

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

CLASSIFICAÇÃO DE IMAGENS DE PORNOGRAFIA E
PORNOGRAFIA INFANTIL UTILIZANDO
RECUPERAÇÃO DE IMAGENS BASEADA EM
CONTEÚDO

ITAMAR ALMEIDA DE CARVALHO

ORIENTADOR: DÍBIO LEANDRO BORGES

DISSERTAÇÃO DE MESTRADO EM ENGENHARIA ELÉTRICA
ÁREA DE CONCENTRAÇÃO INFORMÁTICA FORENSE E
SEGURANÇA DA INFORMAÇÃO

Publicação: ENE/PG.DM – 100/2012

BRASÍLIA/DF: FEVEREIRO / 2012.

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**CLASSIFICAÇÃO DE IMAGENS DE PORNOGRAFIA E
PORNOGRAFIA INFANTIL UTILIZANDO RECUPERAÇÃO DE
IMAGENS BASEADA EM CONTEÚDO**


ITAMAR ALMEIDA DE CARVALHO

DISSERTAÇÃO DE MESTRADO PROFISSIONALIZANTE SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA ELÉTRICA DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE.

APROVADA POR:



**DÍBIO LEANDRO BORGES, Dr., CIC/UNB
(ORIENTADOR)**



**FLÁVIO DE BARROS VIDAL, Dr., CIC/UNB
(EXAMINADOR EXTERNO)**



**ANDERSON CLAYTON ALVES NASCIMENTO, Dr., ENE/UNB
(EXAMINADOR INTERNO)**

Brasília, 15 de fevereiro de 2012.

FICHA CATALOGRÁFICA

CARVALHO, ITAMAR ALMEIDA DE
CLASSIFICAÇÃO DE IMAGENS DE PORNOGRAFIA E PORNOGRAFIA
INFANTIL UTILIZANDO RECUPERAÇÃO DE IMAGENS BASEADA EM
CONTEÚDO. [Distrito Federal] 2012.

xv, 54p., 297 mm (ENE/FT/UnB, Mestre, Engenharia Elétrica, 2012).

Dissertação de Mestrado - Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Elétrica.

- | | |
|--|------------------------------|
| 1. Informática forense | 2. Visão por Computador |
| 3. Classificação de Imagens por Conteúdo | 4. Reconhecimento de padrões |
| I. ENE/FT/UnB | II. Título (série) |

REFERÊNCIA BIBLIOGRÁFICA

CARVALHO, I. A. (2012). CLASSIFICAÇÃO DE IMAGENS DE PORNOGRAFIA E PORNOGRAFIA INFANTIL UTILIZANDO RECUPERAÇÃO DE IMAGENS BASEADA EM CONTEÚDO. Dissertação de Mestrado, Publicação ENE/PG.DM – 100/2012, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, (54)p.

CESSÃO DE DIREITOS

NOME DO AUTOR: Itamar Almeida de Carvalho.

TÍTULO DA DISSERTAÇÃO DE MESTRADO: Classificação de Imagens de Pornografia e Pornografia Infantil Utilizando Recuperação de Imagens Baseada em Conteúdo.

GRAU / ANO: Mestre / 2012

É concedida à Universidade de Brasília permissão para reproduzir cópias desta Dissertação de Mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. Do mesmo modo, a Universidade de Brasília tem permissão para divulgar este documento em biblioteca virtual, em formato que permita o acesso via redes de comunicação e a reprodução de cópias, desde que protegida a integridade do conteúdo dessas cópias e proibido o acesso a partes isoladas desse conteúdo. O autor reserva outros direitos de publicação e nenhuma parte deste documento pode ser reproduzida sem a autorização por escrito do autor.

Itamar Almeida de Carvalho

Universidade de Brasília – Campus Universitário Darcy Ribeiro – Asa Norte

CEP 70910-900 – Brasília – DF – Brasil

DEDICATÓRIA

Este trabalho é dedicado
a Sueli, Juracy, Luísa e Júlia
(as mulheres da minha vida)
e a todas as crianças vítimas de abusos.

AGRADECIMENTOS

A meus pais, Paulo César e Sueli, por me darem o gosto pelo estudo.

À Juracy, minha esposa, e Luísa e Júlia, minhas filhas, que tiveram que suportar minha ausência em diversos momentos.

Ao meu orientador Prof. Dr. Díbio Borges, pelo apoio e incentivo, essenciais para o desenvolvimento deste trabalho e para minha formação como pesquisador.

Ao Perito Criminal Federal Hélio Pereira Peixoto, por ter a visão e a dedicação que permitiram a realização deste programa de Mestrado.

A todos os colegas do Mestrado em Informática Forense, pela amizade.

Aos Dirigentes, Escotistas e jovens do 11º DF Grupo Escoteiro José de Anchieta, por sempre me incentivarem a perseguir este objetivo e por entenderem minhas seguidas ausências aos sábados e nas atividades externas.

A todos os amigos que me incentivaram e me deram forças para concluir este trabalho.

Aos colaboradores dos projetos de *software* livre, sem os quais diversas ferramentas que foram utilizadas não existiriam.

O presente trabalho foi realizado com o apoio do Departamento de Polícia Federal – DPF, com recursos do Programa Nacional de Segurança Pública com Cidadania – PRONASCI, do Ministério da Justiça.

RESUMO

CLASSIFICAÇÃO DE IMAGENS DE PORNOGRAFIA E PORNOGRAFIA INFANTIL UTILIZANDO RECUPERAÇÃO DE IMAGENS BASEADA EM CONTEÚDO

Autor: Itamar Almeida de Carvalho

Orientador: Díbio Leandro Borges

Programa de Pós-graduação em Engenharia Elétrica

Brasília, fevereiro / 2012

A disseminação de materiais de pornografia envolvendo crianças e adolescentes é um problema que vem crescendo nos últimos anos, especialmente através do uso da Internet. O volume de materiais e o número de meios através dos quais estes materiais são distribuídos atualmente é maior que a capacidade de análise visual feita por profissionais das forças da lei, sejam policiais, ONGs ou outros. Neste contexto faz-se necessário o uso de técnicas que automatizem a priorização dos materiais para análise.

O método de classificação pelo conjunto de características visuais, com uso de descritores locais de pontos de interesse em imagens já tem sido estudado tanto para identificação de pornografia em geral quanto a de pornografia infantil. Este trabalho busca identificar uma combinação de detector de pontos de interesse, descritor local e classificador que ofereça melhor resultado que os já testados em outros trabalhos. Para isso, foram testados detectores *Difference of Gaussians*, *Harris-Laplace* e Amostragem Densa, os descritores SIFT, OpponentSIFT e WSIFT e os classificadores pLSA e Naive Bayes.

O detector Amostragem Densa se destacou dos demais, apresentando melhores resultados para o problema aqui tratado, sendo que nas comparações mais complexas, envolvendo imagens de pornografia infantil, o detector *Harris-Laplace* obteve bons resultados. Entre os descritores, o WSIFT apresentou melhores resultados, porém OpponentSIFT teve resultados melhores nas comparações mais complexas, não podendo ser ignorado em estudos futuros. O classificador Naive Bayes foi usado nos experimentos de melhores resultados.

ABSTRACT

IMAGE CLASSIFICATION OF PORNOGRAPHY AND CHILD PORNOGRAPHY USING CONTENT-BASED IMAGE RETRIEVAL

Author: Itamar Almeida de Carvalho

Supervisor: Díbio Leandro Borges

Programa de Pós-graduação em Engenharia Elétrica

Brasília, February, 2012

The dissemination of pornographic material involving children and adolescents is a problem that has been growing in recent years, especially through the use of the Internet. The volume of material and the number of means by which these materials are distributed today is greater than the capacity of visual analysis done by law enforcement professionals, whether police, NGOs or others. In this context, it is necessary the use of automated techniques to prioritize the materials to be analyzed.

The classification method using a set of visual features, with local descriptors of interest points in images has already been studied both for identification of pornography in general and of child pornography. This paper aims to identify a combination of detector of interest points, local descriptor and classifier that provides better results than those already tested in other studies. Thus, we tested the detectors *Difference of Gaussians*, *Harris-Laplace* and Dense Sampling, the descriptors SIFT, OpponentSIFT and WSIFT and the classifiers pLSA and Naive Bayes.

The detector Dense Sampling, in comparison to the others, showed better results for the problem treated here, and in more complex comparisons involving images of child pornography, the detector *Harris-Laplace* had good results. Among the descriptors, WSIFT showed better results, but OpponentSIFT had better results in more complex comparisons and may not be ignored in future studies. The Naive Bayes classifier was used in the experiments with best results.

SUMÁRIO

| | | |
|----------|--|-----------|
| 1 | Introdução | 1 |
| 2 | Trabalhos Correlatos | 6 |
| 3 | Metodologia | 9 |
| 3.1 | Conjunto de Características Visuais | 11 |
| 3.2 | Detectores de pontos de interesse | 13 |
| 3.2.1 | <i>Difference of Gaussians</i> | 14 |
| 3.2.2 | <i>Harris-Laplace</i> | 17 |
| 3.2.3 | Amostragem Densa | 18 |
| 3.3 | Descritores | 18 |
| 3.3.1 | Invariante à Escala | 19 |
| 3.3.2 | Invariante à Escala no Espaço de Cores Oponentes | 20 |
| 3.3.3 | Invariante à Escala e Intensidade no Espaço de Cores Oponentes | 20 |
| 3.4 | Classificadores | 20 |
| 3.4.1 | Naive Bayes | 21 |
| 3.4.2 | Análise Probabilística de Semântica Latente | 23 |
| 3.5 | Medidas de Avaliação | 25 |
| 4 | Resultados e Análise | 27 |
| 4.1 | Experimento 1: Categorias Pornografia feminina e Geral | 28 |
| 4.2 | Experimento 2: Categorias Pornografia infantil feminina e Geral | 29 |
| 4.3 | Experimento 3: Categorias Pornografia feminina e Trajes sumários | 31 |

| | | |
|----------|--|-----------|
| 4.4 | Experimento 4: Categorias Pornografia infantil feminina e Trajes sumários | 32 |
| 4.5 | Experimento 5: Categorias Pornografia infantil feminina e Pornografia feminina | 34 |
| 4.6 | Resumo dos Resultados | 35 |
| 5 | Conclusões | 38 |
| 5.1 | Contribuições | 38 |
| 5.2 | Trabalhos Futuros | 39 |
| | REFERÊNCIAS BIBLIOGRÁFICAS | 40 |
| | Apêndices | 43 |
| A | Resultados dos Experimentos Realizados | 44 |
| A.1 | Experimento 1: Categorias Geral e Pornografia feminina | 44 |
| A.2 | Experimento 2: Categorias Geral e Pornografia infantil feminina | 45 |
| A.3 | Experimento 3: Categorias Trajes sumários e Pornografia feminina | 47 |
| A.4 | Experimento 4: Categorias Trajes sumários e Pornografia infantil feminina | 48 |
| A.5 | Experimento 5: Categorias Pornografia feminina e Pornografia infantil feminina | 50 |
| B | Fluxograma do Código de Classificação de Fei-Fei et al. | 52 |
| C | Fluxograma do Código de Classificação Desenvolvido e suas Fases | 53 |
| D | Fluxo das Imagens no Código de Classificação Desenvolvido | 54 |

LISTA DE TABELAS

| | | |
|-----|--|----|
| 3.1 | Categorias de imagens | 10 |
| 3.2 | Experimentos Realizados | 10 |
| 3.3 | Detectores de pontos de interesse, descritores e classificadores | 11 |
| 3.4 | Matriz confusão | 25 |
| 4.1 | Revocação dos diversos experimentos | 27 |
| 4.2 | Taxa de Falsos Positivos dos diversos experimentos | 29 |
| 4.3 | Precisão dos diversos experimentos | 30 |
| 4.4 | Acurácia dos diversos experimentos | 32 |
| 4.5 | Quantidade de valores máximos e mínimos, entre as medidas de avaliação utilizadas, para cada experimento. O número de máximos e mínimos supera a quantidade de experimentos realizados, pois houve empates em alguns experimentos. | 35 |
| A.1 | Resultado do experimento entre as categorias Pornografia feminina e Geral usando <i>Harris-Laplace</i> e OpponentSIFT | 44 |
| A.2 | Resultado do experimento entre as categorias Pornografia feminina e Geral usando <i>Harris-Laplace</i> e WSIFT | 44 |
| A.3 | Resultado do experimento entre as categorias Pornografia feminina e Geral usando Amostragem Densa e OpponentSIFT | 44 |
| A.4 | Resultado do experimento entre as categorias Pornografia feminina e Geral usando Amostragem Densa e WSIFT | 45 |
| A.5 | Resultado do experimento entre as categorias Pornografia feminina e Geral usando <i>Difference of Gaussians</i> e SIFT | 45 |
| A.6 | Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando <i>Harris-Laplace</i> e OpponentSIFT | 45 |

| | | |
|------|---|----|
| A.7 | Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando <i>Harris-Laplace</i> e WSIFT | 46 |
| A.8 | Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando Amostragem Densa e OpponentSIFT | 46 |
| A.9 | Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando Amostragem Densa e WSIFT | 46 |
| A.10 | Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando <i>Difference of Gaussians</i> e SIFT | 46 |
| A.11 | Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando <i>Harris-Laplace</i> e OpponentSIFT | 47 |
| A.12 | Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando <i>Harris-Laplace</i> e WSIFT | 47 |
| A.13 | Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando Amostragem Densa e OpponentSIFT | 47 |
| A.14 | Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando Amostragem Densa e WSIFT | 48 |
| A.15 | Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando <i>Difference of Gaussians</i> e SIFT | 48 |
| A.16 | Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando <i>Harris-Laplace</i> e OpponentSIFT | 48 |
| A.17 | Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando <i>Harris-Laplace</i> e WSIFT | 49 |
| A.18 | Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando Amostragem Densa e OpponentSIFT | 49 |
| A.19 | Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando Amostragem Densa e WSIFT | 49 |
| A.20 | Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando <i>Difference of Gaussians</i> e SIFT | 49 |
| A.21 | Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando <i>Harris-Laplace</i> e OpponentSIFT | 50 |

| | | |
|------|--|----|
| A.22 | Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando <i>Harris-Laplace</i> e WSIFT | 50 |
| A.23 | Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando Amostragem Densa e Opponent-SIFT | 50 |
| A.24 | Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando Amostragem Densa e WSIFT | 51 |
| A.25 | Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando <i>Difference of Gaussians</i> e SIFT | 51 |

