

PIERRE FERREIRA DO PRADO

**ESTUDO DE DESCRITORES DE TEXTURAS E CORES PARA A
CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS NO CONTEXTO DAS CIÊNCIAS
AMBIENTAIS**

Sorocaba

2018

PROGRAMA DE PÓS-GRADUAÇÃO em

ciências ambientais

PIERRE FERREIRA DO PRADO

**ESTUDO DE DESCRITORES DE TEXTURAS E CORES PARA A CLASSIFICAÇÃO
AUTOMÁTICA DE IMAGENS NO CONTEXTO DAS CIÊNCIAS AMBIENTAIS**

Tese de doutorado apresentada como requisito para a obtenção do título de Doutor em Ciências Ambientais da Universidade Estadual Paulista "Júlio de Mesquita Filho" na Área de Concentração Diagnóstico, Tratamento e Recuperação Ambiental

Orientador: Prof. Dr. Antonio Cesar Germano Martins

Sorocaba

2018

Ficha catalográfica elaborada pela Biblioteca da Unesp
Instituto de Ciência e Tecnologia – Câmpus de Sorocaba

Prado, Pierre Ferreira do.

Estudo de descritores de texturas e cores para a classificação automática de imagens no contexto das ciências ambientais / Pierre Ferreira do Prado, 2018.

76 f.: il.

Orientador: Antonio Cesar Germano Martins.

Tese (Doutorado) – Universidade Estadual Paulista "Júlio de Mesquita Filho". Instituto de Ciência e Tecnologia (Câmpus de Sorocaba), 2018.

1. Lógica difusa. 2. Cores. 3. Classificação. 4. Descritores. I. Universidade Estadual Paulista "Júlio de Mesquita Filho". Instituto de Ciência e Tecnologia (Câmpus de Sorocaba). II. Título.

Bibliotecário responsável: Bruna B. Guimarães – CRB 8/8855


CERTIFICADO DE APROVAÇÃO

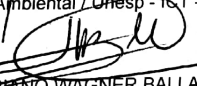
TÍTULO DA TESE: ESTUDO DE DESCRITORES DE TEXTURAS E CORES PARA A CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS NO CONTEXTO DAS CIÊNCIAS AMBIENTAIS

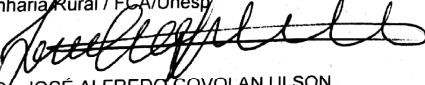
AUTOR: PIERRE FERREIRA DO PRADO

ORIENTADOR: ANTONIO CESAR GERMANO MARTINS


Aprovado como parte das exigências para obtenção do Título de Doutor em CIÊNCIAS AMBIENTAIS, área: Diagnóstico, Tratamento e Recuperação Ambiental pela Comissão Examinadora:


Prof. Dr. ANTONIO CESAR GERMANO MARTINS
Engenharia Ambiental / Unesp - ICT - Sorocaba


Prof. Dr. ADRIANO WAGNER BALLARIN
Engenharia Rural / FCA/Unesp


Prof. Dr. JOSÉ ALFREDO COVOLAN ULSON
Engenharia Elétrica / FEB/Unesp


Prof. Dr. WALDEMAR BONVENTI JUNIOR
Ciência da Computação / Universidade de Sorocaba (UNISO)


Prof. Dr. PAULO SERGIO TONELLO
Engenharia Ambiental / Unesp - ICT - Sorocaba

Sorocaba, 06 de agosto de 2018

Dedicatória

Às Ninetes, aos familiares, amigos e parafraseando o escrito anteriormente: “to our teachers and all those who teach children to question our knowledge, learn through collaboration and the joy of discovery”(Rovelli, Vidotto 2013)

AGRADECIMENTOS

A minha gratidão a todos aqueles que mantêm este essencial sistema de educação em que participei composto por CAPES, UNESP/ICTS, PGCA, UV (Universidade de Valência) , em especial ao Professor Dr. Antonio Cesar Germano Martins e Prof. Dr. Ernesto Lopez-Baeza pelo constante ensinamento.

