

**Testes de significância estatísticos e avaliação
de um modelo de recuperação de imagens por
conteúdo**

Daniel da Silva Andrade

Dissertação de Mestrado

Instituto de Computação
Universidade Estadual de Campinas

Testes de significância estatísticos e avaliação de um modelo de recuperação de imagens por conteúdo

Daniel da Silva Andrade¹

15 de Julho de 2004

Banca Examinadora:

- Prof. Dr. Neucimar Jerônimo Leite
Instituto de Computação IC–Unicamp (Orientador)
- Prof. Dr. Francisco Nivando Bezerra
Universidade de Fortaleza–UNIFOR
- Prof. Dr. Maria Beatriz Felgar de Toledo
Instituto de Computação IC–Unicamp
- Prof. Dr. Ariadne Maria Brito Rizzoni Carvalho
Instituto de Computação IC–Unicamp (Suplente)

¹Este trabalho foi financiado pelo CNPq e foi parcialmente financiado pelos projetos MCT-PRONEX SAI (Sistemas Avançados de Informação), CNPq-WebMaps e Agroflow

Testes de significância estatísticos e avaliação de um modelo de recuperação de imagens por conteúdo

Este exemplar corresponde à redação final da Dissertação devidamente corrigida e defendida por Daniel da Silva Andrade e aprovada pela Banca Examinadora.

Campinas, 26 de Fevereiro de 2004.

Prof. Dr. Neucimar Jerônimo Leite
Instituto de Computação IC–Unicamp
(Orientador)

Dissertação apresentada ao Instituto de Computação, UNICAMP, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação.

© Daniel da Silva Andrade, 2004.
Todos os direitos reservados.

“A resposta para o mistério de todas as coisas não está em uma terra distante, mas em nossos corações”. *Laozi*

Resumo

Nesta dissertação abordamos o problema de recuperação de imagens por conteúdo tendo como enfoque os modelos que utilizam a informação cromática da imagem. Consideraremos alguns modelos apresentados na literatura e propomos um descritor denominado coesão que leva em conta a informação global de regiões homogêneas das imagens.

Visando uma descrição mais criteriosa do seu desempenho, este descritor foi analisado a partir de testes de significância estatísticos, utilizados para melhor caracterizar os diferentes parâmetros empregados. Finalmente foi realizada uma comparação com alguns métodos básicos de representação de imagens que ilustra o bom desempenho do descritor proposto.

Agradecimentos

Agradeço a Deus, ao meu orientador Neucimar Jerônimo Leite, a minha família, a minha namorada, e a todos os meus amigos do Rio de Janeiro e de Campinas.

x

Conteúdo

1	Introdução	1
2	Sistemas de recuperação de imagens por conteúdo	7
2.1	Usos de sistemas de recuperação de imagens por conteúdo	7
2.2	Arquitetura de um sistema de recuperação de imagens por conteúdo	9
2.2.1	Interface	9
2.2.2	Extração de características	10
2.2.3	Indexação	13
2.2.4	Processamento de consultas	14
2.3	Exemplos	14
2.3.1	Qbic	14
2.3.2	Busca na web	15
3	Recuperação de informação por cor	21
3.1	A informação de cor	21
3.1.1	Espaços de cores	22
3.2	Modelos de recuperação por cor	25
3.2.1	Histograma	26
3.2.2	Histograma acumulado	28
3.2.3	Momentos	30
3.2.4	Vetor de coerência de cores	31
3.2.5	QuadTrees	31
3.2.6	Correlogramas	32
4	Modelo Coesão	33
4.1	Definição da classe de imagens considerada	33
4.2	O modelo coesão para recuperação de imagens por conteúdo	35
4.3	Etapas para criação do descriptor coesão	37
4.3.1	Escolha do espaço de cores	37

4.3.2	Quantização do espaço de cores	37
4.3.3	Segmentação	38
4.3.4	Agregação das regiões homogêneas	38
4.3.5	Escolha de propriedades das regiões a serem analisadas	38
4.3.6	Informação das regiões homogêneas e estatísticas	39
4.3.7	Algoritmo do cálculo da coesão por área média	39
4.3.8	Análise da complexidade do algoritmo proposto	39
5	Experimentos	43
5.1	Análise da efetividade	44
5.1.1	Definição da coleção de imagens	44
5.1.2	Definição do conjunto de imagens relevantes	45
5.1.3	Critérios de avaliação da efetividade	45
5.2	Testes de significância estatística	47
5.3	Descrição dos experimentos	49
5.4	Discussão dos resultados	49
5.4.1	Efeito da quantização do espaço de cores na efetividade do descritor coesão	51
5.4.2	Efeito da métrica utilizada na efetividade do descritor coesão	53
5.4.3	Efeito da conexidade na efetividade do descritor coesão	54
5.4.4	Comparação entre coesão, histograma e vetor de coerência de cores	55
5.4.5	Comparação entre coesão, histograma e vetor de coerência de cores utilizando o cubo RGB	55
5.4.6	Comparação entre a utilização das três componentes separadamente e do cubo RGB	58
6	Conclusões e Extensões	63
6.1	Extensões	64
A	Gráficos de precision-recall das consultas	65
A.1	Espaço de cores RGB com os componentes considerados separadamente	65
A.2	Considerando o cubo RGB	78
A.3	Comparação entre coesão com três componentes e coesão com o cubo RGB	82
B	Tabelas dos valores dos critérios de efetividade	87
B.1	Espaço de cores RGB com os componentes considerados separadamente	87
B.2	Considerando o cubo RGB	106
Bibliografia		116

Listas de Figuras

1.1	Exemplo de imagem a ser descrita usando técnica de recuperação de informação.	3
1.2	Exemplos de imagens de consulta para recuperação por conteúdo.	5
2.1	Exemplos de texturas.	11
2.2	Exemplos de formas.	12
2.3	Consulta no sistema Qbic.	15
2.4	Resposta do sistema Qbic a uma consulta por cor.	16
2.5	consulta ao Google por <i>Sunset e Rio de Janeiro</i> .	18
2.6	Novecento.	19
3.1	Uma imagem e seu histograma.	27
3.2	Exemplos de histogramas [SO95]	28
3.3	Uma imagem e seu histograma acumulado	29
3.4	Histogramas acumulados correspondentes aos histogramas da figura 3.2 [SO95]	30
4.1	Exemplos de rotação e translação.	34
4.2	Exemplos de imagens de consulta.	34
4.3	Imagens com histogramas idênticos.	35
4.4	Consulta utilizando histograma acumulado e coesão.	36
4.5	Ilustração das etapas envolvendo o descriptor coesão.	36
5.1	Resultado de uma consulta no Sistema Surf Image.	44
5.2	O conjunto das imagens de consulta.	50
5.3	Seleção de gráficos de precision-recall para a avaliação da métrica utilizada.	53
5.4	Seleção de alguns dos gráficos de precision-recall comparando os modelos coesão, histograma e vetor de coerência de cores.	57
5.5	Seleção de alguns dos gráficos de precision-recall comparando os modelos coesão, histograma e vetor de coerência de cores utilizando o cubo RGB.	59

5.6 Seleção de gráficos de precision-recall entre coesão utilizando três componentes e Coesão utilizando o cubo RGB.	60
A.1 Gráficos de precision e recall comparando os modelos coesão, histograma e vetor de coerência de cores(vcc).	66
A.2 Gráficos de precision e recall comparando os modelos coesão, histograma e vetor de coerência de cores(vcc).	67
A.3 Gráficos de precision e recall comparando os modelos coesão, histograma e vetor de coerência de cores(vcc).	68
A.4 Gráficos de precision e recall para teste de quantização.	69
A.5 Gráficos de precision e recall para teste de quantização.	70
A.6 Gráficos de precision e recall para teste de quantização.	71
A.7 Gráficos de precision e recall para a avaliação da métrica utilizada.	72
A.8 Gráficos de precision e recall para a avaliação da métrica utilizada.	73
A.9 Gráficos de precision e recall para a avaliação da métrica utilizada.	74
A.10 Gráficos de precision e recall da comparação entre o uso de conexidade 4 e 8. .	75
A.11 Gráficos de precision e recall da comparação entre o uso de conexidade 4 e 8. .	76
A.12 Gráficos de precision e recall da comparação entre o uso de conexidade 4 e 8. .	77
A.13 Gráficos de precision e recall comparando os modelos coesão e vetor de coerência de cores.	79
A.14 Gráficos de precision e recall comparando os modelos coesão e vetor de coerência de cores.	80
A.15 Gráficos de precision e recall comparando os modelos coesão e vetor de coerência de cores.	81
A.16 Gráficos de precision e recall entre coesão utilizando três componentes e coesão utilizando o cubo RGB com 64 cores.	83
A.17 Gráficos de precision e recall entre coesão utilizando três componentes e coesão utilizando o cubo RGB com 64 cores.	84
A.18 Gráficos de precision e recall entre coesão utilizando três componentes e coesão utilizando o cubo RGB com 64 cores.	85

Capítulo 1

Introdução

Diariamente, um grande volume de imagens é gerado continuamente por diversas fontes de dados: satélites de sensoriamento remoto, aparelhos de radiografia, tomografia, ultra-som e ressonância magnética, sistemas de vigilância, jornais e revistas. As imagens geradas por essas fontes estão sendo rapidamente disseminadas pela popularização da World Wide Web e pela redução de custo dos meios de armazenamento como cd-roms e dvds. Nesse contexto, surge a necessidade da criação de meios de indexação e recuperação dessas informações de modo eficiente, o que constitui um dos objetivos das pesquisas na área de recuperação de imagens por conteúdo.

De modo geral, existem três abordagens mais comuns para o problema de recuperação de imagens [GR95a] a saber:

Modelo de Bancos de Dados

Nessa abordagem, as imagens podem ser representadas através de dados relacionais, objeto-relacionais ou geográficos associados às imagens. Estes dados podem estar relacionados com o arquivo de imagem como por exemplo: (nome do arquivo, autor, data de criação, formato do arquivo, dimensões da imagem, tipo de representação das cores, número e tipo de bandas); ou dados associados conceitualmente com estas: (número de chassi relacionado com a foto de um veículo, nome identificado com a foto de um funcionário, nome de um paciente em uma radiografia, nome de um pintor e suas pinturas, latitude e longitude de uma cachoeira). Nesse modelo de representação, os dados que permitem a indexação são armazenados em um SGBD e podem ser recuperados, por exemplo a partir de uma consulta SQL. Neste caso, o resultado de uma consulta é um particionamento da informação em dois conjuntos disjuntos, sendo que todos os elementos do conjunto resposta têm a mesma relevância.

A principal vantagem deste modelo é a otimização das consultas e o poder da linguagem SQL na descrição destas consultas. O principal problema é representação é

a descrição insuficiente do conteúdo das imagens.

Ilustrativamente, este tipo de representação pode estar associado aos seguintes tipos de consultas:

- Recuperar imagens de satélite que representam regiões contidas dentro dos limites do município de Campinas, com data de aquisição igual a fevereiro de 2000.
- Recuperar radiografias de pacientes com idade acima de 70 anos e que residam na cidade de Paulínia.
- Recuperar pinturas coloridas feitas por “Juan Miró”.

Modelo de Recuperação por informação textual

Nessa abordagem, as imagens são representadas por uma descrição textual dos seus elementos relevantes, gerada preferencialmente por um especialista na área referente ao conteúdo da imagem. A definição desta descrição pode ser livre, isto é, o indivíduo que a está redigindo pode usar um vocabulário qualquer para descrever o conteúdo da imagem ou este vocabulário pode estar restrito a uma hierarquia de conceitos que definam nomes canônicos, com descrições detalhadas associadas para definir entidades presentes nas imagens.

Um exemplo de utilização de descrição livre é o dispositivo de busca Google em que a descrição é gerada a partir do texto presente na página, com ênfase no texto ao redor da imagem, nome do arquivo, título da página e texto descritivo da tag de html *alt*.

Um exemplo de sistema com vocabulário fixo é o ICONCLASS que é um sistema de classificação e descrição do conteúdo de imagens iconográficas utilizado em museus para indexar obras de arte. Este sistema utiliza uma hierarquia de conceitos divididos em dez áreas: arte abstrata e não representativa, religião e magia, natureza, ser humano e assuntos relacionados ao homem em geral, sociedade, civilização e cultura, idéias abstratas e conceitos, história, Bíblia, literatura, mitologia clássica e história antiga.

As vantagens desta abordagem são principalmente a rapidez na realização das consultas e uma descrição mais precisa da informação contida na imagem. Uma vantagem adicional de uma descrição gerada por um especialista é que este pode atribuir, à descrição da imagem, informações que não estão presentes na mesma mas que são relevantes para a sua compreensão. Numa imagem contendo aves cobertas de petróleo, por exemplo, a descrição poderia conter o nome do navio petroleiro responsável pelo derramamento.

Essa descrição textual das imagens é indexada através de técnicas de recuperação de informação baseadas no conceito de listas invertidas e as consultas são feitas utilizando palavras-chaves.

Algumas desvantagens deste tipo de sistema envolvem: a questão do vocabulário, isto é, o fato que o mesmo objeto pode ter diferentes nomes e diferentes níveis de abstração. A imagem da figura 1.1, por exemplo, pode ser descrita como contendo céu azul com nuvens, uma pedra e um cão ou uma cadela ou um cão da raça Collie ou a Lassie. Outro possível problema é a questão do idioma em que a descrição é feita e a linguagem de consulta que só pode conter uma combinação booleana de strings.

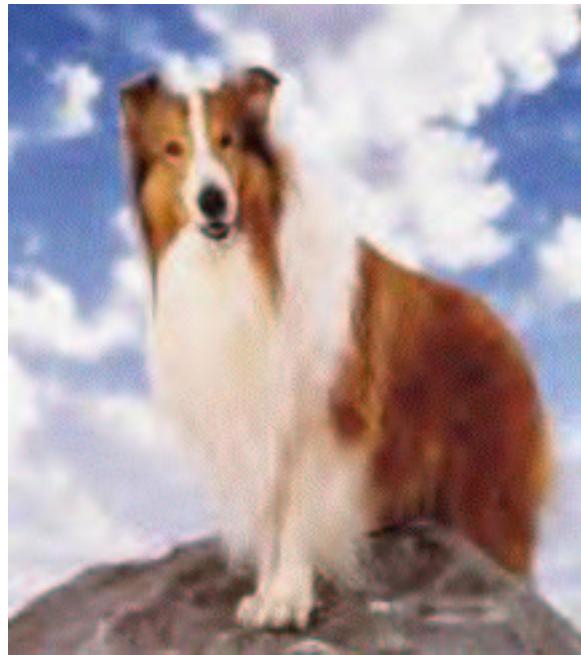


Figura 1.1: Exemplo de imagem a ser descrita usando técnica de recuperação de informação.

Nesse modelo, o resultado de uma consulta é um particionamento do espaço de busca, sendo que os elementos do conjunto de resposta não têm necessariamente a mesma relevância, precisando, portanto, de critérios adicionais para a ordenação destes.

Ilustrativamente algumas consultas associadas a um sistema baseado em técnicas de recuperação de informação textual são:

- Recuperar imagens do pôr-do-sol no Rio de Janeiro.

- Recuperar fotos do encontro de Roosevelt, Stalin e Churchill em 1943.

Modelo de recuperação por conteúdo

Nessa abordagem, as imagens são representadas por um vetor de características obtidas por técnicas de processamento de imagens e reconhecimento de padrões. Essas técnicas utilizam a informação cromática, textural, de forma e de distribuição espacial dos objetos presentes na imagem, para criar uma representação do conteúdo das imagens.

Normalmente os vetores de características são representados como pontos em um espaço multidimensional e uma função de similaridade é definida para permitir a comparação entre esses pontos.

A grande vantagem deste modelo é a capacidade de gerar uma representação da informação da imagem que não é subjetiva e que não está limitada ao uso de uma descrição textual, sendo capaz de representar informações que não podem ser facilmente descritas por palavras.

Alguns dos principais problemas desta abordagem são o custo computacional da criação da representação do conteúdo e da realização das consultas e que as consultas são essencialmente realizadas através de exemplos.

Nesse modelo, o resultado de uma consulta é uma ordenação da informação em relação à imagem de consulta, segundo o critério de similaridade utilizado.

Exemplos de consultas num sistema baseado em recuperação por conteúdo são:

- Recuperar imagens semelhantes as imagens da figura 1.2.
- Recuperar imagens com regiões vermelhas e regiões pretas.

Para que se possa responder consultas de um amplo espectro, um sistema a ser utilizado em uma gama variada de situações e contextos deve combinar as três abordagens acima. A área de recuperação utilizando o modelo de Banco de Dados já é muito bem explorada e tem técnicas bem consolidadas. A área de recuperação de informação textual também é razoavelmente antiga e dispõe de várias técnicas com resultados interessantes.

O problema de recuperação por conteúdo, no entanto, não está bem resolvido no que se refere à representação da informação ou a técnicas de recuperação. Este trabalho enfoca esta área de pesquisa. Nos demais capítulos discutimos o problema da recuperação de imagens por conteúdo e, mais especificamente, a recuperação pela informação cromática das imagens.

Os objetivos desta dissertação são:



Figura 1.2: Exemplos de imagens de consulta para recuperação por conteúdo.

- Propor um descriptor global para a informação cromática da imagem, em combinação com a informação espacial, que seja invariante à rotação e à translação de seus objetos através da sumarização estatística de atributos relativos às regiões homogêneas.
- Realizar de modo correto e adequado os teste de significância estatísticos para a comparação do modelo proposto com alguns dos modelos existentes através de critérios de efetividade existentes.

A estrutura do restante desta dissertação é a seguinte: o capítulo 2 aborda o conceito de recuperação por conteúdo de imagens, ilustrando as áreas de aplicações, as principais características de um sistema de recuperação por conteúdo e apresentando alguns sistemas existentes. O capítulo 3 trata do conceito de cor, de sua forma de representação e dos modelos de recuperação por conteúdo baseados na informação cromática das imagens. O capítulo 4 propõe o modelo de recuperação por conteúdo, utilizando informação das regiões homogêneas das imagens denominado coesão, destacando suas principais vantagens. O capítulo 5 compara o modelo proposto com alguns dos modelos estudados utilizando procedimentos corretos de análise estatística em função do tipo de dados gerados pela avaliação das consultas. Finalmente, o capítulo 6 apresenta as conclusões finais do trabalho e algumas extensões à pesquisa desenvolvida.

Capítulo 2

Sistemas de recuperação de imagens por conteúdo

Como visto anteriormente, a abordagem de recuperação de imagens por conteúdo utiliza técnicas das áreas de processamento de imagens e reconhecimento de padrões para a indexação da informação. Neste sentido, diferentes técnicas são utilizadas para a caracterização do conteúdo, em função do tipo de informação relevante e do domínio ao qual a imagem está relacionada. Este capítulo trata de diversas aplicações da recuperação de imagens por conteúdo, das técnicas utilizadas para representar suas propriedades e da integração destas na construção de sistemas de recuperação de imagens por conteúdo.

Na próxima seção, abordamos algumas das áreas em que esses sistemas podem ter maior utilidade. Na seção seguinte, ilustramos os componentes de um sistema de recuperação de imagens por conteúdo, discutindo as principais áreas de pesquisa no desenvolvimento desses sistemas. Finalmente, na última seção deste capítulo apresentamos um exemplo de sistema de recuperação de imagens por conteúdo, o sistema Qbic, e abordamos os problemas de recuperação de imagens na web que serviram como contraponto às idéias contidas no Qbic.

2.1 Usos de sistemas de recuperação de imagens por conteúdo

Em [EG99] e [GR95b] são apresentadas várias aplicações práticas dos Sistemas de Recuperação de Imagens por Conteúdo. Algumas destas aplicações são resumidas a seguir:

Prevenção ao crime

A área de prevenção ao crime tem muitas aplicações em sistemas de recuperação por conteúdo, sendo uma das principais aplicações a identificação de pessoas através de registros fotográficos, sejam eles feitos a partir de fotos obtidas em fichas criminais ou de dispositivos de segurança. As consultas, em geral, baseiam-se no registro fotográfico de um suspeito que é comparado com um banco de dados de imagens, gerando uma lista de indivíduos mais semelhantes. Outro uso bastante difundido de sistemas de recuperação por conteúdo é o de identificação de impressões digitais. Outros exemplos incluem o uso de sistemas para a identificação de marcas de pneus, marcas de sapatos, identificação de assinaturas e o uso de bancos de imagens de objetos roubados.

Medicina

O uso de sistemas de recuperação de imagens por conteúdo na área médica tem como objetivo principal servir de ferramenta de auxílio ao diagnóstico. Em [SBK⁺98] temos um exemplo de sistema para tratamento de imagens de tomografia de alta resolução do pulmão. Algumas das dificuldades inerentes à criação de sistemas de recuperação de imagens por conteúdo na área médica são: a dificuldade de uma identificação automática das regiões de interesse das imagens e a grande variedade de classes de imagens que podem representar uma mesma patologia ou estrutura.

Publicidade e propaganda

Existem várias aplicações das técnicas de recuperação de imagens por conteúdo nas áreas de publicidade e propaganda. Por exemplo, na pesquisa de logotipos e marcas registradas, principalmente para evitar os possíveis casos em que um logotipo possa ser muito similar a outro já existente. Outra aplicação consiste na busca de um conjunto de imagens adequado a uma determinada peça de propaganda, tais como paisagens ou pessoas.

Arquitetura e projetos de engenharia

As áreas de arquitetura e engenharia são caracterizadas por tipos específicos de imagens, em geral, imagens 2D ou 3D representando objetos ou estruturas vetoriais. Nestes casos, é interessante realizar consultas sobre projetos semelhantes, a um outro em desenvolvimento, para inferir sobre soluções e desenvolvimento de projetos implementados.

Sistemas de informação geográfica e sensoriamento remoto

Uma das principais oportunidades de utilização de recuperação de imagens por conteúdo refere-se à integração de imagens de satélite em sistemas de informação geográfica. Como

o volume de imagens geradas é muito grande, uma classificação das regiões de interesse das imagens, feita de modo automático, é de muita utilidade.

2.2 Arquitetura de um sistema de recuperação de imagens por conteúdo

Um sistema de recuperação de imagens por conteúdo pode ser subdividido alguns módulos básicos:

- A interface, que compreende a inserção das imagens, a formulação das consultas e a visualização dos resultados de uma consulta.
- O módulo de extração de características, responsável pelo processamento das imagens e geração das estruturas de representação que servirão para representá-las.
- O módulo de indexação, responsável pelo armazenamento das estruturas geradas no módulo anterior.
- O módulo de processamento de consultas, responsável pela realização da consultas, simples e complexas.
- O repositório físico das imagens é igualmente importante pois ele deve considerar tanto um número grande de imagens quanto imagens gigantescas, como por exemplo, o sistema Titan [CMA⁺97].

2.2.1 Interface

A interface de um sistema de recuperação de imagens por conteúdo tem como objetivo facilitar a inserção de imagens no banco de imagens, a formulação das consultas e a visualização dos resultados apresentados pelo sistema.

A etapa de inserção de imagens pode ser composta por muitas ações que têm que ser suportadas pela interface como, por exemplo, a segmentação de regiões de interesse (objetos) da imagem sendo inserida, sendo que a interface deve prover meios pelos quais essa identificação possa ser feita automaticamente ou de modo semi-automático como, por exemplo, a identificação de regiões com tumores em imagens médicas.

Na especificação de consultas a serem feitas ao banco de dados, é necessário que a interface permita a especificação fácil de cores desejadas, que forneça meios para a geração de esboços que representem a distribuição espacial de cores e texturas nas imagens e a especificação de contornos de objetos desejados.

Na apresentação das respostas do sistema, uma boa interface deve permitir a fácil percepção da ordenação dos resultados apresentados e a validade destes resultados. Como um exemplo inadequado de interface, podemos citar o sistema ImageFinder, comentado em [VC00], que tem como saída uma lista de nomes de arquivos de imagens, não as imagens em si, e esta lista não é nem mesmo ordenada em função da similaridade em relação à imagem de consulta. A interface também é importante, na etapa de apresentação dos resultados para identificar o comportamento do usuário e auxiliar na identificação de fatores para a realização de “relevance feedback”, com o objetivo de melhorar os resultados das consultas.

Outro aspecto importante da interface, como discutido em [Rub99], é a possibilidade de se fazer uma navegação pelo banco de imagens, permitindo uma interação mais livre com o usuário.

2.2.2 Extração de características

O módulo de extração de características é responsável pela obtenção dos descritores que servem para caracterizar o conteúdo da imagem. Estes descritores podem ser classificados em quatro grupos básicos: os que representam a informação cromática da imagem, a informação textural, as formas dos objetos nas imagens e, por último, os que representam as relações espaciais entre os objetos das imagens. Em geral, sistemas mais flexíveis possuem vários tipos de descritores, tanto para os quatro grupos quanto, possivelmente, para diferentes abordagens dentro destes grupos. A seguir, apresentamos alguns aspectos específicos destes descritores.

Cor

A representação da informação de cor da imagem será tratada com mais detalhes no capítulo 3, mas podemos adiantar que a representação da informação cromática da imagem é uma das representações mais utilizadas para o tratamento de imagens genéricas, isto é, imagens que não são restritas a um domínio específico. Métodos baseados nestes descritores trabalham tanto com a informação cromática simples quanto com a associação desta com a informação da distribuição espacial das cores na imagem. No primeiro caso, podemos citar o uso de histogramas [SB91] e, no segundo caso, o uso de correlogramas [HKM⁺97].

Textura

Outro descritor de imagens muito utilizado refere-se à informação textural. Texturas são propriedades presentes nas imagens caracterizadas pela relação entre os seus pixels, ao

contrário da cor que é uma propriedade individual de cada pixel. Na figura 2.1 podemos ver diversos exemplos de texturas.



Figura 2.1: Exemplos de texturas.

Em [RHC97] e [Bim99] temos bons estudos das principais técnicas para a representação e a comparação de texturas. Alguns exemplos destas técnicas são:

- A abordagem utilizando uma matriz de coocorrência proposta por Haralick [HSD73] a partir da qual se extrai indicadores, tais como contraste, entropia etc.
- A abordagem baseada em modelos psicológicos que propõe a utilização de seis propriedades visuais de textura consideradas mais relevantes pelos psicólogos: granularidade, contraste, direcionalidade, alinhamento, regularidade e rugosidade.
- A abordagem que utiliza decomposição por wavelets para representar a informação textural.

Forma

Em [Bim99] e [Lon98] é considerada a utilização das formas dos objetos presentes nas imagens para recuperação. A figura 2.2 apresenta três exemplos de formas de objetos.

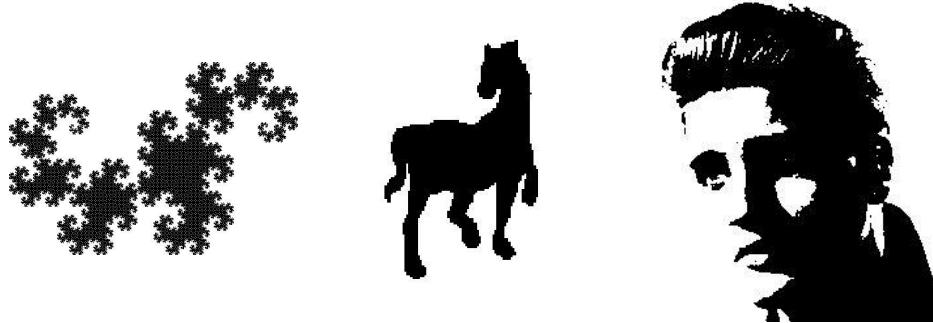


Figura 2.2: Exemplos de formas.

Neste caso podemos destacar três tipos de abordagens:

- Vetor de características: um vetor de características numérico é usado para representar as principais características de modelagem da forma e uma função de distância é utilizada na comparação dos vetores.
- Relacional: nessa abordagem a representação da forma dos objetos é feita através de um conjunto de componentes salientes descritos por características individuais e pela descrição do relacionamento entre esses componentes.
- Casamento de formas: objetos são representados por templates e são diferenciados pelo mapeamento do template do objeto no template da imagem alvo, calculado em tempo de execução.

Relações espaciais

Em muitos casos, a informação da relação espacial entre objetos é relevante no reconhecimento de imagens como, por exemplo, uma fotografia de uma praia em que uma região azul, o mar e o céu, está sobre uma região branca, a areia.

Existem várias formas de representar as relações espaciais entre objetos previamente segmentados de uma imagem. Esses modelos podem ser classificados, em geral, em duas categorias [Bim99]:

- Baseado em objetos: coordenadas dos objetos, como centro de massa, retângulo envolvente mínimo e contorno, são armazenadas sem uma representação explícita das relações espaciais entre os objetos da imagem e cálculos são feitos sob demanda, durante uma consulta, para verificar as relações entre os objetos desta consulta. Geralmente, são utilizadas técnicas de particionamento do espaço baseadas em árvores-R como forma de representação.

- Baseado em relações: os objetos são representados simbolicamente e apenas as relações de interesse são representadas, sendo essa representação explícita. O principal exemplo dessa abordagem são as 2D Strings.

2.2.3 Indexação

A indexação eficiente é fundamental para o uso prático dos sistemas de recuperação de imagens por conteúdo. Só em casos muito específicos em que o conjunto de imagens é pequeno ou em que a forma de representação da informação relevante das imagens é muito especial é que podemos não usar uma estrutura de índice e recorrer a uma busca sequencial. Existe uma variedade de estruturas para a indexação de pontos em espaços multidimensionais [GG98], cada uma criada visando resolver determinado tipo de problema. As estruturas podem ser estáticas ou dinâmicas, isto é, podem ser imutáveis ou tratar de inclusões e remoções de elementos, em qualquer ordem em que as operações se apresentem, e tem de garantir a eficiência da estrutura resultante. As estruturas estáticas são muito úteis quando se dispõe inicialmente de todos os dados a serem considerados e armazenados de forma permanente. Limitamos nossos comentários a estruturas que armazenam pontos multidimensionais e que são de natureza dinâmica. Alguns exemplos dessas estruturas são:

- A K-D-B-tree é uma árvore que organiza os pontos a serem indexados por meio de regiões *disjuntas* criadas com o uso de hiperplanos que dividem estes pontos. Como não existem interseções, as buscas para verificar a existência de algum elemento seguem um caminho único até a folha que contém os pontos indexados, num processo monodimensional.
- A R-tree é uma estrutura hierárquica que divide o espaço em hiper-retângulos não necessariamente disjuntos. Se a sobreposição entre os retângulos for muito grande, uma busca pode ter de percorrer todos os caminhos que saem do nó raiz até um nó desejado. Existem alguma variantes, a R^* -tree e a R^+ -tree que tentam otimizar a R-tree modificando o processo de inserção de elementos na árvore ou proibindo a superposição dos hiper-retângulos.
- A SS-Tree também é estrutura hierárquica com sobreposição, só que representa as regiões a serem separadas através de hiper-esferas, o que gera uma economia de espaço nos nós intermediários permitindo, assim, uma redução da altura das árvores. Para ser capaz de representar diferenças de relevância entre as dimensões a serem indexadas, a SS-tree utiliza uma função euclidiana ponderada de distância. O centro de massa dos pontos contidos em uma região determinam o ponto a ser utilizado como origem da hiper-esfera que circunscreve estes pontos.

- A M-tree é uma estrutura hierárquica, semelhante às anteriores, mas com a diferença que esta possibilita a utilização de espaços com qualquer métrica, não apenas as métricas da forma L_p .

2.2.4 Processamento de consultas

Diferente de um banco de dados tradicional em que o conceito fundamental da busca é o casamento (matching) dos dados descritos na consulta com os dados do banco, em um sistema de recuperação de imagens por conteúdo, o conceito fundamental é o da similaridade entre a imagem de consulta e as imagens presentes na base de dados. Esta similaridade pode ser definida, por exemplo, em termos de métricas do tipo L_p ou através do contraste de características [SJ96]. A combinação de diversos modelos de representação em uma mesma consulta para responder uma consulta complexa é uma área de pesquisa importante e é estudada em vários trabalhos [dVC02], [FW00] e [ORC⁺98].

2.3 Exemplos

Nesta seção ilustramos duas abordagem ao problema de recuperação de imagens por conteúdo. A primeira, a partir do sistema Qbic, que representa a recuperação por conteúdo através de técnicas de processamento de imagens. O segundo exemplo é dado pelos dispositivos de busca na Web, em especial o Google, que representa a combinação do uso de meta-information com conteúdo anotado, que vamos considerar neste capítulo como um instrumento de comparação das possibilidades de cada abordagem.

2.3.1 Qbic

O sistema Qbic (Query by Image Content) [FSN⁺95] foi desenvolvido no Centro de Pesquisas Almaden da IBM. Ele foi o primeiro sistema comercial lançado, e devido à sua versatilidade, isto é, a capacidade de realizar consultas combinando vários descritores e a integração com vários SGBDs, tornou-se uma referência básica na área.

O sistema utiliza vários descritores para representar o conteúdo das imagens como, por exemplo:

- pontos no espaço de cores de Munsell para representar a cor média de uma imagem.
- histogramas para representar a distribuição global das cores na imagem.
- um conjunto de descritores para representar a granularidade, direcionalidade e contraste das texturas.

- um conjunto de descritores de forma para representar objetos das imagens.

Para a realização das consultas utilizando os descritores citados e inserção das imagens no banco de dados, existem ferramentas que permitem:

- a segmentação semi-automática dos objetos das imagens.
- a construção de um esboço representando o layout espacial da imagem procurada.
- a representação da distribuição de cores e padrões de textura da imagem alvo.

Um exemplo de consulta no Qbic, utilizando a ferramenta de representação da distribuição de cores da imagem alvo, pode ser visto nas figuras 2.3 e 2.4. Essa consulta foi feita utilizando a coleção de obras do State Hermitage Museum da Rússia.

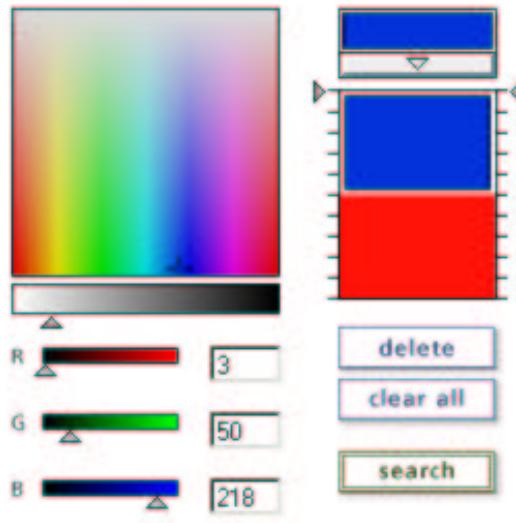


Figura 2.3: Consulta no sistema Qbic.

2.3.2 Busca na web

Idealmente, a busca de imagens na web constitui uma aplicação interessante de recuperação de imagens por conteúdo, e uma série de questões surgem quanto ao seu emprego em situações de uso real em larga escala.

Existem muitas tentativas de se criar dispositivos de busca de imagens para a Web, mas todos os sistemas que consideram recuperação de imagens por conteúdo, como o



Figura 2.4: Resposta do sistema Qbic a uma consulta por cor.

Altavista, que utilizava o sistema Virage [EG99], e o Radix, que empregava um sistema próprio baseado em descrições por forma, abandonaram suas iniciativas e adotaram busca de imagens apenas por palavras-chaves. Sendo assim, abordamos apenas as vantagens e desvantagens dos sistemas existentes que empregam palavras-chaves como base da consulta, tais como o Google e o Altavista.

