução é retornada[12].

3.1.2. Busca gulosa O objetivo deste algoritmo é expandir o nó com menor custo entre as transições, com o intuito de obter a solução mais rápida. Para a avaliação dos nós usa-se a heurística $f(n)=h(n)$, sendo que $h(n)$ representa o custo entre as transições[12].

O problema apresentado por este método é o fato deste poder escolher um caminho maior, visto que leva em consideração apenas a transição dos nós não possuindo retorno, desse modo o algoritmo não pode testar outras rotas. A Figura 3 ilustra um exemplo da aplicação do algoritmo.

3.2. Algoritmos Genéticos

Os algoritmos genéticos³ (AG) são uma técnica inspirada no processo evolutivo e na genética. O ponto de partida desse algoritmo é uma população inicial gerada aleatoriamente. A avaliação dessa função é baseada na proximidade da mesma com a solução do problema. Os melhores atributos servirão de base para as próximas populações. O processo evolutivo prossegue até que se chegue a soluções satisfatórias[12].

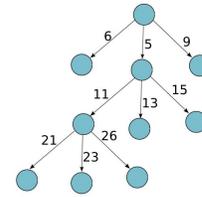


Figura 3. Exemplo do algoritmo Greedy Search.

4. Segmentação

O objetivo da segmentação de textura é identificar um objeto de acordo com regiões similares em uma imagem. Para obter uma melhor segmentação pode-se melhorar a qualidade da classificação do algoritmo. Vários estudos estão sendo realizados nesta área, um deles realiza a fusão da Matriz de co-ocorrência com Filtro de Gabor. Estes atributos foram testados individualmente, em duplas e as mesmas duplas de atributos foram submetidas à análise de Componentes Principais (PCA) e pelo contraste de características (FC)[2]. Já [14] usou a extração e seleção de atributos com o intuito de reconhecer uma malha viária e demais componentes do transporte urbano, para alcançar esse objetivo foram usados os algoritmos genéticos e algoritmo de busca exaustiva por máxima verossimilhança exaustiva.

Neste trabalho foram usados algoritmos para a seleção das características da fusão dos métodos LBP, Mapas de Interação, Matriz de Co-ocorrência e Filtros de Gabor. Essa seleção foi realizada pelos métodos *best-first*, algoritmos genéticos e busca gulosa. Com os atributos selecionados a imagem foi segmentada.

5. Experimento

Para a realização dos experimentos foram usadas 2 imagens de couro no estágio couro cru e 6 imagens do couro no estágio *wet-blue*, sendo que 3 possuem fundo madeirado e as demais fundo branco. As imagens foram selecionadas do banco de imagens do projeto DTCOURO, essas imagens foram capturadas por uma câmera digital em visitas técnicas a frigoríficos e curtumes. Todas as imagens usadas nos experimentos apresentam resolução de 640x480 *pixels*. A Figura 4 ilustra exemplos de imagens usadas nos testes⁴.

O objetivo dos experimentos é encontrar um conjunto que represente as classes usadas nesse trabalho, couro e fundo, que possua a menor quantidade de atributos sem perda na porcentagem de acerto. Após encon-

² Valor mais alto (pico mais alto)

³ Genetic search

⁴ As imagens no estágio *wet-blue* usadas nos experimentos são imagens pequenas que imitam o contorno das peças do couro bovino.

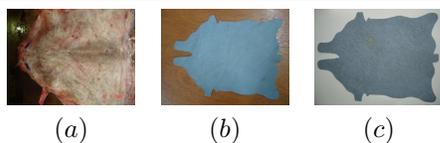


Figura 4. Exemplos de imagens usadas nos experimentos (a) couro cru, (b) *wet-blue* com fundo madeirado e (c) *wet-blue* com fundo branco.

trar esse conjunto, usá-lo como base para a segmentação da imagem. Com a imagem segmentada, estimar a área do couro usando uma moeda para calibrar o sistema. Para extrair características das imagens foram utilizados algoritmos de extração de atributos presentes no projeto DTCOURO, sendo eles: LBP, Mapas de interação, Matriz de co-ocorrência e Filtros de Gabor. Para a etapa de seleção de atributos foram utilizados os métodos *best-first*, busca gulosa e algoritmos genéticos, esses algoritmos estão implementados no WEKA.