LISTA DE FIGURAS

| | | |
|-----|---|----|
| 3.1 | Exemplos de imagens da categoria 4 - Geral. | 11 |
| 3.2 | Ilustração das etapas gerais do método de classificação pelo Conjunto de Características Visuais. | 12 |
| 3.3 | Máximos e mínimos das imagens na <i>Difference of Gaussians</i> são detectados comparando um pixel (marcado com X) com seus 26 vizinhos em regiões 3x3 na escala atual e adjacentes (marcados com círculos). | 15 |
| 3.4 | Demonstração dos pontos de interesse selecionados pelos diferentes algoritmos utilizados | 18 |
| 3.5 | Modelo gráfico do pLSA. Nós dentro de um quadro indicam que eles são replicados o número de vezes indicados no canto superior esquerdo. Círculos preenchidos indicam variáveis aleatórias observadas; não preenchidos são não observadas. | 24 |
| 3.6 | No pLSA, o objetivo é encontrar a distribuição específica de tópicos $P(t c_k)$ e as correspondentes proporções de mistura específicas de cada documento $P(c d_j)$, que cria a distribuição de palavras específica de um documento $P(t d_j)$ | 24 |
| 4.1 | Revocação para todos os experimentos. | 28 |
| 4.2 | Taxa de Falsos Positivos para todos os experimentos. | 28 |
| 4.3 | Precisão para todos os experimentos. | 31 |
| 4.4 | Acurácia para todos os experimentos. | 31 |
| B.1 | Fluxograma do código criado por Fei-Fei, Fergus e Torralba (2005), com o descritor SIFT, incluindo a estrutura do código, as entradas e saídas para o caso específico do uso do classificador pLSA. | 52 |

| | |
|--|----|
| C.1 Fluxograma com as fases, os nomes dos <i>scripts</i> , os algoritmos ou técnicas utilizadas em cada etapa, as entradas e saídas para o caso específico do uso de um classificador <i>Naive Bayes</i> , no código criado para este trabalho, com o uso de <i>Color Descriptors</i> implementados por van de Sande (SANDE; GEVERS; SNOEK, 2008, 2010). | 53 |
| D.1 Fluxo das imagens considerando suas categorias e se estas foram selecionadas para o grupo de treino ou de teste, com relação ao código criado para este trabalho, com o uso de <i>Color Descriptors</i> implementados por van de Sande (SANDE; GEVERS; SNOEK, 2008, 2010). | 54 |

LISTA DE ABREVIATURAS E SIGLAS

| | | |
|-------|--|-------|
| SIFT | <i>Scale Invariant Feature Transform,</i> | p. 3 |
| pLSA | <i>Probabilistic Latent Semantic Analysis,</i> | p. 3 |
| DCT | <i>Discrete Cosine Transform,</i> | p. 6 |
| SVM | <i>Support Vector Machine,</i> | p. 6 |
| FIVES | <i>Forensic Image and Video Examination Support,</i> | p. 6 |
| RGB | <i>Red, Green, Blue,</i> | p. 7 |
| VQ | <i>Vector Quantization,</i> | p. 13 |

1 Introdução

A popularização da Internet em muitos países, ao mesmo tempo que criou um canal de comunicação entre universidades e instituições de pesquisa e viabilizou a globalização do comércio, também abriu espaço para troca de informações entre pessoas e grupos que têm como objetivo a prática de crimes. Um dos crimes que passou a explorar este canal de comunicação é o da distribuição de material pornográfico envolvendo crianças e adolescentes.

Devido ao grande volume de informações disponíveis na Internet, em seus vários serviços e formatos, as forças da lei não conseguem rastrear toda a informação que se passa na rede. Por isso, é importante a participação da população, através de denúncias, o que já vem ocorrendo no Brasil através dos diversos canais disponíveis, sejam do Ministério Público, da Polícia Federal, da Presidência da República ou mesmo de Organizações Não Governamentais.

A partir da abertura destes canais de denúncias, o problema passa a ser a disponibilidade de recursos (especialmente humanos) para receber e tratar os dados recebidos, primeiramente eliminando falsas denúncias, depois verificando se as páginas denunciadas continuam disponíveis e realmente contém pornografia envolvendo crianças ou adolescentes, e por fim preservar o conteúdo e as informações associadas, passando para uma equipe de investigação o material que será usado para tratar este caso, buscando a materialidade e a autoria do crime.

A verificação da disponibilidade da página, a coleta de informações sobre a mesma e a preservação do conteúdo são tarefas de automatização trivial, através de ferramentas já existentes. A maior dificuldade para que seja viável a automatização deste processo consiste na verificação do conteúdo das fotografias disponíveis, para constatação da presença de pornografia envolvendo criança ou adolescente.

Este não é um problema totalmente novo, já existem alguns trabalhos(THOMPSON, 2009; ULGES; STAHL, 2011) sobre este tema ou em temas muito próximos, como a detecção de pornografia em geral(POLASTRO; ELEUTERIO, 2010; LOPES et al., 2009; LIENHART; HAUKE, 2009). Porém, os trabalhos com resultados já publicados

ainda possuem taxa de acerto muito pequena quando comparamos com uma rápida análise visual da imagem, sugerindo que há um grande espaço para melhorias. Outro problema presente em alguns dos trabalhos já existentes refere-se à conceituação do que é pornografia envolvendo criança ou adolescente, que no Brasil é descrita no Estatuto da Criança e do Adolescente (BRASIL, 1990, 2008), da seguinte forma:

Art. 241-E. Para efeito dos crimes previstos nesta Lei, a expressão “cena de sexo explícito ou pornográfica” compreende qualquer situação que envolva criança ou adolescente em atividades sexuais explícitas, reais ou simuladas, ou exibição dos órgãos genitais de uma criança ou adolescente para fins primordialmente sexuais.

O presente trabalho tem como objetivo geral analisar a performance de classificadores de imagens quando aplicados para classificação automática de imagens com conteúdo pornográfico envolvendo crianças.

Visando este objetivo geral, os seguintes objetivos específicos foram buscados:

1. Identificar e avaliar a capacidade do método ser capaz de classificar pornografia em geral;
2. Identificar e avaliar a capacidade do método ser capaz de classificar presença de pornografia infantil;
3. Identificar e avaliar a capacidade do método de classificar ausência de pornografia.

O presente trabalho procura efetuar classificação de imagens baseada em conteúdo, utilizando o método de classificação baseado em um conjunto de características visuais, comumente chamado *Bag Of Visual Words*, como descrito por Sivic et al. (2005). A técnica é derivada de aplicações de classificação de documentos texto sem supervisão. De forma análoga ao método com textos, são extraídas das imagens “palavras visuais”, constituídas de descritores locais de uma imagem, invariantes a alterações de escala, rotação, iluminação e pontos de vista.

Para possibilitar a comparação de diferentes métodos de identificação dos pontos de interesse e dos descritores locais destes pontos, foram adotados os seguintes algoritmos:

O descritor SIFT (*Scale Invariant Feature Transform*)¹(LOWE, 2004), calculado a partir de pontos de interesse identificados com uso de detecção de bordas e em seguida por seleção de pontos salientes nestas bordas, pela técnica de *Difference of Gaussians*. Para este descritor, as imagens coloridas são convertidas para monocromáticas antes do processamento.

Foram também utilizados dois descritores que trabalham diretamente com imagens coloridas, através de adaptações do descritor SIFT, combinados com duas técnicas de identificação de pontos de interesse.

A partir dos descritores locais de cada imagem, é utilizado o método K-Médias (MACQUEEN, 1967) para criar o vocabulário visual com K categorias. Foi adotado K igual ao número de categorias de imagens do experimento, como sugerido por Sivic et al. (2005). Este método utiliza diversas iterações, onde são calculados centróides para cada grupo pré-definido e cada descritor é incluído no grupo cuja distância do centróide for menor. Depois disso, é re-calculado o centróide, a partir da mediana dos vetores que estão no grupo. Após um certo número de iterações, esses grupos convergem e estabilizam, quando o valor do centróide permanece o mesmo durante duas iterações consecutivas.

Uma vez obtido o vocabulário visual, os vetores de todas as imagens são quantizados e usados para cálculo de histogramas das imagens, representando as ocorrências de cada “palavra visual” na imagem.

Por sua vez, os histogramas são usados, através de aplicação de um classificador, tanto para gerar o modelo na fase de treinamento, quanto para classificar as imagens, na fase de teste. Em conjunto com o descritor SIFT, foi utilizada a classificação através de pLSA (*Probabilistic Latent Semantic Analysis*)²(SIVIC et al., 2005). Já para os descritores color, foi utilizada classificação com uso de *Naive Bayes*.

As imagens que contém pornografia infantil foram obtidas do arquivo de laudos gerados por Peritos Criminais Federais da Polícia Federal do Brasil. Devido a vedação legal(BRASIL, 1990, 2008), as imagens desta categoria não podem ser divulgadas e por isso nenhuma delas ilustra este trabalho (grifo meu):

¹Descritor de Características Invariante à Escala

²Análise Probabilística de Semântica Latente

Art. 241-B. Adquirir, possuir ou armazenar, por qualquer meio, fotografia, vídeo ou outra forma de registro que contenha cena de sexo explícito ou pornográfica envolvendo criança ou adolescente:

Pena – reclusão, de 1 (um) a 4 (quatro) anos, e multa.

§ 1º A pena é diminuída de 1 (um) a 2/3 (dois terços) se de pequena quantidade o material a que se refere o caput deste artigo.

§ 2º Não há crime se a posse ou o armazenamento tem a finalidade de comunicar às autoridades competentes a ocorrência das condutas descritas nos arts. 240, 241, 241-A e 241-C desta Lei, quando a comunicação for feita por:

I – agente público no exercício de suas funções;

II – membro de entidade, legalmente constituída, que inclua, entre suas finalidades institucionais, o recebimento, o processamento e o encaminhamento de notícia dos crimes referidos neste parágrafo;

III – representante legal e funcionários responsáveis de provedor de acesso ou serviço prestado por meio de rede de computadores, até o recebimento do material relativo à notícia feita à autoridade policial, ao Ministério Público ou ao Poder Judiciário.

§ 3º As pessoas referidas no § 2º deste artigo deverão manter sob sigilo o material ilícito referido.

Para realização dos experimentos com o descritor SIFT, foi utilizado código criado por Fei-Fei et al. (FEI-FEI; PERONA, 2005; FEI-FEI; FERGUS; TORRALBA, 2005) para um mini-curso oferecido na ICCV 2005. O código, disponível na Internet, possui partes codificadas para rodar no software MATLAB³ e outras partes são código fonte em linguagem C++, feitos para compilação em Linux pela ferramenta MEX, que é parte do pacote MATLAB.

Como não haviam recursos para obtenção de licença do MATLAB, foi utilizada a ferramenta Octave (EATON, 2011), de código livre, que busca manter compatibilidade de sintaxe com o MATLAB. Para tal, foram necessários ajustes no código MATLAB, para que pudesse ser executado no ambiente Octave.

Foi utilizada a versão 3.2.3 do GNU Octave, rodando sobre Ubuntu Linux.

³MATLAB©1994-2011 The MathWorks, Inc.

Para os experimentos com os descritores OpponentSIFT e WSIFT, foi utilizada a implementação destes *color descriptors* e dos detectores de pontos de interesse *Harris-Laplace* e Amostragem Densa feita por van de Sande (SANDE; GEVERS; SNOEK, 2008, 2010), em combinação com implementações dos algoritmos K-Médias e Quantização de Vetores do pacote SciPy (JONES et al., 2001). Para a classificação foi utilizado o algoritmo Naive Bayes, como descrito por Manning, Raghavan e Schutze (2008), implementado em linguagem Python versão 2.6.

2 Trabalhos Correlatos

A detecção de imagens com conteúdo pornográfico é um problema bastante estudado, com uso de diferentes técnicas que vêm evoluindo ao longo do tempo. Mais recentemente alguns pesquisadores têm se dedicado ao problema específico de detecção de pornografia envolvendo crianças e adolescentes. Neste capítulo são apresentados alguns dos trabalhos mais recentes com relação aos dois problemas, que utilizam algumas das técnicas mais promissoras na área de visão computacional, algumas das quais foram utilizadas neste trabalho.

No estudo de Ulges e Stahl (2011), foi utilizada a técnica das “palavras visuais”, através de descritores color DCT (*Discrete Cosine Transform*)¹ no espaço de cores YUV², utilizando classificador SVM (*Support Vector Machine*)³. Para extração dos pontos de interesse, foi utilizada a técnica de Amostragem Densa. O diferencial deste trabalho foi o processamento de imagens de pornografia infantil através de parceria com órgãos policiais através do projeto FIVES (*Forensic Image and Video Examination Support*)⁴. Apesar de sua abordagem apresentar resultados melhores do que a técnica de detecção de cor da pele, a identificação de pornografia infantil comparada com pornografia adulta ainda possui resultados com taxa de erro muito grande: 24,0%.

No artigo de Thompson (2009), é apresentada uma proposta de metodologia para detecção automática de pornografia infantil. Este artigo define uma linha de trabalho que o autor pretende adotar em seu doutorado. A definição dele do que é pornografia infantil não está de acordo com o ECA brasileiro (BRASIL, 1990, 2008), pois por sua definição, é necessário que a criança esteja em posição de exploração ou sendo vítimas de situações onde não podem reagir, o que permitiria que mesmo cenas de crianças vestidas poderiam ser classificadas como pornografia infantil, contrariando a definição da legislação brasileira, apresentada na Seção 1. Como esta é uma pesquisa em andamento, nenhum resultado é apresentado no artigo, porém o pesquisador trabalha com a hipótese de que nenhuma técnica isolada consegue identificar pornografia infantil,

¹Transformada Discreta de Cosseno

²Espaço de cores onde o componente Y representa a luminância e os componentes U e V representam canais de cores sem a luminância.

³Máquina de Vetores de Suporte

⁴<http://fives.kau.se/>

sendo necessária a combinação de técnicas, incluindo detecção de pele, localização de faces, estimativa de idade e análise das formas e curvaturas das regiões de pele.