Estes sites permitem a realização de uma consulta em função de uma lista de palavras-chaves. Estas palavras-chave são obtidas através de informações tais como: URL completa da image, nome do arquivo html onde ela se encontra, texto presente no arquivo html ao redor da imagem e links que referenciam a imagem.

Enfatizamos aqui que este é um exemplo de utilização de imagens por conteúdo segundo o modelo de recuperação por atributos e por conteúdo anotado. Na figura 2.5 temos um exemplo de consulta no Google utilizando as palavras-chaves *Sunset* e *Rio de Janeiro*. Na consulta, podemos perceber que os sistemas têm a capacidade de retornar bons resultados logo nas primeiras posições do ranking das respostas. O problema que encontramos é que o método de extração de palavras-chaves identifica palavras que podem não corresponder ao conteúdo real da imagem, tendo em vista o fato de que essas informações não foram definidas pelos criadores da página onde a imagem se encontra, com a intenção de permitir a recuperação das mesmas. Outro problema é o vocabulário utilizado para identificar as imagens e um problema mais grave ainda é a questão do idioma em que as palavras-chaves são definidos, além, é claro, de consultas que obviamente o sistema não pode responder. Um exemplo disto é obter uma pintura em que não se sabe o nome do autor ou o título da obra, isto é, consultas em que não se pode identificar palavras-chaves para a sua realização.

Para exemplificar a dificuldade de realização de determinadas consultas, usando a abordagem de recuperação de informação textual, vamos supor que gostaríamos de identificar a imagem da figura 2.6. Quais seriam as palavras-chaves que permitiriam a sua recuperação? Elas poderiam ser: *trabalhadores saindo da fábrica, pessoas* mas esses termos não retornam a imagem em questão. Na realidade, as consultas que conseguiram recuperar a imagem em questão foram as que utilizaram as palavras-chave *Novecento* ou *Novecent* que é o nome de um filme de Bernardo Bertolucci ao qual esta imagem está associada.

Neste capítulo apresentamos os sistemas de recuperação por conteúdo, seus componentes, um exemplo de sistema, o Qbic e o caso de recuperação de imagens na web. No próximo capítulo tratamos da informação cromática e das técnicas utilizadas para a sua representação e recuperação

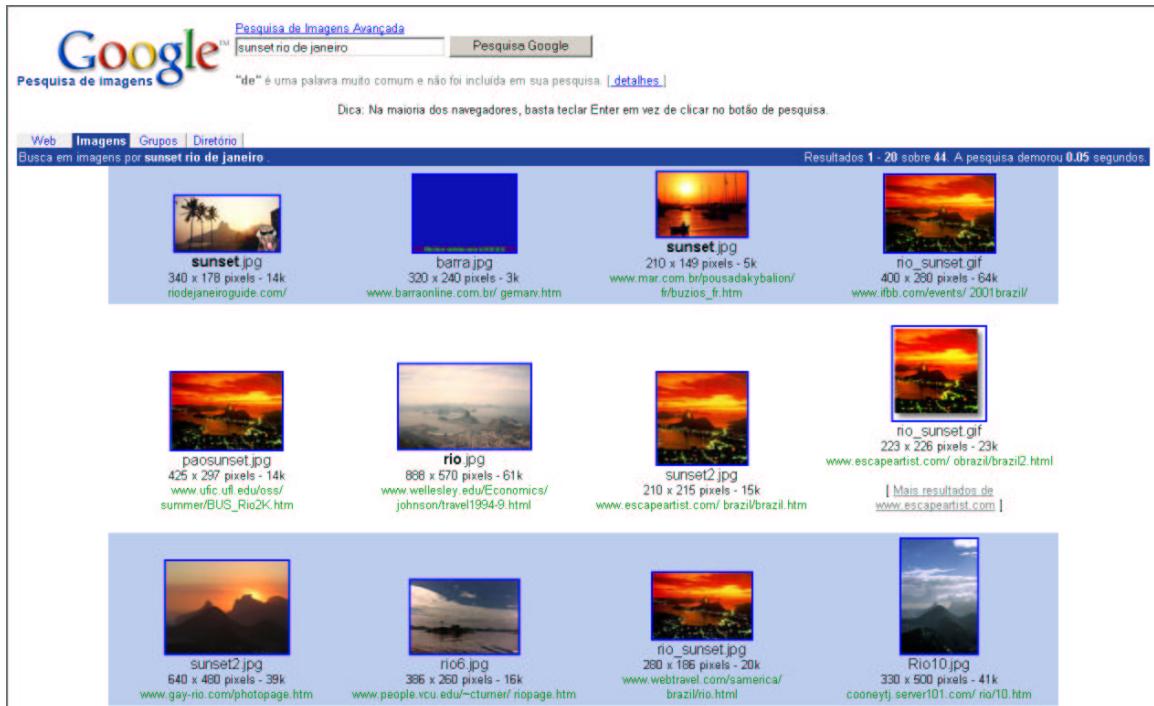


Figura 2.5: consulta ao Google por *Sunset e Rio de Janeiro*.



Figura 2.6: Novecento.

Capítulo 3

Recuperação de informação por cor

Neste capítulo abordamos a informação de cor e a sua utilização em recuperação de imagens por conteúdo. Na primeira parte deste capítulo, caracterizamos esta informação e os seus diferentes modos de representação. Na segunda parte do capítulo, analisamos alguns modelos de recuperação por conteúdo com base na informação cromática. Mais especificamente, abordamos histograma, histograma acumulado e momentos, para o caso de recuperação sem informação espacial da distribuição das cores nas imagens. Quadtrees, vetores de coerência de cores e correlogramas são mencionados nos casos de modelos que consideram a informação espacial.

Em geral, os objetos de uma imagem podem ser identificados por sua informação cromática, e um dos principais motivos para o uso da cor na sua recuperação é que a mesma é um atributo individual dos pixels das imagens que pode ser utilizado diretamente, sem a necessidade da realização de processamento adicional no emprego e caracterização.

3.1 A informação de cor

A cor é a interpretação do cérebro humano para os impulsos elétricos emitidos por células da retina que reagem à radiação eletromagnética com comprimento de onda entre 380 nm e 750nm, a chamada luz visível. Esta luz é gerada por diversas fontes luminosas como o sol, lâmpadas incandescentes e outros dispositivos. Como cada uma dessas fontes gera a luz por processos físicos diferentes, a distribuição de energia em função da freqüência (o espectro) da luz gerada é diferente para cada uma delas, ou seja, a definição do que é uma luz “branca” ou “pura” depende da fonte luminosa.

Os raios luminosos interagem com os objetos e, em função das propriedades físicas dos mesmos, (material constituinte, etc), parte do espectro da onda luminosa é absorvida e parte é refletida. A parte refletida é o que chamamos de cor do objeto.

O sistema ocular capta a luz refletida pelos objetos utilizando um sistema composto

pela córnea, íris e cristalino, convergindo os raios e os focando na retina, principalmente na região da fóvea.

A captação dos sinais luminosos é realizada por células especializadas presentes na retina que são de dois tipos: os bastonetes e os cones. Os bastonetes são responsáveis pela visão em condições de baixa luminosidade (visão noturna) e não possuem informações relativas às informações cromáticas do ambiente. Eles se encontram espalhados por toda a retina mas em maior concentração fora da área focal denominada fóvea. Os cones são os responsáveis pela percepção de informação cromática, e concentram-se na fóvea, que corresponde a uma abertura da retina da ordem de 5 graus. Eles são de três tipos S, M e L que se diferenciam pelos intervalos de comprimentos de onda aos quais são sensíveis. O identificado como S é mais sensível num intervalo que tem um pico de intensidade em aproximadamente 430 nm; o identificado como M, num intervalo com pico de intensidade por volta de 530 nm e, por último, o L cujo intervalo tem um pico de intensidade em 560 nm.

Posteriormente os sinal emitidos pelos cones na retina são convertidos em pares de impulsos antagônicos: os eixos vermelho-verde, amarelo-azul e preto-branco que são os sinais que chegam ao cérebro. Esse modelo de cores oponentes acrescido da característica de saturação de estímulo dos cones é capaz de explicar muito das chamadas ilusões cromáticas.

3.1.1 Espaços de cores

Como base em uma série de experimentos de casamentos de cores realizados pelo CIE (Commission Internationale de L'Éclairage) e nas informações anatômicas citadas acima, foi proposto um modelo de representação de cores chamado de tri-stimuli, em que todos as cores são representadas pela combinação linear de três elementos primários, linearmente independentes.

Neste ponto, o problema é a identificação desses elementos primários e da natureza do espaço de representação que eles compõem. Existe uma grande variedade de soluções para esse problema, em geral propostas em função de alguma limitação ou característica das aplicações.

A cada combinação de três componentes primárias, com a definição do respectivo espaço gerado, damos o nome de espaço de cores. Alguns espaços de cores são criados em função dos dispositivos usados na geração das cores, alguns visam permitir uma fácil especificação de cores por um operador, outros, ainda, têm como objetivo garantir alguma propriedade específica do espaço de cores.

Como todos os espaços de cores são formados pela combinação de cores primárias, espaços que têm como cores primárias cores *reais* não podem representar todas as cores visíveis ao olho humano.

Há vários aspectos através dos quais podemos classificar os espaços de cor [Poy98]. Por exemplo, se ele é dependente de algum dispositivo, perceptualmente uniforme ou intuitivo. Um espaço de cor *dependente de dispositivo* é um espaço de cor em que a informação cromática codificada pode gerar sensações visuais diferentes dependendo do dispositivo empregado na visualização da informação, (por exemplo, um televisor, um monitor de video ou uma impressora), pois a codificação representa porcentagens da intensidade das cores primárias do dispositivo de saída utilizado.

Um espaço de cor *independente de dispositivo* é um espaço que permite que a informação cromática codificada seja reproduzida de maneira fidedigna em qualquer dispositivo de visualização, isto é, a codificação é relativa a um conjunto de cores primárias pré-definidas.

Um espaço de cor é *perceptualmente uniforme* se uma pequena perturbação no valor de uma das componentes que compõe a cor é perceptível de forma aproximadamente uniforme em todo o espaço de cores.

Outra abordagem para a representação de cores é o uso de “catálogos”, isto é, uma extensa lista com amostras das cores que podem ser geradas pelos meios disponíveis, em geral pela combinação de tintas, como o sistema pantone¹. Como esses modelos não permitem a realização de uma série de operações como, por exemplo, o cálculo da distância entre duas cores, eles não são abordados neste trabalho.

A seguir, apresentamos quatro espaços de cor comunmente utilizados na área de processamento de imagens, sendo que maiores detalhes podem ser encontrados em [GW93, FR98, Poy98]. Os sistemas RGB e HSV são apresentados pois são utilizados em boa parte dos experimentos na área de recuperação de imagens por conteúdo, já o sistema XYZ foi escolhido por ser a primeira tentativa de se criar um sistema capaz de representar *todas* as cores visíveis ao olho humano e o sistema CIE $L^*a^*b^*$ é apresentado como um representante dos sistemas que são praticamente perceptualmente uniformes.

Sistema RGB

É um dos espaços de cor mais utilizados na área de computação. Foi criado para representar a composição de cores em televisores e monitores de fósforo. Esse espaço possui três componentes: vermelho, azul, e verde, variando, em geral, entre 0 e 255. A composição desses valores é realizada de maneira aditiva. Como os vetores das cores primárias são ortogonais entre si, temos um espaço representado com a forma de um cubo. Este espaço é chamado de dependente de equipamento, pois a cor gerada depende diretamente das características do fósforo utilizado. Neste caso uma mesma codificação pode gerar cores distintas em monitores e aparelhos de televisão diferentes. Esse aspecto é muito impor-

¹<http://www.pantone.com>

tante quando desejamos realizar a transformação de uma cor em RGB para um outro espaço de cor que não seja dependente do equipamento. Só podemos fazer uma transformação fiel se tivermos as informações sobre as cores primárias do dispositivo onde a imagem é gerada.

Sistema HSV

HSL, HSV, HSI, HCI constituem uma série de espaços semelhantes criados com a intenção de permitir a um usuário humano definir facilmente uma cor de forma mais intuitiva. Esses modelos têm como idéia básica separar a informação cromática da imagem das informações de luminosidade. Como esses espaços são transformações do RGB, eles possuem os mesmos problemas deste espaço, ou seja, eles são dependentes do dispositivo e, consequentemente, o mesmo conjunto de valores pode gerar visualizações diferentes. A consideração de que esses espaços são independentes do dispositivo é uma confusão muito comum em vários trabalhos da área, assim como a crença de que eles são perceptualmente uniformes.

A conversão de modelo RGB para HSV(Hue, Saturation, Value) dá-se através das seguintes equações [GW93]:

$$\begin{aligned}
 v &= \max(r, g, b) \\
 s &= (\max(r, g, b) - \min(r, g, b)) / \max(r, g, b) \\
 h &= \text{não definido} && \text{se } s = 0 \\
 h &= (g - b) / \max(r, g, b) - \min(r, g, b) && \text{se } r = \max(r, g, b) \\
 h &= 2 + (b - r) / \max(r, g, b) - \min(r, g, b) && \text{se } g = \max(r, g, b) \\
 h &= 4 + (r - g) / \max(r, g, b) - \min(r, g, b) && \text{se } b = \max(r, g, b)
 \end{aligned} \tag{3.1}$$

Sistema XYZ

Em 1931 a CIE (Commission Internationale de L'Éclairage) realizou um estudo em que foi considerado um observador padrão com um campo de visão de 4 graus. Com base neste observador padrão foram definidas três cores primárias capazes de representar todas as cores visíveis ao olho humano. Para se conseguir essa propriedade, estas cores escolhidas são imaginárias e definidas de maneira precisa, o que resulta no sistema XYZ independente de dispositivo.

Transformação de RGB Rec.709(cores primárias de TV e HDTV) com iluminante D_{65} (luz solar) para XYZ

$$\begin{aligned}
 X &= 0.412453R_{709} + 0.357580G_{709} + 0.180423B_{709} \\
 Y &= 0.212671R_{709} + 0.715160G_{709} + 0.180423B_{709} \\
 Z &= 0.019334R_{709} + 0.119193G_{709} + 0.950227B_{709}
 \end{aligned} \tag{3.2}$$

Transformação de XYZ para RGB Rec.709 com iluminante D_{65}

$$\begin{aligned} R_{709} &= 3.240479X - 1.537150Y - 0.498535Z \\ G_{709} &= -0.969256X + 1.875992Y + 0.041556Z \\ B_{709} &= 0.055648X - 0.204043Y + 1.057311Z \end{aligned} \quad (3.3)$$

Sistema CIE $L^*a^*b^*$

Esse sistema foi proposto pelo CIE em 1976 para suprir a deficiência do sistema XYZ que não é perceptualmente uniforme. No sistema CIELab, perceptualmente uniforme, o L^* está relacionado com a Luminância, a^* com o eixo vermelho-verde e o b^* , com o eixo amarelo-azul.

Transformação do sistema XYZ para o sistema CIELab da-se da seguinte forma:

$$L^* = \begin{cases} 116 \left(\frac{Y}{Y_0} \right)^{\frac{1}{3}} - 16 & \text{se } \left(\frac{Y}{Y_0} \right) > 0.008856 \\ 903.3 \left(\frac{Y}{Y_0} \right) - 16 & \text{se } \left(\frac{Y}{Y_0} \right) \leq 0.008856 \end{cases} \quad (3.4)$$

$$a^* = 500 \left[f \left(\frac{X}{X_0} \right) - f \left(\frac{Y}{Y_0} \right) \right] \quad (3.5)$$

$$b^* = 200 \left[f \left(\frac{Y}{Y_0} \right) - f \left(\frac{Z}{Z_0} \right) \right] \quad (3.6)$$

$$\text{onde } f(t) = \begin{cases} t^{\frac{1}{3}} & \text{se } t > 0.008856 \\ 7.787t + 16/116 & \text{se } t \leq 0.008856 \end{cases} \quad (3.7)$$

e $[X_0, Y_0, Z_0]$ são as coordenadas da cor branca de referência da cena presentes na tabela 3.1.

3.2 Modelos de recuperação por cor

Nesta seção ilustramos algumas abordagens para a recuperação de imagens que utilizam a informação cromática. Os modelos de recuperação por cor podem ser classificados em dois grupos básico quanto a utilização ou não de informação espacial associada a informação cromática. No caso apenas da informação cromática, temos, como exemplo, os modelos de histograma [SB91], histograma acumulado [SO95] e momentos [SO95]. No caso de uma associação da informação espacial da distribuição das cores na imagem, podemos ter uma subdivisão em duas abordagens: aquelas que fixam as coordenadas das cores em pontos específicos da imagem, tais como as Quadtrees [LOT94] e as abordagens que não fixam as

iluminante	X_0	Y_0	Z_0
A(lâmpada incandescente)	109.850	100	35.585
C	98.074	100	118.232
D50	96.422	100	82.521
D55	95.682	100	92.149
D65(luz do dia)	95.047	100	108.883
D75	94.972	100	122.638
F2(lâmpada fluorescente)	99.044	100	108.755
F7	95.044	100	108.755
F11	100.966	100	64.370

Tabela 3.1: Tabela de luminosidade(valor da cor branca de referência)

cores em pontos fixos da imagem como, por exemplo, os Vetores de Coerência de Cores [PZM96] e os Correlogramas [HKM⁺97].

3.2.1 Histograma

Essa abordagem foi apresentada por Swain e Ballard em 1991 [SB91] no contexto de visão computacional. Nesse contexto, um robô deve ser capaz de comparar e identificar determinado objeto presente na imagem com os objetos presentes em um banco de modelos pré-definidos. Esta abordagem surgiu como uma alternativa ao paradigma de que a informação existente na geometria dos objetos estudados é o único aspecto a ser analisado e que contém informações relevantes para a identificação destes objetos.

Um histograma é uma função de distribuição de probabilidade da informação cromática da imagem, isto é, uma função que para cada valor discreto de cor informa a probabilidade de um pixel da imagem pertencer a essa cor. Formalmente podemos definir um histograma $H(k)$ como:

$$H(k) = \frac{n_k}{n} \quad (3.8)$$

onde n_k é o número de pixels da imagem contendo a cor (ou nível de cinza) k e n é o seu número total de pixels.

A partir desta representação do conteúdo de uma imagem, podem ser utilizadas as métricas L_1 , L_2 e L_∞ , por exemplo, para se calcular a similaridade entre histogramas.

$$d_{L_1}(H, I) = \sum_{j=1}^k |h_j - i_j| \quad (3.9)$$

$$d_{L_2}(H, I) = \sqrt{\sum_{j=1}^k (h_j - i_j)^2} \quad (3.10)$$

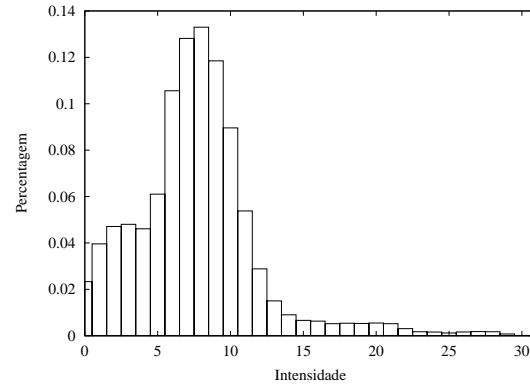
$$d_{L_\infty}(H, I) = \max_{1 \leq j \leq k} |h_j - i_j| \quad (3.11)$$

Em que k é o número de cores da imagem e h_j e i_j são as probabilidades de se encontrar um pixel da cor j na imagem.

A figura 3.1 apresenta um exemplo de imagem em níveis de cinza e seu histograma correspondente.



(a) Imagem



(b) Histograma

Figura 3.1: Uma imagem e seu histograma.

Como o uso do histograma como forma de representação de imagens para a recuperação por conteúdo foi proposto na área de visão robótica, é importante considerarmos as classes de imagens sobre as quais o método é empregado, para podermos fazer comentários específicos sobre suas vantagens e deficiências. Inicialmente, as imagens são obtidas através de uma câmera presente no corpo do robô e que se movimenta com ele. O robô se movimenta até que um dos objetos presentes no ambiente esteja associado à maioria dos pixels da imagem. Neste caso temos uma série de imagens com um objeto central ocupando a maior parte da imagem e um fundo com poucas variações. O banco de dados é formado por uma série de vistas ortogonais dos objetos, sendo que nessas imagens o seu fundo foi removido, deixando apenas as cores pertencentes ao objeto para a criação do histograma. As vantagens do histograma que permitem um bom desempenho com o conjunto de imagens descrito são: invariância à rotação, invariância à translação e a facilidade computacional. Portanto, os objetos presentes nas imagens podem estar em

qualquer posição e em qualquer orientação, o que define, assim, uma grande flexibilidade na identificação dos mesmos. Como o histograma pode ser calculado com apenas uma varredura da imagem, um histograma pode ser facilmente gerado para cada quadro fornecido pela câmera presente no robô. Além de não conter informações espaciais, as limitações do histograma são a sua dependência de um parâmetro de quantização da imagem, o que pode influir na sua efetividade, a sua sensibilidade às variações de iluminação, e a falta de consideração da proximidade entre as cores de um mesmo histograma, aspecto este considerado pelo próximo modelo.

3.2.2 Histograma acumulado

Essa abordagem foi proposta por Stricker e Orengo em 1995 [SO95] e tem como objetivo tratar de dois problemas existentes com o uso de histogramas que são a não consideração da relação entre as cores que compõem um histograma e a sensibilidade ao parâmetro de quantização.

Esses problemas podem ser exemplificados na figura 3.2. Nela temos três histogramas cuja similaridade calculada com base nas métricas L_1 e L_2 não corresponde à similaridade percebida. Estes histogramas mostram o problema de não se levar em conta a relação entre os seus bins. Considerando os histogramas H_1 , H_2 e H_3 normalizados, temos que $d_{L_1}(H_1, H_2) = 1$, $d_{L_1}(H_1, H_3) = 2/3$ e $d_{L_1}(H_2, H_3) = 2/3$. A distância entre os histogramas H_1 e H_2 é maior do que entre H_1 e H_3 ou H_2 e H_3 , o que contradiz nossa percepção de similaridade.

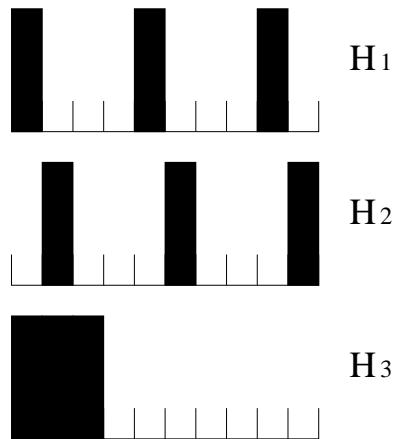


Figura 3.2: Exemplos de histogramas [SO95]

Um modo de resolver esse problema é usar uma função que leve em conta a similaridade

entre os bins. Um dos problemas dessa abordagem é que o cálculo da similaridade torna-se mais complexo. Uma outra solução é utilizar uma representação mais robusta para a distribuição de cores da imagem, tendo nessa representação a informação da similaridade entre os bins. Uma dessas soluções é a utilização de histogramas acumulados apresentado por Stricker e Orengo.

Para a criação desse histograma acumulado é importante determinar a ordem relativa das cores, já que essa ordem vai representar a similaridade entre as mesmas. Assim, bins próximos serão mais similares que bins distantes. Os autores propuseram o uso da ordenação natural das cores, isto é, as cores são ordenadas pelos valores de R, G e B nesta ordem para criar a ordenação do histograma acumulado.

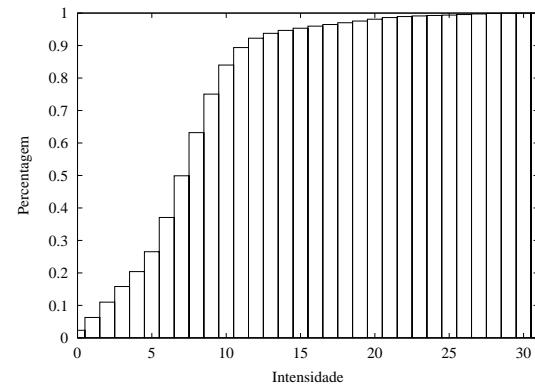
Formalmente, podemos definir um histograma acumulado $\widetilde{H}(i)$ como

$$\widetilde{H}(i) = \sum_{i=0}^k \frac{n_i}{n} \quad (3.12)$$

em que n_i é o número de pixels da imagem de cor i , n é o número total de pixels e k é o número de cores da imagem. Na figura 3.3 temos uma exemplo de uma imagem em níveis de cinza e seu histograma acumulado.



(a) Imagem



(b) Histograma acumulado

Figura 3.3: Uma imagem e seu histograma acumulado

A figura 3.4 apresenta os histogramas acumulados correspondentes aos histogramas da figura 3.2. Com os histogramas acumulados temos $d_{L_1}(\widetilde{H}_1, \widetilde{H}_2) = 1/6$, $d_{L_1}(\widetilde{H}_1, \widetilde{H}_3) = 3/6$ e $d_{L_1}(\widetilde{H}_2, \widetilde{H}_3) = 4/6$. Podemos perceber uma relação mais correta de similaridade entre as imagens representadas por estes histogramas acumulados.

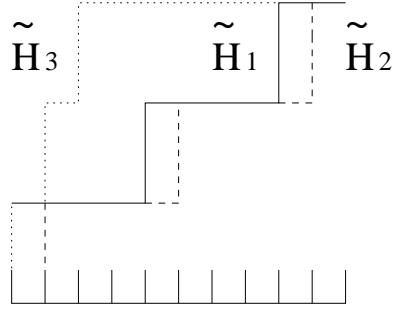


Figura 3.4: Histogramas acumulados correspondentes aos histogramas da figura 3.2 [SO95]

3.2.3 Momentos

Essa abordagem, também proposta por Stricker e Orengo em 1995[SO95], tem como objetivo principal a criação de um modelo de indexação da informação cromática da imagem, independente de parâmetros de quantização durante a criação dos índices.

Segundo os autores podemos interpretar a distribuição de cores de uma imagem como uma função de distribuição de probabilidade, então podemos caracterizar essa distribuição pelos seus momentos. Por questão de eficiência, são utilizados apenas os três primeiros destes momentos que correspondem, respectivamente à média(E_i), variância(σ_i) e assimetria(s_i).

Formalmente temos:

$$E_i = \frac{1}{N} \sum_{j=1}^N p_{ij} \quad (3.13)$$

$$\sigma_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^2 \right)^{\frac{1}{2}} \quad (3.14)$$

$$s_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^3 \right)^{\frac{1}{3}} \quad (3.15)$$

onde p_{ij} é o valor do pixel na posição (i, j) e N , o total de pixels da imagem. Para a avaliação da similaridade, utilizamos a seguinte definição:

$$d_{mom}(H, I) = \sum_{i=1}^r w_{i1}|E_i - F_i| + w_{i2}|\sigma_i - \varsigma_i| + w_{i3}|s_i - t_i| \quad (3.16)$$

onde w_{i1} , w_{i2} e w_{i3} são pesos, r é o número de componentes de cor, E_i e F_i são médias, σ_i e ς_i são variâncias e s_i e t_i são valores de assimetria. d_{mom} não é uma métrica pois como

são utilizados apenas os três primeiros momentos, podem haver distribuições de cores com $d_{mom} = 0$ entre si mas que não são necessariamente idênticas.

Esta abordagem consegue criar uma estrutura de representação da informação cromática da imagem independente de qualquer parâmetro, na sua criação, mas introduz o problema da utilização de pesos no cálculo da similaridade, o que dificulta a utilização de estruturas eficientes para a representação desses índices.

3.2.4 Vetor de coerência de cores

Proposta por Greg Pass, Ramin Zabih e Justin Miller em 1996 [PZM96], tem como idéia básica a coerência entre os pixels da imagem, ou seja, a característica de que pixels de uma cor fazem parte de grandes regiões similares. Baseado nesse conceito, a imagem é segmentada em seus componentes conexos, regiões maximais compostas por pixels de mesma cor. Um fator τ é fixado para servir de referência na definição dos pixels coerentes e incoerentes. Se o pixel pertencer a uma região de área menor que τ ele é classificado como incoerente, e se pertencer a uma região com área maior que τ , classificado como coerente. A partir dessa classificação são criados dois histogramas distintos: um composto apenas pelos pixels coerentes e outro pelos pixels incoerentes. Na comparação entre dois vetores de coerência de cores, cada tipo de histograma é comparado separadamente, isto é, os histogramas coerentes são comparados entre si, utilizando, por exemplo, a métrica L_1 e os histogramas incoerentes também são comparados entre si utilizando o mesmo critério. O resultado final é dado pela média dos dois resultados.

Os testes apresentados pelos autores foram realizados usando o seguinte critério: pares de imagens foram selecionados correspondendo a pares evidentes e foi avaliada a melhoria na posição do ranking das saídas das consultas feitas com um dos elementos do par. Esse critério é a medida $Rank_1$, a ser apresentada no capítulo 5. Mesmo sendo importante, na análise do desempenho de um sistema, essa medida sozinha não contém informação suficiente para a avaliação da efetividade do modelo proposto.

O trabalho proposto por Stehling, Nascimento e Falcão em [SNF02] se insere neste contexto, sendo que ao propor um critério de classificação, dependente apenas da vizinhança local de cada pixel, a etapa de segmentação pode ser descartada.

3.2.5 QuadTrees

Esse modelo foi proposto por Hongjun Lu, Beng Chin Ooi e Kian-Lee Tan em 1994 [LOT94] e é a base de uma abordagem que tenta lidar com diferentes níveis de abstração da representação da imagem. Para associar a informação da posição ao histograma, é criada uma quadtree completa denominada histograma de cor multiníveis. No primeiro nível dessa estrutura, temos o histograma global da imagem; no nível seguinte, temos

quatro histogramas diferentes, cada um para os quatro quadrantes em que a imagem é subdividida. Assim, em cada novo nível, quatro novos histogramas são criados para cada histograma do nível anterior pela subdivisão da região correspondente em quatro subregiões. Esse processo é repetido até que um número de níveis conveniente seja alcançado. A comparação é feita da seguinte forma: as estruturas de duas imagens são comparadas nível a nível e se em algum ponto a diferença entre os histogramas ultrapassa um determinado valor de corte, as imagens são consideradas diferentes, caso contrário, a comparação é feita até se chegar ao nível mais baixo e as imagens são consideradas semelhantes. Com essa estrutura é possível resolver consultas que tenham informação espacial da imagem como, por exemplo, uma imagem de um pôr do sol no mar que tem uma grande região azul na porção inferior da imagem e uma grande área amarela na sua parte superior. Porém, essa estrutura perde algumas das propriedades interessantes do histograma que são a invariância à rotação e à translação.

3.2.6 Correlogramas

Esse modelo foi proposto por Huang et al em 1997 [HKM⁺97] e baseia-se no conceito empregado em análise de texturas, a matriz de co-ocorrência, aplicada a uma imagem colorida.

Um correograma é uma matriz que armazena a probabilidade de cada par de cores possíveis na imagem estar separado por uma distância d variando de 1 até a maior distância possível na imagem. Para simplificar esta estrutura, o artigo propõe a utilização de um subconjunto de distâncias possíveis e a utilização apenas da correlação entre pixels da mesma cor. Este modelo é denominado autocorreograma.

Os autores afirmam que esse modelo é capaz de tratar uma série de casos específicos como, por exemplo, problemas relativos à mudança de fundo, posição da cena na imagem, oclusão parcial de objetos e zoons.

O tamanho da estrutura de representação é proporcional a m^2d , onde m é o número de cores utilizadas e d é o número de distâncias entre pixels utilizadas no cálculo do correograma, sendo este valor muito maior que o espaço ocupado por um histograma com o mesmo número de cores. O autocorreograma no entanto ocupa apenas um espaço proporcional à md , o que torna a sua utilização mais prática.

Capítulo 4

Modelo Coesão

Neste capítulo apresentamos o modelo proposto para a recuperação por conteúdo de imagens baseado em homogeneidade de regiões denominado coesão.

A primeira seção deste capítulo identifica o tipo de imagem ao qual o modelo se destina. A seção seguinte, apresenta a idéia geral do modelo proposto e, finalmente, a última seção detalha alguns dos seus principais aspectos.

4.1 Definição da classe de imagens considerada

O modelo proposto neste trabalho tem como objetivo recuperar imagens através de uma informação global baseada em homogeneidade de cores das imagens. Assim sendo, o tipo de imagens que buscamos representar são imagens coloridas cujas informações cromática e geométrica das regiões de pixels homogêneos sejam características importantes na identificação dos objetos presentes nas imagens correspondentes.

Como um dos objetivos deste trabalho foi a definição de um descritor global invariante à rotação e translação dos objetos presentes nas imagens, consideramos equivalentes, portanto, imagens em que os mesmos objetos aparecem em diferentes disposições espaciais sem que contudo exista oclusão entre os objetos, como pode ser visto na figura 4.1.

A figura 4.2 ilustra 3 das 18 imagens do banco de dados utilizadas como imagens de consulta neste trabalho.

Em muitos modelos que realizam a recuperação por conteúdo combinando a informação de cor com a informação espacial ou topológica, é assumido que a imagem contém um objeto na região central da cena e que este objeto ocupa uma grande parte da imagem [SB91] ou que a representação de cada componente está associada a sua posição na imagem [LOT94], o que é um modelo válido para uma variada gama de aplicações.

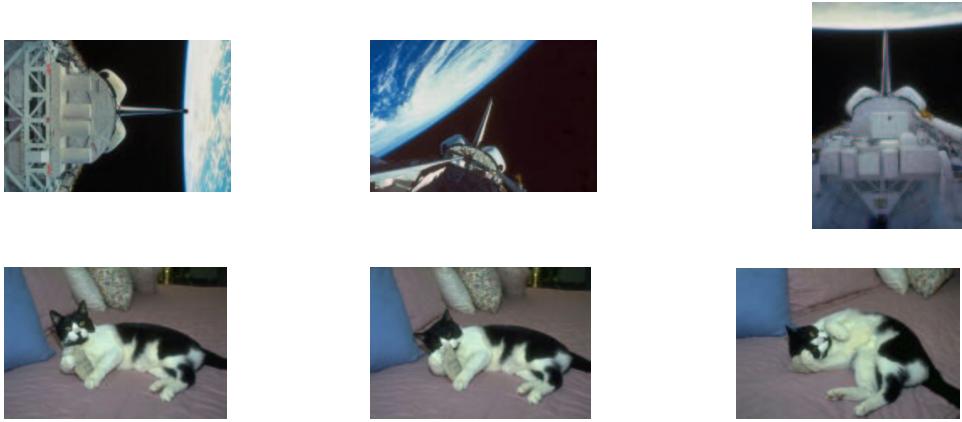


Figura 4.1: Exemplos de rotação e translação.



Figura 4.2: Exemplos de imagens de consulta.

4.2 O modelo coesão para recuperação de imagens por conteúdo

Com base nos tipos de imagens mencionados anteriormente, consideramos que estatísticas relativas à distribuição das regiões coloridas das imagens podem fornecer informações relevantes a uma discriminação destas imagens. Na figura 4.3 apresentamos quatro imagens sintéticas que ilustram bem o tipo de situação que pretendemos abordar, casos estes em que os histogramas das imagens são muito similares mas que a disposição espacial das cores as tornam diferentes entre si.