RESUMO

Há uma crescente disponibilidade de imagens no contexto das ciências ambientais, sendo que a análise automática destas, pode permitir a identificação de objetos e regiões de interesse de forma mais eficiente, agilizando o estudo de fenômenos e a ocorrência de situações de impactos. No entanto, como em qualquer sistema de classificação automática, os resultados obtidos dependem de quais descritores são utilizados para se representar as imagens. Neste sentido, este trabalho busca discutir e comparar o uso de descritores em níveis de cinza, que estão diretamente ligados a textura, e os referentes aos canais de cores. Para isto, foi realizado um estudo para se avaliar os resultados da seleção automática de descritores para se representar imagens de forma a permitir a classificação de imagens de troncos de árvores e imagens aéreas de uso e ocupação do solo no contexto das Ciências Ambientais. Este estudo utilizou a arquitetura de rede neural artificial Fuzzy ARTMAP como classificador e um algoritmo para seleção sequencial de descritores. Os resultados consolidam a importância dos descritores de textura Haralick, de segunda ordem, a partir de níveis de cinza e a relevância do espaço de cores RGB e Lab.

Palavras-Chave: textura, cores, níveis de cinza, Fuzzy ARTMAP, classificação

ABSTRACT

There is a growing availability of images in the context of the environmental sciences, and the automatic analysis of these can allow the identification of objects and regions of interest in a more efficient way, speeding up the study of phenomena and the occurrence of situations of impacts. However, as in any automatic classification system, the results obtained depend on which parameters are used to represent the images. In this sense, this work seeks to discuss and compare the use of parameters in gray levels, which are directly linked to texture, and those referring to color channels. For this, a study was carried out to evaluate the results of the automatic selection of descriptors to represent images in order to allow the classification of images of tree trunks and aerial images of use and occupation of the soil in the context of Environmental Sciences. This study used the artificial neural network architecture Fuzzy ARTMAP as a classifier and an algorithm for the sequential selection+ of descriptors. The results consolidate the importance of ,second order, Haralicks' s texture descriptors from gray levels and the relevance of the RGB and Lab color space.

Keywords: texture, colors, gray levels, Fuzzy ARTMAP, classification

LISTA DE FIGURAS

Figura 1 – Inter-relações que caracterizam a informática aplicada ao meio ambiente	15
Figura 2 – Exemplos de texturas	20
Figura 3 – Exemplo de textura gerada por composição das texturas 1 e 2	20
Figura 4 – Espaços de cores RGB	21
Figura 5 – Espaços de cores HSV	
Figura 6- Diagrama de blocos da RNA Fuzzy ARTMAP (Carpenter et al, 1997)	25
Figura 7 - Mosaico com uma imagem de cada categoria do SB	32
Figura 8 - Mosaico com amostra de imagens das 21 categorias ordenadas da 1ª até 21ª	34
Figura 9- Diagrama esquemático de rotina implementada iterativamente em software	
Figura 10 - Exemplo típico da relação de IBC com o número de descritores selecionados pelo SFS	44
Figura 11 - Números totais de descritores selecionados (Total) para cada subgrupo de descritores (ver Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de SB	45
Figura 12 - Número total mínimo de descritores selecionado para se atingir o máximo IBC (Total) e o número de descritores que aumentam o IBC (Contribuintes) para cada experimento de SB	46
Figura 13 – IBC versus n_{max} relacionados a E=12 experimentos de classificação de imagens	47
Figura 14 - Número de descritores n_{max} e a razão GNC/GC entre a quantidade de descritores: barras em hachura escura (GNC), e em hachura clara (GC) para cada experimento. A razão é observável na projeção dos marcadores circulares à direita em preto no eixo vertical secundário	47
Figura 15 - Acumulo de incrementos unitários (AIU) indica a dinâmica qualitativa da seleção de descritores GC (IU<0) ou GNC (IU>0) de cada um dos 12 experimentos e respectivas séries de dados	48
Figura 16 - Dinâmica do IBCN da classificação em relação ao DMN para os 12 experimentos	49
Figura 17 - Exemplo típico da relação de IBC com o número de descritores selecionados pelo SFS	51