O trabalho de Polastro e Eleutério (POLASTRO; ELEUTERIO, 2010) é relacionado a detecção automática de nudez, através de identificação de cor da pele e de análise do nome dos arquivos. Enquanto a análise das imagens realizada no sistema desenvolvido por eles busca a identificação de cenas de nudez em geral, a análise do nome dos arquivos busca por termos comumente usados em compartilhamentos de pornografia infantil. Na análise das imagens, inicialmente são identificados os pixels que possuem cor da pele, analisando o espaço de cores RGB (*Red, Green, Blue*). Se a quantidade destes pixels superar um certo limiar, a análise continua, comparando as cores das três maiores regiões da imagem que tiverem cor da pele e filtrando o resultado desta análise com o uso de limiares estabelecidos empiricamente. Esta técnica parte do princípio que cenas de nudez apresentam diversas tonalidades de pele em regiões próximas. Este trabalho apresenta bons resultados na detecção de nudez, porém não foca na detecção de pornografia infantil diretamente através da análise das imagens, apontando as imagens com prováveis cenas de nudez e exibindo ao investigador para que ele busque ocorrências de pornografia infantil.

Lopes (LOPES et al., 2009), em seu trabalho, utiliza também a técnica das “palavras visuais”, porém com descritor Hue-SIFT⁵ e com objetivo de identificar apenas imagens pornográficas, sem distinção de adulta ou infantil. Para classificação, Lopes utilizou SVM com um *kernel* linear. Lopes comparou os resultados da classificação com Hue-SIFT e SIFT, alcançando taxas melhores com Hue-SIFT, indicando que a informação de cores é importante no problema de identificação de imagens pornográficas.

Lienhart e Hauke (LIENHART; HAUKE, 2009) trataram detecção de pornografia com pLSA, utilizando Amostragem Densa para identificação dos pontos de interesse e comparando a performance do descritor SIFT com o descritor *Self-Similarity*(SHECHTMAN; IRANI, 2007). Os autores utilizaram dois conjuntos de imagens: um com imagens de pessoas em biquinis e imagens em diversas outras categorias, visando a comparação da classe “biquini” contra as demais classes combinadas, e outro conjunto substituindo as imagens de pessoas em biquinis por imagens pornográficas, visando verificar se o resultado com biquinis se sustenta ao usar imagens pornográficas, o que se mostrou verdadeiro. O experimento também

⁵Hue-SIFT é uma extensão do descritor SIFT, composto da concatenação de um histograma da matiz (*hue*) ao descritor SIFT, adicionando informação de cores ao descritor.

comparou diversos espaços de cores, incluindo imagens monocromáticas e coloridas, com várias representações do espaço de cores, assim como a forma de representação, tanto através de números de ponto flutuante quanto a representação utilizando um byte sem sinal (*unsigned*). O experimento atingiu boas taxas de negativos e positivos corretamente classificados, demonstrando que esta abordagem pode ser usada para classificação de imagens pornográficas.

Neste trabalho, é testada a hipótese de que é possível a identificação de pornografia infantil, inclusive sua diferenciação de pornografia adulta, com o uso do método de classificação pelo conjunto de características visuais, sendo testados diferentes detectores de pontos de interesse, descritores locais e classificadores, para avaliar qual das combinações testadas apresenta melhores resultados.

3 Metodologia

Neste capítulo, são descritos os experimentos que foram realizados, os diversos métodos utilizados na realização dos experimentos e as medidas utilizadas na análise comparativa destes métodos.

O método utilizado foi o de classificação pelo conjunto de características visuais, como descrito adiante na seção 3.1.

O presente trabalho utilizou implementação feita por Li Fei-Fei et al. (FEI-FEI; PERONA, 2005; FEI-FEI; FERGUS; TORRALBA, 2005), para o cálculo do descritor SIFT utilizando *Difference of Gaussians* para identificação dos pontos de interesse. Também foi utilizada a implementação de diversos *color descriptors* e dos detectores de pontos de interesse *Harris-Laplace* e Amostragem Densa feita por van de Sande (SANDE; GEVERS; SNOEK, 2008, 2010), em combinação com implementações dos algoritmos K-Médias e Quantização de Vetores. Para a classificação foi utilizado o algoritmo *Naive Bayes*, como descrito por Manning, Raghavan e Schutze (2008). Os detectores de pontos de interesse e os descritores locais utilizados estão detalhados nas seções 3.2 e 3.3, respectivamente.

Para a análise, foram usadas métricas descritas por Fawcett (2006), como Revocação, Taxa de Falsos Positivos, Precisão e Acurácia. Estas métricas estão detalhadas na seção 3.5.

Para os experimentos, foram selecionadas imagens que se encaixam em uma das categorias listadas na Tabela 3.1. As imagens possuem origens diferentes, de acordo com sua categoria: as imagens da categoria Pornografia infantil feminina utilizadas foram obtidas do arquivo de laudos gerados por Peritos Criminais Federais da Polícia Federal do Brasil, como já citado no capítulo 1, as das categorias Pornografia feminina e Trajes sumários foram obtidas na Internet, em sites de armazenamento de fotografias, através de buscas por palavras-chave, e as imagens da categoria Geral foram selecionadas de fotografias do arquivo pessoal do autor, buscando a maior variabilidade possível com relação ao conteúdo das cenas, condições de iluminação e câmera fotográfica utilizada. Algumas imagens da categoria Geral podem ser vistas

na Figura 3.1.

| Nº | Quantidade | Categoria | Descrição |
|----|------------|-------------------------------|--|
| 1 | 100 | Pornografia infantil feminina | Imagens contendo pornografia infantil, onde era visível a genitália feminina de crianças ou adolescentes e não havia presença de genitália de adultos. |
| 2 | 100 | Pornografia feminina | Imagens contendo genitália feminina de adulta. |
| 3 | 100 | Trajes sumários | Imagens não contendo pornografia, porém com presença de pessoas em roupas sumárias (geralmente sungas e biquínis). |
| 4 | 100 | Geral | Imagens gerais, não contendo pornografia nem pessoas em roupas sumárias. Algumas das imagens não possuem a presença de pessoas. |

Tabela 3.1: Categorias de imagens

Para análise dos dados foram realizados cinco experimentos, cada um comparando duas das categorias, como listado na Tabela 3.2. Procurou-se avaliar a performance dos classificadores testados nas tarefas de identificação de pornografia adulta, identificação de pornografia infantil e diferenciação entre pornografia adulta da infantil.

Cada experimento listado na Tabela 3.2 foi realizado com as combinações de detectores de pontos de interesse, de descritores e classificadores listados na Tabela 3.3, e seus resultados comparados para avaliação da performance de cada combinação.

| Experimento | Categoria Negativa | Categoria Positiva |
|-------------|--------------------------|-----------------------------------|
| 1 | 4 - Geral | 2 - Pornografia feminina |
| 2 | 4 - Geral | 1 - Pornografia infantil feminina |
| 3 | 3 - Trajes sumários | 2 - Pornografia feminina |
| 4 | 3 - Trajes sumários | 1 - Pornografia infantil feminina |
| 5 | 2 - Pornografia feminina | 1 - Pornografia infantil feminina |

Tabela 3.2: Experimentos Realizados




Figura 3.1: Exemplos de imagens da categoria 4 - Geral.

| Detector | Descritor | Classificador |
|--------------------------------|--------------|---------------|
| <i>Difference of Gaussians</i> | SIFT | pLSA |
| Harris-Laplace | OpponentSIFT | Naive Bayes |
| Amostragem Densa | OpponentSIFT | Naive Bayes |
| Harris-Laplace | WSIFT | Naive Bayes |
| Amostragem Densa | WSIFT | Naive Bayes |

Tabela 3.3: Detectores de pontos de interesse, descritores e classificadores

3.1 Conjunto de Características Visuais

Foi utilizado o método de classificação pelo Conjunto de Características Visuais (comumente conhecido como *Bag of Visual Words*), que é adaptado de uma método análogo (chamado de *Bag of Words*), utilizado para classificação de documentos texto.

A Figura 3.2 ilustra em linhas gerais o uso do método de classificação pelo Conjunto de Características Visuais e suas etapas. Inicialmente (1) é necessário ter imagens de treino e de teste. Para os experimentos, as imagens que compuseram os dois grupos

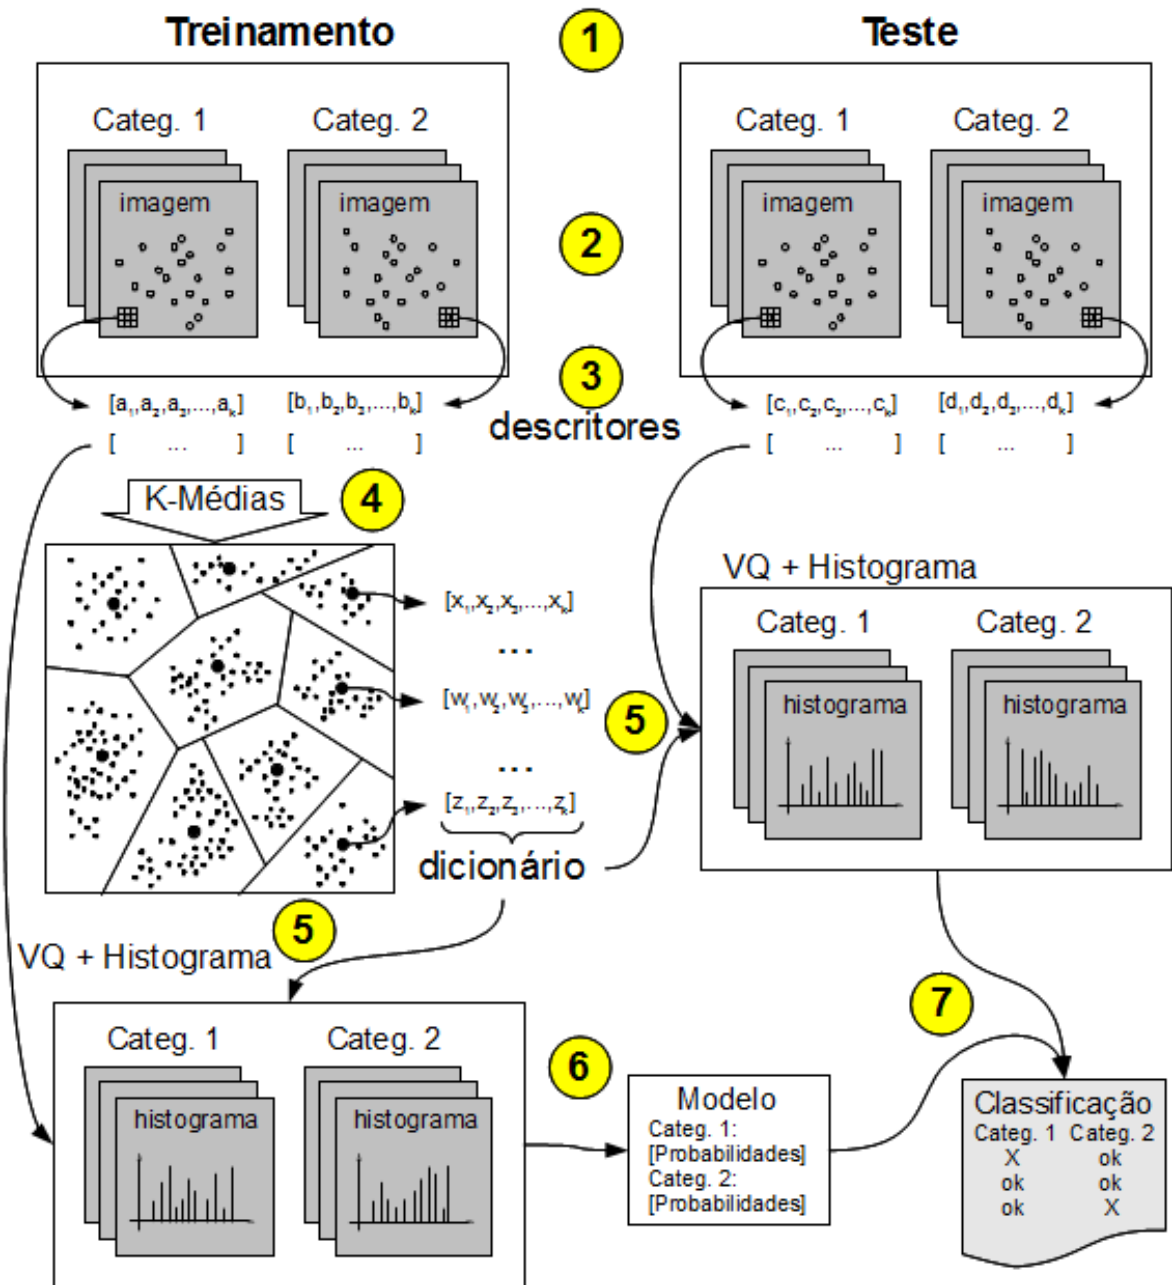


Figura 3.2: Ilustração das etapas gerais do método de classificação pelo Conjunto de Características Visuais.

foram selecionadas aleatoriamente, dentro de cada categoria. Para o presente trabalho, as categorias das imagens foram comparadas duas a duas.

Em seguida, em cada imagem são selecionados pontos de interesse (2). Foram utilizadas três algoritmos nesta etapa: *Difference of Gaussians*, *Harris-Laplace* e Amostragem Densa, como explicado na seção 3.2.

Sobre cada ponto de interesse selecionado, é calculado um descritor deste ponto (3). Para este cálculo foram utilizados os descritores SIFT, OpponentSIFT e WSIFT, conforme descrito na seção 3.3.

Na próxima etapa (4), os descritores calculados são agrupados para criação do dicionário de “palavras visuais” identificadas nas imagens de teste. Foi utilizado o algoritmo K-Médias, que divide o conjunto de descritores em K grupos, cada um representado pelo seu centróide.

Após esta etapa, os descritores, tanto das imagens de treino, quanto de teste, passam por um processo de quantização de vetores – VQ (*Vector Quantization*) e criação de um histograma (5), que representa a frequência de cada palavra visual presente no dicionário em uma imagem.

Os histogramas das imagens de treino são utilizados (6) para cálculo de probabilidades, criando um modelo que será usado a partir de então no processo de classificação (7), em conjunto com os histogramas das imagens de teste. Estas duas últimas etapas do processo variam de acordo com os classificadores utilizados, que neste caso foram pLSA e Naive Bayes, conforme descrito na seção 3.4. O resultado é uma categorização de cada imagem, sendo classificada em uma das categorias e esta categoria calculada é comparada com a categoria original da imagem, viabilizando a análise da eficácia do método utilizado e daquele conjunto específico de técnicas e algoritmos.