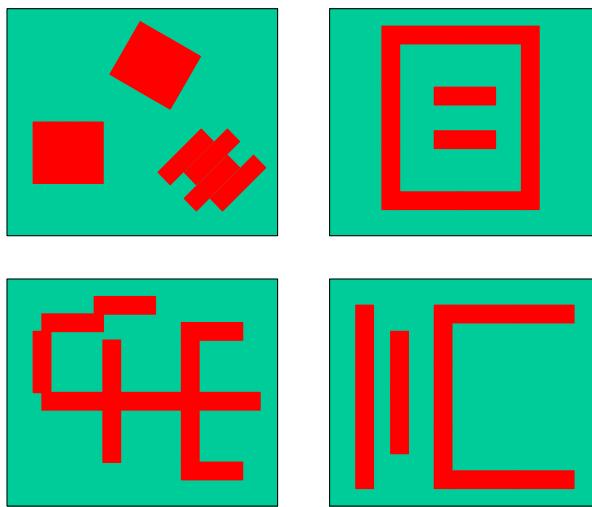


Figura 4.3: Imagens com histogramas idênticos.

A definição deste descritor tem como base a utilização da informação cromática, informação esta que em muitos casos é capaz de identificar os objetos presentes nas imagens em conjunto com a distribuição espacial desta informação. Um dos requisitos básicos que pretendemos satisfazer era o que refere-se à preservação de algumas das propriedades que julgamos interessantes nos modelos de recuperação baseados em histograma que são a invariância à rotação e à translação dos objetos dentro da imagem. Um exemplo do tipo de situação que pretendemos abordar pode ser visto na figura 4.4. Nesta figura, a imagem definida como mais relevante a partir de uma consulta baseada no histograma acumulado (figura 4.4b) tem a mesma distribuição de cores da imagem de consulta (figura 4.4a), sem no entanto estar realmente relacionada com a imagem de consulta, enquanto que o modelo de coesão, por explorar de alguma forma a informação espacial da imagem, é capaz de retornar uma imagem mais próxima da imagem de consulta como sendo a mais relevante

(figura 4.4c).

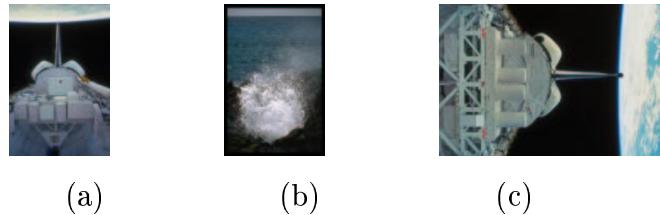


Figura 4.4: Consulta utilizando histograma acumulado e coesão.

O modelo de coesão tem como objetivo representar o grau de agregação das regiões homogêneas da imagem representado através de informações relativas à distribuição destas regiões, isto é, através da análise da distribuição de atributos das regiões considerados. A figura 4.5 ilustra as principais etapas envolvendo a criação de um tal descritor de imagens. A próxima seção comenta estas etapas em maiores detalhes

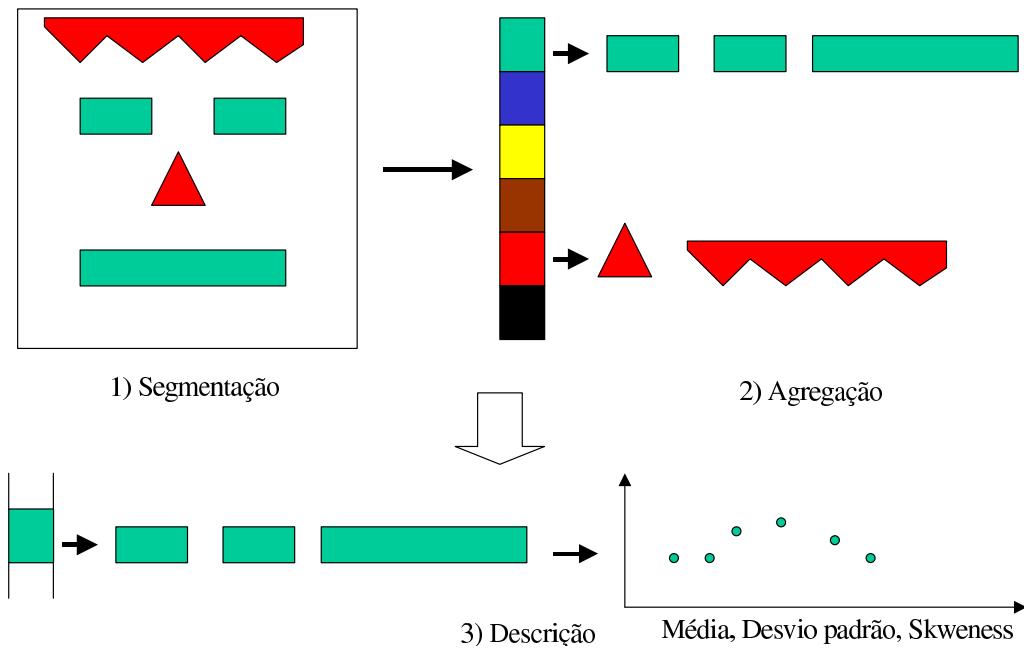


Figura 4.5: Ilustração das etapas envolvendo o descritor coesão.

4.3 Etapas para criação do descritor coesão

As etapas necessárias à criação de um descritor coesão são as seguintes:

- escolha do espaço de cores,
- quantização do espaço de cores,
- segmentação,
- agregação das regiões homogêneas,
- escolha de propriedades das regiões a serem analisadas,
- cálculo de estatísticas usadas para descrever a propriedade escolhida.

4.3.1 Escolha do espaço de cores

Inicialmente, devemos definir o espaço de cores a ser utilizado e a quantização deste [Smi02]. Neste trabalho escolhemos o espaço RGB para descrever as cores da imagens de consulta por ser o espaço de cores original das imagens e um dos mais utilizados na área de processamento de imagens. A não utilização de outros espaços de cores como, por exemplo, o espaço $L^*a^*b^*$ deve-se ao fato que a conversão correta para este outro formato exige um conhecimento das características cromáticas do dispositivo de captura das imagens e da fonte de iluminação presente quando da obtenção das imagens.

4.3.2 Quantização do espaço de cores

A quantização ou particionamento do espaço de cores em regiões é necessária por dois aspectos:

- Com a quantização é possível tratar pequenas variações nas cores das imagens, pois um intervalo de valores próximos no espaço de cores é mapeado para o mesmo valor após a quantização.
- Outro motivo para a realização do particionamento do espaço de cores é o problema de representar e armazenar todas as cores possíveis do espaço que, por exemplo, no caso do espaço RGB seria de 2^{24} cores, o que demanda um espaço grande de armazenamento, sendo que a maioria das cores não está naturalmente presente nas imagens. A divisão do espaço de cores pode não ser uma divisão uniforme, permitindo que o método seja ajustado para aplicações específicas em que a distribuição das cores é conhecida a priori.

4.3.3 Segmentação

Como nosso objetivo é considerar as regiões de cores homogêneas das imagens, a etapa de segmentação torna-se especialmente importante para a criação do descritor. Existem várias técnicas que podem ser empregadas na segmentação das imagens inseridas no banco de dados [LM01]. No entanto, como partimos do pressuposto de que estamos realizando uma busca por similaridade e que as imagens podem ser genéricas, ou seja, não temos informação adicional sobre as mesmas, decidimos considerar uma abordagem simples de segmentação e computacionalmente barata baseada em crescimento de regiões. O critério de homogeneidade para a agregação de um pixel a uma dada região considera que a cor atribuída ao pixel sendo avaliado tem a mesma quantificação que a de um pixel de uma região vizinha a este. Foram geradas segmentações que consideram como vizinhanças os caso 4 e 8 conexos, separadamente. De um modo geral, a partir de maiores informações sobre a natureza das imagens, técnicas mais poderosas de segmentação podem ser utilizadas, o que deve melhorar o desempenho dos descritores associados.

4.3.4 Agregação das regiões homogêneas

Após a segmentação da imagem, é feito um rotulamento das regiões obtidas atribuindo-se, assim, um identificador único a cada partição. A partir deste rotulamento, é criada uma estrutura que agrupa as regiões homogêneas pela sua informação cromática. Esta estrutura servirá de base para a criação do descritor proposto nesta dissertação.

4.3.5 Escolha de propriedades das regiões a serem analisadas

Após o agrupamento das regiões homogêneas devemos escolher algumas propriedades características das regiões a serem analisadas visando a definição do descritor coesão. Há uma série de atributos geométricos e topológicos que podem ser avaliados para a criação de um tal descritor, tais como, a área das regiões, a compacidade, a excentricidade, o “elongatedness”, o número de Euler da região [GW93], etc. Uma utilização combinada destas propriedades pode ser feita através de técnicas de combinação de múltiplos descritores utilizando, por exemplo, o conceito de “relevance feedback” utilizado em [CC99, FW00, dVC02, ORC⁺98, RHMO97]. Consideramos que a área das regiões homogêneas é uma propriedade básica para representar a idéia do grau de agregação dos pixels e por isso será a propriedade escolhida para ilustrar a criação do nosso descritor. Outro fator que contribuiu na escolha da área como propriedade para representar a informação das regiões homogêneas é que devido à simplicidade de sua obtenção é possível criar um descritor com complexidade computacional semelhante ao dos modelos estudados no capítulo 3 como, por exemplo, o vetor de coerência de cores.

4.3.6 Informação das regiões homogêneas e estatísticas

Com a escolha de um atributo para representar a informação de geometria das regiões homogêneas da imagem, no nosso caso a área das regiões, deve-se então escolher a melhor maneira de representar este atributo. Uma abordagem natural seria criar o descritor com a informação de área de cada região individualmente, abordagem esta que seria muito custosa em espaço de armazenagem e em tempo de processamento das consultas. A abordagem aqui escolhida foi a utilização de parâmetros estatísticos para realizar a summarização da distribuição da área das regiões homogêneas de cada cor. Vários podem ser os parâmetros utilizados para fazer essa summarização como, por exemplo, média, mediana, moda, mínimo, máximo, desvio padrão, percentis. Neste trabalho a média é empregada inicialmente para descrever a distribuição da áreas das regiões nas imagens.

Tendo escolhido a propriedade das regiões homogêneas e sua forma de representação, podemos fazer uma comparação com os principais modelos que combinam a informação cromática com a geométrica apresentados no capítulo 3, ou seja, o vetor de coerência de cores e o correlograma. No caso do vetor de coerência de cores [PZM96], podemos observar que a informação extraída pelo modelo relativa à área das regiões homogêneas, se limita ao uso desta como um valor de corte para a criação dos histogramas que compõem o modelo, sendo que todo o resto da informação é descartada. Já o modelo baseado em correlograma [HKM⁺97], mais especificamente no caso do autocorrelograma, tem potencialmente mais informação, dependendo especificamente da escolha do conjunto de distâncias empregadas na criação do descritor para representar a agregação das regiões homogêneas.

4.3.7 Algoritmo do cálculo da coesão por área média

O pseudo-código (algoritmo 4.1) apresentado a seguir refere-se à criação do descritor coesão a partir da informação da área média de regiões homogêneas. Este algoritmo pode ser facilmente generalizado para outros atributos da região e é dividido em três etapas: segmentação da imagem, criação de um vetor de áreas e criação do descritor coesão. A próxima seção aborda a complexidade computacional do algoritmo proposto.

4.3.8 Análise da complexidade do algoritmo proposto

A análise da complexidade computacional do algoritmo proposto considera os seguintes parâmetros:

- N_p : número de pixels da imagem.
- N_r : número de regiões homogêneas presentes na imagem sendo $N_r \leq N_p$

Algoritmo 4.1 Criação do descritor coesão

Entrada: Imagem I , Número de cores N_c
Saída: Imagem de rótulos R , Número de Regiões N_r , Descritor Coesão C

- 1: Criar Imagem de rótulos R ; Inicializar N_r com 0
- 2: **for all** pixel p da imagem I em ordem direta **do** {início da segmentação da imagem}
- 3: **if** p ainda não foi visitado **then**
- 4: $CorAtual \leftarrow$ cor de p
- 5: VisitarVizinhos($I, R, p, N_r, CorAtual$)
- 6: Incrementar N_r
- 7: **end if**
- 8: **end for**{fim da segmentação da imagem}
- 9: Criar Vetor de áreas, VA , de tamanho N_r com valores iniciais iguais a 0
- 10: **for all** pixel p da imagem I em ordem direta **do** {início da geração da lista de regiões}
- 11: $VA[R[p]].cor \leftarrow$ cor de p
- 12: Incrementar $VA[R[p]].area$
- 13: **end for**{fim da geração da lista de regiões}
- 14: Criar Descritor Coesão C de tamanho N_c com valores iniciais iguais 0
- 15: Criar vetor NumeroDeRegiões NR de tamanho N_c com valores iniciais iguais 0
- 16: **for** $r = 0$ até $N_r - 1$ **do** {início da geração do descritor Coesão}
- 17: Incrementar $C[VA[r].cor]$ com $VA[r].area$
- 18: Incrementar $NR[VA[r].cor]$
- 19: **end for**
- 20: **for** $e = 0$ até $N_c - 1$ **do**
- 21: $C[e] \leftarrow \frac{C[e]}{NR[e]}$
- 22: **end for**{fim da geração do descritor Coesão}

Algoritmo 4.2 VisitarVizinhos

Entrada: Imagem I , Imagem de rótulos R , pixel p , Número de Regiões N_r , CorAtual C
Saída: Imagem de rótulos R

- 1: **if** pixel p não foi visitado AND possui a cor atual **then**
 - 2: $R[p] \leftarrow N_r$
 - 3: Chamar VisitarVizinhos para os vizinhos de p
 - 4: **end if**
-

- N_c : número de cores definidas na quantização.

O código das linhas 4-6, responsável pela segmentação da imagem, visita todos os pixels, sendo que o número de testes de cada um dos pixels corresponde, no máximo, ao número de seus vizinhos. O trecho de código entre as linhas 11-12, responsável pela geração da lista de regiões homogêneas, é executado N_p vezes. O código compreendido entre as linhas 17 e 18 é executado N_r vezes e, finalmente, o código da linha 21 é executado N_c vezes. Estes dois últimos trechos são responsáveis pela geração do descritor coesão. Como $N_r \leq N_p$ temos que a complexidade do algoritmo é $O(N_p + N_c)$. Considerando que N_c será uma constante no momento da criação do banco de dados temos, portanto, que a complexidade final do algoritmo é $O(N_p)$.

Capítulo 5

Experimentos

Neste capítulo analisamos o resultado de dois experimentos, visando uma comparação do modelo de coesão com dois modelos básicos mencionados no capítulo 3. Um dos modelos considera apenas a informação dos níveis de cinza da imagem (histograma, seção 3.2.1), e o outro que acrescenta uma certa informação espacial à informação cromática (vetor de coerência de cores, seção 3.2.4).

Em alguns dos trabalhos que apresentam os modelos de recuperação por conteúdo estudados, a etapa de análise dos resultados não apresenta o rigor e a abrangência necessários para permitir uma avaliação mais completa dos resultados. Por isso, nesta dissertação temos como um dos principais objetivos realizar uma análise dos resultados que consideramos apropriada.

Visando uma análise mais abrangente do que aquela apresentada na literatura para os métodos descritos no capítulo 3, como veremos, nossa análise baseia-se na utilização dos parâmetros propostos em [MMS⁺01] e numa análise estatística a partir de uma escolha do tipo de teste a ser empregado coerente com os critérios de avaliação considerados nos experimentos.

A *Efetividade* de um sistema de recuperação de informações [Dim99, MS83, vR79] indica o grau de corretude das respostas produzidas por este sistema. Ela pode ser dada, por exemplo, pelos parâmetros de *precision* (precisão) e *recall* (revocação) do sistema. O *precision* é a capacidade do sistema de apresentar apenas os resultados relevantes a uma determinada consulta, e o *recall* é a capacidade do sistema de apresentar todos os seus resultados relevantes.

Nas próximas seções apresentamos os elementos necessários à realização da análise da efetividade dos modelos considerados e à verificação da significância estatística dos testes realizados.

5.1 Análise da efetividade

Em [MMS⁺01] temos a identificação das três questões principais relacionadas com a avaliação da efetividade dos sistemas de recuperação de imagens por conteúdo: a definição da coleção de imagens utilizada, a definição dos conjuntos de imagens relevantes para cada consulta e a escolha do critério de avaliação da efetividade.

5.1.1 Definição da coleção de imagens

O conjunto de imagens utilizado nas avaliações deve conter elementos significativos da área de atuação da aplicação considerada. As imagens devem permitir que as diferenças de discriminação das diversas abordagens testadas sejam corretamente avaliadas. Por isso deve-se evitar que o conjunto de imagens utilizado tenha uma natureza muito compartimentada, isto é, que todas as imagens possam ser divididas em grupos muito bem definidos e muito distintos uns dos outros. Como exemplo a ser evitado, podemos analisar o conjunto de imagens disponíveis para a avaliação na Internet do sistema *Surf Image* no qual um dos bancos de imagens é populado por dezenas de imagens dos mesmos objetos, com mínimas variações, como pode ser visto na figura 5.1. Este tipo de conjunto de imagens dificulta a avaliação da efetividade dos modelos testados.



Figura 5.1: Resultado de uma consulta no Sistema Surf Image.

Outro problema refere-se à propriedade das imagens utilizadas. Como existem poucas

coleções de imagens de domínio público que possam ser utilizadas livremente, cada sistema é avaliado a partir de um conjunto diferente de dados, o que torna difícil a comparação de desempenho entre diferentes sistemas. Este aspecto impediu, por exemplo, a realização da avaliação proposta por pesquisadores da Universidade de Manchester no estudo dos sistemas existentes na área de recuperação de imagens por conteúdo [VC00].

5.1.2 Definição do conjunto de imagens relevantes

Esta é uma das tarefas que consome mais tempo no processo de avaliação de um sistema de recuperação por conteúdo. Como apresentado em [Dim99], podemos considerar dois tipos de conjuntos de imagens relevantes: as que são usadas para estudar a estabilidade do sistema com relação a uma série de fatores, tais como deslocamentos de cores, rotações das imagens e presença de ruído e as que são consideradas na avaliação do poder de discernimento dos modelos em estudo. No primeiro caso, só é necessário definir a imagem que serve de base para a aplicação dos elementos de perturbação sendo que, em geral, a criação do conjunto é semi-automática ou automática. No segundo caso, é necessária uma seleção manual de um conjunto de imagens relevantes. Esta seleção pode seguir uma série de critérios que, em último caso, dependente do próprio avaliador. Neste caso, uma abordagem recomendada é a utilização de vários avaliadores para determinar os conjuntos de relevância e a utilização de um critério que permita a integração dos diferentes conjuntos selecionados. Infelizmente, isto nem sempre é possível devido ao enorme conjunto de dados necessário e ao tempo dispendido nesta seleção.

5.1.3 Critérios de avaliação da efetividade

Existem várias formas de se avaliar a efetividade de um sistema de recuperação de imagens por conteúdo. Os critérios mais utilizados são o precision e o recall [MS83, vR79] que devido à característica de ordenação/particionamento das consultas podem ser representados graficamente. Conjuntamente com as informações dos gráficos de precision-recall, usamos também as medidas propostas em [MMS⁺01], definidas a seguir, para complementar as avaliações das consultas, permitindo assim uma análise mais precisa do resultado dos experimentos.

Precision e recall

No contexto de recuperação de imagens por conteúdo, o resultado de uma consulta é uma ordenação de todo o banco de imagens em relação a uma imagem de consulta. Assim, podemos definir um valor de corte k para avaliarmos as k primeiras imagens retornadas pela consulta e, a partir desta configuração, definir o conjunto das imagens relevantes

recuperadas até o valor de corte k . A partir destas informações e do total de imagens relevantes especificado a priori para a consulta, podemos definir o precision e o recall como:

$$Precision = \frac{\text{Total de imagens relevantes recuperadas}}{k} \quad (5.1)$$

$$Recall = \frac{\text{Total de imagens relevantes recuperadas}}{\text{Total de imagens relevantes}} \quad (5.2)$$

Variando o valor de corte k podemos obter pares de precision e recall e a partir destes valores montar um gráfico de precision-recall, gráfico este que constitui nosso instrumento básico de avaliação da efetividade dos modelos estudados.

Os gráficos de precision-recall não possuem todas as informações necessárias para uma avaliação completa dos modelos de representação de conteúdo. Associados a estes gráficos, consideramos ainda o conjunto de medidas proposta em [MMS⁺01]: $Rank_1$, \widetilde{Rank} , $P(20)$, $P(50)$, $P(N_R)$, $R_{P(0.5)}$ e $R(100)$.

$Rank_1$ é a posição (rank) da primeira imagem relevante obtida na consulta. Em sistemas em que é esperada uma resposta única a uma consulta, esta medida é o indicador mais importante para a avaliação da sua efetividade.

\widetilde{Rank} é a posição média das imagens relevantes normalizada. A necessidade da normalização deve-se ao fato adverso que uma única imagem com posição alta pode ter no valor da posição média. Ela é dada pela seguinte formula:

$$\widetilde{Rank} = \frac{1}{NN_R} \left(\sum_{i=1}^{N_R} R_i - \frac{N_R(N_R + 1)}{2} \right) \quad (5.3)$$

onde N é o numero de imagens no banco de dados, N_R é o número de imagens relevantes e R_i é a posição da i -ésima imagem relevante retornada. Este valor varia de 0 para o caso ideal e se aproxima de 1 para o pior caso. Um resultado próximo de 0.5 indica que o resultado não é melhor do que um resultado obtido aleatoriamente.

$P(20)$, $P(50)$, $P(N_R)$ são valores de precision calculados em determinados valores de corte, considerando, respectivamente, a recuperação de 20 imagens, 50 imagens e com o número de imagens recuperadas correspondente ao número de imagens relevantes à consulta. Estes valores servem para medir a satisfação do usuário com as imagens iniciais apresentadas por um sistema, sendo 20, usualmente, o número de imagens apresentadas na tela inicial dos resultados de uma consulta e 50 o número médio de imagens percorridas por um usuário ao tentar identificar imagens relevantes no conjunto das respostas do sistema. $P(N_R)$ avalia quanto o valor do precision se afasta do caso ideal.

$R_{P(0.5)}$ é o valor do recall quando o precision cai abaixo de 0.5, ou seja, qual a porcentagem das imagens relevantes recuperadas considerando-se que existem mais imagens não relevantes na resposta da consulta do que imagens relevantes.

$R(100)$ é o valor de recall após a recuperação de 100 imagens.

5.2 Testes de significância estatística

Definidos os critérios a serem considerados na avaliação da efetividade dos modelos testados, devemos considerar se os resultados obtidos nestas avaliações são significativos do ponto de vista estatístico, isto é, se as diferenças encontradas não se devem ao acaso. Para tanto, consideraremos os chamados testes de significância estatísticos.

Um teste de significância estatístico é um teste que permite avaliar a validade de uma hipótese, tradicionalmente chamada de hipótese nula ou H_0 . Este teste produz um valor p que indica a probabilidade de se aceitar H_0 como verdadeira.

O teste escolhido para cada uma das medidas de avaliação da efetividade, vistas anteriormente, deve considerar três condições básicas: qual o tipo de variável sendo utilizada para avaliar os resultados de uma consulta, quantos modelos serão comparados e se há um pareamento entre os experimentos.

O número de modelos de representação considerados num teste influencia na escolha já que existem testes específicos para o caso particular de dois modelos sendo comparados, e testes para os casos em que três ou mais modelos são considerados.

Testes pareados são aqueles em que todos os modelos são testados com os mesmos elementos. A grande vantagem de se poder utilizar testes pareados é pela sua maior sensibilidade, isto é, possuem uma maior capacidade de detectar diferenças entre os modelos. Todos os testes de significância realizados na comparação de modelos para a recuperação de imagens devem ser pareados já que todos os modelos são avaliados a partir do mesmo conjunto de imagens.

As variáveis utilizadas na avaliação dos resultados de uma consulta podem ser de três tipos: nominais, ordinais ou cardinais. Variáveis nominais são as que possuem classes de valores sem que haja qualquer relação de *ordem* entre elas, como, por exemplo, nacionalidade ou religião. Variáveis do tipo ordinal só possuem uma indicação da ordem relativa entre as suas classes de valores como, por exemplo, ordem de chegada em uma corrida. E, finalmente, variáveis do tipo cardinal são aquelas em que a diferença entre as classes de valores tem significado como, por exemplo, temperatura, peso ou altura. Não foram utilizadas variáveis nominais neste trabalho. A variável $Rank_1$ é do tipo ordinal e as demais variáveis mencionadas são do tipo cardinal.

Há algumas questões adicionais relativas às variáveis cardinais que devem consideradas para a escolha do teste correto de significância que são: a necessidade da variável ser linear, isto é, de que a diferença entre duas medições da variável tenha o mesmo significado em todo o domínio da variável e de que os seus valores pertençam a uma população com distribuição normal. Para saber se a variável possui uma distribuição normal, são

realizados testes de normalidade como o teste Kolmogorov-Smirnov ou o teste Shapiro-Wilk.

As duas divisões principais dos testes de significância são entre testes paramétricos (cardinal com distribuição normal) que são os testes mais comumente utilizados e não paramétricos (ordinal e cardinal sem distribuição normal).

Com o resultado dos testes de normalidade podemos escolher o teste de significância estatística adequado através da tabela 5.1 [Mot95]

Número de modelos de representação comparados	Tipo de variável	
	Cardinal com distribuição normal	Ordinal e cardinal sem distribuição normal
Dois modelos	teste t-student pareado	teste de Wilcoxon pareado
Três ou mais modelos	teste ANOVA	teste de Friedman

Tabela 5.1: Escolha do teste estatístico apropriado no caso de testes pareados [Mot95].

Escolhido o teste adequado, devemos considerar dois aspectos adicionais para a sua realização: definir se o teste será mono ou bicaudal, assim como o valor do nível de significância α .

Só devemos escolher um teste monocaudal, isto é, um teste em que se supõe que a diferença entre os modelos testados se apresenta em uma única direção como, por exemplo, o modelo A é *melhor* que o modelo B , se tivermos razões baseadas em estudos anteriores ou alguma fundamentação teórica para acreditar nesta hipótese. Caso não existam estudos anteriores que indiquem esta relação, deve-se escolher um teste bicaudal (o modelo A é *diferente* do modelo B) pois os testes monocaudais são mais sensíveis às variações na direção escolhida.

α é um limiar indicando que se o valor de p , representando a probabilidade de se aceitar a hipótese H_0 , produzido pelo teste estatístico estiver abaixo deste limiar, então é seguro rejeitar esta hipótese. Usualmente α é escolhido como 0.05 ou 0.01.

Ao se utilizar o teste de Friedman ou ANOVA, é necessário considerar a realização de testes denominados *post hoc* para se detectar quais modelos de recuperação apresentam diferenças entre si. Normalmente, no caso não paramétrico (teste de Friedman), é utilizado o teste de Wilcoxon através de testes dois a dois entre modelos. Neste caso, devemos considerar ainda o ajuste do limiar α empregado nestes testes para evitar a ocorrência de erros acumulados pela realização de muitos testes simultâneos. Em [Sha95] é apresentada uma revisão das principais técnicas utilizadas para a realização dos testes *post hoc*. Neste trabalho, consideramos o método de ordenação de valores de p proposto por Holm [Hol79] para realizar o ajuste do valor de α necessário aos testes. Informalmente, este método considera uma lista de valores de p , p_1, \dots, p_n de tamanho n , ordenada em ordem decrescente. Para cada valor p_i da lista nesta ordem é realizado o teste $p_i < \alpha/(n - i + 1)$.

Quando um valor de p satisfaz esta condição, ele e todos os valores ainda não testados são aceitos como abaixo do limiar α corrigido.

Para uma referência detalhada de todos os testes aqui mencionados recomendamos as referências [Zar84] e [Mot95]. A implementação destes testes pode ser obtida através do sistema livre e gratuito R¹.

5.3 Descrição dos experimentos

A realização dos experimentos considera um conjunto formado por aproximadamente 7000 imagens de variados tipos: imagens de satélite, texturas, pessoas, paisagens, edificações, obras de arte, animais, plantas etc.

Para a criação dos subconjuntos de imagens relevantes utilizados na avaliação dos modelos de representação foi feita uma avaliação exaustiva do conjunto de imagens disponível. A partir desta análise foram gerados 18 conjuntos de imagens relevantes, um para cada uma das 18 imagens de consulta consideradas. O conjunto das imagens de consulta contém diversos tipos de imagens presentes na coleção como, por exemplo, imagens de satélite, paisagens, objetos e animais. As imagens de consulta consideradas podem ser vistas na figura 5.2.

Uma série de experimentos foi considerada visando a avaliação da efetividade dos modelos implementados, a saber: histograma (seção 3.2.1), vetor de coerência de cores (seção 3.2.4) e coesão (seção 4.2). Os experimentos foram realizados com diferentes valores de quantização do espaço de cores, utilizando vizinhanças 4- e 8-conexas na segmentação da imagem, e empregando L_1 , L_2 e L_∞ como métricas de similaridade.

Para a realização dos experimentos foram consideradas duas configurações de uso do espaço de cores RGB. A primeira corresponde ao emprego do descritor coesão sobre as três bandas separadamente, e a segunda, ao emprego do descritor sobre o cubo RGB.

5.4 Discussão dos resultados

A primeira etapa na realização dos testes estatísticos relativos à análise da efetividade dos três modelos considerados é descobrir se as variáveis cardinais utilizadas (seção 5.1.3) seguem uma distribuição normal. Para tanto, aplicamos o teste de normalidade de Shapiro-Wilk cujos resultados (tabela 5.2) mostram que a probabilidade destas variáveis possuírem uma distribuição normal é praticamente nula.

Em função dos dados da tabela 5.2 e com base na tabela 5.1 consideremos apenas os testes de Wilcoxon e Friedman sobre os modelos analisados.

¹<http://www.r-project.org>

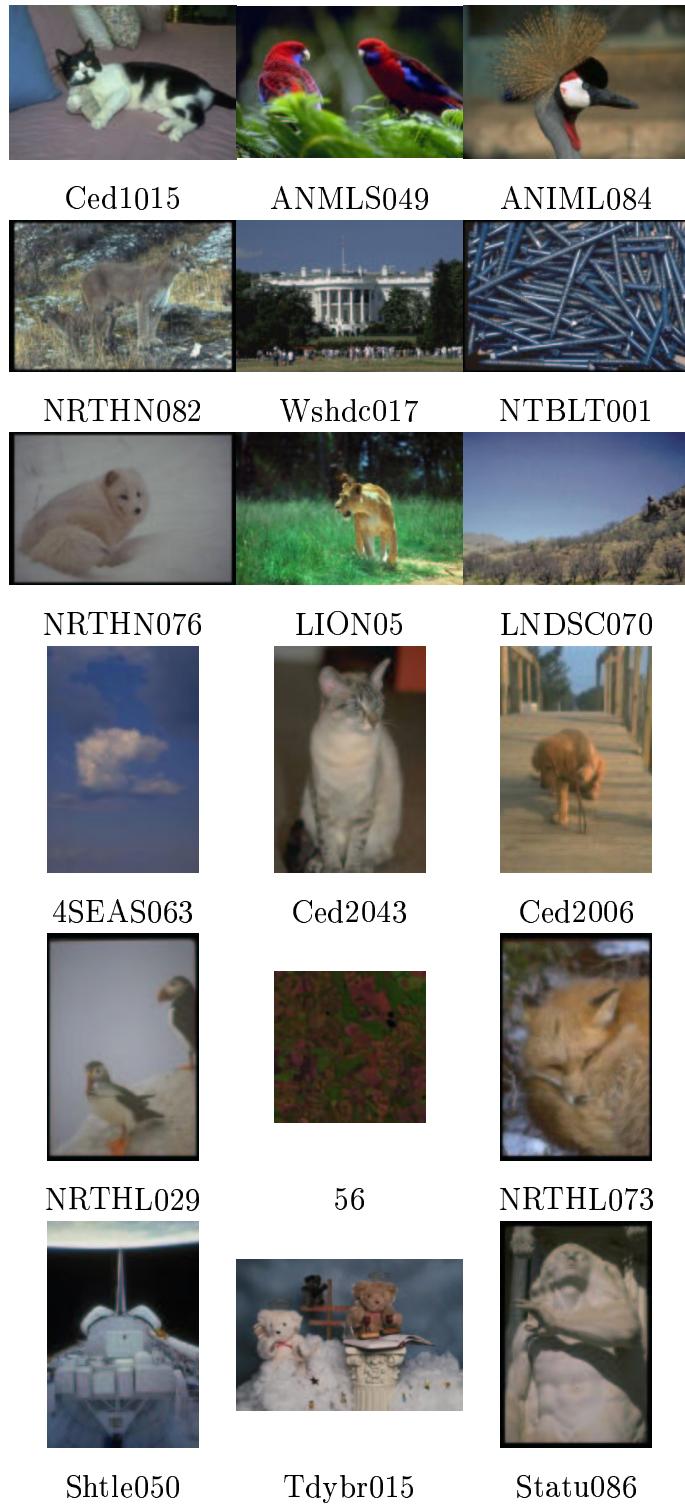


Figura 5.2: O conjunto das imagens de consulta.

\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
6.7×10^{-4}	2.2×10^{-16}				

Tabela 5.2: Valores de p do teste de normalidade de Shapiro-Wilk.

Os seguintes aspectos foram considerados na comparação entre os modelos de representação das configurações de uso do espaço de cores RGB:

- Verificação do efeito da quantização na efetividade do descritor coesão.
- Verificação do efeito da métrica utilizada na efetividade do descritor coesão.
- Verificação do efeito da conexidade no modelo coesão.
- Comparação do modelo coesão com os modelos baseados em histograma e vetor de coerência de cores.

5.4.1 Efeito da quantização do espaço de cores na efetividade do descritor coesão

As figuras A.4, A.5 e A.6 no apêndice A apresentam os gráficos de precision-recall relativos aos resultados das consultas das imagens na figura 5.2 empregando o descritor coesão. Estas consultas consideram quantizações de 32, 64, 128 e 256 bins do espaço de cores RGB, considerando as três bandas separadamente. Baseado nestas figuras e nos dados das tabelas 5.3 e 5.4 podemos analisar o efeito da quantização do espaço de cores na efetividade do modelo coesão.

De modo geral, podemos ver que a utilização da quantização em 128 ou 256 bins por componente permitiu uma melhora na efetividade do modelo em relação à utilização de 32 bins, considerando os critérios $P(20)$, $P(N_R)$ e $R_{P(0.5)}$, no caso de 128 bins, e $P(20)$ e $R_{P(0.5)}$, no caso de 256 bins. A quantização em 128 bins foi considerada na implementação do descritor coesão por ser ligeiramente superior à quantização considerando 256 bins e por ser um pouco menos suscetível a variações nas cores das imagens.

Critério de efetividade	valor de p do teste de Friedman($\alpha = 0.05$)
$Rank_1$	0.0512
$Rank$	0.3237
$P(20)$	0.003921
$P(50)$	0.09658
$P(N_R)$	0.002519
$R_{P(0.5)}$	0.002972
$R(100)$	0.08836

Tabela 5.3: Avaliação da quantização na efetividade do descritor coesão baseada no teste de Friedman.