Figura 18 - Números totais de descritores selecionados (Total) para cada subgrupo de descritores (ver Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de UC	52
Figura 19 - Número total mínimo de descritores selecionado para se atingir o máximo IBC (Total) e o número de descritores que aumentam o IBC (Contribuintes) para cada experimento de UC	53
Figura 20 - Dispersão obtida do IBC versus n_{max} relacionados a E=12 experimentos de classificação de imagens	53
Figura 21 - Número de descritores n_{max} e a razão GNC/GC entre a quantidade de descritores: barras em hachura escura (GNC) e em hachura clara (GC). A razão é observável na projeção dos marcadores circulares à direita em preto no eixo vertical secundário	54
Figura 22 - O acúmulo de incrementos unitários (AIU) indica a dinâmica qualitativa da seleção de descritores GC (IU<0) ou GNC (IU>0) de cada um dos 12 experimentos e respectivas séries de dados	55
Figura 23 - Dinâmica do IBCN da classificação em relação ao DMN para os 12 experimentos e respectivas séries de dados	55
Figura24 - Porcentagem de descritores Contribuintes de cada grupo, considerando-se todos os experimentos, para SB e UC	57

LISTA DE TABELAS

Tabela 1 – Quantidades de imagens de casca de arvores e respectivos nomes científicos que constituem o BARKTEX	31
Tabela 2 – Códigos BARKTEX das imagens que compõem o subconjunto usado no estudo de classificação	32
Tabela 3 - Representação do vetor de características com posição, descrição e agrupamentos a partir de canais de cor (GC) ou grupo de descritores a partir de níveis de cinza (GNC) que estão com fundo cinza	38
Tabela 4 – Resultados dos experimentos com SB. A primeira coluna traz o número do experimento em ordem de execução, a segunda e terceira colunas apresentam, respectivamente, a sequência e o número de descritores selecionados para se obter o máximo IBC e a última coluna traz o máximo valor de IBC obtido em cada experimento	43
Tabela 5 – Número total de descritores selecionados (Total) para cada grupo de descritores (ver Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de SB	45
Tabela 6 – Resultados dos experimentos com UC. A primeira coluna é o número do experimento em ordem de execução, a segunda e terceira colunas apresentam, respectivamente, a sequência e o número de descritores selecionados para se obter o máximo IBC e a última coluna traz o máximo valor de IBC obtido em cada experimento	50
Tabela 7 – Número total de descritores selecionados (Total) para cada subgrupo de descritores (ver Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de UC.	51

LISTA DE ABREVIATURAS E SIGLAS

ACM - auto-correlation method

AIU - acumulo de incremento unitário

ART – adaptative ressonance theory

ARTMAP- arquitetura de rede neural baseada na teoria ART

BOVW - bag of visual words

CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

COMM - co-occurrence matrices method

CPU - central processing unit

CIE - Comission Internationale de l'Eclairage

DNM.- razão entre o quantia de descritores selecionados e quantia necessária para que se obtenha a máxima acurácia de classificação.

E - experimento

FAPESP - Fundação de Amparo à Pesquisa do Estado de São Paulo

GC – grupo de descritores baseados em cores

GLCM - gray-level co-occurrence matrix

GNC -grupo de descritores baseados em níveis de cinza

HM - histogram method

HOG - histogram of oriented gradients

$IBC_{n,E}$ - acurácia da classificação considerando n descritores no experimento E

$IBCN_{n,E}$ – acurácia da classificação normalizada em relação ao máxima acurácia , usando n descritores no experimento E.

