



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Tecnologia

Queila Valentim Martins de Souza Teixeira

**Análise de imagens de folhas de tabaco
afetadas por CVC via técnicas de
Ranqueamento e Re-ranqueamento**

**Analysis of tobacco leaves affected by CVC via
Ranking and Re-ranking techniques**

Limeira/SP

2018



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Tecnologia

Queila Valentim Martins de Souza Teixeira

Análise de imagens de folhas de tabaco afetadas por CVC via técnicas de Ranqueamento e Re-ranqueamento

Dissertação apresentada à Faculdade de Tecnologia da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestra em Tecnologia, na Área de Tecnologia e Inovação.

Orientador: Prof. Dr. Marco Antonio Garcia de Carvalho

Este exemplar corresponde à versão final da dissertação defendida pela aluna Queila Valentim Martins de Souza Teixeira, e orientada pelo Prof. Dr. Marco Antonio Garcia de Carvalho

Limeira/SP

2018

Agência(s) de fomento e nº(s) de processo(s): Não se aplica.

ORCID: <https://orcid.org/0000-0003-3993-5949>

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Faculdade de Tecnologia
Felipe de Souza Bueno - CRB 8/8577

T235a Teixeira, Queila Valentim Martins de Souza, 1981-
Análise de folhas de tabaco afetadas por CVC via técnicas de
ranqueamento e re-ranqueamento / Queila Valentim Martins de Souza Teixeira.
– Limeira, SP : [s.n.], 2018.

Orientador: Marco Antonio Garcia de Carvalho.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade
de Tecnologia.

1. Recuperação de imagens baseada em conteúdo. 2. Ranqueamento. 3.
Re-ranqueamento. 4. Descritor de imagem. 5. Análise de textura. I. Carvalho,
Marco Antonio Garcia de, 1970-. II. Universidade Estadual de Campinas.
Faculdade de Tecnologia. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Analysis of tobacco leaves affected by CVC via ranking and re-ranking techniques

Palavras-chave em inglês:

Content-based image retrieval

Ranking

Re-ranking

Image descriptor

Texture analysis

Área de concentração: Tecnologia e Inovação

Titulação: Mestra em Tecnologia

Banca examinadora:

Marco Antonio Garcia de Carvalho [Orientador]

Leandro Nunes de Castro Silva

Guilherme Palermo Coelho

Data de defesa: 23-02-2018

Programa de Pós-Graduação: Tecnologia

FOLHA DE APROVAÇÃO

Abaixo se apresentam os membros da comissão julgadora da sessão pública de defesa de dissertação para o Título de Mestre em Tecnologia na área de concentração de Tecnologia e Inovação, a que submeteu a aluna Queila Valentim Martins de Souza Teixeira, em 23 de fevereiro de 2018 na Faculdade de Tecnologia- FT/ UNICAMP, em Limeira/SP.

Prof. Dr. Marco Antonio Garcia de Carvalho

Presidente da Comissão Julgadora

Prof. Dr. Leandro Nunes de Castro Silva

Universidade Presbiteriana Mackenzie

Prof. Dr. Guilherme Palermo Coelho

Faculdade de Tecnologia – Universidade Estadual de Campinas

A Ata da defesa com as respectivas assinaturas dos membros encontra-se no processo de vida acadêmica do aluno na Universidade.

Dedico essa dissertação a meu esposo Daniel, que me incentivou em todos momentos desta jornada. Dedico também aos meus pais Almyr e Suely, que me ensinaram a perseverar para conseguir alcançar meus sonhos e que serão sempre meus modelos de fé.

*“A esperança é o sonho do homem acordado”
(Aristóteles)*

Agradecimentos

Agradeço primeiramente a Deus pelo sustento durante todo este processo, pela saúde para prosseguir, por me ouvir nos momentos difíceis e pelas pessoas especiais que colocou em meu caminho.

Ao meu esposo Daniel agradeço pelo sustento emocional, por sua paciência, compreensão, patrocínio e cuidado constantes. Agradeço por ajudar-me a crer que meu sonho era possível. Sem ele, certamente eu não teria chegado ao fim deste projeto de mestrado.

Às minhas irmãs Quézia e Quênia, por serem as amigas especiais que Deus me deu desde cedo para compartilhar a vida. À minha sobrinha Isabela, por ter iluminado meus dias com seu sorriso. A meu pai Almyr, por ser meu grande modelo de caráter e por ter sempre palavras de encorajamento. À minha mãe Suely, por ter me ensinado através de seu exemplo que na vida é necessário ser resiliente para vencer.

Aos meus colegas do grupo ImageLab, por me inspirarem durante todo o decorrer do trabalho. Em especial ao Kauê, que tornou-se um amigo, por oferecer ajuda e compartilhar seu conhecimento com todos sem esperar nada em troca.

À empresa em que trabalho, a IBM. A todos os gerentes que permitiram que eu me ausentasse para assistir as aulas e que me estimularam a estudar, a aprender e a crescer. Em especial agradeço aos amigos Grazielle, Marcus e Thiago, que tantas vezes me ouviram nessa trajetória.

Aos meus amigos da Igreja Batista Central de Campinas, pelos conselhos, risadas e pelo encorajamento. Em especial agradeço aos amigos Marcos, Marlúcia, Márcio, Milene, Ana, Marco Antônio, Fernando e Ana Rafaela.

À minha equipe de natação, aos técnicos e colegas desse esporte que foi uma terapia durante todos estes anos. Em especial à minha amiga Arleine, minha companheira de treinos, pela sua alegria e cuidado para comigo.

Ao meu orientador, Prof. Dr. Marco Antonio Garcia de Carvalho, pela paciência, direção e disponibilidade para ajudar-me. Lembro-me da importância de suas reuniões de acompanhamento, às quais compareci muitas vezes desanimada, mas das quais saí com esperança e motivação para continuar a trabalhar em meu projeto.

Ao prof. Dr. Paulo Martins Pedro, pelo auxílio em minha caminhada. Ao prof. Dr. André Franceschi de Angelis, pelos conselhos durante minha vida acadêmica. Ao prof. Dr. Daniel Carlos Guimarães Pedronette, por compartilhar seu conhecimento comigo

e também pela disponibilidade em responder às minhas dúvidas técnicas. Ao Willian Eduardo Lino Pereira do Instituto Agrônomo de Campinas, por compartilhar as imagens de seu trabalho de pesquisa, as quais foram parte importante para o desenvolvimento deste projeto.

À Faculdade de Tecnologia da Unicamp, onde estudei na graduação e fui aceita para o mestrado. A todos os amigos que ali encontrei, em especial agradeço à amiga Karen Macedo pelas conversas, pela compreensão e por ser uma inspiração para mim como mulher e pesquisadora.

Por fim, a todos os familiares e amigos que, direta ou indiretamente, contribuíram para que eu continuasse firme em meus propósitos.

Resumo

A Clorose Variegada dos Citros (CVC) é uma doença que afeta boa parte da produção de citros no Brasil, provocando expressivo prejuízo econômico à agricultura. Usualmente, é necessário conhecer o grau dessa doença na cultura de citros a fim de identificar o melhor tratamento. A análise de textura das folhas das plantas infectadas por meio de técnicas de processamento digital de imagens consiste em uma importante abordagem para análise do grau de comprometimento da cultura afetada pela CVC. Este trabalho propõe uma abordagem de análise de folhas de tabaco através do ranqueamento de imagens, uma técnica importante da área de *Content-Based Image Retrieval* (CBIR). Os ranqueamentos são calculados a partir de duas funções de distância, a Euclidiana e a de Canberra. As imagens são analisadas através de três descritores de textura: GLCM, LBP e *Haralick*. Com o intuito de melhorar os resultados obtidos foi aplicado um algoritmo de aprendizado não-supervisionado, o RL-Sim (*RankedLists-Similarities*), que consiste na obtenção de um novo ranqueamento a partir daquele inicialmente calculado. Experimentos foram realizados utilizando um conjunto de imagens cedido pelo Instituto Agrônomo de Campinas (IAC). A performance dos métodos propostos é comparada à classificação manual realizada, de acordo com o grau de infecção da planta. Os resultados experimentais demonstram que a abordagem proposta atingiu níveis de eficiência da ordem de 37,33% a 48,37% de acordo com a métrica *Precision*, indicando a necessidade de novos estudos a fim de tornar esta abordagem totalmente adequada ao auxílio da análise de folhas de plantas infectadas.

Palavras-chaves: CBIR; Ranqueamento; Re-ranqueamento; Descritores de Imagem; Análise de Textura.

Abstract

The Citrus Variegated Chlorosis (CVC) affects a significant part of citrus production in Brazil and causes expressive economic loss to agriculture. Usually, it is necessary to know the degree of this disease in the citrus to identify the best and correct treatment. The texture analysis of the leaves of infected plants by means of digital image processing techniques is an important method to analyze the degree of impairment affected by CVC. This paper proposes an approach to analyze tobacco leaves using image ranking, an important technique from the Content-Based Image Retrieval (CBIR) domain. Rankings are computed through two distance functions: Euclidean and Canberra. The images are analyzed by using three texture descriptors: GLCM, LBP and Haralick. With the intention of improving the retrieved results, an unsupervised distance learning algorithm was applied, the RL-Sim (*RankedLists-Similarities*), which consists in obtaining a new ranking from the one that was initially computed. Experiments were performed using a set of images provided by the Instituto Agronômico de Campinas (IAC). The performance of the methods is compared to the manual image classification, according to the degree of CVC infection. Experiment results demonstrate that the proposed approach achieved efficiency levels from 37,33% to 48,37% according to the Precision metric, which indicates the need of new studies to make sure this approach is totally proper to be used as an assistance to the analysis of infected plant leaves.

Keywords: CBIR; Ranking; Re-ranking; Image Descriptors; Texture Analysis.

Lista de ilustrações

Figura 1 – Níveis sintomáticos de folhas infectadas: (a) estágio inicial de infecção; (b) estágio final de infecção.	15
Figura 2 – Exemplos de Arquiteturas de um sistema de recuperação de imagem por conteúdo (CBIR): (a) Arquitetura apresentada em (ANDALO <i>et al.</i> , 2007); (b) Arquitetura do sistema CBIR deste trabalho.	23
Figura 3 – Ilustração do cálculo do LBP: (a) Análise de uma imagem em tons de cinza, considerando uma vizinhança 3x3 ao redor do <i>pixel</i> central; (b) Vizinhança limiarizada pelo valor do <i>pixel</i> central gerando matriz com valores binários; (c) Cada <i>pixel</i> de vizinhança (V_i) adquire o valor (E_i), sendo o seu valor '0', se estiver abaixo do valor do <i>pixel</i> central (V_0), senão adquire o valor '1' se for igual ou maior que o valor do <i>pixel</i> central; (d) Valores dos <i>pixels</i> na vizinhança limiarizada são multiplicados por uma matriz de pesos (VIEIRA, 2013).	26
Figura 4 – Exemplo de uma matriz que usa $L=8$ e direção 0° com 1 <i>pixel</i> de distância. À esquerda, encontra-se a imagem f e à direita sua matriz de co-ocorrência p (GONZALEZ; WOODS, 2001).	27
Figura 5 – Exemplos de representação espacial de funções de distância em um espaço bidimensional: (a) L_1 ; (b) L_2 ; (c) L_∞	30
Figura 6 – Cubo do modelo RGB (CATTIN, 2016).	32
Figura 7 – Canais de cor do modelo RGB: (a) Imagem colorida original; (b) <i>Red</i> (Vermelho); (c) <i>Green</i> (Verde); (d) <i>Blue</i> (Azul) (CATTIN, 2016).	32
Figura 8 – Diagrama de cromaticidade xyY (ADOBE, 2017).	34
Figura 9 – Diagrama de cromaticidade xyY em três dimensões (ADOBE, 2017).	35
Figura 10 – Modelo de cor CIELab (ADOBE, 2017).	36
Figura 11 – Evolução dos ranqueamentos através de diversas iterações (PEDRONETTE; TORRES, 2012a).	41
Figura 12 – Diagrama que apresenta uma visão geral do algoritmo RL-Sim.	43
Figura 13 – Métrica de Intersecção (PEDRONETTE; TORRES, 2013).	46
Figura 14 – Escala diagramática utilizada para avaliação das imagens de folha de tabaco afetadas por CVC. Cada imagem de folha na escala representa uma nota de grau de infecção, numa escala de 1 a 6 (PEREIRA <i>et al.</i> , 2014).	51
Figura 15 – Exemplo de imagem cedida pelos pesquisadores do Centro de Citricultura Sylvio Moreira.	51

Figura 16 – Diagrama de blocos que ilustra a metodologia proposta.	52
Figura 17 – Amostras de imagens de folhas afetadas por CVC. (a) Amostra original, com três imagens de folhas infectadas; (b) Amostra de imagem recortada, com apenas uma imagem de folha.	53
Figura 18 – Resultados da fase de binarização. (a) imagem após processo de binarização; (b) imagem com região da folha em tons de cinza e background preto, obtida através de imagem binarizada.	54
Figura 19 – Resultados da fase de seleção de canais de cores. (a) Imagem em tons de cinza; (b) imagem em canal de cor verde; (c) imagem em canal de cor vermelho.	55
Figura 20 – Resultados da fase de seleção de canais de cores. (a) Imagem em tons de cinza; (b) imagem em canal de cor verde; (c) imagem em canal de cor vermelho.	56
Figura 21 – Exemplo de resultado da fase de extração de regiões. (a) imagem que mostra a seleção da área que será recortada na imagem da folha; (b) região extraída da imagem da folha.	57
Figura 22 – Resultados da fase de execução do cálculo do LBP na região da imagem da folha. (a) imagem antes da execução do cálculo de LBP; (b) imagem gerada após execução do cálculo de LBP.	58
Figura 23 – Diagrama que ilustra o processamento de ranqueamento.	59
Figura 24 – Exemplo de imagem de folha descartada da coleção utilizada nos experimentos de avaliação.	63
Figura 25 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor RGB; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.	69
Figura 26 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor CIELab; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.	70
Figura 27 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco no modelo de cor RGB.	72

Figura 28 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco no modelo de cor CIELab.	73
Figura 29 – Visualização dos ranqueamentos do conjunto Haralick-a-Euclidiana, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.	75
Figura 30 – Visualização dos ranqueamentos do conjunto LBP-Red-Euclidiana, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.	76
Figura 31 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor RGB; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.	82
Figura 32 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor CIELab; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.	83
Figura 33 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco denotadas com grau de infecção de CVC e no modelo de cor RGB.	86
Figura 34 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco denotadas com grau de infecção de CVC e no modelo de cor CIELab.	86
Figura 35 – Visualização dos ranqueamentos do conjunto LBP-TC-Canberra, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.	88
Figura 36 – Visualização dos ranqueamentos do conjunto LBP-L-Euclidiana, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.	89

Lista de Acrônimos e Abreviações

- CBIR *Content-Based Image Retrieval*
- CIELab *Commission Internationale de l'Eclairage L*a*b**
- CVC Clorose Variegada dos Citros
- FCTH *Fuzzy Color and Texture Histogram*
- GLCM *Gray-Level Cooccurrence Matrix*
- HSV *Hue, Saturation, Value*
- IAC Instituto Agronômico de Campinas
- LAS *Local Activity Spectrum*
- LBP *Local Binary Patterns*
- P-10 Precisão entre as 10 primeiras posições
- P-5 Precisão entre as 5 primeiras posições
- PDI Processamento Digital de Imagens
- PIBE *Personalizable Image Browser Engine*
- QBIC *Query by Image Content*
- RGB *Red, Green, Blue*
- RL-Sim *RankedLists-Similarities*
- RNA PMC Redes Neurais Artificiais *Perceptron* Multicamadas

Sumário

1	Introdução	15
1.1	Desafios	17
1.2	Objetivos	18
1.3	Contribuições	18
1.4	Organização do Trabalho	18
2	Estado da Arte	19
2.1	Fundamentação Teórica	19
2.1.1	Recuperação de Imagem por Conteúdo	19
2.1.2	Sistemas CBIR	20
2.1.2.1	Arquitetura de Sistemas CBIR	22
2.2	Descritores de Imagem	24
2.2.1	Descritores de Textura	25
2.2.1.1	Local Binary Pattern (LBP)	25
2.2.1.2	Gray-Level Co-Occurrence Matrix (GLCM)	26
2.2.1.3	Haralick	28
2.3	Funções de Similaridade e Distância	28
2.4	Modelos de representação de cores	31
2.4.1	Modelo RGB	31
2.4.2	Modelo CIEXYZ	33
2.4.3	Modelo CIELab	35
2.4.4	Conversão de Cores	37
2.5	Ranqueamento de Imagens	39
2.6	Re-ranqueamento de Imagens	40
2.6.1	Tipos de Abordagem de Re-ranqueamento	42
2.6.1.1	O Algoritmo RL-Sim	42
2.7	Trabalhos Relacionados	46
2.7.1	Trabalhos Relacionados à Análise de folhas infectadas por doenças	46
2.7.2	Trabalhos Relacionados a Ranqueamento e Re-ranqueamento	48
3	Ranqueamento e Re-ranqueamento de Folhas de Tabaco - Abordagem pro- posta	50
3.1	Descrição da coleção de imagens	50
3.2	Metodologia	51
3.2.1	Pré-Processamento	52
3.2.1.1	Recorte de imagens	53

3.2.1.2	Binarização de imagens	53
3.2.1.3	Conversão de modelo de cor RGB para CIELab	54
3.2.1.4	Seleção de Canais de Cores	55
3.2.1.5	Extração de regiões de interesse	56
3.2.2	Extração de Características	57
3.2.2.1	Extração de Características com o descritor LBP	57
3.2.2.2	Extração de Características com o descritor GLCM	58
3.2.2.3	Extração de Características com o descritor de Haralick	58
3.2.3	Ranqueamento	58
3.2.4	Re-ranqueamento	60
4	Experimentos, Resultados e Discussões	62
4.1	Protocolo Experimental	62
4.2	Experimentos realizados com o <i>dataset</i> completo	64
4.2.1	Seleção dos Conjuntos de descritores, canal de cor e função de distância	64
4.2.2	Efeitos da variação do parâmetro k do RL-Sim	68
4.2.3	Melhores Cenários	72
4.3	Experimentos realizados com imagens do <i>Dataset</i> denotadas de acordo com seu grau de infecção de CVC	77
4.3.1	Seleção dos Conjuntos de descritores, canal de cor e função de distância	77
4.3.2	Efeitos da variação do parâmetro k do RL-Sim	81
4.3.3	Melhores Cenários	85
4.4	Análise de resultados	90
5	Conclusões	92
	Referências	95
	Apêndice	100
	A Artigos	101

1 Introdução

A bactéria *Xylella fastidiosa* atualmente representa a causa de perdas significativas na produção de frutas como a uva, o pêsego, a ameixa e a laranja (PEREIRA *et al.*, 2014). Devido a tais perdas, tem sido objeto constante de estudo por pesquisadores da área agrícola que, através de experimentos, procuram entender os sintomas associados à doença provocada pela bactéria, assim como encontrar meios para combatê-la.

No Brasil, a bactéria afeta principalmente as plantações de laranja doce, causando a propagação da Clorose Variegada dos Citros (CVC), doença que gera anomalias nas folhas da fruta, como alteração de tamanho e lesões de cor laranja escuro (LOPES *et al.*, 2000). Os sintomas evoluem para necroses e abscisão foliar, morte de ramos e declínio no vigor das plantas. Assim, a CVC reduz a produção de frutos, já que estes ficam atrofiados, endurecidos e com maturação irregular. Como consequência, tornam-se inadequados para a comercialização (ROSSETTI; NEGRI, 1990).

Pesquisadores do Centro de Citricultura Sylvio Moreira, vinculado ao Instituto Agrônomo de Campinas, têm focado parte de sua pesquisa no estudo de sintomas da colonização de *Xylella fastidiosa*, procurando identificar os diferentes níveis sintomáticos existentes. Para esta pesquisa, têm utilizado folhas de Tabaco, visto que experimentos artificiais demonstram que esta planta, quando infectada, apresenta sintomas em um período menor que o da laranja doce. A Figura 1 apresenta exemplos de níveis sintomáticos de folhas infectadas, cujo registro foi feito no Centro de Citricultura Sylvio Moreira no ano de 2015.

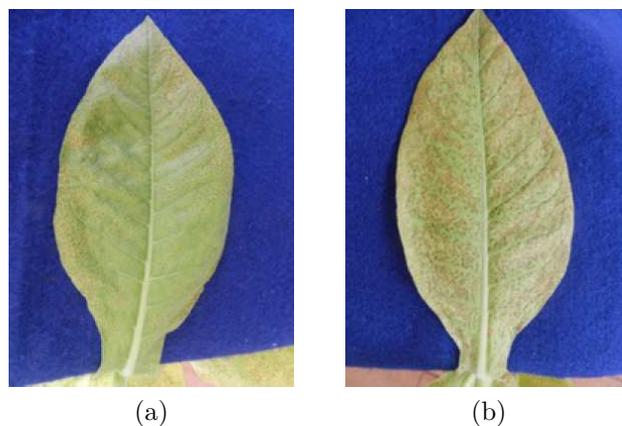


Figura 1 – Níveis sintomáticos de folhas infectadas: (a) estágio inicial de infecção; (b) estágio final de infecção.

Com o intuito de analisar as folhas de tabaco infectadas pela bactéria, pes-

quisadores do Centro de Citricultura Sylvio Moreira empregaram técnicas de análise e processamento de imagens por meio do *software ImageJ*. No entanto, dada a necessidade de analisar cada imagem de folha individualmente, o processo tornou-se dispendioso, pois demandava muito tempo e esforço dos pesquisadores. Além disso, como o *software* utilizado não continha informações específicas sobre o problema em questão, os resultados obtidos poderiam não ser precisos e robustos.

Neste cenário surge então a necessidade de encontrar alternativas para realizar a análise e classificação automática das imagens de folhas. Diversas opções podem ser encontradas na literatura atualmente, algumas das quais pertencentes às áreas de Processamento de Imagens e Visão Computacional. No entanto, antes de explanar mais sobre as teorias e técnicas apresentadas em tais áreas, é necessário entender qual a importância do uso de imagens como representação daquilo que o ser humano vê.

Por apresentarem riquezas de detalhes, imagens muitas vezes são capazes de descrever cenas melhor do que dados apenas textuais e, graças ao avanço da tecnologia, cada vez mais têm surgido dispositivos para armazená-las e processá-las rapidamente. Aliado a isso, o crescimento e popularização da Internet proporcionaram um crescimento significativo do número de imagens disponíveis (ANDALO *et al.*, 2007), o que tem motivado o estudo de imagens em diversas áreas: Medicina, Sistemas de Biodiversidade, Bibliotecas digitais e Agricultura (área relacionada à pesquisa feita neste trabalho).

No entanto, conforme cresce o número de coleções de imagens, surge também a necessidade de desenvolver produtos de *software* capazes de gerenciar tais coleções, de modo a possibilitar a recuperação de informações relacionadas às imagens em questão.

Uma das abordagens utilizadas para recuperação de informações de imagens é a baseada em consultas textuais. Porém, esta técnica requer prévia associação de textos às imagens de um banco de dados, o que é uma tarefa muito laboriosa e de grande consumo de tempo (TORRES; FALCAO, 2006). Em outra abordagem, a de Recuperação de imagens por conteúdo (*Content-Based Image Retrieval* – CBIR), a busca de informações sobre uma imagem é baseada no próprio conteúdo visual desta. Tal busca é possível através da utilização de descritores, métodos capazes de extrair características relacionadas à cor, textura e forma de uma imagem.

O uso de descritores possibilita, por exemplo, que sejam criadas listas de imagens ordenadas de acordo com critérios predeterminados, processo conhecido como Ranqueamento. Dada sua relevância na área de Processamento Digital de Imagens, o ranqueamento tem sido um assunto bastante pesquisado, o que tem levado à descoberta de novas abordagens. Entre elas, surge o Re-ranqueamento, processo que analisa a similaridade de imagens de diversas listas ranqueadas e cria então listas ranqueadas melhores, ou seja,

aumenta a eficácia dos ranqueamentos existentes.

Portanto, devido às possibilidades apresentadas pelos métodos de sistemas CBIR para a recuperação e organização de imagens, propõe-se neste trabalho o estudo do uso de tais técnicas para abordar o desafio de automatizar a análise e processamento de imagens de folhas de tabaco afetadas por CVC. Serão discutidos os principais conceitos e técnicas relacionados aos sistemas CBIR, as propostas de ranqueamento e re-ranqueamento para a tarefa de classificação de imagens, os experimentos feitos e resultados obtidos através destes. Os principais desafios observados, assim como os objetivos da abordagem proposta são apresentados nas sub-seções a seguir.

1.1 Desafios

Diante do cenário apresentado, diversos desafios de pesquisa ainda estão em aberto, e vários serão discutidos ao longo desse trabalho. Alguns destes desafios são apresentados a seguir:

- O uso de técnicas de sistemas CBIR representa a melhor opção na classificação de imagens de folhas afetadas por doenças?
- Quais características visuais seriam as mais adequadas para a extração de informações de folhas afetadas pela CVC?
- Qual o melhor modelo de cor no que tange à eficiência na extração de características: CIELAB ou RGB?
- O processo de *Re-ranqueamento* apresenta resultados mais eficientes em relação ao ranqueamento comum quando se trata da classificação de imagens de folhas com sintomas de CVC?
- A combinação de descritores pode indicar melhoria na classificação de imagens em relação ao uso individual de descritores?
- As técnicas de CBIR propostas podem ser eficazes na classificação de outras doenças que atingem plantas?

Com base nesses desafios, na próxima seção são apresentados os objetivos para os quais este trabalho irá contribuir.

1.2 Objetivos

Este trabalho tem como objetivo principal a análise e avaliação de métodos de ranqueamento de imagens de folhas de tabaco através do uso de descritores. Entre os descritores propostos, estão o LBP (*Local Binary Pattern*), o GLCM (*Gray-Level Co-Occurrence Matrix*) e o *Haralick*, obtido a partir das matrizes resultantes do GLCM.

Adicionalmente, propõe-se também avaliar o uso dos descritores em imagens de dois modelos de cor: RGB (*Red, Green, Blue*) e CIELab, os quais permitem a divisão dos canais de cores presentes nas imagens do *dataset* disponível.

Finalmente, pretende-se analisar a aplicação de métodos de aprendizado não supervisionado de ranqueamento, a fim de verificar se estes podem aumentar a eficácia dos ranqueamentos gerados.

1.3 Contribuições

Dentre as contribuições deste trabalho, indica-se o pré-processamento realizado em imagens de folhas de tabaco afetadas por CVC, o qual possibilitou posteriormente a extração de características de textura através dos descritores. Complementarmente, é apresentada uma análise comparativa de descritores, além da combinação dos mesmos, aplicada no contexto de ranqueamento das imagens de folhas.

Enfim, considerando-se os desafios e objetivos deste trabalho, ressalta-se como maior contribuição a avaliação do uso de métodos de aprendizado não-supervisionado no suporte à classificação de imagens de folhas de tabaco de acordo com o grau de infecção que apresentam.

1.4 Organização do Trabalho

Este trabalho está organizado nos capítulos a seguir. O Capítulo 2 apresenta conceitos das técnicas que serão utilizadas e a fundamentação teórica, além dos trabalhos relacionados com esta pesquisa. O Capítulo 3 apresenta os métodos propostos no desenvolvimento do trabalho, o que inclui as técnicas utilizadas no pré-processamento de imagens de folhas de tabaco, a aplicação de descritores e o uso de métodos de aprendizado não supervisionados. O Capítulo 4 traz os experimentos realizados, além da discussão dos resultados obtidos pela implementação dos métodos. Finalmente, no capítulo 5 são apresentadas as conclusões e sugestões de trabalhos futuros.

2 Estado da Arte

Neste Capítulo serão descritos os conceitos essenciais para o entendimento deste trabalho, além das referências ao que já foi estudado e proposto sobre os assuntos relacionados a esta pesquisa.

A Seção 2.1 apresenta a teoria relacionada aos Sistemas CBIR, enquanto que a Seção 2.2 explana sobre os Descritores de Imagem e suas aplicações. A Seção 2.3 traz detalhes sobre as Funções de Similaridade e a Seção 2.4 discorre sobre os modelos de cor RGB, CIEXYZ e CIELab. As Seções 2.5 e 2.6 apresentam os conceitos de Ranqueamento e Re-ranqueamento, respectivamente e, por último, a Seção 2.7 apresenta os trabalhos relacionados à metodologia proposta e avaliada neste trabalho.

2.1 Fundamentação Teórica

A área de Processamento Digital de Imagens (PDI) concentra técnicas para a análise de imagens digitais. Esta tem crescido progressivamente, pois viabiliza o desenvolvimento de aplicações de duas categorias: 1) aprimoramento de imagens para interpretação humana e 2) análise automática por computador de informações extraídas de uma cena. Atualmente, aplicações de processamento de imagens têm sido utilizadas em quase todas as áreas: na Medicina, por exemplo, para realização de diagnóstico através do uso de imagens; em Biologia, no processamento automático de imagens obtidas através de microscópios; em Geografia, para a interpretação automática de imagens captadas por satélites (FILHO; NETO, 1999). Assim, devido aos benefícios que a área de processamento de imagens proporciona aos mais diversos setores, tem crescido significativamente o número de pesquisas em PDI com o objetivo de automatizar a extração de dados contidos em imagens, além de otimizar imagens para interpretação e análise humana.

Uma das áreas de pesquisa de PDI é a de Recuperação de Imagens, que se propõe a realizar buscas eficientes em grandes bancos de imagens. Para o desenvolvimento deste trabalho, serão utilizadas técnicas de recuperação e classificação de imagens baseadas em conteúdo, cuja busca é baseada em informações extraídas de cada imagem. A teoria relacionada aos métodos e técnicas que serão utilizados é apresentada nas seções a seguir.

2.1.1 Recuperação de Imagem por Conteúdo

A evolução dos sistemas de armazenamento de dados aliada à diminuição dos custos para aquisição de equipamento para a geração de imagens são dois dos fatores que

explicam o crescimento de grandes coleções de imagens nos últimos anos. Paralelo a esse crescimento, muitos sistemas têm sido desenvolvidos com o objetivo de organizar, buscar, indexar e classificar coleções de imagens de maneira automatizada. Nesse sentido, dois tipos de abordagens têm sido propostas: a recuperação de imagens baseada em informações textuais e a recuperação de imagens baseada em seu conteúdo.

A primeira abordagem consiste em anexar textos (metadados) em cada imagem e utiliza técnicas tradicionais de busca para recuperar imagens através de palavras-chave. Assim, sistemas desse tipo requerem que cada imagem da coleção seja previamente descrita através de anotações, o que é uma tarefa trabalhosa e que consome muito tempo (apesar de existirem também ferramentas automáticas e anotação). Além disso, esse processo de anotação (descrição) das imagens, geralmente mostra-se ineficiente, já que uma imagem pode ser descrita de maneiras diferentes por diversas pessoas (TORRES; FALCAO, 2006).

A segunda abordagem, de Recuperação de imagens por conteúdo (*Content-Based Image Retrieval* - CBIR), surge como solução aos problemas apresentados pela busca textual, já que possibilita a organização de arquivos de imagens através de seu conteúdo visual. O processo de recuperação dos sistemas CBIR realiza buscas em um amplo banco de imagens e retorna aquelas que são visualmente similares a uma imagem de consulta definida por um usuário. Após o processo de busca, as imagens recuperadas são então ordenadas de acordo com seu grau de similaridade em relação à imagem de consulta, gerando um ranqueamento.

2.1.2 Sistemas CBIR

Muitos sistemas CBIR têm sido propostos atualmente. Ainda que alguns tenham desenvolvido produtos comerciais, muitos sistemas foram propostos como protótipos, sendo desenvolvidos em universidades e laboratórios de pesquisa (TORRES; FALCAO, 2006).

Os primeiros sistemas de recuperação de imagens por conteúdo conhecidos são da década de 80: Chang e Fu (CHANG; FU, 1980) descreveram o sistema REDI (*Relational Database System or Images*), desenvolvido na Universidade de Purdue, nos Estados Unidos. REDI continha conjuntos de funções de processamento de imagens capazes de realizar tarefas como medições de textura, detecção de arestas, segmentação e classificação, entre outras. Ademais, apresentava um novo paradigma, definido como “*Query By Pictorial Example*”, o qual permitia a recuperação de imagens através de uma imagem de entrada.

Durante a década de 90, pesquisas relacionadas à recuperação de imagens progrediram, e a IBM lançou o QBIC (*Query by Image Content*). O QBIC utilizava

padrões de cor, forma e textura para recuperar imagens em um banco de dados. Permitia consultas através de imagens de exemplo, e usuários poderiam também definir padrões de formas, selecionar cores ou pré-definir texturas (TORRES; FALCAO, 2006). Para a verificação de similaridade entre as imagens do banco de dados e a imagem de exemplo, o QBIC calculava distâncias Euclidianas ponderadas entre o objeto de consulta e aqueles presentes no banco de dados (ANDALO *et al.*, 2007).

Em 1997, foi apresentado o NeTra (MA; MANJUNATH, 1999), um protótipo que utilizava informações de cor, textura e forma para organizar e recuperar imagens em um banco de dados. Um dos aspectos que o diferenciavam era a segmentação automática e o uso de informações locais de regiões na indexação das imagens do banco de dados. Isto contrastava com os demais sistemas CBIR, que utilizavam atributos globais das imagens.

No ano 2000, Cox (COX *et al.*, 2000) descreveram o sistema PicHunter, um *framework* Bayesiano utilizado para auxiliar o usuário na definição de sua busca: através de uma ferramenta de navegação por imagens, o PicHunter auxiliava os usuários na busca de uma imagem específica, mostrando imagens que maximizavam o ganho de informação em cada passo de *feedback* (CHANG; FU, 1980).

Em 2004, BARTOLINI *et al.* (BARTOLINI *et al.*, 2004) apresentaram o PIBE (*Personalizable Image Browser Engine*), um sistema de recuperação de imagens que provia aos usuários uma visão hierárquica de imagens (chamada de *Browsing Tree*), a qual podia ser customizada de acordo com as preferências do usuário. Uma característica chave do PIBE era que mantinha um critério de similaridade local para cada porção da *Browsing Tree*. Isto tornava possível evitar custo de reorganização durante ação de usuários e, combinado com um armazenamento persistente da *Browsing Tree*, provia um suporte eficiente a múltiplas tarefas de busca (ABU, 2013).

O Macroglossa, sistema baseado na comparação de imagens, surgiu em 2010, desenvolvido pelo grupo italiano MVE. Para a recuperação de imagens, a consulta segue o modelo “*Query by Example*”, que permite uma imagem de entrada para consulta. As buscas podem ser feitas em diversas categorias: animais, biológicas, panorâmicas (paisagens), artísticas ou botânicas. O sistema suporta todas as extensões populares de imagens, como jpeg, png, bmp, gif e formatos de vídeo, como avi, mov, mp4 e mpeg, entre outros (ABU, 2013).