Critério de efetividade	256×128	256×64	256×32	128×64	128×32	64×32
$P(20)$	0.7991	0.08253	0.02267+	0.09027	0.01829+	0.03242
$P(N_R)$	0.1508	0.3199	0.05037	0.03864	0.002647+	0.1609
$R_{P(0.5)}$	0.5294	0.05964	0.00872+	0.09239	0.01285+	0.1813

Tabela 5.4: Valores de p dos testes *post hoc* entre as quantizações testadas. Valores em destaque(+) indicam testes para os quais persistem diferenças entre as quantizações testadas após o ajuste do valor de α pelo método de Holm.

5.4.2 Efeito da métrica utilizada na efetividade do descriptor coesão

A tabela 5.5 apresenta o resultado da análise da significância estatística na comparação entre a utilização de três métricas, L_1 , L_2 e L_∞ para avaliar a similaridade entre os descriptores. Os resultados do teste de Friedman mostram que existe diferença entre as métricas sendo comparadas. Através de testes post hoc adicionais (Wilcoxon com correção de α , tabela 5.6) entre as métricas e dos gráficos de precision-recall das figuras A.7 ,A.8 e A.9 (alguns casos são apresentados na figura 5.3), podemos perceber que a métrica L_1 tem um desempenho superior às métricas L_2 e L_∞ . A métrica L_2 também se mostrou superior à métrica L_∞ , cujos resultados se mostraram desfavoráveis para todos os descriptores considerados.

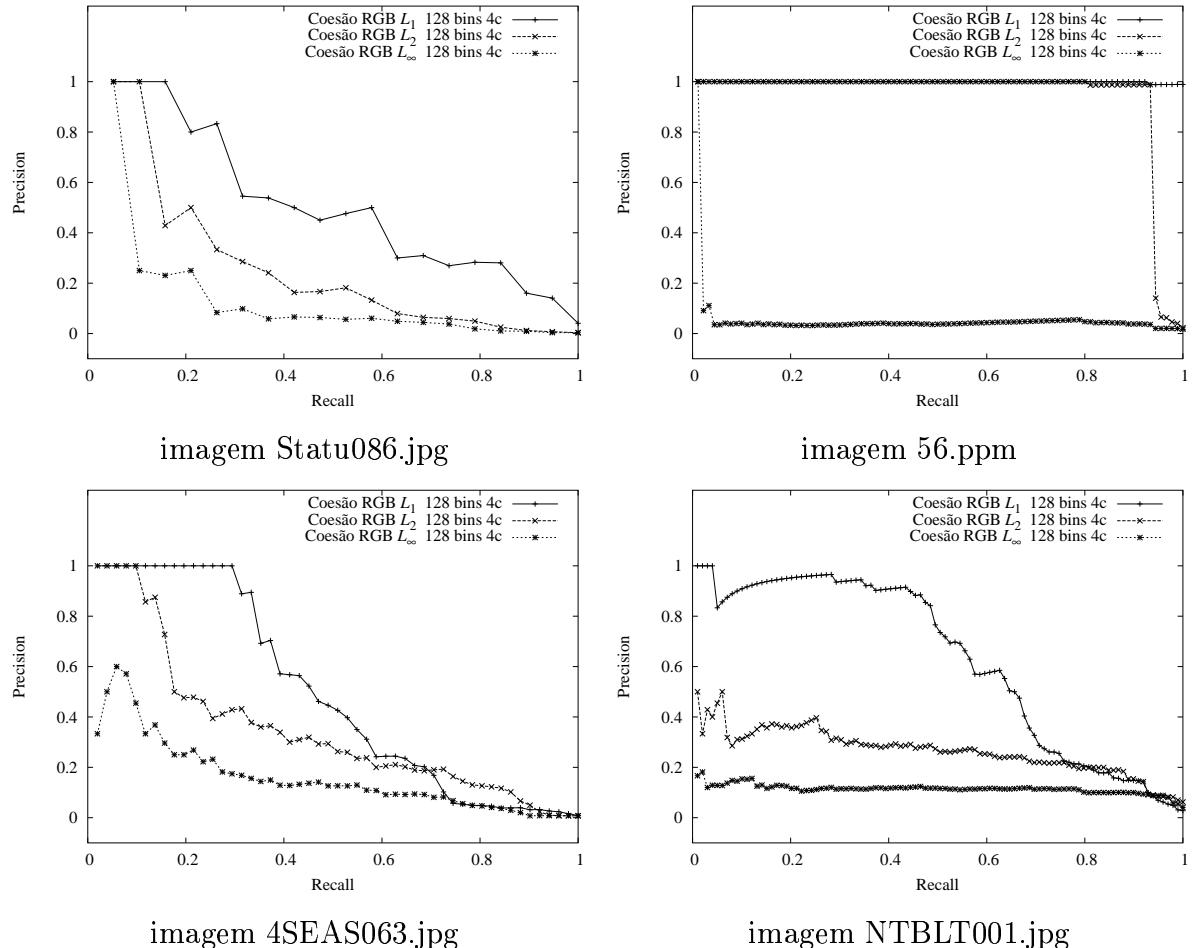


Figura 5.3: Seleção de gráficos de precision-recall para a avaliação da métrica utilizada.

Critério de efetividade	valor de p do teste de Friedman($\alpha = 0.05$)
$\bar{R}ank_1$	8.843e-05
$\bar{R}ank$	8.365e-05
$P(20)$	0.0003294
$P(50)$	1.82e-06
$P(N_R)$	7.532e-06
$R_{P(0.5)}$	0.0001430
$R(100)$	0.0002569

Tabela 5.5: Avaliação do efeito da função de similaridade na efetividade do descritor coesão.

Critério de efetividade	$L_1 \times L_2$	$L_1 \times L_\infty$	$L_2 \times L_\infty$
$\bar{R}ank_1$	0.03103	0.005603+	0.005857+
$\bar{R}ank$	0.001579+	0.0008392+	0.01823+
$P(20)$	0.02075+	0.005275+	0.04643
$P(50)$	0.02046+	0.0004699+	0.0006911+
$P(N_R)$	0.005355+	0.0007247+	0.002507+
$R_{P(0.5)}$	0.009152+	0.005889+	0.05906
$R(100)$	0.01002+	0.001470+	0.001367+

Tabela 5.6: Valores de p dos testes *post hoc* entre as métricas testadas. Valores em destaque(+) indicam testes para os quais persistem diferenças entre as métricas tratadas após o ajuste do valor de α pelo método de Holm.

5.4.3 Efeito da conexidade na efetividade do descritor coesão

A partir dos dados da tabela 5.7, podemos concluir que nenhum dos critérios de efetividade expressa uma diferença significativa entre a utilização de uma vizinhança 4 ou 8-conexa, quando da realização da segmentação das regiões homogêneas da imagem (seção 4.3.3). A vizinhança 4-conexa foi considerada aqui na implementação do descritor coesão.

As seções seguintes realizam algumas comparações entre os descritores abordados neste trabalho.

Critério de efetividade	valor de p do teste de Wilcoxon ($\alpha = 0.05$)
$Rank_1$	1.0
$Rank$	0.2559
$P(20)$	0.2463
$P(50)$	0.2016
$P(N_R)$	0.4469
$R_{P(0.5)}$	0.1775
$R(100)$	0.4412

Tabela 5.7: Avaliação do efeito da conexidade na efetividade do descritor coesão.

5.4.4 Comparação entre coesão, histograma e vetor de coerência de cores

Com base nos resultados do teste de Friedman, na tabela 5.8, observamos que existem diferenças entre os modelos de descritores comparados. Utilizando-se os resultados dos testes *post hoc* na tabela 5.9, em conjunto com os gráficos de precision-recall das consultas apresentados nas figuras A.1, A.2 e A.3 do apêndice A (alguns casos são ilustrados na figura 5.4), podemos observar que o descritor coesão teve um desempenho melhor, especialmente em relação ao vetor de coerência de cores. Comentários análogos aos considerados na seção 5.4.1 sobre o resultado dos testes podem ser feitos em relação aos resultados da tabela 5.9.

Os valores de cada um dos critérios de efetividade para as imagens de consulta encontram-se no apêndice B, e os respectivos gráficos de precision-recall, no apêndice A.

É importante lembrar que, de acordo com as análises anteriores, estes resultados foram obtidos considerando-se a métrica de similaridade L_1 , a vizinhança 4-conexa entre os pixels e 128 bins de quantização. A utilização da métrica L_1 e da quantização de 128 bins também apresentou os melhores resultados com os histogramas e com os vetores de coerência de cores.

5.4.5 Comparação entre coesão, histograma e vetor de coerência de cores utilizando o cubo RGB

De acordo com os testes de Friedman apresentados na tabela 5.10 uma diferença significativa entre os descritores foi detectada apenas no caso do critério $Rank_1$. A tabela 5.11 indica que esta diferença se apresenta entre os descritores coesão e histograma e apartir dos gráficos de precision-recall das figuras A.13, A.14 e A.15 do apêndice A (alguns

Critério de efetividade	valor de p do teste de Friedman($\alpha = 0.05$)
$Rank_1$	0.02971
$Rank$	0.008525
$P(20)$	0.003388
$P(50)$	0.01312
$P(N_R)$	7.532e-06
$R_{P(0.5)}$	0.02387
$R(100)$	0.007652

Tabela 5.8: Resultado do teste de Friedman para a comparação entre os descritores coesão, histograma e vetor de coerência de cores.

Critério de efetividade	coesão × histograma	coesão × vcc	histograma × vcc
$Rank_1$	0.02086+	0.02086+	0.8655
$Rank$	0.1183	0.07986	0.01058+
$P(20)$	0.02541	0.01418+	0.2476
$P(50)$	0.02178+	0.01531+	0.1148
$P(N_R)$	0.001884+	0.001949+	0.674
$R_{P(0.5)}$	0.02427+	0.06655	1
$R(100)$	0.03294	0.001868+	0.1455

Tabela 5.9: Valores de p dos testes *post hoc* entre coesão, histograma e vetor de coerência de cores(vcc). Valores em destaque(+) indicam testes para os quais persistem diferenças entre as métricas tratadas após o ajuste do valor de α pelo método de Holm.

Critério de efetividade	valor de p do teste de Friedman($\alpha = 0.05$)
$Rank_1$	0.02089
$Rank$	0.4655
$P(20)$	0.5292
$P(50)$	0.7548
$P(N_R)$	0.7408
$R_{P(0.5)}$	0.1188
$R(100)$	0.7338

Tabela 5.10: Resultado do teste de Friedman para a comparação entre os descritores coesão, histograma e vetor de coerência de cores.

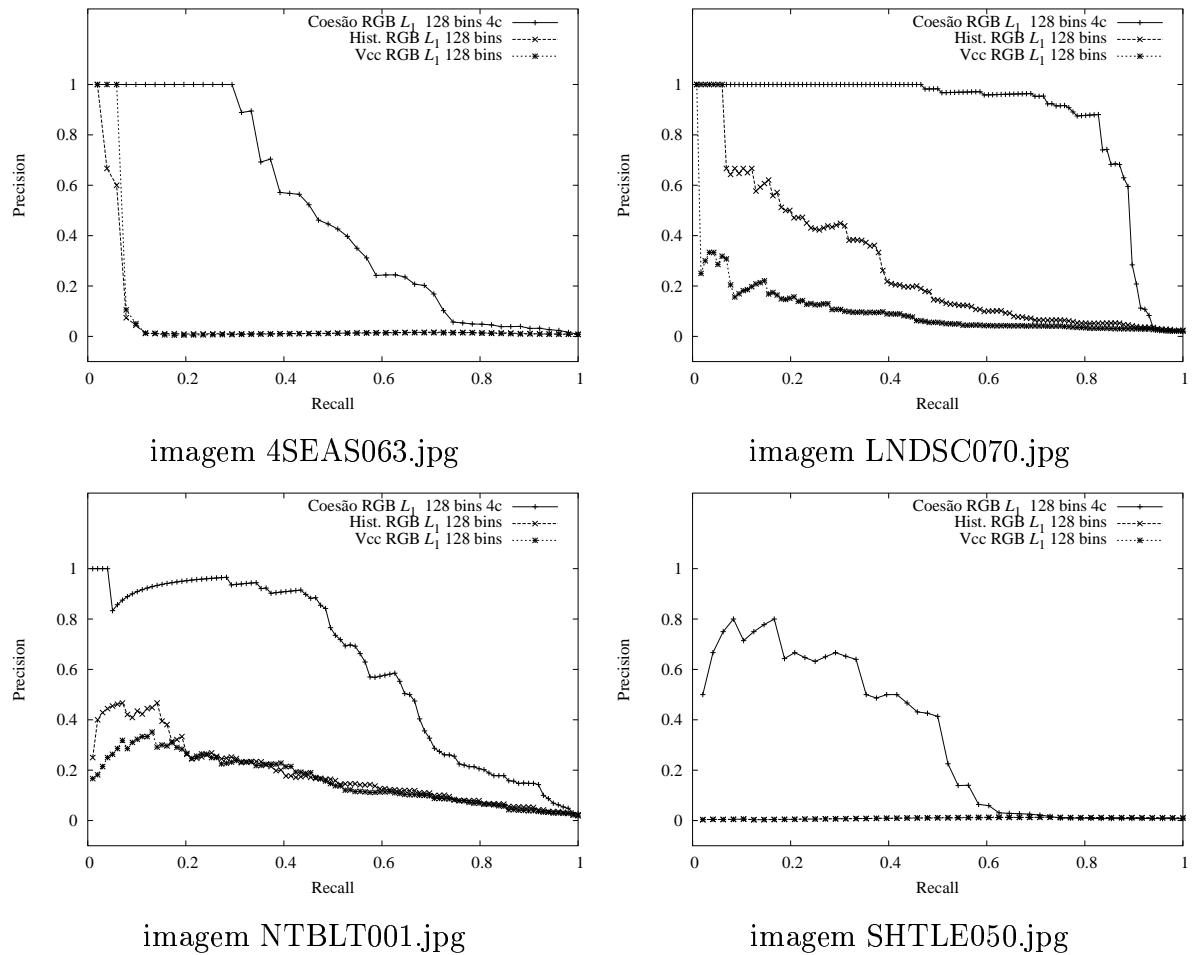


Figura 5.4: Seleção de alguns dos gráficos de precision-recall comparando os modelos coesão, histograma e vetor de coerência de cores.

casos são ilustrados na figura 5.5), podemos ver que o modelo coesão apresenta melhor desempenho.

Todos os modelos tiveram uma diminuição da efetividade em relação ao caso de utilização das três componentes em separado, como discutido a seguir e observado nas tabelas do apêndice B.

Critério de efetividade	coesão × histograma	coesão × vcc	histograma × vcc
$Rank_1$	0.03209+	0.4069	0.3433

Tabela 5.11: Valor de p do teste *post hoc* entre coesão, histograma e vetor de coerência de cores(vcc). O valor em destaque(+) indica o teste para o qual persiste diferença entre os descritores após o ajuste do valor de α pelo método de Holm.

5.4.6 Comparação entre a utilização das três componentes separadamente e do cubo RGB

A utilização das três componentes do espaço de cores RGB, separadamente, é realizada através da criação de um mesmo descritor para cada uma delas. A comparação de similaridade é realizada, individualmente, considerando-se como resultado geral a média destas similaridades.

No caso do cubo RGB, em que se consideram as três componentes simultaneamente, é criado um único descritor.

Este experimento mostra que a opção de utilização de um descritor coesão para cada uma das componentes RGB apresenta um resultado superior em relação a um descritor único. Isto pode ser constatado a partir dos gráficos de precision-recall nas figuras A.16, A.17, A.18 no apêndice A (alguns casos apresentados na figura 5.6), e do resultado do teste apresentado na tabela 5.12.

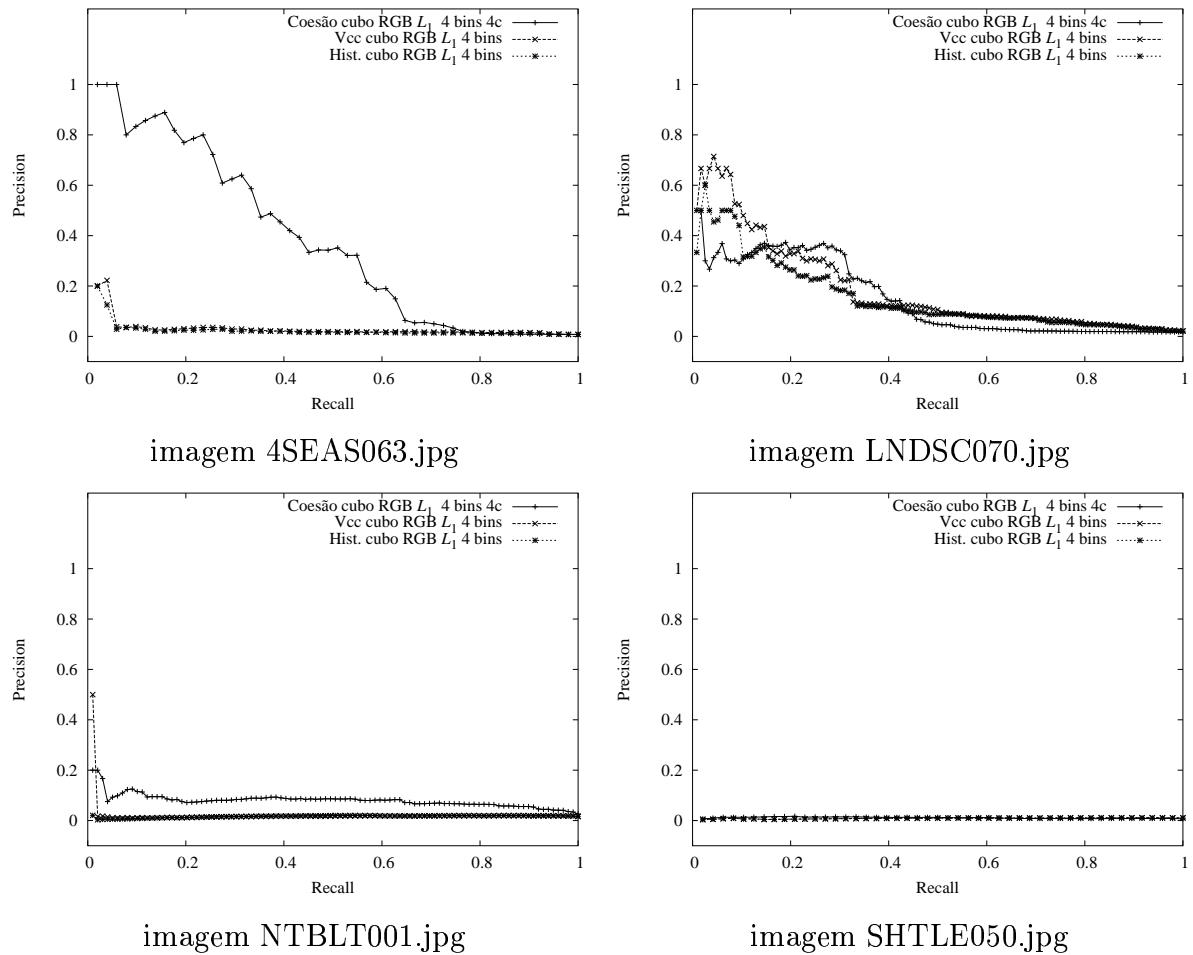


Figura 5.5: Seleção de alguns dos gráficos de precision-recall comparando os modelos coesão, histograma e vetor de coerência de cores utilizando o cubo RGB.

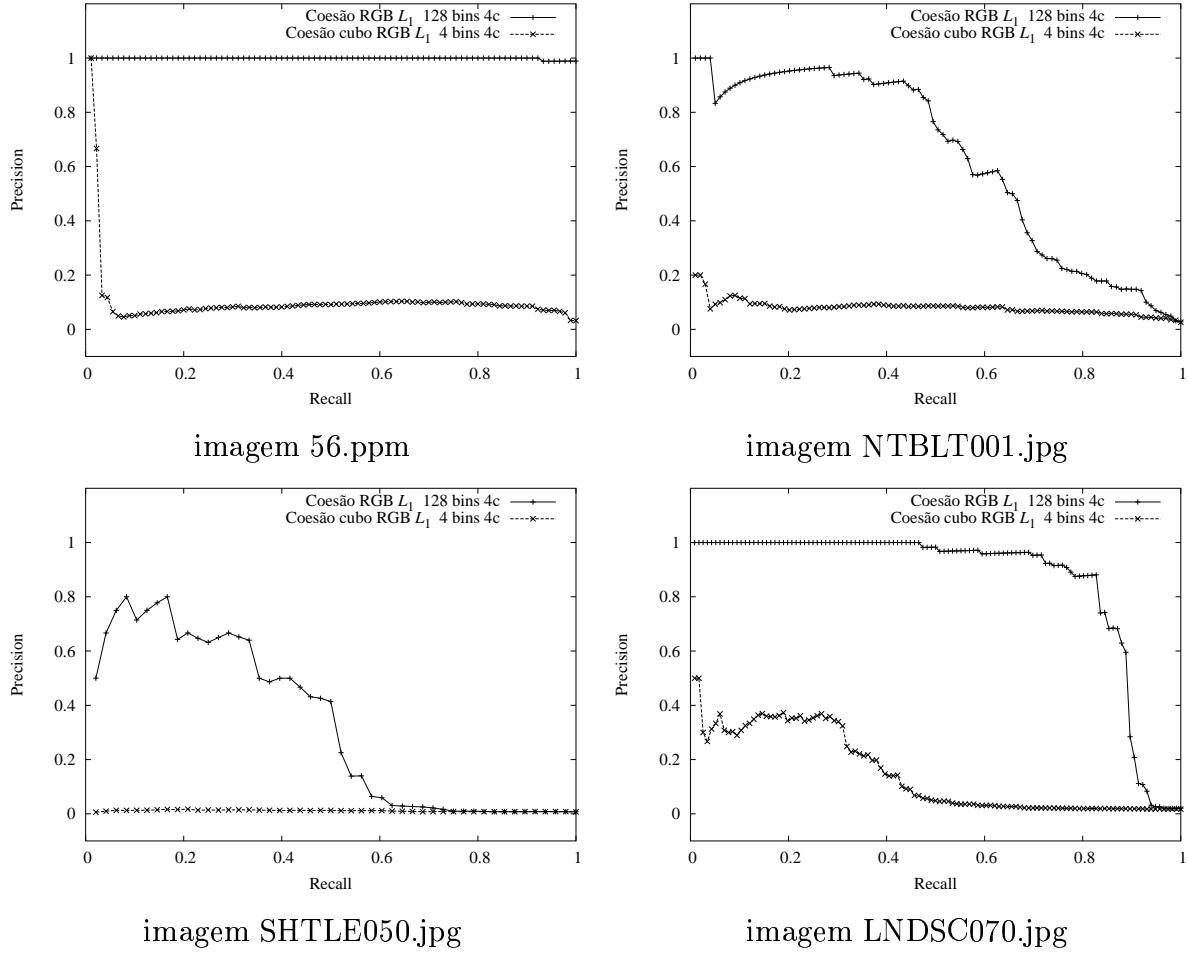


Figura 5.6: Seleção de gráficos de precision-recall entre coesão utilizando três componentes e Coesão utilizando o cubo RGB.

Critério de efetividade	valor de p do teste de Wilcoxon($\alpha = 0.05$)
$Rank_1$	0.009298
\widetilde{Rank}	0.01211
$P(20)$	0.006822
$P(50)$	0.003431
$P(N_R)$	0.001094
$R_{P(0.5)}$	0.003857
$R(100)$	0.01568

Tabela 5.12: Comparaçāo entre coesāo utilizando trēs componentes e coesāo utilizando cubo RGB.

Capítulo 6

Conclusões e Extensões

Resumidamente, os principais objetivos desta dissertação foram:

- O estudo de representações da informação cromática das imagens no âmbito da área de recuperação de imagens por conteúdo.
- A criação de um novo modelo de representação para esse tipo de informação que combinasse a informação espacial à informação cromática.
- A aplicação correta de testes de significância estatística para a validação dos resultados obtidos na área de recuperação de imagens por conteúdo.

Consideramos, numa primeira etapa, um estudo sobre formas de representação, revisando diversas abordagens existentes para a representação da informação cromática de imagens, com ou sem informação espacial associada.

Em seguida, propusemos um modelo para recuperação de imagens por conteúdo que combina a informação cromática com a informação espacial e que possui algumas propriedades interessantes tais como invariância à rotação e translação dos elementos presentes nas imagens.

Um conjunto de imagens para a realização de teste foi considerado, seguido da definição de uma série de imagens de consulta e conjuntos de imagens relevantes para cada imagem em questão, trabalho este bastante demorado que exigiu, para cada uma das imagens de consulta, a análise manual de toda a base de dados contendo cerca de sete mil imagens. Simultaneamente, foram consideradas formas efetivas de se avaliar a efetividade de modelos de recuperação por conteúdo cujas consultas têm como resultado uma ordenação total do banco de imagens. Esta avaliação baseou-se em testes de significância estatísticos aplicados visando-se um maior aproveitamento das informações obtidas pelos diferentes critérios de avaliação. Os apêndices desta dissertação contêm gráficos e tabelas referentes aos valores de efetividade utilizados nesta avaliação.

Na realização dos experimentos foram considerados, na efetividade das respostas às consultas, os efeitos dos parâmetros de similaridade, quantização e conexidade a serem escolhidos quando da criação e utilização do descritor proposto. A partir dos parâmetros escolhidos foram realizados testes em que o modelo proposto é comparado com métodos baseados em histograma e vetor de coerência de cores. Os experimentos mostraram que o modelo proposto tem bons resultados para vários dos critérios de efetividade considerados e a opção de se utilizar as componentes do espaço de cores separadamente possui vantagens tanto do ponto de vista da efetividade das consultas quanto da utilização do espaço físico de representação das imagens.

6.1 Extensões

Além da área média empregada na representação das regiões homogêneas das imagens, outros atributos (compacidade, entropia, número de Euler etc) podem ser utilizados e combinados adequadamente, visando a extração de suas características espaciais e/ou topológicas. Da mesma forma, outras medidas estatísticas, tais como mediana, moda, máximo, mínimo, podem ser empregadas na representação da distribuição destes diferentes atributos. Finalmente, o emprego de técnicas mais eficientes de segmentação, na fase que antecede a extração de características, é um aspecto que deve contribuir, naturalmente, para um melhor desempenho do descritor abordado neste trabalho.

Outra possível extensão refere-se à introdução dos testes de significância aqui considerados na avaliação de sistemas de recuperação de imagens por conteúdo que englobam múltiplos descritores na sua definição [dVC02].

Apêndice A

Gráficos de precision-recall das consultas

A.1 Espaço de cores RGB com os componentes considerados separadamente

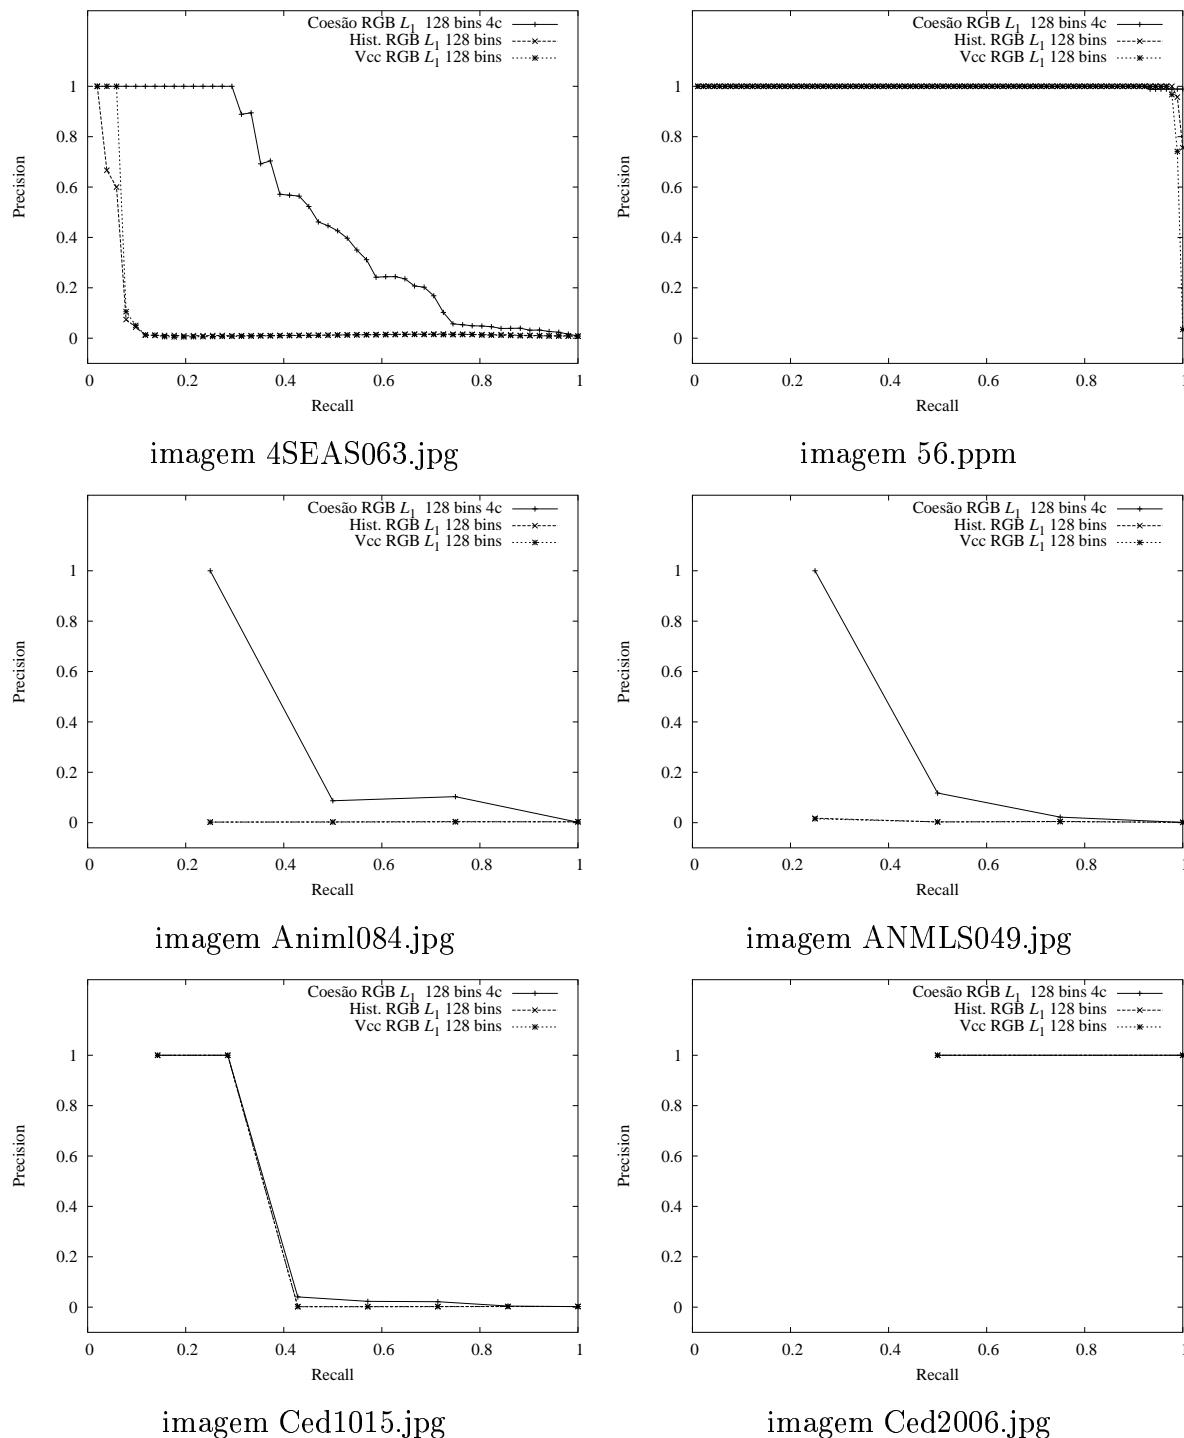


Figura A.1: Gráficos de precision e recall comparando os modelos coesão, histograma e vetor de coerência de cores(vcc).

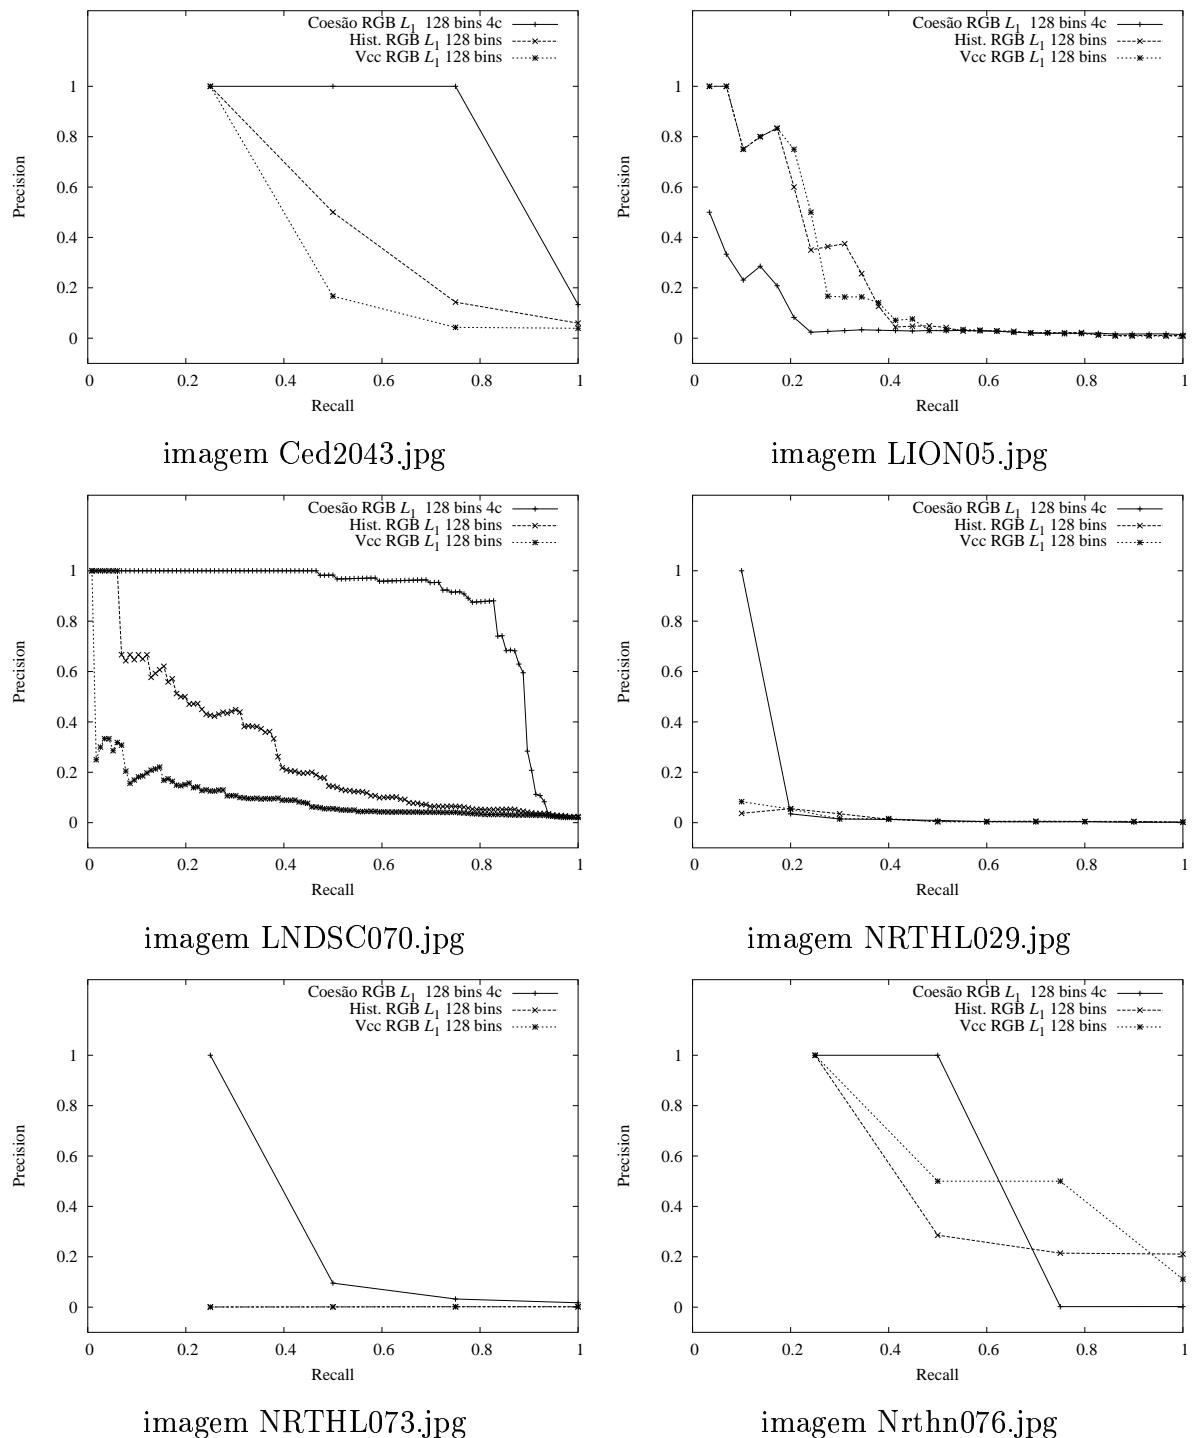


Figura A.2: Gráficos de precision e recall comparando os modelos coesão, histograma e vetor de coerência de cores(vcc).