Selecionadas as imagens, iniciou-se a etapa de marcação, sendo que nesta fase foram marcadas regiões das classes couro e fundo. Realizadas as marcações, foram obtidas amostras de 40x40 *pixels* com espaçamento de 2 *pixels* entre cada amostra. No estágio *wet-blue* com fundo madeirado foram extraídas 2598 amostras de couro e 1454 amostras de fundo. Já no estágio *wet-blue* com fundo branco foram extraídas 2369 amostras de couro e 1203 amostras de fundo. No estágio couro cru totalizaram 2352 amostras de couro e 4457 amostras de fundo.

O conjunto de dados foi submetido aos métodos de seleção de atributos e, para cada experimento, obteve-se um subconjunto de informações selecionadas. O subconjunto escolhido é composto pelo menor conjunto de atributos que represente as classes tratadas nesse trabalho sem perda na porcentagem de acerto. Este subconjunto foi usado como base para a segmentação da imagem. Para a segmentação, a imagem é percorrida e são extraídas amostras com a mesma configuração, tamanho e distância entre *pixels*, das amostras extraídas na etapa inicial. As informações obtidas são classificadas pelo algoritmo de classificação escolhido, para estes experimentos foi usado o algoritmo C4.5[11]. O resultado da classificação da amostra em questão recebeu uma cor escolhida pelo usuário, a cor escolhida nesses experimentos foi preto para couro e para o fundo a cor não sofreu alteração, logo este ficou com sua coloração natural. Na classificação, a árvore do algoritmo C4.5 foi treinada com os atributos selecionados. A imagem em questão foi percorrida e, a cada dois *pixels* no eixo *x* e dez no eixo *y*, uma nova amostra foi capturada. Para cada amostra os algoritmos de extração de atributos foram aplicados e os resulta-

	QCI	QSC
Best-First	90	8
Busca gulosa	90	8
Algoritmos genéticos	90	29

Tabela 1. Resultados da seleção de atributos no estágio couro cru. Na segunda coluna são apresentados a quantidade de atributos no conjunto inicial e na terceira coluna a quantidade de atributos no subconjunto.

dos foram classificados pela árvore de decisão. Na extração de características, foram extraídos apenas os atributos usados para o treinamento da árvore. Os parâmetros para o deslocamento usados nesse trabalho foram os valores que obtiveram os melhores resultados.

Para os testes da área da imagem, foi usada uma moeda de R\$0,05 centavos, este objeto foi escolhido por ser de fácil acesso e possuir área fixa e conhecida. A moeda foi capturada através de uma ROI (região de interesse) e foi obtida a quantidade de *pixels* presente na moeda. Armazenados os dados da moeda, a região com cor preta na imagem segmentada foi analisada e a quantidade de *pixels* calculada. Com as informações da quantidade de *pixels* da moeda, da peça de couro segmentada e da área real da moeda, uma regra de três foi aplicada e a área da peça de couro foi estimada.

6. Discussão dos resultados

O conjunto inicial de atributos foi comparado ao subconjunto selecionado, os resultados estão presentes nas Tabelas 1, 2 e 3. Como esse trabalho tem objetivo de encontrar o conjunto que possua a menor quantidade de atributos sem perda de resultado, as porcentagens de acerto do conjunto inicial e do subconjunto, permaneceram as mesmas.

A Tabela 1 mostra os resultados da seleção de atributos no estágio couro cru. A porcentagem de acerto foi de 99,98%. As siglas QCI e QSC, correspondem à quantidade de atributos no conjunto inicial e à quantidade de atributos no subconjunto, respectivamente.