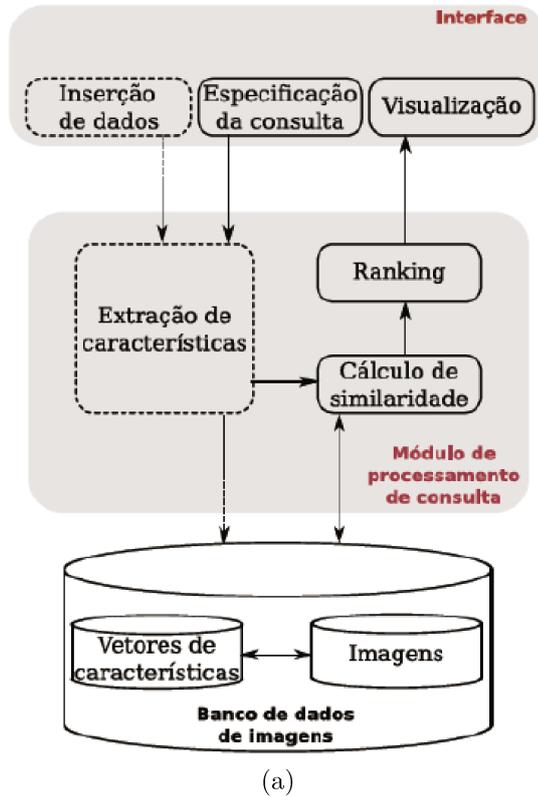
Entre os sistemas CBIR disponíveis atualmente, estão o Google Image Search e o TinEye, da empresa Indée. Apesar de terem sido lançados na década de 2000, ambos têm sido constantemente atualizados. O Google Image search especifica suas consultas através do modelo “*Query by Example*”, utilizando também metadados (textos) anexados às imagens (ABU, 2013). O TinEye apresenta funcionalidades interessantes que permitem

que, ao submeter uma imagem, o usuário descubra de onde ela vem, como tem sido utilizada, se existem versões modificadas da mesma ou até mesmo versões de maior resolução. A empresa criadora do TynEye o descreve como o primeiro sistema de busca de imagens da internet a utilizar tecnologia de identificação de imagens ao invés de palavras-chave e metadados (RAHIMZADEH *et al.*, 2014).

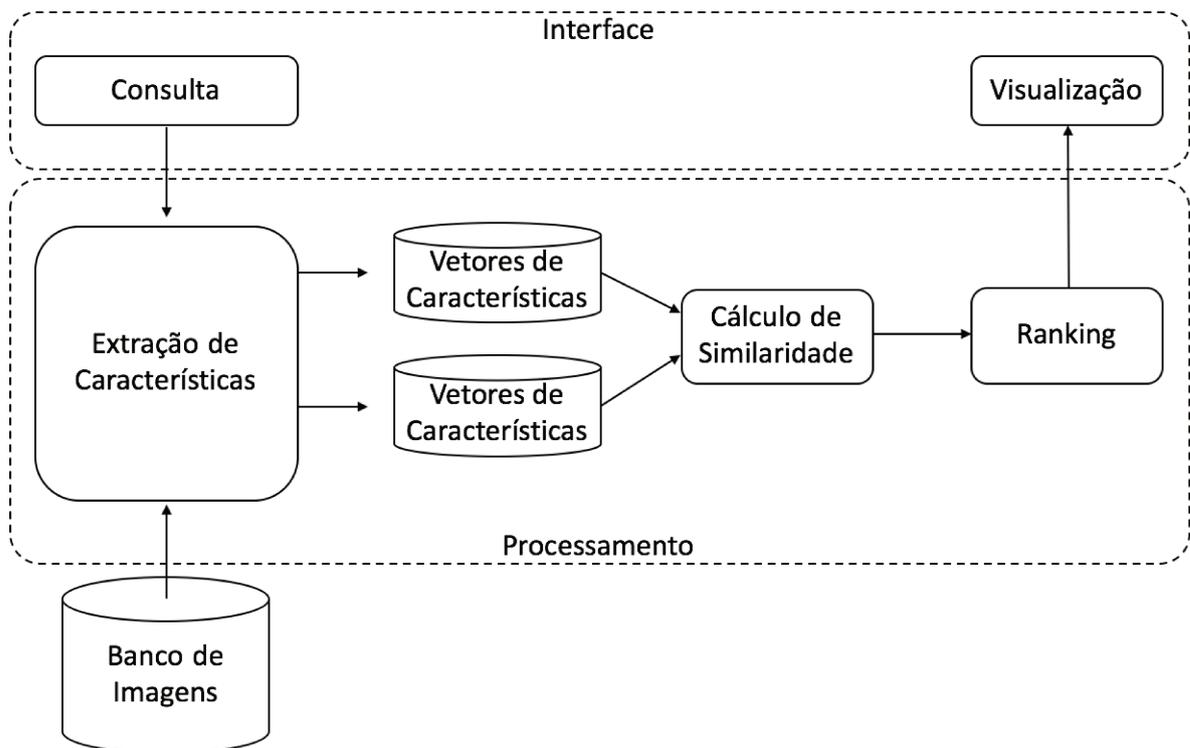
Mais informações sobre sistemas CBIR podem ser encontradas em (NALINI; MALLESWARI, 2016).

2.1.2.1 Arquitetura de Sistemas CBIR

Em um sistema CBIR, a busca de imagens é realizada através de algoritmos de processamento de imagens, os quais analisam os *pixels* das imagens e extraem vetores de características relacionados a cor, textura e forma. Assim, quando um usuário submete uma imagem de consulta em um sistema CBIR, algoritmos de extração de características processam tanto a imagem submetida (imagem de entrada), quanto todas as imagens de uma coleção. Em seguida, as características extraídas são armazenadas e indexadas como vetores e, a partir desta fase, são calculadas as distâncias entre as características extraídas da imagem de consulta e aquelas extraídas de todas as imagens presentes na coleção (ANDALO *et al.*, 2007). Como resultado, o sistema deverá enviar a um módulo de visualização as imagens ordenadas por nível de similaridade em relação à imagem de entrada. Este processo é ilustrado pela Figura 2(a) e pela Figura 2(b) a seguir.



(a)



(b)

Figura 2 – Exemplos de Arquiteturas de um sistema de recuperação de imagem por conteúdo (CBIR): (a) Arquitetura apresentada em (ANDALO *et al.*, 2007); (b) Arquitetura do sistema CBIR deste trabalho.

O primeiro módulo da Figura 2(a) apresenta a Interface, ou seja, aquilo que

será inserido como entrada no sistema CBIR (o *dataset* de imagens e a imagem de consulta) e a visualização dos ranqueamentos gerados. O segundo módulo (processamento de consulta) consiste na extração das características das imagens do *dataset*, o cálculo de similaridade entre as imagens e a geração dos ranqueamentos que serão apresentados como resultados da consulta feita.

A Figura 2(b) apresenta a arquitetura do sistema CBIR desenvolvido neste trabalho. No módulo Interface acontece a consulta (inserção de imagem de entrada) e a visualização dos ranqueamentos gerados. No segundo módulo (Processamento), acontece a extração de características da imagem que foi inserida como consulta e também das imagens que do banco de imagens (*dataset*). A extração de características gera vetores de características que serão utilizados para o cálculo de similaridade entre as imagens. Após o cálculo de similaridade, são gerados ranqueamentos que serão apresentados como resultados da consulta realizada.

2.2 Descritores de Imagem

A fase de Extração de Atributos é uma das mais importantes de um sistema de processamento de imagens, pois possibilita que informações úteis para análise sejam captadas em uma imagem. Nessa fase de extração, métodos específicos obtêm de uma imagem características relacionadas à forma, textura e cor. As características obtidas podem ser armazenadas em vetores para serem utilizadas, por exemplo, na comparação da imagem com outras na classificação da imagem em um determinado conjunto.

Os objetos que armazenam características de uma imagem são chamados de descritores. Estes possuem duas funções: a primeira, de extração de um vetor de características que representam as propriedades extraídas da imagem; e a segunda, uma função de distância, capaz de medir a diferença entre imagens a partir de seus vetores de características (ANDALO *et al.*, 2007).

Formalmente, um vetor de características \vec{v}_I de uma imagem \hat{I} pode ser considerado como um ponto no espaço \mathbb{R}^n : $\vec{v}_I = (v_1, v_2, \dots, v_n)$, onde n é a dimensão do vetor (TORRES; FALCAO, 2006), e codifica o conteúdo da imagem. O histograma é um exemplo de vetor de características que armazena informações de cor em uma imagem, já que ele indica o número de *pixels* de cada cor em uma imagem.

Um descritor de imagem simples D é definido pela tupla (\in_D, δ_D) (TORRES; FALCAO, 2006), onde:

- $\in_D : \hat{I} \rightarrow \mathbb{R}^n$ é uma função que extrai o vetor de características \vec{v}_I da imagem \hat{I} ;

- $\delta_D : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$ é uma função que calcula a similaridade entre duas imagens.

Dentre as propriedades que um descritor deve possuir para garantir sua efetividade na indexação e recuperação de imagens, a mais importante é a caracterização única de um objeto a partir do vetor de características (LONCARIC, 1998). Esta propriedade facilita a distinção entre duas imagens visualmente diferentes, de acordo com alguma métrica definida previamente. A segunda propriedade mais importante é a Invariância do descritor a alguns tipos de transformações, como a rotação e a translação (GARCIA *et al.*, 2011). Outras propriedades importantes são: geração de vetores de características compactos (requerem pouco espaço de armazenamento), função de extração eficiente e a robustez ao ruído (ANDALO *et al.*, 2007).

A seguir, são apresentados os tipos de descritores que serão utilizados neste trabalho: os descritores de textura.

2.2.1 Descritores de Textura

A textura, embora não tenha definição formal, é uma medida do arranjo estrutural dos *pixels* em uma imagem. Descritores de textura são capazes de medir algumas propriedades como regularidade, orientação (direção), suavidade e granularidade, entre outras (GONZALEZ; WOODS, 2001). Assim como cor e forma, a textura é um poderoso descritor de baixo nível.

Os descritores que serão utilizados neste trabalho são o LBP (*Local Binary Pattern*), o GLCM (*Gray-Level Co-Occurrence Matrix*) e uma derivação do GLCM, o *Haralick*, descritos a seguir. Estes foram escolhidos por serem amplamente utilizados na literatura acadêmica atual, além de serem aparentemente os mais adequados à abordagem proposta neste trabalho.

2.2.1.1 Local Binary Pattern (LBP)

O *Local Binary Pattern* (LBP), um descritor de textura local proposto por OJALA (OJALA *et al.*, 1996), possibilita a análise de uma imagem em relação às intensidades relativas entre os *pixels* de uma pequena vizinhança. Este descritor realiza análise de imagem em uma única componente de cor e considera uma janela 3x3 ao redor de um determinado *pixel* central, conforme mostra a Figura 3(a). Tal vizinhança é limiarizada pelo valor do *pixel* central, produzindo uma matriz com valores binários, como mostra a Figura 3(b), e que possibilita que sejam gerados 2^8 (256) códigos. Cada *pixel* de vizinhança (V_i) adquire o valor (E_i), sendo atribuído a ele o valor '0', se seu valor for menor que o valor do *pixel* central (V_0), caso contrário recebe o valor '1', como pode ser observado na Figura 3(c). Os valores dos *pixels* na vizinhança limiarizada são multiplicados por uma

matriz de pesos (Figura 3(d)), a qual é formada dos valores resultantes de 2^{i-1} (parte da equação 2.1 de cálculo do LBP e na qual o valor de i varia de 1 a 8). Assim, conforme a Equação 2.1, ao realizar-se a soma desses valores, é obtido como resultado o código LBP, o que pode ser observado na Figura 3 (e) (VIEIRA, 2013). O valor LBP para cada *pixel* é dado conforme a Equação 2.1.

$$N_{LBP} = \sum_{k=1}^8 E_i \cdot 2^{i-1} \quad (2.1)$$

Na sequência é então gerado um histograma, o qual será utilizado para determinar as ocorrências dos diferentes códigos LBP e formará o vetor de características LBP (que identifica uma imagem de textura).

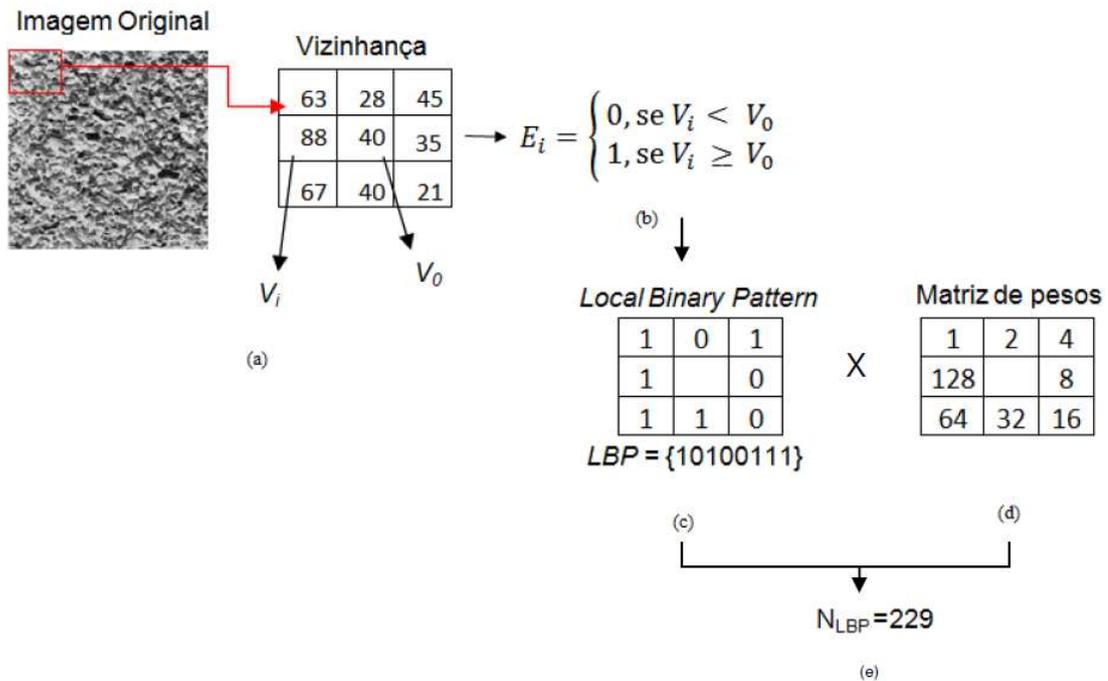


Figura 3 – Ilustração do cálculo do LBP: (a) Análise de uma imagem em tons de cinza, considerando uma vizinhança 3x3 ao redor do *pixel* central; (b) Vizinhança limiarizada pelo valor do *pixel* central gerando matriz com valores binários; (c) Cada *pixel* de vizinhança (V_i) adquire o valor (E_i), sendo o seu valor '0', se estiver abaixo do valor do *pixel* central (V_0), senão adquire o valor '1' se for igual ou maior que o valor do *pixel* central; (d) Valores dos *pixels* na vizinhança limiarizada são multiplicados por uma matriz de pesos (VIEIRA, 2013).

2.2.1.2 Gray-Level Co-Occurrence Matrix (GLCM)

O descritor *Gray-Level Co-Occurrence Matrix* (HARALICK *et al.*, 1973) descreve uma matriz de co-ocorrência de níveis de cinza capaz de armazenar a probabilidade

de que dois valores de intensidade de cinza estejam envolvidos em uma determinada relação espacial. De acordo com esta matriz de probabilidades, são extraídas distintas medidas estatísticas com a finalidade de caracterizar a textura presente na imagem (MARTINS *et al.*, 2011), como por exemplo o contraste, energia, correlação e homogeneidade.

Matematicamente, uma GLCM considera um operador $p(i, j; d, \theta)$, em uma imagem f , com L níveis de intensidade, onde p é uma matriz cujo elemento $p_{i,j}$ é o número de vezes que os pares de *pixels* com intensidades z_i e z_j ocorrem em f na posição definida por p e $1 \leq i, j \leq L$. Ou seja, a matriz de co-ocorrência considera a relação de dois elementos (*pixels*) de textura por vez: um chamado de *pixel* de referência e outro de *pixel* vizinho com propriedades i e j , separados por uma distância d em uma direção θ . O *pixel* vizinho pode estar em qualquer distância do *pixel* de referência, como por exemplo 1 *pixel*, ou 2, ou 3, ou L , e em qualquer direção, como por exemplo, a 0° , a 45° , a 135° , a 180° , a 225° e a 270° . A Figura 4 mostra um exemplo de como construir uma matriz de co-ocorrência usando $L=8$ e direção 0° com 1 *pixel* de distância. O elemento (1,1) de p é 1, pois existe apenas uma ocorrência em f de um *pixel* com o valor de 1 com outro *pixel* vizinho de valor 1 à sua direita. Passando para outro exemplo, o elemento (6,2) de p é 3, porque há apenas três ocorrências em f de um *pixel* com o valor de 6 e com outro *pixel* vizinho de valor 2 à sua direita (GONZALEZ; WOODS, 2001).

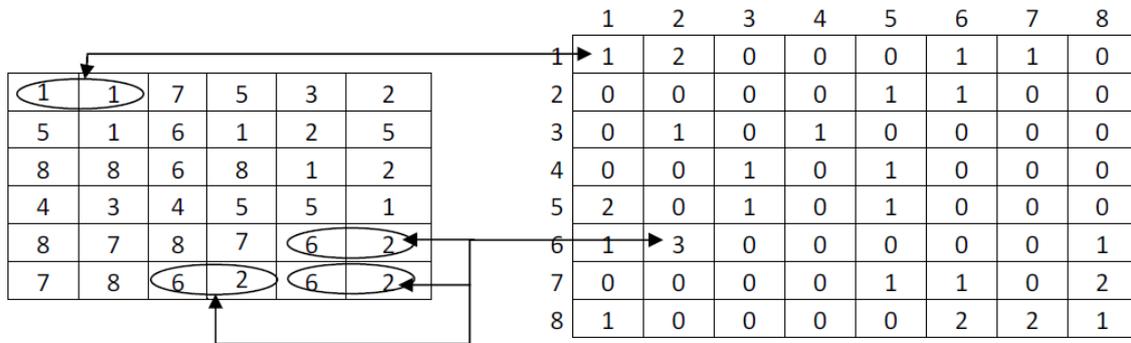


Figura 4 – Exemplo de uma matriz que usa $L=8$ e direção 0° com 1 *pixel* de distância. À esquerda, encontra-se a imagem f e à direita sua matriz de co-ocorrência p (GONZALEZ; WOODS, 2001).

É necessário ressaltar que a escolha do tamanho da distância d e do ângulo de direção θ é determinada por quem está aplicando o GLCM a uma imagem. Ao analisar a literatura, é possível observar trabalhos de pesquisa que mostram valores de distância d que variam entre 1, 2 e 10, os quais concluíram que, em termos de acurácia, $d = 1$ apresenta os melhores resultados. Já em relação ao ângulo θ , estudos mostram que ao levar em consideração a definição do GLCM, os pares co-ocorrentes obtêm resultados semelhantes quando se determina que o ângulo θ será igual a 0° ou igual a 180° (e isto estende-se aos ângulos 45° , 90° e 135° (GADKARI, 2004).

2.2.1.3 Haralick

Um descritor de Haralick permite a extração de 14 características de textura de imagem com base em uma matriz de co-ocorrência (GLCM), sendo elas: segundo momento angular, contraste, correlação, variância, momento de diferença inverso, média da soma, variância da soma, entropia da soma, entropia, variância da diferença, entropia da diferença, medidas de informação da correlação (com duas propriedades) e coeficiente de correlação máximo. As equações que definem essas características podem ser encontradas em (HARALICK *et al.*, 1973).

Segundo Haralick (HARALICK *et al.*, 1973), este descritor possibilita a análise de características não invariantes sobre as transformações monotônicas de níveis de cinza, o que possibilita classificar, por exemplo, imagens de mesma textura porém com níveis de cinza claro e escuros, algo que o olho humano não é capaz de fazer.

2.3 Funções de Similaridade e Distância

Em um sistema de Recuperação de imagens, operações de comparação entre duas ou mais imagens são fundamentais. Para realizar tais operações, é necessário utilizar as características extraídas das imagens (armazenadas em vetores) e também funções de similaridade ou distância, as quais serão responsáveis por calcular a similaridade ou calcular a distância entre os vetores de características das imagens. Ambos, vetores de características e funções de similaridade, integram os descritores mencionados anteriormente.

A eficiência e eficácia da recuperação de dados é afetada pela habilidade que sua função de similaridade tem de separar os dados (BUGATTI *et al.*, 2008). Algumas funções tem sido propostas, entre elas, as da Família *Minkowski*, a da Forma Quadrática, de *Canberra*, Divergência de *Jeffrey* e a *Hausdorff*.

A Família *Minkowski* ou L_p , compreende as funções de distância mais utilizadas: *Manhattan* (L_1), Euclidiana (L_2) e *Chebychev* (L_∞). Para decidir qual deve ser usada, deve-se observar o valor de p : quando $p = 1$ tem-se a distância L_1 (Manhattan), quando $p = 2$ tem-se a distância L_2 (Euclidiana) e, quando $p \rightarrow \infty$, tem-se a distância L_∞ (Chebychev) (RIBEIRO, 2008). Funções deste espaço métrico são empregadas com objetos compostos por n -atributos de valores numéricos. Considerando cada atributo como um eixo de ordenadas cartesianas, o objeto pode ser visto como um ponto no espaço de n -dimensões, também chamado de espaço vetorial. Assim, estas métricas são utilizadas para calcular a distância entre os objetos (FILHO *et al.*, 2001). As distâncias L_p são

conhecidas pela função:

$$L_p((x_1, \dots, x_n), (y_1, \dots, y_n)) = \sqrt[p]{\sum_{i=1}^n |x[i] - y[i]|^p} \quad (2.2)$$

A distância L_1 , também chamada de *Manhattan*, corresponde à soma do valor absoluto das diferenças entre as coordenadas. Neste caso, o conjunto de pontos equidistantes de um centro, dada uma extensão de raio r_q , forma um losango em um espaço bidimensional com paralelas ao eixo de coordenadas (veja a Figura 5(a)) (BUGATTI *et al.*, 2008). A distância L_1 é utilizada frequentemente para calcular a distância entre imagens coloridas (LONG *et al.*, 2003). A equação da distância L_1 é dada por:

$$L_1(X, Y) = \sum_{i=1}^n |x[i] - y[i]| \quad (2.3)$$

A distância L_2 , conhecida como *Euclidiana*, é comumente usada para calcular a distância entre vetores e corresponde à noção espacial de distância dos seres humanos, o que a torna a mais empregada em comparações de distância. O conjunto de pontos equidistantes usando a distância L_2 forma uma circunferência em um espaço bidimensional (Figura 5(b)) (BUGATTI *et al.*, 2008). Em um espaço de n dimensões, forma uma hipersfera. A equação da distância L_2 é dada por:

$$L_2 = \sqrt{\sum_{i=1}^n (x[i] - y[i])^2} \quad (2.4)$$

A distância L_∞ , também conhecida como *Chebychev*, corresponde a alcançar o limite da equação das distâncias L_p quando p tende ao infinito. O conjunto de pontos equidistantes forma um quadrado em um espaço bidimensional, com arestas paralelas ao eixo de coordenadas (Figura 5(c)) (BUGATTI *et al.*, 2008). Em um espaço de n dimensões, forma um hipercubo. A equação da distância L_∞ é dada por:

$$L_\infty(X, Y) = \max_i |x[i] - y[i]| \quad (2.5)$$

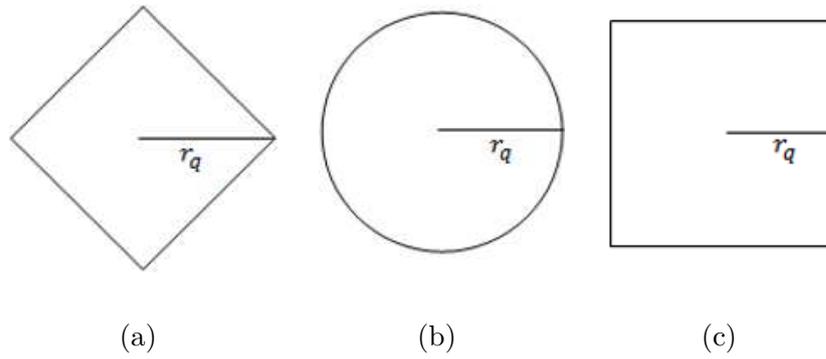


Figura 5 – Exemplos de representação espacial de funções de distância em um espaço bidimensional: (a) L_1 ; (b) L_2 ; (c) L_∞ .

A função de distância de Forma Quadrática, ao contrário das funções da família *Minkowski*, considera o fato de que alguns pares de atributos correspondem a características que são mais importantes para a percepção de similaridade do que outros (BUGATTI *et al.*, 2008). É definida através da seguinte equação:

$$d_q(X, Y) = \sqrt{(x - y)^T A (x - y)} \quad (2.6)$$

Onde $A = [a_{ij}]$ é uma matriz de similaridade $N \times N$; $[a_{ij}]$ denota a similaridade entre as características i e j .

A função de distância Canberra é comparada à Manhattan, já que a diferença absoluta dos valores das características é dividida por sua soma absoluta. Esta é a mais restritiva das funções de distância, pois é muito sensível a pequenas mudanças (BUGATTI *et al.*, 2008). É formalmente definida pela equação:

$$d_c = \sum_{i=1}^n \frac{|x_i - y_i|}{|x_i| + |y_i|} \quad (2.7)$$

A função de Divergência de *Jeffrey* é uma versão modificada de outra função de distância, chamada de divergência *Kullback-Leibler*. É simétrica e apresenta um comportamento numérico melhor, sendo mais robusta em relação a ruídos e *bins* de histogramas (RUBNER; TOMASI, 2013). É formalmente definida pela equação:

$$D_J(X, Y) = \sum_{i=1}^n \left(x_i \log \frac{x_i}{m_i} + y_i \log \frac{y_i}{m_i} \right) \quad (2.8)$$

Onde $m_i = \frac{x_i + y_i}{2}$.

Por fim, a função de *Hausdorff* tem por objetivo calcular o grau de similaridade e se concentra nas relações fuzzy entre dois elementos, sem focar em encontrar o par absoluta (GAO; DAI, 2008). Sejam $M = \{m_1, m_2, \dots, m_n\}$ e $N = \{n_1, n_2, \dots, n_n\}$ dois

conjuntos de pontos finitos, onde m_n e n_n representam o número de elementos dos dois conjuntos, respectivamente. A equação de distância *Hausdorff* é definida por:

$$H(M, N) = \max(h(M, N), h(N, M)) \quad (2.9)$$

Onde $h(M, N) = \max_{m \in M} \min_{n \in N} \|m - n\|$ e $h(N, M) = \max_{n \in N} \min_{m \in M} \|n - m\|$.

Mais informações sobre equações de distância e similaridade podem ser encontradas em (BUGATTI *et al.*, 2008) e (YU, LI, *et al.*, 2005).

2.4 Modelos de representação de cores

As cores representam a sensação criada em resposta à vibração de nosso sistema visual por causa da radiação eletromagnética conhecida como luz. Mais especificamente, a cor é o resultado perceptível da luz na região visível do espectro eletromagnético, a qual tem comprimento de ondas de 400 *nm* a 700 *nm* que incidem na retina do olho humano (PLATANIOTIS; VENETSANOPOULOS, 2013).

A retina humana possui três tipos de cones, células fotorreceptoras de cor que podem ser sensíveis à luz vermelha, à verde ou à azul. Da mesma forma, constata-se que uma cor pode ser descrita por um vetor de três componentes, desde que sejam apresentadas funções de ponderação espectral adequadas.

O conjunto de todas as cores forma um vetor espacial chamado de modelo de cor, o qual tem por objetivo permitir a especificação de cores em um formato padronizado e aceito por todos. Em linhas gerais, um modelo de cor é uma representação tridimensional na qual cada cor é representada por um ponto no sistema de coordenadas 3-D (FILHO; NETO, 1999).

O propósito de um modelo de cor é representar adequadamente as cores de uma imagem (CATTIN, 2016). Assim, é necessário analisar diversos modelos de cor antes de decidir qual é o mais adequado para determinada aplicação. Entre os modelos de cor mais utilizados estão o RGB, o CIEXYZ e o CIELab, apresentados a seguir.

2.4.1 Modelo RGB

O modelo RGB (*Red*, *Green*, *Blue*) é baseado em um sistema de coordenadas cartesianas, que pode ser visto como um cubo onde três de seus vértices são as cores primárias e outros três são as cores secundárias, sendo o vértice junto à origem o preto e o mais afastado da origem corresponde à cor branca (FILHO; NETO, 1999), conforme ilustra a Figura 6. Este modelo é o mais utilizado por câmeras e monitores de vídeo.

O valor de cada cor primária deve ter uma partição de 8 bits (256 valores). A cor preta é representada pela ausência das cores primárias, ou seja, quanto mais próximo ao zero, mais escura será a coloração final, por isso, a especificação RGB (0,0,0) define a cor preta (RODRIGUES *et al.*, 2015).

Em contrapartida, ao se adicionar simultaneamente as cores primárias, será obtida a cor branca, especificada por RGB(255, 255, 255). Isso denota que, se os valores estiverem iguais, a cor resultará em um tom de cinza (JUNIOR, 2009).

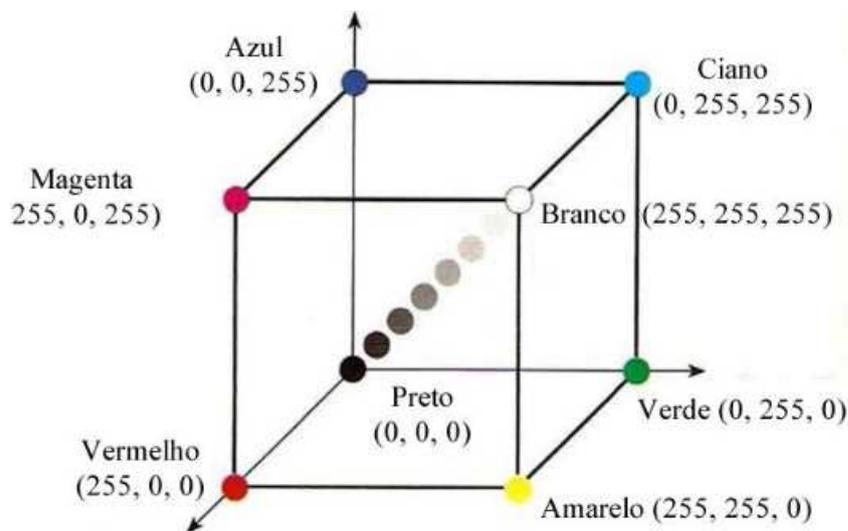


Figura 6 – Cubo do modelo RGB (CATTIN, 2016).

A Figura 7 apresenta a divisão de uma imagem colorida nos seus três componentes de cor: Vermelho (b), Verde (c) e Azul (d). Ao dividir uma imagem em seus componentes RGB, são obtidas três imagens em tons de cinza, as quais representam a intensidade de cada componente da Figura 7(a). Assim, nas imagem em tons de cinza, as porções mais claras representam as regiões com maior intensidade do componente, enquanto que as porções mais escuras representam as regiões com menor intensidade do componente.



Figura 7 – Canais de cor do modelo RGB: (a) Imagem colorida original; (b) *Red* (Vermelho); (c) *Green* (Verde); (d) *Blue* (Azul) (CATTIN, 2016).

Dado que a distância entre duas cores no cubo do modelo RGB não é necessariamente a diferença da sensação de cor compreendida por um ser humano, o modelo de cor

RGB pode não ser o mais adequado na recuperação das imagens desta pesquisa. Portanto, torna-se necessário avaliar outro modelo de cor, o CIEXYZ, apresentado a seguir.

2.4.2 Modelo CIEXYZ

A CIE (*Commission Internationale de l'Eclairage*) é uma organização independente e sem fins lucrativos que se dedica à troca de informações sobre todos os assuntos relacionados à luminância, cores e visão, fotometria e tecnologias de imagem. Propõe modelos de cor baseados na percepção de cor do olho humano, os quais são desenvolvidos para serem completamente independentes de qualquer dispositivo.

Em 1931, ao considerar que os valores de triestímulos para as cores vermelho (R , *Red*), verde (G , *Green*) e Azul (B , *Blue*) do modelo RGB não eram suficientes para a criação de um modelo padronizado de cores, a CIE utilizou equações matemáticas para converter dados RGB para um sistema que utiliza apenas inteiros positivos como valores. Estes valores de triestímulos que foram reformulados foram chamados de XYZ , os quais não correspondem diretamente às cores vermelho, verde e azul do modelo RGB, mas se aproximam destas. A curva do triestímulo Y é igual à curva que indica a resposta do olho humano à potência total de uma fonte de luz. Por essa razão, o valor Y é chamado de fator de luminância e os valores XYZ foram normalizados de maneira que o valor de Y sempre seja 100 (ADOBE, 2017).

A obtenção dos triestímulos XYZ é apenas parte da definição da cor. A cor por si mesma é melhor entendida em termos de matiz (*hue*) e croma. Para tornar isto possível, a CIE utilizou os valores dos triestímulos XYZ para formular um novo conjunto de coordenadas de cromaticidade, as quais são identificadas por xyz . As coordenadas de cromaticidade são utilizadas em conjunto com um diagrama de cromaticidade xyY , mostrado na Figura 8.

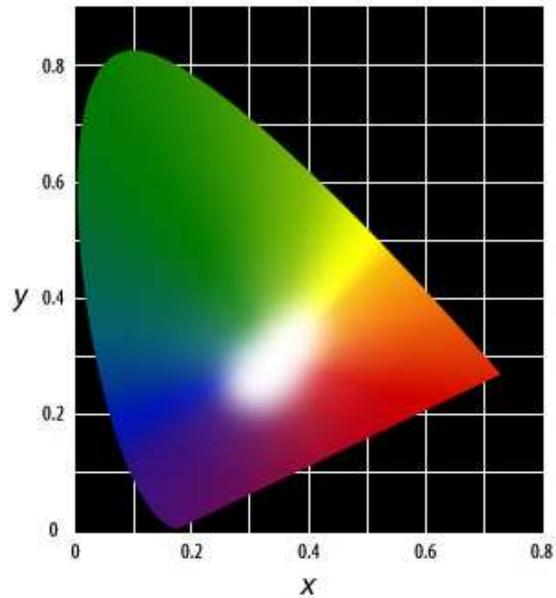


Figura 8 – Diagrama de cromaticidade xyY (ADOBE, 2017).

O modelo de cor é inserido em uma grade usando as coordenadas de cromaticidade x e y como localizadoras de qualquer valor de matiz e croma. Estas correspondem à cor em si (por exemplo, laranja-avermelhado) e à cor ou saturação completa. A coordenada z não é utilizada, mas pode ser deduzida a partir das outras duas, já que o resultado da soma das coordenadas $x + y + z$ é sempre 1.

O local em branco na Figura 9 representa a localização do iluminante. A terceira dimensão é indicada pelo triestímulo de valor Y . Conforme mencionado, este valor se refere à luminância da cor. A escala para Y se estende desde o local em branco em uma linha perpendicular ao plano formado por x e y , usando uma escala que vai de 0 a 100. A faixa completa de cor se encontra em 0 (zero), onde o ponto branco é igual ao iluminante C da CIE. Como o valor de Y aumenta e a cor se torna mais clara, a faixa de cor (ou gama) diminui de maneira que o espaço de cor em 100 é apenas uma banda da área original, como mostrado na Figura 9.

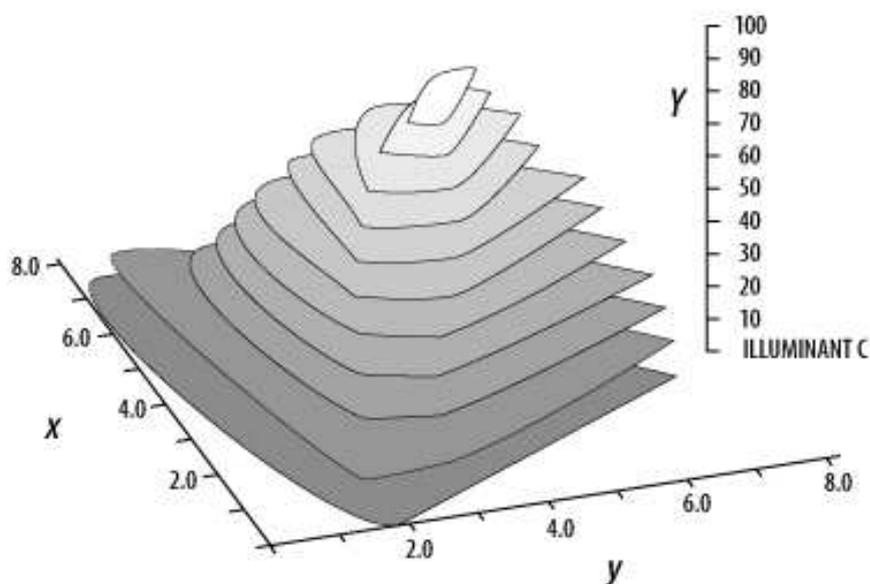


Figura 9 – Diagrama de cromaticidade xyY em três dimensões (ADOBE, 2017).