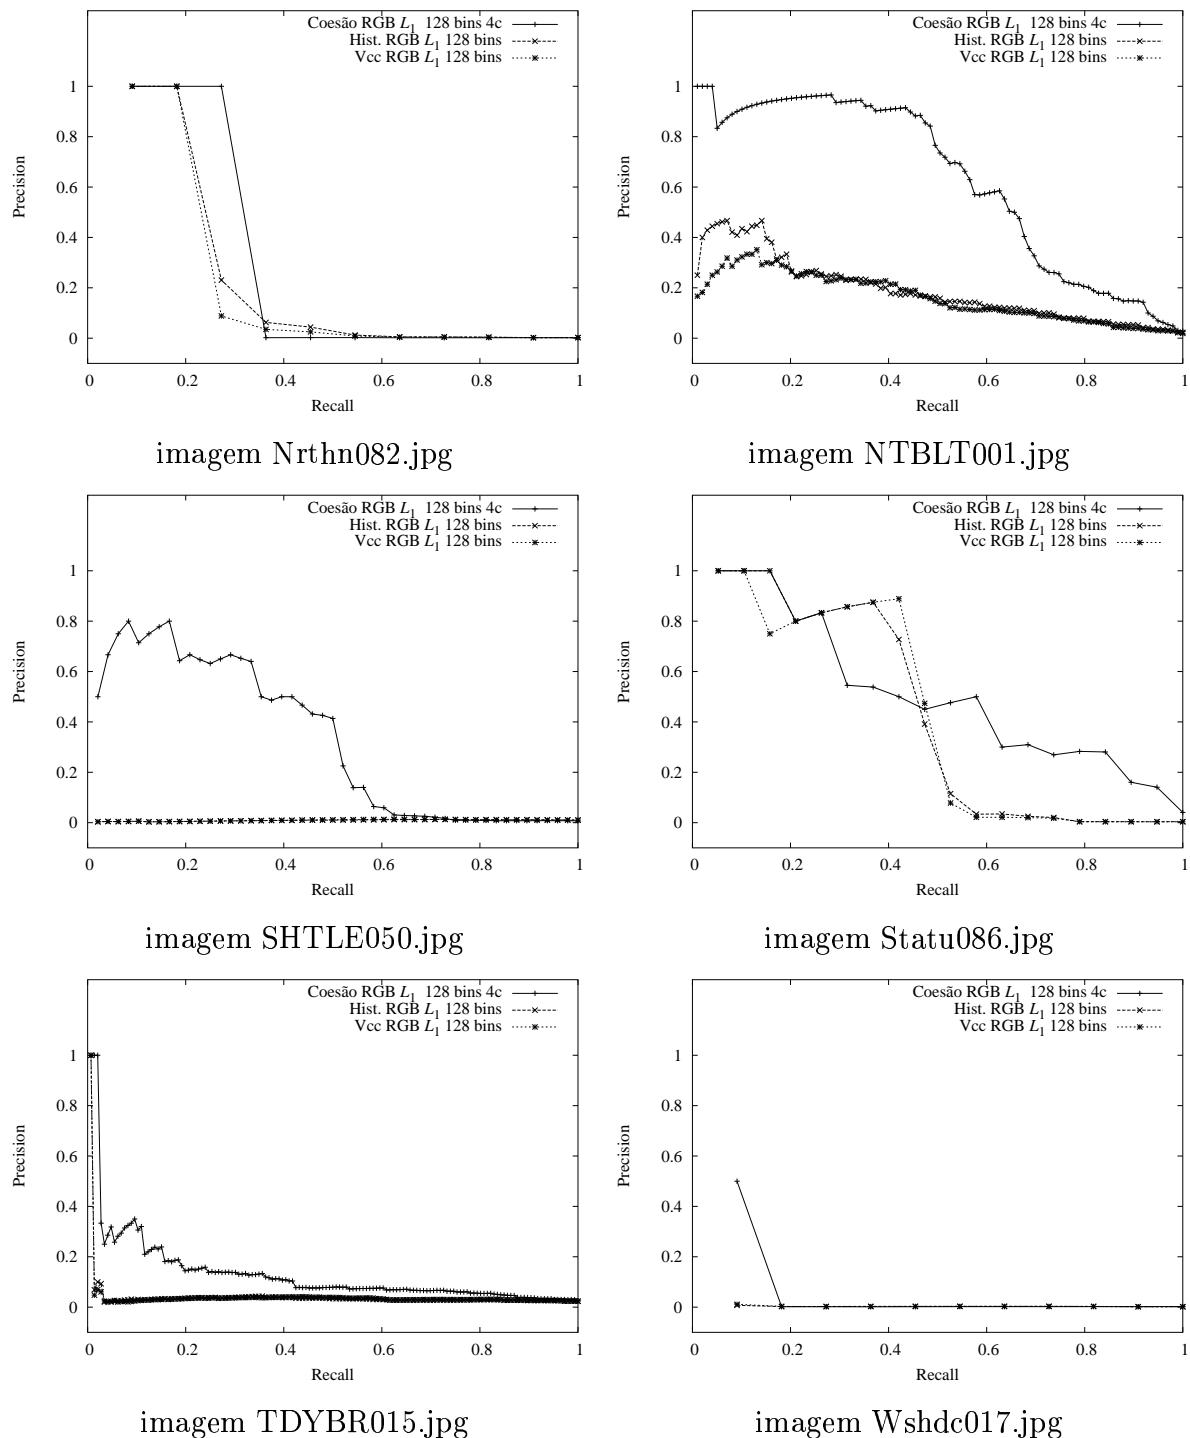


Figura A.3: Gráficos de precision e recall comparando os modelos coesão, histograma e vetor de coerência de cores(vcc).

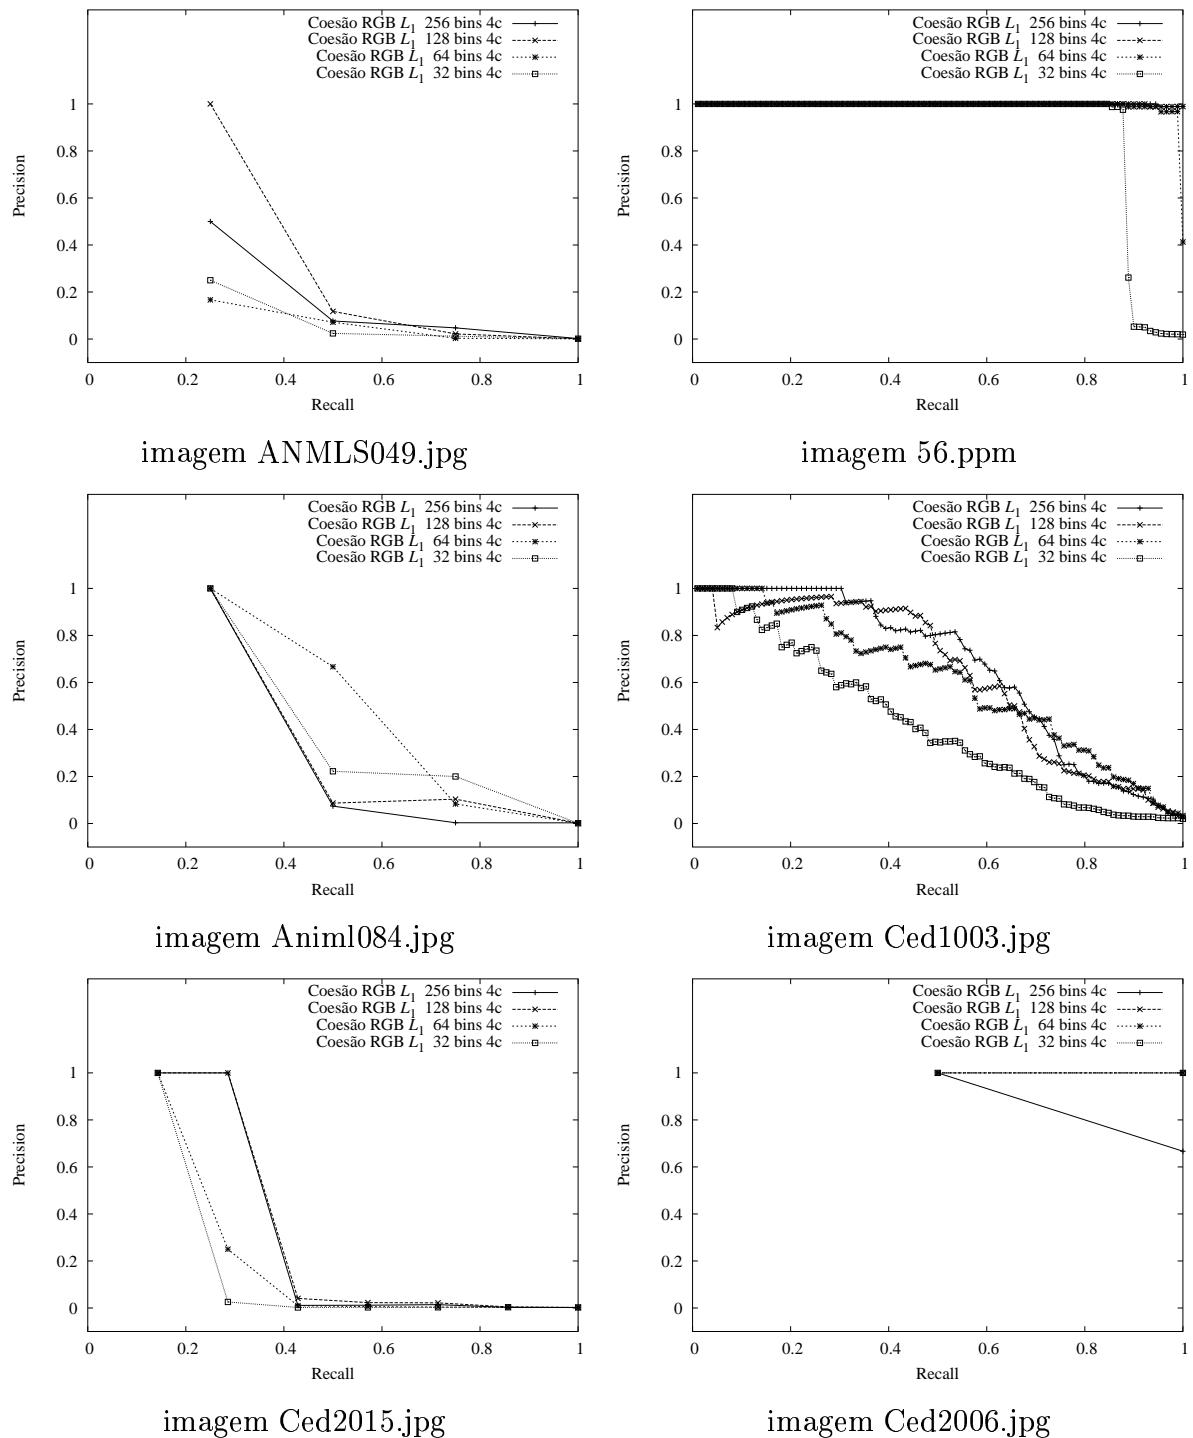


Figura A.4: Gráficos de precision e recall para teste de quantização.

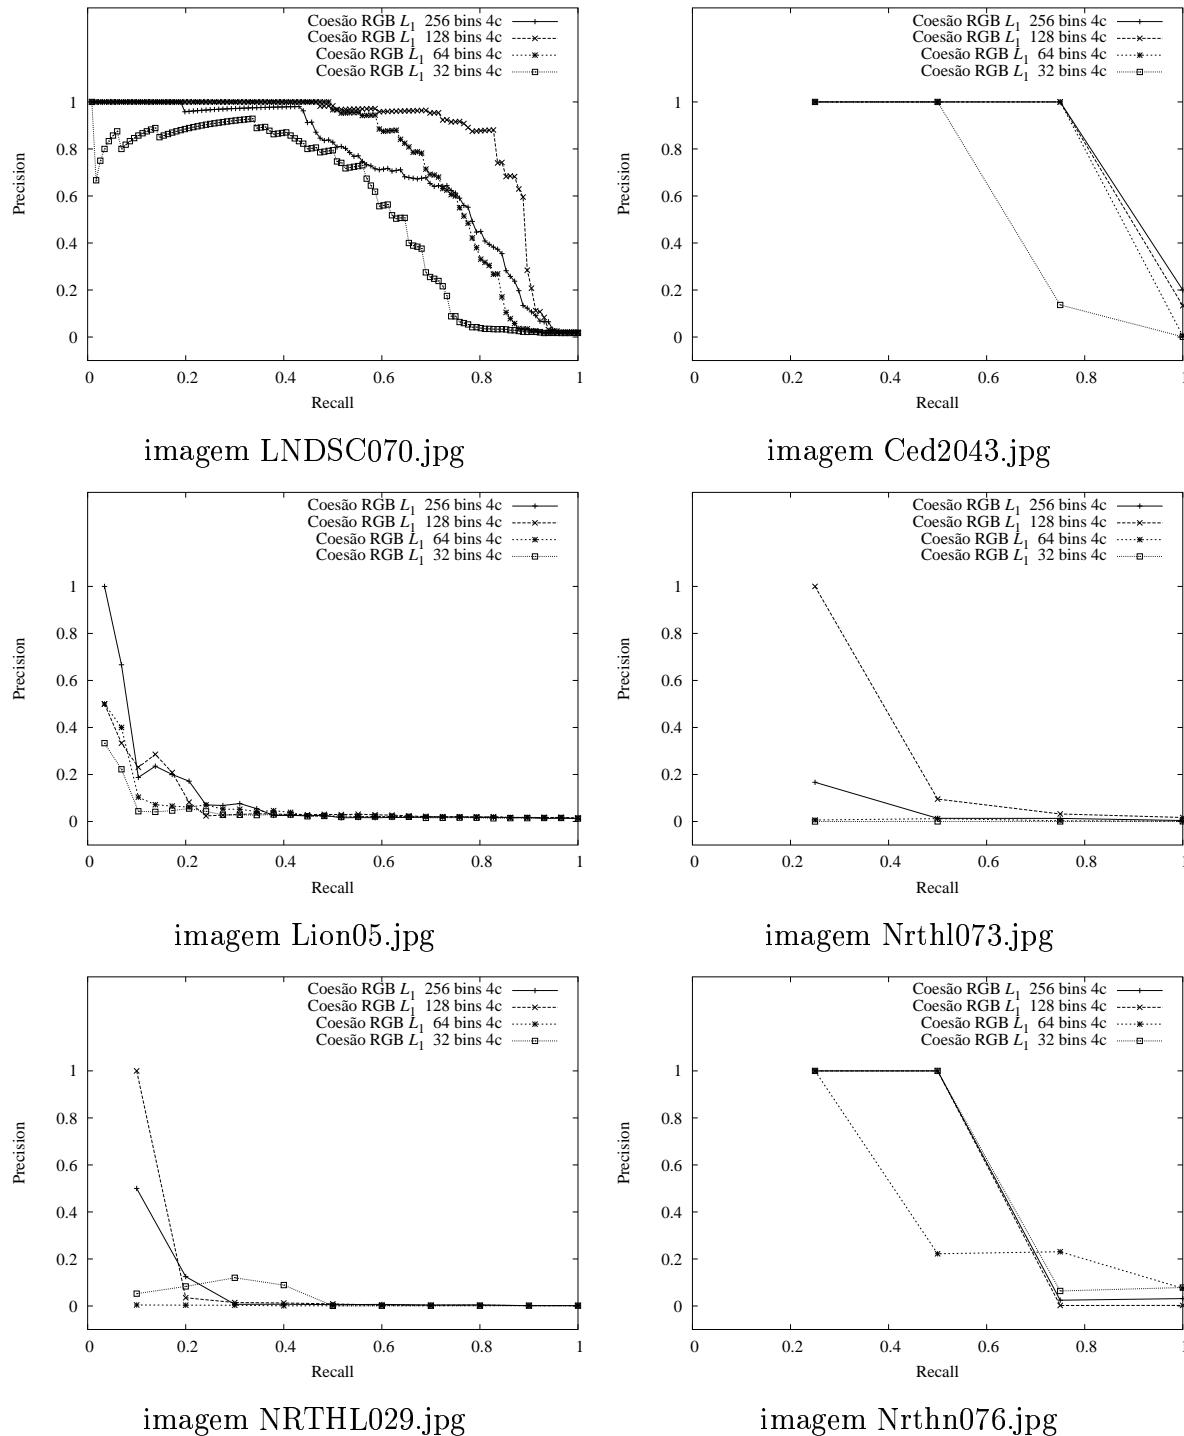


Figura A.5: Gráficos de precision e recall para teste de quantização.

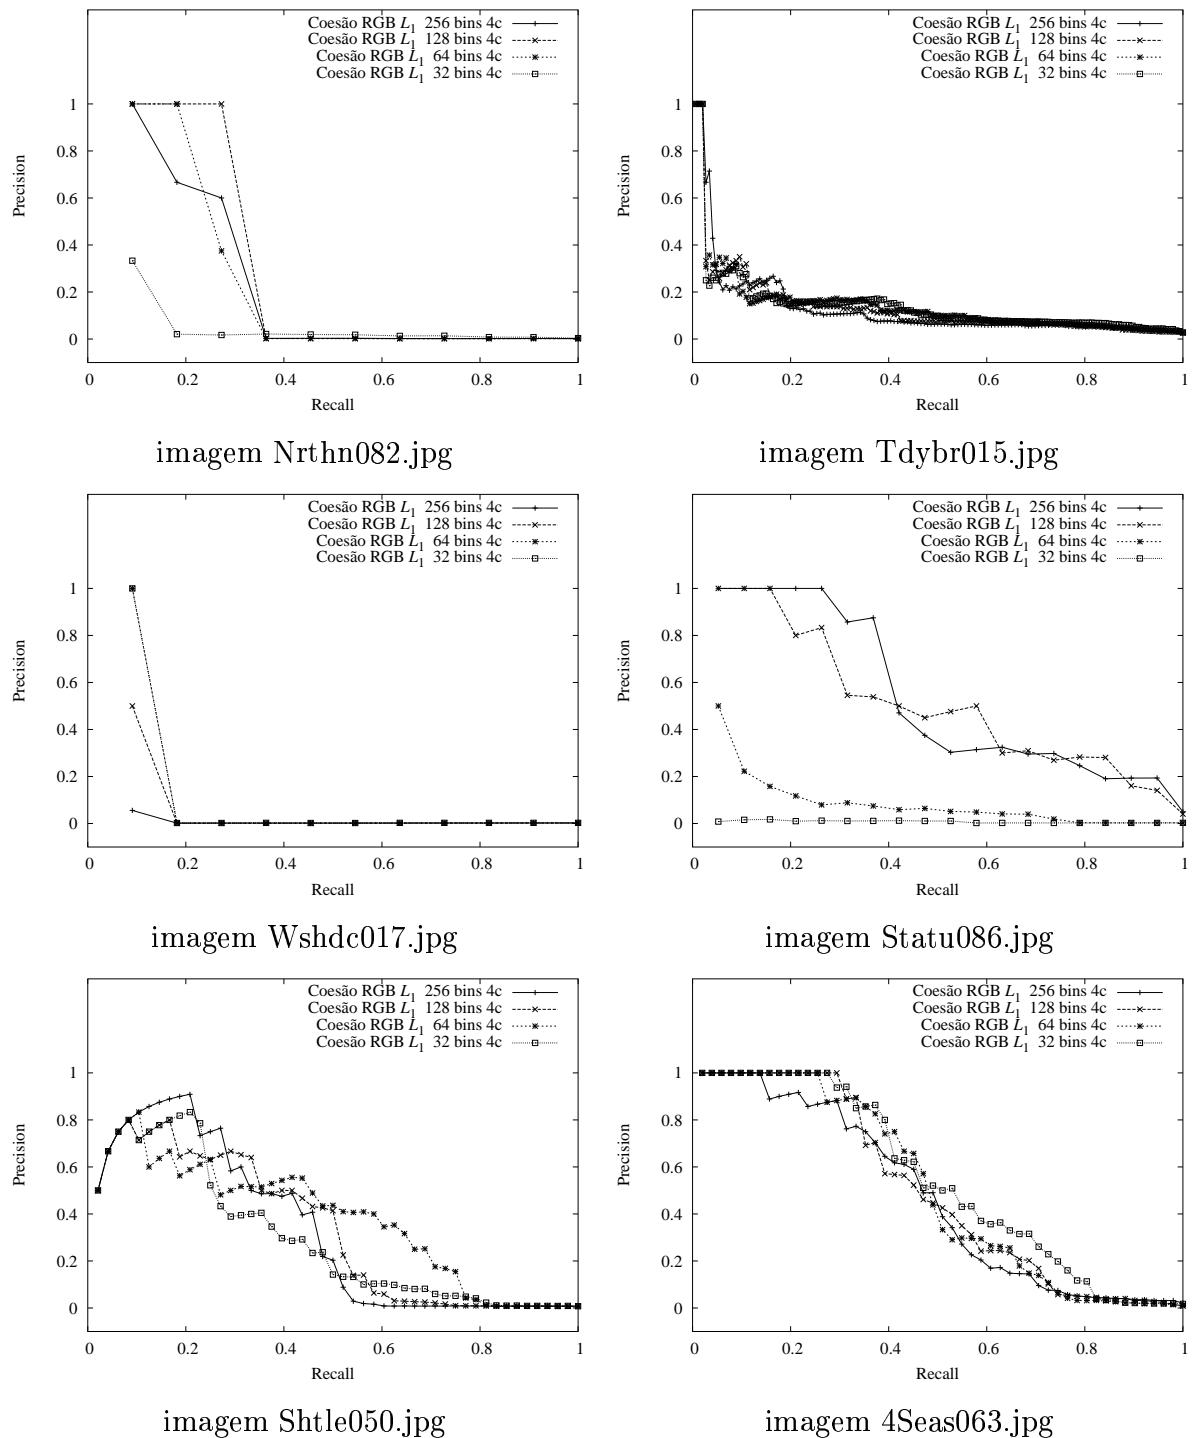


Figura A.6: Gráficos de precision e recall para teste de quantização.

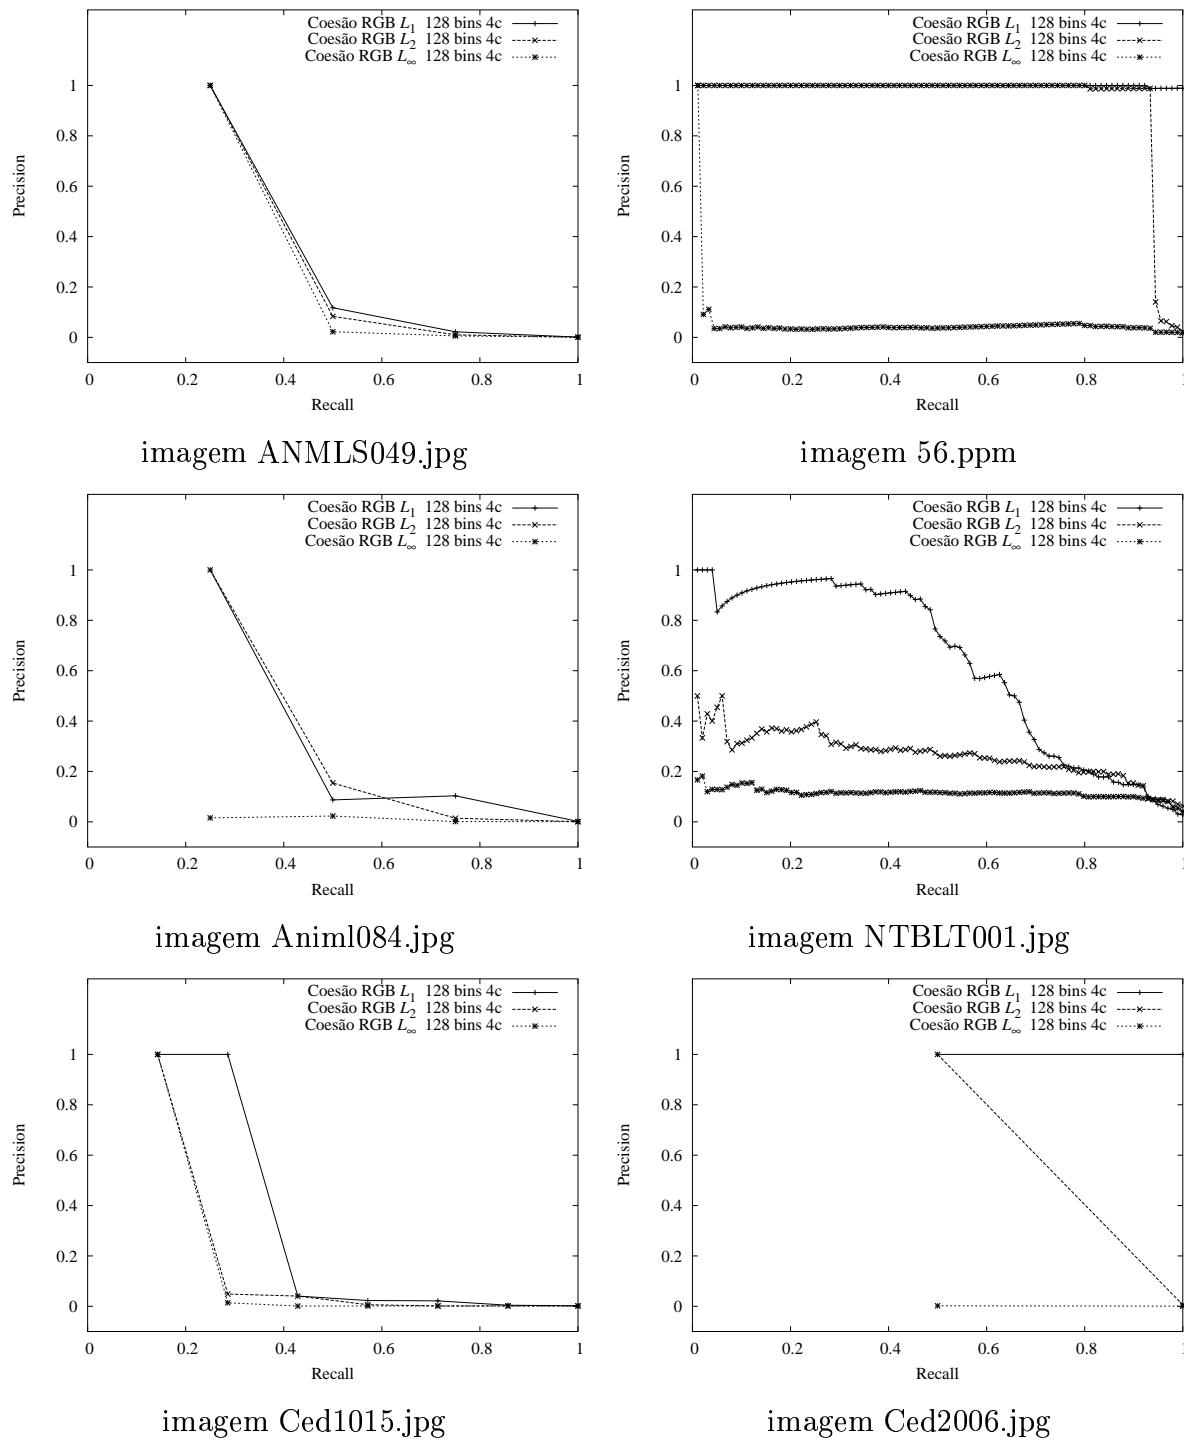


Figura A.7: Gráficos de precision e recall para a avaliação da métrica utilizada.

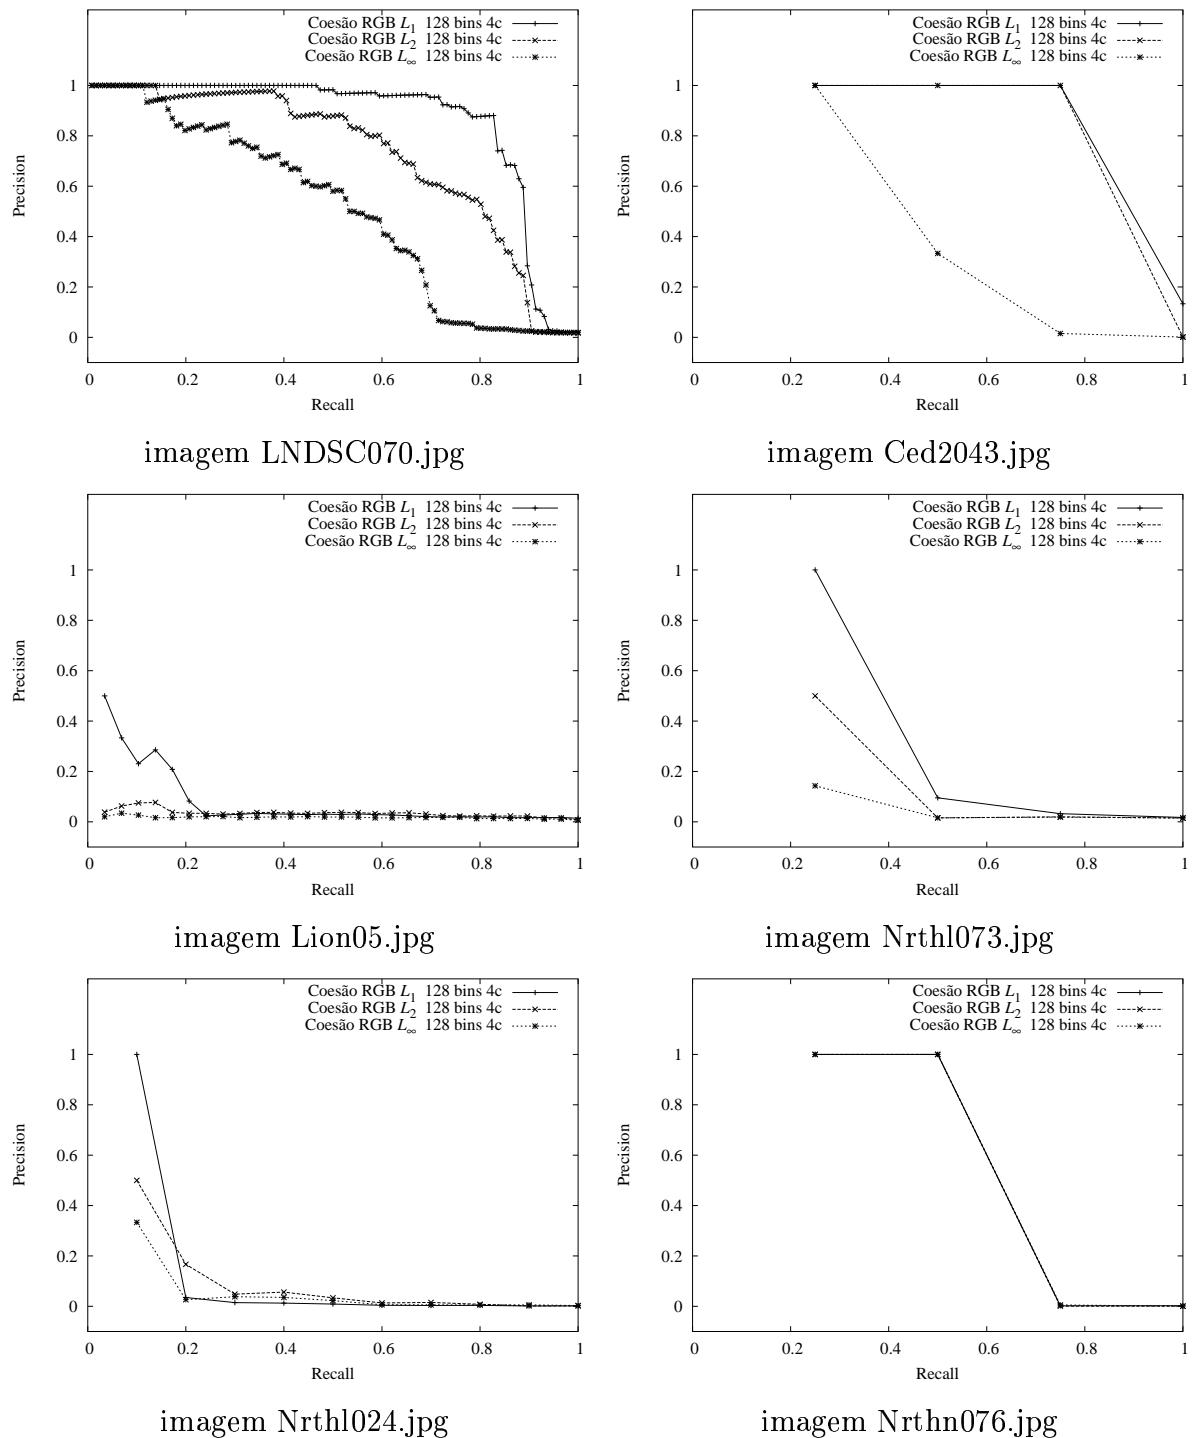


Figura A.8: Gráficos de precision e recall para a avaliação da métrica utilizada.