IFK - Improved Fisher kernel

IU-incremento unitário

KNN - k-nearest neighbourhood

LBP - local binary pattern

LPB - Local Binary Pattern

MMC - moving median centers

n - Quantidade de descritores selecionados pelo SFS na execução E

n_{max} - Quantidade de descritores necessário para obtenção do máximo $IBC_{n,E}$ e usado para fins de normalização

RAM-random access memory

RLM - gray level run-length method

RNA – redes neurais artificiais

R – canal vermelho do espaço de cores RGB

SB - subconjunto de BARKTEX

SFS - Sequecial Forward Selection

SIFT- Scale-invariant feature transform

SPCK - Spatial Pyramidal Co-occurrence Kernel

UAV- unmanned aerial vehicle

UC – Conjunto de experimentos executado com imagens da base UCMERCED

UCMERCED – Banco de imagens da University of California Merced

USGS- United States Geological Survey

VANT – veículo aéreo não tripulado

1-NN - 1K-nearest neighborhood

SUMÁRIO

1 INTRODUÇÃO E REVISÃO BIBLIOGRÁFICA	15
1.1 Inspeção visual	15
1.2 Texturas e cores em imagens digitais	19
1.2.1 Texturas	19
1.2.2 Cores	19
1.2.3 Associações de descritores de cores e textura	23
1.3 Sistemas classificadores de imagens com redes Neuro-Fuzzy	25
2 JUSTIFICATIVA	30
2.1. Classificação automática de espécies arbóreas	
2.2 Classificação automática de imagens aéreas	
3 OBJETIVOS	
3.1 Objetivo Geral	
3.2 Objetivos específicos	30
4 MATERIAL E MÉTODOS	31
4.1 Conjuntos de Imagens	31
4.1.1 Subconjunto Barktex-SB	31
4.1.2 Banco de Imagens de usos e ocupação do solo - UCMERCED	33
4.2 Descritores candidatos	34
4.2.1 Descritores estatísticos de primeira ordem em tons de cinza (PEPOTC)	35
4.2.2 Descritores candidatos de Haralick	36
4.2.3 Descritores espectrais	37
4.3 Vetor de características	37
4.4 Seleção dos descritores mínimos	40
4.5 Classificador	40
4.6 Análise de resultados	41
5 RESULTADOS	43
5. 1 Experimentos com texturas coloridas de cascas de árvores – SB	43
5. 2 Experimentos com a coleção de imagens UC	49
6. DISCUSSÃO	56
6.1. Resultados Gerais	56
6.2 Resultados dos experimentos usando SB e a literatura	57
6. 3 Resultados dos experimentos usando UC e a literatura	59
6. 4 Análise comparativa dos resultados SB e UC	60
7 CONCLUSÕES	62
8 PERSPECTIVAS FUTURAS	64
9 REFERÊNCIAS	65

1 INTRODUÇÃO E REVISÃO BIBLIOGRÁFICA

A informática em estudos do meio ambiente tem como atribuições prover infraestrutura e sistemas de aquisição e comunicação e processamento de dados para as aplicações interdisciplinares da área (HILTY et al., 1995) (Figura 1).

Figura 1 – Inter-relações que caracterizam a informática aplicada ao meio ambiente



Fonte: adaptado de Hilty et al. (1995)

Um uso tradicional no contexto da informática aplicada ao meio ambiente é a resolução por cálculo numérico de equações de modelos matemáticos determinísticos de processos ecológicos (JORGENSEN; VOLLENWEIDER, 2000) que contribuem para aumentar o conhecimento sobre uma questão científica, podendo implicar na diminuição dos esforços com experimentos de campo (BERGAMASCO et al., 2002).

Outra aplicação importante se dá na inspeção visual que será detalhada a seguir na seção 1.1.

1.1 Inspeção visual

O termo inspeção é derivado do Latim *inspectionem*, cujo significado é examinar cuidadosamente. Esta tarefa exige um esforço deliberado e em profundidade, maior do que um simples olhar, requerendo o uso da memória de curto e longo prazo, além de processamento mental e transmissão de informação (PRABHU; DRURY, 1992). Este é um dos principais processos de controle de qualidade em diversas indústrias como de: alimentos, manutenção

aeronáutica, montagem de circuitos impressos, checagem de bagagens, medicina (raios-x, histologia, farmacêutica), entre outros.