Usando os valores xyY , quaisquer duas cores podem ser comparadas para determinar se elas são correspondentes - o que de fato é o propósito dos padrões da CIE. No entanto, não é possível usar o diagrama de cromaticidade xyY como um mapa para mostrar a relação entre cores, pois o diagrama é uma representação plana do que seria na realidade uma superfície curva. Então, assim como acontece em uma projeção plana do mundo em um mapa, algumas partes são visualmente distorcidas em relação a outras: Cores que têm valores de diferença iguais aparecem mais distantes na parte verde do diagrama do que na parte vermelha ou violeta deste.

Com o intuito de resolver os problemas de escala de cor não uniforme, a CIE propôs outros modelos de cor que utilizam diagramas uniformes. Entre eles está o modelo de cor CIELab, apresentado a seguir.

2.4.3 Modelo CIELab

O Modelo CIELab foi estabelecido pela CIE em 1976 como um sistema tridimensional quase uniforme. Por ser um modelo tridimensional, permite uma variação de cores maior que a apresentada por modelos bidimensionais. Além disso, sua uniformidade permite que, por exemplo, a distância euclidiana entre os valores de cor possa ser comparada à da percepção do olho humano (CIE, 2004).

No CIELab, o L representa o valor de luminosidade da cor, o a representa a variação de cores do verde ao vermelho e o b representa a variação de cores do amarelo para o azul (ARAÚJO, 2005). A Figura 10 apresenta o esquema utilizado na definição de cores deste modelo.

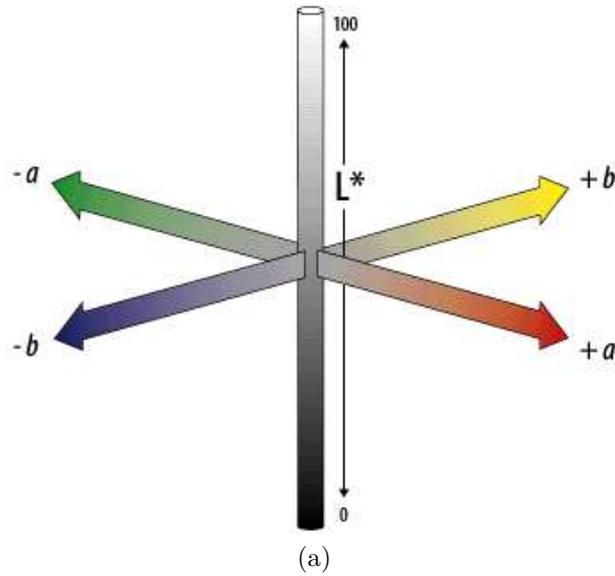


Figura 10 – Modelo de cor CIELab (ADOBE, 2017).

O eixo central representa a luminância (assinalado como L), cujos valores variam de 0 (preto) a 100 (branco). Os eixos de cores são baseados no fato de que uma cor não pode ser simultaneamente vermelha e verde, ou azul e amarelo, já que tais cores são opostas umas às outras. Em cada eixo os valores variam de positivo a negativo. No eixo a , os valores positivos indicam quantidade de cor vermelha, enquanto que os valores negativos denotam quantidade de cor verde. Já no eixo b , os valores positivos indicam quantidade de cor amarela, enquanto que os negativos indicam quantidade de cor azul. Para ambos os eixos o zero representa cinza natural (ADOBE, 2017).

A plotagem dos valores de L , a e b em coordenadas retangulares produz um espaço de cor tridimensional aproximadamente uniforme, o qual é definido portanto pelas seguintes equações:

$$L = 116 * f\left(\frac{Y}{Y_n}\right) - 16 \quad (2.10)$$

$$a = 500 * \left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right] \quad (2.11)$$

$$b = 200 * \left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right] \quad (2.12)$$

Onde

$$f\left(\frac{X}{X_n}\right) = \left(\frac{X}{X_n}\right)^{\frac{1}{3}} \quad \text{se } \frac{X}{X_n} > \left(\frac{24}{116}\right)^3 \quad (2.13)$$

$$f\left(\frac{X}{X_n}\right) = \left(\frac{841}{108}\right) \left(\frac{X}{X_n}\right) + \left(\frac{16}{116}\right) \quad \text{se } \frac{X}{X_n} \leq \left(\frac{24}{116}\right)^3 \quad (2.14)$$

e

$$f\left(\frac{Y}{Y_n}\right) = \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} \quad \text{se} \quad \frac{Y}{Y_n} > \left(\frac{24}{116}\right)^3 \quad (2.15)$$

$$f\left(\frac{Y}{Y_n}\right) = \left(\frac{841}{108}\right) \left(\frac{Y}{Y_n}\right) + \left(\frac{16}{116}\right) \quad \text{se} \quad \frac{Y}{Y_n} \leq \left(\frac{24}{116}\right)^3 \quad (2.16)$$

e

$$f\left(\frac{Z}{Z_n}\right) = \left(\frac{Z}{Z_n}\right)^{\frac{1}{3}} \quad \text{se} \quad \frac{Z}{Z_n} > \left(\frac{24}{116}\right)^3 \quad (2.17)$$

$$f\left(\frac{Z}{Z_n}\right) = \left(\frac{841}{108}\right) \left(\frac{Z}{Z_n}\right) + \left(\frac{16}{116}\right) \quad \text{se} \quad \frac{Z}{Z_n} \leq \left(\frac{24}{116}\right)^3 \quad (2.18)$$

Onde temos que X , Y e Z são os valores dos triestímulos das colorações medidas e X_n , Y_n e Z_n são os valores triestímulos da área com branco ideal sob iluminação correspondente, por exemplo, à luz do dia, onde $X = 94.811$, $Y = 100$ e $Z = 107.304$ (CIE, 2004).

2.4.4 Conversão de Cores

Conforme mencionado previamente, neste trabalho foram utilizadas fotos de folhas de tabaco afetadas por CVC. Tais imagens, captadas através de câmeras digitais, estão todas no modelo RGB. Com o intuito de comparar resultados gerados através de modelos de cores diferentes, foi necessário converter as imagens do modelo RGB para o CIELab. No entanto, essa conversão só é possível se primeiro é feita do RGB para o CIEXYZ e em seguida do CIEXYZ para o CIELab de fato.

O algoritmo 2.1 mostra os passos para a conversão do modelo RGB para o modelo CIEXYZ:

Algoritmo 2.1 Conversão do modelo de cor RGB para o modelo de cor CIEXYZ

Entrada:

R : Valor de R de 0 até 255 dividido por 255

G : Valor de G de 0 até 255 dividido por 255

B : Valor de B de 0 até 255 dividido por 255

```
1: Início
2: se  $R > 0.04045$  então
3:    $R = ((R + 0.055) / 1.055)^{2.4}$ 
4: senão
5:    $R = R / 12.92$ 
6: fim se
7: se  $G > 0.04045$  então
8:    $G = ((G + 0.055) / 1.055)^{2.4}$ 
9: senão
10:   $G = G / 12.92$ 
11: fim se
12: se  $B > 0.04045$  então
13:    $B = ((B + 0.055) / 1.055)^{2.4}$ 
14: senão
15:    $B = B / 12.92$ 
16: fim se
17:
18:  $R = R * 100$ 
19:  $G = G * 100$ 
20:  $B = B * 100$ 
21:
22:  $X = R * 0.4124 + G * 0.3576 + B * 0.1805$ 
23:  $Y = R * 0.2126 + G * 0.7152 + B * 0.0722$ 
24:  $Z = R * 0.0193 + G * 0.1192 + B * 0.9505$ 
25: Fim
```

Em seguida, para fazer a conversão do modelo CIEXYZ para o CIELab, foi utilizado o algoritmo 2.2 a seguir:

Algoritmo 2.2 Conversão do modelo de cor CIEXYZ para o modelo de cor CIELab
 Valores de referência de iluminação ideal da luz do dia

```

  refX: 95.047
  refY: 100.000
  refZ: 108.883

1: Início
2:  $X : X / refX$ 
3:  $Y : Y / refY$ 
4:  $Z : Z / refZ$ 
5:
6: se  $X > 0.008856$  então
7:    $X = X^{1/3}$ 
8: senão
9:    $X = (7.787 * X) + (16 / 116)$ 
10: fim se
11: se  $Y > 0.008856$  então
12:    $Y = Y^{1/3}$ 
13: senão
14:    $Y = (7.787 * Y) + (16 / 116)$ 
15: fim se
16: se  $Z > 0.008856$  então
17:    $Z = Z^{1/3}$ 
18: senão
19:    $Z = (7.787 * Z) + (16 / 116)$ 
20: fim se
21:
22:  $CIE\_L = (116 * Y) - 16$ 
23:  $CIE\_a = 500 * (X - Y)$ 
24:  $CIE\_b = 200 * (Y - Z)$ 
25: Fim

```

Os algoritmos mostrados foram desenvolvidos por (RODRIGUES *et al.*, 2015), baseadas no Relatório Técnico de Colorimetria da CIE de 2004.

2.5 Ranqueamento de Imagens

Após a extração de vetores de características e o cálculo de distâncias entre as características extraídas das imagens de um banco, um sistema CBIR deve apresentar como saída um módulo de visualização, o qual apresentará as imagens relevantes mais similares a uma imagem de consulta, ordenando-as por seu grau de similaridade (geralmente em ordem decrescente). O processo mediante o qual as imagens são ordenadas ou classificadas de acordo com determinado padrão é chamado de ranqueamento.

Formalmente, em um algoritmo de ranqueamento, um descritor D calcula a

distância $\rho(img_i, img_j)$ entre duas imagens img_i e img_j , pertencentes a uma coleção de imagens C . O valor de distância calculado considera apenas as duas imagens img_i e img_j . Na sequência, para criar listas ranqueadas para as imagens img_i e img_j , calcula-se a distância destas imagens em relação a todas as imagens da coleção.

O ranqueamento é afetado pela escolha das funções de distância utilizadas para verificar a distância entre imagens. A escolha de funções inapropriadas pode ocasionar o retorno de resultados insuficientes na consulta em um sistema CBIR, atestando assim sua ineficiência. Funções tradicionais de cálculo de distância como a função Euclidiana, podem falhar no retorno de resultados satisfatórios, geralmente devido ao já conhecido problema de lacuna semântica (HOI *et al.*, 2010), que é originado pelo fato de que medidas de similaridade sobre os descritores das imagens em geral não possuem correlação direta com a semântica subjetiva humana.

Muitos estudos têm sido propostos para a melhoria de resultados obtidos pelos sistemas CBIR ((SANTOS *et al.*, 2011), (YANG *et al.*, 2012), (TAO *et al.*, 2006), (RUI *et al.*, 1998), (LIU *et al.*, 2007), (PEDRONETTE; TORRES, 2012a)). Uma das técnicas de melhoria proposta, a de re-ranqueamento, é utilizada neste trabalho e é descrita a seguir.

2.6 Re-ranqueamento de Imagens

Conforme mencionado, a definição de uma medida de distância afeta diretamente os resultados obtidos por um sistema CBIR. Em operações comuns de ranqueamento, a medida de distância é utilizada para recuperar, em uma coleção de imagens, aquelas mais similares a uma imagem de consulta. As imagens são então organizadas por ordem de similaridade, em catálogos chamados de listas ranqueadas. No entanto, nesse processo a medição considera apenas pares de imagens, e ignora informações relevantes que há no contexto em que as imagens se encontram.

O contexto representa uma grande fonte de informações sobre uma coleção de imagens, já que leva em consideração não apenas a comparação entre pares de imagens, mas também outras informações codificadas tanto nas listas ranqueadas quanto nas distâncias entre todas as imagens. Desta maneira, através do contexto, sistemas CBIR podem comparar-se ao comportamento humano que, ao julgar a similaridade entre imagens, analisa uma lista ranqueada como um todo, e não apenas partes em separado (PEDRONETTE; TORRES, 2013).

Com o intuito de melhorar a eficácia do processo de recuperação de imagens em sistemas CBIR, têm sido propostos métodos de re-ranqueamento. Estes métodos, através da exploração de informações contextuais, agregam informações a um ranqueamento

inicial e podem assim refinar o resultados de uma busca.

Um algoritmo de re-ranqueamento utiliza como entrada uma matriz de distância A e um conjunto de listas ranqueadas R para calcular uma nova e mais eficiente matriz de distância \hat{A} . Portanto, as distâncias entre todas as imagens contidas na matriz A são redefinidas por uma medida de distância mais eficaz (PEDRONETTE; TORRES, 2012a). Um método de re-ranqueamento que considera relacionamento entre todas as imagens de uma coleção pode ser representado pela função f_r :

$$\hat{A} = f_r(A, R) \quad (2.19)$$

Então, dada a nova matriz de distância \hat{A} , um novo conjunto \hat{R} pode ser obtido. \hat{R} contém as novas posições de ranqueamento de todas as imagens da coleção, ou seja, as imagens da coleção foram re-ranqueadas. É necessário ressaltar que a função f_r consiste na exploração de todos os relacionamentos codificados em ambos A e R (PEDRONETTE; TORRES, 2012a).

A Figura 11 apresenta um experimento realizado em (PEDRONETTE; TORRES, 2012a), o qual mostra a evolução de ranqueamentos e sua precisão através das iterações. Cada linha apresenta 20 resultados para uma determinada imagem de consulta (a qual está na primeira coluna, de borda de cor verde). A primeira linha mostra o resultado obtido através de descritores de forma (com os resultados errados com borda de cor vermelha). As demais linhas apresentam os resultados obtidos em cada iteração através do Algoritmo RL-Sim, que executa a tarefa de re-ranqueamento baseado na similaridade entre listas. Conforme aumentam as iterações, observa-se uma melhora expressiva na precisão do ranqueamento. Além disso, conforme ocorrem as iterações, os resultados errados são removidos das posições do topo. Para o experimento, foram realizadas iterações em ranqueamentos obtidos na recuperação de imagens do conjunto MPEG-7 (LATECKI *et al.*, 2000).

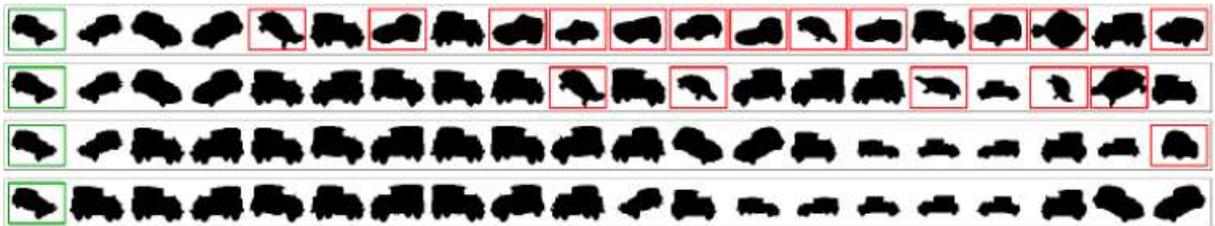


Figura 11 – Evolução dos ranqueamentos através de diversas iterações (PEDRONETTE; TORRES, 2012a).

2.6.1 Tipos de Abordagem de Re-ranqueamento

A seguir, são apresentadas as abordagens utilizadas atualmente na área de re-ranqueamento, agrupadas em três categorias de algoritmos: de aprendizado supervisionado, semi-supervisionado e não supervisionado.

- **Aprendizado Supervisionado:** Neste tipo de abordagem, amostras de treinamento são disponibilizadas na indução de uma função. Cada amostra é um par que contém um objeto de entrada e um valor de saída desejado (PEDRONETTE; TORRES, 2012a). Matematicamente, seja um domínio de instâncias de objetos X , e um domínio de rótulos Y , poderá acontecer uma junção de distribuição de probabilidades entre as instâncias X e os rótulos $Y(X \times Y)$. Dada uma amostra de treinamento $\{(X_i), Y_i\}_{i=1}^n$, o aprendizado supervisionado treina uma função $f : X \rightarrow Y$, com o objetivo de que $f(x)$ preveja o verdadeiro rótulo y em dados futuros x (PEDRONETTE; TORRES, 2012a).
- **Aprendizado Semi-Supervisionado:** Encontra-se entre o aprendizado supervisionado e o não supervisionado. Refere-se ao uso tanto de dados rotulados quanto não rotulados no seu treinamento. Na realidade, a maioria das abordagens de aprendizado semi-supervisionado são baseadas na extensão tanto de abordagens não supervisionadas quanto supervisionadas para a inclusão de informação adicional de outros paradigmas de aprendizado (ZHU; GOLDBERG, 2009).
- **Aprendizado Não supervisionado:** Nesta abordagem, o método de aprendizado recebe apenas o domínio da instância de objetos X , ou seja, nenhum dado rotulado de treinamento é disponibilizado. Como dados rotulados geralmente requerem esforço humano (de custo alto), e dados não rotulados são de fácil obtenção, em muitos cenários este tipo de abordagem não supervisionada representa uma solução muito atraente (PEDRONETTE; TORRES, 2012a).

Para realizar a tarefa de re-ranqueamento do resultado obtido na recuperação de imagens de folhas de tabaco infectadas por CVC, este trabalho utilizará o algoritmo RL-Sim proposto por PEDRONETTE; TORRES (PEDRONETTE; TORRES, 2013), que utiliza métodos de aprendizado não supervisionado. Uma descrição sobre o RL-Sim é apresentada a seguir.

2.6.1.1 O Algoritmo RL-Sim

O algoritmo *RankedLists-Similarities* (RL-Sim) proposto por PEDRONETTE; TORRES (PEDRONETTE; TORRES, 2013), é um método não supervisionado cujo obje-

tivo é o aumento da eficácia das tarefas de recuperação de imagem através de um procedimento de reclassificação iterativa, também chamado de re-ranqueamento. Para atingir seu propósito, o RL-Sim explora também a informação contextual existente na similaridade entre listas ranqueadas, as quais são importante fonte de informação por estabelecerem relação não somente entre pares de imagens, mas também entre conjunto de imagens.

O conceito principal do algoritmo baseia-se na teoria de que se duas imagens são similares, então suas listas ranqueadas também devem ser similares. Assim, ao analisar a similaridade entre as listas ranqueadas de imagens, o algoritmo possibilita o aumento de eficácia do ranqueamento realizado.

A Figura 12 apresenta os principais passos do algoritmo. Em suma, para cada imagem img_i de uma coleção de ranqueamentos de imagens, o processo de re-ranqueamento é executado. Tal processo consiste em uma etapa de cálculo de similaridade entre a lista ranqueada da imagem em processamento (img_i) e as listas ranqueadas de cada imagem (img_j) contidas nas primeiras posições da lista ranqueada img_i . Assim, baseado no cálculo de similaridade, são redefinidas as distâncias entre img_i e img_j .

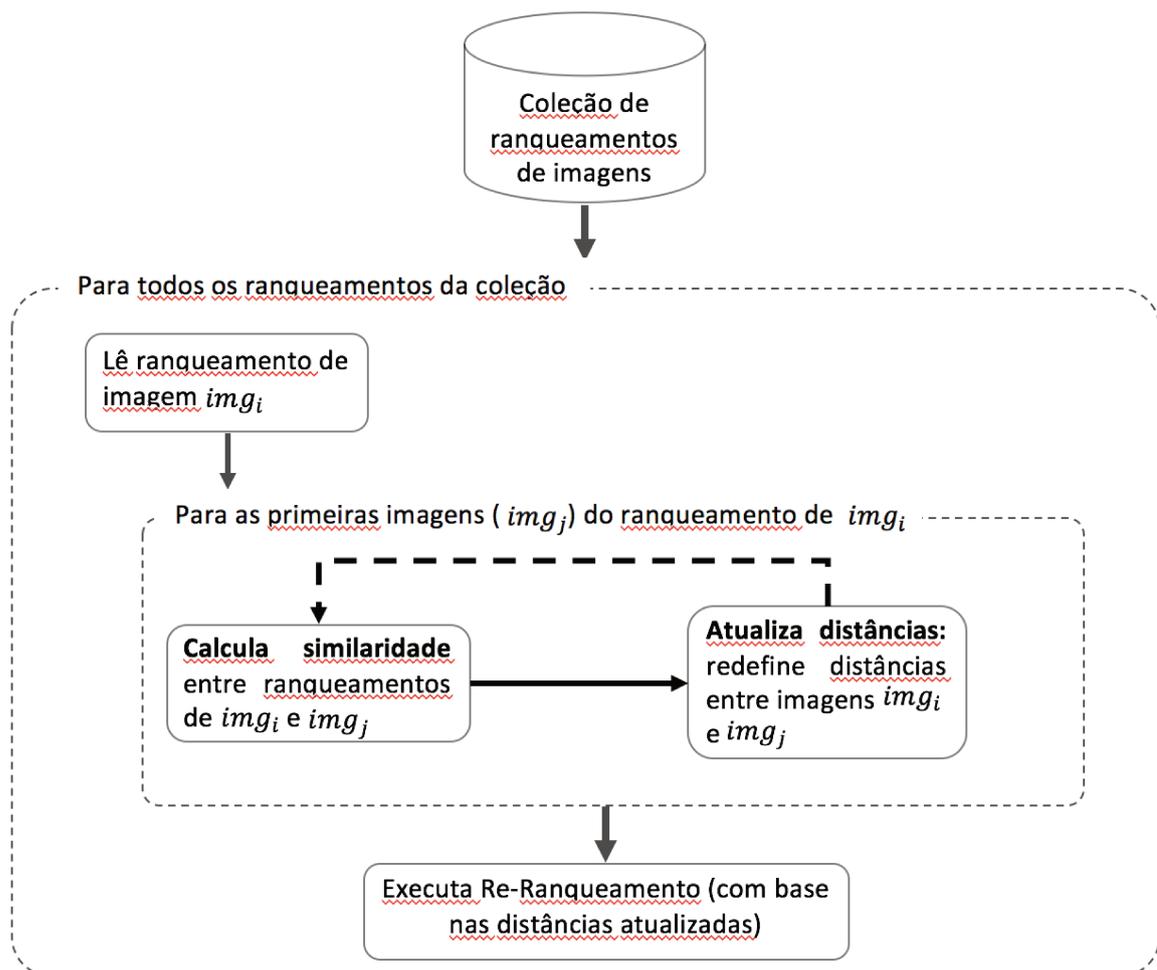


Figura 12 – Diagrama que apresenta uma visão geral do algoritmo RL-Sim.

Métrica Contextual de Distância Baseada em Ranqueamento

Dado um conjunto inicial de listas ranqueadas, o algoritmo RL-Sim utiliza uma abordagem iterativa (PEDRONETTE; TORRES, 2013), usando uma métrica de distância baseada na similaridade entre as listas ranqueadas. Formalmente, seja $(^t)$ a notação utilizada para a iteração atual, um novo e mais efetivo conjunto de listas ranqueadas $R^{(t+1)}$ é calculado levando em consideração as distâncias entre as listas ranqueadas. Após, $R^{(t+1)}$ é utilizado na próxima execução do algoritmo de re-ranqueamento e assim sucessivamente. Estes passos são repetidos ao longo de iterações com o objetivo de melhorar a eficácia de forma incremental. Depois de um número T de iterações, é realizada uma reclassificação definitiva.

Assim, a métrica contextual de distância calculada a cada iteração baseia-se na suposição de que as imagens melhor classificadas (*top-k*) são semelhantes entre si e suas listas ranqueadas contêm algumas imagens em comum (PEDRONETTE; TORRES, 2013). Neste cenário, o cálculo da similaridade entre as imagens depende do uso de métricas de correlação de ranqueamento.

Uma métrica contextual de distância é aprendida iterativamente em um cenário não supervisionado através da informação contextual fornecida por métricas de correlação de ranqueamento. Consideremos o conjunto $N(i, k)$ de uma imagem img_i , que contém as imagens mais similares de img_i de acordo com uma determinada distância ρ . O conjunto $N(i, k)$ pode ser obtido pelos k vizinhos mais próximos, onde a cardinalidade do conjunto é indicada por $|N(i, k)| = k$.

Seja $d(\tau_i, \tau_j, k)$ uma métrica de correlação entre listas ranqueadas considerando suas primeiras posições definidas pelo conjunto $N(i)$ e $N(j)$, definida pelo intervalo $[0,1]$, uma métrica de distância $\rho_c(img_i, img_j)$ baseada na comparação das listas ranqueadas τ_i e τ_j pode ser determinada da seguinte forma:

$$\rho_c(img_i, img_j) = d(\tau_i, \tau_j, k) \quad (2.20)$$

Com base na conjectura de que a métrica de distância ρ_c representa uma distância mais eficaz entre imagens (PEDRONETTE; TORRES, 2013), a distância entre todas as imagens em uma coleção pode ser recalculada baseada nesta métrica. Portanto, um novo conjunto de listas ranqueadas pode ser obtido de tal modo que a distância contextual pode também ser recalculada e o processo pode se repetir de maneira iterativa. Seja $(^t)$ a atual iteração e seja $\tau_i^{(t)}$ a lista ranqueada da iteração t . Seja $\rho_c^{(0)}$ a distância contextual da primeira iteração, que é igual à distância definida pelo descritor visual, tal que $\rho_c^{(0)}(img_i, img_j) = \rho(img_i, img_j)$ para todas as imagens $img_i, img_j \in C$. A métrica

iterativa é definida como:

$$\rho_c^{(t+1)}(img_i, img_j) = d(\tau_i^{(t)}, \tau_j^{(t)}, k) \quad (2.21)$$

Então, espera-se que a eficácia da medida de distância melhore ao longo das iterações, de maneira que as imagens não relevantes sejam removidas das primeiras posições das listas ranqueadas. Desta maneira, o tamanho da vizinhança k pode ser aumentada por considerar mais imagens ao longo das iterações (PADOVESE, 2017). Assim, a métrica pode ser redefinida como:

$$\rho_c^{(t+1)}(img_i, img_j) = d(\tau_i^{(t)}, \tau_j^{(t)}, k + t) \quad (2.22)$$

Depois de um determinado número T de iterações, uma nova distância é calculada com base na métrica de distância contextual:

$$\hat{\rho}(img_i, img_j) = \rho_c^{(T)}(img_i, img_j) \quad (2.23)$$

Finalmente, utilizando-se a distância $\hat{\rho}$, uma nova matriz de distância pode ser calculada como $\hat{A}_{ij} = \hat{\rho}(img_i, img_j)$. Baseada em \hat{A} , um novo conjunto de listas ranqueadas \hat{R} também pode ser calculado.

Métrica de Intersecção

O algoritmo RL-Sim possibilita o uso de diversas métricas de distância. É possível citar algumas como (OKADA *et al.*, 2015) : Métrica de Intersecção, Kendall τ , Spearman ρ , Jaccard, Goodman e Kendall τ_w , entre outras. Neste trabalho foi utilizada a métrica clássica de intersecção, a qual consiste na captura da sobreposição cumulativa, entre duas listas ranqueadas, em profundidades k crescentes (medida de similaridade) (FAGIN *et al.*, 2003). Formalmente, a Métrica de Intersecção pode ser definida como:

$$\psi(\tau_i, \tau_j, k) = \frac{\sum_{k_c=1}^k |N(i, k_c) \cap N(j, k_c)|}{k} \quad (2.24)$$

Então, a métrica de distância d_ψ pode ser definida como:

$$d_\psi(\tau_i, \tau_j, k) = \frac{\sum_{k_c=1}^k |N(i, k_c) \cap N(j, k_c)|}{k} \quad (2.25)$$

A Figura 13 ilustra a métrica de intersecção, onde duas listas ranqueadas, R_x e R_y , são tão similares quanto maior for o valor ψ calculado pelo número de interseções no conjunto vizinhança.

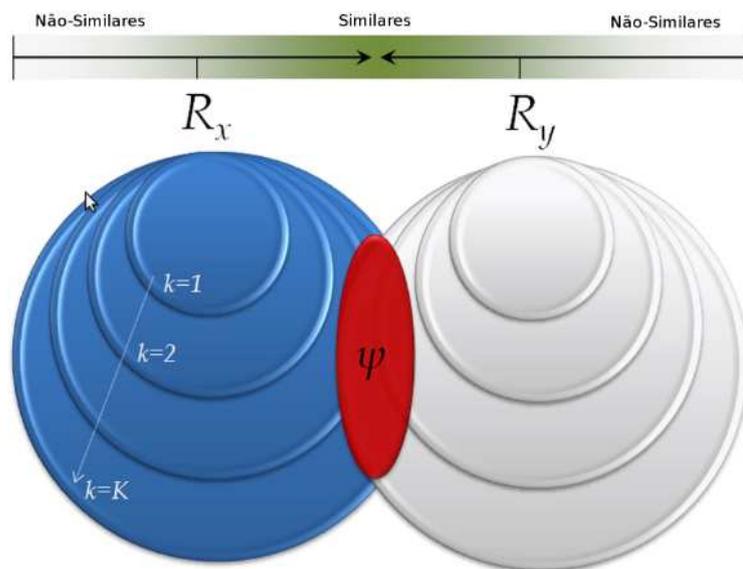


Figura 13 – Métrica de Intersecção (PEDRONETTE; TORRES, 2013).

2.7 Trabalhos Relacionados

Ao realizar-se uma revisão bibliográfica dos assuntos abordados neste trabalho, foi possível observar que as técnicas aqui propostas assemelham-se às pesquisas de outros autores na literatura acadêmica recente.

Esta seção tem por objetivo apresentar alguns trabalhos relacionados aos principais temas desta pesquisa: análise de folhas infectadas por patologias, ranqueamento e re-ranqueamento.

2.7.1 Trabalhos Relacionados à Análise de folhas infectadas por doenças

Em relação aos trabalhos que abordam o estudo de folhas de plantas infectadas por patologias, o trabalho de (RIBEIRO, 2012) utilizou métodos de segmentação por cor e análise de textura para avaliar folhas de citros afetadas por doenças diversas (como *Greening*, CVC e rubelose), tendo esse trabalho como objetivo principal a diferenciação do *Greening* de outras doenças. Foram realizados dois experimentos, um que utilizou métodos de segmentação baseados em RNA PMC (Redes Neurais Artificiais *Perceptron* Multicamadas) e outro que utilizou os descritores de textura LBP, LFP e os de *Haralick*, os quais se mostraram mais eficientes que o primeiro experimento com as Redes Neurais. Ao se analisar os resultados, o descritor LBP destacou-se como o mais eficiente na tarefa de diferenciar o *Greening* de outras pragas, tendo alcançado índices de sensibilidade de até 97%.

Em (MARATHE; KOTHE, 2013), foi proposto um método que utiliza técnicas de Processamento de Imagens para a detecção da área de folhas infectadas por doenças.

O método sugere a utilização do cálculo de *pixels* de uma imagem para determinar a área total de uma folha e a área total de cor verde. Após, calcula-se a porcentagem de área infectada ao subtrair a área total verde pela área total da folha. Experimentos realizados comprovaram que o método foi capaz de computar de maneira eficaz a área total e área verde da folha e utilizar tais dados no cálculo de porcentagem da área infectada de uma folha. A abordagem proposta possibilitou a automatização do processo de detecção de doenças de plantas e, em comparação aos métodos manuais utilizados, mostrou-se eficaz ao consumir menos tempo e esforço, além de apresentar bons índices de precisão e acurácia.

Em outro trabalho, de (PEREIRA *et al.*, 2014), foi feita a inoculação da doença CVC em folhas de tabaco. Folhas de plantas infectadas foram digitalizadas com o propósito de serem analisadas através de um *software* de edição de imagens, o que permitiu que fosse feita uma classificação de cada folha de acordo com o nível de infecção que apresentava. Esta fase de análise e classificação possibilitou o desenvolvimento de uma escala diagramática que auxilia na denotação de folhas de acordo com seu nível de infecção, sendo 1 o nível mais baixo e 6 o nível mais severo. Foi realizado um experimento em que avaliadores inexperientes utilizaram a escala diagramática para avaliar visualmente as folhas de tabaco e assim puderam designar-lhes notas que indicavam seu grau de infecção.

No trabalho de (WARNE; GANORKAR, 2015) foram propostas técnicas para a detecção de doenças em folhas de algodão, as quais poderiam ser relacionadas a bactérias, fungos ou vírus. Inicialmente foi feita a captura digital de imagens de folhas de algodão, as quais posteriormente foram processadas através de histogramas de equalização com o propósito de aprimorá-las, retirando possíveis ruídos de sua superfície na imagem. Em seguida, foi utilizado um algoritmo de *cluster k-means* em conjunto com a função de distância Euclidiana para classificar as imagens de folhas em relação às imagens de uma base de dados previamente preparada. Resultados obtidos com este experimento atingiram níveis de acurácia de até 89,56%, o que fez os autores concluírem que o método proposto foi o melhor para a detecção de doenças em folhas de algodão.

Finalmente, em (BATULE *et al.*, 2016), foi proposto um estudo em que seria utilizado um algoritmo *k-means* para detectar doenças na superfície de folhas de plantas em geral. Inicialmente, a abordagem propõe que imagens de folhas sejam convertidas do modelo de cor RGB para o HSV (*Hue, Saturation, Value*). Na sequência, técnicas de *threshold* seriam utilizadas para separar o fundo (*background*) do primeiro plano, extraíndo-se de cada imagem a região de interesse para análise. Captada a região de interesse de cada imagem, seriam extraídas suas características e aplicado o algoritmo *k-means*, o qual faria a separação das imagens em grupos, de acordo com sua infecção. A implantação do método proposto seria útil à prevenção de perdas na produção agrícola mundial.

2.7.2 Trabalhos Relacionados a Ranqueamento e Re-ranqueamento

Em relação ao ranqueamento de imagens, no trabalho desenvolvido por (FERREIRA *et al.*, 2011) foram apresentados dois *frameworks* de CBIR baseados na relevância de *feedback* de usuários. O primeiro explora apenas a seleção de imagens consideradas pelos usuários como relevantes. O segundo considera tanto as imagens relevantes indicadas pelos usuários quanto aquelas classificadas como irrelevantes. Ambos utilizam técnicas de programação genética para captar preferências dos usuários. Após aplicação de tais técnicas, as imagens são apresentadas em um ranqueamento, ordenadas de acordo com o grau de similaridade que apresentam em relação à imagem de consulta selecionada.

Já em (LIU *et al.*, 2011), foi proposto um novo descritor chamado de *micro-structure descriptor* (MSD). Por integrar informações de cor, forma e textura como um todo na recuperação de imagens, o MSD consegue simular a percepção visual humana. Através de experimentos realizados em grandes coleções, demonstrou-se que o descritor proposto apresenta níveis altos de precisão na recuperação e ranqueamento de imagens.

Em relação aos trabalhos que abordam propostas de re-ranqueamento de imagens, o trabalho de (CUI *et al.*, 2008) apresentou uma técnica baseada no aprendizado ao modelar interações de usuários de modo a ajustá-las para obter combinações e seleção de características relacionadas à busca feita. A técnica, chamada de *IntentSearch*, foi desenvolvida com o propósito de realizar, em tempo real, consultas de imagens na *Web*. Ao receber uma imagem de consulta especificada por um usuário, o *IntentSearch* compreende as intenções do usuário e, baseado nelas, realiza o re-ranqueamento de consultas textuais de maneira interativa, apresentando ao usuários imagens semelhantes à de consulta.