3.2 Detectores de pontos de interesse

A primeira etapa do processamento das imagens no método do conjunto de características visuais é a seleção dos pontos de interesse. Estes pontos devem ser característicos da imagem e é desejável que tenham outras características, como invariância à escala,

rotação e outras transformações na imagem. Duas das técnicas utilizadas, *Difference of Gaussians* e *Harris-Laplace*, buscam estas características de invariância, como descrito nas próximas seções. A terceira técnica, Amostragem Densa, apenas seleciona um grande conjunto de pontos distribuídos uniformemente, esperando que desta forma alguns pontos relevantes sejam selecionados.

3.2.1 *Difference of Gaussians*

O detector de pontos de interesse *Difference of Gaussians*, descrito por Lowe (LOWE, 2004), é aplicada uma abordagem de filtragem em cascata, visando minimizar o custo computacional do processamento: as operações mais custosas somente são aplicadas sobre partes da imagem que passem por um teste inicial.

Inicialmente, são identificadas partes da imagem que são invariantes a mudanças de escala. Para isso, são buscadas características estáveis em todas as escalas possíveis, usando uma função contínua de escala conhecida como “espaço de escala”. O espaço de escala de uma imagem é definido como uma função $L(x, y, \sigma)$ que é produzida pela convolução de uma função Gaussiana de escala variável, $G(x, y, \sigma)$ com uma imagem de entrada $I(x, y)$, conforme a equação (3.1), onde $*$ é a operação de convolução em x e y e G é definido na equação (3.2).

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (3.1)$$

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (3.2)$$

Para eficientemente detectar pontos de interesse estáveis, Lowe propôs aplicar uma função de diferença Gaussiana na imagem, $D(x, y, \sigma)$ que é calculada pela diferença de duas escalas diferentes, separadas por uma constante multiplicativa k , conforme a equação (3.3).

$$\begin{aligned} D(x, y, \sigma) &= (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) \\ &= L(x, y, k\sigma) - L(x, y, \sigma) \end{aligned} \quad (3.3)$$




Figura 3.3: Máximos e mínimos das imagens na *Difference of Gaussians* são detectados comparando um pixel (marcado com X) com seus 26 vizinhos em regiões 3×3 na escala atual e adjacentes (marcados com círculos). Adaptado de Lowe (2004).

Uma vez que as imagens L já serão calculadas de qualquer forma para a descrição das características do espaço de escala, D pode ser facilmente calculado através de simples diferença entre as imagens.

Para identificar os máximos e mínimos locais de $D(x, y, \sigma)$, cada ponto é comparado com seus 8 vizinhos, e com os 9 vizinhos das escalas abaixo e acima, como ilustrado na Figura 3.3. Se for maior que todos ou menor que todos, será selecionado.

Após este procedimento, é realizada uma filtragem dos pontos identificados originalmente, buscando um aumento de estabilidade.

É usada a expansão de Taylor até os termos quadráticos da função do espaço de escalas $D(x, y, \sigma)$ (Equação (3.3)) deslocada de forma que o ponto de origem está no ponto selecionado:

$$D(\mathbf{x}) = D + \frac{\partial D^T}{\partial \mathbf{x}} \mathbf{x} + \frac{1}{2} \mathbf{x}^T \frac{\partial^2 D}{\partial \mathbf{x}^2} \mathbf{x} \quad (3.4)$$

onde D e suas derivadas são calculados no ponto identificado e $\mathbf{x} = (x, y, \sigma)^T$ é o deslocamento a partir deste ponto. A localização do extremo \mathbf{x} é determinado definindo a derivada desta função com relação a \mathbf{x} como zero, resultando em:

$$\hat{\mathbf{x}} = -\frac{\partial^2 D^{-1}}{\partial \mathbf{x}^2} \frac{\partial D}{\partial \mathbf{x}} \quad (3.5)$$

A Hessiana e derivada de D são aproximadas usando as diferenças de pontos vizinhos. O sistema linear resultante é resolvido e se o deslocamento $\hat{\mathbf{x}}$ for maior que 0,5 em qualquer dimensão, isso significa que o extremo está mais próximo de um ponto diferente. Neste caso, é selecionado outro ponto e a interpolação é feita neste ponto. O deslocamento final $\hat{\mathbf{x}}$ é adicionado à localização deste ponto para obtenção da estimativa da interpolação para a localização do extremo.

A função $D(\hat{\mathbf{x}})$ no extremo é útil para rejeitar os pontos extremos instáveis com baixo contraste. Isto pode ser alcançado substituindo a equação (3.5) em (3.4), obtendo:

$$D(\hat{\mathbf{x}}) = D + \frac{1}{2} \frac{\partial D^T}{\partial \mathbf{x}} \hat{\mathbf{x}} \quad (3.6)$$

Desta forma, é usado um limiar mínimo de $D(\hat{\mathbf{x}})$ para filtrar os pontos indesejáveis.

Em seguida, é realizada a eliminação dos pontos de borda, pois estes são instáveis a pequenos níveis de ruído. Isto é conseguido (SZELISKI, 2010) computando a Hessiana local da função D :

$$\mathbf{H} = \begin{bmatrix} D_{xx} & D_{xy} \\ D_{xy} & D_{yy} \end{bmatrix} \quad (3.7)$$

e então rejeitando pontos através da relação entre o traço (Tr) e o determinante (Det) da matriz \mathbf{H} , em que:

$$\frac{\text{Tr}(\mathbf{H})^2}{\text{Det}(\mathbf{H})} > 10 \quad (3.8)$$

Um exemplo dos pontos selecionados em uma imagem utilizando *Difference of Gaussians* pode ser visto na Figura 3.4(b).

3.2.2 *Harris-Laplace*

No caso do detector de pontos de interesse *Harris-Laplace*, descrito por Mikolajczyk e Schmid (2004), o algoritmo consiste em dois passos: um detector de pontos multi-escala e uma seleção iterativa da escala e localização. No primeiro passo, é usada a função de Harris, apresentada na equação (3.9). O máximo local de c determina a localização dos pontos de interesse.

$$c = \det(\mu(x, \sigma_I, \sigma_D)) - \alpha \text{trace}^2(\mu(x, \sigma_I, \sigma_D)) \quad (3.9)$$

A função de Harris se baseia na *second moment matrix*, representada na equação (3.10). A matriz descreve a distribuição de gradiente na vizinhança de um ponto. Uma propriedade desta matriz é que seus autovalores representam duas mudanças de sinal principais na vizinhança de um ponto, o que permite a extração de pontos que são estáveis em condições de luz variáveis e são representativas de uma imagem. O detector de Harris é baseado neste princípio.

$$\begin{aligned} \mu(x, \sigma_I, \sigma_D) &= \begin{bmatrix} \mu_{11} & \mu_{12} \\ \mu_{21} & \mu_{22} \end{bmatrix} \\ &= \sigma_D^2 g(\sigma_I) * \begin{bmatrix} L_x^2(x, \sigma_D) & L_x L_y(x, \sigma_D) \\ L_x L_y(x, \sigma_D) & L_y^2(x, \sigma_D) \end{bmatrix} \end{aligned} \quad (3.10)$$

onde σ_I é a escala de integração, σ_D é a escala de diferenciação e L_a é a derivada calculada na direção a .

Uma vez identificados os pontos, o detector *Harris-Laplace* seleciona os pontos para os quais a Laplaciana de Gauss, apresentada na equação (3.11), é um máximo local e está acima de um determinado limiar, para alguma das escalas do espaço de escalas. Se o ponto não for máximo local em nenhuma escala ou estiver abaixo do limiar, é descartado e outro ponto passa a ser analisado.

$$|LoG(x, \sigma_n)| = \sigma_n^2 |L_{xx}(x, \sigma_n) + L_{yy}(x, \sigma_n)| \quad (3.11)$$

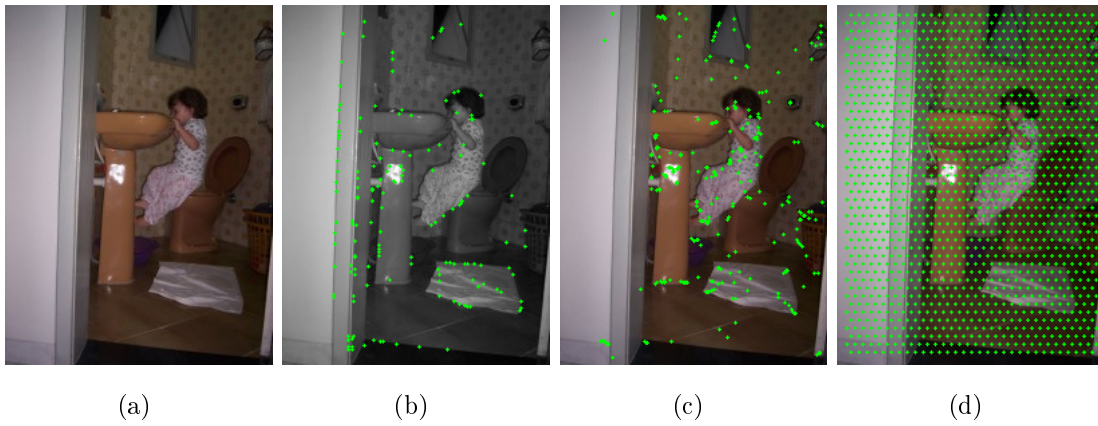


Figura 3.4: Imagem original (a) e demonstração dos pontos de interesse selecionados nesta imagem por (b) *Difference of Gaussians*, (c) *Harris-Laplace* e (d) Amostragem Densa.

A Figura 3.4(c) mostra um exemplo dos pontos selecionados em uma imagem com o uso do detector *Harris-Laplace*.

3.2.3 Amostragem Densa

A técnica de Amostragem Densa consiste em selecionar pontos em intervalos regulares por toda a imagem, sem se basear no conteúdo, como pode ser visto na Figura 3.4(d). A implementação utilizada para este descritor foi a de van de Sande (SANDE; GEVERS; SNOEK, 2008, 2010). Neste trabalho, foram utilizadas as configurações padrão da implementação: são obtidos pontos a cada 6 pixels, sendo que cada linha ímpar é deslocada em 3 pixels, para reduzir a sobreposição de pontos. A escala utilizada é de 1,2.

3.3 Descritores

Foram utilizados três descritores locais: SIFT, que trabalha somente com imagens monocromáticas, porém é invariante à escala, e mais dois que trabalham com imagens coloridas – um invariante à escala no espaço de cores oponentes (OpponentSIFT) e outro invariante tanto à escala quanto à intensidade, também no espaço de cores oponentes (WSIFT). Estes dois últimos são baseados no próprio SIFT, porém trabalham com informações de cores das imagens, ao invés de se limitarem à informação

de intensidade, como explicado nas próximas seções, e foram selecionados por terem sido apontados como os de melhor performance entre os descritores que trabalham com informações de cores, por Sande, Gevers e Snoek (2010).

3.3.1 Invariante à Escala

Com relação aos descritores utilizados, o descritor SIFT, conforme definido por Lowe (LOWE, 2004), é um descritor calculado a partir de uma imagem monocromática, e é invariante à escala e rotação e é robusto a uma substancial gama de transformações afim.

Para o cálculo do descritor, utilizando a imagem suavizada com Filtro Gaussiano, $L(x, y)$, na escala mais próxima da escala do ponto de interesse, identificado através de *Difference of Gaussians*, como descrito na Seção 3.2.1, inicialmente é definida a orientação $\theta(x, y)$ e a magnitude do gradiente $m(x, y)$ nos pontos dentro de uma região em volta do ponto de interesse.

$$m(x, y) = \sqrt{(L(x + 1, y) - L(x - 1, y))^2 + (L(x, y + 1) - L(x, y - 1))^2} \quad (3.12)$$

$$\theta(x, y) = \tan^{-1}((L(x, y + 1) - L(x, y - 1)) / (L(x + 1, y) - L(x - 1, y))) \quad (3.13)$$

Estes pontos recebem pesos de acordo com uma janela Gaussiana, para dar menor ênfase a gradientes que estão distantes do centro do descritor, pois estes são mais afetados por erros de registro. Esses valores são então acumulados em histogramas de orientação sumarizando os conteúdos em subregiões 4×4 , com a soma das magnitudes dos gradientes próximos a cada direção dentro da região. O maior pico no histograma é detectado e identificado como a direção dominante. Se houver outro pico com até 80% do valor do máximo, é criado outro descritor, que terá a mesma localização e escala, porém orientação diferente.

O descritor é formado de um vetor contendo os valores de todas as entradas do histograma de orientação. São armazenadas matrizes de 4×4 histogramas com 8

posições de orientação em cada. Portanto, o vetor do descritor SIFT tem $4 \times 4 \times 8 = 128$ elementos para cada ponto de interesse.

A implementação utilizada já converte as imagens para remover as cores, caso presentes, antes do processamento.

3.3.2 Invariante à Escala no Espaço de Cores Oponentes

O descritor OpponentSIFT (SANDE; GEVERS; SNOEK, 2008) atua com o espaço de cores oponentes, cujo cálculo dos canais é descrito na equação (3.14), onde a informação de intensidade é representada pelo canal O_3 e a informação sobre as cores por O_1 e O_2 . O OpponentSIFT descreve todos os canais do espaço de cores oponentes usando descritores SIFT. Este descritor não é invariante em relação à intensidade da luz, pois os canais O_1 e O_2 também possuem alguma informação de intensidade, nem em relação à cor da luz.

$$\begin{pmatrix} O_1 \\ O_2 \\ O_3 \end{pmatrix} = \begin{pmatrix} \frac{R-G}{\sqrt{2}} \\ \frac{R+G-2B}{\sqrt{6}} \\ \frac{R+G+B}{\sqrt{3}} \end{pmatrix} \quad (3.14)$$

3.3.3 Invariante à Escala e Intensidade no Espaço de Cores Oponentes

O descritor WSIFT (SANDE; GEVERS; SNOEK, 2008) é baseado no espaço de cores oponentes, porém seu objetivo é ser invariante em relação à intensidade da luz. Para atingir este objetivo, é usada a invariante W , que elimina a informação de intensidade dos canais O_1 e O_2 , e pode ser definida como $\frac{O_1}{O_3}$ e $\frac{O_2}{O_3}$. Assim como outros descritores coloridos, este não é invariante a mudança de cor da luz.

3.4 Classificadores

Foram utilizados dois classificadores: Análise Probabilística de Semântica Latente (pLSA) e Naive Bayes. Ambos tratam de produzir modelos de probabilidade

condicional a partir de um conjunto de dados de treino, que serão em seguida aplicados a dados de teste, para efetuar a classificação destes.