A importância da inspeção visual é amplificada pela própria particularidade e por implicações de caráter difuso dos objetos de inspeção (SEE, 2012) e, portanto, é foco de esforços no que tange ao treinamento de agentes através de softwares específicos (SADASIVAN; GRAMOPADHYE, 2009).

A inspeção visual é entendida como a análise por meio do canal visual de um objeto, fenômeno ou cena e tem arcabouço teórico ainda em desenvolvimento e decorrente principalmente de resultados obtidos no âmbito do controle de qualidade em operações industriais feito por pessoas (LAOFOR; PEANSUPAP, 2012).

A análise de imagens é intensamente utilizada nas mais diversas áreas do conhecimento humano, e com o uso do computador intensificou-se a possibilidade de se realizar muitos destes estudos de forma eficiente e automática.

Uma imagem digital pode ser entendida como a representação matricial de uma cena a partir da medida da radiação refletida e/ou emitida pelos objetos presentes, sendo que, as obtidas por câmeras comuns, nos comprimentos de onda na região do visível, estão amplamente difundidas.

A imagem pode revelar mais do que os elementos que estão aparentes, pois, a cena no instante da aquisição é o resultado da ação de diversos fatores naturais e/ou antrópicos, provendo inclusive informações sociais, econômicas e históricas.

Um indicativo da crescente abrangência e complexidade deste ramo de investigação pode ser evidenciado pelo desenvolvimento de algoritmos de processamento de imagens e aprendizado de máquina que objetivam investigar questões fundamentais da física como a direção da passagem do tempo (flecha do tempo) em vídeos disponíveis na internet (PICKUP et al., 2014)

Há evidências de que tarefas visuais possuem conexões com processos fundamentais da chamada inteligência fluida no que se refere a eficiência de processamento neural (OSMON; JACKSON, 2002).

Em uma tarefa de inspeção visual, a variável tempo relaciona-se positivamente com o envelhecimento humano uma vez que este implica em mudanças nos processamentos visuais básicos (MCCRORY; COOPER, 2007, RITCHIE; TUCKER-DROB; DEARY, 2014).

Forestier, Wemmert e Puissant (2013) ressaltaram que a interpretação de imagens está conectada a qualidades individuais da cognição e a conhecimentos obtidos a priori sobre a área, os objetos presentes, a relação dos objetos e o domínio de aplicação dos mesmos.

Esta individualização é considerada por Oliva e Torralba (2007) fator determinante na diferença de velocidade de aquisição de informações sobre objetos em imagens considerando a percepção do contexto em que este se insere. Oliva et al. (2005) sugerem que o mesmo é válido no que se refere a maximização do entendimento de visualizações extremamente breves de imagens que apresentam contextos complexos.

Essas inferências se orientam com o chamado modelo empirista de aquisição de conhecimento e respectiva valorização da experiência sensorial individual (KUTSCHERA et al., 1973).

No recorte das ciências ambientais, existem muitos relatos do uso de imagens para inspeção como, por exemplo, no controle da poluição em ambientes fechados hospitalares relacionadas às infecções no qual se compara a efetividade entre inspeção visual e métodos laboratoriais, concluindo-se que, por apresentar resultados semelhantes, em geral, a inspeção visual torna-se mais atraente na avaliação de métodos de limpeza pós-alta hospitalar (SNYDER et al., 2013).

No viés dos estudos de paisagens, considera-se que a inspeção da imagem de um local permite que se capture informações sobre como este é construído, utilizado as razões de seu uso (RIJNKS; STRIJKER, 2013). Nesta perspectiva, Tok et al. (2010) argumentam que o uso de imagens obtidas de cenas de espaços construídos em Karaköy, Istambul, permitiram intensificar a compreensão qualitativa sobre a ocupação urbana no processo de treinamento de alunos de arquitetura.