O trabalho de (PEDRONETTE; TORRES, 2013) propôs uma técnica que redefine distâncias entre imagens levando em consideração a similaridade que há entre suas listas ranqueadas. Para isso, é apresentado o algoritmo RL-Sim que, através de um ranqueamento inicial, produz uma nova matriz de distâncias otimizada. A partir desta nova matriz, é possível obter ranqueamentos mais eficientes. Foram criados ranqueamentos iniciais utilizando-se descritores de forma, de cor e de textura. Após a execução do re-ranqueamento, todos os descritores apresentaram ganho de eficácia em relação aos ranqueamentos iniciais, sendo que os descritores de forma apresentaram os maiores ganhos de eficácia (30,90%), seguidos dos descritores de cor (23,18%) e de textura (10,27%). Em comparação com outros métodos (*Graph Transduction* (LING; JACOBS, 2007), *Shortest path propagation* (WANG *et al.*, 2011) e *Locally constrained diffusion process* (YANG *et al.*, 2009), por exemplo), o RL-Sim mostrou-se mais eficiente, apresentando ganhos de precisão de até 12,91%.

Em (VALEM *et al.*, 2015), foi proposto um método de aprendizado não-

supervisionado que teve por objetivo a melhora dos resultados obtidos em tarefas de recuperação. Para isto, foi desenvolvido um algoritmo chamado *RL-Recommendation*, o qual simula a abordagem de recomendações, criada originalmente para seleção automática de itens que vão de encontro a preferências pessoais. No *RL-Recommendation*, as recomendações são executadas com base nas informações codificadas que se encontram nas listas ranqueadas, sendo que as imagens no topo da lista são recomendadas umas às outras. Neste cenário, não só a distância entre duas imagens deve diminuir como ambas devem ser movidas para posições melhores nas listas ranqueadas uma da outra. Este método, ao contrário de outros métodos de re-ranqueamento, não requer todos os valores de distância entre as imagens de um conjunto, mas apenas o valor de distância daquelas que estão no topo das listas ranqueadas, o que faz dele um método que requer pouco esforço computacional. Resultados de experimentos demonstraram ganhos de eficácia de até 29% ao se utilizar esta abordagem e, em comparação a outros métodos (como o *Pairwise Recommendation* (PEDRONETTE; TORRES, 2012b)), o *RL-Recommendation* apresentou resultados superiores de eficácia.

Em um trabalho mais recente, (PADOVESE, 2017) propôs uma nova abordagem de recuperação de imagens para auxílio ao diagnóstico precoce da doença de Alzheimer. Em uma etapa inicial, foram utilizados descritores de uso geral para processar e recuperar exames de ressonância magnética cerebral. Em seguida, foram aplicados dois algoritmos de aprendizado não-supervisionado baseados em ranqueamento (RL-Sim e ReckNN) com o intuito de melhorar a eficácia dos resultados iniciais. Os resultados experimentais obtidos neste trabalho demonstraram que a abordagem proposta mostrou-se adequada ao propósito de auxiliar profissionais da área médica na recuperação de imagens similares em relação a um determinado diagnóstico.

Ao estudar os trabalhos relacionados, é possível analisar as semelhanças e diferenças deste trabalho em relação a alguns dos que foram apresentados. O trabalho de (PEREIRA *et al.*, 2014) (que também analisou imagens de folhas de tabacos infectadas por CVC) utilizou técnicas manuais para a classificação de folhas de tabaco infectadas por CVC, enquanto que neste trabalho a análise e classificação das imagens de folhas foi feita através de técnicas (descritores de textura e funções de distância) que permitem a automatização de fases de pré-processamento e ranqueamento das imagens de folhas. No que se refere à proposta de utilizar re-ranqueamento como técnica para obtenção de melhores resultados de classificação, este trabalho também assemelha-se aos trabalhos de (PADOVESE, 2017) e (PEDRONETTE; TORRES, 2012a), porém com aplicação a imagens de folhas de tabaco, enquanto que o trabalho de (PADOVESE, 2017) foi aplicado a imagens de ressonância magnética e o trabalho de (PEDRONETTE; TORRES, 2012a) foi aplicado a diversos *datasets* de imagens que compreendiam coleções de forma e textura.

3 Ranqueamento e Re-ranqueamento de Folhas de Tabaco - Abordagem proposta

Neste Capítulo é descrita a abordagem adotada para o desenvolvimento da pesquisa, desde o processo de recuperação de imagens de folhas de tabaco afetadas pela CVC até a geração de ranqueamentos de similaridade e o processo de re-ranqueamento. Como ambiente computacional foi utilizado o *software* Matlab para o desenvolvimento desta pesquisa.

O Capítulo está organizado da seguinte maneira: A Seção 3.1 descreve o *dataset* de imagens e sua captação. Em seguida, a Seção 3.2 discorre sobre a metodologia que esta abordagem propõe, que inclui o pré-processamento de imagens, a extração de características delas, a criação de ranqueamentos de similaridade e o processamento de re-ranqueamento.

3.1 Descrição da coleção de imagens

A coleção de imagens utilizada nesta pesquisa foi cedida por pesquisadores do Centro de Citricultura Sylvio Moreira, sendo esta coleção parte do trabalho de (PEREIRA *et al.*, 2014).

Para aquisição das imagens, primeiramente foi feita a inoculação da bactéria *Xylella fastidiosa* nas plantas de tabaco. Uma vez identificados os sintomas, foram coletadas amostras de folhas de diversos níveis de severidade de infecção da doença. Em uma segunda fase da pesquisa foram escaneadas folhas coloridas (modelo RGB), as quais foram agrupadas em conjuntos de folhas neste processo de digitalização. Finalmente, após a digitalização das imagens, avaliadores do Centro de Citricultura que não tinham experiência na avaliação de doenças de plantas utilizaram uma escala diagramática desenvolvida por (PEREIRA *et al.*, 2014) para a classificação de parte das imagens de acordo com o grau de sintomas de CVC que apresentavam. Tal classificação foi feita através da atribuição de notas em uma escala de 1 a 6, sendo a nota 1 o grau de menor infecção da doença em uma folha e 6 o grau de maior infecção.

A Figura 14 mostra a escala diagramática desenvolvida em (PEREIRA *et al.*, 2014) e que foi utilizada por avaliadores para a classificação de grau de sintomas de CVC das imagens de plantas de tabaco. As porcentagens que estão à esquerda de cada imagem de folha referem-se à quantidade da região da folha que foi afetada pela CVC. Cada

porcentagem corresponde a determinada nota em uma escala de 1 a 6, portanto, 0,6% refere-se à nota 1, 4,5% refere-se à nota 2, 11% refere-se à nota 3, 18% refere-se à nota 4, 28% refere-se à nota 5 e, enfim, 48% refere-se à nota 6.



Figura 14 – Escala diagramática utilizada para avaliação das imagens de folha de tabaco afetadas por CVC. Cada imagem de folha na escala representa uma nota de grau de infecção, numa escala de 1 a 6 (PEREIRA *et al.*, 2014).

A Figura 15 mostra uma das imagens da coleção cedida para esta pesquisa.



Figura 15 – Exemplo de imagem cedida pelos pesquisadores do Centro de Citricultura Sylvio Moreira.

3.2 Metodologia

A abordagem proposta consiste de 4 fases sequenciais, conforme ilustra o diagrama de blocos da Figura 16 : (i) pré-processamento; (ii) extração de características; (iii) Ranqueamento (*Ranking*) e (iv) Re-ranqueamento (*Re-ranking*).

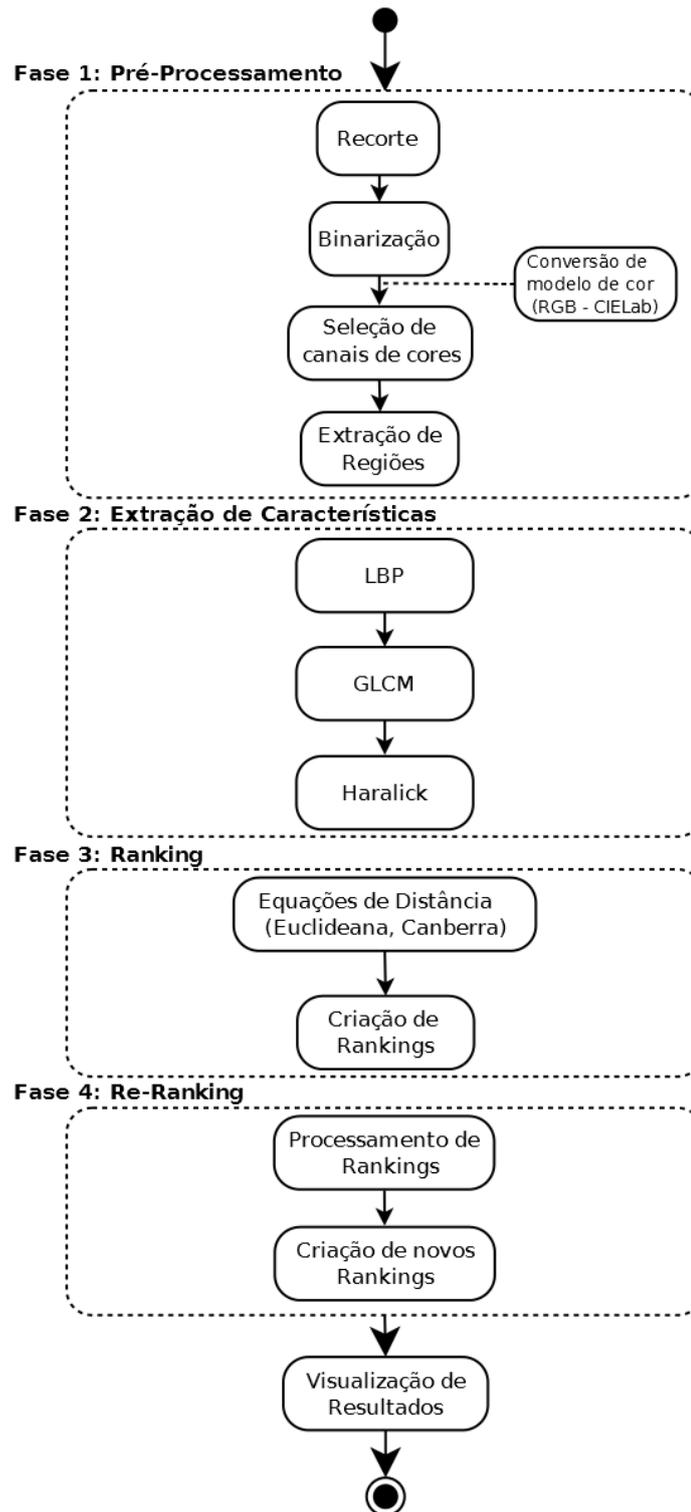


Figura 16 – Diagrama de blocos que ilustra a metodologia proposta.

As fases mostradas no diagrama serão detalhadas a seguir.

3.2.1 Pré-Processamento

A fase de Pré-Processamento é composta de 5 fases, descritas na sequência.

3.2.1.1 Recorte de imagens

Esta etapa foi necessária para a preparação das imagens de folhas cedidas para a pesquisa, visto que os arquivos de imagens RGB disponibilizados continham mais de uma folha de tabaco e isto prejudicaria as avaliações nas etapas seguintes. Utilizou-se, portanto, um *software* de edição de imagens para realizar o recorte manual das folhas por arquivo. A Figura 17 (a) apresenta imagens antes do recorte, na qual cada arquivo possui três folhas. A Figura 17 (b) apresenta uma imagem após o recorte, e contém a imagem da folha que estava no centro da Figura 17 (a).

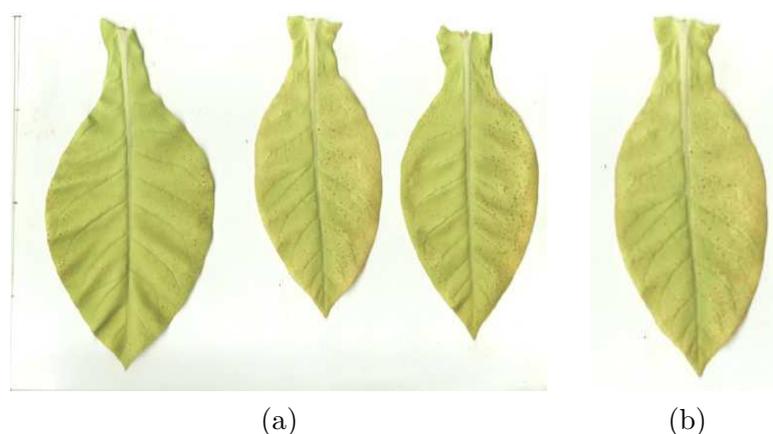


Figura 17 – Amostras de imagens de folhas afetadas por CVC. (a) Amostra original, com três imagens de folhas infectadas; (b) Amostra de imagem recortada, com apenas uma imagem de folha.

O recorte realizado possibilitou a geração de novos arquivos, cada um contendo apenas uma imagem de folha de tabaco. Feito este processo, passou-se à fase seguinte, de binarização.

3.2.1.2 Binarização de imagens

A fase de binarização tem como objetivo gerar uma imagem que contém região de folha e seu *background* separados. Para isto, foi desenvolvido um programa para modificar cada uma das imagens da coleção de forma que seu *background* passasse a ter apenas *pixels* de cor preta e a folha (parte de interesse na análise) passasse a ter *pixels* de cor branca, conforme ilustrado pela Figura 18.

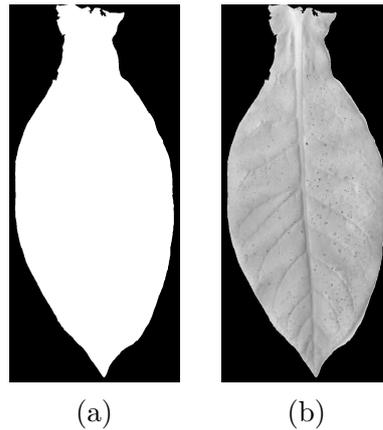


Figura 18 – Resultados da fase de binarização. (a) imagem após processo de binarização; (b) imagem com região da folha em tons de cinza e background preto, obtida através de imagem binarizada.

Para binarizar uma imagem, primeiramente é feita uma segmentação para separar seu fundo (*background*) da região da imagem que corresponde à folha. Como resultado desta segmentação, é obtida uma imagem de fundo composto de *pixels* pretos e cuja região da folha tem apenas *pixels* brancos. Esta imagem é então armazenada para ser utilizada como máscara na etapa seguinte.

Em seguida uma imagem original de cor RGB é transformada em uma imagem em tons de cinza. Feito isto, a imagem binarizada correspondente (mesmo nome de arquivo) é aplicada como máscara na imagem em tons de cinza, resultando em uma imagem cuja região de folha é em tons de cinza, enquanto que seu fundo é de *pixels* pretos, como mostrado na Figura 18 (b).

3.2.1.3 Conversão de modelo de cor RGB para CIELab

Toda a coleção de imagens utilizada nesta pesquisa está no modelo de cor RGB. No entanto, com a finalidade de validar o método apresentado, foi proposta a utilização de imagens em outros modelos de cor. Neste caso, o modelo de cor escolhido é o CIELab.

Para transformar as imagens da coleção desta pesquisa do modelo RGB para o modelo CIELab, foram utilizadas as equações apresentadas nos algoritmos 2.1 e 2.2 da Seção 2.4 do Capítulo 2.

No diagrama de blocos apresentado na Figura 16 esta etapa foi mostrada como adicional no processo, visto que é desnecessária para a geração dos ranqueamentos de imagens RGB.

3.2.1.4 Seleção de Canais de Cores

Após a conversão das imagens do modelo RGB para o CIELab, foi possível selecionar diferentes canais de cores para as imagens dos respectivos modelos. Nos dois casos, foi necessário gerar as imagens em tons de cinza antes de se fazer a seleção dos canais.

No caso das imagens em RGB, foram selecionados para análise apenas os canais de cores R e G, visto que a cor azul do canal B tem pouca relevância nas imagens de folhas. Já em relação às imagens do modelo CIELab, foram selecionados os canais L (luminância), a (sendo +a vermelho e -a o verde), e b (onde +b indica amarelo e -b indica azul).

Cada canal de cor selecionado foi gravado em uma nova imagem identificada pelo canal de cor correspondente. A Figura 19 apresenta os resultados das seleções de cores efetuadas, sobre a máscara binarizada, para o modelo de cor RGB.

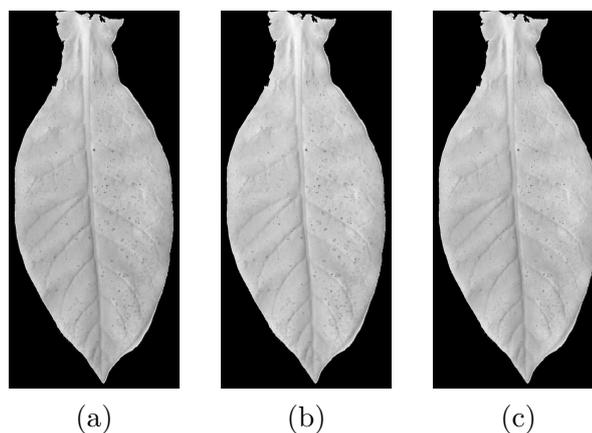


Figura 19 – Resultados da fase de seleção de canais de cores. (a) Imagem em tons de cinza; (b) imagem em canal de cor verde; (c) imagem em canal de cor vermelho.

A Figura 20 apresenta os resultados das seleções de cores efetuadas, sobre a máscara binarizada, para o modelo de cor CIELab. Neste caso, é possível perceber a olho nu a diferença entre as imagens para cada canal de cor selecionado, o que não acontece com as imagens do modelo RGB.

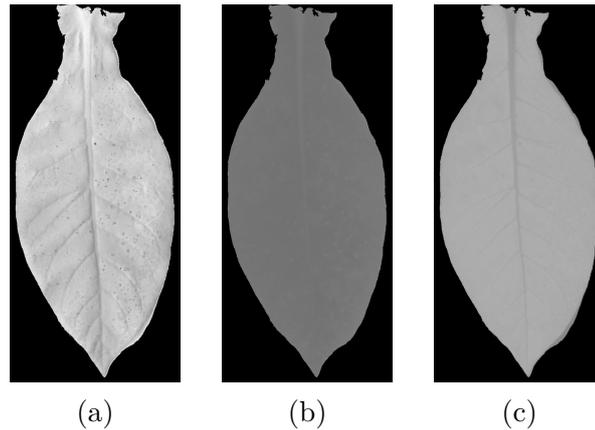


Figura 20 – Resultados da fase de seleção de canais de cores. (a) Imagem em tons de cinza; (b) imagem em canal de cor verde; (c) imagem em canal de cor vermelho.

3.2.1.5 Extração de regiões de interesse

Esta etapa tem por finalidade a seleção de regiões específicas de cada imagem para que, na sequência, possam ser calculados os descritores de textura. Para isto, foi desenvolvido um procedimento cuja técnica consiste primeiro na localização do centróide da folha na imagem, desconsiderando os *pixels* de cor preta, para então extrair uma região retangular. Esta etapa é automática e tem grande importância, pois gerará regiões de imagens de mesmas dimensões, o que possibilita o cálculo da similaridade entre os *pixels* nas etapas seguintes.

A Figura 21 (a) apresenta uma imagem e a seleção feitas nesta etapa, sendo o retângulo a área onde é realizado o corte da região de interesse. A Figura 21 (b) apresenta a região extraída que será utilizada nas fases seguintes.

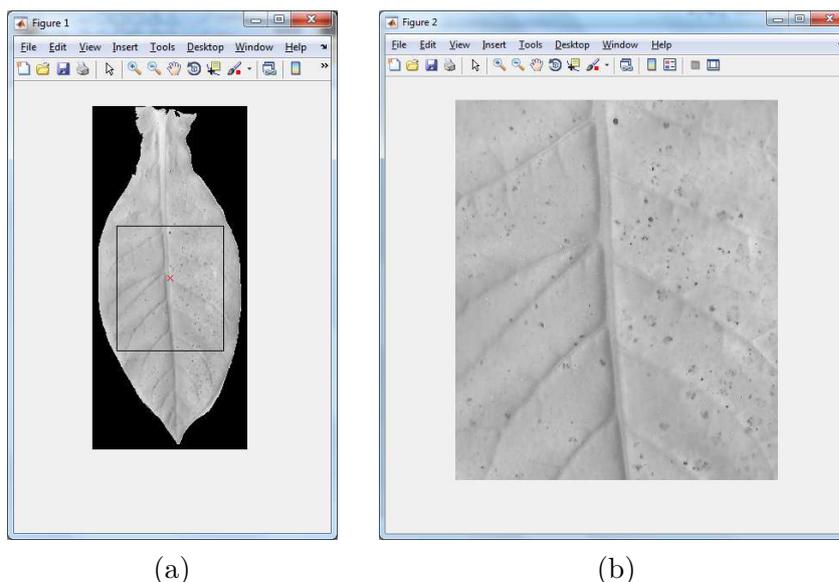


Figura 21 – Exemplo de resultado da fase de extração de regiões. (a) imagem que mostra a seleção da área que será recortada na imagem da folha; (b) região extraída da imagem da folha.

A etapa de extração de regiões é a última na fase de pre-processamento na metodologia desta pesquisa. Após ela, é iniciada a fase de criação extração de características através do uso de descritores.

3.2.2 Extração de Características

Para esta etapa, foram utilizados descritores de textura, os quais foram apresentados no Capítulo 2 deste trabalho. Os descritores utilizados foram o *Local Binary Pattern* (LBP), o *Gray-Level Co-Occurrence Matrix* (GLCM) e o descritor de *Haralick*, cujas técnicas são apresentadas a seguir.

3.2.2.1 Extração de Características com o descritor LBP

A extração de características através do descritor LBP é constituída de dois procedimentos: inicialmente, são calculados os códigos LBP para cada imagem em cada modelo e canal de cor, e em seguida são gerados os histogramas que contém os códigos LBP referentes a cada imagem. Os histogramas gerados são armazenados e utilizados no cálculo de similaridade entre todas as imagens (fase de criação de ranqueamentos).

A Figura 22 (a) mostra a região da imagem antes da aplicação do cálculo do LBP, enquanto que a Figura 22 (b) mostra a região da mesma imagem após o cálculo do descritor LBP.

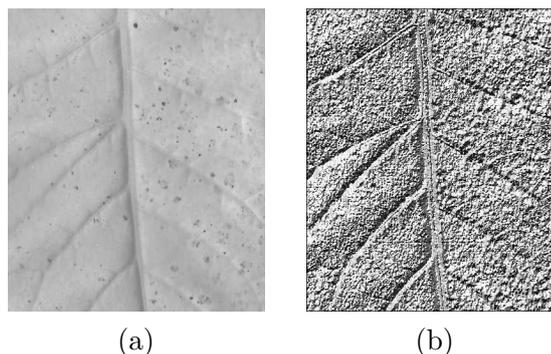


Figura 22 – Resultados da fase de execução do cálculo do LBP na região da imagem da folha. (a) imagem antes da execução do cálculo de LBP; (b) imagem gerada após execução do cálculo de LBP.

3.2.2.2 Extração de Características com o descritor GLCM

Para realizar a extração de características através do descritor GLCM, foi necessário calcular uma matriz GLCM para cada região extraída de cada modelo e canal de cor. Assim, para cada imagem foi gerada um arquivo que contém os dados da matriz GLCM.

3.2.2.3 Extração de Características com o descritor de Haralick

Conforme mencionado, os descritores de Haralick possibilitam a extração de características de textura de imagem a partir de uma matriz de co-ocorrência (GLCM). Foram extraídas as seguintes características: segundo momento angular, contraste, correlação, variância, momento de diferença inverso, média da soma, variância da soma, entropia da soma, entropia, variância da diferença, entropia da diferença, medidas de informação da correlação (com duas propriedades) e coeficiente de correlação máximo.

A extração de características com o descritor de *Haralick* para cada modelo e canal de cor foi feita a partir das matrizes de co-ocorrência geradas com o descritor GLCM.

3.2.3 Ranqueamento

Esta etapa tem como objetivo o processamento dos ranqueamentos de similaridade entre as imagens. Para isto, foi criado um procedimento que utiliza as funções de distância Euclidiana e Canberra para calcular a distância entre as imagens do *dataset* desta pesquisa.

Em síntese, o processamento de ranqueamento ocorre da seguinte maneira: após a extração de características de imagens, são calculadas as distâncias entre todas as imagens e, a partir delas, criados os ranqueamentos de similaridade entre as imagens.

Tanto as distâncias calculadas quanto os ranqueamentos criados são armazenados em arquivos de texto que serão utilizados posteriormente. A Figura 23 ilustra esta etapa de processamento de ranqueamento.

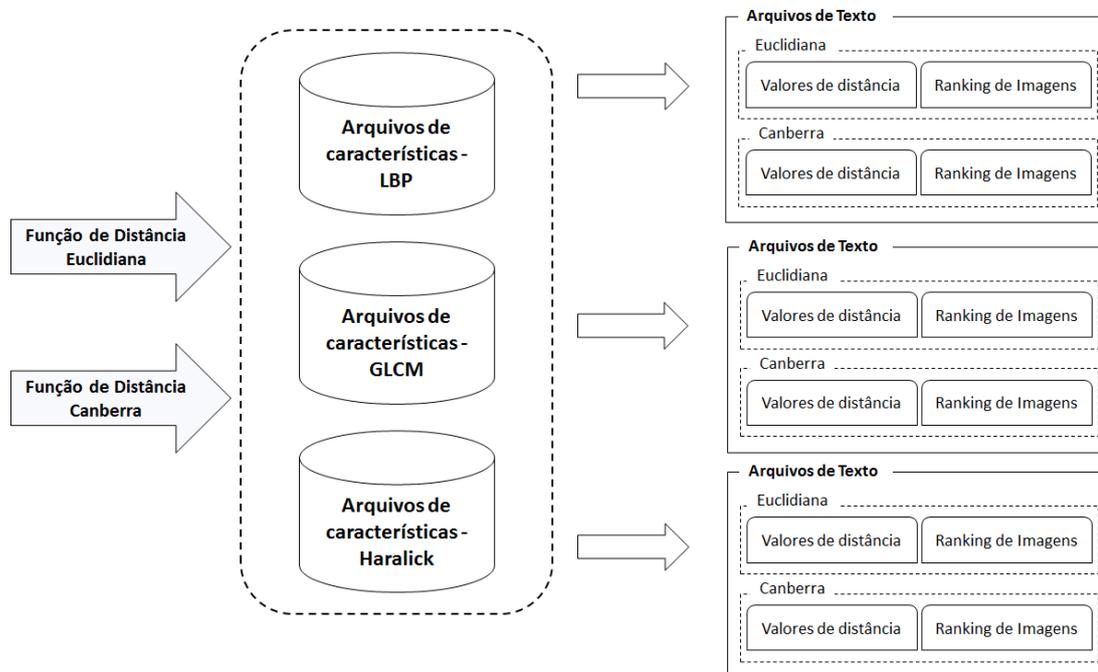


Figura 23 – Diagrama que ilustra o processamento de ranqueamento.

É necessário ressaltar que os arquivos de texto que contêm as distâncias e *rankings* são gerados para cada um dos canais de cor selecionados em cada modelo de cor e para cada descritor e função de distância utilizados. Para o modelo de cor RGB e com o uso do descritor LBP no canal R, por exemplo, são gerados 4 arquivos de texto (2 deles contêm as distâncias obtidas com as funções Euclidiana e de Canberra e os outros dois contêm os *rankings* gerados a partir de tais valores de distância). Da mesma maneira, ainda no modelo de cor RGB e utilizando o descritor GLCM também no canal de cor R, também serão gerados 4 arquivos de texto (e o mesmo acontecerá para o descritor *Haralick* no canal de cor R). Ao somar a quantidade de arquivos gerados para o canal de cor R e com aplicação de todos os descritores, o resultado será de 12 arquivos. Como são 3 canais (R, G, e B) e para cada um deles serão gerados 12 arquivos de texto, chega-se ao total de 36 arquivos para o modelo de cor RGB. De maneira semelhante ocorrerá a geração de arquivos para o modelo de cor CIELab: serão geradas também 36 arquivos de texto (12 para cada canal de cor: L, a ou b) e assim, no total, serão gerados 72 arquivos, sendo que 36 apresentam os valores de distância entre todas as imagens e outros 36 apresentam o *Ranking* de similaridade entre as imagens.

3.2.4 Re-ranqueamento

Esta etapa tem por objetivo a melhoria dos ranqueamentos criados na etapa anterior. Para isso, foi utilizado o algoritmo RL-Sim (*RankedLists-Similarities*) (PEDRO-NETTE; TORRES, 2013).

Conforme mencionado no Capítulo 2, o algoritmo RL-Sim é capaz de realizar re-ranqueamentos ao explorar a informação de similaridade existente entre listas ranqueadas. Para isso, o algoritmo analisa a similaridade de duas imagens e, sendo elas de fato similares, assume que suas listas ranqueadas também devem ser similares. Ao final de sua execução, o algoritmo é capaz de aumentar a eficácia do ranqueamento que foi realizado, gerando listas ranqueadas melhores.

Em síntese, o objetivo do RL-Sim é explorar o conjunto inicial de listas ranqueadas $R = \{R_1, R_2, \dots, R_N\}$ para calcular uma matriz de distância \hat{A} mais eficaz e, portanto, um conjunto de listas ranqueadas \hat{R} mais eficaz. O algoritmo RL-Sim é baseado na métrica contextual ρ_c , apresentada na Subseção 2.6.1.1 do Capítulo 2, a qual leva em consideração a similaridade entre listas ranqueadas de maneira iterativa (PEDRO-NETTE; TORRES, 2012a). Para iniciar sua execução, o RL-Sim recebe como entrada dois arquivos: o primeiro contém o nome de todos arquivos de imagens, enquanto que o segundo contém os valores de distância entre todas as imagens (arquivos gerados na etapa de ranqueamento). No fim de sua execução, após analisar todas as listas ranqueadas, é gerada uma nova matriz de distâncias otimizada. O algoritmo 3.1 representa um esboço do que propõe o RL-Sim.

Algoritmo 3.1 O Algoritmo de re-ranqueamento RL-Sim (PEDRONETTE; TORRES, 2012a)

Entrada: Conjunto original de listas ranqueadas R e parâmetros k_s , T e λ

Saída: Conjunto de listas ranqueadas \hat{R}

```

1:  $t \leftarrow 0$ 
2:  $\hat{R}^{(t)} \leftarrow R$ 
3:  $A^{(t)} \leftarrow A$ 
4:  $k \leftarrow k_s$ 
5: enquanto  $t < T$  faça
6:   para todo  $R_i \in R^{(t)}$  faça
7:      $c \leftarrow 0$ 
8:     para todo  $img_i \in R_i$  faça
9:       se  $c \leq \lambda$  então
10:         $A^{(t+1)}[i, j] \leftarrow d(\tau_i, \tau_j, k)$ 
11:       senão
12:         $A^{(t+1)}[i, j] \leftarrow 1 + A^{(t)}[i, j]$ 
13:       fim se
14:      $c \leftarrow c + 1$ 
15:   fim para
16: fim para
17:  $R^{(t+1)} \leftarrow executarReranking(A^{(t+1)})$ 
18:  $k \leftarrow k + 1$ 
19:  $t \leftarrow t + 1$ 
20: fim enquanto
21:  $\hat{R} \leftarrow R^{(T)}$ 

```

É necessário observar que as distâncias são redefinidas considerando-se a função $d(\tau_i, \tau_j, k)$ para as primeiras λ posições de cada lista ranqueada, tal que $\lambda \in \mathbb{N}$ e $0 \leq \lambda \leq N$. Para as imagens nas posições restantes das listas ranqueadas, a nova distância é redefinida (linha 12 do Algoritmo 3.1) com base nas distâncias atuais. Nestes casos, a função $d(\tau_i, \tau_j, k)$ não precisa ser calculada, considerando-se que as imagens relevantes devem estar no começo das listas ranqueadas. Desta maneira, os esforços computacionais são reduzidos, fazendo com que este passo do algoritmo não dependa do tamanho N da coleção.

Na linha 18, a cada iteração t , é incrementado o número k de vizinhos considerados. A motivação deste incremento está ligada ao fato de que a eficácia das listas ranqueadas aumenta ao longo das iterações. Assim, imagens não relevantes são removidas das primeiras posições das listas ranqueadas e k pode ser aumentado de maneira que mais imagens sejam consideradas.

4 Experimentos, Resultados e Discussões

Neste capítulo serão apresentados os resultados obtidos pela avaliação experimental realizada. Alguns experimentos foram conduzidos com o objetivo de avaliar a precisão obtida através dos métodos propostos, os quais consideraram o uso de um *dataset* de imagens, descritores de textura, canais de cores e funções de distância.

O capítulo é organizado da seguinte forma: A Seção 4.1 descreve o protocolo experimental adotado. Já a Seção 4.2 apresenta os experimentos realizados com todas as imagens do *dataset*, com a seleção dos melhores conjuntos de descritores, canal de cor e função de distância, a aplicação do algoritmo RL-Sim e seu desempenho e os resultados obtidos. A Seção 4.3 é semelhante à anterior, porém apresenta os experimentos e resultados obtidos apenas com as imagens que foram avaliadas e receberam notas com o grau de infecção do CVC que apresentavam.

4.1 Protocolo Experimental

No intuito de avaliar os métodos propostos nesta pesquisa, foram realizados diversos experimentos. Nesta Seção é apresentado o protocolo experimental, o qual contém informações relacionadas ao *dataset* utilizado, à métrica de precisão e os cenários dos experimentos feitos.

Conforme descrito na Seção 3.1 do Capítulo 3, as imagens utilizadas nesta pesquisa foram cedidas por (PEREIRA *et al.*, 2014), que as escaneou e em sua pesquisa as classificou de acordo com grau de infecção de CVC que apresentavam. Conforme mencionado também no Capítulo 3, os arquivos cedidos apresentavam conjuntos de imagens com várias folhas, portanto foi necessário recortar as imagens e armazená-las em arquivos individuais para posterior processamento. Neste processo de recorte foram obtidas um total de 193 imagens de folhas, sendo que 95 apresentavam nota de classificação de infecção da doença de CVC enquanto que 98 não apresentavam nota (não foram avaliadas). Do total de 193 imagens, foi necessário descartar 21 delas já que, em função de sua baixa qualidade quando coletadas, estas apresentaram erros durante a fase de binarização.

A Figura 24 é um exemplo de imagem que foi descartada do conjunto total de imagens.



Figura 24 – Exemplo de imagem de folha descartada da coleção utilizada nos experimentos de avaliação.

Após o descarte realizado, obteve-se um total de 172 imagens, sendo que 86 foram avaliadas pelos pesquisadores do IAC e tinham nota de grau de infecção de CVC, enquanto que outras 86 não foram avaliadas.

Em relação à execução dos métodos e algoritmos utilizados neste trabalho, foi necessário definir alguns parâmetros experimentais. Para a execução do algoritmo RL-Sim em especial, foi necessário definir valores para os parâmetros k de vizinhança e T de iterações. Para isso, inicialmente foi escolhido um valor de $k = 5$ e $T = 3$ e, posteriormente, k variando entre $k = 2$ e $k = 16$. Essa escolha será explorada em seções mais adiante.

Para avaliar os resultados de recuperação dos métodos propostos, a métrica de avaliação escolhida foi a Precisão (*Precision*), definida a seguir:

$$precisão = \frac{|\{imagens recuperadas\} \cap \{imagens relevantes\}|}{|\{imagens recuperadas\}|} \quad (4.1)$$

onde $|\{imagens recuperadas\}|$ representa a quantidade total de imagens recuperadas, e $|\{imagens relevantes\}|$ representa a quantidade de imagens que fazem parte da mesma classe da imagem de entrada.