3.4.1 Naive Bayes

Como explicado na Seção 3.1, o método de classificação pelo conjunto de características visuais é uma adaptação para classificação de imagens de um método aplicado ao problema de classificação de documentos texto.

Seguindo a explicação de Manning et al. (MANNING; RAGHAVAN; SCHUTZE, 2008), consideremos que temos uma descrição d de um documento (imagem), de forma que $d \in \mathbb{X}$, onde \mathbb{X} é o *espaço de documentos*, e um conjunto de classes $\mathbb{C} = \{c_1, c_2, \dots, c_j\}$. Temos um conjunto de treino \mathbb{D} de documentos previamente classificados $\langle d, c \rangle$, onde $\langle d, c \rangle \in \mathbb{X} \times \mathbb{C}$.

Utilizando um *algoritmo de aprendizado*, desejamos então aprender uma *função de classificação* γ , que mapeie documentos a classes:

$$\gamma : \mathbb{X} \rightarrow \mathbb{C} \quad (3.15)$$

Uma vez aprendido γ , podemos aplicá-la ao *conjunto de teste*, cujas classes são desconhecidas.

No classificador Naive Bayes, a probabilidade de um documento d ser da classe c é calculada como:

$$P(c|d) \propto P(c) \prod_{1 \leq k \leq n_d} P(t_k|c) \quad (3.16)$$

onde $P(t_k|c)$ é a probabilidade condicional do termo t_k ocorrer em um documento da classe c . $P(c)$ é a probabilidade a priori de um documento ocorrer em uma classe c . $\langle t_1, t_2, \dots, t_{n_d} \rangle$ são os descritores em d que fazem parte do *codebook* que usamos para a classificação e n_d é o número de descritores em d .

Para que a Equação (3.16) seja verdadeira, é necessário estabelecer um pressuposto: de que todos os elementos t_k são condicionalmente independentes dos demais, independente de em qual posição do documento apareça. Este pressuposto é que faz este classificador ser chamado de Naive Bayes (*Bayes ingênuo*). Apesar deste pressuposto parecer irreal, o classificador tem demonstrado boa eficácia na prática.

A melhor classe para um dado documento na classificação utilizando Naive Bayes é a classe com o máximo *a posteriori* (MAP) c_{map} :

$$c_{map} = \arg \max_{c \in \mathbb{C}} \hat{P}(c|d) = \arg \max_{c \in \mathbb{C}} \hat{P}(c) \prod_{1 \leq k \leq n_d} \hat{P}(t_k|c) \quad (3.17)$$

onde \hat{P} é uma estimativa de P obtida a partir do conjunto de treino.

Para evitar que ocorra *underflow* pela multiplicação de várias probabilidades condicionais, em muitas implementações de Naive Bayes, é utilizado o somatório dos logaritmos das probabilidades, já que $\log(xy) = \log(x) + \log(y)$. Portanto o cálculo que é realmente feito em muitas implementações é:

$$c_{map} = \arg \max_{c \in \mathbb{C}} \left[\log \hat{P}(c) + \sum_{1 \leq k \leq n_d} \log \hat{P}(t_k|c) \right] \quad (3.18)$$

A estimativa de $\hat{P}(c)$ é:

$$\hat{P}(c) = \frac{N_c}{N} \quad (3.19)$$

onde N_c é o número de documentos na classe c e N é o número total de documentos.

Estimamos a probabilidade condicional $\hat{P}(t|c)$ como a frequência relativa do termo t em documentos que pertencem à classe c :

$$\hat{P}(t|c) = \frac{T_{ct}}{\sum_{t' \in V} T_{ct'}} \quad (3.20)$$

onde T_{ct} é o número de ocorrências de t nos documentos de treino que pertencem à classe c , incluindo múltiplas ocorrências de um termo em um documento.

O problema desta estimativa de $\hat{P}(t|c)$ é que se um termo não ocorrer em uma determinada classe no conjunto de treino, o produto indicado na Equação (3.17) resulta em zero, independente dos demais termos do documento. Para evitar este efeito, é utilizado “somar um” ou “*Laplace smoothing*”, o que simplesmente adiciona um em cada conta:

$$\hat{P}(t|c) = \frac{T_{ct} + 1}{\sum_{t' \in V} (T_{ct'} + 1)} = \frac{T_{ct} + 1}{(\sum_{t' \in V} T_{ct'}) + B} \quad (3.21)$$

onde $B = |V|$ é o número de termos no vocabulário.

Os diagramas nos Apêndices C e D ilustram o código implementado com o uso de Naive Bayes.

3.4.2 Análise Probabilística de Semântica Latente

O Apêndice B apresenta em forma geral o funcionamento da implementação do classificador de Análise Probabilística de Semântica Latente (pLSA) feita por Fei-Fei, Fergus e Torralba (2005), como parte do método de classificação por conjunto de características visuais, conforme descrito no trabalho de Sivic et al. (2005).

A probabilidade $P(t_i, d_j, c_k)$ tem a forma apresentada no modelo gráfico da Figura 3.5. Marginalizando sobre as classes c_k , é determinada a probabilidade condicional $P(t_i|d_j)$:

$$P(t_i|d_j) = \sum_{k=1}^K P(c_k|d_j)P(t_i|c_k) \quad (3.22)$$

Onde $P(c_k|d_j)$ é a probabilidade de uma classe c_k acontecer no documento d_j ; e $P(t_i|c_k)$ é a probabilidade do termo t_i ocorrer em uma determinada classe.

Cada documento neste modelo é descrito como um conjunto de K classes. Isto nos leva a uma decomposição de matriz, como ilustrado na Figura 3.6, com a restrição




Figura 3.5: Modelo gráfico do pLSA. Nós dentro de um quadro indicam que eles são replicados o número de vezes indicados no canto superior esquerdo. Círculos preenchidos indicam variáveis aleatórias observadas; não preenchidos são não observadas. Adaptado de Sivic et al. (2005, p. 3).




Figura 3.6: No pLSA, o objetivo é encontrar a distribuição específica de tópicos $P(t|c_k)$ e as correspondentes proporções de mistura específicas de cada documento $P(c|d_j)$, que cria a distribuição de palavras específica de um documento $P(t|d_j)$. Adaptado de Sivic et al. (2005, p. 3).

que os vetores e os coeficientes são normalizados para fazer deles distribuições de probabilidade.

Encaixar no modelo requer determinar os vetores de classes que são comuns a todos os documentos e os coeficientes que são específicos para cada documento. O objetivo é determinar o modelo que resulta em alta probabilidade dos termos de aparecerem no documento. Uma estimativa é obtida ao maximizar a equação:

$$L = \prod_{i=1}^B \prod_{j=1}^N P(t_i|d_j)^{n(t_i,d_j)} \quad (3.23)$$

onde $P(t_i|d_j)$ é fornecido por (3.22).

3.5 Medidas de Avaliação

Para a análise dos dados, foram utilizadas algumas métricas comumente usadas para avaliar a performance de classificadores (FAWCETT, 2006). As métricas se baseiam nos dados da Matriz Confusão, ilustrada na Tabela 3.4.

| | | Classe Verdadeira | |
|---------------------|---|----------------------------|----------------------------|
| | | p | n |
| Classe Calculada | Y | Positivos Verdadeiros (TP) | Falsos Positivos (FP) |
| | N | Falsos Negativos (FN) | Negativos Verdadeiros (TN) |
| Totais das colunas: | | P | N |

Tabela 3.4: Matriz Confusão. Adaptado de Fawcett (2006, p.862).

As métricas utilizadas foram: Revocação, Taxa de Falsos Positivos, Precisão e Acurácia. A primeira indica o índice de positivos verdadeiros, isto é, quantas das imagens da categoria “positiva” foram identificadas corretamente. Esta métrica também é chamada de *recall* ou simplesmente Taxa de Positivos Verdadeiros. A segunda, Taxa de Falsos Positivos, indica o índice de falsos positivos, isto é, quantas das imagens da categoria “negativa” foram incorretamente classificadas.

$$\text{Revocação} \approx \frac{\text{Positivos corretamente classificados}}{\text{Total de positivos}} = \frac{TP}{P} = \frac{TP}{TP + FN} \quad (3.24)$$

$$\text{Taxa de Falsos Positivos} \approx \frac{\text{Negativos incorretamente classificados}}{\text{Total de negativos}} = \frac{FP}{N} = \frac{FP}{FP + TN} \quad (3.25)$$

Das outras duas métricas, Precisão indica, das imagens que foram identificadas pelo classificador como fazendo parte da categoria “positiva”, qual a proporção das que são realmente desta categoria. Já Acurácia representa o qual foi o acerto global do classificador, juntando os acertos nas duas categorias, em relação ao total de imagens.

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (3.26)$$

$$\text{Acurácia} = \frac{TP + TN}{P + N} \quad (3.27)$$

4 Resultados e Análise

Foram realizados no total 25 experimentos, combinando os 5 pares de categorias listados na tabela 3.2 com as 5 combinações de detectores de pontos de interesse e descritores listados na Tabela 3.3. Cada experimento foi executado 10 vezes e foi calculada a média e o desvio padrão das execuções, para a construção das Tabelas Confusão, que podem ser vistas no Apêndice A. Abaixo são analisadas as medidas de avaliação de cada experimento com relação às diversas combinações de detectores e descritores e também entre os experimentos. Estas medidas foram calculadas a partir das médias apresentadas nas Tabelas Confusão citadas. Para cada execução dos experimentos, foram selecionadas aleatoriamente as 50 imagens de cada categoria que foram utilizadas na fase de treino e as 50 utilizadas na fase de teste.

| Experimento | <i>Harris-Laplace</i> | | Amostragem Densa | | <i>Diff of Gaussians</i> |
|--|-----------------------|-------|------------------|-------|--------------------------|
| | OpponentSIFT | WSIFT | OpponentSIFT | WSIFT | SIFT |
| Geral × Pornografia feminina | 81% | 87% | 88% | 89% | 84% |
| Geral × Pornografia infantil feminina | 78% | 90% | 88% | 90% | 85% |
| Trajes sumários × Pornografia feminina | 76% | 82% | 82% | 82% | 57% |
| Trajes sumários × Pornografia infantil feminina | 80% | 80% | 84% | 85% | 51% |
| Pornografia feminina × Pornografia infantil feminina | 67% | 60% | 67% | 67% | 58% |

Tabela 4.1: Revocação dos diversos experimentos

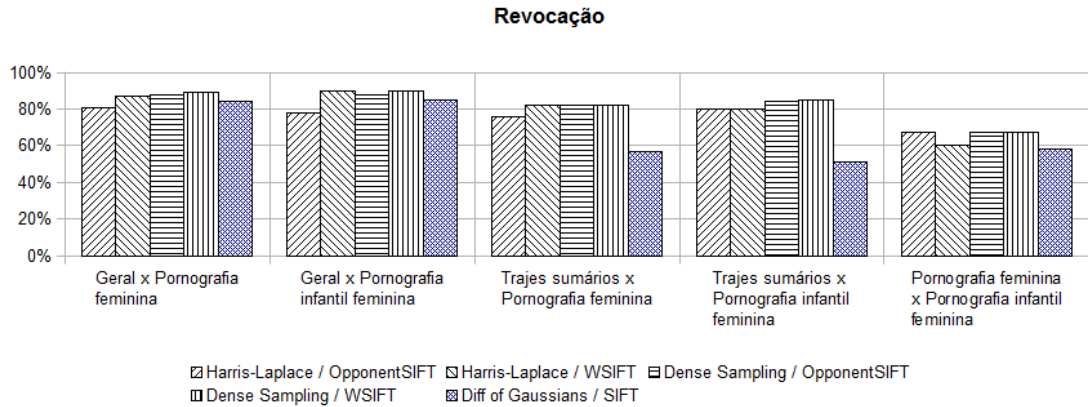


Figura 4.1: Revocação para todos os experimentos.




Figura 4.2: Taxa de Falsos Positivos para todos os experimentos.

4.1 Experimento 1: Categorias Pornografia feminina e Geral

O primeiro experimento comparou imagens das categorias Pornografia feminina e Geral, com o intuito de verificar a capacidade do método de diferenciar pornografia feminina de imagens gerais não pornográficas, duas categorias bastante distintas. A revocação atingida nesta classificação pode ser vista na Tabela 4.1. A maior Revocação obtida foi de 89% utilizando Amostragem Densa e WSIFT. A menor Revocação foi de 81%, utilizando *Harris-Laplace* e OpponentSIFT. Pode ser observado na tabela 4.1 que para este experimento, a combinação de Amostragem Densa com qualquer dos dois descritores analisados teve resultado melhor que os detectores *Harris-Laplace* e *Difference of Gaussians*.

A Taxa de Falsos Positivos variou de 16% a 26%. É visível na figura 4.2 que o resultado

| Experimento | <i>Harris-Laplace</i> | | Amostragem Densa | | <i>Diff of Gaussians</i> |
|--|-----------------------|-------|------------------|-------|--------------------------|
| | OpponentSIFT | WSIFT | OpponentSIFT | WSIFT | SIFT |
| Geral × Pornografia feminina | 26% | 23% | 19% | 16% | 16% |
| Geral × Pornografia infantil feminina | 18% | 24% | 16% | 18% | 15% |
| Trajes sumários × Pornografia feminina | 34% | 35% | 38% | 24% | 43% |
| Trajes sumários × Pornografia infantil feminina | 18% | 25% | 29% | 23% | 49% |
| Pornografia feminina × Pornografia infantil feminina | 20% | 21% | 26% | 24% | 42% |

Tabela 4.2: Taxa de Falsos Positivos dos diversos experimentos

com Amostragem Densa e *Difference of Gaussians* foi consideravelmente melhor que quando usado detector *Harris-Laplace*. A taxa de precisão (Precisão) variou entre 76% e 85%, sendo que mais uma vez *Harris-Laplace* apresentou resultado inferior aos demais, o que se repetiu na medida de Acurácia, quando os valores variaram de 78% a 87%.