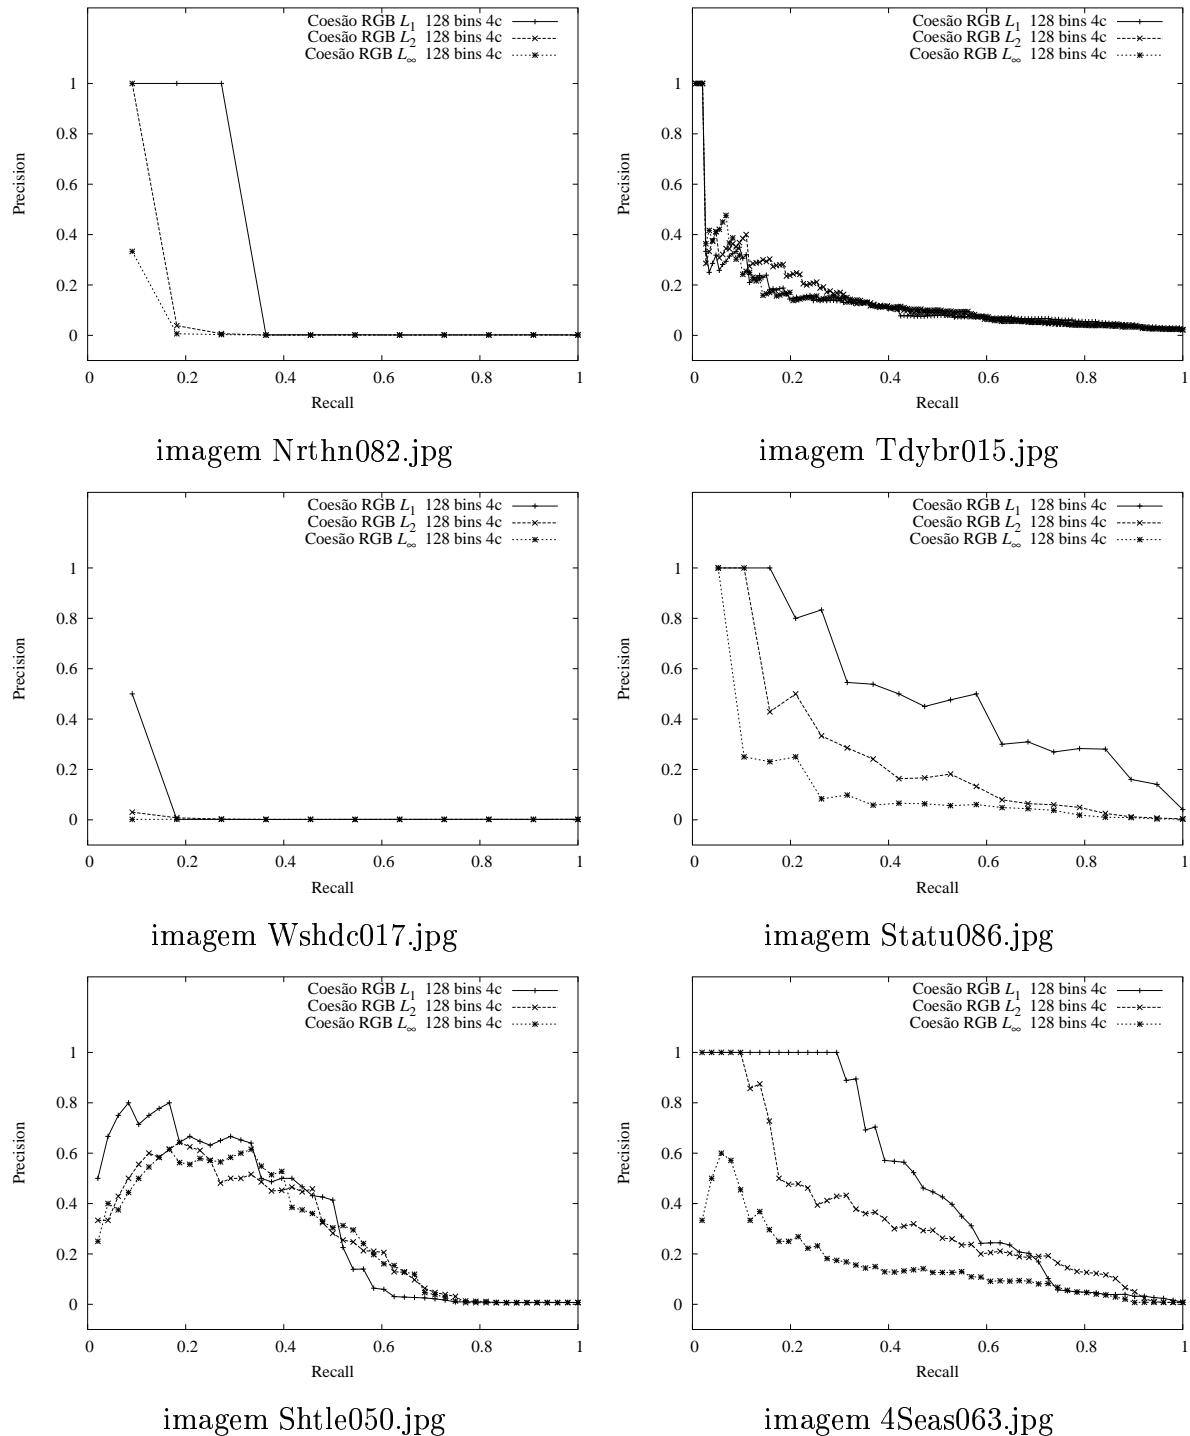


Figura A.9: Gráficos de precision e recall para a avaliação da métrica utilizada.

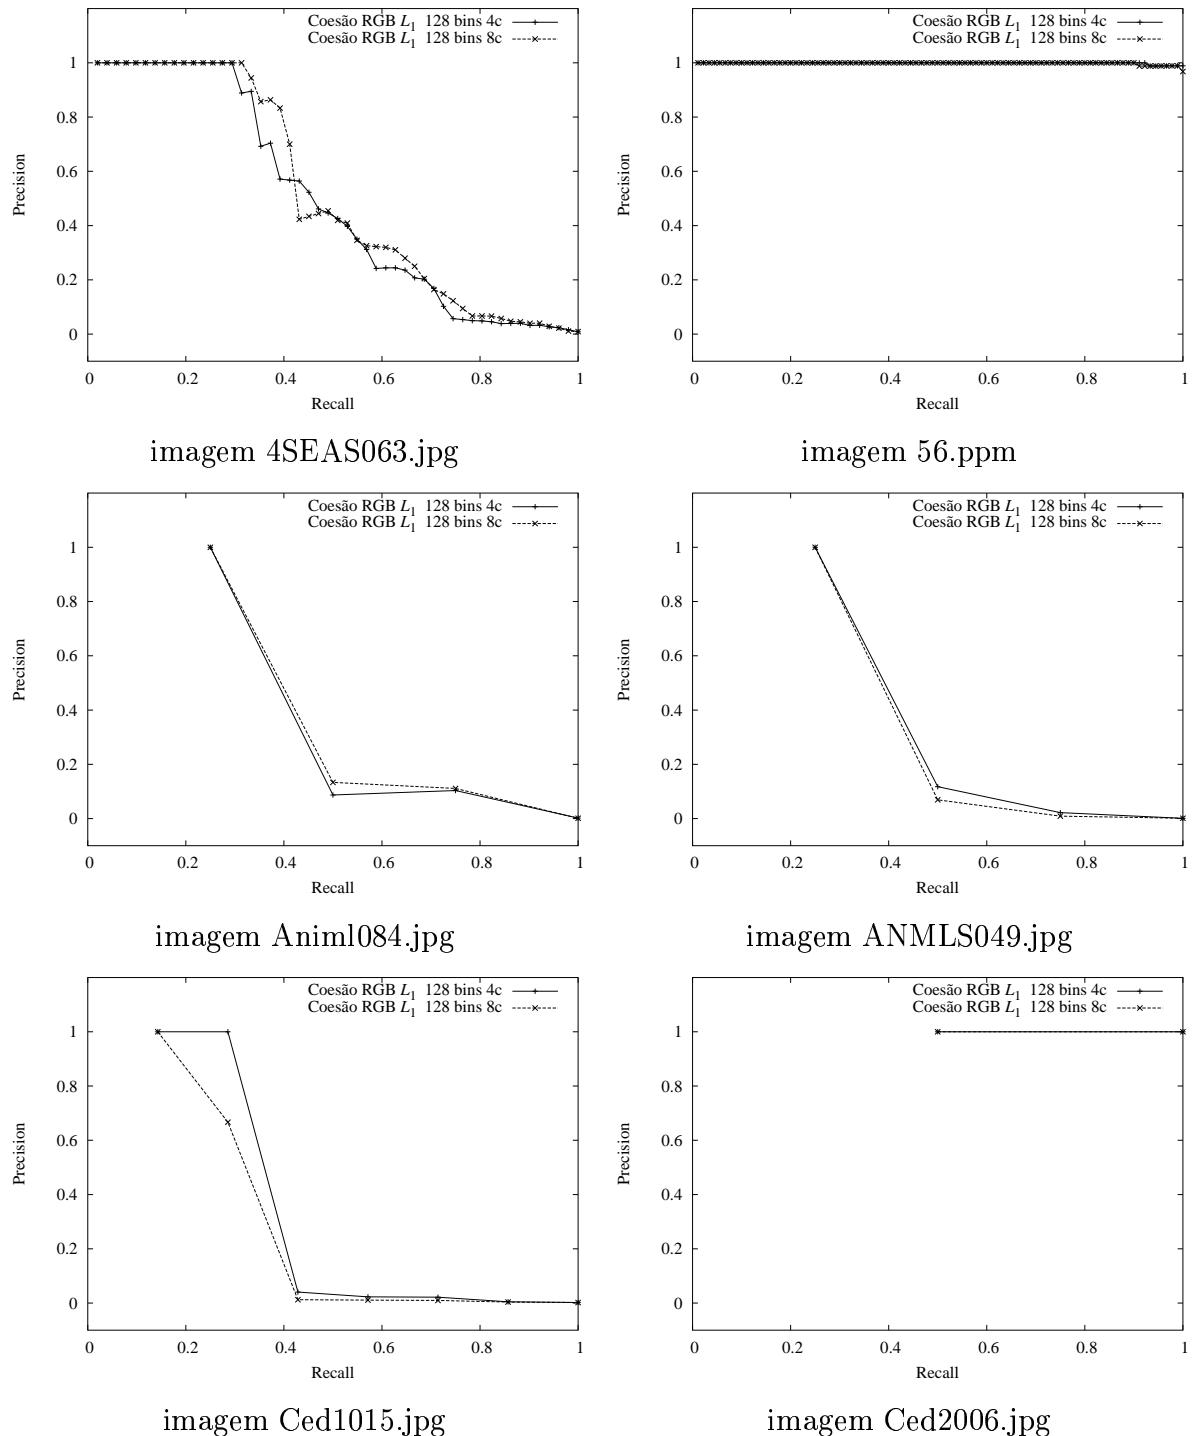


Figura A.10: Gráficos de precision e recall da comparação entre o uso de conexidade 4 e 8.

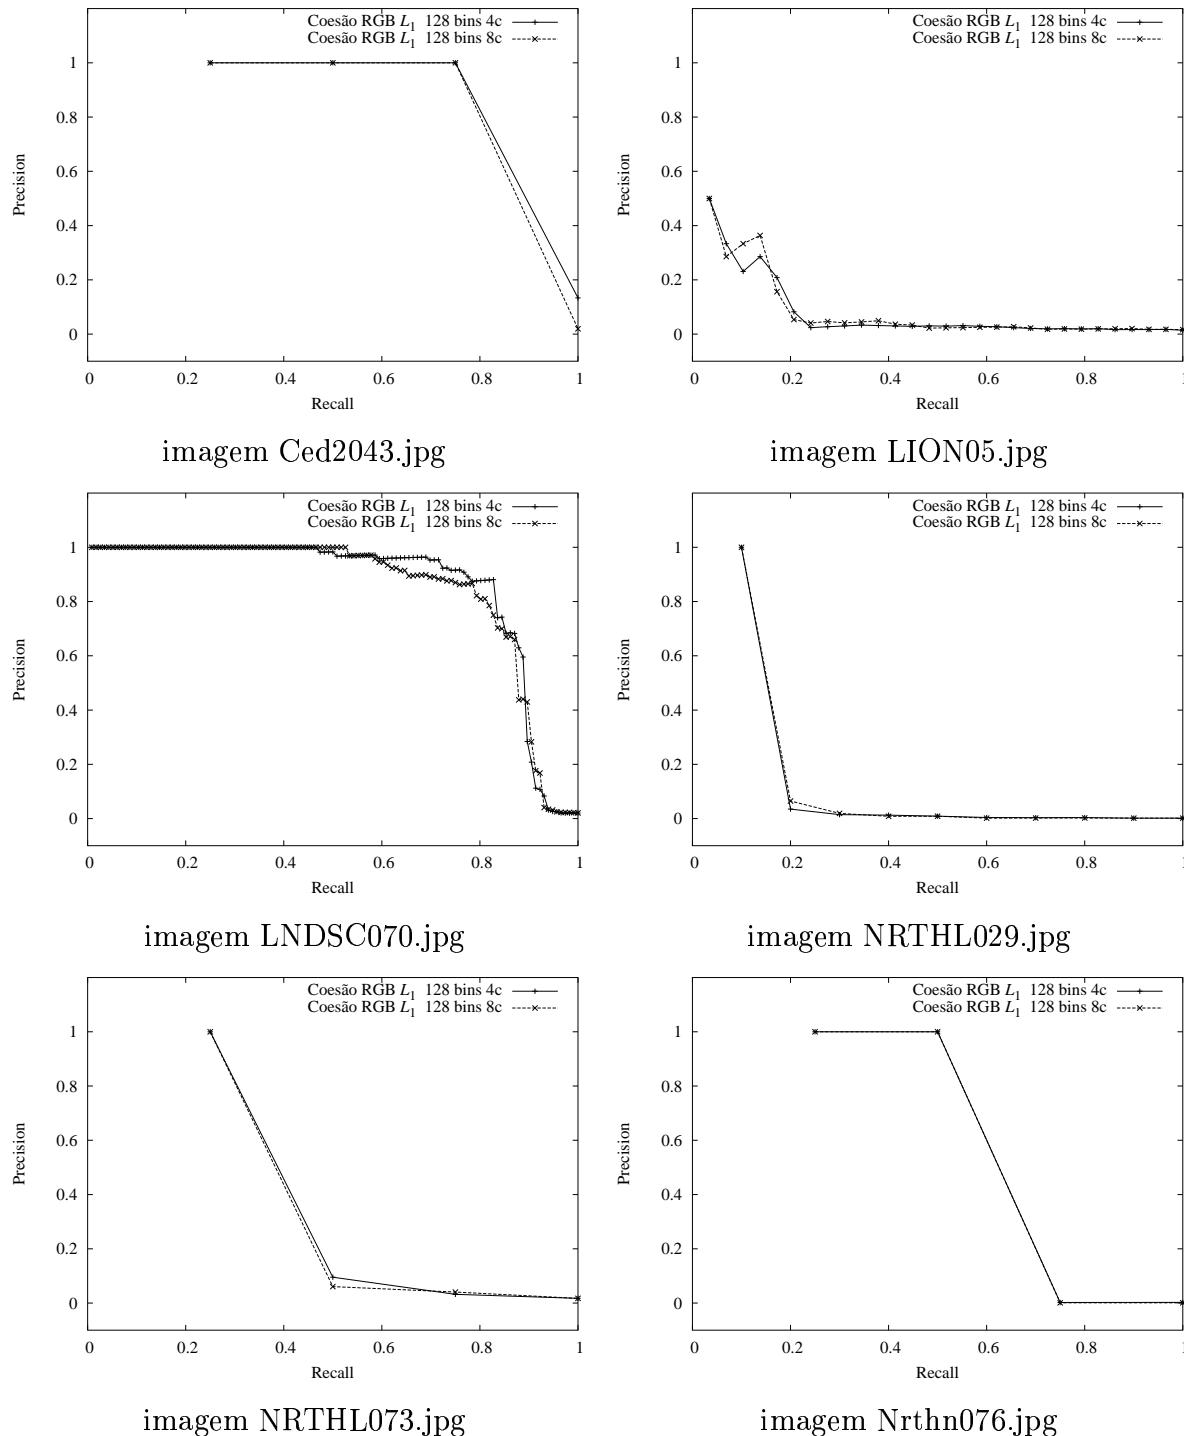


Figura A.11: Gráficos de precision e recall da comparação entre o uso de conexidade 4 e 8.

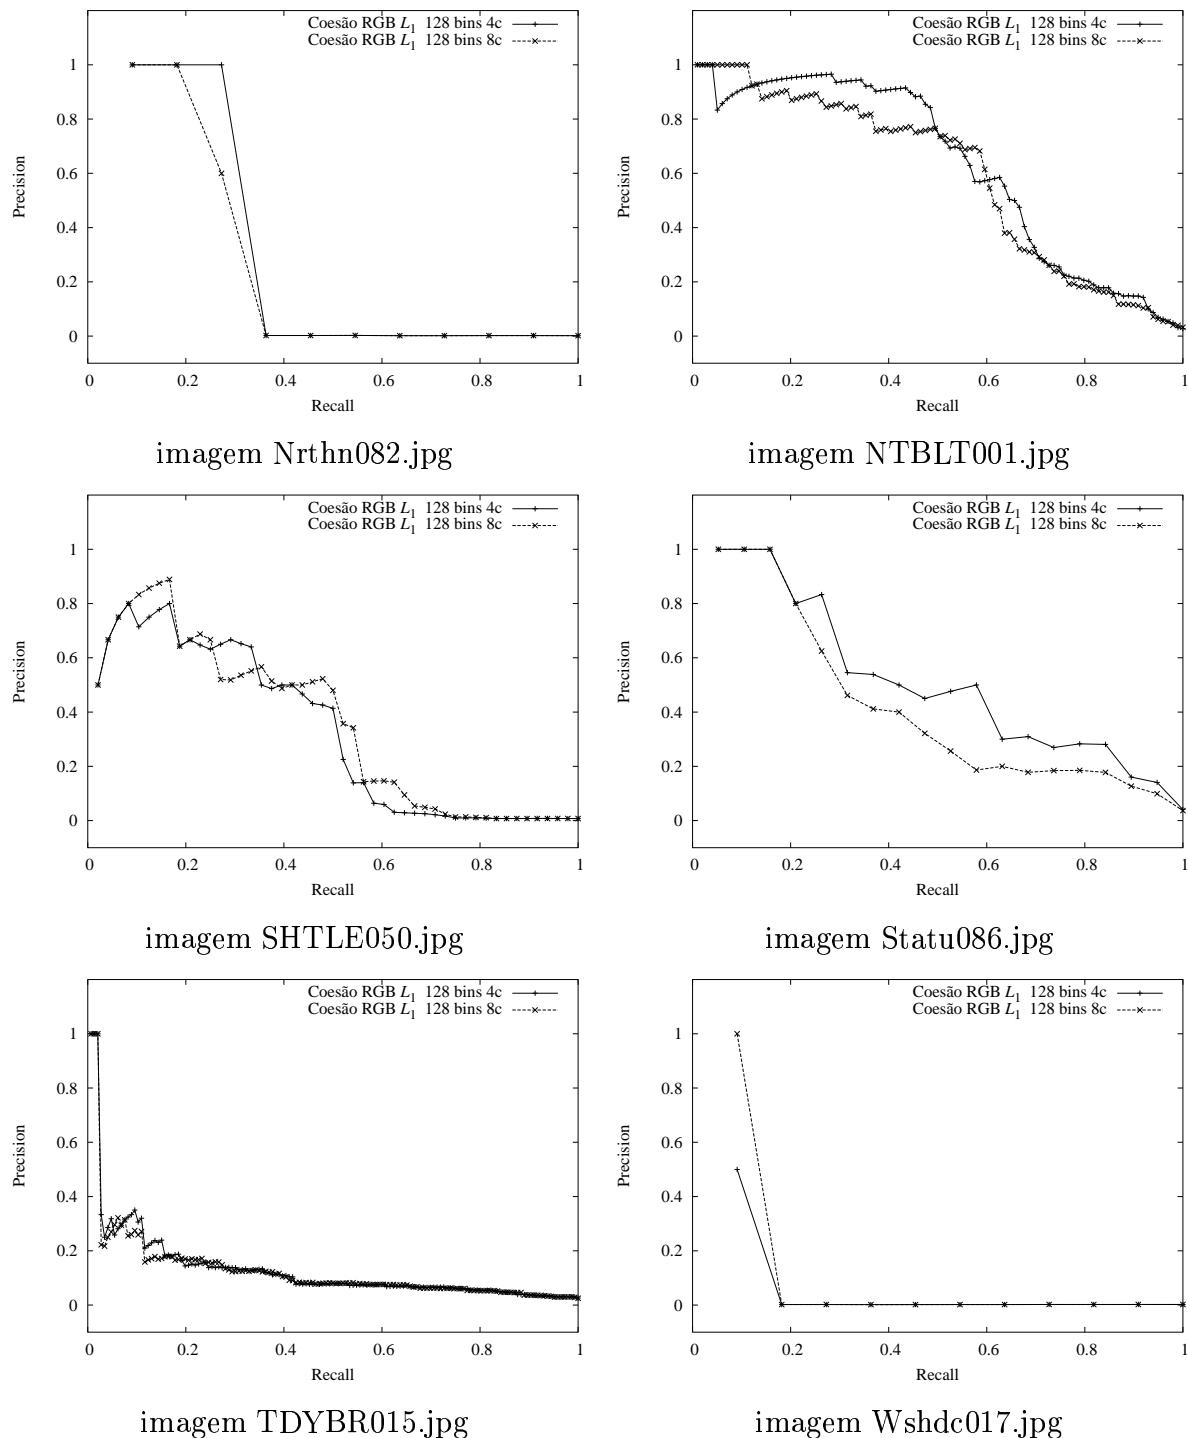


Figura A.12: Gráficos de precision e recall da comparação entre o uso de conexidade 4 e 8.

A.2 Considerando o cubo RGB

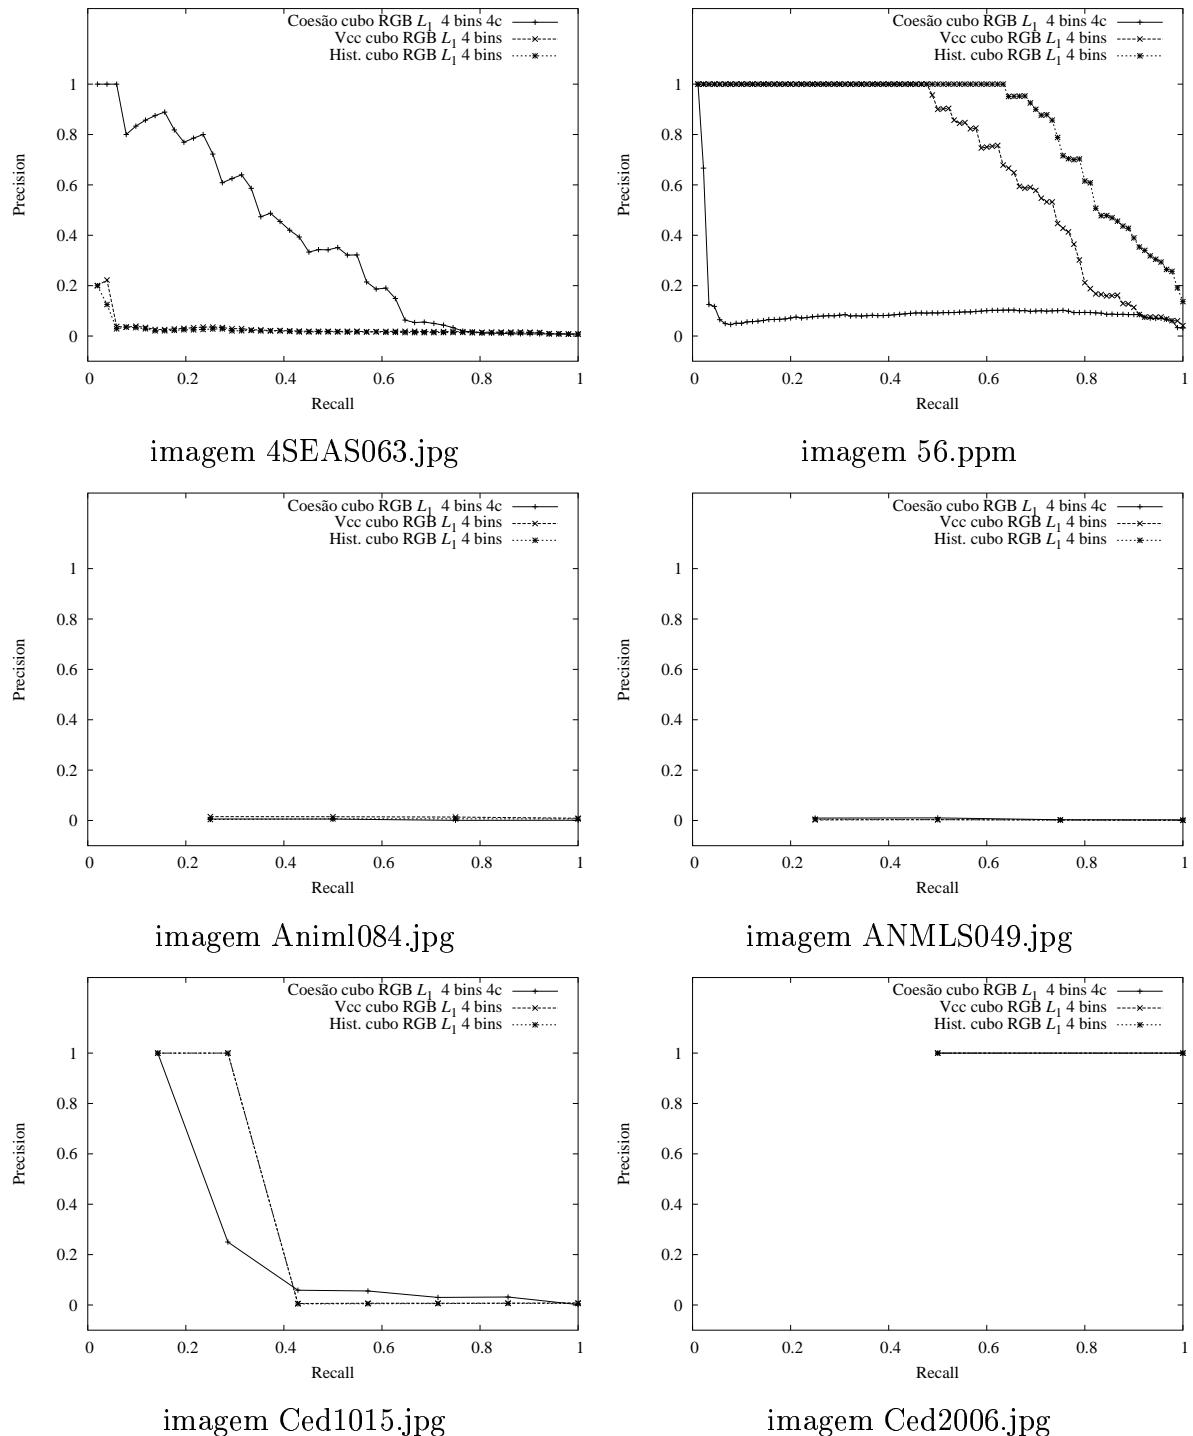


Figura A.13: Gráficos de precision e recall comparando os modelos coesão e vetor de coerência de cores.

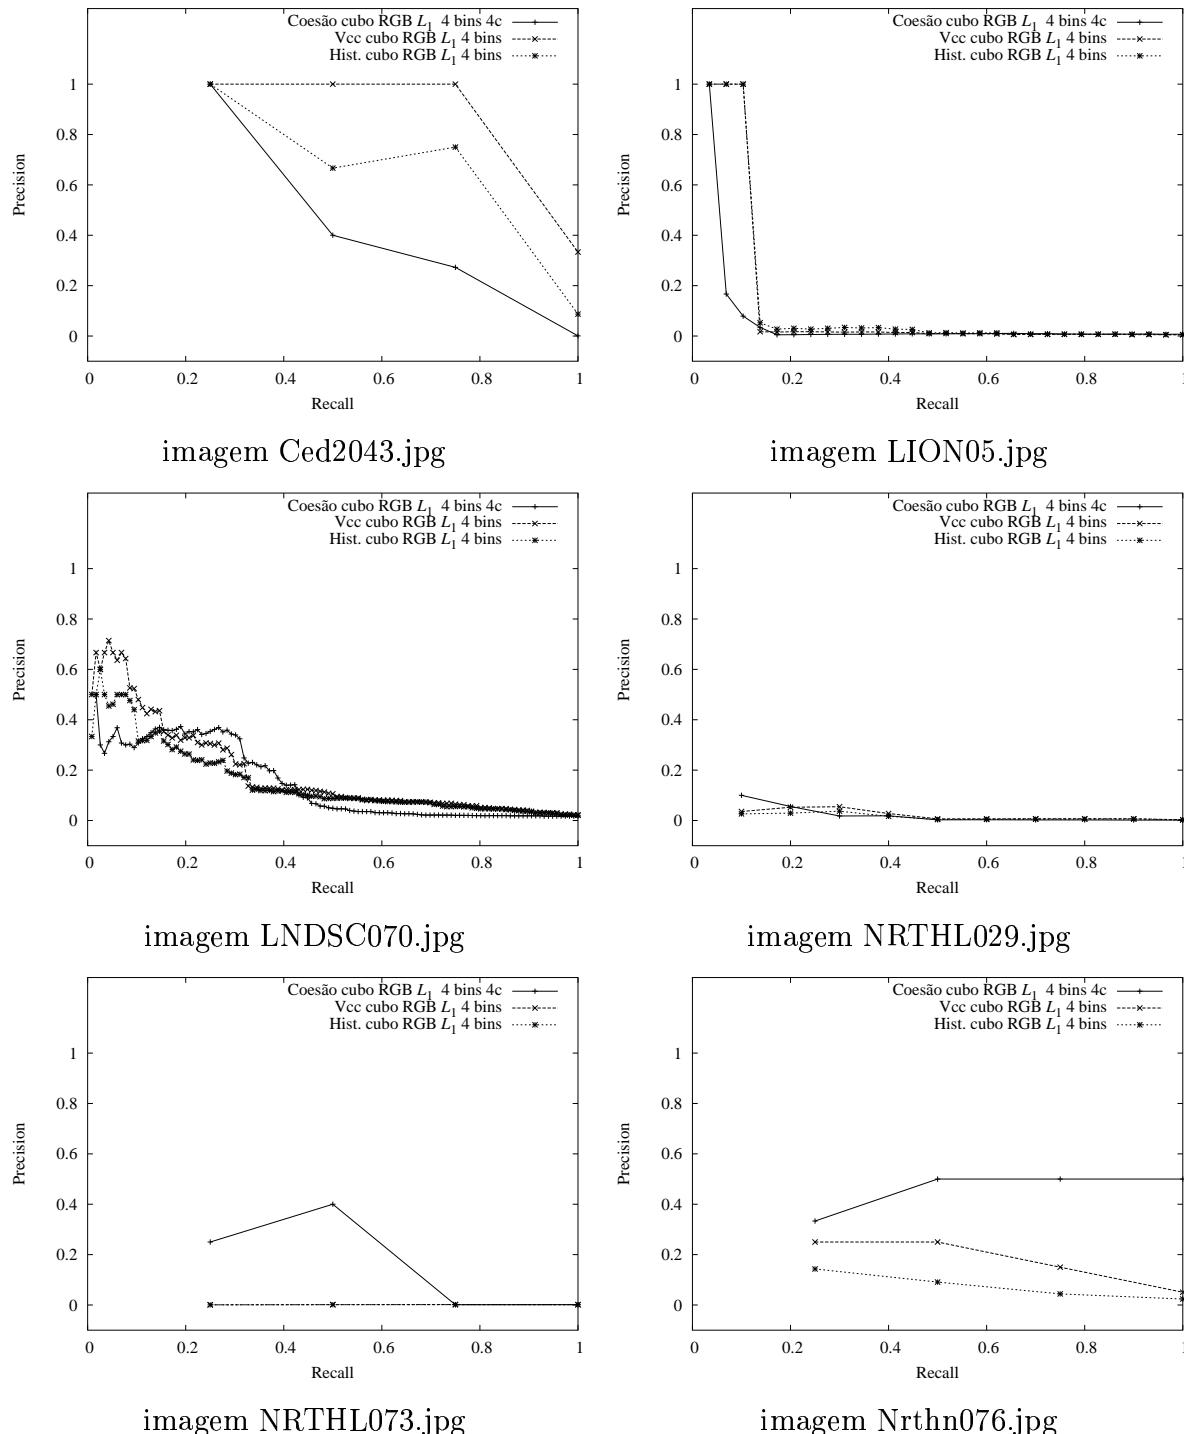


Figura A.14: Gráficos de precision e recall comparando os modelos coesão e vetor de coerência de cores.