Ainda em relação a esta métrica de precisão, foram utilizadas duas medidas: a precisão entre as 5 primeiras posições (P-5) e a precisão entre as 10 primeiras posições (P-10). Isto é, quando se utiliza *Precision*, considera-se apenas as primeiras k posições para avaliação $|\{imagens recuperadas\}|$. Posteriormente também são apresentados os resultados da aplicação do algoritmo RL-Sim e o ganho relativo de cada descritor utilizado.

Enfim, os experimentos realizados estão detalhados e separados em seções a seguir, de acordo com seus objetivos.

4.2 Experimentos realizados com o *dataset* completo

Esta Seção tem por objetivo mostrar os experimentos realizados com as 172 imagens do *dataset* de folhas de tabaco infectadas por CVC. Todos os experimentos realizados, assim como os resultados obtidos e discussões sobre estes estão nas subseções adiante.

4.2.1 Seleção dos Conjuntos de descritores, canal de cor e função de distância

Este experimento inicial teve como objetivo a seleção dos descritores que, em conjunto com determinados canais de cores e funções de distância, obtiveram os melhores resultados de precisão após o re-ranqueamento de imagens de folhas de tabaco. Para a execução do re-ranqueamento, foi utilizado o algoritmo RL-Sim (descrito na Subseção 3.2.4 do Capítulo 3) com uma vizinhança fixa de $k = 5$. As Tabelas 5 e 6 apresentam os resultados obtidos para cada descritor nos modelos de cor RGB e CIELab, tendo sido destacados em negrito os resultados de maior precisão e ganhos obtidos com o RL-Sim. É importante observar como é feito o cálculo do ganho de precisão: divide-se o resultado de porcentagem final pelo resultado de porcentagem inicial, e em seguida subtrai-se 1 do total obtido através da divisão feita.

Tabela 1 – Experimento para seleção de conjuntos de descritores, canal de cor e função de distância no modelo de cor RGB: Resultados obtidos com $k = 5$ em ranqueamentos originais e após execução de re-ranqueamento através do algoritmo RL-Sim. A sigla “TC” refere-se ao canal de Tons de Cinza.

Descritor	Canal de cor	Função	P-5 (%)	P-5 RL-Sim	Ganho (%)	P-10 (%)	P-10 RL-Sim (%)	Ganho (%)
LBP	TC	Eucl.	32,91	32,56	-1,06	23,37	23,31	-0,26
LBP	TC	Canb.	31,74	32,33	1,86	22,38	21,74	-2,86
LBP	Red	Eucl.	32,79	32,67	-0,37	23,49	22,56	-3,96
LBP	Red	Canb.	32,79	31,98	-2,47	22,50	21,28	-5,42
LBP	Green	Eucl.	32,67	31,28	-4,25	22,97	22,27	-3,05
LBP	Green	Canb.	31,40	29,42	-6,31	20,47	20,29	-0,88
GLCM	TC	Eucl.	25,93	26,40	1,81	17,79	17,91	0,67
GLCM	TC	Canb.	28,95	27,67	-4,42	19,48	17,91	-8,06
GLCM	Red	Eucl.	29,07	27,21	-6,40	19,01	18,14	-4,58
GLCM	Red	Canb.	29,77	28,72	-3,53	19,01	18,37	-3,37
GLCM	Green	Eucl.	26,86	26,63	-0,86	17,33	17,79	2,65
GLCM	Green	Canb.	29,77	26,86	-9,77	19,36	17,73	-8,42
Haralick	TC	Eucl.	26,40	26,51	0,42	18,20	18,43	1,26
Haralick	TC	Canb.	26,98	26,86	-0,44	18,20	18,14	-0,33
Haralick	Red	Eucl.	27,44	27,44	0,00	19,24	18,55	-3,59
Haralick	Red	Canb.	28,37	30,23	6,56	19,94	19,48	-2,31
Haralick	Green	Eucl.	24,42	25,35	3,81	17,33	17,03	-1,73
Haralick	Green	Canb.	28,72	26,63	-7,28	18,55	17,91	-3,45
LBP_GLCM	TC	Eucl.	26,86	26,05	-3,02	18,20	17,21	-5,44
LBP_GLCM	TC	Canb.	32,79	27,79	-15,25	21,22	18,20	-14,23
LBP_GLCM	Red	Eucl.	29,65	27,09	-8,63	18,84	17,97	-4,62
LBP_GLCM	Red	Canb.	31,51	28,72	-8,85	20,99	18,31	-12,77
LBP_GLCM	Green	Eucl.	27,67	27,21	-1,66	17,09	17,67	3,39
LBP_GLCM	Green	Canb.	32,67	28,95	-11,39	20,81	19,01	-8,65
LBP_Har	TC	Eucl.	33,02	30,58	-7,39	23,60	21,80	-7,63
LBP_Har	TC	Canb.	31,86	27,91	-12,40	22,50	19,19	-14,71
LBP_Har	Red	Eucl.	33,14	31,98	-3,50	23,20	20,70	-10,78
LBP_Har	Red	Canb.	32,79	29,30	-10,64	22,79	19,71	-13,51
LBP_Har	Green	Eucl.	32,56	30,58	-6,08	22,44	21,86	-2,58
LBP_Har	Green	Canb.	31,51	29,42	-6,63	20,76	19,07	-8,14
GLCM_Har	TC	Eucl.	25,93	25,93	0,00	17,79	17,50	-1,63
GLCM_Har	TC	Canb.	28,95	28,49	-1,59	18,95	18,72	-1,21
GLCM_Har	Red	Eucl.	29,07	27,09	-6,81	19,01	17,91	-5,79
GLCM_Har	Red	Canb.	29,19	26,28	-9,97	19,01	16,57	-12,84
GLCM_Har	Green	Eucl.	26,86	26,63	-0,86	17,33	17,73	2,31
GLCM_Har	Green	Canb.	30,23	26,98	-10,75	19,42	16,98	-12,56

Tabela 2 – Experimento para seleção de conjuntos de descritores, canal de cor e função de distância no modelo de cor CIELab: Resultados obtidos com $k = 5$ em ranqueamentos originais e após execução de re-ranqueamento através do algoritmo RL-Sim.

Descritor	Canal de cor	Função	P-5 (%)	P-5 RL-Sim (%)	Ganho (%)	P-10 (%)	P-10 RL-Sim (%)	Ganho (%)
LBP	L	Eucl.	32,21	31,28	-2,89	22,91	21,45	-6,37
LBP	L	Canb.	30,70	28,72	-6,45	21,63	19,07	-11,84
LBP	a	Eucl.	27,44	26,86	-2,11	18,14	17,62	-2,87
LBP	a	Canb.	29,88	26,86	-10,11	19,65	17,67	-10,08
LBP	b	Eucl.	31,05	29,42	-5,25	19,71	18,26	-7,36
LBP	b	Canb.	31,86	27,44	-13,87	21,63	18,08	-16,41
GLCM	L	Eucl.	26,28	26,98	2,66	17,62	17,33	-1,65
GLCM	L	Canb.	29,42	26,51	-9,89	19,13	18,49	-3,35
GLCM	a	Eucl.	15,47	35,81	131,48	12,09	26,92	122,66
GLCM	a	Canb.	16,16	36,40	125,25	12,38	27,62	123,10
GLCM	b	Eucl.	29,88	29,30	-1,94	21,16	20,41	-3,54
GLCM	b	Canb.	28,49	28,26	-0,81	20,06	20,00	-0,30
Haralick	L	Eucl.	27,67	26,86	-2,93	17,91	17,27	-3,57
Haralick	L	Canb.	28,60	28,84	0,84	18,31	19,71	7,65
Haralick	a	Eucl.	16,16	36,98	128,84	12,21	28,02	129,48
Haralick	a	Canb.	15,93	36,28	127,75	12,33	27,27	121,17
Haralick	b	Eucl.	31,05	30,93	-0,39	21,40	20,81	-2,76
Haralick	b	Canb.	29,42	29,42	0,00	20,17	20,12	-0,25
LBP_GLCM	L	Eucl.	27,79	26,63	-4,17	17,91	17,33	-3,24
LBP_GLCM	L	Canb.	32,56	29,42	-9,64	21,28	19,48	-8,46
LBP_GLCM	a	Eucl.	27,21	27,09	-0,44	18,20	17,79	-2,25
LBP_GLCM	a	Canb.	29,88	26,51	-11,28	20,00	17,79	-11,05
LBP_GLCM	b	Eucl.	29,30	29,53	0,78	19,30	19,59	1,50
LBP_GLCM	b	Canb.	31,86	28,60	-10,23	22,03	19,01	-13,71
LBP_Har	L	Eucl.	32,56	31,63	-2,86	22,85	21,10	-7,66
LBP_Har	L	Canb.	30,70	29,53	-3,81	21,40	19,53	-8,74
LBP_Har	a	Eucl.	27,44	27,21	-0,84	18,14	17,67	-2,59
LBP_Har	a	Canb.	29,65	27,56	-7,05	19,77	18,37	-7,08
LBP_Har	b	Eucl.	31,16	28,14	-9,69	19,77	18,37	-7,08
LBP_Har	b	Canb.	31,16	28,26	-9,31	21,51	19,01	-11,62
GLCM_Har	L	Eucl.	26,28	26,74	1,75	17,62	18,02	2,27
GLCM_Har	L	Canb.	28,72	27,67	-3,66	19,53	17,85	-8,60
GLCM_Har	a	Eucl.	15,58	29,07	86,59	12,27	19,53	59,17
GLCM_Har	a	Canb.	16,16	29,42	82,05	12,56	19,83	57,88
GLCM_Har	b	Eucl.	29,88	29,53	-1,17	21,16	21,74	2,74
GLCM_Har	b	Canb.	28,72	29,42	2,44	20,00	20,76	3,80

Ao analisar os resultados deste experimento inicial, pode-se identificar alguns conjuntos de descritores, canal de cor e função de distância que apresentaram resultados

interessantes após a execução do algoritmo RL-Sim. Foram selecionados aqueles que obtiveram melhor resultado de precisão após a execução do re-ranqueamento e que também apresentaram maior ganho relativo de precisão.

Entre os resultados apresentados no modelo de cor RGB para as 5 primeiras posições (P-5), é possível observar que o conjunto LBP-Red-Euclidiana apresentou precisão de 32,67% após a execução do RL-Sim. Adicionalmente, em P-5 o maior ganho relativo de precisão foi dado pelo uso conjunto Haralick-Red-Canberra, que inicialmente obteve precisão de 28,37% (sem o RL-Sim) e após o re-ranqueamento aumentou para 30,23%, gerando um ganho de precisão de 6,56%. Ainda no modelo de cor RGB, os resultados apresentados para as 10 primeiras posições (P-10) mostram que o conjunto LBP-TC-Euclidiana obteve resultados de precisão de 23,31%. Além disso, foi possível observar que o conjunto LBPGLCM-Green-Euclidiana alcançou ganho relativo de precisão de 3,39%.

Em relação aos resultados apresentados no modelo de cor CIELab para as 5 primeiras posições dos ranqueamentos (P-5), foi possível identificar que o conjunto Haralick-a-Euclidiana obteve precisão de 36,98%. Neste caso, em P-5 o conjunto GLCM-a-Euclidiana apresentou valor significativo de ganho de precisão, chegando a 131,48%. Para as 10 primeiras posições (P-10), nota-se que, assim como aconteceu em P-5, o conjunto Haralick-a-Euclidiana apresentou o melhor resultado após o re-ranqueamento, com o valor de 28,02% de precisão obtida. Já em relação ao ganho relativo de precisão, é possível observar que em P-10 o conjunto GLCM-a-Euclidiana obteve um resultado bastante expressivo, de 129,48% de ganho relativo.

Em conclusão, é possível notar que o uso de uma vizinhança fixa (definida pelo uso do parâmetro $k = 5$) produz resultados interessantes. Porém, é necessário avaliar se o uso de diferentes tamanhos de vizinhança pode gerar resultados ainda melhores através da execução do algoritmo RL-Sim. Por isso, para realizar mais experimentos, foram selecionados os conjuntos de descritores, canais de cores e funções de distância que juntos produziram os melhores resultados de precisão e ganho de precisão neste experimento, os quais são mostrados nas tabelas 3 e 4 a seguir:

Tabela 3 – Seleção de conjunto de descritores, canal de cor e função de distância que apresentaram melhores resultados de precisão no ranqueamento e ganho de precisão para o modelo de cor RGB. A sigla “TC” refere-se ao canal de Tons de Cinza.

Descritor	Canal de Cor	Função de Distância	Posições (P-5/P-10)
LBP	Red	Euclidiana	P-5
Haralick	Red	Canberra	P-5
LBP	TC	Euclidiana	P-10
LBP_GLCM	Green	Euclidiana	P-10

Tabela 4 – Seleção de conjunto de Descritores, canal de cor e função de distância que apresentaram melhores resultados de precisão no re-ranqueamento e ganho de precisão para o modelo de cor CIELab.

Descritor	Canal de Cor	Função de Distância	Posições (P-5/P-10)
Haralick	a	Euclidiana	P-5
GLCM	a	Euclidiana	P-5
Haralick	a	Euclidiana	P-10
Haralick	a	Euclidiana	P-10

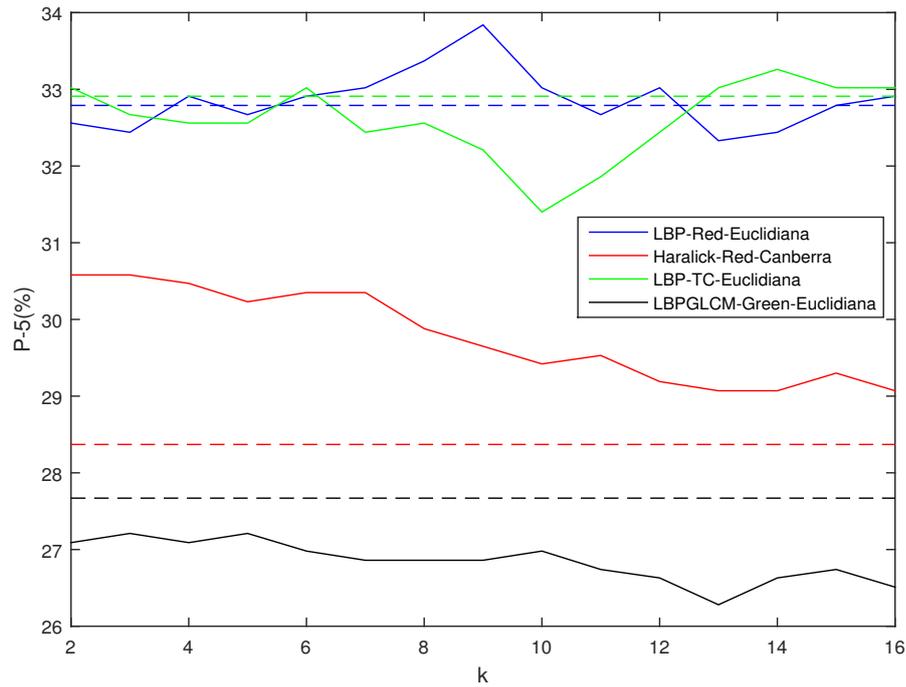
Os conjuntos selecionados serão avaliados nos experimentos realizados nas seções a seguir, as quais consideram o uso do algoritmo RL-Sim com variações do tamanho de vizinhança através do parâmetro k . Para o modelo de cor RGB foram selecionados 4 conjuntos para avaliação e para o modelo de cor CIELab apenas 2, já que o conjunto Haralick-a-Euclidiana apresentou bons resultados tanto para P-5 quanto para P-10.

4.2.2 Efeitos da variação do parâmetro k do RL-Sim

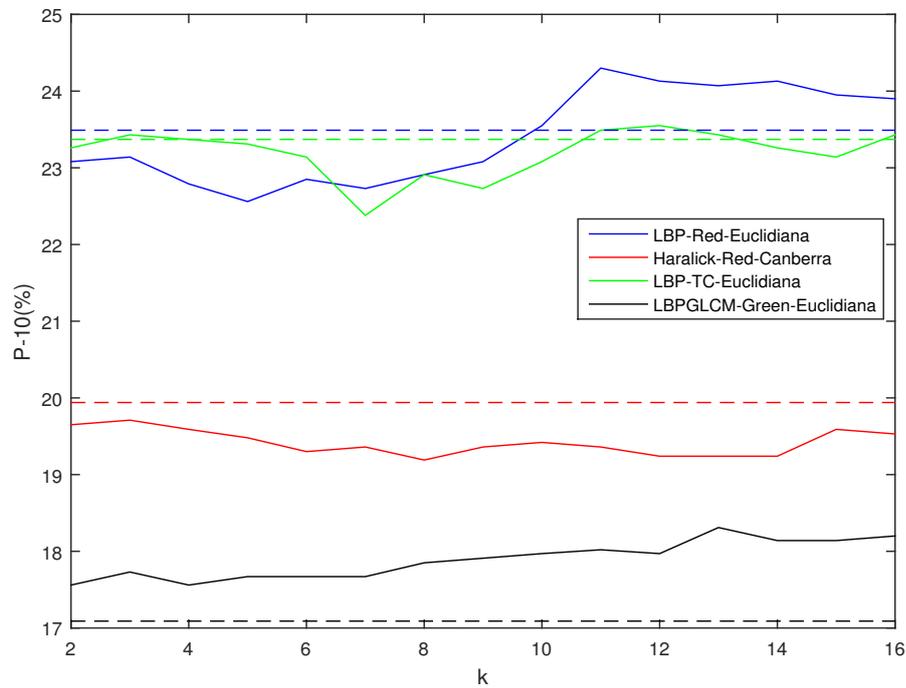
Conforme mostrado previamente, o experimento inicial considerou uma vizinhança cujo valor era $k = 5$ fixo. No entanto, com o objetivo de avaliar se a mudança do parâmetro k pode apresentar resultados melhores, foi realizado um outro experimento no qual o valor de k foi modificado para cada execução do RL-Sim, variando de 2 até 16.

Para este experimento foram utilizados os conjuntos de descritores, canal de cor e função de distância selecionados no experimento inicial (descrito na Seção 4.2.1). Foram avaliados os resultados obtidos para as 5 e 10 primeiras posições dos ranqueamentos gerados e nos modelos de cor RGB e CIELab.

A Figura 25 mostra os resultados de precisão obtidos pelos conjuntos propostos para as primeiras 5 (a) e 10 posições (b) para o modelo de cor RGB. A Figura 26 mostra os mesmos resultados de precisão (P-5 (a) e P-10 (b)) para o modelo de cor CIELab. Em todas as figuras as linhas tracejadas representam o resultado de precisão obtido na geração dos ranqueamentos iniciais, ou seja, antes da execução do algoritmo RL-Sim.

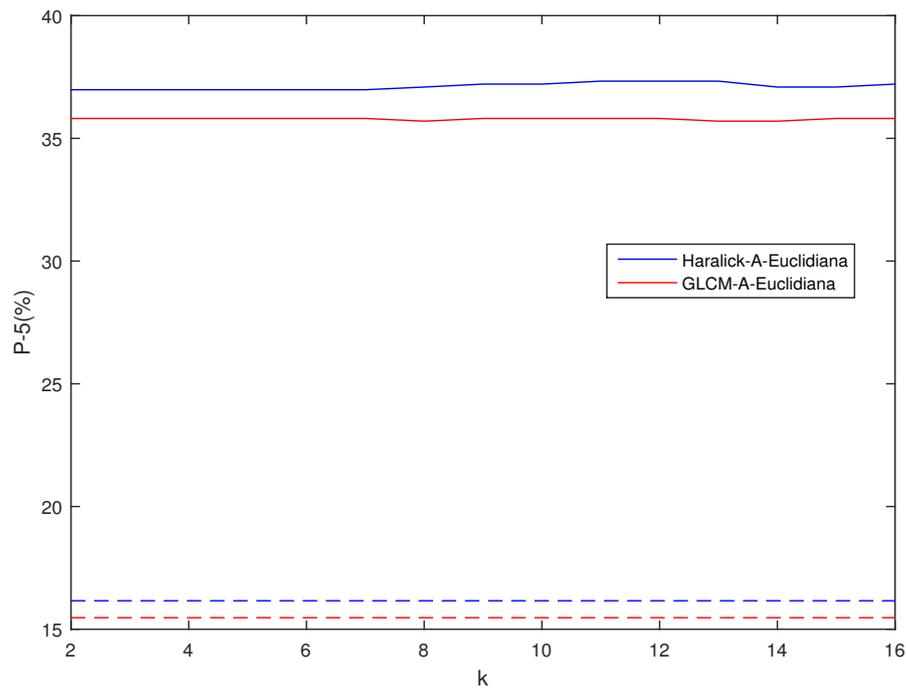


(a)

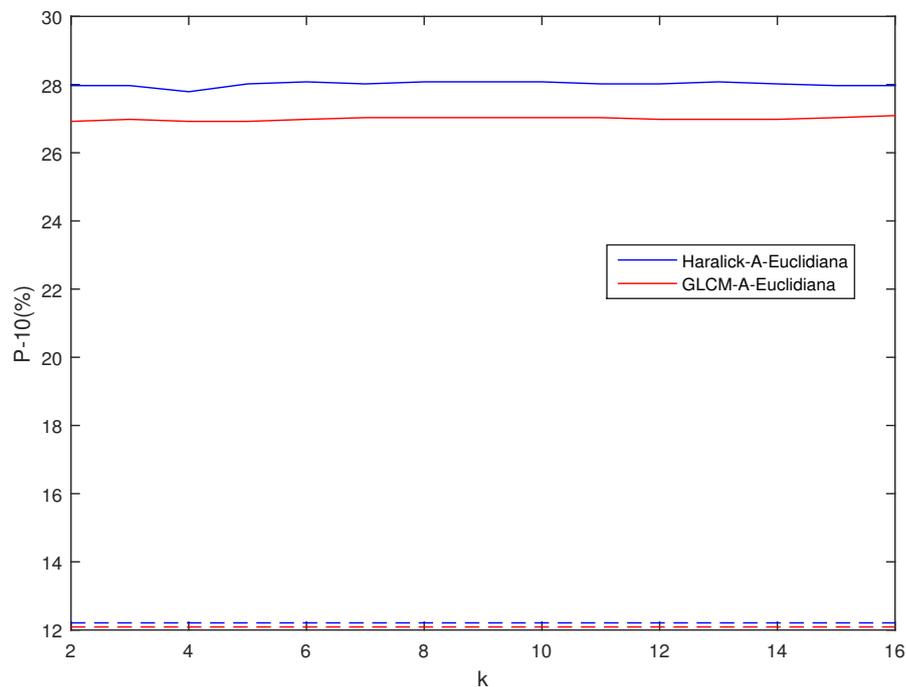


(b)

Figura 25 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor RGB; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.



(a)



(b)

Figura 26 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor CIELab; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.

Em relação ao experimento realizado com o modelo de cor RGB, ao observar a Figura 25 nota-se que a variação do parâmetro k apresenta melhoria de precisão em alguns conjuntos após a execução do algoritmo RL-Sim, porém não em todos. Para as 5 primeiras posições (P-5, Figura 25 (a)), observa-se que a variação de k apresentou melhoria de precisão para os conjuntos LBP-Red-Euclidiana (chegando a 33,84% quando $k = 9$), Haralick-Red-Canberra (com 30,58% quando $k = 3$) e LBP-TC-Euclidiana (com 33,26% de precisão quando $k = 14$). No entanto, observa-se que o conjunto LBPGLCM-Green-Euclidiana não apresentou melhoria de precisão e sim queda desta, pois o valor de precisão obtido inicialmente foi de 27,67% e, após a execução do algoritmo RL-Sim, passou a ser de, no máximo, 27,21% (quando $k = 2$ e 5).

Em relação às 10 primeiras posições (P-10) no modelo de cor RGB, é possível notar que a maioria dos conjuntos apresentou melhora de precisão em relação aos resultados obtidos sem a execução do RL-Sim. O conjunto LBP-Red-Euclidiana apresentou o maior valor de precisão, obtendo 24,30% quando $k = 11$, e continuou com valores satisfatórios entre $k = 11$ e $k = 16$. Outro conjunto, o LBP-TC-Euclidiana, apresentou melhoria de precisão em alguns pontos, tendo alcançado como melhor valor de precisão (23,55%) quando $k = 12$. Nota-se também que, apesar do conjunto LBPGLCM-Green-Euclidiana não ter apresentado os maiores valores de precisão entre os quatro conjuntos, este foi o único que obteve melhora de precisão para todos os valores do parâmetro k . Enfim, nota-se que o conjunto Haralick-Red-Canberra não apresentou melhoria de precisão em nenhum momento, já que o máximo de precisão obtida com ele foi de 19,71% (quando $k = 3$), valor menor que o valor de precisão obtido sem o re-ranqueamento (19,94%).

Quanto aos experimentos realizados com o modelo de cor CIELab, mostrados na Figura 26, é possível observar que tanto em P-5 quanto em P-10 os conjuntos utilizados apresentaram melhora significativa de precisão em relação aos resultados de precisão inicialmente obtidos sem a execução do algoritmo RL-Sim. Em P-5 nota-se que os melhores resultados foram obtidos com o conjunto Haralick-a-Euclidiana, que apresentou precisão de até 37,33% (quando $k = 12$ e 13). O conjunto GLCM-a-Euclidiana apresentou resultados equilibrados, tendo obtido precisão de até 35,81%. Em P-10, nota-se que também o conjunto Haralick-a-Euclidiana apresentou os melhores resultados de precisão, chegando a obter o valor de 28,08% quando $k = 6, 8$ e de 9 a 13. Por último, é possível notar que apesar do conjunto GLCM-a-Euclidiana ter obtido menores valores de precisão, (chegando no valor máximo de 27,09% quando $k = 16$), pode-se dizer que este e o conjunto Haralick-a-Euclidiana apresentaram leve diferença entre seus valores de precisão pós RL-Sim.

Em síntese, analisando-se os experimentos e resultados obtidos, é possível identificar que os melhores resultados de precisão para ambos os modelos de cor foram ob-

tidos para as 5 primeiras posições dos ranqueamentos, sendo que numa avaliação geral, o conjunto Haralick-a-Euclidiana apresentou o melhor resultado de precisão, seguido do conjunto GLCM-a-Euclidiana (ambos do modelo de cor CIELab).

4.2.3 Melhores Cenários

Esta Seção tem como objetivo avaliar os métodos propostos em tarefas de recuperação para os melhores cenários encontrados nos dois experimentos das seções 4.2.1 e 4.2.2. Foram considerados os conjuntos de descritores, canal de cor e função de distância selecionados na Seção anterior de acordo com os modelos de cor RGB e CIELab e foram comparados seus resultados antes e após a execução do algoritmo RL-Sim. Conforme mencionado anteriormente, os resultados obtidos utilizaram os parâmetros $T = 3$ e os valores de k que obtiveram os melhores valores de precisão quando se variou k de 2 a 16.

As Figuras 27 e 28 mostram os resultados de precisão obtidos pelo método proposto nas primeiras 5 e 10 posições (P-5 e P-10, respectivamente) antes e após a execução do Algoritmo RL-Sim, além do ganho relativo para cada modelo de cor (RGB e CIELab). Na Figura 27 foram considerados os conjuntos LBP-Red-Euclidiana, Haralick-Red-Canberra, LBP-TC-Euclidiana e LBPGLCM-Green-Euclidiana para o modelo de cor RGB. Já na Figura 28 foram considerados os conjuntos Haralick-a-Euclidiana e GLCM-a-Euclidiana para o modelo de cor CIELab.

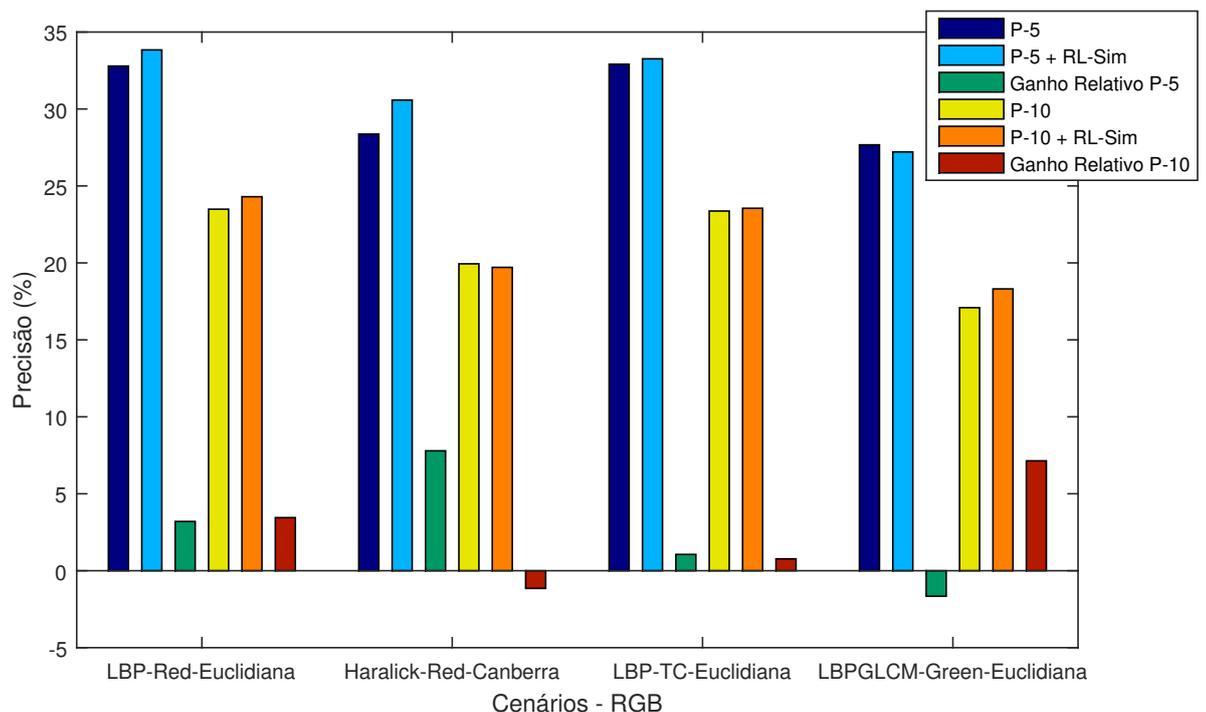


Figura 27 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco no modelo de cor RGB.

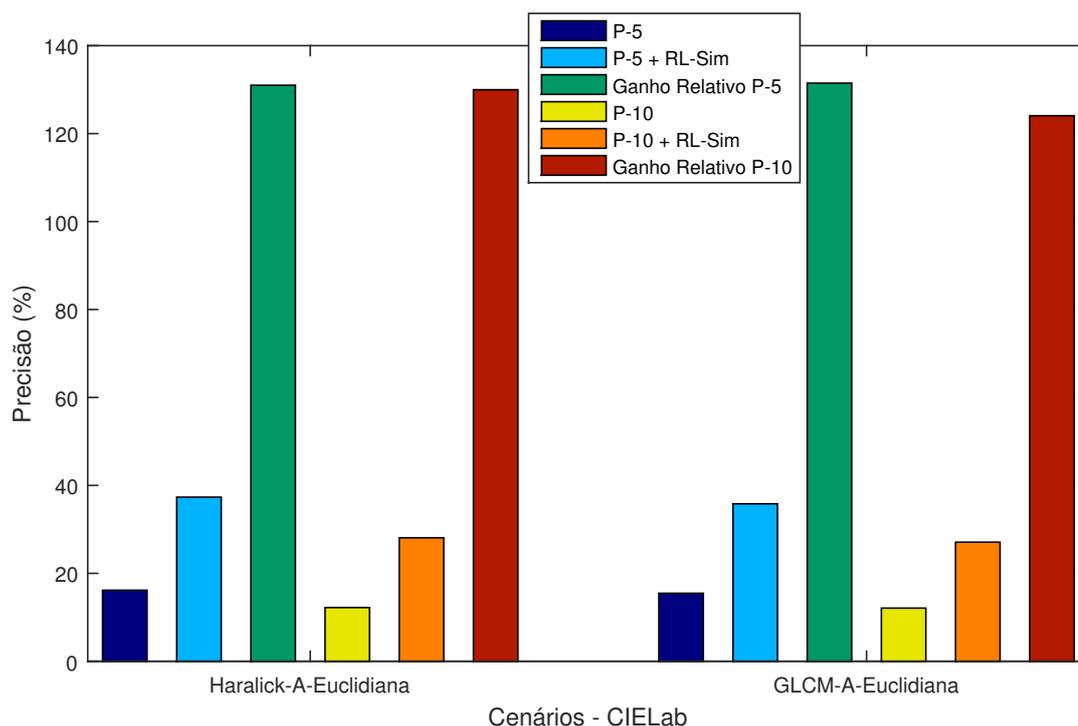


Figura 28 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco no modelo de cor CIELab.

Na Figura 27, que apresenta os resultados para o modelo de cor RGB, é possível notar que em P-5 todos os conjuntos apresentaram ganho de precisão com exceção do LBPGLCM-Green-Euclidiana, que apresentou perda de precisão. Ainda em P-5, observa-se que apesar do conjunto LBP-Red-Euclidiana ter obtido a maior precisão após o re-ranqueamento (33,84%), foi o conjunto Haralick-Red-Canberra que alcançou o maior ganho de precisão, alcançando até 7,79% de melhoria de precisão. Em relação às 10 primeiras posições (P-10), é possível observar que apenas o conjunto Haralick-Red-Canberra apresentou perda de precisão. Por outro lado, o conjunto LBPGLCM-Green-Euclidiana foi o que obteve maior ganho de precisão (7,14%), seguido do conjunto LBP-Red-Euclidiana (3,45%).

Em relação aos resultados obtidos através dos experimentos no modelo de cor CIELab, a Figura 28 mostra que os dois conjuntos apresentaram ganho de precisão tanto em P-5 quanto em P-10. Para as 5 primeiras posições (P-5), verifica-se que o conjunto Haralick-a-Euclidiana apresentou o maior valor de precisão, chegando a 37,33% de precisão após o re-ranqueamento. Apesar disso, o mesmo conjunto apresentou leve desvantagem em relação ao ganho de precisão após o re-ranqueamento, pois obteve o valor de 131% de ganho de precisão, enquanto que o conjunto GLCM-a-Euclidiana obteve 131,48%. Em relação às 10 primeiras posições (P-10), nota-se pequena diferença nos valores de precisão obtidos após o RL-Sim para cada conjunto: o Haralick-a-Euclidiana obteve o maior valor

de precisão (28,08%), enquanto que o conjunto GLCM-a-Euclidiana obteve 27,47%. Em relação ao ganho relativo de precisão, é possível observar que o conjunto Haralick-a-Euclidiana obteve o maior valor, alcançando até 129,98% de melhoria de precisão, sendo que o conjunto GLCM-a-Euclidiana obteve 124,07%.

Em conclusão, ao comparar os resultados obtidos entre os dois modelos de cor, é possível observar que apesar do modelo CIELab ter obtido valores menores de precisão inicialmente, após o re-ranqueamento este modelo apresentou o maior valor de precisão, dado através do conjunto Haralick-a-Euclidiana (37,33%, em P-5). O modelo de cor RGB, apesar de não ter obtido o valor mais alto de precisão após o re-ranqueamento, também apresentou valores satisfatórios ao alcançar a precisão máxima de 33,84% através do conjunto LBP-Red-Euclidiana (em P-5).

A Figura 29 mostra visualmente os ranqueamentos obtidos com o conjunto Haralick-a-Euclidiana antes e depois da execução do re-ranqueamento com o algoritmo RL-Sim, apresentando a imagem de consulta selecionada como a primeira (destacada em vermelho). O texto acima de cada imagem de folha representa a nota de grau de infecção de CVC designada a cada uma: as imagens denotadas com “SN” (sem nota) são as imagens que não foram avaliadas, enquanto que aquelas denotadas com “N” e numeração indicam que aquela imagem foi avaliada e denotada com aquela nota em relação à escala diagramática utilizada pelos avaliadores (uma imagem denotada com “N5.4”, por exemplo, recebeu a nota 5.4 de grau de infecção de CVC).