Freitas et al. (2010) usaram imagens como elementos ilustrativos de um questionário sobre a temática ambiental no âmbito do território de um campus universitário, com o objetivo de apresentar a definição de ambiente através de três cenas que mostravam diferentes graus de interferência humana.

Çalaskian (2011) utilizou as chamadas viagens virtuais e as considerou como uma opção técnica e economicamente atraente para a promoção da educação em ciências ambientais.

Na área da mineralogia a correlação de imagens de estruturas geológicas e micro resistividade elétrica forneceu informações para a prospecção de petróleo (MOVAHED et al., 2014) e imagens geradas por ressonância magnética ofereceram informações sobre a dinâmica de poluentes em fraturas de rochas (BECKER et al., 2003).

Dell et al. (2014) consideram que a aquisição automatizada de imagens, no contexto de estudos em ecologia, fornece bases para conectar a biologia molecular, neurobiologia e ecologia porque provê informações detalhadas em escala local sobre movimento, e a informação sensorial disponível.

Em reatores químicos, as inspeções visuais fornecem informações sobre a hidrodinâmica, como, por exemplo, anomalias no regime de escoamento do tipo pistão (KARRABI et al., 2011). O estudo das imagens de bolhas em reatores de acrílico proporcionou subsídios para a classificação do regime do fluxo, com indicações de turbulência em reatores de flotação por ar dissolvido (LIN; CHEN, 2005).

Na área de monitoramento, a disponibilidade de imagens aéreas é crescente, inclusive devido ao uso de veículos aéreos não tripulados (VANT) possibilitando novos caminhos para as pesquisas em ciências ambientais. Há a possibilidade de que o uso destes causem uma revolução devido à qualidade e à facilidade de coleta serem superiores a métodos tradicionais (HODGSON et al., 2016). Hodgson et al. (2016) utilizaram VANTS na contagem de colônias de pássaros obtendo resultados que sugerem que as estimativas de populações de aves marinhas, através de imagens produzidas por estes aparatos são tão apropriadas que devem se tornar frequentes em estudos ecológicos futuros.

VANTS de baixo custo associados a softwares para roteamento de vôo tem sido consideradas como plataformas de sensoriamento remoto, permitindo a aquisição de imagens compostas por pixels na escala de centímetros e cuja flexibilidade de uso, portabilidade e rápida resposta o tornam como ferramentas ideais para monitoramento, em especial relativas às perturbações fenológicas de vegetais sob condições meteorológicas variáveis (MADDEN et al., 2015; NEVALAINEN et al, 2017).

Algumas formas de voos de VANTS podem gerar imagens tipo “*Bird-eye-view*” que capturaram informações necessárias e suficientes para a identificação vegetal. Estas imagens

podem, por exemplo, fornecer evidências sobre efeitos da proximidade humana, de fontes de poluição e espécie invasoras que afetam um recurso vegetal (MADDEN et al., 2015).

No caso específico de VANTS com multi-rotor, a baixa autonomia de voo pode ser uma limitação importante, apesar de estes serem geralmente vantajosos quando a operação permite a decolagem de posições estacionárias (superfícies duras e planas idealmente) além do controle fino de pequenos movimentos (MADDEN et al., 2015).

A aplicação para monitoramento de uso e ocupação do solo a partir de VANTS é direta (EZEQUIEL et al., 2014), podendo ser manualmente executadas por especialistas humanos ou de forma automática.

Com o avanço de técnicas de inteligência artificial (IA), é possível se realizar a inspeção visual automaticamente, permitindo a identificação de objetos e regiões de interesse de forma mais eficiente, que, no contexto das ciências ambientais, agiliza muito o estudo de fenômenos e a ocorrência de situações de impactos.