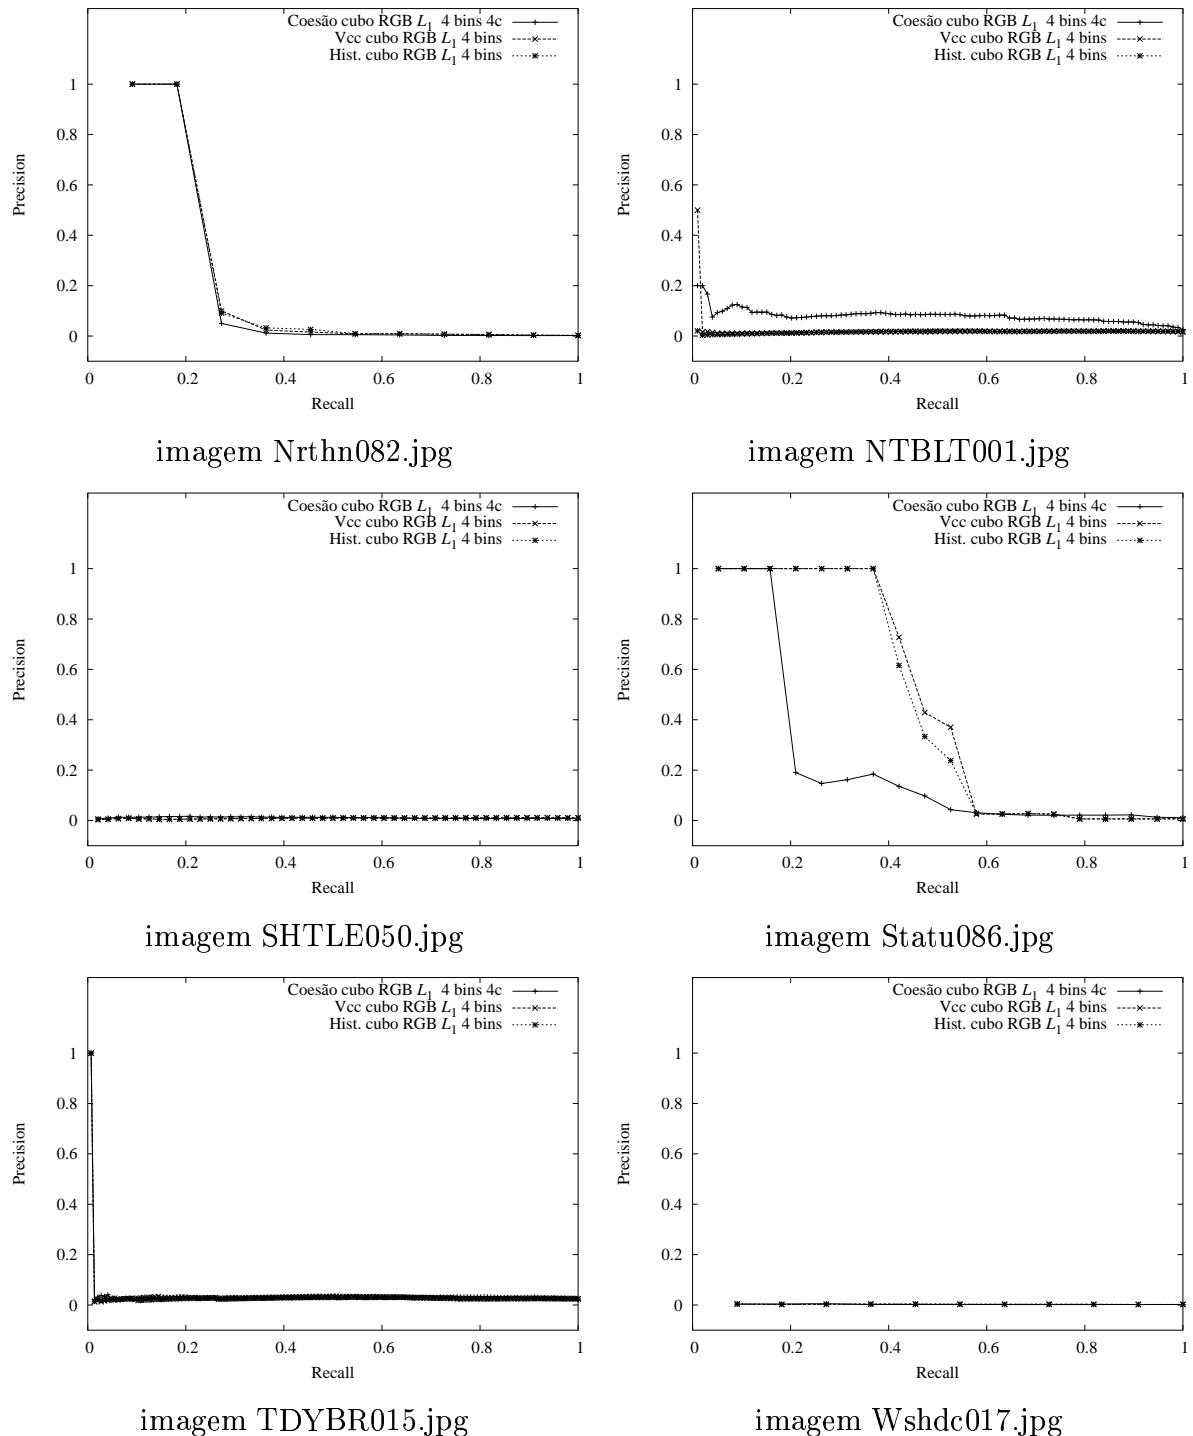


Figura A.15: Gráficos de precision e recall comparando os modelos coesão e vetor de coerência de cores.

A.3 Comparação entre coesão com três componentes e coesão com o cubo RGB

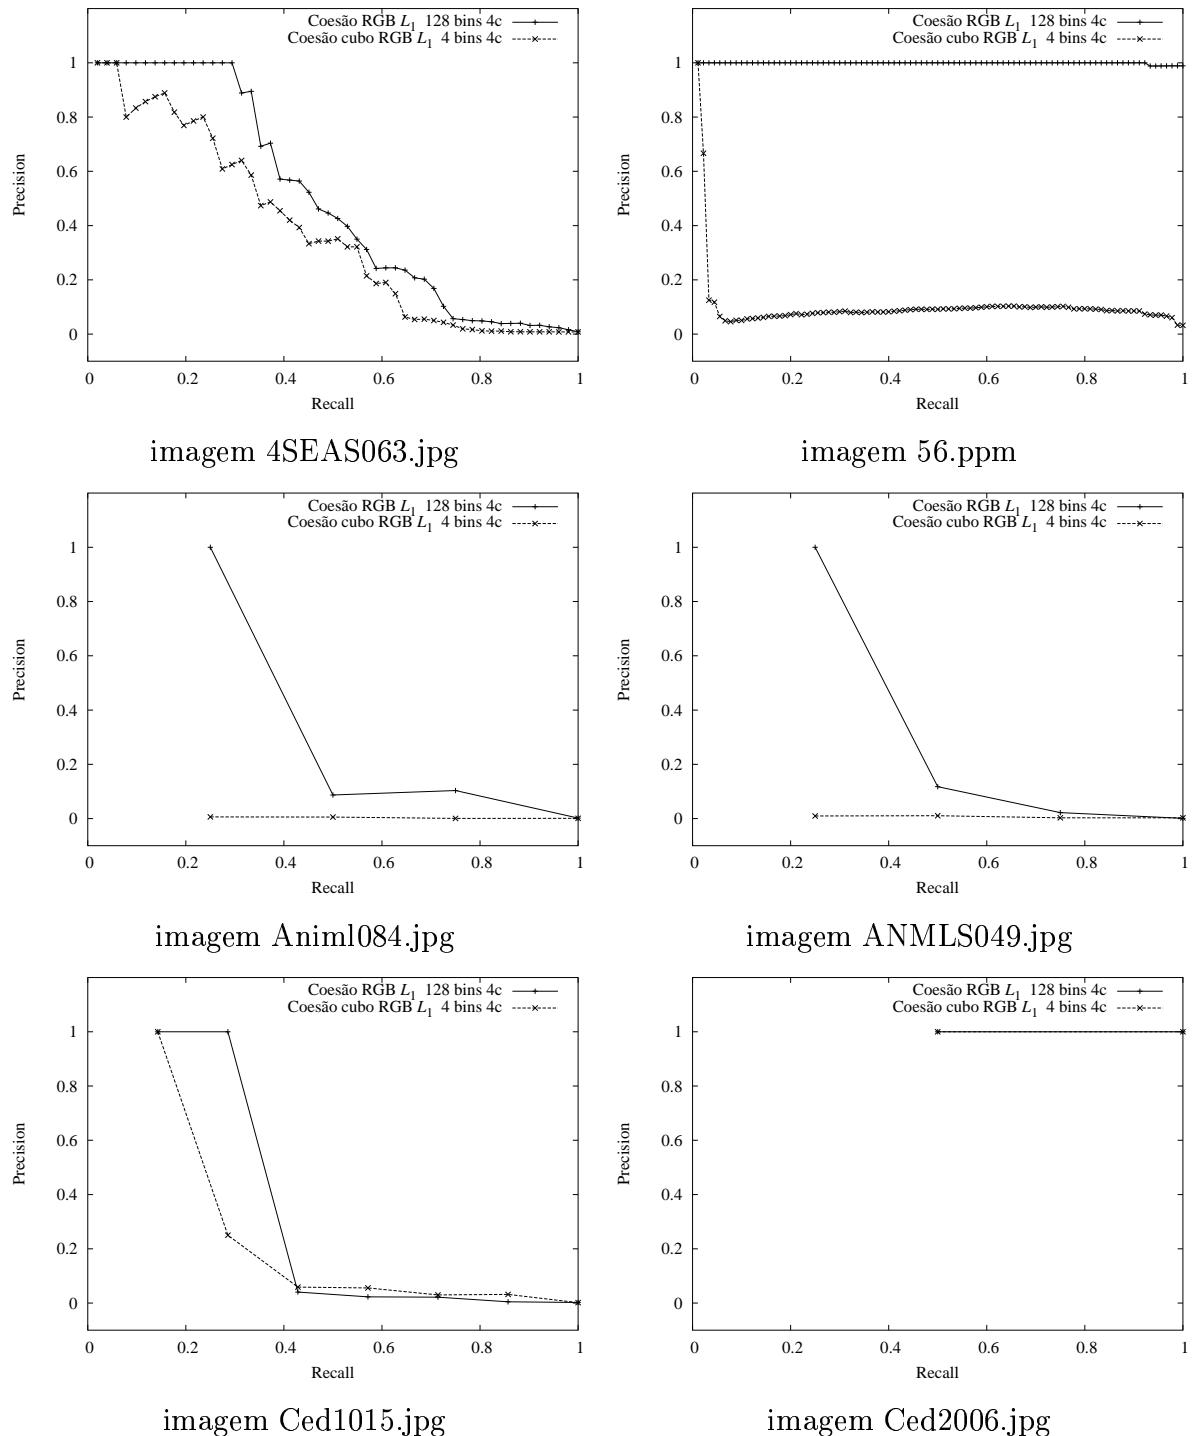


Figura A.16: Gráficos de precision e recall entre coesão utilizando três componentes e coesão utilizando o cubo RGB com 64 cores.

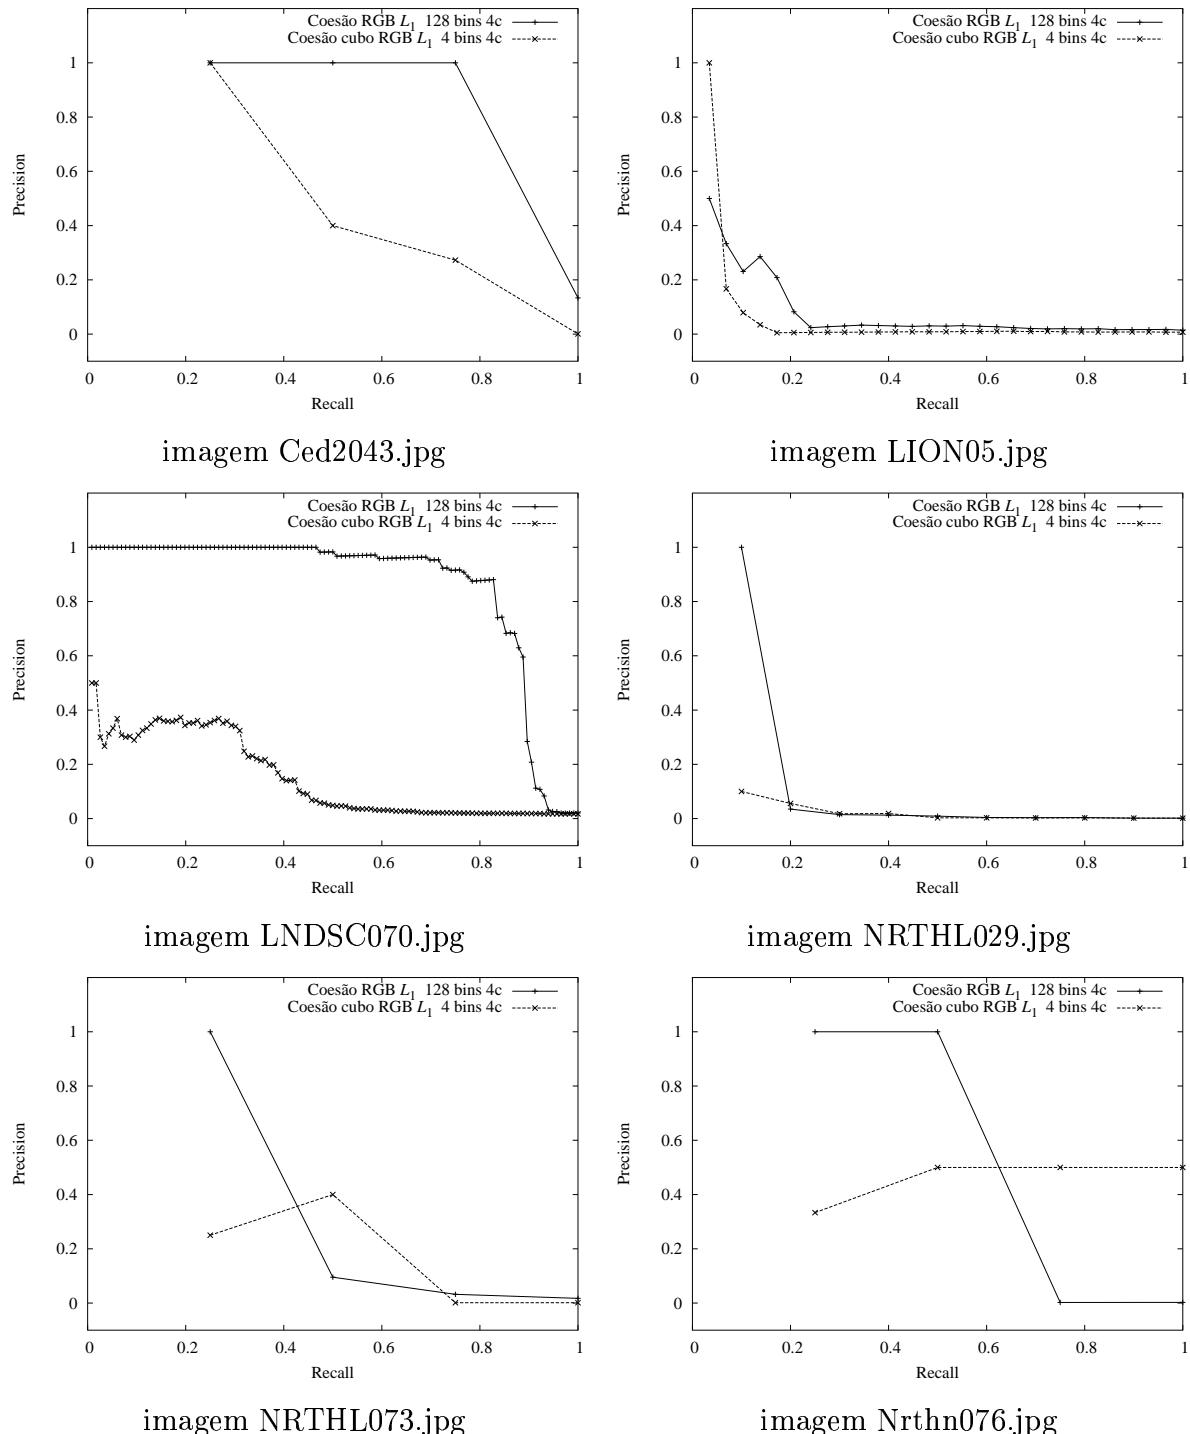


Figura A.17: Gráficos de precision e recall entre coesão utilizando três componentes e coesão utilizando o cubo RGB com 64 cores.

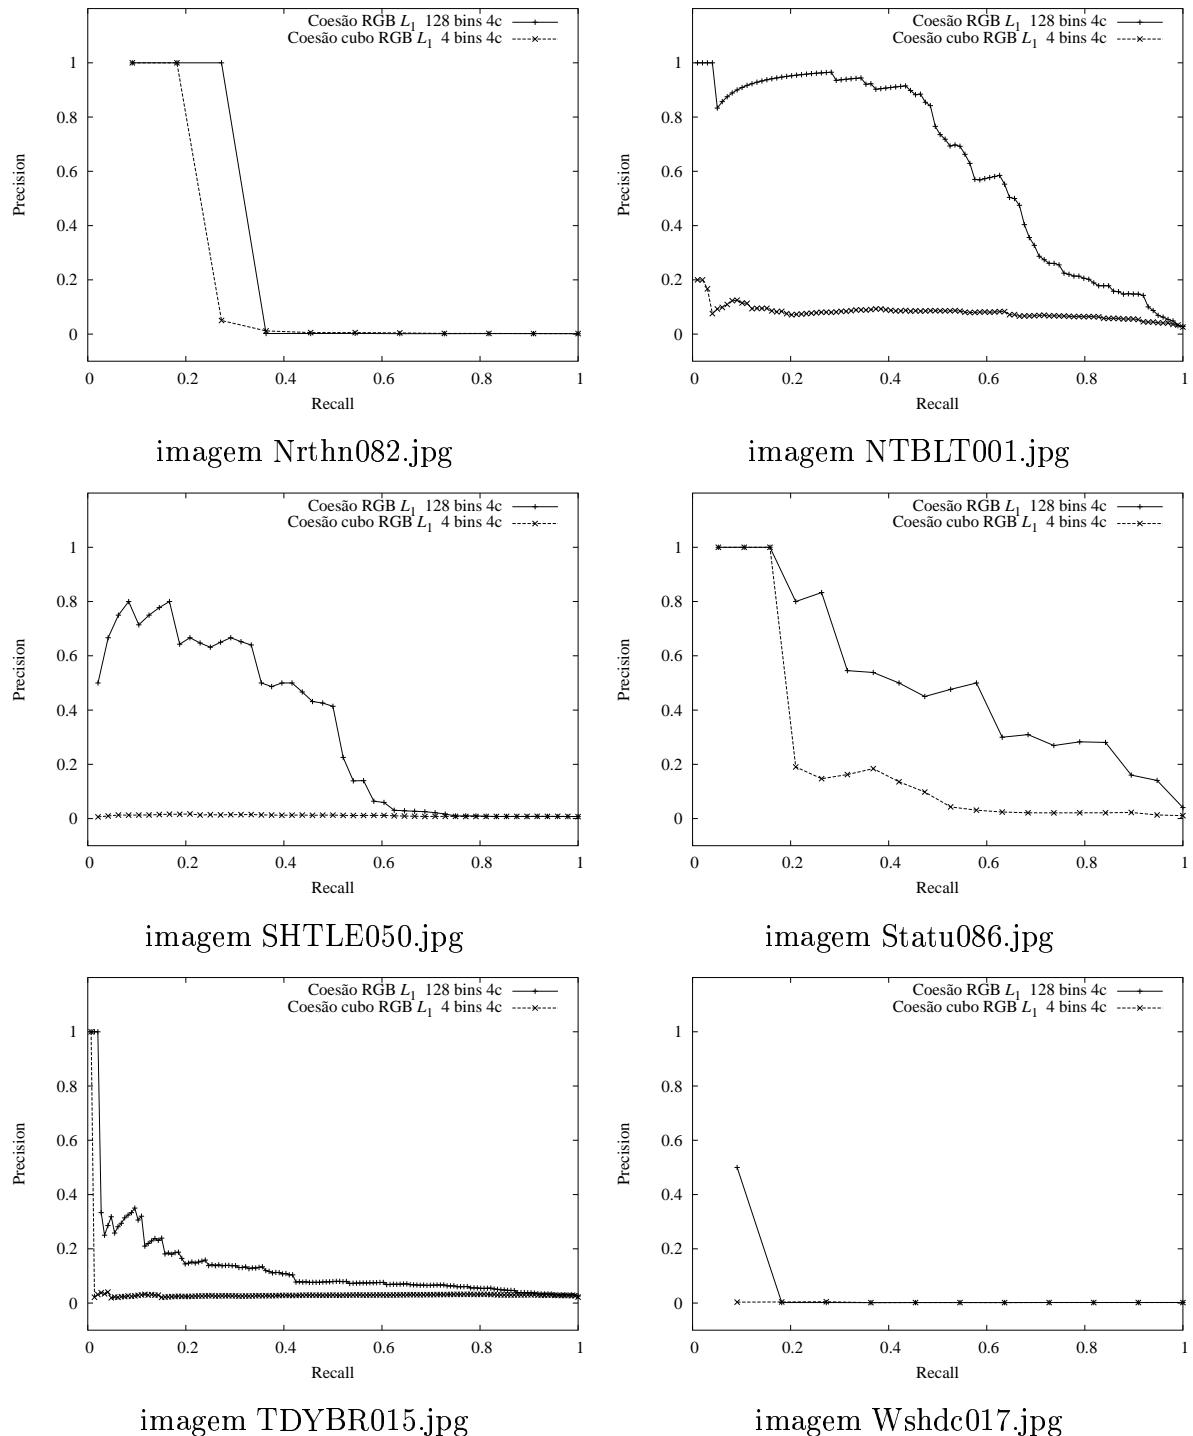


Figura A.18: Gráficos de precision e recall entre coesão utilizando três componentes e coesão utilizando o cubo RGB com 64 cores.

Apêndice B

Tabelas dos valores dos critérios de efetividade

B.1 Espaço de cores RGB com os componentes considerados separadamente

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.355	0.15	0.08	0.078	0.059	0.098
Vcc RGB Métrica L_2	1	0.602	0.05	0.04	0.039	0.02	0.059
Vcc RGB Métrica L_∞	3	0.544	0.05	0.04	0.039	0.02	0.059
Histograma RGB Métrica L_1 128 bins	1	0.309	0.15	0.06	0.059	0.059	0.078
Histograma RGB Métrica L_2 128 bins	2	0.464	0.15	0.08	0.078	0.059	0.098
Histograma RGB Métrica L_∞ 128 bins	11	0.378	0.15	0.06	0.059	0.02	0.098
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.473	0.15	0.08	0.078	0.059	0.118
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.536	0.15	0.06	0.059	0.02	0.059
Histograma Acumulado RGB Métrica L_∞ 128 bins	2	0.481	0.05	0.02	0.02	0.02	0.039
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.069	0.85	0.46	0.451	0.451	0.569
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.09	0.45	0.36	0.353	0.176	0.51
Coesão RGB Métrica L_∞ 128 bins 4-conexo	3	0.145	0.35	0.22	0.216	0.02	0.314
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.063	0.85	0.42	0.412	0.412	0.608
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.079	0.6	0.4	0.392	0.314	0.51
Coesão RGB Métrica L_∞ 128 bins 8-conexo	3	0.131	0.35	0.24	0.255	0.02	0.333

Tabela B.1: Valores dos critérios de efetividade para a imagem 4SEAS063.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.004	1.0	1.0	0.967	0.989	0.978
Vcc RGB Métrica L_2	1	0.012	1.0	1.0	0.967	0.978	0.967
Vcc RGB Métrica L_∞	1	0.048	1.0	1.0	0.878	0.911	0.889
Histograma RGB Métrica L_1 128 bins	1	0.0	1.0	1.0	0.978	1.0	0.989
Histograma RGB Métrica L_2 128 bins	1	0.001	1.0	1.0	0.967	0.989	0.978
Histograma RGB Métrica L_∞ 128 bins	1	0.023	1.0	1.0	0.933	0.933	0.933
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.0	1.0	1.0	1.0	1.0	1.0
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.0	1.0	1.0	0.989	1.0	1.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.0	1.0	1.0	0.978	0.989	0.978
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.0	1.0	1.0	0.989	1.0	1.0
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.018	1.0	1.0	0.933	0.933	0.933
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.176	0.05	0.06	0.033	0.011	0.033
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.0	1.0	1.0	0.989	1.0	1.0
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.034	1.0	1.0	0.933	0.933	0.933
Coesão RGB Métrica L_∞ 128 bins 8-conexo	5	0.161	0.1	0.1	0.078	0.011	0.078

Tabela B.2: Valores dos critérios de efetividade para a imagem 56.ppm utilizando espaço de cores RGB com 128 bins

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	445	0.119	0.0	0.0	0.0	0.25	0.0
Vcc RGB Métrica L_2	537	0.141	0.0	0.0	0.0	0.25	0.0
Vcc RGB Métrica L_∞	152	0.307	0.0	0.0	0.0	0.25	0.0
Histograma RGB Métrica L_1 128 bins	430	0.11	0.0	0.0	0.0	0.25	0.0
Histograma RGB Métrica L_2 128 bins	434	0.249	0.0	0.0	0.0	0.25	0.0
Histograma RGB Métrica L_∞ 128 bins	226	0.276	0.0	0.0	0.0	0.25	0.0
Histograma Acumulado RGB Métrica L_1 128 bins	788	0.281	0.0	0.0	0.0	0.25	0.0
Histograma Acumulado RGB Métrica L_2 128 bins	781	0.3	0.0	0.0	0.0	0.25	0.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	563	0.291	0.0	0.0	0.0	0.25	0.0
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.086	0.05	0.06	0.25	0.25	0.75
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.219	0.1	0.04	0.25	0.25	0.5
Coesão RGB Métrica L_∞ 128 bins 4-conexo	64	0.338	0.0	0.0	0.0	0.25	0.5
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.113	0.1	0.06	0.25	0.25	0.75
Coesão RGB Métrica L_2 128 bins 8-conexo	7	0.219	0.1	0.04	0.0	0.25	0.75
Coesão RGB Métrica L_∞ 128 bins 8-conexo	47	0.297	0.0	0.02	0.0	0.25	0.5

Tabela B.3: Valores dos critérios de efetividade para a imagem ANIML084.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	65	0.163	0.0	0.0	0.0	0.25	0.25
Vcc RGB Métrica L_2	93	0.184	0.0	0.0	0.0	0.25	0.25
Vcc RGB Métrica L_∞	24	0.087	0.0	0.02	0.0	0.25	0.25
Histograma RGB Métrica L_1 128 bins	57	0.166	0.0	0.0	0.0	0.25	0.25
Histograma RGB Métrica L_2 128 bins	18	0.141	0.05	0.02	0.0	0.25	0.25
Histograma RGB Métrica L_∞ 128 bins	3	0.097	0.05	0.02	0.25	0.25	0.25
Histograma Acumulado RGB Métrica L_1 128 bins	6	0.436	0.05	0.02	0.0	0.25	0.25
Histograma Acumulado RGB Métrica L_2 128 bins	28	0.45	0.0	0.02	0.0	0.25	0.25
Histograma Acumulado RGB Métrica L_∞ 128 bins	111	0.444	0.0	0.0	0.0	0.25	0.0
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.155	0.1	0.04	0.25	0.25	0.5
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.231	0.05	0.04	0.25	0.25	0.5
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.25	0.05	0.02	0.25	0.25	0.5
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.139	0.05	0.04	0.25	0.25	0.5
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.316	0.05	0.04	0.25	0.25	0.5
Coesão RGB Métrica L_∞ 128 bins 8-conexo	1	0.379	0.05	0.02	0.25	0.25	0.5

Tabela B.4: Valores dos critérios de efetividade para a imagem ANMLS049.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	6	0.106	0.25	0.3	0.242	0.01	0.253
Vcc RGB Métrica L_2	7	0.111	0.2	0.26	0.232	0.01	0.232
Vcc RGB Métrica L_∞	14	0.086	0.05	0.04	0.071	0.01	0.071
Histograma RGB Métrica L_1 128 bins	4	0.091	0.4	0.32	0.253	0.01	0.253
Histograma RGB Métrica L_2 128 bins	3	0.076	0.2	0.24	0.202	0.01	0.202
Histograma RGB Métrica L_∞ 128 bins	13	0.139	0.1	0.04	0.03	0.01	0.03
Histograma Acumulado RGB Métrica L_1 128 bins	90	0.181	0.0	0.0	0.01	0.01	0.02
Histograma Acumulado RGB Métrica L_2 128 bins	68	0.152	0.0	0.0	0.061	0.01	0.071
Histograma Acumulado RGB Métrica L_∞ 128 bins	23	0.133	0.0	0.14	0.141	0.01	0.141
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.035	0.95	0.88	0.566	0.657	0.576
Coesão RGB Métrica L_2 128 bins 4-conexo	2	0.034	0.3	0.36	0.303	0.01	0.303
Coesão RGB Métrica L_∞ 128 bins 4-conexo	6	0.065	0.1	0.12	0.121	0.01	0.121
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.037	0.9	0.76	0.596	0.606	0.596
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.045	0.65	0.56	0.444	0.384	0.455
Coesão RGB Métrica L_∞ 128 bins 8-conexo	6	0.072	0.2	0.26	0.263	0.01	0.263

Tabela B.5: Valores dos critérios de efetividade para a imagem Ced1003.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.25	0.1	0.04	0.286	0.286	0.286
Vcc RGB Métrica L_2	1	0.281	0.1	0.04	0.286	0.286	0.286
Vcc RGB Métrica L_∞	2	0.266	0.1	0.04	0.143	0.143	0.286
Histograma RGB Métrica L_1 128 bins	1	0.228	0.1	0.04	0.286	0.286	0.286
Histograma RGB Métrica L_2 128 bins	1	0.229	0.1	0.04	0.286	0.286	0.286
Histograma RGB Métrica L_∞ 128 bins	1	0.222	0.05	0.04	0.143	0.143	0.286
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.378	0.1	0.04	0.286	0.286	0.286
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.387	0.1	0.04	0.286	0.286	0.286
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.38	0.1	0.04	0.286	0.286	0.286
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.11	0.1	0.04	0.286	0.286	0.429
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.265	0.05	0.04	0.143	0.143	0.429
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.421	0.05	0.02	0.143	0.143	0.143
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.142	0.1	0.04	0.286	0.286	0.286
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.297	0.05	0.02	0.143	0.143	0.286
Coesão RGB Métrica L_∞ 128 bins 8-conexo	1	0.445	0.05	0.02	0.143	0.143	0.143

Tabela B.6: Valores dos critérios de efetividade para a imagem Ced1015.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.0	0.1	0.04	1.0	1.0	1.0
Vcc RGB Métrica L_2	1	0.0	0.1	0.04	1.0	1.0	1.0
Vcc RGB Métrica L_∞	1	0.043	0.05	0.02	0.5	0.5	0.5
Histograma RGB Métrica L_1 128 bins	1	0.0	0.1	0.04	1.0	1.0	1.0
Histograma RGB Métrica L_2 128 bins	1	0.0	0.1	0.04	1.0	1.0	1.0
Histograma RGB Métrica L_∞ 128 bins	2	0.001	0.1	0.04	0.5	0.5	1.0
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.0	0.1	0.04	1.0	1.0	1.0
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.0	0.1	0.04	1.0	1.0	1.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.0	0.1	0.04	0.5	0.5	1.0
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.0	0.1	0.04	1.0	1.0	1.0
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.024	0.05	0.02	0.5	0.5	0.5
Coesão RGB Métrica L_∞ 128 bins 4-conexo	476	0.235	0.0	0.0	0.0	0.5	0.0
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.0	0.1	0.04	1.0	1.0	1.0
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.017	0.05	0.02	0.5	0.5	0.5
Coesão RGB Métrica L_∞ 128 bins 8-conexo	9	0.196	0.05	0.02	0.0	0.5	0.5

Tabela B.7: Valores dos critérios de efetividade para a imagem Ced2006.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.006	0.1	0.04	0.25	0.25	0.75
Vcc RGB Métrica L_2	1	0.014	0.1	0.06	0.5	0.5	0.75
Vcc RGB Métrica L_∞	1	0.084	0.05	0.02	0.25	0.25	0.25
Histograma RGB Métrica L_1 128 bins	1	0.003	0.1	0.06	0.5	0.5	1.0
Histograma RGB Métrica L_2 128 bins	1	0.029	0.05	0.02	0.25	0.25	0.25
Histograma RGB Métrica L_∞ 128 bins	1	0.149	0.05	0.02	0.25	0.25	0.25
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.012	0.15	0.06	0.5	0.75	0.75
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.017	0.15	0.06	0.5	0.5	0.75
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.021	0.05	0.06	0.25	0.25	0.75
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.001	0.15	0.08	0.75	0.75	1.0
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.118	0.15	0.06	0.75	0.75	0.75
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.172	0.1	0.04	0.25	0.25	0.5
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.007	0.15	0.06	0.75	0.75	0.75
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.176	0.15	0.06	0.5	0.75	0.75
Coesão RGB Métrica L_∞ 128 bins 8-conexo	1	0.193	0.1	0.04	0.25	0.25	0.75

Tabela B.8: Valores dos critérios de efetividade para a imagem Ced2043.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.129	0.35	0.16	0.241	0.241	0.379
Vcc RGB Métrica L_2	1	0.178	0.3	0.14	0.241	0.138	0.241
Vcc RGB Métrica L_∞	5	0.153	0.15	0.16	0.172	0.034	0.379
Histograma RGB Métrica L_1 128 bins	1	0.112	0.35	0.2	0.31	0.207	0.379
Histograma RGB Métrica L_2 128 bins	1	0.118	0.25	0.18	0.207	0.103	0.345
Histograma RGB Métrica L_∞ 128 bins	7	0.183	0.1	0.08	0.069	0.034	0.276
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.208	0.35	0.2	0.241	0.207	0.345
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.209	0.35	0.16	0.276	0.241	0.379
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.204	0.35	0.16	0.276	0.241	0.345
Coesão RGB Métrica L_1 128 bins 4-conexo	2	0.099	0.2	0.1	0.172	0.034	0.207
Coesão RGB Métrica L_2 128 bins 4-conexo	26	0.096	0.0	0.06	0.034	0.034	0.138
Coesão RGB Métrica L_∞ 128 bins 4-conexo	50	0.156	0.0	0.02	0.0	0.034	0.069
Coesão RGB Métrica L_1 128 bins 8-conexo	2	0.094	0.2	0.1	0.138	0.034	0.172
Coesão RGB Métrica L_2 128 bins 8-conexo	27	0.092	0.0	0.06	0.034	0.034	0.207
Coesão RGB Métrica L_∞ 128 bins 8-conexo	146	0.144	0.0	0.0	0.0	0.034	0.0

Tabela B.9: Valores dos critérios de efetividade para a imagem LION05.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.207	0.25	0.18	0.164	0.009	0.147
Vcc RGB Métrica L_2	12	0.251	0.15	0.08	0.103	0.009	0.069
Vcc RGB Métrica L_∞	19	0.288	0.05	0.02	0.026	0.009	0.026
Histograma RGB Métrica L_1 128 bins	1	0.126	0.65	0.46	0.353	0.198	0.328
Histograma RGB Métrica L_2 128 bins	1	0.152	0.6	0.42	0.276	0.112	0.276
Histograma RGB Métrica L_∞ 128 bins	1	0.205	0.6	0.4	0.25	0.155	0.241
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.202	0.5	0.3	0.216	0.086	0.207
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.211	0.55	0.34	0.259	0.095	0.233
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.196	0.55	0.42	0.284	0.095	0.25
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.055	1.0	1.0	0.828	0.888	0.767
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.087	0.95	0.94	0.664	0.802	0.629
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.155	0.9	0.76	0.526	0.543	0.5
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.051	1.0	1.0	0.81	0.871	0.75
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.087	1.0	0.96	0.681	0.802	0.629
Coesão RGB Métrica L_∞ 128 bins 8-conexo	1	0.161	0.85	0.82	0.534	0.578	0.509

Tabela B.10: Valores dos critérios de efetividade para a imagem LNDSC070.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	12	0.212	0.05	0.04	0.0	0.1	0.2
Vcc RGB Métrica L_2	31	0.299	0.0	0.04	0.0	0.1	0.2
Vcc RGB Métrica L_∞	14	0.357	0.05	0.04	0.0	0.1	0.2
Histograma RGB Métrica L_1 128 bins	27	0.174	0.0	0.04	0.0	0.1	0.3
Histograma RGB Métrica L_2 128 bins	28	0.289	0.0	0.04	0.0	0.1	0.3
Histograma RGB Métrica L_∞ 128 bins	22	0.333	0.0	0.04	0.0	0.1	0.3
Histograma Acumulado RGB Métrica L_1 128 bins	119	0.277	0.0	0.0	0.0	0.1	0.0
Histograma Acumulado RGB Métrica L_2 128 bins	102	0.297	0.0	0.0	0.0	0.1	0.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	67	0.312	0.0	0.0	0.0	0.1	0.1
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.285	0.05	0.02	0.1	0.1	0.2
Coesão RGB Métrica L_2 128 bins 4-conexo	2	0.191	0.1	0.04	0.1	0.1	0.4
Coesão RGB Métrica L_∞ 128 bins 4-conexo	3	0.132	0.05	0.02	0.1	0.1	0.3
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.369	0.05	0.04	0.1	0.1	0.2
Coesão RGB Métrica L_2 128 bins 8-conexo	2	0.198	0.1	0.06	0.1	0.1	0.4
Coesão RGB Métrica L_∞ 128 bins 8-conexo	3	0.144	0.05	0.08	0.1	0.1	0.4