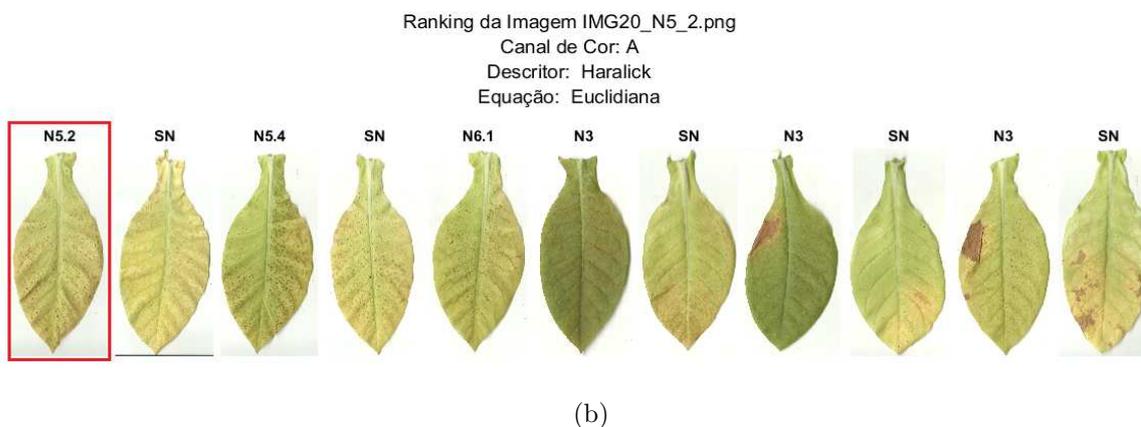
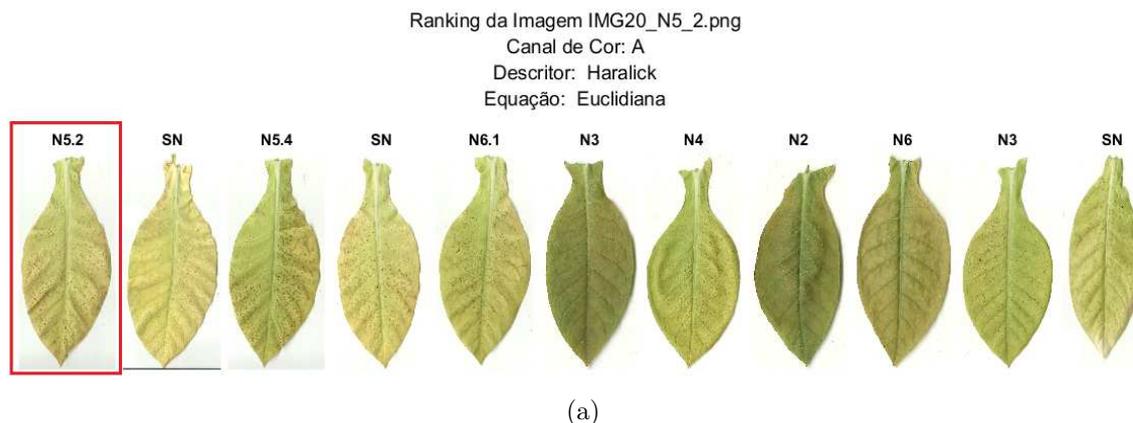


Figura 29 – Visualização dos ranqueamentos do conjunto Haralick-a-Euclidiana, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.

A Figura 30 apresenta de maneira visual os ranqueamentos obtidos com o conjunto LBP-Red-Euclidiana antes e depois da execução do re-ranqueamento com o algoritmo RL-Sim, apresentando a imagem de consulta selecionada como a primeira (destacada em vermelho). O texto acima de cada imagem de folha representa a nota de grau de infecção de CVC designada a cada uma: as imagens denotadas com “SN” (sem nota) são as imagens que não foram avaliadas, enquanto que aquelas denotadas com “N” e numeração indicam que aquela imagem foi avaliada e denotada com aquela nota em relação à escala diagramática utilizada pelos avaliadores.

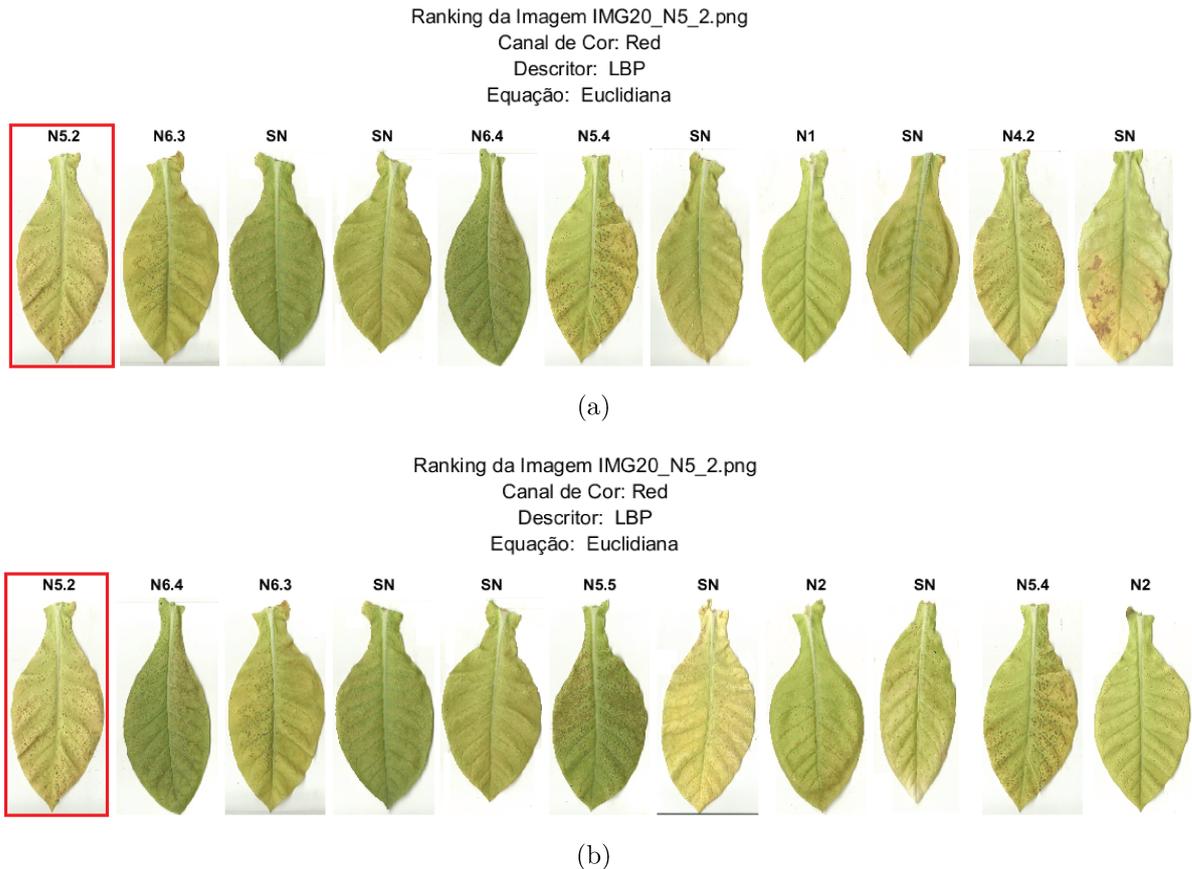


Figura 30 – Visualização dos ranqueamentos do conjunto LBP-Red-Euclidiana, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.

A Figura 29(a) mostra que foi selecionada como imagem de consulta uma imagem de folha que tinha nota de grau de infecção de CVC igual a 5.2. Antes do reranqueamento, foram encontradas como mais similares a essa imagem de consulta diversas imagens não avaliadas (aquelas denotadas como "SN" ou "sem nota"), além de outras imagens com notas, entre as quais foi apresentada a imagem de nota 5.4 como a segunda mais similar (e a primeira, entre aquelas que tinham nota). Em relação à Figura 29(b), que mostra o ranqueamento após aplicação do algoritmo RL-Sim, observa-se que o ranqueamento obtido para a imagem de consulta de nota 5.2 também apresentou como similares algumas imagens sem nota de grau de infecção de CVC e, adicionalmente, também mostrou a imagem de folha de nota 5.4 como a segunda mais similar à imagem de consulta.

Já a Figura 30(a), também mostra que foi selecionada uma imagem de consulta de folha cuja nota de grau de infecção de CVC era de 5.2. Neste caso, antes do ranqueamento, pode-se observar que a imagem mais similar é a de nota de grau de infecção de 6.3, sendo que foram apresentadas como similares diversas imagens de folha não avaliadas (denotadas como "SN") e, adicionalmente, a segunda imagem de folha mais

similar à imagem de consulta é uma denotada com nota de grau de infecção de 6.4. Em relação à Figura 30(b), verifica-se que as imagens mais similares à imagem de consulta são as denotadas com grau de infecção de 6.4 e 6.3 respectivamente, o que mostra visualmente a capacidade do RL-Sim de atualizar distâncias entre imagens e então criar um ranqueamento mais eficaz.

4.3 Experimentos realizados com imagens do *Dataset* denotadas de acordo com seu grau de infecção de CVC

Esta Seção tem por objetivo mostrar os experimentos realizados apenas com as imagens do *dataset* de folhas de tabaco infectadas por CVC que foram avaliadas e receberam notas de acordo com o grau de infecção que apresentavam. Todos os experimentos realizados, assim como os resultados obtidos e discussões sobre estes estão nas subseções a seguir.

4.3.1 Seleção dos Conjuntos de descritores, canal de cor e função de distância

Este experimento foi feito para selecionar os conjuntos de descritores, canais de cores e funções de distância que obtiveram os melhores resultados de precisão após a execução do re-ranqueamento de imagens de folhas de tabaco. Neste experimento foi utilizado também um parâmetro $k = 5$ para todos os conjuntos. As Tabelas 5 e 6 apresentam os resultados obtidos para cada descritor nos modelos de cor RGB e CIELab, tendo sido destacados em negrito os resultados de maior precisão e os ganhos obtidos com o RL-Sim.

Tabela 5 – Experimento para seleção de conjuntos de descritores, canal de cor e função de distância no modelo de cor RGB: Resultados obtidos com $k = 5$ em ranqueamentos originais e após execução de re-ranqueamento através do algoritmo RL-Sim. A sigla “TC” refere-se ao canal de Tons de Cinza.

Descritor	Canal de cor	Função	P-5 (%)	P-5 RL-Sim (%)	Ganho (%)	P-10 (%)	P-10 RL-Sim (%)	Ganho (%)
LBP	TC	Eucl.	45.12	44.88	-0.53	34.42	33.84	-1.69
LBP	TC	Canb.	44.19	48.37	9.46	34.42	36.74	6.74
LBP	Red	Eucl.	43.26	44.88	3.74	33.72	33.95	0.68
LBP	Red	Canb.	45.12	39.30	-12.90	34.19	32.91	-3.74
LBP	Green	Eucl.	42.56	45.81	7.64	33.26	34.07	2.44
LBP	Green	Canb.	42.79	42.79	0.00	34.65	34.07	-1.67
GLCM	TC	Eucl.	37.21	35.81	-3.76	26.86	26.63	-0.86
GLCM	TC	Canb.	39.07	38.37	-1.79	29.53	28.02	-5.11
GLCM	Red	Eucl.	36.28	36.28	0.00	27.79	28.14	1.26
GLCM	Red	Canb.	39.30	39.07	-0.59	27.79	26.51	-4.61
GLCM	Green	Eucl.	36.51	34.42	-5.72	27.56	26.63	-3.37
GLCM	Green	Canb.	37.91	35.58	-6.15	27.56	26.05	-5.48
Haralick	TC	Eucl.	34.88	35.58	2.01	25.58	26.16	2.27
Haralick	TC	Canb.	37.21	36.05	-3.12	27.79	28.14	1.26
Haralick	Red	Eucl.	35.35	32.09	-9.22	25.58	25.47	-0.43
Haralick	Red	Canb.	35.58	35.35	-0.65	25.93	25.81	-0.46
Haralick	Green	Eucl.	34.88	33.26	-4.64	26.63	25.47	-4.36
Haralick	Green	Canb.	37.91	35.12	-7.36	28.60	26.74	-6.50
LBP_GLCM	TC	Eucl.	37.91	35.12	-7.36	27.21	27.44	0.85
LBP_GLCM	TC	Canb.	44.19	39.77	-10.00	34.19	34.07	-0.35
LBP_GLCM	Red	Eucl.	37.21	34.65	-6.88	27.79	28.14	1.26
LBP_GLCM	Red	Canb.	45.58	41.40	-9.17	33.49	33.26	-0.69
LBP_GLCM	Green	Eucl.	36.51	35.12	-3.81	28.02	26.05	-7.03
LBP_GLCM	Green	Canb.	45.81	42.33	-7.60	33.72	32.21	-4.48
LBP_Har	TC	Eucl.	44.88	42.09	-6.22	34.42	34.42	0.00
LBP_Har	TC	Canb.	44.65	40.23	-9.90	34.42	36.40	5.75
LBP_Har	Red	Eucl.	43.49	44.19	1.61	33.26	34.30	3.13
LBP_Har	Red	Canb.	46.05	42.56	-7.58	33.95	32.09	-5.48
LBP_Har	Green	Eucl.	42.09	43.72	3.87	33.14	34.42	3.86
LBP_Har	Green	Canb.	42.56	43.02	1.08	34.53	36.05	4.40
GLCM_Har	TC	Eucl.	37.21	36.51	-1.88	26.86	27.44	2.16
GLCM_Har	TC	Canb.	37.67	37.44	-0.61	29.07	27.33	-5.99
GLCM_Har	Red	Eucl.	36.28	35.12	-3.20	27.79	28.14	1.26
GLCM_Har	Red	Canb.	39.07	35.35	-9.52	28.02	27.09	-3.32
GLCM_Har	Green	Eucl.	36.51	35.35	-3.18	27.56	27.09	-1.71
GLCM_Har	Green	Canb.	37.44	35.58	-4.97	27.09	25.47	-5.98

Tabela 6 – Experimento para seleção de conjuntos de descritores, canal de cor e função de distância no modelo de cor CIELab: Resultados obtidos com $k = 5$ em ranqueamentos originais e após execução de re-ranqueamento através do algoritmo RL-Sim.

Descritor	Canal de cor	Função	P-5 (%)	P-5 RL-Sim (%)	Ganho (%)	P-10 (%)	P-10 RL-Sim (%)	Ganho (%)
LBP	L	Eucl.	43.72	46.28	5.86	33.02	33.60	1.76
LBP	L	Canb.	43.49	40.93	-5.89	33.26	33.49	0.69
LBP	a	Eucl.	36.28	31.63	-12.82	23.60	25.35	7.42
LBP	a	Canb.	37.91	32.79	-13.51	26.98	25.93	-3.89
LBP	b	Eucl.	40.00	30.00	-25.00	28.84	23.95	-16.96
LBP	b	Canb.	43.26	36.28	-16.13	31.74	27.67	-12.82
GLCM	L	Eucl.	35.58	32.79	-7.84	28.14	24.30	-13.65
GLCM	L	Canb.	36.98	35.35	-4.41	28.49	25.12	-11.83
GLCM	a	Eucl.	26.28	29.07	10.62	24.42	24.53	0.45
GLCM	a	Canb.	27.44	34.65	26.28	25.12	27.44	9.24
GLCM	b	Eucl.	36.28	37.91	4.49	26.98	26.98	0.00
GLCM	b	Canb.	35.12	32.79	-6.63	25.58	24.19	-5.43
Haralick	L	Eucl.	36.98	32.09	-13.22	27.79	25.58	-7.95
Haralick	L	Canb.	39.53	36.05	-8.80	28.37	29.07	2.47
Haralick	a	Eucl.	26.74	35.35	32.20	24.07	26.63	10.64
Haralick	a	Canb.	27.91	35.35	26.66	25.12	26.63	6.01
Haralick	b	Eucl.	36.05	31.86	-11.62	26.74	24.88	-6.96
Haralick	b	Canb.	35.35	34.19	-3.28	26.51	24.30	-8.34
LBP_GLCM	L	Eucl.	35.81	33.95	-5.19	27.91	25.35	-9.17
LBP_GLCM	L	Canb.	46.05	34.42	-25.26	33.26	26.40	-20.63
LBP_GLCM	a	Eucl.	35.58	33.02	-7.20	24.65	25.12	1.91
LBP_GLCM	a	Canb.	37.67	33.26	-11.71	26.74	23.26	-13.01
LBP_GLCM	b	Eucl.	39.07	32.56	-16.66	29.19	25.35	-13.16
LBP_GLCM	b	Canb.	43.49	33.02	-24.07	32.21	26.40	-18.04
LBP_Har	L	Eucl.	43.49	36.05	-17.11	33.02	27.21	-17.60
LBP_Har	L	Canb.	42.33	35.58	-15.95	33.14	28.37	-14.39
LBP_Har	a	Eucl.	36.28	36.74	1.27	23.60	27.33	15.81
LBP_Har	a	Canb.	37.44	36.74	-1.87	27.91	26.63	-4.59
LBP_Har	b	Eucl.	40.00	33.26	-16.85	28.84	23.84	-17.34
LBP_Har	b	Canb.	43.49	36.74	-15.52	32.67	27.21	-16.71
GLCM_Har	L	Eucl.	35.58	32.79	-7.84	28.14	27.33	-2.88
GLCM_Har	L	Canb.	37.21	33.02	-11.26	28.95	25.12	-13.23
GLCM_Har	a	Eucl.	26.05	32.33	24.11	24.65	25.12	1.91
GLCM_Har	a	Canb.	27.67	36.51	31.95	25.23	26.63	5.55
GLCM_Har	b	Eucl.	36.28	32.33	-10.89	26.98	27.79	3.00
GLCM_Har	b	Canb.	35.12	28.84	-17.88	26.16	21.63	-17.32

Da mesma maneira que aconteceu com todas as imagens do *dataset*, o experimento com as imagens que tinham notas de grau de infecção de CVC permitiu identificar

alguns conjuntos de descritores, canal de cor e função de distância que apresentaram resultados relevantes após a execução do algoritmo RL-Sim. Foram selecionados os conjuntos que, após a execução do RL-Sim, obtiveram melhores resultados de precisão e maior ganho de precisão, tanto em P-5 quanto em P-10.

Entre os resultados apresentados no modelo de cor RGB, o conjunto LBP-TC-Canberra apresentou os melhores resultados de precisão e ganho de precisão tanto para as 5 primeiras posições (ao obter precisão de 48,37% e ganho relativo de precisão de 9,46%) quanto para as 10 primeiras posições (ao obter 36,74% de precisão e 6,74% de ganho relativo). Assim, adicionalmente foram selecionados outros conjuntos que obtiveram bons resultados: Para P-5 foi selecionado o conjunto LBP-Green-Euclidiana (que obteve precisão de 45,81% e ganho relativo de 7,64%) e para P-10 foi selecionado o conjunto LBPHaralick-TC-Canberra (com precisão de 36,40% e ganho relativo de 5,75%).

Em relação aos resultados apresentados no modelo de cor CIELab para as 5 primeiras posições dos ranqueamentos, pode-se identificar que o conjunto LBP-L-Euclidiana apresentou precisão de 46,28% após execução do re-ranqueamento, o que mostra um ganho relativo de precisão de 5,86%. Por outro lado, o conjunto Haralick-a-Euclidiana obteve um ganho relativo de precisão de 32,20% após a execução do re-ranqueamento. Finalmente, é possível identificar resultados expressivos também para as 10 primeiras posições dos ranqueamentos, os quais mostram que o conjunto LBP-L-Euclidiana obteve precisão de 33,60% após a execução do RL-Sim, enquanto que o uso do conjunto LBPHaralick-a-Euclidiana apresentou ganho relativo de precisão de 15,81% após execução do RL-Sim.

Enfim, apesar dos resultados expressivos obtidos neste experimento, é necessário também verificar se o uso de tamanhos diferentes de vizinhança pode obter resultados ainda melhores. Assim, foram selecionados os conjuntos que geraram os melhores resultados de precisão e ganho de precisão neste experimento, os quais serão utilizados nos experimentos a seguir. Tais conjuntos são mostrados nas tabelas 7 e 8:

Tabela 7 – Seleção de conjunto de descritores, canal de cor e função de distância que apresentaram melhores resultados de precisão no re-ranqueamento e ganho de precisão para o modelo de cor RGB. A sigla “TC” refere-se ao canal de Tons de Cinza.

Descritor	Canal de Cor	Função de Distância	Posições (P-5/P-10)
LBP	TC	Canberra	P-5
LBP	Green	Euclidiana	P-5
LBP	TC	Canberra	P-10
LBP-Har	TC	Canberra	P-10

Tabela 8 – Seleção de conjunto de descritores, canal de cor e função de distância que apresentaram melhores resultados de precisão no re-ranqueamento e ganho de precisão para o modelo de cor CIELab.

Descritor	Canal de Cor	Função de Distância	Posições (P-5/P-10)
LBP	L	Euclidiana	P-5
Haralick	a	Euclidiana	P-5
LBP	L	Euclidiana	P-10
LBP_Har	a	Euclidiana	P-10

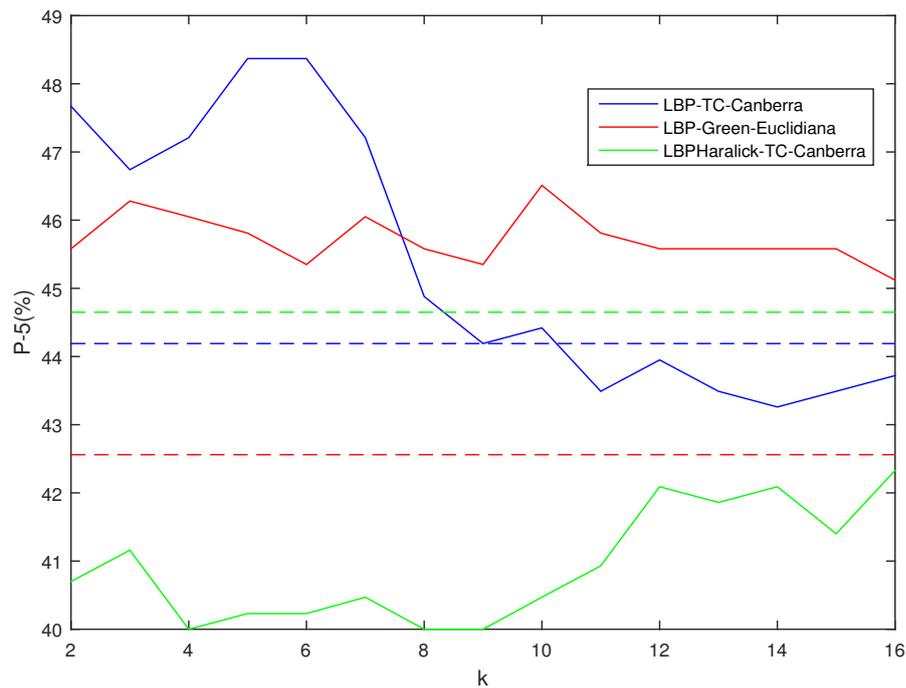
Selecionados os conjuntos com melhores resultados, estes serão avaliados nos experimentos em seguida, que consideram o uso do algoritmo RL-Sim com variações do tamanho de vizinhança através do parâmetro k . Tanto para o modelo de cor RGB quanto para o CIELab foram selecionados 3 conjuntos para avaliação.

4.3.2 Efeitos da variação do parâmetro k do RL-Sim

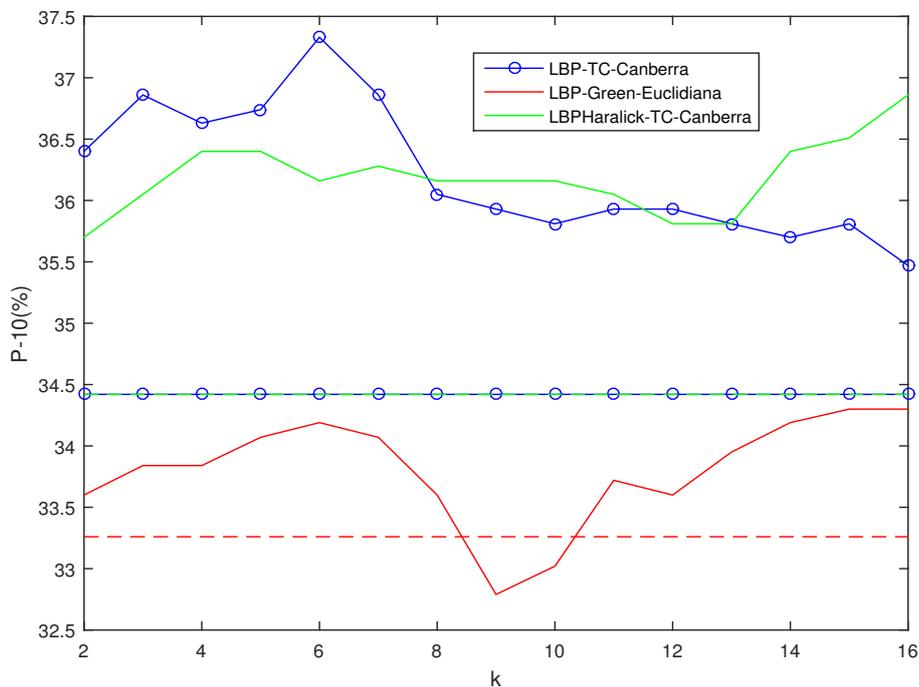
Conforme mostrado previamente, o experimento inicial considerou uma vizinhança cujo valor era $k = 5$ fixo. No entanto, com o objetivo de avaliar se a alteração do parâmetro k poderia apresentar resultados melhores, foi realizado um outro experimento no qual o valor de k foi alterado, variando de 2 até 16.

Para este experimento foram utilizados os conjuntos de descritores, canal de cor e função de distância selecionados no experimento inicial (descrito na Seção 4.3.1). Foram avaliados os resultados obtidos para as 5 e 10 primeiras posições dos ranqueamentos gerados e nos modelos de cor RGB e CIELab.

A Figura 31 mostra os resultados de precisão obtidos pelos conjuntos propostos para as primeiras 5 (a) e 10 posições (b) para o modelo de cor RGB. A Figura 32 mostra os mesmos resultados de precisão (P-5 (a) e P-10 (b)) para o modelo de cor CIELab. Em todas as figuras as linhas tracejadas representam o resultado de precisão obtido na geração dos ranqueamentos originais, ou seja, antes da execução do algoritmo RL-Sim.

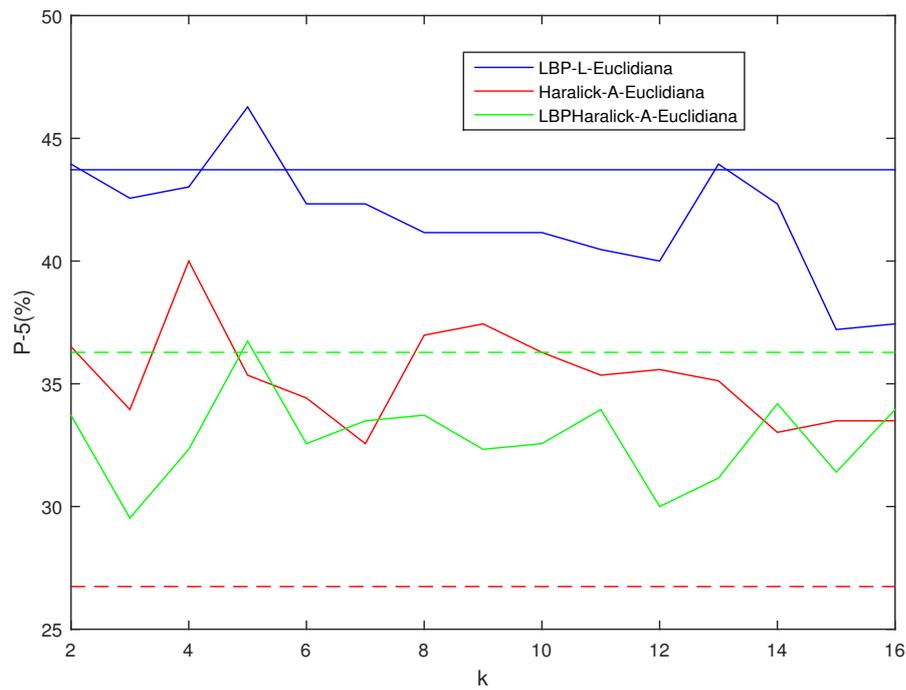


(a)

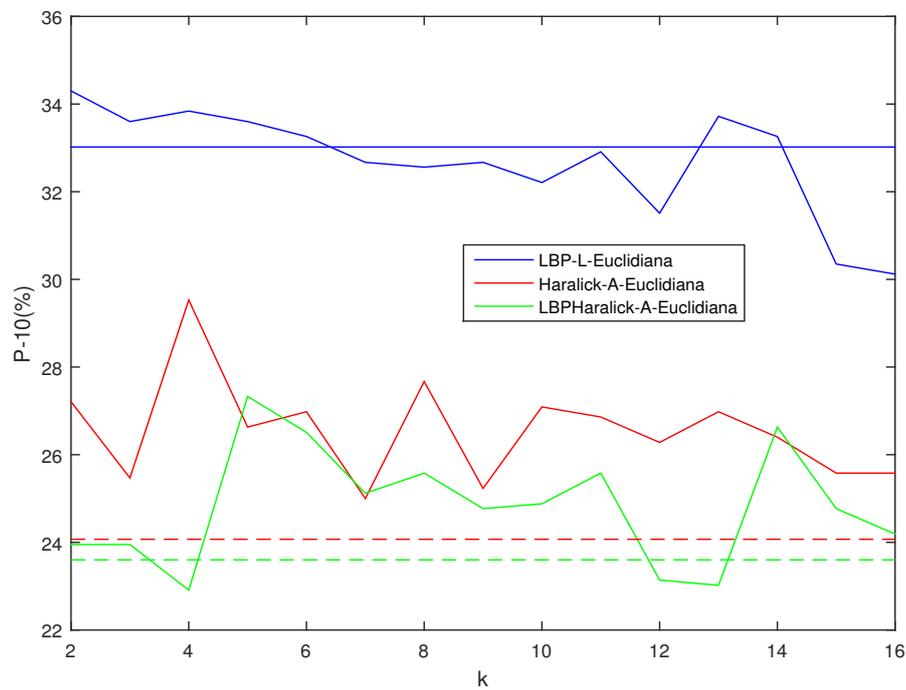


(b)

Figura 31 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor RGB; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.



(a)



(b)

Figura 32 – Impacto da variação do parâmetro k ao utilizar o algoritmo RL-Sim no modelo de cor CIELab; (a) resultados obtidos para as 5 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais; (b) resultados obtidos para as 10 primeiras posições dos ranqueamentos, sendo as linhas tracejadas a representação do resultado de precisão obtido nos ranqueamentos originais.

Ao observar a Figura 31 é possível verificar que nos experimentos realizados com o modelo de cor RGB, em P-5 a variação do parâmetro k na execução do re-ranqueamento apresentou melhora de precisão com os conjuntos LBP-TC-Canberra e LBP-Green-Euclidiana e piora com o conjunto LBPHaralick-TC-Canberra. Já em P-10, todos os conjuntos apresentaram melhora de precisão.

Em relação ao modelo de cor CIELab, nota-se na Figura 32 que em P-5 a variação do parâmetro k no re-ranqueamento apresentou melhora de precisão em todos os pontos do conjunto Haralick-a-Euclidiana, enquanto que para os conjuntos LBP-L-Euclidiana e LBPHaralick-a-Euclidiana houve melhora de precisão em apenas alguns pontos. Em P-10, observa-se que também houve melhora de precisão em todos os pontos do conjunto Haralick-a-Euclidiana com a variação do parâmetro k no re-ranqueamento, sendo que os conjuntos LBP-L-Euclidiana e LBPHaralick-a-Euclidiana apresentaram resultados que variaram entre melhora e queda de precisão.

Analisando-se de maneira mais detalhada os resultados obtidos para o modelo de cor RGB, é possível notar que para a métrica P-5 os melhores resultados foram obtidos com o conjunto LBP-TC-Canberra, que alcançou valor de precisão de 48,37% quando $k = 5$ e 6. Observa-se também que o conjunto LBP-Green-Euclidiana obteve valores de precisão melhores em toda a variação do parâmetro k , chegando a alcançar 46,51% de precisão quando $k = 10$. Ainda em P-5, o conjunto que apresentou os resultados menos satisfatórios foi o de LBPHaralick-TC-Canberra, pois todos os valores de precisão obtidos após o re-ranqueamento alcançaram índices menores que os obtidos no ranqueamento inicial. Já em relação à métrica P-10, o conjunto LBP-TC-Canberra foi o que apresentou resultados melhores, obtendo precisão de 37,33% quando $k = 6$, apesar de apresentar queda nos resultados de precisão conforme o valor de k foi incrementado. Ainda na métrica P-10 é notável que o conjunto LBPHaralick-TC-Canberra obteve melhora de precisão em todos os pontos em relação ao ranqueamento inicial, tendo obtido como valor máximo de precisão 36,86% quando $k = 16$.

Quanto aos experimentos realizados com o modelo de cor CIELab, observou-se que para a métrica P-5 o conjunto LBP-L-Euclidiana apresentou os melhores valores de precisão, tendo obtido até 46,28% quando $k = 5$. Olhando os resultados deste conjunto, nota-se que conforme k variou de 2 a 16, os resultados de precisão obtidos foram irregulares: para alguns valores de k , a precisão aumenta ($k = 5$ e 13) e para outros valores de k a precisão diminui ($k = 6$ a 12, por exemplo). Nesta mesma métrica, nota-se que os menores resultados de precisão foram obtidos pelo conjunto LBPHaralick-a-Euclidiana, que apresentou leve melhora de precisão apenas em um ponto ($k = 5$), alcançando precisão 36,74%. Em relação à métrica P-10, o conjunto que apresentou os melhores resultados de precisão também foi o de LBP-L-Euclidiana, que obteve valores de precisão entre 30,12%

($k = 16$) e 34,30% ($k = 2$), o que mostra que neste caso o aumento dos valores do parâmetro k produziu resultados de precisão menos satisfatórios. Por outro lado, o conjunto LBPHaralick-a-Euclidiana apresentou os resultados mais baixos de precisão, sendo o menor deles o de 22,91% quando $k = 4$.

Enfim, analisando-se todos os experimentos e resultados obtidos, é possível identificar que os melhores resultados de precisão para ambos os modelos de cor foram obtidos para as 5 primeiras posições dos ranqueamentos (métrica P-5), sendo que o conjunto LBP-TC-Euclidiana apresentou o melhor resultado de precisão de todos (48,37%), seguido do conjunto LBP-L-Euclidiana (46,28%).

4.3.3 Melhores Cenários

Assim como feito para todas as imagens do *dataset*, nesta seção serão avaliados os métodos propostos em tarefas de recuperação para os melhores cenários encontrados nos experimentos das seções 4.3.1 e 4.3.2, porém para as imagens que continham nota de grau de infecção. Para isso, foram analisados os conjuntos de descritores, canal de cor e função de distância selecionados e analisados nas seções anteriores para cada modelo de cor, RGB e CIELab. Foi feita uma comparação de resultados obtidos antes e após a execução do algoritmo RL-Sim e utilizados os resultados que apresentaram melhores valores de precisão ao se variar o parâmetro k de 2 a 16.