Dentre a diversidade de atividades que correlacionam inspeções visuais e seu caráter eminentemente cognitivo, imagens e ciências ambientais, este trabalho abordou duas aplicações: (1) inspeção e classificação supervisionada possibilitando à identificação de árvores através de imagens do tronco destas e (2) inspeção de imagens aéreas para a classificação de usos do solo no viés da classificação supervisionada (mediante exemplos). Para isto, utilizou-se informações da textura e cor presentes na imagem.

1.2 Texturas e cores em imagens digitais

1.2.1 Texturas

Enfatizando o caráter visual e ignorando o tátil tridimensional, define-se textura como a aparência 2D de uma superfície (RAO, 1990).

Rao e Laohse (1993) propuseram que as principais informações para a caracterização de textura estão relacionadas a: 1) repetitividade versus não repetitividade, 2) alto contraste e não direcionalidade versus baixo contraste e direcionalidade, 3) baixa complexidade e macro texturas (granulometria grosseira) versus alta complexidade e microtexturas (granulometria fina). Seguindo esta proposta, neste trabalho, textura refere-se à distribuição espacial da informação em uma superfície (2D) de uma imagem, mas especificamente a distribuição espacial dos tons de cinza.

Uma textura pode ser classificada em (quase-) ordenada ou aleatória. Na primeira, têm-se a presença de elementos primitivos e regras de repetição destes. Nas texturas aleatórias percebe-se que os valores dos pixels são distribuídos pela imagem de maneira não uniforme. Entre estas duas situações limites, pode-se verificar a existência de texturas intermediárias como as fracamente ordenadas ou fortemente ordenadas (Figura 2). Além destas, têm-se ainda as texturas composicionais (Figura 3) que são obtidas pela composição de características de diferentes texturas (RAO, 1990).


Para a análise de texturas (quase-) ordenadas e aleatórias, pode-se usar, respectivamente, a abordagem estrutural, que busca a identificação de elementos que se repetem, e a estatística que objetiva estimar parâmetros que caracterizem a distribuição dos pixels em uma região (RAO, 1990).

Figura 2 – Exemplos de texturas



Fonte: RAO (1990)

Figura 3 – Exemplo de textura gerada por composição das texturas 1 e 2



Fonte: RAO (1999)

1.2.2 Cores

A noção física de cor está associada ao comprimento de onda da radiação eletromagnética. No entanto, no caso de cenas naturais, não se tem apenas um comprimento de onda, mas sim uma distribuição. Desta forma, para se distinguir as diversas cores presentes em


objetos e regiões são utilizadas as seguintes características: brilho, matiz e saturação. O brilho se relaciona com a noção de intensidade, a matiz é um atributo associado ao comprimento de onda mais intenso da distribuição e a saturação expressa a largura da distribuição.

Para se representar as cores em imagens digitais são utilizados os chamados modelos de cores (GONZALEZ; WOODS, 2006) que se baseiam em sistemas de coordenadas tridimensionais, seguindo o conceito presente na teoria tri estímulo de Young e Helmotz (RANGAYYAN; ACHA; SERRANO, 2011).

O modelo de cores mais conhecido pelo público em geral é o RGB devido a sua utilização em sistemas de aquisição e apresentação de imagens, como câmeras digitais e monitores.

Este modelo foi projetado a partir da escolha das cores vermelha (R – *red*), verde (G – *green*) e azul (B – *blue*) de forma que uma cor é representado um vetor (r,g,b) em um sistema de eixos cartesianos (Figura 4).

Figura 4 – Espaços de cores RGB.



Fonte: autoria própria

Em outro modelo, baseando-se em experimentos psicofísicos, a Comissão Internationale de l'Eclairage (CIE) estabeleceu comprimentos de ondas para os três estímulos, denominando-os de X, Y e Z. Considerando-se valores normalizados, têm-se:

$$x = \frac{X}{X + Y + Z} \quad (1)$$

$$y = \frac{Y}{X + Y + Z} \quad (2)$$

$$z = \frac{Z}{X + Y + Z} \quad (3)$$

Como:


$$x + y + z = 1 , \quad (4)$$

pode-se especificar as cores através do diagrama de cromaticidade CIE uma vez que, dado o par (x,y) a coordenada z já está determinada por (4).