4.2 Experimento 2: Categorias Pornografia infantil feminina e Geral

No segundo experimento, foram comparadas imagens das categorias Pornografia infantil feminina e Geral, buscando avaliar se a comparação com imagens de pornografia infantil feminina tem performance diferente da comparação de pornografia feminina (adulta). A Revocação neste experimento variou de 78%, com *Harris-Laplace* e OpponentSIFT, a 90%, com WSIFT (tanto Amostragem Densa quanto *Harris-Laplace*). Neste segundo experimento, o descritor WSIFT teve performance bem superior ao OpponentSIFT e ao SIFT com relação à Revocação, como pode ser visto

| Experimento | <i>Harris-Laplace</i> | | Amostragem Densa | | <i>Diff of Gaussians</i> |
|--|-----------------------|-------|------------------|-------|--------------------------|
| | OpponentSIFT | WSIFT | OpponentSIFT | WSIFT | SIFT |
| Geral × Pornografia feminina | 76% | 79% | 82% | 85% | 84% |
| Geral × Pornografia infantil feminina | 82% | 79% | 84% | 84% | 85% |
| Trajes sumários × Pornografia feminina | 69% | 70% | 68% | 78% | 57% |
| Trajes sumários × Pornografia infantil feminina | 82% | 77% | 75% | 79% | 51% |
| Pornografia feminina × Pornografia infantil feminina | 77% | 74% | 72% | 73% | 58% |

Tabela 4.3: Precisão dos diversos experimentos

na Figura 4.1. Em compensação, tal performance não se repetiu com relação à Taxa de Falsos Positivos, como fica claro na Tabela 4.2, onde se vê que a combinação do detector *Harris-Laplace* e do descritor WSIFT teve performance muito pior que as demais, atingindo 24%, contra 18% das combinações de Amostragem Densa com WSIFT e *Harris-Laplace* com OpponentSIFT, 16% de Amostragem Densa e OpponentSIFT e 15% de *Difference of Gaussians* e SIFT, que foi a melhor performance neste experimento com relação à Taxa de Falsos Positivos.

Ao analisarmos os valores de Precisão e Acurácia neste experimento, vemos que a combinação de *Difference of Gaussians* e SIFT teve a melhor performance em termos de Precisão e a segunda melhor quando consideramos a Acurácia, como pode ser verificado nas Tabelas 4.3 e 4.4. Para essas métricas, também podemos ver que o detector *Harris-Laplace* obteve as piores performances. As combinações que incluíram o detector Amostragem Densa tiveram a melhor performance em termos de Acurácia e a segunda melhor em Precisão.

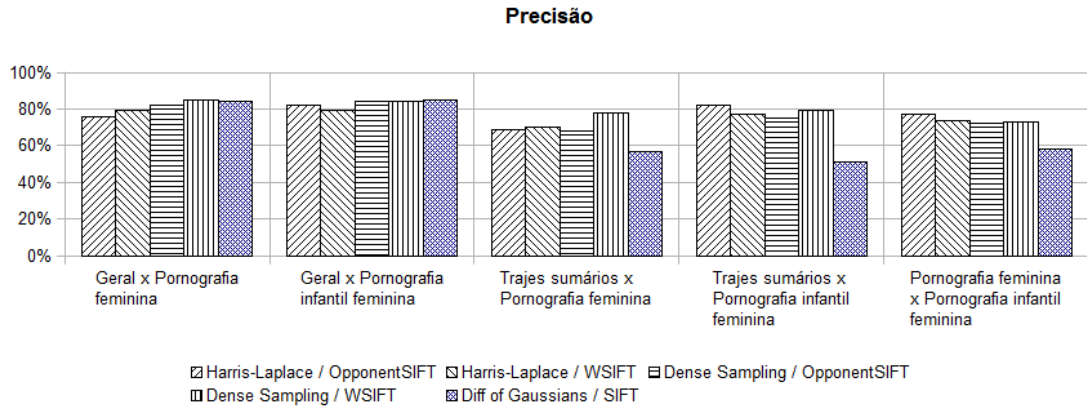


Figura 4.3: Precisão para todos os experimentos.




Figura 4.4: Acurácia para todos os experimentos.

4.3 Experimento 3: Categorias Pornografia feminina e Trajes sumários

As categorias Pornografia feminina e Trajes sumários foram comparadas no terceiro experimento, visando verificar o quanto a performance dos classificadores é afetada quando se comparam imagens pornográficas com outras que, apesar de não serem pornográficas, possuem grandes extensões de pele expostas, por pessoas vestindo trajes sumários. Como esperado, houve uma redução de performance em todas as combinações de detectores de pontos de interesse e descritores locais, de acordo com todas as métricas utilizadas. A Revocação teve sua maior variação com a combinação de *Difference of Gaussians* e SIFT, que atingiu 57%, contra 84% do primeiro experimento, como é visível na Figura 4.1. A utilização de Amostragem Densa continuou apresentando melhor performance com Revocação do que os demais detectores e WSIFT se confirmou como melhor descritor, mantendo a tendência dos

| Experimento | <i>Harris-Laplace</i> | | Amostragem Densa | | <i>Diff of Gaussians</i> |
|--|-----------------------|-------|------------------|-------|--------------------------|
| | OpponentSIFT | WSIFT | OpponentSIFT | WSIFT | SIFT |
| Geral × Pornografia feminina | 78% | 82% | 85% | 87% | 84% |
| Geral × Pornografia infantil feminina | 80% | 83% | 86% | 86% | 85% |
| Trajes sumários × Pornografia feminina | 71% | 74% | 72% | 79% | 57% |
| Trajes sumários × Pornografia infantil feminina | 81% | 78% | 78% | 81% | 51% |
| Pornografia feminina × Pornografia infantil feminina | 74% | 69% | 70% | 71% | 58% |

Tabela 4.4: Acurácia dos diversos experimentos

experimentos anteriores.

Com relação à Taxa de Falsos Positivos, a combinação de Amostragem Densa com WSIFT destaca-se das demais, pois obteve índice de 24% contra índices que variaram de 34% (*Harris-Laplace* e OpponentSIFT) a 43% (*Difference of Gaussians* e SIFT) nas demais combinações de detectores e descritores. Com relação à Precisão e Acurácia, a combinação de Amostragem Densa e WSIFT também se destacou positivamente, atingindo índices de 78% e 79%, respectivamente, bastante acima das demais.

4.4 Experimento 4: Categorias Pornografia infantil feminina e Trajes sumários

O quarto experimento comparou imagens das categorias Pornografia infantil feminina e Trajes sumários, visando comparar a performance tanto com o segundo quanto com o terceiro experimentos. A variação da Revocação com relação ao experimento anterior

foi pequena, sendo que se confirmou a performance fraca da combinação *Difference of Gaussians* e SIFT em relação às demais, atingindo um máximo de apenas 51%, como visto na Tabela 4.1. A combinação de *Harris-Laplace* com OpponentSIFT foi a única que obteve resultados melhores neste experimentos do que nos anteriores, porém atingiu apenas índice de 80%, abaixo dos índices alcançados ao se usar a Amostragem Densa, de 84% e 85%.

Ao analisarmos a Figura 4.2 é possível ver que a combinação de *Difference of Gaussians* e SIFT teve performance muito inferior às demais, classificando consideravelmente mais imagens da categoria Trajes sumários como sendo da categoria Pornografia infantil feminina. Neste quesito, a combinação citada teve Taxa de Falsos Positivos de 49%. Com relação ao segundo experimento, as combinações utilizando *Harris-Laplace* tiveram performance igual (com OpponentSIFT) ou muito similar (com WSIFT) e a Amostragem Densa, assim como a *Difference of Gaussians* tiveram performance bastante inferior com relação à Taxa de Falsos Positivos. Já com relação ao terceiro experimento, as combinações de *Harris-Laplace* com OpponentSIFT e WSIFT e a combinação de Amostragem Densa com OpponentSIFT tiveram a Taxa de Falsos Positivos substancialmente menores neste (9 pontos percentuais ou mais), como pode ser analisado na Tabela 4.2. A combinação Amostragem Densa e WSIFT teve índice muito próximo ao do terceiro experimento: 23% contra 24%. Somente a combinação de *Difference of Gaussians* e SIFT teve performance pior neste experimento em relação ao terceiro.

Ao analisar os dados de Precisão com relação a este experimento, vemos na Tabela 4.3 que todos os índices obtidos são inferiores aos índices obtidos no segundo experimento, com exceção à combinação de *Harris-Laplace* com OpponentSIFT, que repetiu o índice de 82%, sendo o máximo de Precisão neste quarto experimento. A maior diferença neste caso ocorreu na combinação da *Difference of Gaussians* com SIFT, quando o índice passou de 85% para 51%. Com relação ao terceiro experimento, as combinações de *Harris-Laplace* e de Amostragem Densa tiveram performance melhor no quarto experimento. Somente o par *Difference of Gaussians* com SIFT teve performance pior que o terceiro experimento, passando de 57% para 51%.

Sobre a medida de Acurácia, ao comparar os dados do quarto com o segundo experimento, observamos que a combinação *Harris-Laplace* e OpponentSIFT teve resultado levemente melhor no quarto experimento (81% contra 80% no segundo). As demais combinações tiveram resultados inferiores no quarto experimento. Na

comparação com o terceiro experimento, o comportamento da medida de Precisão se repetiu: somente *Difference of Gaussians* e SIFT tiveram performance pior no quarto experimento.

4.5 Experimento 5: Categorias Pornografia infantil feminina e Pornografia feminina

O quinto experimento comparou imagens das categorias Pornografia infantil feminina e Pornografia feminina, visando analisar se a diferença de idade e as características de cada tipo de imagem é capaz de fornecer elementos para diferenciar pornografia feminina adulta da infantil. Este experimento é considerado o mais complexo de todos. Como pode ser observado na Figura 4.1, em geral a performance dos classificadores neste par de categorias foi inferior aos demais experimentos, como era de se esperar. A única exceção foi na combinação de *Difference of Gaussians* e SIFT, que apresentou performance pouco melhor que a do terceiro experimento, com Revocação de 58% (o terceiro teve Revocação de 57%), e superior que a do quarto experimento, onde foi observado índice de 51%.

Este comportamento não se repetiu com relação à Taxa de Falsos Positivos: as combinações de *Harris-Laplace* com WSIFT e de Amostragem Densa com OpponentSIFT tiveram valores melhores que o terceiro e o quarto experimentos. O par Amostragem Densa e WSIFT igualou a performance no terceiro experimento e foi um pouco pior que no quarto. A combinação de *Harris-Laplace* com WSIFT teve performance melhor que os dois primeiros experimentos também. A combinação de *Harris-Laplace* com OpponentSIFT obteve performance melhor que os experimentos 1 e 3, onde imagens da categoria Pornografia feminina foram comparadas com imagens não pornográficas, porém pior que os experimentos 2 e 4, onde imagens da categoria Pornografia infantil feminina foram comparadas também com imagens não pornográficas. O par de *Difference of Gaussians* com SIFT, tiveram valores piores que todas as demais combinações, com Taxa de Falsos Positivos de 42%.

Quando levamos em conta a Precisão, a combinação Amostragem Densa com WSIFT teve resultados inferiores aos demais experimentos. As combinações com *Harris-Laplace* e a combinação de Amostragem Densa com OpponentSIFT tiveram Precisão maior que a alcançada no terceiro experimento e inferior à alcançada no quarto experimento. A combinação de *Difference of Gaussians* e SIFT apresentou performance

pior que os três primeiros experimentos, e melhor que o quarto experimento, que atingiu somente 51%.

Ao considerarmos a Acurácia, em geral, as quatro combinações dos *color descriptors* (OpponentSIFT e WSIFT) apresentaram performance inferior ou igual (em apenas um caso) que a dos demais experimentos realizados. A única exceção está par *Harris-Laplace* e OpponentSIFT, que teve resultado melhor neste quinto experimento que no terceiro. No caso da *Difference of Gaussians* e SIFT, a Acurácia foi quase igual ao terceiro experimento, com 58% contra 57% e melhor que no quarto, que teve 51%.

4.6 Resumo dos Resultados

| Exper. | Detectores | | | Descritores | | |
|--------|-----------------------|------------------|--------------------------------|---------------|-------|------|
| | <i>Harris-Laplace</i> | Amostragem Densa | <i>Difference of Gaussians</i> | Opponent SIFT | WSIFT | SIFT |
| 1 | 0 | 4 | 1 | 0 | 4 | 1 |
| 2 | 1 | 2 | 2 | 1 | 3 | 2 |
| 3 | 1 | 5 | 0 | 1 | 5 | 0 |
| 4 | 3 | 2 | 0 | 3 | 2 | 0 |
| 5 | 4 | 2 | 0 | 5 | 1 | 0 |
| Total | 9 | 15 | 3 | 10 | 15 | 3 |

Tabela 4.5: Quantidade de valores máximos e mínimos, entre as medidas de avaliação utilizadas, para cada experimento. O número de máximos e mínimos supera a quantidade de experimentos realizados, pois houve empates em alguns experimentos.

A Tabela 4.5 foi construída contando quais combinações de detectores e descritores atingiram valores máximos (para Revocação, Precisão e Acurácia) ou mínimos (para Taxa de Falsos Positivos) em cada um dos pares de categorias analisados, a partir dos dados das Tabelas 4.1, 4.2, 4.3 e 4.4. Quando mais de uma combinação obteve o valor extremo da medida de avaliação, todas as ocorrências eram somadas para o descritor e o detector correspondente, inclusive podendo contar dobrado para um certo descritor ou detector. Por exemplo, na Tabela 4.1, o experimento 2 teve dois valores máximos para a revocação. Neste caso, foi somado 1 para *Harris-Laplace*, 1 para Amostragem Densa e 2 para WSIFT na Tabela 4.5.

Com relação à Revocação, houve 10 índices máximos, pois ocorreram alguns empates entre combinações de detectores e descritores. Destes 10 índices máximos: 7 utilizaram Amostragem Densa e 3 utilizaram *Harris-Laplace*; 7 utilizaram WSIFT e 3 utilizaram OpponentSIFT, como pode ser verificado na Tabela 4.1.

Ao considerarmos a Taxa de Falsos Positivos, podemos identificar um mínimo para cada experimento na Tabela 4.2, com exceção do experimento 1, onde houve dois mínimos empatados. Destes 6 mínimos: 2 foram com uso do WSIFT, 2 com SIFT e 2 com OpponentSIFT; 2 utilizaram *Harris-Laplace*, 2 outros, Amostragem Densa e os 2 restantes, *Difference of Gaussians*. Apesar do “empate” entre os diferentes detectores e descritores, cabe salientar que os experimentos 4 e 5, considerados mais complexos e relevantes, tiveram ambos o valor mínimo com utilização de *Harris-Laplace* e OpponentSIFT.

Pela análise da métrica Precisão, podemos identificar 5 valores máximos na Tabela 4.3: 2 com uso de OpponentSIFT, 2 com uso de WSIFT e 1 com uso de SIFT; 2 com uso de Amostragem Densa, 2 com uso de *Harris-Laplace* e 1 com uso de *Difference of Gaussians*. Novamente é observado um resultado melhor nos experimentos 4 e 5 com o uso de *Harris-Laplace* e OpponentSIFT.