As Figuras 33 e 34 a seguir mostram os resultados de precisão obtidos pelo método proposto nas primeiras 5 (P-5) e 10 (P-10) posições antes e após a execução do Algoritmo RL-Sim, assim como também o ganho relativo de precisão para cada modelo de cor (RGB e CIELab). Na Figura 33, que representa os resultados obtidos para o modelo de cor RGB, foram considerados os conjuntos LBP-TC-Canberra, LBP-Green-Euclidiana e LBPHaralick-TC-Canberra. Os resultados para o modelo de cor CIELab são apresentados na Figura 34, que mostra os conjuntos considerados: LBP-L-Euclidiana, Haralick-a-Euclidiana e LBPHaralick-a-Euclidiana.

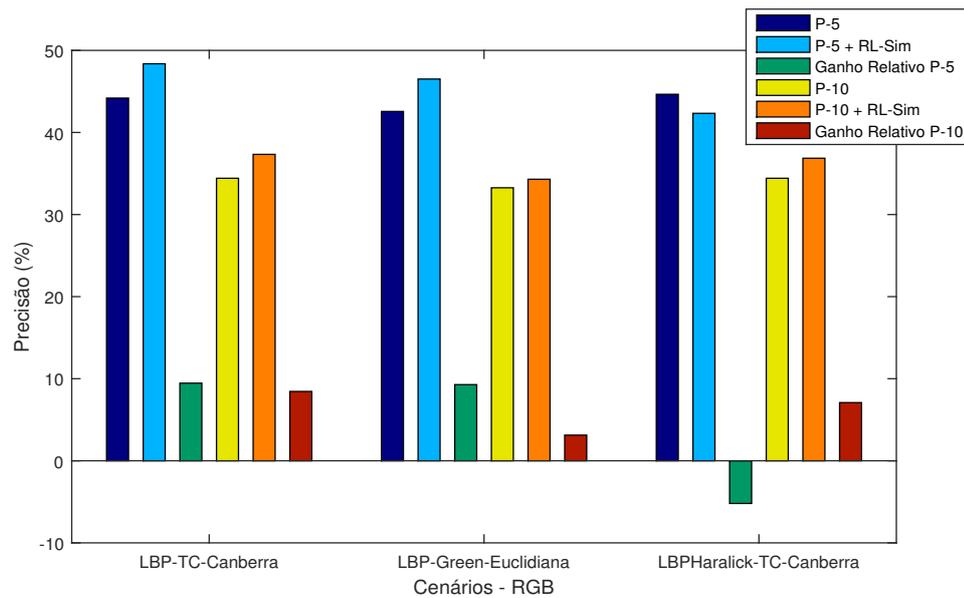


Figura 33 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco denotadas com grau de infecção de CVC e no modelo de cor RGB.

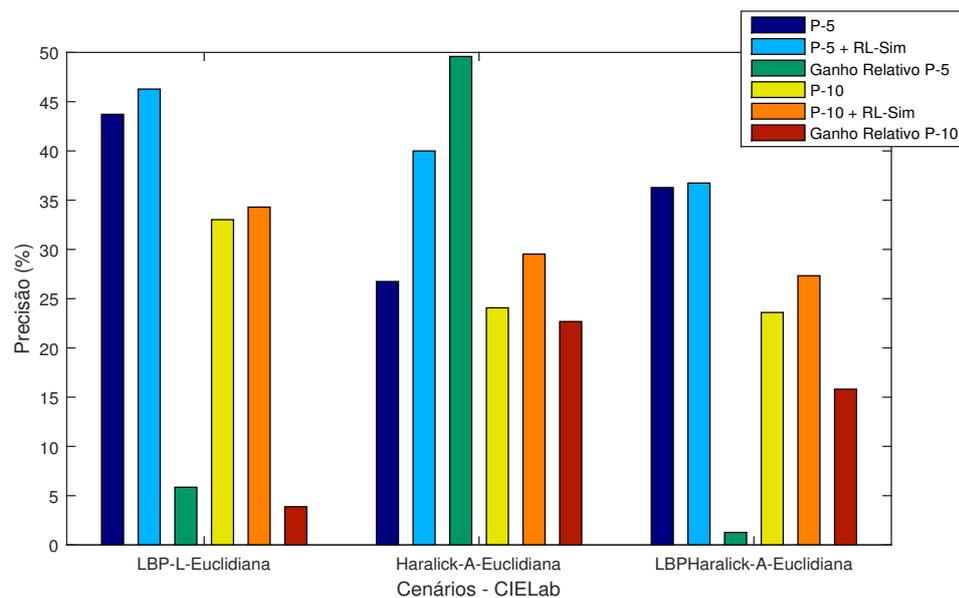


Figura 34 – Precisão dos conjuntos de descritores, canal de cor e função de distância em imagens de folhas de tabaco denotadas com grau de infecção de CVC e no modelo de cor CIELab.

Na Figura 33, é possível notar que no modelo de cor RGB houve queda de precisão apenas com o LBPHaralick-TC-Canberra. Após o re-ranqueamento, nota-se que em P-5 o conjunto LBP-TC-Canberra alcançou a maior precisão (48,37%), tendo apresentado um ganho relativo de precisão de 9,46%, uma leve vantagem em relação ao conjunto LBP-Green-Euclidiana que apresentou ganho de 9,28%. Em P-10, observa-se que todos os con-

juntos apresentaram aumento de precisão, sendo que o conjunto LBP-TC-Canberra apresentou o maior valor (37,33%), seguido do conjunto LBPHaralick-TC-Canberra (36,86%). Em relação ao ganho de precisão em P-10, o conjunto que obteve o melhor resultado foi o LBP-TC-Canberra (8,45%), uma pequena diferença em relação ao ganho relativo do conjunto LBPHaralick-TC-Canberra (7,09%).

Já a Figura 34 mostra os resultados obtidos com o experimentos no modelo de cor CIELab, no qual também foi alcançada melhora de precisão e ganho de precisão para todos os conjuntos após o re-ranqueamento. Em P-5, apesar do conjunto LBP-L-Euclidiana ter obtido o maior valor de precisão após o re-ranqueamento (46,28%), nota-se que o conjunto Haralick-a-Euclidiana foi o que apresentou o maior ganho relativo de precisão (49,49%). Em P-10, é possível observar que o conjunto que obteve maior valor de precisão após o re-ranqueamento foi o LBP-L-Euclidiana (34,30%), seguido do conjunto Haralick-a-Euclidiana (29,53%). No entanto, apesar do conjunto Haralick-a-Euclidiana não ter obtido o maior valor de precisão, pode-se observar que este alcançou o maior ganho relativo de precisão (22,68%).

Em conclusão, observa-se que de um modo geral, os valores de precisão obtidos para as 5 primeiras posições (P-5) foram maiores do que os obtidos para P-10, tanto antes quanto depois do re-ranqueamento através do algoritmo RL-Sim e para ambos os modelos de cor (RGB ou CIELab). Nos cenários apresentados para o modelo de cor RGB, os conjuntos que apresentaram maior precisão após o re-ranqueamento foram o LBP-TC-Canberra (com 48,37% em P-5) e LBP-Green-Euclidiana (com 46,51% em P-10). Por outro lado, no cenário apresentado para o modelo de cor CIELab, o conjunto que apresentou maior precisão após o RL-Sim foi o LBP-L-Euclidiana, tanto para P-5 (com 46,28%) quanto para P-10 (com 34,30%). Ao comparar os resultados de precisão atingidos por cada modelo de cor, percebe-se que o modelo de cor RGB apresenta leve vantagem nos resultados de precisão, pois possui como maior valor de precisão 48,37% (obtido através do conjunto LBP-TC-Canberra). O modelo CIELab apresentou valor de precisão um pouco menor obtido com o conjunto LBP-L-Euclidiana: 46,29%.

A Figura 35 mostra visualmente os ranqueamentos obtidos com o conjunto LBP-Green-Euclidiana antes e depois da execução do re-ranqueamento com o algoritmo RL-Sim, apresentando a imagem de consulta selecionada como a primeira (destacada em vermelho). O texto acima de cada imagem de folha representa a nota de grau de infecção de CVC designada a cada uma: as imagens denotadas com “SN” (sem nota) são as imagens que não foram avaliadas, enquanto que aquelas denotadas com “N” e numeração indicam que aquela imagem foi avaliada e denotada com aquela nota em relação à escala diagramática utilizada pelos avaliadores.

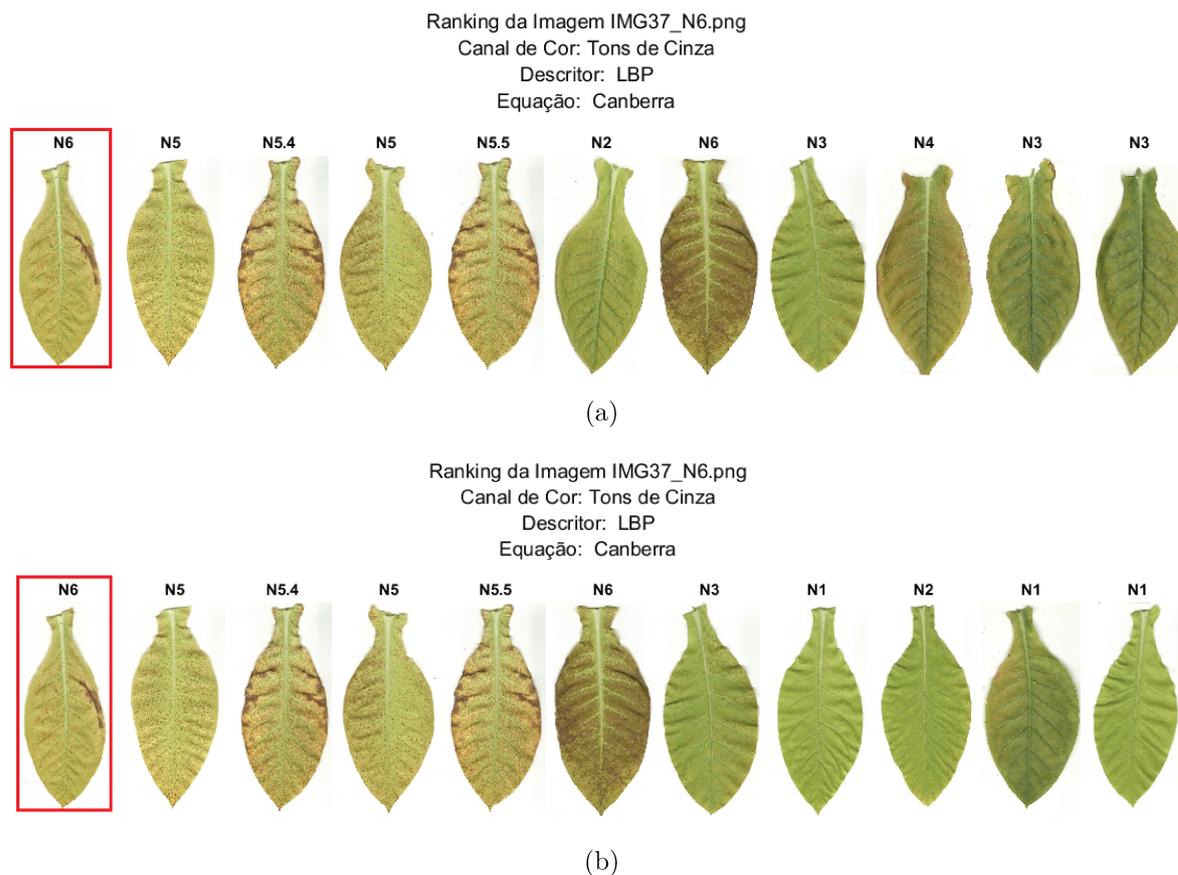


Figura 35 – Visualização dos ranqueamentos do conjunto LBP-TC-Canberra, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.

A Figura 36 apresenta de maneira visual os ranqueamentos obtidos com o conjunto LBP-L-Euclidiana antes e depois da execução do re-ranqueamento com o algoritmo RL-Sim, apresentando a imagem de consulta selecionada como a primeira (destacada em vermelho). O texto acima de cada imagem de folha representa a nota de grau de infecção de CVC designada a cada uma: as imagens denotadas com “SN” (sem nota) são as imagens que não foram avaliadas, enquanto que aquelas denotadas com “N” e numeração indicam que aquela imagem foi avaliada e denotada com aquela nota em relação à escala diagramática utilizada pelos avaliadores.

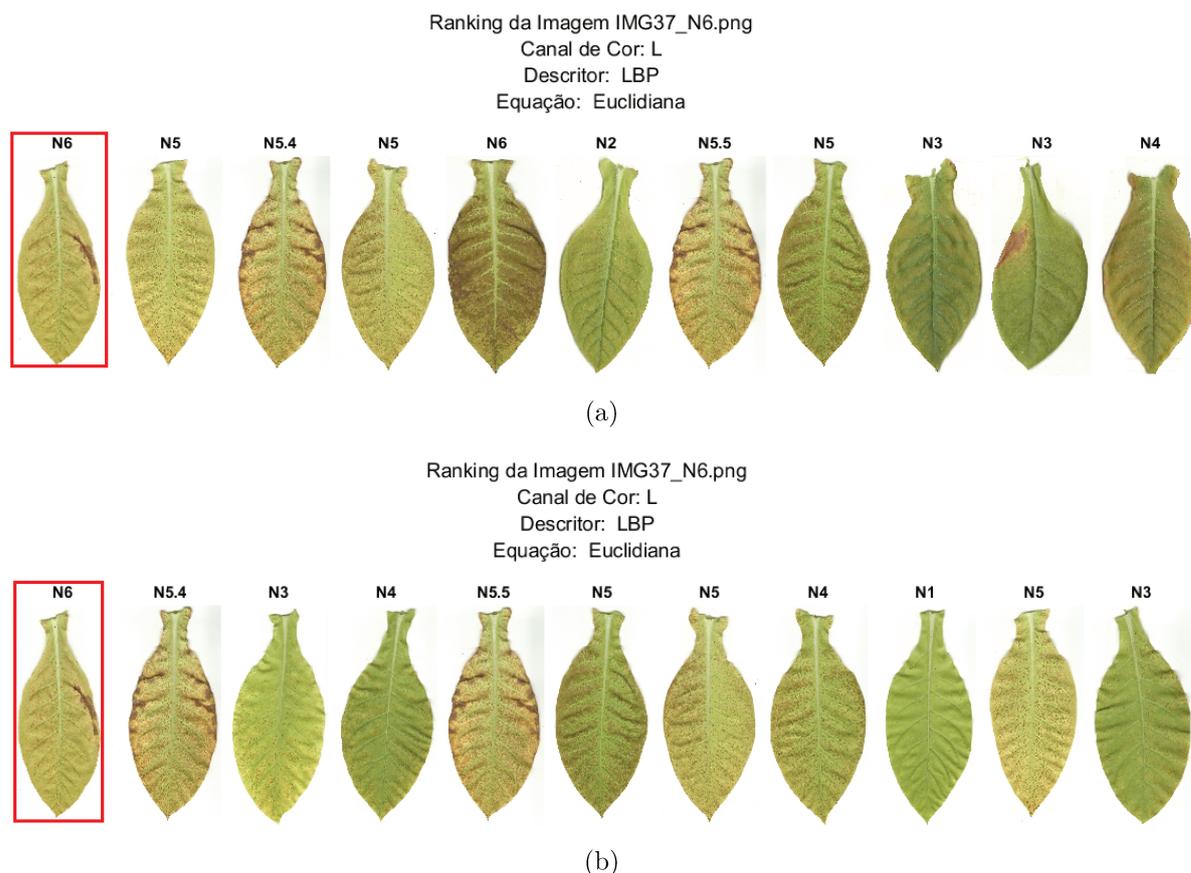


Figura 36 – Visualização dos ranqueamentos do conjunto LBP-L-Euclidiana, com notas de grau de infecção de CVC apresentadas acima de cada imagem de folha: (a) Ranqueamento antes da execução do RL-Sim; (b) Ranqueamento após execução do RL-Sim.

A Figura 35(a) mostra que foi selecionada como imagem de consulta uma imagem de folha que tinha nota de grau de infecção de CVC igual a 6. Antes do re-ranqueamento, foram encontradas como mais similares a essa imagem de consulta imagens avaliadas com notas de grau de infecção de 5, 5.4, 5 e 5.5. No entanto, observa-se que a quinta imagem mais semelhante à imagem de consulta é uma imagem de folha cuja nota é 2. Em relação à Figura 35(b), que mostra o ranqueamento após a aplicação do algoritmo RL-Sim, observa-se que o re-ranqueamento obtido para a imagem de consulta de nota 6 apresentou um ranqueamento similar ao feito sem o RL-Sim, porém nota-se que agora a quinta imagem dada como mais similar é a de nota 6 e não a de nota 2 (como mostrado no ranqueamento anterior), o que mostra visualmente que a aplicação do algoritmo RL-Sim apresentou uma melhoria no ranqueamento inicial gerado.

Já a Figura 36(a), também mostra que foi selecionada uma imagem de consulta de folha cuja nota de grau de infecção de CVC era de 6. Neste caso, antes do ranqueamento, pode-se observar que as imagens mais similares à imagem de consulta são aquelas que têm notas 5, 5.4, 5 e 6. No entanto, é possível observar que a quinta imagem ordenada como

mais similar à imagem de consulta é uma imagem de nota 2. Em relação à Figura 36(b), verifica-se que as imagens mais similares à imagem de consulta são as denotadas com grau de infecção de 5.4, 3, 4 e 5.5. Observa-se então uma relativa melhora visual em relação ao ranqueamento inicial gerado pois, embora uma imagem de folha de nota 3 tenha sido apresentada como a segunda mais similar à imagem de consulta (de nota 6), houve também neste novo ranqueamento a remoção da imagem de nota 2 que anteriormente havia sido apresentada como a quinta imagem mais similar à imagem de consulta.

4.4 Análise de resultados

Neste Capítulo foram apresentados os resultados obtidos com os experimentos realizados através da aplicação das técnicas propostas em dois tipos de *datasets*: um que continha todas as imagens de folhas de tabaco afetadas por CVC (incluindo imagens sem denotação de grau de infecção) e outro que era composto apenas de imagens denotadas por seu grau de infecção. Os resultados obtidos após o processamento de re-ranqueamento mostram que no primeiro experimento, realizado com o *dataset* completo, o melhor resultado obtido foi de 37,33% de precisão no modelo de cor CIELab, através do conjunto Haralick-a-Euclidiana. Em relação ao segundo experimento, realizado com o *dataset* que continha apenas imagens denotadas com grau de infecção de CVC, os resultados mostraram que o melhor resultado de precisão obtido foi o de 48,37% no modelo de cor RGB, através do conjunto LBP-TC-Canberra. Para avaliar estes resultados, é importante compará-los aos resultados obtidos em outros trabalhos que utilizaram técnicas e métricas semelhantes ao deste trabalho.

Apesar do trabalho de (PADOVESE, 2017) ter analisado tipos de imagens diferentes das que foram analisadas neste trabalho, é possível referenciá-lo para fins de comparação de resultados, já que aplicou a mesma métrica para avaliação (Precisão) e utilizou descritores diversos (de cor e de textura) para o processamento de suas imagens. Ao analisar os resultados obtidos naquele trabalho, verifica-se que após o processamento do re-ranqueamento foram obtidos resultados de aproximadamente 64% de precisão com o descritor GLCM, sendo que o melhor resultado de precisão foi obtido através do descritor FCTH (*Fuzzy Color and Texture Histogram*) (CHATZICHRISTOFIS; BOUTALIS, 2008b), com quase 66% de precisão.

Em outro trabalho, o de (PEDRONETTE; TORRES, 2012a), foram processadas imagens de textura de um *dataset* conhecido como Brodatz. Para avaliação dos resultados, foi utilizada a métrica MAP (*Mean Average Precision*) (MOFFAT; ZOBEL, 2008), que calcula a média de precisão obtida em ranqueamentos. Ao utilizar o descritor LBP, foram obtidas médias de precisão de até 48,40%, porém, os melhores resultados de

média de precisão foram obtidos com o descritor de textura LAS (*Local Activity Spectrum*) (TAO; DICKINSON, 2000), que chegou à média de precisão de até 75,15%.

Ao comparar os resultados obtidos neste trabalho com os resultados dos trabalhos citados, percebe-se que são menores os valores alcançados através dos experimentos deste Capítulo. Apesar disto, conclui-se que a abordagem apresentada poderia ser utilizada como ferramenta auxiliar para a avaliação inicial de imagens de folhas de tabaco infectadas por CVC e, além disso, a adição de novas técnicas à abordagem (o uso de outros descritores de textura e de cor, por exemplo) poderia trazer resultados ainda melhores.

5 Conclusões

Neste trabalho foi apresentado um estudo sobre a aplicação de técnicas de ranqueamento e re-ranqueamento na análise de imagens de folhas de tabaco afetadas pela doença CVC. Foram discutidas técnicas para recuperação de imagens baseada no conteúdo destas (CBIR), técnicas que incluíam o uso de descritores, funções de distância e métodos de aprendizado não supervisionado.

A principal contribuição deste trabalho consiste nos métodos propostos para a busca e ranqueamento de imagens de folhas de tabaco afetadas por CVC. Os métodos baseiam-se na recuperação de imagens de folhas similares, as quais são ordenadas de acordo com o grau de infecção de CVC que apresentam. Em geral, a abordagem proposta consiste na extração de características de textura de imagens de folhas de tabaco digitalizadas no Centro de Citricultura Sylvio Moreira do IAC (Instituto Agronômico de Campinas), onde pesquisadores avaliaram todas as imagens e deram a elas notas de 1 a 6 para representar seu grau de infecção por CVC. Após a extração de características, foram aplicadas funções de distância para calcular a diferença entre todas as imagens e criar ranqueamentos de acordo com a ordenação entre elas. Posteriormente, foi utilizado um método de aprendizado não-supervisionado capaz de realizar tarefas de re-ranqueamento, ou seja, a reordenação dos ranqueamentos iniciais criados e o cálculo de novas distâncias entre as imagens, processo este que tem como propósito o aumento da precisão de tarefas de recuperação e ordenação.

É necessário destacar também o pré-processamento realizado com as imagens do *dataset* desta pesquisa. Foi necessário separar manualmente as imagens através de *software* de edição de imagens, além de desenvolver métodos para binarizar, selecionar os canais de cores e extrair as regiões de interesse, processos que são fundamentais para a realização de tarefas posteriores de extração de características. Assim, pode-se ressaltar que os métodos desenvolvidos para a fase de pré-processamento são outra contribuição deste projeto, já que permitiram a automação desta fase dos experimentos realizados e podem ser aplicados a outros tipos de imagens, não apenas de folhas ou plantas.

Para o desenvolvimento deste trabalho diversas pesquisas foram analisadas, entre as quais pode-se destacar aquelas que utilizaram características visuais de imagens (cor, forma e textura) no auxílio ao diagnóstico de diferentes doenças que afetam plantas. Foram avaliadas características visuais e um método de aprendizado não-supervisionado: o RL-Sim. Os resultados experimentais mostraram que em geral foi obtido aumento de precisão pela aplicação do algoritmo RL-Sim nos ranqueamentos gerados inicialmente. Foi

possível notar também que a métrica P-5 logrou resultados melhores para os conjuntos selecionados de descritor, canal de cor e função de similaridade, porém é necessário ressaltar que na métrica P-10 foram obtidos resultados expressivos, relacionados principalmente ao ganho de precisão.

Adicionalmente, analisando-se os resultados obtidos, pode-se concluir que em relação aos experimentos feitos com todas as imagens do *dataset*, os ranqueamentos criados para as imagens no modelo de cor CIELab apresentaram valores mais expressivos de precisão após aplicação do re-ranqueamento do que os experimentos feitos com ranqueamento de imagens no modelo de cor RGB, sendo o conjunto Haralick-A-Euclidiana o que apresentou melhores índices. Já em relação aos resultados obtidos apenas com as imagens do *dataset* denotadas por grau de severidade de CVC foi possível verificar que, após o re-ranqueamento, os resultados de precisão obtidos para as imagens no modelo RGB (através do conjunto LBP-TC-Canberra) mostraram-se superiores aos resultados obtidos para as imagens no modelo de cor CIELab.

Em síntese, analisando-se os resultados obtidos com este estudo, é possível observar que o uso de aplicações CBIR e métodos não supervisionados (como o RL-Sim) para a análise de imagens é um tema com grande potencial a ser explorado. Dado este fato, em relação a esta pesquisa surgem novas perspectivas para o desenvolvimento de trabalhos futuros, como as sugeridas a seguir:

- Neste trabalho foram utilizados os descritores LBP, GLCM e *Haralick* em conjunto com as funções de similaridade Euclidiana e de Canberra. Seria interessante analisar em uma futura abordagem o desempenho de outros tipos de descritores (não apenas de textura, mas também de cor) e funções, a fim de procurar melhoria dos valores de precisão obtidos para os ranqueamentos criados.
- Dado que os métodos aqui apresentados são flexíveis, sugere-se que sejam utilizados também em pesquisas relacionadas a outros tipos de *dataset* de imagens, não apenas de folhas de plantas.
- Visto que esta pesquisa foi composta apenas de imagens infectadas pelo CVC, propõe-se uma abordagem que inclua também imagens de folhas saudáveis e que, dada uma imagem de consulta, seja possível analisar se esta é saudável ou não.
- O *dataset* utilizado nos experimentos deste trabalho inclui imagens que não foram avaliadas pelos pesquisadores do IAC, ou seja, não possuem notação que indique o grau de infecção de CVC delas. Propõe-se uma pesquisa na qual, a partir dos métodos propostos neste trabalho, seriam gerados ranqueamentos para tais imagens. Em paralelo, seria solicitado a um especialista na avaliação de doenças de plantas

que analisasse as mesmas imagens, designando a elas notas de acordo com seu grau de infecção. Por último, seria feita uma comparação entre os ranqueamentos gerados e a análise feita pelo especialista.

- Como este trabalho obteve resultados interessantes com o uso de um método de aprendizado não supervisionado (o RL-Sim), seria importante que novos estudos avaliassem o uso de outros métodos não supervisionados, como por exemplo, os que utilizam técnicas de agregação de ranqueamentos.

Ao analisar os resultados obtidos através da abordagem proposta neste trabalho, observa-se que tais resultados são promissores. Isto mostra que talvez o uso de outras técnicas poderia produzir resultados superiores. Entre as alternativas a serem exploradas está o uso de descritores diferentes dos que foram aqui empregados, como por exemplo o *Fuzzy Color and Texture Histogram* (CHATZICHRISTOFIS; BOUTALIS, 2008a), um descritor que combina características de cor e de textura. Uma outra alternativa seria o uso de funções de distância adicionais, como a função de Divergência de *Jeffrey* e a função de *Hausdorff*, ambas descritas neste trabalho.

Para finalizar, ao verificar os resultados visuais dos ranqueamentos de imagens de folhas gerados, percebe-se que apresentam imagens cujas notas são distantes da nota da imagem de consulta selecionada. Visto que a classificação de imagens de acordo com seu grau de infecção de CVC foi feita por avaliadores sem experiência na avaliação de doenças de plantas (PEREIRA *et al.*, 2014) e que, como seres humanos, poderiam ter diferentes percepções visuais sobre cada imagem, pondera-se que seria interessante propor uma nova avaliação das imagens por parte de um avaliador especialista em doenças de plantas. Possivelmente tal avaliação seria capaz de obter resultados mais precisos em relação às notas de infecção das imagens apresentadas.

Referências

- ABU, A. *Architecture for biodiversity image retrieval using ontology and Content Based Image Retrieval (CBIR)*. Tese (Doutorado) — University of Malaya, 2013.
- ADOBE. *Color Models @ONLINE*. 2017. Disponível em: <http://dba.med.sc.edu/price/irf/Adobe_tg/models/main.html>.
- ANDALO, F. A. *et al. Descritores de forma baseados em tensor scale*. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2007.
- ARAÚJO, A. de A. *GERENCIAMENTO DE CORES PARA IMAGENS DIGITAIS*. Tese (Doutorado) — Universidade Federal de Minas Gerais, 2005.
- BARTOLINI, I.; CIACCIA, P.; PATELLA, M. The pibe personalizable image browsing engine. In: ACM. *Proceedings of the 1st international workshop on Computer vision meets databases*. [S.l.], 2004. p. 43–50.
- BATULE, V. B.; CHAVAN, G. U.; SANAP, V. P.; WADKAR, K. D. Leaf disease detection using image processing and support vector machine (svm). *Journal for Research/ Volume*, v. 2, n. 02, 2016.
- BUGATTI, P. H.; TRAINA, A. J.; JR, C. T. Assessing the best integration between distance-function and image-feature to answer similarity queries. In: ACM. *Proceedings of the 2008 ACM symposium on Applied computing*. [S.l.], 2008. p. 1225–1230.
- CATTIN, P. *Digital Image Fundamentals Introduction to Signal and Image Processing*. [S.l.]: MIAC, University of Basel, 2016.
- CHANG, N.-S.; FU, K.-S. Query-by-pictorial-example. *IEEE Transactions on Software Engineering*, IEEE, n. 6, p. 519–524, 1980.
- CHATZICHRISTOFIS, S. A.; BOUTALIS, Y. S. Cedd: color and edge directivity descriptor: a compact descriptor for image indexing and retrieval. In: SPRINGER. *International Conference on Computer Vision Systems*. [S.l.], 2008. p. 312–322.
- CHATZICHRISTOFIS, S. A.; BOUTALIS, Y. S. Fcth: Fuzzy color and texture histogram—a low level feature for accurate image retrieval. In: IEEE. *Image Analysis for Multimedia Interactive Services, 2008. WIAMIS'08. Ninth International Workshop on*. [S.l.], 2008. p. 191–196.
- CIE. Cie 15: Technical report: Colorimetry. [s.n.], 2004.
- COX, I. J.; MILLER, M. L.; MINKA, T. P.; PAPATHOMAS, T. V.; YIANILOS, P. N. The bayesian image retrieval system, pichunter: theory, implementation, and psychophysical experiments. *IEEE transactions on image processing*, IEEE, v. 9, n. 1, p. 20–37, 2000.
- CUI, J.; WEN, F.; TANG, X. Intentsearch: interactive on-line image search re-ranking. In: ACM. *Proceedings of the 16th ACM international conference on Multimedia*. [S.l.], 2008. p. 997–998.

- FAGIN, R.; KUMAR, R.; SIVAKUMAR, D. Comparing top k lists. *SIAM Journal on discrete mathematics*, SIAM, v. 17, n. 1, p. 134–160, 2003.
- FERREIRA, C. D.; SANTOS, J.; TORRES, R. d. S.; GONÇALVES, M. A.; REZENDE, R. C.; FAN, W. Relevance feedback based on genetic programming for image retrieval. *Pattern Recognition Letters*, Elsevier, v. 32, n. 1, p. 27–37, 2011.
- FILHO, O. M.; NETO, H. V. *Processamento digital de imagens*. [S.l.]: Brasport, 1999.
- FILHO, R. F. S.; SOUSA, E. d.; TRAINA, A. J. M.; JR, C. T. *Desmistificando o Conceito de Consultas por Similaridade: A Busca de Novas Aplicações na Medicina*. [S.l.]: WIM, 2001.
- GADKARI, D. *Image quality analysis using GLCM*. Dissertação (Mestrado) — University of Central Florida, 2004.
- GAO, Y.; DAI, Q.-H. *Shot-based similarity measure for content-based video summarization*. 2008. 2512–2515 p.
- GARCIA, O. B. *et al. Estudio comparativo de descriptores visuales para la detección de escenas cuasi-duplicadas*. Dissertação (B.S. thesis) — Universidad Autonoma de Madrid, 2011.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. [S.l.]: Prentice Hall, 2001.
- HARALICK, R. M.; SHANMUGAM, K. *et al.* Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, v. 3, n. 6, p. 610–621, 1973.
- HOI, S. C.; LIU, W.; CHANG, S.-F. Semi-supervised distance metric learning for collaborative image retrieval and clustering. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, ACM, v. 6, n. 3, p. 18, 2010.
- JUNIOR, O. S. *Mistura de cores: Uma nova abordagem para processamento de cores e sua aplicação na segmentação de imagens*. Tese (Doutorado) — Universidade de São Paulo, 2009.
- LATECKI, L. J.; LAKAMPER, R.; ECKHARDT, T. Shape descriptors for non-rigid shapes with a single closed contour. *IEEE*, v. 1, p. 424–429, 2000.
- LING, H.; JACOBS, D. W. Shape classification using the inner-distance. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 29, n. 2, p. 286–299, 2007.
- LIU, G.-H.; LI, Z.-Y.; ZHANG, L.; XU, Y. Image retrieval based on micro-structure descriptor. *Pattern Recognition*, Elsevier, v. 44, n. 9, p. 2123–2133, 2011.
- LIU, Y.-T.; LIU, T.-Y.; QIN, T.; MA, Z.-M.; LI, H. Supervised rank aggregation. p. 481–490, 2007.
- LONCARIC, S. A survey of shape analysis techniques. *Pattern recognition*, Elsevier, v. 31, n. 8, p. 983–1001, 1998.
- LONG, F.; ZHANG, H.; FENG, D. D. *Fundamentals of content-based image retrieval*. Springer, p. 1–26, 2003.

- LOPES, S.; RIBEIRO, D.; ROBERTO, P.; FRANCA, S.; SANTOS, J. *Nicotiana tabacum* as an experimental host for the study of plant-xylella fastidiosa interactions. *Plant Disease*, Am Phytopath Society, v. 84, n. 8, p. 827–830, 2000.
- MA, W.-Y.; MANJUNATH, B. S. Netra: A toolbox for navigating large image databases. *Multimedia systems*, Springer, v. 7, n. 3, p. 184–198, 1999.
- MARATHE, H. D.; KOTHE, P. N. Leaf disease detection using image processing techniques. *International Journal of Engineering Research and Technology*, v. 2, n. 3, p. 1–4, 2013.
- MARTINS, J. G.; COSTA, Y.; BERTOLINI, D.; OLIVEIRA, L. Uso de descritores de textura extraídos de glcm para o reconhecimento de padrões em diferentes domínios de aplicação. p. 637–652, 2011.
- MOFFAT, A.; ZOBEL, J. Rank-biased precision for measurement of retrieval effectiveness. *ACM Transactions on Information Systems (TOIS)*, ACM, v. 27, n. 1, p. 2, 2008.
- NALINI, M. P.; MALLESWARI, B. Review on content based image retrieval: From its origin to the new age. *International Journal of Research Studies in Science, Engineering and Technology*, v. 3, n. 2, p. 18–41, 2016.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, Elsevier, v. 29, n. 1, p. 51–59, 1996.
- OKADA, C. Y.; PEDRONETTE, D. C. G.; TORRES, R. da S. Unsupervised distance learning by rank correlation measures for image retrieval. p. 331–338, 2015.
- PADOVESE, B. T. Suporte ao diagnóstico da doença de alzheimer a partir de imagens de ressonância magnética. Universidade Estadual Paulista (UNESP), 2017.
- PEDRONETTE, D. C. G.; TORRES, R. d. S. Exploiting contextual information for image re-ranking and rank aggregation. *International Journal of Multimedia Information Retrieval*, Springer, v. 1, n. 2, p. 115–128, 2012.
- PEDRONETTE, D. C. G.; TORRES, R. D. S. Exploiting pairwise recommendation and clustering strategies for image re-ranking. *Information Sciences*, Elsevier, v. 207, p. 19–34, 2012.
- PEDRONETTE, D. C. G.; TORRES, R. d. S. Image re-ranking and rank aggregation based on similarity of ranked lists. *Pattern Recognition*, Elsevier, v. 46, n. 8, p. 2350–2360, 2013.
- PEREIRA, W. E. L. *et al.* *Uso de Nicotiana tabacum e Arabidopsis thaliana como plantas modelo para estudo funcional de genes associados à resistência a clorose variegada dos citros*. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2014.
- PLATANIOTIS, K.; VENETSANOPOULOS, A. N. *Color image processing and applications*. [S.l.]: Springer Science & Business Media, 2013.
- RAHIMZADEH, R.; FARZAN, A.; FATHABAD, Y. F. A survey on semantic content based image retrieval and cbir systems. *Int. J. Tech. Phys. Probl. Eng.(IJTPE)*, 2014.