A Tabela 2, mostra os resultados da seleção de atributos no estágio *wet-blue* com fundo madeirado. A porcentagem de acerto foi de 100,00%.

A Tabela 3, mostra os resultados da seleção de atributos no estágio *wet-blue* com fundo branco. A porcentagem de acerto foi de 99,97%.

Os resultados da seleção de atributos foram usados para segmentar uma imagem de couro. A Figura 5 ilustra a segmentação de uma imagem de couro bovino no estágio *wet-blue* com fundo branco submetida ao método de seleção de atributos busca gulosa. Pode-se perceber que houve

	QCI	QSC
Best-First	90	6
Busca gulosa	90	6
Algoritmos genéticos	90	31

Tabela 2. Resultados da seleção de atributos no estágio *wet-blue* com fundo madeirado. Na segunda coluna são apresentados a quantidade de atributos no conjunto inicial e na terceira coluna a quantidade de atributos no subconjunto.

	QCI	QSC
Best-First	90	37
Busca gulosa	90	37
Algoritmos genéticos	90	42

Tabela 3. Resultados da seleção de atributos no estágio *wet-blue* com fundo branco. Na segunda coluna são apresentados a quantidade de atributos no conjunto inicial e na terceira coluna a quantidade de atributos no subconjunto.

uma boa segmentação, porém com confusões na regiões de tonalidades semelhantes.

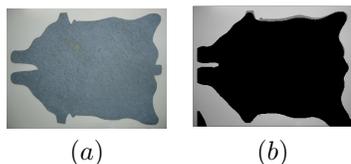


Figura 5. Imagens *wet-blue* com fundo branco, (a) imagem original e (b) imagem segmentada.

Observou-se que os algoritmos *best-first* e busca gulosa levam em consideração atributos distintos, por exemplo, dissimilaridade, correlação, entropia alguns atributos do LBP e Gabor. Já os algoritmos genéticos trabalham com vários atributos de um mesmo método caso todos não sejam escolhidos e utilizam em poucos testes os atributos do método LBP.

Como visto, os resultados para os experimentos com imagens com fundo madeirado e imagens couro cru obtiveram resultados com um número de atributos muito baixo em relação ao conjunto inicial. Tal fato é justificado pela

grande diferença apresentada entre as classes. A distinção entre *wet-blue* e madeira é muito grande o mesmo acontece com o fundo escuro e o couro claro, estágio couro cru, desse modo, um pequeno conjunto de atributos é capaz de caracterizar cada classe (couro e fundo).

A Figura 6 mostra algumas imagens usadas para os testes da área da imagem. Para verificar a veracidade dos resultados também foram usadas imagens com a área já conhecida e posteriormente os testes com as imagens do projeto DTCOURO foram realizados. A Figura 6 (a) possui área estimada de 29cm^2 e a Figura 6 (b) possui área estimada de $5,34\text{m}^2$. Nos experimentos com imagens cujos objetos possuíam áreas conhecidas, em 87,5% dos casos o sistema acertou 97% da área da peça de couro.

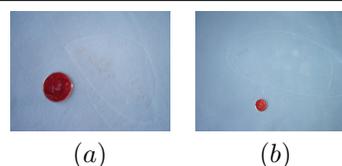


Figura 6. Exemplos de imagens usadas no experimentos para cálculo da área.

7. Conclusão e trabalhos futuros

Nos resultados da seleção de atributos observou-se uma diminuição significativa na quantidade de atributos selecionados. Em relação à estimativa da área da peça de couro o sistema comportou-se de forma satisfatória.

Estima-se que em um futuro próximo, com um banco de imagens com um maior número de fotografias, os atributos para cada tipo de estágio do couro bovino (couro cru e *wet-blue*) sejam fixados. Com isto serão extraídos apenas atributos relevantes a cada situação, sem perda na porcentagem de acerto. A extração de apenas um subconjunto específico torna tanto a extração quanto a segmentação tarefas mais rápidas, enriquecendo, ainda mais, o projeto DTCOURO.