Já ao analisarmos a Acurácia, podemos identificar 7 valores máximos na Tabela 4.4: 5 deles usam Amostragem Densa e 2, *Harris-Laplace*; 4 utilizaram WSIFT e os outros 3, OpponentSIFT.

Se considerarmos apenas os experimentos 1 e 3 (de acordo com a Tabela 3.2), onde houve apenas comparação de imagens não pornográficas com imagens de pornografia feminina (sem ser pornografia infantil), quase todos os máximos e mínimos foram atingidos com o uso de Amostragem Densa e WSIFT.

Ao considerarmos o experimento 2, que comparou imagens das categorias Geral e Pornografia infantil feminina, os melhores resultados foram obtidos com Amostragem Densa e WSIFT ou com *Difference of Gaussians* e SIFT. Apenas um extremo deste experimento foi obtido com *Harris-Laplace* e OpponentSIFT.

Já no experimento 4, que comparou imagens da categoria Pornografia infantil feminina com as da categoria Trajes sumários, a maioria dos valores máximos e da mínima Taxa de Falsos Positivos foram obtidos com a combinação *Harris-Laplace* e OpponentSIFT,

sendo os demais resultados extremos obtidos com o uso de Amostragem Densa e WSIFT.

Por fim, no experimento considerado mais complexo, que comparou imagens das categorias Pornografia feminina e Pornografia infantil feminina, a combinação de *Harris-Laplace* e OpponentSIFT obteve o valor máximo em todas as medidas de avaliação, sendo que a medida de Revocação teve empate no valor máximo com as duas combinações de Amostragem Densa.

5 Conclusões

Para o problema de classificação de imagens de pornografia e pornografia infantil, o método de classificação pelo conjunto de características visuais se mostrou viável. A técnica de Amostragem Densa apresenta melhores resultados na identificação de pontos de interesse, indicando que talvez os atuais detectores de pontos não selecionam adequadamente pontos em regiões relevantes do corpo humano. Porém, cabe destacar que o detector *Harris-Laplace* obteve boa performance nas classificações mais complexas, envolvendo imagens de pornografia infantil. A informação de cores é importante para a classificação de pornografia e pornografia infantil: o descritor SIFT apresenta baixa performance nas comparações mais difíceis, por não utilizar informações de cores.

Nas comparações mais simples, de Pornografia feminina com imagens não pornográficas ou mesmo de Pornografia infantil feminina com imagens gerais, a Amostragem Densa e o descritor WSIFT apresentam resultados superiores. Porém, nas comparações mais complexas, de Pornografia infantil feminina com Trajes sumários ou com Pornografia feminina, o detector de pontos *Harris-Laplace* e o descritor OpponentSIFT apresentaram resultados melhores.

5.1 Contribuições

Até onde foi identificado, este é o primeiro trabalho de análise comparativa de descritores locais na classificação de pornografia infantil. Por isso, houve dificuldade no acesso a bases de imagens para análise e trabalhos similares para comparações. Foi identificada a importância do uso de descritores que trabalham com as informações de cores das imagens, inclusive na comparação de imagens de pornografia adulta *versus* infantil. Foi confirmada a viabilidade do uso de classificação pelo conjunto de características visuais para classificação de imagens de pornografia e pornografia infantil, mesmo com o uso de diferentes detectores de pontos de interesse e descritores locais.

5.2 Trabalhos Futuros

A seguir listamos algumas extensões possíveis do trabalho aqui apresentado, visando subsidiar pesquisas futuras na área:

1. Inclusão de imagens envolvendo pornografia masculina (adulta e infantil) e envolvendo pornografia com mais de uma pessoa (tanto envolvendo criança quanto somente adultos).
2. Construção de bases de imagens maiores, para análise em larga escala.
3. Desenvolvimento de um melhor detector de pontos de interesse que identifique pontos característicos em áreas com cor da pele de forma mais específica, aumentando a taxa de acerto do método.
4. Estender o trabalho para análise de vídeos, utilizando a técnica aqui descrita.

REFERÊNCIAS BIBLIOGRÁFICAS

BRASIL. Lei nº8.069, de 13 de julho de 1990. *Diário Oficial da União*, 16 de julho 1990. Dispõe sobre o Estatuto da Criança e do Adolescente e dá outras providências. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/L8069.htm>.

BRASIL. Lei nº11.829, de 25 de novembro de 2008. *Diário Oficial da União*, 26 de novembro 2008. Altera a Lei nº8.069, de 13 de julho de 1990 - Estatuto da Criança e do Adolescente. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2008/lei/l11829.htm>.

EATON, J. W. *GNU Octave*. 2011. [Http://www.octave.org](http://www.octave.org). Disponível em: <<http://www.octave.org>>.

FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861 – 874, 2006. ISSN 0167-8655. ROC Analysis in Pattern Recognition.

FEI-FEI, L.; FERGUS, R.; TORRALBA, A. Recognizing and learning object categories. *ICCV Short Course*, 2005. Disponível em: <<http://people.csail.mit.edu/fergus/iccv2005/bagwords.html>>.

FEI-FEI, L.; PERONA, P. A bayesian hierarchical model for learning natural scene categories. In: IEEE. *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. San Diego, CA, USA, 2005. v. 2, p. 524 – 531. ISSN 1063-6919.

JONES, E. et al. *SciPy: Open source scientific tools for Python*. 2001. Disponível em: <<http://www.scipy.org/>>.

LIENHART, R.; HAUKE, R. Filtering adult image content with topic models. In: IEEE. *Multimedia and Expo, 2009. ICME 2009. IEEE International Conference on*. New York, NY, USA, 2009. p. 1472 –1475. ISSN 1945-7871.

LOPES, A. et al. A bag-of-features approach based on hue-sift descriptor for nude detection. In: EURASIP. *Proceedings of the 17th European Signal Processing Conference*. Glasgow, Scotland, 2009. p. 1552–1556.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, Springer Netherlands, v. 60, p. 91–110, 2004. ISSN 0920-5691.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: *5th Berkeley Symposium on Mathematical Statistics and Probability*. Berkeley, CA, USA: University of California Press, 1967. v. 1, p. 281–297.

MANNING, C.; RAGHAVAN, P.; SCHUTZE, H. *Introduction to information retrieval*. Cambridge University Press Cambridge, 2008. Draft. Disponível em: <<http://nlp.stanford.edu/IR-book/>>.

MIKOLAJCZYK, K.; SCHMID, C. Scale & affine invariant interest point detectors. *International Journal of Computer Vision*, Springer Netherlands, v. 60, p. 63–86, 2004. ISSN 0920-5691.

POLASTRO, M. de C.; ELEUTERIO, P. M. da S. Nudetective: A forensic tool to help combat child pornography through automatic nudity detection. In: *Database and Expert Systems Applications, International Workshop on*. Bilbao, Spain: IEEE Computer Society, 2010. p. 349 –353. ISSN 1529-4188. Issue Date : Aug. 30 2010-Sept. 3 2010.

SANDE, K. E. A. van de; GEVERS, T.; SNOEK, C. G. M. Evaluation of color descriptors for object and scene recognition. In: IEEE COMPUTER SOCIETY. *IEEE Conference on Computer Vision and Pattern Recognition*. Anchorage, Alaska, USA, 2008.

SANDE, K. E. A. van de; GEVERS, T.; SNOEK, C. G. M. Evaluating color descriptors for object and scene recognition. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 32, n. 9, p. 1582 –1596, sept. 2010. ISSN 0162-8828.

SHECHTMAN, E.; IRANI, M. Matching local self-similarities across images and videos. In: IEEE COMPUTER SOCIETY. *Computer Vision and Pattern Recognition, 2007. CVPR '07. IEEE Conference on*. Minneapolis, Minnesota, USA, 2007. p. 1–8.

SIVIC, J. et al. Discovering object categories in image collections. In: *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. Beijing, China: IEEE Computer Society, 2005.

SZELISKI, R. *Computer vision: Algorithms and applications*. Springer-Verlag New York Inc, 2010. September 3, 2010 draft. Disponível em: <<http://szeliski.org/Book/>>.

THOMPSON, G. Automatic detection of child pornography. In: CONFERENCES, S. R. C. (Ed.). *Proceedings of the 7th Australian Digital Forensics Conference*. Edith Cowan University, Perth Western Australia, 2009.

ULGES, A.; STAHL, A. Automatic detection of child pornography using color visual words. In: IEEE. *Proceedings of the IEEE International Conference on Multimedia and Expo. (ICME-11)*. Barcelona, Spain, 2011.

Apêndices

A Resultados dos Experimentos Realizados

A.1 Experimento 1: Categorias Geral e Pornografia feminina

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-------|---------------|
| | Pornografia feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 40.4 | 2.6 | 12.9 | 1.7 |
| Geral | 9.6 | 2.6 | 37.1 | 1.7 |

Tabela A.1: Resultado do experimento entre as categorias Pornografia feminina e Geral usando *Harris-Laplace* e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-------|---------------|
| | Pornografia feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 43.5 | 2.7 | 11.5 | 1.8 |
| Geral | 6.5 | 2.7 | 38.5 | 1.8 |

Tabela A.2: Resultado do experimento entre as categorias Pornografia feminina e Geral usando *Harris-Laplace* e WSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-------|---------------|
| | Pornografia feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 44.2 | 1.8 | 9.4 | 2.0 |
| Geral | 5.8 | 1.8 | 40.6 | 2.0 |

Tabela A.3: Resultado do experimento entre as categorias Pornografia feminina e Geral usando Amostragem Densa e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-------|---------------|
| | Pornografia feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 44.6 | 2.3 | 8.0 | 2.4 |
| Geral | 5.4 | 2.3 | 42.0 | 2.4 |

Tabela A.4: Resultado do experimento entre as categorias Pornografia feminina e Geral usando Amostragem Densa e WSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-------|---------------|
| | Pornografia feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 42.0 | 1.6 | 8.0 | 1.6 |
| Geral | 8.0 | 1.6 | 42.0 | 1.6 |

Tabela A.5: Resultado do experimento entre as categorias Pornografia feminina e Geral usando *Difference of Gaussians* e SIFT

A.2 Experimento 2: Categorias Geral e Pornografia infantil feminina

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-------|---------------|
| | Pornografia infantil feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 39.2 | 3.1 | 8.8 | 2.3 |
| Geral | 10.8 | 3.1 | 41.2 | 2.3 |

Tabela A.6: Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando *Harris-Laplace* e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-------|---------------|
| | Pornografia infantil feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 45.2 | 1.5 | 12.1 | 2.3 |
| Geral | 4.8 | 1.5 | 37.9 | 2.3 |

Tabela A.7: Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando *Harris-Laplace* e WSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-------|---------------|
| | Pornografia infantil feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 43.8 | 2.4 | 8.2 | 2.3 |
| Geral | 6.2 | 2.4 | 41.8 | 2.3 |

Tabela A.8: Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando Amostragem Densa e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-------|---------------|
| | Pornografia infantil feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 44.9 | 2.4 | 8.8 | 2.2 |
| Geral | 5.1 | 2.4 | 41.2 | 2.2 |

Tabela A.9: Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando Amostragem Densa e WSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-------|---------------|
| | Pornografia infantil feminina | | Geral | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 42.7 | 1.6 | 7.3 | 1.6 |
| Geral | 7.3 | 1.6 | 42.7 | 1.6 |

Tabela A.10: Resultado do experimento entre as categorias Geral e Pornografia infantil feminina usando *Difference of Gaussians* e SIFT

A.3 Experimento 3: Categorias Trajes sumários e Pornografia feminina

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-----------------|---------------|
| | Pornografia feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 38.0 | 4.2 | 17.2 | 2.7 |
| Trajes sumários | 12.0 | 4.2 | 32.8 | 2.7 |

Tabela A.11: Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando *Harris-Laplace* e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-----------------|---------------|
| | Pornografia feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 41.0 | 3.5 | 17.3 | 4.3 |
| Trajes sumários | 9.0 | 3.5 | 32.7 | 4.3 |

Tabela A.12: Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando *Harris-Laplace* e WSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-----------------|---------------|
| | Pornografia feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 41.1 | 2.8 | 19.0 | 4.5 |
| Trajes sumários | 8.9 | 2.8 | 31.0 | 4.5 |

Tabela A.13: Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando Amostragem Densa e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-----------------|---------------|
| | Pornografia feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 41.0 | 3.4 | 11.8 | 2.7 |
| Trajes sumários | 9.0 | 3.4 | 38.2 | 2.7 |

Tabela A.14: Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando Amostragem Densa e WSIFT

| Categoria Identificada | Categoria Real | | | |
|------------------------|----------------------|---------------|-----------------|---------------|
| | Pornografia feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia feminina | 28.7 | 1.3 | 21.3 | 1.3 |
| Trajes sumários | 21.3 | 1.3 | 28.7 | 1.3 |

Tabela A.15: Resultado do experimento entre as categorias Trajes sumários e Pornografia feminina usando *Difference of Gaussians* e SIFT

A.4 Experimento 4: Categorias Trajes sumários e Pornografia infantil feminina

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-----------------|---------------|
| | Pornografia infantil feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 40.2 | 3.2 | 9.0 | 3.1 |
| Trajes sumários | 9.8 | 3.2 | 41.0 | 3.1 |

Tabela A.16: Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando *Harris-Laplace* e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-----------------|---------------|
| | Pornografia infantil feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 40.2 | 2.4 | 12.3 | 2.6 |
| Trajes sumários | 9.8 | 2.4 | 37.7 | 2.6 |

Tabela A.17: Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando *Harris-Laplace* e WSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-----------------|---------------|
| | Pornografia infantil feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 42.1 | 2.5 | 14.3 | 3.7 |
| Trajes sumários | 7.9 | 2.5 | 35.7 | 3.7 |

Tabela A.18: Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando Amostragem Densa e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-----------------|---------------|
| | Pornografia infantil feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 42.5 | 3.3 | 11.3 | 4.2 |
| Trajes sumários | 7.5 | 3.3 | 38.7 | 4.2 |

Tabela A.19: Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando Amostragem Densa e WSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|-----------------|---------------|
| | Pornografia infantil feminina | | Trajes sumários | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 25.5 | 1.3 | 24.5 | 1.3 |
| Trajes sumários | 24.5 | 1.3 | 25.5 | 1.3 |

Tabela A.20: Resultado do experimento entre as categorias Trajes sumários e Pornografia infantil feminina usando *Difference of Gaussians* e SIFT

A.5 Experimento 5: Categorias Pornografia feminina e Pornografia infantil feminina

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|----------------------|---------------|
| | Pornografia infantil feminina | | Pornografia feminina | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 33.5 | 2.9 | 9.9 | 4.5 |
| Pornografia feminina | 16.5 | 2.9 | 40.1 | 4.5 |

Tabela A.21: Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando *Harris-Laplace* e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|----------------------|---------------|
| | Pornografia infantil feminina | | Pornografia feminina | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 30.0 | 5.1 | 10.6 | 3.8 |
| Pornografia feminina | 20.0 | 5.1 | 39.4 | 3.8 |

Tabela A.22: Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando *Harris-Laplace* e WSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|----------------------|---------------|
| | Pornografia infantil feminina | | Pornografia feminina | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 33.3 | 2.8 | 12.8 | 3.8 |
| Pornografia feminina | 16.7 | 2.8 | 37.2 | 3.8 |

Tabela A.23: Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando Amostragem Densa e OpponentSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|----------------------|---------------|
| | Pornografia infantil feminina | | Pornografia feminina | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 33.5 | 2.8 | 12.2 | 2.7 |
| Pornografia feminina | 16.5 | 2.8 | 37.8 | 2.7 |

Tabela A.24: Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando Amostragem Densa e WSIFT

| Categoria Identificada | Categoria Real | | | |
|-------------------------------|-------------------------------|---------------|----------------------|---------------|
| | Pornografia infantil feminina | | Pornografia feminina | |
| | Média | Desvio Padrão | Média | Desvio Padrão |
| Pornografia infantil feminina | 29.2 | 1.7 | 20.8 | 1.7 |
| Pornografia feminina | 20.8 | 1.7 | 29.2 | 1.7 |

Tabela A.25: Resultado do experimento entre as categorias Pornografia feminina e Pornografia infantil feminina usando *Difference of Gaussians* e SIFT

B Fluxograma do Código de Classificação de Fei-Fei et al.