Tabela B.11: Valores dos critérios de efetividade para a imagem NRTHL029.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1828	0.307	0.0	0.0	0.0	0.25	0.0
Vcc RGB Métrica L_2	2690	0.441	0.0	0.0	0.0	0.25	0.0
Vcc RGB Métrica L_∞	2076	0.351	0.0	0.0	0.0	0.25	0.0
Histograma RGB Métrica L_1 128 bins	1767	0.291	0.0	0.0	0.0	0.25	0.0
Histograma RGB Métrica L_2 128 bins	1820	0.313	0.0	0.0	0.0	0.25	0.0
Histograma RGB Métrica L_∞ 128 bins	1388	0.276	0.0	0.0	0.0	0.25	0.0
Histograma Acumulado RGB Métrica L_1 128 bins	3807	0.711	0.0	0.0	0.0	0.25	0.0
Histograma Acumulado RGB Métrica L_2 128 bins	3922	0.703	0.0	0.0	0.0	0.25	0.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	2643	0.462	0.0	0.0	0.0	0.25	0.0
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.012	0.05	0.04	0.25	0.25	0.75
Coesão RGB Métrica L_2 128 bins 4-conexo	2	0.019	0.05	0.02	0.25	0.25	0.25
Coesão RGB Métrica L_∞ 128 bins 4-conexo	7	0.02	0.05	0.02	0.0	0.25	0.25
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.012	0.05	0.04	0.25	0.25	0.75
Coesão RGB Métrica L_2 128 bins 8-conexo	7	0.017	0.05	0.02	0.0	0.25	0.5
Coesão RGB Métrica L_∞ 128 bins 8-conexo	32	0.019	0.0	0.04	0.0	0.25	0.5

Tabela B.12: Valores dos critérios de efetividade para a imagem NRTHL073.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.001	0.15	0.08	0.5	0.75	1.0
Vcc RGB Métrica L_2	1	0.002	0.15	0.06	0.5	0.5	1.0
Vcc RGB Métrica L_∞	1	0.025	0.15	0.06	0.25	0.25	0.75
Histograma RGB Métrica L_1 128 bins	1	0.001	0.2	0.08	0.25	0.25	1.0
Histograma RGB Métrica L_2 128 bins	1	0.003	0.1	0.06	0.25	0.25	1.0
Histograma RGB Métrica L_∞ 128 bins	2	0.01	0.15	0.06	0.25	0.25	0.75
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.001	0.2	0.08	0.5	0.5	1.0
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.002	0.15	0.08	0.5	0.5	1.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.007	0.1	0.06	0.25	0.25	0.75
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.111	0.1	0.04	0.5	0.5	0.5
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.44	0.1	0.04	0.5	0.5	0.5
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.249	0.1	0.04	0.5	0.5	0.5
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.26	0.1	0.04	0.5	0.5	0.5
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.449	0.1	0.04	0.5	0.5	0.5
Coesão RGB Métrica L_∞ 128 bins 8-conexo	1	0.327	0.1	0.04	0.5	0.5	0.5

Tabela B.13: Valores dos critérios de efetividade para a imagem NRTHN076.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.218	0.1	0.06	0.182	0.182	0.273
Vcc RGB Métrica L_2	1	0.182	0.1	0.06	0.182	0.182	0.364
Vcc RGB Métrica L_∞	1	0.28	0.15	0.08	0.182	0.182	0.364
Histograma RGB Métrica L_1 128 bins	1	0.201	0.15	0.06	0.182	0.182	0.364
Histograma RGB Métrica L_2 128 bins	1	0.204	0.1	0.06	0.182	0.182	0.364
Histograma RGB Métrica L_∞ 128 bins	1	0.256	0.1	0.06	0.182	0.182	0.364
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.225	0.1	0.04	0.182	0.091	0.182
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.22	0.1	0.04	0.182	0.091	0.182
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.202	0.1	0.04	0.182	0.091	0.273
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.444	0.15	0.06	0.273	0.273	0.273
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.533	0.05	0.02	0.091	0.091	0.182
Coesão RGB Métrica L_∞ 128 bins 4-conexo	3	0.566	0.05	0.02	0.091	0.091	0.091
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.452	0.15	0.06	0.273	0.273	0.273
Coesão RGB Métrica L_2 128 bins 8-conexo	9	0.508	0.05	0.02	0.091	0.091	0.273
Coesão RGB Métrica L_∞ 128 bins 8-conexo	56	0.517	0.0	0.0	0.0	0.091	0.091

Tabela B.14: Valores dos critérios de efetividade para a imagem NRTHN082.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	254	0.349	0.0	0.0	0.0	0.021	0.0
Vcc RGB Métrica L_2	139	0.327	0.0	0.0	0.0	0.021	0.0
Vcc RGB Métrica L_∞	5	0.675	0.15	0.06	0.063	0.021	0.083
Histograma RGB Métrica L_1 128 bins	319	0.359	0.0	0.0	0.0	0.021	0.0
Histograma RGB Métrica L_2 128 bins	123	0.595	0.0	0.0	0.0	0.021	0.0
Histograma RGB Métrica L_∞ 128 bins	12	0.676	0.05	0.02	0.021	0.021	0.021
Histograma Acumulado RGB Métrica L_1 128 bins	232	0.578	0.0	0.0	0.0	0.021	0.0
Histograma Acumulado RGB Métrica L_2 128 bins	215	0.543	0.0	0.0	0.0	0.021	0.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	233	0.448	0.0	0.0	0.0	0.021	0.0
Coesão RGB Métrica L_1 128 bins 4-conexo	2	0.234	0.65	0.42	0.438	0.354	0.5
Coesão RGB Métrica L_2 128 bins 4-conexo	3	0.25	0.55	0.44	0.458	0.021	0.521
Coesão RGB Métrica L_∞ 128 bins 4-conexo	4	0.227	0.55	0.38	0.396	0.021	0.542
Coesão RGB Métrica L_1 128 bins 8-conexo	2	0.212	0.6	0.48	0.479	0.375	0.542
Coesão RGB Métrica L_2 128 bins 8-conexo	4	0.243	0.6	0.42	0.417	0.021	0.521
Coesão RGB Métrica L_∞ 128 bins 8-conexo	4	0.215	0.5	0.4	0.417	0.021	0.521

Tabela B.15: Valores dos critérios de efetividade para a imagem SHTLE050.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.197	0.45	0.18	0.474	0.421	0.474
Vcc RGB Métrica L_2	1	0.219	0.45	0.2	0.474	0.474	0.526
Vcc RGB Métrica L_∞	7	0.238	0.1	0.06	0.105	0.053	0.211
Histograma RGB Métrica L_1 128 bins	1	0.183	0.4	0.18	0.421	0.421	0.526
Histograma RGB Métrica L_2 128 bins	1	0.189	0.3	0.16	0.263	0.211	0.474
Histograma RGB Métrica L_∞ 128 bins	1	0.224	0.1	0.1	0.105	0.053	0.316
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.187	0.2	0.08	0.211	0.211	0.474
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.207	0.2	0.08	0.211	0.211	0.421
Histograma Acumulado RGB Métrica L_∞ 128 bins	3	0.243	0.2	0.1	0.211	0.053	0.368
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.007	0.45	0.26	0.421	0.421	0.842
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.085	0.25	0.16	0.263	0.105	0.579
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.13	0.2	0.08	0.211	0.053	0.316
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.009	0.4	0.2	0.368	0.263	0.842
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.116	0.15	0.08	0.158	0.105	0.263
Coesão RGB Métrica L_∞ 128 bins 8-conexo	11	0.179	0.1	0.06	0.105	0.053	0.158

Tabela B.16: Valores dos critérios de efetividade para a imagem Statu086.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	1	0.34	0.05	0.06	0.027	0.007	0.027
Vcc RGB Métrica L_2	1	0.397	0.05	0.02	0.021	0.007	0.021
Vcc RGB Métrica L_∞	1	0.411	0.05	0.02	0.007	0.007	0.007
Histograma RGB Métrica L_1 128 bins	1	0.352	0.05	0.08	0.027	0.007	0.027
Histograma RGB Métrica L_2 128 bins	1	0.375	0.05	0.06	0.027	0.007	0.021
Histograma RGB Métrica L_∞ 128 bins	1	0.387	0.05	0.02	0.021	0.007	0.021
Histograma Acumulado RGB Métrica L_1 128 bins	1	0.515	0.05	0.02	0.014	0.007	0.014
Histograma Acumulado RGB Métrica L_2 128 bins	1	0.526	0.05	0.02	0.014	0.007	0.014
Histograma Acumulado RGB Métrica L_∞ 128 bins	1	0.51	0.05	0.02	0.014	0.007	0.007
Coesão RGB Métrica L_1 128 bins 4-conexo	1	0.181	0.25	0.32	0.185	0.021	0.151
Coesão RGB Métrica L_2 128 bins 4-conexo	1	0.201	0.35	0.32	0.219	0.021	0.185
Coesão RGB Métrica L_∞ 128 bins 4-conexo	1	0.214	0.45	0.28	0.164	0.021	0.137
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.181	0.2	0.26	0.171	0.021	0.11
Coesão RGB Métrica L_2 128 bins 8-conexo	1	0.197	0.4	0.24	0.205	0.021	0.171
Coesão RGB Métrica L_∞ 128 bins 8-conexo	1	0.208	0.3	0.24	0.137	0.021	0.116

Tabela B.17: Valores dos critérios de efetividade para a imagem TDYBR015.jpg utilizando espaço de cores RGB com 128 bins.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc RGB Métrica L_1	88	0.358	0.0	0.0	0.0	0.091	0.091
Vcc RGB Métrica L_2	77	0.34	0.0	0.0	0.0	0.091	0.091
Vcc RGB Métrica L_∞	98	0.407	0.0	0.0	0.0	0.091	0.091
Histograma RGB Métrica L_1 128 bins	135	0.364	0.0	0.0	0.0	0.091	0.0
Histograma RGB Métrica L_2 128 bins	111	0.384	0.0	0.0	0.0	0.091	0.0
Histograma RGB Métrica L_∞ 128 bins	52	0.533	0.0	0.0	0.0	0.091	0.091
Histograma Acumulado RGB Métrica L_1 128 bins	435	0.509	0.0	0.0	0.0	0.091	0.0
Histograma Acumulado RGB Métrica L_2 128 bins	333	0.52	0.0	0.0	0.0	0.091	0.0
Histograma Acumulado RGB Métrica L_∞ 128 bins	270	0.533	0.0	0.0	0.0	0.091	0.0
Coesão RGB Métrica L_1 128 bins 4-conexo	2	0.44	0.05	0.02	0.091	0.091	0.091
Coesão RGB Métrica L_2 128 bins 4-conexo	33	0.483	0.0	0.02	0.0	0.091	0.091
Coesão RGB Métrica L_∞ 128 bins 4-conexo	572	0.516	0.0	0.0	0.0	0.091	0.0
Coesão RGB Métrica L_1 128 bins 8-conexo	1	0.441	0.05	0.02	0.091	0.091	0.091
Coesão RGB Métrica L_2 128 bins 8-conexo	17	0.487	0.05	0.02	0.0	0.091	0.091
Coesão RGB Métrica L_∞ 128 bins 8-conexo	154	0.482	0.0	0.0	0.0	0.091	0.0

Tabela B.18: Valores dos critérios de efetividade para a imagem Wshdc017.jpg utilizando espaço de cores RGB com 128 bins.

B.2 Considerando o cubo RGB

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	5	0.24	0.1	0.04	0.039	0.02	0.059
Vcc cubo RGB Métrica L_2	11	0.255	0.05	0.06	0.059	0.02	0.078
Vcc cubo RGB Métrica L_∞	12	0.439	0.05	0.04	0.039	0.02	0.059
Histograma cubo RGB Métrica L_1 4 bins	5	0.279	0.1	0.04	0.039	0.02	0.039
Histograma cubo RGB Métrica L_2 4 bins	42	0.434	0.0	0.02	0.02	0.02	0.059
Histograma cubo RGB Métrica L_∞ 4 bins	58	0.502	0.0	0.0	0.0	0.02	0.02
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.19	0.65	0.42	0.412	0.333	0.549
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.196	0.7	0.32	0.314	0.294	0.451
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	1	0.193	0.55	0.3	0.294	0.216	0.333

Tabela B.19: Valores dos critérios de efetividade para a imagem 4SEAS063.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.027	1.0	0.9	0.644	0.733	0.656
Vcc cubo RGB Métrica L_2	1	0.032	1.0	0.98	0.744	0.778	0.767
Vcc cubo RGB Métrica L_∞	1	0.068	0.8	0.52	0.378	0.289	0.389
Histograma cubo RGB Métrica L_1 4 bins	1	0.005	1.0	1.0	0.744	0.822	0.778
Histograma cubo RGB Métrica L_2 4 bins	1	0.045	1.0	0.66	0.467	0.422	0.489
Histograma cubo RGB Métrica L_∞ 4 bins	1	0.053	0.75	0.54	0.356	0.322	0.378
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.077	0.1	0.08	0.056	0.022	0.056
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	8	0.205	0.05	0.04	0.033	0.011	0.033
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	19	0.236	0.05	0.02	0.022	0.011	0.033

Tabela B.20: Valores dos critérios de efetividade para a imagem 56.ppm utilizando cubo RGB 64 cores

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	65	0.031	0.0	0.0	0.0	0.25	0.25
Vcc cubo RGB Métrica L_2	336	0.178	0.0	0.0	0.0	0.25	0.0
Vcc cubo RGB Métrica L_∞	167	0.111	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_1 4 bins	260	0.06	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_2 4 bins	639	0.116	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_∞ 4 bins	785	0.226	0.0	0.0	0.0	0.25	0.0
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	165	0.346	0.0	0.0	0.0	0.25	0.0
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	587	0.402	0.0	0.0	0.0	0.25	0.0
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	797	0.202	0.0	0.0	0.0	0.25	0.0

Tabela B.21: Valores dos critérios de efetividade para a imagem ANIML084.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	445	0.231	0.0	0.0	0.0	0.25	0.0
Vcc cubo RGB Métrica L_2	1155	0.287	0.0	0.0	0.0	0.25	0.0
Vcc cubo RGB Métrica L_∞	1414	0.398	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_1 4 bins	200	0.239	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_2 4 bins	948	0.342	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_∞ 4 bins	1899	0.412	0.0	0.0	0.0	0.25	0.0
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	105	0.104	0.0	0.0	0.0	0.25	0.0
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	129	0.187	0.0	0.0	0.0	0.25	0.0
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	103	0.201	0.0	0.0	0.0	0.25	0.0

Tabela B.22: Valores dos critérios de efetividade para a imagem ANMLS049.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	2	0.407	0.05	0.02	0.01	0.01	0.01
Vcc cubo RGB Métrica L_2	6	0.405	0.05	0.02	0.051	0.01	0.051
Vcc cubo RGB Métrica L_∞	18	0.75	0.05	0.04	0.02	0.01	0.02
Histograma cubo RGB Métrica L_1 4 bins	48	0.406	0.0	0.02	0.01	0.01	0.01
Histograma cubo RGB Métrica L_2 4 bins	60	0.568	0.0	0.0	0.01	0.01	0.01
Histograma cubo RGB Métrica L_∞ 4 bins	162	0.648	0.0	0.0	0.0	0.01	0.0
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	5	0.11	0.15	0.06	0.111	0.01	0.111
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	9	0.179	0.05	0.02	0.02	0.01	0.02
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	50	0.204	0.0	0.02	0.02	0.01	0.02

Tabela B.23: Valores dos critérios de efetividade para a imagem Ced1003.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.072	0.1	0.04	0.286	0.286	0.286
Vcc cubo RGB Métrica L_2	1	0.031	0.15	0.06	0.429	0.429	0.714
Vcc cubo RGB Métrica L_∞	1	0.126	0.1	0.04	0.286	0.286	0.286
Histograma cubo RGB Métrica L_1 4 bins	1	0.094	0.1	0.04	0.286	0.286	0.286
Histograma cubo RGB Métrica L_2 4 bins	1	0.138	0.1	0.04	0.286	0.286	0.286
Histograma cubo RGB Métrica L_∞ 4 bins	1	0.185	0.1	0.04	0.286	0.286	0.286
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.106	0.1	0.04	0.143	0.143	0.571
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.087	0.1	0.06	0.286	0.286	0.714
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	1	0.068	0.15	0.08	0.429	0.286	0.857

Tabela B.24: Valores dos critérios de efetividade para a imagem Ced1015.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.0	0.1	0.04	1.0	1.0	1.0
Vcc cubo RGB Métrica L_2	1	0.001	0.1	0.04	0.5	0.5	1.0
Vcc cubo RGB Métrica L_∞	6	0.001	0.1	0.04	0.0	0.5	1.0
Histograma cubo RGB Métrica L_1 4 bins	1	0.0	0.1	0.04	1.0	1.0	1.0
Histograma cubo RGB Métrica L_2 4 bins	2	0.0	0.1	0.04	0.5	1.0	1.0
Histograma cubo RGB Métrica L_∞ 4 bins	5	0.001	0.1	0.04	0.0	0.5	1.0
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.0	0.1	0.04	1.0	1.0	1.0
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.009	0.05	0.02	0.5	0.5	0.5
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	1	0.196	0.05	0.02	0.5	0.5	0.5

Tabela B.25: Valores dos critérios de efetividade para a imagem Ced2006.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.0	0.2	0.08	0.75	0.75	1.0
Vcc cubo RGB Métrica L_2	1	0.0	0.2	0.08	0.75	1.0	1.0
Vcc cubo RGB Métrica L_∞	1	0.002	0.15	0.06	0.5	0.5	1.0
Histograma cubo RGB Métrica L_1 4 bins	1	0.002	0.15	0.08	0.75	0.75	1.0
Histograma cubo RGB Métrica L_2 4 bins	1	0.007	0.15	0.06	0.5	0.5	0.75
Histograma cubo RGB Métrica L_∞ 4 bins	1	0.014	0.1	0.04	0.25	0.25	0.5
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.215	0.15	0.06	0.25	0.25	0.75
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.228	0.05	0.06	0.25	0.25	0.75
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	1	0.233	0.1	0.04	0.25	0.25	0.5

Tabela B.26: Valores dos critérios de efetividade para a imagem Ced2043.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.291	0.15	0.06	0.103	0.103	0.103
Vcc cubo RGB Métrica L_2	1	0.481	0.1	0.04	0.069	0.069	0.069
Vcc cubo RGB Métrica L_∞	1	0.267	0.3	0.18	0.241	0.138	0.379
Histograma cubo RGB Métrica L_1 4 bins	1	0.246	0.15	0.06	0.103	0.103	0.138
Histograma cubo RGB Métrica L_2 4 bins	1	0.252	0.35	0.18	0.276	0.207	0.345
Histograma cubo RGB Métrica L_∞ 4 bins	1	0.272	0.45	0.2	0.345	0.31	0.414
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.269	0.1	0.06	0.069	0.034	0.103
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.426	0.1	0.04	0.069	0.034	0.103
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	1	0.492	0.05	0.04	0.069	0.034	0.103

Tabela B.27: Valores dos critérios de efetividade para a imagem LION05.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	2	0.142	0.5	0.34	0.284	0.095	0.259
Vcc cubo RGB Métrica L_2	5	0.311	0.2	0.12	0.078	0.009	0.078
Vcc cubo RGB Métrica L_∞	1	0.16	0.4	0.26	0.216	0.009	0.181
Histograma cubo RGB Métrica L_1 4 bins	3	0.153	0.45	0.34	0.233	0.009	0.207
Histograma cubo RGB Métrica L_2 4 bins	3	0.158	0.45	0.26	0.207	0.009	0.181
Histograma cubo RGB Métrica L_∞ 4 bins	2	0.155	0.35	0.26	0.19	0.026	0.172
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	2	0.307	0.35	0.36	0.31	0.017	0.293
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.28	0.2	0.16	0.181	0.017	0.138
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	1	0.3	0.2	0.18	0.121	0.017	0.121

Tabela B.28: Valores dos critérios de efetividade para a imagem LNDSC070.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	28	0.127	0.0	0.04	0.0	0.1	0.3
Vcc cubo RGB Métrica L_2	18	0.092	0.05	0.04	0.0	0.1	0.5
Vcc cubo RGB Métrica L_∞	27	0.329	0.0	0.02	0.0	0.1	0.3
Histograma cubo RGB Métrica L_1 4 bins	38	0.168	0.0	0.02	0.0	0.1	0.3
Histograma cubo RGB Métrica L_2 4 bins	33	0.31	0.0	0.02	0.0	0.1	0.1
Histograma cubo RGB Métrica L_∞ 4 bins	31	0.374	0.0	0.02	0.0	0.1	0.1
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	10	0.324	0.05	0.04	0.1	0.1	0.2
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	11	0.292	0.05	0.04	0.0	0.1	0.2
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	22	0.284	0.0	0.04	0.0	0.1	0.2

Tabela B.29: Valores dos critérios de efetividade para a imagem NRTHL029.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1324	0.271	0.0	0.0	0.0	0.25	0.0
Vcc cubo RGB Métrica L_2	2679	0.543	0.0	0.0	0.0	0.25	0.0
Vcc cubo RGB Métrica L_∞	2544	0.55	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_1 4 bins	1431	0.326	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_2 4 bins	2348	0.458	0.0	0.0	0.0	0.25	0.0
Histograma cubo RGB Métrica L_∞ 4 bins	3149	0.552	0.0	0.0	0.0	0.25	0.0
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	4	0.214	0.1	0.04	0.25	0.25	0.5
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	5	0.27	0.1	0.04	0.0	0.25	0.5
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	32	0.247	0.0	0.02	0.0	0.25	0.5

Tabela B.30: Valores dos critérios de efetividade para a imagem NRTHL073.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	4	0.004	0.15	0.06	0.25	0.25	1.0
Vcc cubo RGB Métrica L_2	5	0.003	0.1	0.08	0.0	0.25	1.0
Vcc cubo RGB Métrica L_∞	6	0.009	0.05	0.04	0.0	0.25	0.75
Histograma cubo RGB Métrica L_1 4 bins	7	0.009	0.05	0.04	0.0	0.25	0.75
Histograma cubo RGB Métrica L_2 4 bins	24	0.022	0.0	0.04	0.0	0.25	0.5
Histograma cubo RGB Métrica L_∞ 4 bins	25	0.026	0.0	0.02	0.0	0.25	0.5
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	3	0.0	0.2	0.08	0.5	0.25	1.0
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	3	0.001	0.2	0.08	0.5	0.25	1.0
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	3	0.002	0.15	0.08	0.25	0.25	1.0

Tabela B.31: Valores dos critérios de efetividade para a imagem NRTHN076.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.148	0.1	0.06	0.182	0.182	0.273
Vcc cubo RGB Métrica L_2	1	0.283	0.15	0.08	0.182	0.091	0.364
Vcc cubo RGB Métrica L_∞	3	0.135	0.1	0.04	0.182	0.091	0.182
Histograma cubo RGB Métrica L_1 4 bins	1	0.152	0.1	0.06	0.182	0.182	0.273
Histograma cubo RGB Métrica L_2 4 bins	1	0.152	0.1	0.04	0.182	0.091	0.182
Histograma cubo RGB Métrica L_∞ 4 bins	2	0.151	0.1	0.04	0.182	0.182	0.182
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.302	0.1	0.04	0.182	0.182	0.273
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.313	0.1	0.04	0.091	0.091	0.273
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	9	0.312	0.05	0.04	0.091	0.091	0.182

Tabela B.32: Valores dos critérios de efetividade para a imagem NRTHN082.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	178	0.382	0.0	0.0	0.0	0.021	0.0
Vcc cubo RGB Métrica L_2	142	0.449	0.0	0.0	0.0	0.021	0.0
Vcc cubo RGB Métrica L_∞	400	0.524	0.0	0.0	0.0	0.021	0.0
Histograma cubo RGB Métrica L_1 4 bins	352	0.37	0.0	0.0	0.0	0.021	0.0
Histograma cubo RGB Métrica L_2 4 bins	474	0.492	0.0	0.0	0.0	0.021	0.0
Histograma cubo RGB Métrica L_∞ 4 bins	585	0.543	0.0	0.0	0.0	0.021	0.0
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	159	0.382	0.0	0.0	0.0	0.021	0.0
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	148	0.389	0.0	0.0	0.0	0.021	0.0
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	194	0.341	0.0	0.0	0.0	0.021	0.0

Tabela B.33: Valores dos critérios de efetividade para a imagem SHTLE050.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.11	0.4	0.2	0.421	0.421	0.526
Vcc cubo RGB Métrica L_2	1	0.21	0.25	0.1	0.263	0.105	0.421
Vcc cubo RGB Métrica L_∞	2	0.234	0.3	0.16	0.316	0.316	0.474
Histograma cubo RGB Métrica L_1 4 bins	1	0.136	0.4	0.2	0.421	0.421	0.526
Histograma cubo RGB Métrica L_2 4 bins	1	0.213	0.4	0.16	0.421	0.421	0.474
Histograma cubo RGB Métrica L_∞ 4 bins	1	0.235	0.25	0.14	0.263	0.211	0.421
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.06	0.15	0.14	0.158	0.158	0.474
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	2	0.139	0.15	0.06	0.158	0.053	0.263
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	2	0.165	0.1	0.06	0.105	0.053	0.211

Tabela B.34: Valores dos critérios de efetividade para a imagem Statu086.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	1	0.378	0.05	0.02	0.007	0.007	0.007
Vcc cubo RGB Métrica L_2	1	0.345	0.15	0.16	0.116	0.007	0.068
Vcc cubo RGB Métrica L_∞	1	0.402	0.05	0.02	0.007	0.007	0.007
Histograma cubo RGB Métrica L_1 4 bins	1	0.389	0.05	0.02	0.021	0.007	0.007
Histograma cubo RGB Métrica L_2 4 bins	1	0.41	0.05	0.02	0.007	0.007	0.007
Histograma cubo RGB Métrica L_∞ 4 bins	1	0.421	0.05	0.02	0.007	0.007	0.007
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	1	0.36	0.05	0.02	0.027	0.007	0.021
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	1	0.335	0.05	0.04	0.068	0.007	0.041
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	1	0.27	0.05	0.06	0.055	0.007	0.034

Tabela B.35: Valores dos critérios de efetividade para a imagem TDYBR015.jpg utilizando cubo RGB 64 cores.

Modelo	$Rank_1$	\widetilde{Rank}	$P(20)$	$P(50)$	$P(N_R)$	$R_{P(0.5)}$	$R(100)$
Vcc cubo RGB Métrica L_1	285	0.337	0.0	0.0	0.0	0.091	0.0
Vcc cubo RGB Métrica L_2	182	0.296	0.0	0.0	0.0	0.091	0.0
Vcc cubo RGB Métrica L_∞	58	0.409	0.0	0.0	0.0	0.091	0.091
Histograma cubo RGB Métrica L_1 4 bins	235	0.351	0.0	0.0	0.0	0.091	0.0
Histograma cubo RGB Métrica L_2 4 bins	56	0.409	0.0	0.0	0.0	0.091	0.091
Histograma cubo RGB Métrica L_∞ 4 bins	164	0.438	0.0	0.0	0.0	0.091	0.0
Coesão cubo RGB Métrica L_1 4 bins 4-conexo	308	0.467	0.0	0.0	0.0	0.091	0.0
Coesão cubo RGB Métrica L_2 4 bins 4-conexo	559	0.499	0.0	0.0	0.0	0.091	0.0
Coesão cubo RGB Métrica L_∞ 4 bins 4-conexo	488	0.523	0.0	0.0	0.0	0.091	0.0

Tabela B.36: Valores dos critérios de efetividade para a imagem Wshdc017.jpg utilizando cubo RGB 64 cores.

Bibliografia

- [Bim99] Alberto Del Bimbo. *Visual Information Retrieval*. Morgan Kaufmann, San Francisco, CA, 1999.
- [CC99] A. Celentano e S. Chiereghin. Multiple strategies for relevance feedback in image retrieval. Relatório Técnico CS-99-8, Department of Computer Science, Ca' Foscari University, Venice, 1999.
- [CMA⁺97] Chialin Chang, Bongki Moon, Anurag Acharya, Carter Shock, Alan Sussman, e Joel Saltz. Titan: a high-performance remote-sensing database. Em *Proceedings of the Thirteenth International Conference on Data Engineering*, Birmingham, U.K., 1997.
- [Dim99] Alexander Dimai. Assessment of effectiveness of content based image retrieval systems. Em *Visual Information and Information Systems*, páginas 525–532, 1999.
- [dVC02] Luis Mariano del Val Cura. *Um modelo para recuperação por conteúdo de imagens de sensoriamento remoto*. Tese de Doutorado, Universidade Estadual de Campinas, 2002.
- [EG99] J. Eakins e M. Graham. Content-based image retrieval: A report to the jisc technology applications programme. Relatório Técnico, Institute for Image Data Research, University of Northumbria at Newcastle., 1999.
- [FR98] Adrian Ford e Alan Roberts. Colour space conversions. disponível em <http://www.poynton.com/PDFs/coloureq.pdf>, 1998.
- [FSN⁺95] M. Flicker, H. Sawhney, W. Niblack, J. Ashley, Q. Huang, B. Dom, M. Gorokani, J. Hafner, D. Lee, D. Petkovic, D. Steele, e P. Yanker. Query by image and video content: The qbic system. *IEEE Computer*, 28(9):23–32, 1995.
- [FW00] Ronald Fagin e Edward L. Wimmers. A formula for incorporating weights into scoring rules. *Theoretical Computer Science*, 239(2):309–338, 2000.

- [GG98] Volker Gaede e Oliver Günther. Multidimensional access methods. *ACM Computing Surveys*, 30(2):170–231, 1998.
- [GR95a] Venkat N. Gudivada e Vijay V. Raghavan. Content-based image retrieval systems. *IEEE Computer*, 28(9):18–22, 1995.
- [GR95b] Venkat N. Gudivada e Vijay V. Raghavan. Content-based image retrieval systems. *IEEE Computer*, 28(9):18–22, 1995.
- [GW93] Rafael C. Gonzalez e Richard E. Woods. *Digital Image Processing*. addison-Wesley, 1993.
- [HKM⁺97] J. Huang, S. Kumar, M. Mitra, W. Zhu, e R. Zabih. Image indexing using color correlograms. Em *IEEE Conference on Computer Vision and Pattern Recognition (CVPR '97)*, páginas 762–768, 1997.
- [Hol79] Sture Holm. A simple sequentially rejective multiple test procedure. *scandinavian journal of statistics theory and applications*, 6:65–70, 1979.
- [HSD73] R M Haralick, K S Shanmugan, e I Dunstein. Textural features for image classification. *IEEE Trans. SMC*, 3(6):610–621, 1973.
- [LM01] L. Lucchese e S.K. Mitra. Color image segmentation: A state-of-the-art survey. Em *Image Processing, Vision, and Pattern Recognition, Proceedings of the Indian National Science Academy (INSA-A)*, volume 67, A, 2, páginas 207–221, 2001.
- [Lon98] S. Loncaric. A survey of shape analysis techniques. *Pattern Recognition*, 31(8):983–1001, 1998.
- [LOT94] Hongjun Lu, Beng Chin Ooi, e Kian-Lee Tan. Efficient image retrieval by color contents. Em *Applications of Databases*, páginas 95–108, 1994.
- [MMS⁺01] Henning Müller, Wolfgang Müller, David McG. Squire, Stéphane Marchand-Maillet, e Thierry Pun. Performance evaluation in content-based image retrieval: Overview and proposals. *Pattern Recognition Letters*, 22(5):593–601, 2001. (special issue on Image/Video Indexing and Retrieval).
- [Mot95] Harvey Motulsky. *Intuitive Biostatistics*. Oxford University Press Inc., 1995.
- [MS83] M. J. McGill e Gerard Salton. *Introduction to Modern Information Retrieval*. McGraw-Hill, New York, NY, 1983.

- [ORC⁺98] Michael Ortega, Yong Rui, Kaushik Chakrabarti, Kriengkrai Porkaew, Sharad Mehrotra, e Thomas S. Huang. Supporting ranked boolean similarity queries in MARS. *Knowledge and Data Engineering*, 10(6):905–925, 1998.
- [Poy98] C. Poynton. Frequently asked questions about color. disponível em <http://www.poynton.com/ColorFAQ.html>., 1998.
- [PZM96] Greg Pass, Ramin Zabih, e Justin Miller. Comparing images using color coherence vectors. Em *ACM Multimedia*, páginas 65–73, 1996.
- [RHC97] Yong Rui, Thomas S. Huang, e Shih-Fu Chang. Image retrieval: Past, present, and future. Em *International Symposium on Multimedia Information Processing*, volume 10, páginas 1–23, 1997.
- [RHMO97] Y. Rui, T. Huang, S. Mehrotra, e M. Ortega. A relevance feedback architecture in content-based multimedia information. Em *IEEE Workshop on Content-Based Access of Image and Video Libraries*, páginas 82–89, 1997.
- [Rub99] Yossi Rubner. Perceptual metrics for image database navigation. Relatório Técnico CS-TR-99-1621, Stanford University, Department of Computer Science, 1999.
- [SB91] Michael J. Swain e Dana H. Ballard. Color indexing. *International Journal of Computer Vision*, 7(1):11–32, 1991.
- [SBK⁺98] C. Shyu, C. Brodley, A. Kak, A. Kosaka, A. Aisen, e L. Broderick. Local versus global features for content-based image retrieval. Em *IEEE workshop on content-based access of image and video libraries*, páginas 30–34, 1998.
- [Sha95] Juliet Popper Shaffer. Multiple hypothesis testing.[review]. *Annual Review of Psychology*, 46:561–584, 1995.
- [SJ96] S. Santini e R. Jain. Similarity matching. *Lecture Notes in Computer Science*, 1035:571–??, 1996.
- [Smi02] John R. Smith. *Color for Image Retrieval*, capítulo 11, páginas 285–311. Wiley-Interscience, 2002.
- [SNF02] Renato O. Stehling, Mario A. Nascimento, e Alexandre X. Falcão. A compact and efficient image retrieval approach based on border/interior pixel classification. Em *Proceedings of the eleventh international conference on Information and knowledge management*, páginas 102–109. ACM Press, 2002.

- [SO95] Markus A. Stricker e Markus Orengo. Similarity of color images. Em *Storage and Retrieval for Image and Video Databases (SPIE)*, páginas 381–392, 1995.
- [VC00] Colin Venters e Matthew Cooper. A review of content-based image retrieval. Relatório Técnico jtap-054, Manchester Visualization Centre, Manchester Computing, University of Manchester, 2000.
- [vR79] C. J. van Rijsbergen. *Information Retrieval*. 2nd ed., Butterworths, 1979.
- [Zar84] Jerrold H. Zar. *Biostatistical Analysis*. Prentice-Hall, Inc., 1984.