- RIBEIRO, P. P. E. *Aplicação de técnicas de processamento de imagens para diferenciação do greening de outras pragas*. Tese (Doutorado) — Universidade de São Paulo, 2012.
- RODRIGUES, L. C. *et al.* *Sistema computacional de medidas de colorações humanas para exame médico de sudorese*. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2015.
- ROSSETTI, V.; NEGRI, J. D. D. Clorose variegada dos citros: revisão. *Laranja*, v. 11, n. 1, p. 14, 1990.
- RUBNER, Y.; TOMASI, C. *Perceptual metrics for image database navigation*. [S.l.]: Springer Science & Business Media, 2013. v. 594.
- RUI, Y.; HUANG, T. S.; ORTEGA, M.; MEHROTRA, S. Relevance feedback: a power tool for interactive content-based image retrieval. *IEEE Transactions on circuits and systems for video technology*, IEEE, v. 8, n. 5, p. 644–655, 1998.
- SANTOS, J. A. dos; FERREIRA, C. D.; TORRES, R. d. S.; GONÇALVES, M. A.; LAMPARELLI, R. A. A relevance feedback method based on genetic programming for classification of remote sensing images. *Information Sciences*, Elsevier, v. 181, n. 13, p. 2671–2684, 2011.
- TAO, B.; DICKINSON, B. W. Texture recognition and image retrieval using gradient indexing. *Journal of Visual Communication and Image Representation*, Elsevier, v. 11, n. 3, p. 327–342, 2000.
- TAO, D.; TANG, X.; LI, X.; WU, X. Asymmetric bagging and random subspace for support vector machines-based relevance feedback in image retrieval. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 28, n. 7, p. 1088–1099, 2006.
- TORRES, R. da S.; FALCAO, A. X. Content-based image retrieval: theory and applications. *RITA*, v. 13, n. 2, p. 161–185, 2006.
- VALEM, L. P.; PEDRONETTE, D. C. G.; TORRES, R. d. S.; BORIN, E.; ALMEIDA, J. Effective, efficient, and scalable unsupervised distance learning in image retrieval tasks. p. 51–58, 2015.
- VIEIRA, R. T. *Análise de micropadrões em imagens digitais baseada em números fuzzy*. Tese (Doutorado) — Universidade de São Paulo, 2013.
- WANG, J.; LI, Y.; BAI, X.; ZHANG, Y.; WANG, C.; TANG, N. Learning context-sensitive similarity by shortest path propagation. *Pattern Recognition*, Elsevier, v. 44, n. 10, p. 2367–2374, 2011.
- WARNE, P. P.; GANORKAR, S. Detection of diseases on cotton leaves using k-mean clustering method. *International Research Journal of Engineering and Technology (IRJET)*, v. 2, p. 04, 2015.
- YANG, X.; KOKNAR-TEZEL, S.; LATECKI, L. J. Locally constrained diffusion process on locally densified distance spaces with applications to shape retrieval. p. 357–364, 2009.
- YANG, Y.; NIE, F.; XU, D.; LUO, J.; ZHUANG, Y.; PAN, Y. A multimedia retrieval framework based on semi-supervised ranking and relevance feedback. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 34, n. 4, p. 723–742, 2012.

ZHU, X.; GOLDBERG, A. B. Introduction to semi-supervised learning (synthesis lectures on artificial intelligence and machine learning). *Morgan and Claypool Publishers*, v. 14, 2009.

Apêndice

A Artigos

A seguir é apresentado um artigo original dos autores. Tal artigo, relacionado à pesquisa desenvolvida nesta dissertação, foi submetido à Revista do IEEE América Latina e encontra-se em revisão por parte dos autores.

Digital Image Ranking Of Tobacco Leaves Affected By CVC Disease

Q. V. M. D. S. Teixeira, M. A. G. D. Carvalho, D. C. G. Pedronette

Abstract— The Clorose Variegada dos Citros (CVC) affects a significant part of citrus production in Brazil and causes expressive economic loss to agriculture. Usually, it is necessary to know the the degree of this disease in the citrus in order to identify the best and correct treatment. The texture analysis of the leaves of the affected plants by means of digital image processing techniques is an important method to analyze the degree of impairment. This paper proposes an image-based approach in order to analyze tobacco leaves using image ranking, an important technique from the Content-Based Image Retrieval (CBIR) domain. The rankings are computed from two different distance measures. We analyze the images considering three distinct color components and texture descriptors: GLCM, LBP and Haralick. Experiments were performed using a set of images provided by the Instituto Agronômico de Campinas - Brazil. The performance of the method is compared to the manual image classification, according to the degree of CVC infection.

Keywords— CVC, CBIR, image ranking, texture analysis.

I. INTRODUÇÃO

A Bactéria *Xylella fastidiosa* atualmente representa a causa de perdas significativas na produção de frutas como a uva, o pêssego, a ameixa e a laranja. Devido a tais perdas, a bactéria tem sido objeto de estudo constante de estudo por pesquisadores área agrícola, em que diversas iniciativas procuram entender os sintomas de doenças associadas à bactéria, assim como encontrar meios para combatê-los.

No Brasil, a bactéria afeta principalmente as plantações de laranja doce, causando a propagação da Clorose Variegada dos Citros (CVC), doença que gera anomalias nas folhas da fruta, como alteração de tamanho e lesões de cor laranja escuro [1].

Pesquisadores do Centro de Citricultura Sylvio Moreira, vinculado ao Instituto Agronômico de Campinas-SP (IAC), tem focado parte de sua pesquisa no estudo de sintomas da colonização de *Xylella fastidiosa*, procurando identificar os diferentes níveis sintomáticos existentes. Para esta pesquisa, a utilização de folhas de Tabaco é altamente difundida, visto que experimentos controlados demonstram que esta planta, quando infectada, apresenta sintomas em um período menor que o da laranja doce. A Fig. 1 apresenta exemplos de níveis sintomáticos de folhas infectadas, cujo registro foi feito no Centro de Citricultura Sylvio Moreira.

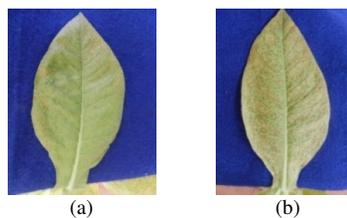


Figura 1. Níveis sintomáticos de folhas infectadas: (a) estágio inicial de infecção; (b) estágio final de infecção.

Entre os desafios encontrados na análise automática de folhas pode-se destacar a ordenação ou organização das folhas de acordo com o nível de infecção da doença CVC. Esse problema pode ser modelado como uma tarefa de classificação ou de ranqueamento de imagens, sendo esta última a abordagem adotada neste artigo.

Alguns estudos tem proposto alternativas para a classificação de imagens de folhas. No trabalho de [2] foi realizada uma classificação manual de folhas de plantas de Tabaco colonizadas pela bactéria *Xylella fastidiosa*. A finalidade dessa classificação era avaliar o grau de sintomas da CVC que as folhas apresentavam. Com o auxílio de um software, foi possível calcular o nível de severidade de sintomas de cada folha, gerando uma escala, que depois foi comparada com a classificação de avaliadores inexperientes: nível sintomático variando de 1 (menor nível sintomático) a 6 (maior nível sintomático). Em outro trabalho, o de [3], amostras de folhas de citros foram analisadas por meio de técnicas de segmentação de imagens, utilizando descritores de cor e textura, e posterior classificação. As folhas estavam infectadas por doenças como o *Greening*, a CVC e a rubelose ou que apresentavam deficiências nutricionais de manganês, magnésio e zinco. Resultados obtidos evidenciaram que a técnica de análise de textura através do descritor LBP (*Local Binary Pattern*) foi a mais eficiente para diferenciar o *Greening* de outras pragas. Há ainda trabalhos que utilizam técnicas de *re-ranking* [4] e *ranking* [5], por exemplo, que abordam o problema sob uma outra ótica.

O objetivo deste trabalho consiste na proposta de uma abordagem baseada em ranqueamento de imagens a partir da análise de folhas de tabaco afetadas por CVC de acordo com seu nível sintomático. Foram comparados os *rankings* obtidos por meio de uso de diferentes medidas de distância e três canais de cores: tons de cinza, verde e vermelho. Como resultado desta comparação, é possível apontar a melhor combinação de canal

Q. V. M. S. Teixeira, Universidade Estadual de Campinas, Limeira-SP, Brasil, queilamartins@gmail.com

M. A. G. Carvalho, Universidade Estadual de Campinas, Limeira-SP, Brasil, magic@ft.unicamp.br

D. C. G. Pedronette, Universidade Estadual Paulista, Rio Claro-SP, Brasil, daniel@rc.unesp.br

Corresponding author: Q. V. M. S. Teixeira

de cor e medida de distância na obtenção de resultados mais eficazes no que tange à classificação de folhas afetadas pela CVC.

Este trabalho é organizado da seguinte maneira: a seção II apresenta alguns trabalhos relacionados presentes na literatura da área; a abordagem proposta é descrita na seção III. Os experimentos e resultados são descritos na seção IV. Finalmente, a seção V mostra as discussões e conclusões relacionadas a este trabalho.

II. TRABALHOS RELACIONADOS

Existe uma grande gama de trabalhos relacionados aos assuntos abordados neste artigo: (i) *ranking*, (ii) análise de textura e (iii) classificação. Alguns destes trabalhos, os quais apresentam técnicas semelhantes às propostas neste artigo, são apresentados a seguir.

No tema de *Ranking* de imagens, em [5] foram apresentados dois frameworks de CBIR baseados na relevância de *feedback* de usuários. O primeiro explora apenas a seleção de imagens consideradas pelos usuários como relevantes. O segundo considera tanto as imagens relevantes quanto aquelas classificadas como irrelevantes pelos usuários. Ambos utilizam técnicas de programação genética para captar preferências dos usuários. Na sequência, as imagens são apresentadas em um *ranking*, ordenadas de acordo com o grau de similaridade que apresentam em relação a uma dada imagem de consulta. Em outro trabalho sobre o mesmo tema, é proposta uma técnica que redefine distâncias entre imagens levando em consideração a similaridade existente entre suas listas ranqueadas [4]. É apresentado o algoritmo RL-Sim que, através de um *ranking* inicial, produz uma nova matriz de distância otimizada, sendo possível obter *rankings* mais eficientes.

Em relação ao tema de análise de textura, no trabalho de Patrícia [3] é realizada um análise das características de cor e textura em cerca de 300 imagens de folhas de plantas de citros. O objetivo foi identificar se as plantas estavam afetadas por uma doença denominada greening. Na análise de textura feita são utilizados os descritores LBP, LFP e Haralick. Este trabalho inclui também a classificação de folhas, a qual foi realizada por meio de redes neurais e medidas de distância. Após experimentos, os autores concluíram que o descritor LBP foi o mais eficiente na diferenciação do *greening* das outras pragas existentes nas folhas.

No artigo de Penatti et al. [6] é apresentado um estudo comparativo de descritores globais de cor e textura, considerando a *Web* como ambiente de uso. Após comparações de 24 descritores de cor e 28 descritores de textura, os de resultados mais promissores foram implementados e avaliados. Os experimentos possibilitaram a medição da eficiência na extração de características, no cálculo de distâncias e armazenamento de vetores de características, além da medição da eficácia de cada descritor. Após análise de resultados, os descritores BIC [7] e ACC [8] foram apontados como a melhor escolha para ambientes heterogêneos como o ambiente *Web*.

No trabalho de Marathe [9] é proposto um método que utiliza processamento de imagens para a detecção da área de folhas infectadas por doenças. Este método sugere o cálculo de *pixels* de uma imagem para determinar a área total de uma folha e a área total de cor verde desta. Após, calcula-se a porcentagem

de área infectada ao se subtrair a área total verde da folha pela área total da mesma.

Na área de classificação, Zhang et al. [10] apresenta um método de reconhecimento de patologias em imagens de folhas de plantas. Após segmentar a área da folha infectada, um descritor é utilizado na extração de características pertinentes à doença. Então é configurado um classificador *K-Nearest Neighbors* (KNN), responsável por identificar qual doença afetou a folha em questão.

Em [2], após inoculação de CVC em folhas de tabaco foi desenvolvida uma escala diagramática para auxiliar na classificação do nível sintomático das folhas afetadas. A escala possibilitou que avaliadores classificassem de maneira visual as folhas afetadas, atribuindo a elas notas entre os valores 1 (nível mais baixo de severidade de infecção) a 6 (nível mais severo de infecção).

Este trabalho propõe a utilização de descritores de textura e medidas de distância na análise de imagens de folhas de tabaco afetadas por CVC. A análise é realizada em 3 canais de cores (vermelho, verde e tons de cinza) e produz como resultado listas de *rankings*, as quais organizam ou ordenam as imagens de acordo com seu nível sintomático. As técnicas aqui propostas contribuem para o aprimoramento da classificação de folhas doentes realizada em [2], pois automatizam análises que previamente requeriam interação humana, acrescentando assim precisão aos resultados obtidos e reduzindo o esforço necessário para categorizar as imagens de folhas.

III. METODOLOGIA

A abordagem proposta consiste basicamente de 3 fases, conforme ilustra a Fig. 2: (i) pré-processamento; (ii) extração de características; (iii) *ranking*.

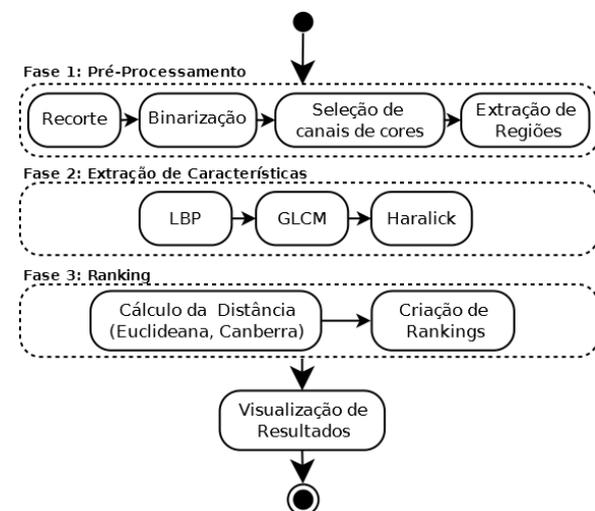


Figura 2. Diagrama de blocos do processo de ranqueamento de folhas de tabaco.

Em geral, na primeira fase são realizadas as ações de aquisição e preparação das imagens, identificando a região de interesse; na segunda fase as características de textura são obtidas para as regiões da imagem que foram definidas como significativas; e a última fase consiste na obtenção do *ranking*

a partir das equações de distância estipuladas. As seções seguintes apresentam um detalhamento de cada uma dessas etapas.

A. Pré-processamento

A fase de Pré-processamento é composta por 4 etapas, descritas na sequência.

1. Recorte de Imagens

Esta etapa foi responsável pela preparação das imagens de folhas cedidas pelo Centro de Citricultura Sylvio Moreira. Em geral, cada arquivo de imagem RGB disponibilizado continha mais de uma folha de tabaco, o que prejudicaria as avaliações do *ranking*. Utilizou-se, portanto, um software de edição de imagens para realizar o recorte manual das folhas por arquivo. A Fig. 3 (a) apresenta imagens antes do recorte, na qual cada arquivo possui três folhas. A Fig. 3 (b) apresenta uma imagem após o recorte, e contém a imagem da folha que estava no centro da Fig. 3 (a).

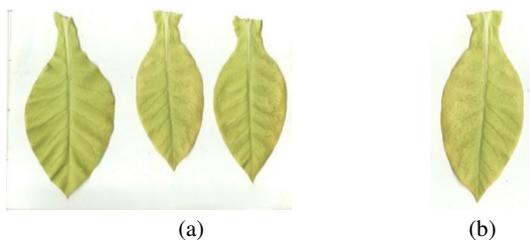


Figura 3. Amostras de imagens de folhas afetadas por CVC. (a) Amostra original, com três imagens de folhas infectadas; (b) Amostra de imagem recortada, com apenas uma imagem de folha.

2. Binarização

A binarização teve como objetivo gerar uma imagem de máscara para uso em etapas seguintes. Cada imagem foi modificada de forma que seu background passou a ter apenas *pixels* de cor preta e a folha (parte de interesse na análise) passou a ter *pixels* de cor branca, conforme ilustrado pela Fig. 4.

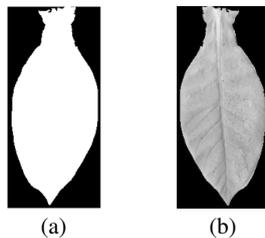


Figura 4. Resultados da fase de binarização. (a) imagem após processo de binarização; (b) imagem em tons de cinza obtida através de imagem binarizada.

3. Seleção de Canais de cores

Para efeitos de comparação e avaliação de resultados, este trabalho também extraiu amostras das imagens de folhas nos canais de cores vermelho (canal R, de red) e verde (canal G, de green). Cada canal de cor, incluindo a imagem em tons de cinza (TC) foi gravado em uma nova imagem identificada pelo canal

de cor correspondente. A Fig. 5 apresenta os resultados das seleções de cores efetuadas, sobre a máscara binarizada.

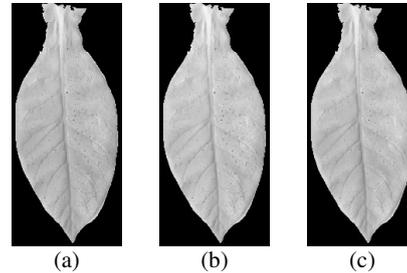


Figura 5. Resultados da fase de seleção de canais de cores. (a) Imagem em tons de cinza; (b) imagem em canal de cor verde; (c) imagem em canal de cor vermelho.

4. Extração de Regiões

O objetivo desta etapa é selecionar regiões específicas de cada imagem para que, na sequência, possam ser calculados os descritores de textura. A técnica consiste na localização do centróide da folha na imagem, desconsiderando os *pixels* de cor preta, e então extrai uma região retangular. Esta etapa tem grande importância, pois possibilita o cálculo da similaridade entre os *pixels*, dado que as regiões comparadas possuirão as mesmas dimensões. A Fig. 6 (a) apresenta a imagem e a seleção feitas nesta etapa, sendo o retângulo a área onde será realizado o corte da região de interesse. A Fig. 6 (b) apresenta a região extraída que será utilizada nas fases seguintes.

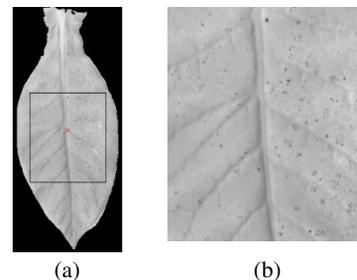


Figura 6. Resultados da fase de extração de regiões. (a) imagem que mostra a seleção da área que será cortada na imagem; (b) região extraída da imagem da folha.

B. Extração de características

De forma geral, um descritor tem por finalidade captar atributos de forma, textura ou cor de uma imagem e é definido por duas funções: a primeira, de extração de um vetor de características que representam as propriedades de uma imagem; e a segunda, uma função de distância, capaz de medir a diferença entre imagens a partir de seus vetores de características [11]. Essa segunda função será abordada na próxima seção. Esta fase, portanto, consiste no cálculo das características de textura da imagem de folha. Neste trabalho foram utilizados descritores de textura capazes de medir algumas propriedades como regularidades, orientação (direção), suavidade e granularidade, entre outras [12]. Os descritores utilizados foram o *Local Binary Pattern* (LBP), o

Gray-Level Co-Occurrence Matrix (GLCM) e o Haralick, detalhados a seguir.

1. Local Binary Pattern (LBP)

O descritor LBP foi proposto por Ojala [13], sendo considerado um descritor de textura local que analisa a imagem em relação às intensidades relativas entre os *pixels* e uma pequena vizinhança. o LBP realiza a análise de uma imagem em uma única componente de cor, considerando uma janela 3x3 ao redor do *pixel* central. O valor LBP para cada *pixel* é dado conforme a Equação 1.

$$N_{LBP} = \sum_{k=1}^8 E_k \cdot 2^{k-1} \quad (1)$$

Onde E_k apresenta o valor 1 caso a intensidade do *pixel* central seja menor do que o vizinho k , e 0 caso contrário.

Finalmente, é gerado um histograma para indicar as ocorrências dos diferentes códigos LBP, o qual forma o vetor de características LBP que caracteriza uma imagem de textura. Para esta fase do trabalho foram adotados dois procedimentos: o primeiro realiza o cálculo dos códigos LBP para cada imagem, em cada canal de cor, e o segundo gera os histogramas que contêm os códigos LBP de cada imagem. Os histogramas gerados são armazenados e utilizados no cálculo de similaridade entre todas as imagens. A Fig. 7 (a) mostra a região da imagem antes da aplicação do cálculo do LBP, enquanto que a Fig. 7 (b) mostra a região da mesma imagem após o cálculo do descritor LBP.

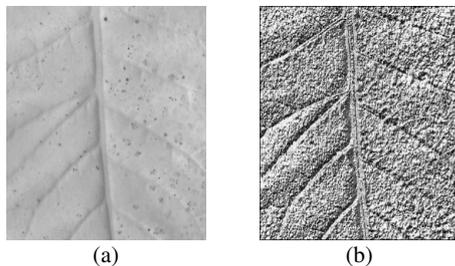


Figura 7. Resultados da fase de execução do cálculo do LBP na região da imagem da folha. (a) imagem antes da execução do cálculo do LBP; (b) imagem gerada após execução do cálculo do LBP.

2. Gray-Level Co-Occurrence Matrix (GLCM)

O descritor GLCM descreve uma matriz de co-ocorrência de níveis de cinza que armazena a probabilidade de que dois valores de intensidade de cinza estejam envolvidos por uma determinada relação espacial [14]. A partir desta matriz de probabilidades, diferentes medidas estatísticas são extraídas a fim de caracterizar a textura presente na imagem [15]. Uma GLCM permite a extração de várias medidas de características relacionadas a texturas, como por exemplo, contraste, energia, correlação e homogeneidade.

Matematicamente, uma GLCM considera um operador $p(i, j; d, \theta)$, em uma imagem f , com L níveis de intensidade, onde p é uma matriz cujo elemento $p_{i,j}$ é o número de vezes que os pares de *pixels* com intensidades z_i e z_j ocorrem em f na posição definida por p e $1 \leq i, j \leq L$. Ou seja, a matriz de

co-ocorrência considera a relação de dois elementos (*pixels*) de textura por vez: um chamado de *pixel* de referência e outro de *pixel* vizinho com propriedades i e j , separados por uma distância d em uma direção θ . O *pixel* vizinho pode estar em qualquer distância do *pixel* de referência, como por exemplo, 1 *pixel*, ou 2, ou 3, ou L , e em qualquer direção, como por exemplo, a 0° , a 45° , a 135° , a 180° , a 225° e a 270° .

Foi calculada uma matriz GLCM para cada região selecionada na imagem original, extraída para cada canal de cor (canais TC, R e G).

2. Haralick

Os descritores de Haralick possibilitam a extração de 14 características de textura de imagem a partir de uma matriz de co-ocorrência (GLCM), sendo elas: segundo momento angular, contraste, correlação, variância, momento de diferença inverso, média da soma, variância da soma, entropia da soma, entropia, variância da diferença, entropia da diferença, medidas de informação da correlação (com duas propriedades) e coeficiente de correlação máximo. Segundo Haralick [14], este descritor permite a análise de características que não são invariantes sobre as transformações monotônicas de níveis de cinza, o que possibilita classificar, por exemplo, imagens que possuem a mesma textura porém com níveis de cinza claro e escuros, algo que o olho humano não é capaz de fazer. Neste trabalho são calculadas as características de Haralick a partir das matrizes de co-ocorrência geradas previamente para cada canal de cor.

C. Ranking

Rankings podem ser obtidos por meio do cálculo de similaridade ou distância entre objetos. Em nosso caso, obtiveram-se *rankings* ou listas ranqueadas por meio do cálculo de distância entre vetores de características das imagens. Neste trabalho foram utilizadas duas métricas de distância: Euclidiana e Canberra, especificadas a seguir.

Euclidiana

A distância Euclidiana é comumente usada para calcular a distância entre vetores e corresponde à noção espacial de distância dos seres humanos, o que a torna a mais empregada em comparações de distância. Sua Equação é dada por:

$$D_E = \sqrt{\sum_{i=1}^n (x[i] - y[i])^2} \quad (2)$$

Onde $x[i]$ e $y[i]$ representam, respectivamente, uma posição i do vetor de características das imagens x e y .

Canberra

A distância de Canberra é sensível a mudanças, sendo considerada a mais restritiva equação de distância [16]. Para obter o valor de distância entre as características de uma imagem, realiza-se o cálculo da divisão da diferença absoluta dos valores das características e o divide por sua soma absoluta. Sua equação é dada por:

$$D_c = \sum_{i=1}^n \frac{|x[i] - y[i]|}{|x[i]| + |y[i]|} \quad (3)$$

Onde $x[i]$ e $y[i]$ representam, respectivamente, uma posição i do vetor de características das imagens x e y .

IV. AVALIAÇÃO EXPERIMENTAL

Esta seção discute a avaliação experimental realizada. Em primeiro lugar, são apresentadas a coleção de imagens e a métrica de avaliação empregada para avaliar o método proposto. Na sequência, são apresentados os experimentos e discutidos os resultados.

A. Coleção de imagens

Os experimentos foram realizados utilizando uma coleção de 30 imagens de folhas de tabaco. São imagens coloridas, modelo RGB, sendo que algumas imagens da coleção apresentam mais de um folha de tabaco - o que gera diferentes tamanhos de imagens. Todas as imagens foram classificadas por avaliadores do IAC de acordo com o grau de sintomas de CVC que apresentavam. A classificação foi feita por meio da atribuição de notas em uma escala de 1 a 6, sendo a nota 1 o grau de menor infecção e 6 o grau de maior infecção.

B. Métrica de Eficácia

Os resultados foram avaliados utilizando a métrica *Mean Average Precision* - MAP [17]. Esta é uma das métricas de eficácia mais utilizadas na literatura que combina os valores de precisão e recall de forma a obter um único valor como medida. Para a obtenção do MAP, calcula-se a precisão média (*Average Precision* - AP) para cada *ranking*, e, em seguida, a média destes valores. Para o cálculo da precisão média (AP), considera-se a quantidade de elementos da mesma classe da imagem de consulta nas primeiras posições dos *rankings*. A medida AP pode ser formalmente definida pela seguinte equação:

$$AP = \frac{1}{N_r} \sum_{i=1}^d \left(\frac{r_i}{i} \sum_{j=1}^i r_j \right) \quad (4)$$

Onde N_r representa o número de imagens relevantes à consulta e $\left(\frac{r_i}{i} = 1, 2, \dots, d \right)$ um vetor de relevâncias de tamanho d , e r indica o valor numérico da relevância da imagem que ocupa a i -ésima posição, sendo que 0 significa não-relevante e 1, relevante.

C. Experimentos e Resultados

Nós focamos neste trabalho a análise da lista ranqueada obtida a partir do uso dos descritores LBP, GLCM e de Haralick, combinada às métricas de distância Euclidiana e Canberra, para os canais de cores TC (tons de cinza), R (vermelho) e G (green). Todos esses elementos foram abordados em seções anteriores. A Tabela I sumariza os resultados obtidos, à luz dos valores de MAP.

TABELA I
VALORES DE MAP PARA A COLEÇÃO DE 30 IMAGENS DE FOLHAS DE TABACO

Descritor	Euclidiana			Canberra		
	TC	R	G	TC	R	G
LBP	73,91 %	72,56 %	74,05 %	70,43 %	71,11 %	71,12 %
GLCM	67,62 %	68,86 %	67,27 %	66,68 %	66,17 %	67,43 %
Haralick	64,56 %	68,55 %	62,65 %	69,66 %	70,58 %	64,27 %

Foram utilizados todos os descritores de Haralick em nossos experimentos. O tamanho da região de interesse selecionada em cada imagem de folha foi de 401 por 476 *pixels*.

Observe que o descritor LBP apresenta quase sempre os melhores resultados, independente do canal de cor e medida de distância. De acordo com a Tabela I, a combinação do canal de cor Green com o descritor LBP e a métrica de distância Euclidiana apresenta o melhor resultado de MAP (*Mean Average Precision*), conforme mostrado na célula destacada em cor verde. Este resultado é ilustrado na Fig. 8, na qual são apresentadas as folhas e seus níveis sintomáticos.

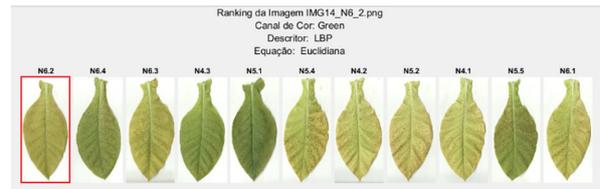


Figura 8. Apresentação visual de *ranking* de similaridade de imagens de folhas de tabaco com imagem de consulta de nota 6.2 de nível sintomático de CVC.

A Fig. 8 ilustra graficamente o *ranking* de classificação das 10 imagens mais similares à imagem da folha de nota 6.2 (destacada com borda de cor vermelha), que foi selecionada como imagem de consulta. Conforme pode-se observar na Figura 8, ao aplicar-se o descritor LBP no canal de cor verde (Green) das imagens em conjunto com a função de distância Euclidiana, obteve-se como resultado de classificação que a imagem de folha mais similar à imagem de consulta é a de nota 6.4, enquanto que a menos similar é a de nota 6.1.

IV. CONCLUSÕES

Este trabalho apresentou um estudo comparativo entre duas medidas de distância aplicadas ao problema de ranqueamento de imagens de folhas infectadas pela doença CVC. Foram testados diferentes canais de cor a fim de se obter uma melhor configuração de análise das imagens. Esse estudo baseou-se na extração de características de textura das imagens digitais das folhas.

De acordo com os experimentos realizados, foi possível notar que os resultados mais eficientes na classificação das folhas infectadas por CVC foram obtidos através da utilização do descritor LBP em conjunto com a função de distância Euclidiana no canal de cor verde (canal G - Green).

Para trabalhos futuros, serão abordados algoritmos de *re-ranking* como o apresentado em [4] para tentar obter *rankings*

mais eficientes, visto que os *rankings* gerados neste trabalho ainda apresentam algumas deficiências em relação à classificação de imagens (por exemplo, apresentando como imagens similares algumas imagens de folhas com grau de infecção muito menor ou muito maior à imagem de consulta selecionada). Uma outra possibilidade interessante para um futuro trabalho seria utilizar as técnicas aqui apresentadas para a classificação de folhas infectadas por outras doenças e também folhas de outras espécies de plantas.

AGRADECIMENTOS

Os autores agradecem ao Centro de Citricultura Sylvio Moreira do Instituto Agrônomo de Campinas pela permissão do uso das imagens digitais das folhas de tabaco. Agradecemos também à FAPESP (processo 2013/08645-0) pelo apoio financeiro.

REFERÊNCIAS

- [1] S. Lopes, D. Ribeiro, P. Roberto, S. Franca, and J. Santos, "Nicotiana tabacum as an experimental host for the study of plant-xylella fastidiosa interactions," *Plant Disease*, vol. 84, no. 8, pp. 827–830, 2000.
- [2] W. E. L. Pereira et al., "Uso de nicotiana tabacum e arabidopsis thaliana como plantas modelo para estudo funcional de genes associados à resistência a clorose variegada dos citros," 2014.
- [3] P. P. E. Ribeiro, "Aplicação de técnicas de processamento de imagens para diferenciação do greening de outras pragas," Ph.D. dissertation, 2014.
- [4] D. C. G. Pedronette and R. d. S. Torres, "Image re-ranking and rank aggregation based on similarity of ranked lists," *Pattern Recognition*, vol. 46, no. 8, pp. 2350–2360, 2013.
- [5] C. D. Ferreira, J. Santos, R. d. S. Torres, M. A. Gonçalves, R. C. Rezende, and W. Fan, "Relevance feedback based on genetic programming for image retrieval," *Pattern Recognition Letters*, vol. 32, no. 1, pp. 27–37, 2011.
- [6] O. A. Penatti, E. Valle, and R. d. S. Torres, "Comparative study of global color and texture descriptors for web image retrieval," *Journal of visual communication and image representation*, vol. 23, no. 2, pp. 359–380, 2012.
- [7] R. O. Stehling, M. A. Nascimento, and A. X. Falcão, "A compact and efficient image retrieval approach based on border/interior pixel classification," in *Proceedings of the eleventh international conference on Information and knowledge management*. ACM, 2002, pp. 102–109.
- [8] J. Huang, S. R. Kumar, M. Mitra, W.-J. Zhu, and R. Zabih, "Image indexing using color correlograms," in *Computer Vision and Pattern Recognition*, 1997. *Proceedings.*, 1997 IEEE Computer Society Conference on. IEEE, 1997, pp. 762–768.
- [9] H. D. Marathe and P. N. Kothe, "Leaf disease detection using image processing techniques," in *International Journal of Engineering Research and Technology*, vol. 2, no. 3 (March-2013). ESRSA Publications, 2013.
- [10] S. Zhang, Y. Shang, L. Wang et al., "Plant disease recognition based on plant leaf image," *JAPS, Journal of Animal and Plant Sciences*, vol. 25, no. Suppl. 1, pp. 42–45, 2015.
- [11] F. A. Andalo et al., "Descritores de forma baseados em tensor scale," 2007.
- [12] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*. Prentice Hall, 2001.
- [13] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern recognition*, vol. 29, no. 1, pp. 51–59, 1996.
- [14] R. M. Haralick, K. Shanmugam et al., "Textural features for image classification," *IEEE Transactions on systems, man, and cybernetics*, vol. 3, no. 6, pp. 610–621, 1973.
- [15] J. G. Martins, Y. Costa, D. Bertolini, and L. Oliveira, "Uso de descritores de textura extraídos de glm para o reconhecimento de padrões em diferentes domínios de aplicação," in *XXXVII Conferencia Latinoamericana de Informática*, 2011, pp. 637–652.
- [16] P. H. Bugatti, A. J. Traina, and C. Traina Jr, "Assessing the best integration between distance-function and image-feature to answer

similarity queries," in *Proceedings of the 2008 ACM symposium on Applied computing*. ACM, 2008, pp. 1225–1230.

[17] A. Moffat and J. Zobel, "Rank-biased precision for measurement of retrieval effectiveness," *ACM Transactions on Information Systems (TOIS)*, vol. 27, no. 1, p. 2, 2008.



Queila V. Martins S. Teixeira Possui graduação em Tecnologia em Informática pela Universidade Estadual de Campinas (2003) e é mestranda em Tecnologia pela mesma universidade, na área de Processamento de Imagens. Atua como especialista de informática na empresa IBM desde 2008, onde trabalha na análise e desenvolvimento de sistemas para Recursos Humanos.



Marco Antonio G. Carvalho Possui graduação em Engenharia Elétrica pela Universidade Federal do Rio Grande do Norte (1994), mestrado (1997) e doutorado (2004) em Engenharia Elétrica e Computação pela Universidade Estadual de Campinas, com Estágio Sanduiche no ESIEE em 2001-2002 (França). Em 2009, foi professor na Universidade de Coimbra (Portugal), como parte de suas atividades no Programa ERASMUS. Atua principalmente nos seguintes temas: processamento digital de imagens, visão computacional e grafos.



Daniel Carlos Guimarães Pedronette Possui graduação em Ciência da Computação pela Universidade Estadual Paulista - UNESP (2005), mestrado (2008) e doutorado (2012) em Ciência da Computação pela Universidade Estadual de Campinas - UNICAMP. Atualmente é professor no departamento de Estatística, Matemática Aplicada e Computação (DEMAC), da UNESP. Atua em diversas áreas da Ciência da Computação, incluindo sistemas de informação, bibliotecas digitais, processamento e análise de imagens, recuperação de informações, computação de alto desempenho e sistemas de recuperação de imagens por conteúdo.