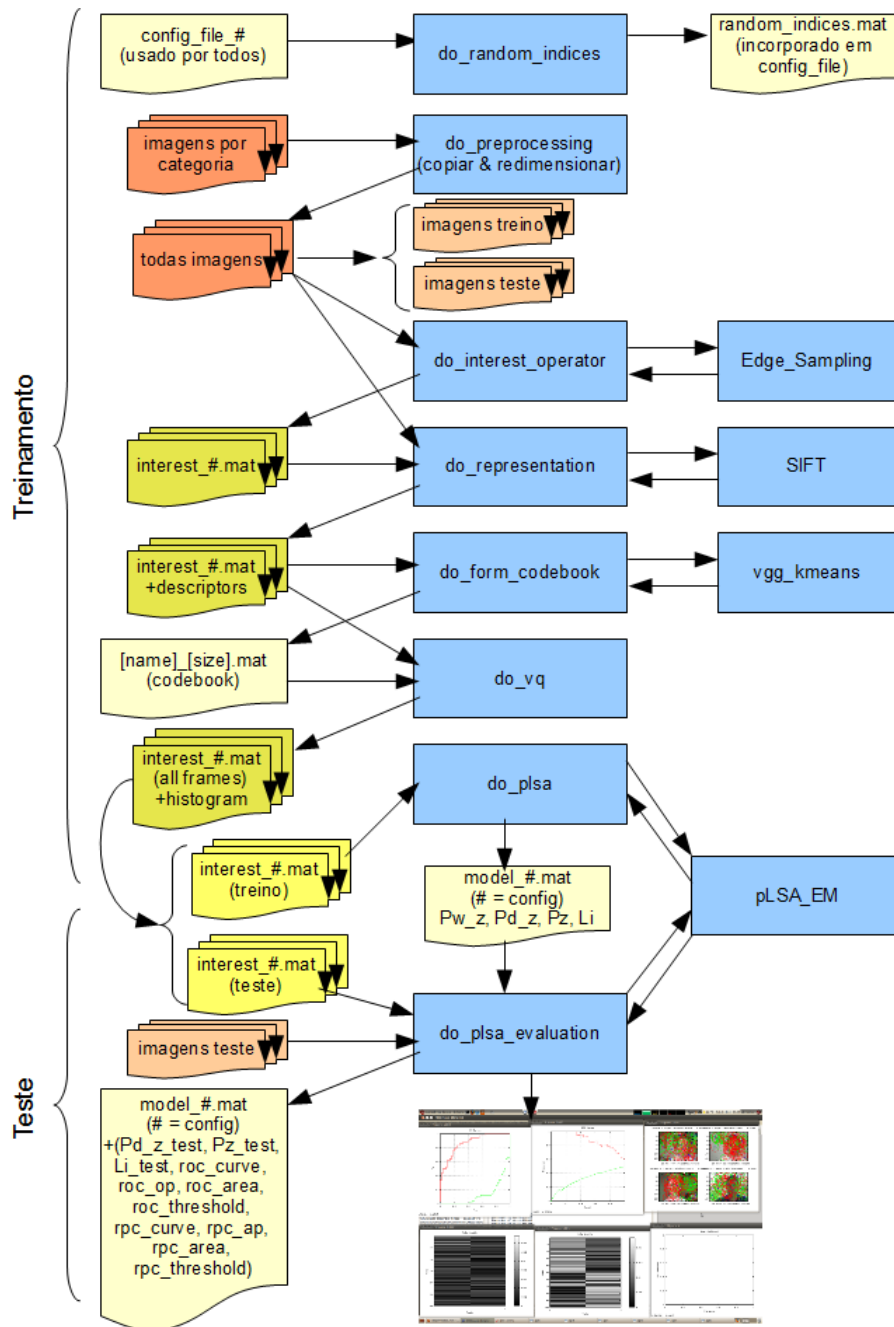


Figura B.1: Fluxograma do código criado por Fei-Fei, Fergus e Torralba (2005), com o descritor SIFT, incluindo a estrutura do código, as entradas e saídas para o caso específico do uso do classificador pLSA.

C Fluxograma do Código de Classificação Desenvolvido e suas Fases

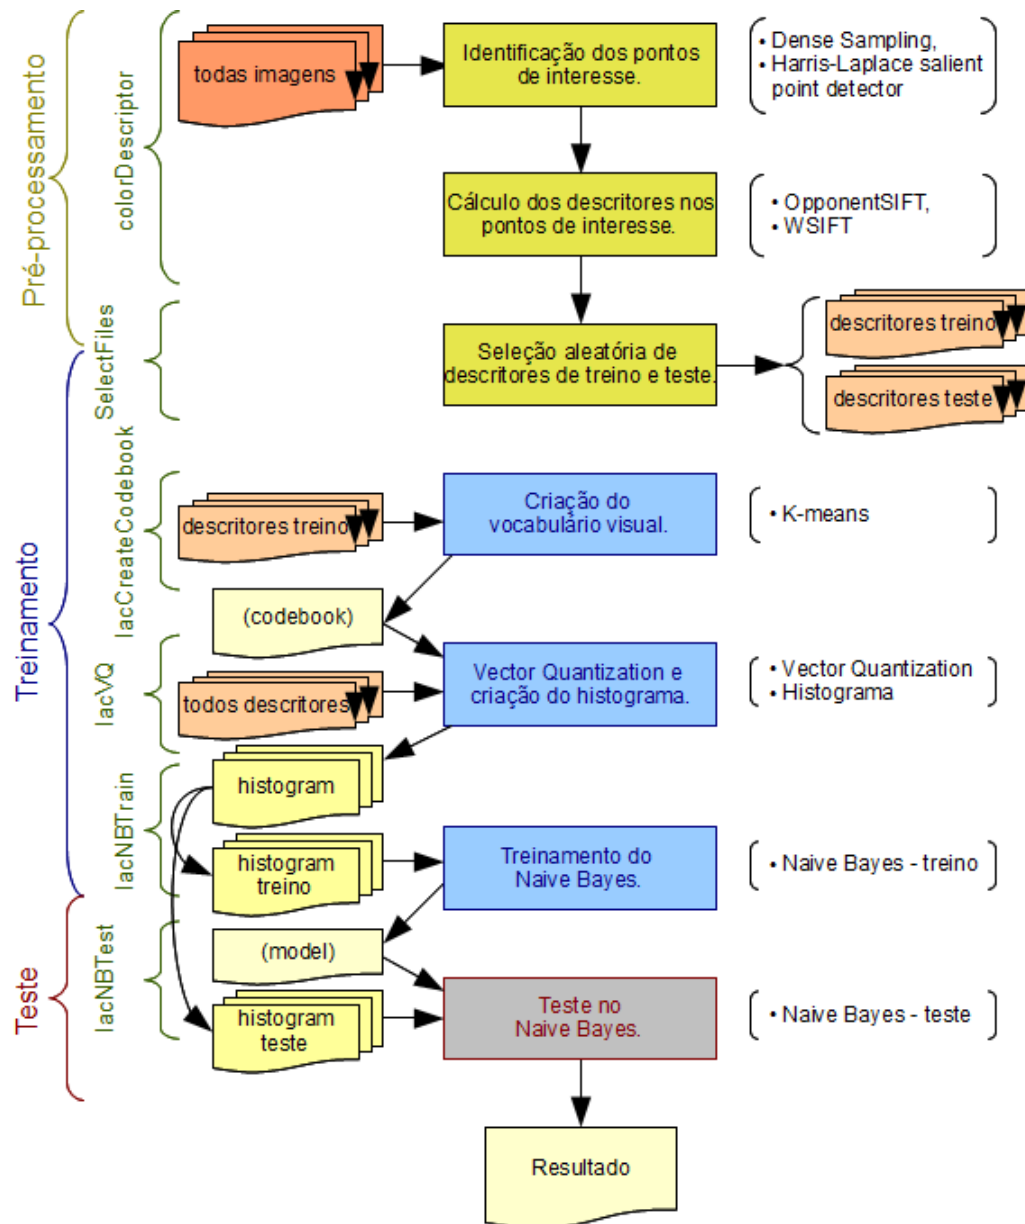


Figura C.1: Fluxograma com as fases, os nomes dos *scripts*, os algoritmos ou técnicas utilizadas em cada etapa, as entradas e saídas para o caso específico do uso de um classificador *Naive Bayes*, no código criado para este trabalho, com o uso de *Color Descriptors* implementados por van de Sande (SANDE; GEVERS; SNOEK, 2008, 2010).

D Fluxo das Imagens no Código de Classificação Desenvolvido

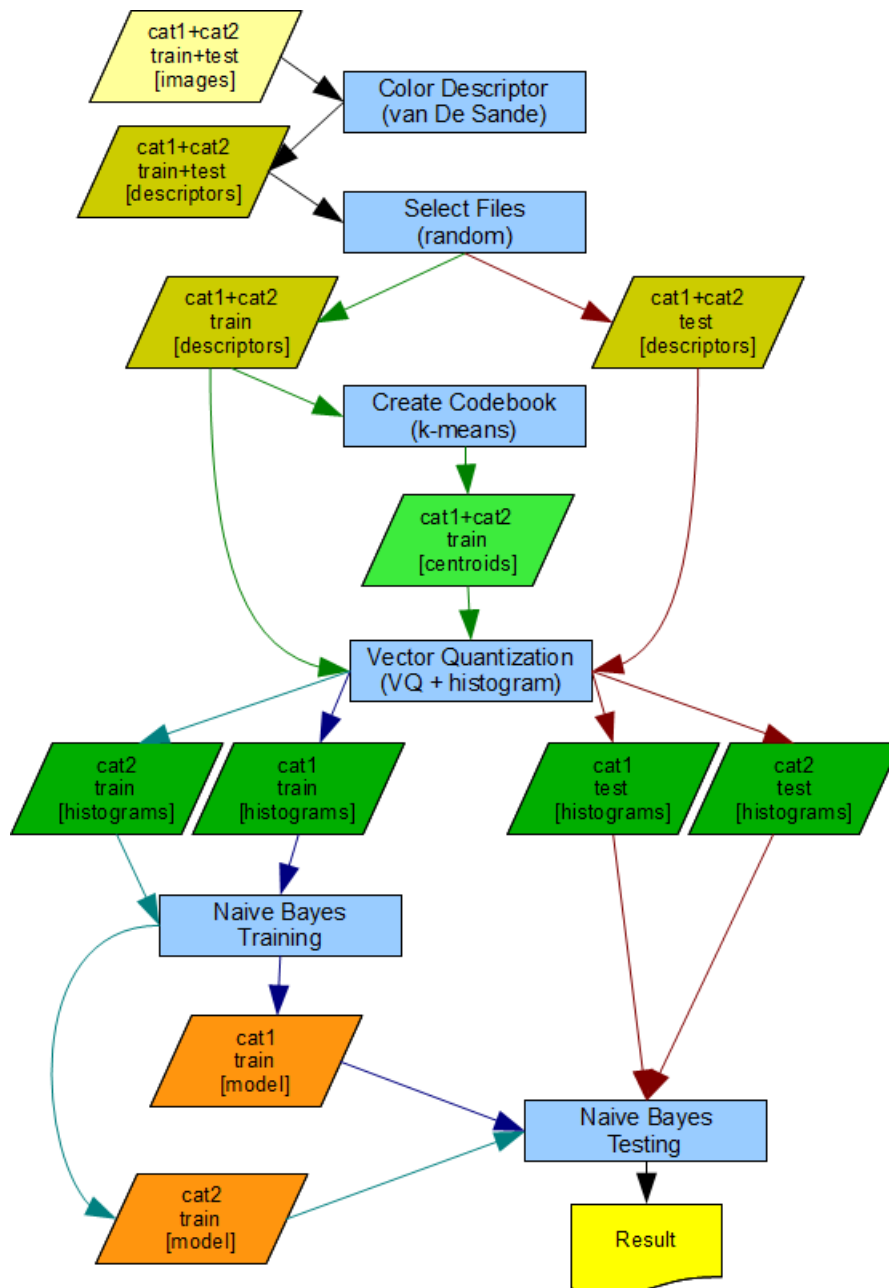


Figura D.1: Fluxo das imagens considerando suas categorias e se estas foram selecionadas para o grupo de treino ou de teste, com relação ao código criado para este trabalho, com o uso de *Color Descriptors* implementados por van de Sande (SANDE; GEVERS; SNOEK, 2008, 2010).