A alta porcentagem de acerto apresentada na classificação, o baixo número de imagens usadas nos testes pode ter contribuído para este fato. As imagens presentes no banco do projeto DTCOURO são imagens preliminares e não possuem o plano da peça de couro paralelo ao plano da câmera, porém tais características foram assumidas para a realização dos experimentos. Como trabalho futuro pretende-se realizar visitas técnicas com os equipamentos específicos (grua, tripé, etc), para obter imagens mais padronizadas e com planos, de câmera e peça do couro, paralelos. Ampliar o número de algoritmos de

seleção de atributos, aprimorar os critérios de seleção de atributos. E realizar experimentos com um maior conjunto de imagens, a ampliação do conjunto de imagens tem como objetivo testar as técnicas utilizadas neste trabalho em novas situações, tais como: novas pelagens, tonalidades, etc.

8. Agradecimentos

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco, UCDB, da Agência Financiadora de Estudos e Projetos, FINEP. O co-autor é bolsista de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora do CNPQ e a autora recebeu bolsa do CNPQ.

Referências

- [1] D. Chetverikov. Structural filtering with texture feature based interaction maps: Fast algorithm and applications. In *In Proceedings of International Conf. on Pattern Recognition*, volume 2, pages 795–799, 1996.
- [2] D. A. Clausi and H. Deng. Feature fusion for image texture segmentation. In *17th International Conference on Pattern Recognition*, volume 1, pages 23–26, august 2004.
- [3] A. Gomes. Aspectos da cadeia produtiva do couro bovino no Brasil e em Mato Grosso do Sul. In *Palestras e proposicoes: Reunioes Tecnicas sobre Couros e Peles, 25 a 27 de setembro e 29 de outubro a 1 de novembro de 2001*, pages 61–72. Embrapa Gado de Corte, 2002.
- [4] A. Latif-Amet, A. Ertuzun, and A. Ercil. An efficient method for texture defect detection: Sub-band domain co-occurrence matrices. *Image and Vision Computing*, 18(6):543–553, May 2000.
- [5] M. P. T. O. T. Mäenpää. Multiresolution gray scale and rotation invariant texture classification with local binary patterns. In *IEEE Transactions on Pattern Analysis and Machine Intelligence* 24, pages 971–987, 2002.
- [6] T. Mäenpää. The local binary pattern approach to texture analysis. Master’s thesis, University Oulu, 2003.
- [7] M. S. Nixon and A. S. Aguado. *Feature Extraction and Image Processing*. Butterworth-Heinemann, 2002.
- [8] T. Ojala, M. Pietikäinen, and T. Mäenpää. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Trans. Pattern Anal. Mach. Intell.*, 24(7):971–987, 2002.
- [9] A. L. Pasquali, R. Rodrigues, R. Viana, and H. Pistori. Extração de características utilizando filtro de gabor aplicado à identificação no couro bovino. In *Hifen*, pages 99–105.
- [10] M. Pietikäinen, T. Mäenpää, and T. Ojala. Gray scale and rotation invariant texture classification with local binary pattern. In Springer, editor, *Computer Vision, Sixth European Conference on Computer Vision Proceedings, Lecture Notes in Computer Science 1842*, pages 404 – 420, 2000.
- [11] J. R. Quinlan. *C4.5: programs for machine learning*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 1993.
- [12] S. Russel and P. Norvin. *Inteligência Artificial*. Prentice Hall.
- [13] C. L. Sanches. Novel image processing of 3d textures. Master’s thesis, Heriot Watt University, september 2003.
- [14] J. C. Santos, J. R. de Freitas Oliveira, L. V. Dutra, S. J. S. Sant’Anna, and C. D. Rennó. Seleção de atributos usando algoritmos genéticos para classificação de regiões. In *XIII Simpósio Brasileiro de sensoriamento remoto.*, pages 6143–6150.