O modelo Lab é obtido através de uma transformação não linear de XYZ de forma a representar a resposta logarítmica do olho humano (RANGAYYAN; ACHA; SERRANO, 2011). Neste, o brilho da cor é associado a L, a se relaciona a uma matriz no intervalo de verde (negativos) a magenta (positivos) e b a uma matriz no intervalo de azul (valores negativos) a amarelo (positivos).

Outro modelo de cor utiliza as características de matiz ($H - hue$), saturação ($S - saturation$) e intensidade ($V - value$), de forma a procurar desacoplar a cromaticidade (H e S) do brilho. Trata-se de um sistema que utiliza coordenadas cilíndricas, onde dado um plano com um eixo contido neste, H é o ângulo entre este eixo e a projeção do vetor representativo da cor no plano, S é o comprimento desta projeção e V é o comprimento da projeção do vetor representativo da cor em um eixo perpendicular ao plano (Figura 5).

Figura 5 – Espaços de cores HSV



Fonte: autoria própria

Já o modelo YCbCr armazena no canal Y a informação de como os seres humanos percebem o brilho de uma área iluminada a partir de uma soma ponderada dos canais RGB, e as informações de cromaticidade são armazenadas em dois componentes (Cb e Cr) sendo que Cb representa a diferença entre a componente azul e um valor de referência e o Cr representa a diferença entre a componente vermelha e um valor de referência. A conversão do modelo RGB para o modelo YCbCr é dada por (RANGAYYAN; ACHA; SERRANO, 2011):

$$Y = 0,299R + 0,587G + 0,114B \quad (5)$$

$$Cb = 0,172R - 0,339G + 0,511B + 128 \quad (6)$$

$$Cr = 0,511R - 0,428G + 0,083B + 128 \quad (7)$$

1.2.3 Associações de descritores de cores e textura

Textura e cor são usadas para a classificação de objetos e regiões nas mais diversas áreas de conhecimento (ACHA et al., 2013; CHEN et al., 2011; FONGARO; KVAAL, 2013; KADIR et al., 2011; KHALIL; KHAN; RAZZAK, 2011; MOHD SAAD et al., 2011; PRASEITYO et al., 2010).

Estudos com enfoques e proposições metodológicas distintas evidenciam as diferentes facetas da problemática sobre o uso combinado ou não de descritores de cor e textura. A descrição de textura é um problema desafiador em visão computacional e reconhecimento de padrões porque envolve, entre outras, a variação de escala e iluminação.

Khan et al. (2015) propuseram o uso concomitante de múltiplos descritores locais de textura para melhorar a performance comparativamente ao uso de um único descritor na classificação de imagens e concluíram que houve melhora na abordagem combinatória.

Cernadas et al. (2017) reafirmaram que a classificação de texturas (imagens) coloridas, entendidas como aquelas resultantes da associação de todas as texturas relativas a cada canal de cores de um espaço, é importante em visão computacional aplicada à realidade quando as imagens são adquiridas sob diversas condições de iluminação. Neste trabalho, estes autores aplicaram algoritmos de normalização para obterem invariância quanto à iluminação, combinando diferentes espaços de cores e descritores de texturas e comparando uma abordagem integrativa e paralela para a classificação de textura colorida usando os conjuntos de imagens

de testes. Considerando os resultados dos experimentos, a abordagem paralela foi considerada melhor para a classificação de texturas coloridas, em específico com o espaço CIELab com “*Local Binary Patterns*”, uma metodologia caracterizada por, ao invés de se apoiar na imagem completa, gerar descritores em conjunto, denominados dicionário, a partir de padrões de algumas regiões de interesse selecionadas sobre a imagem. Os autores concluem que os descritores tradicionais somente de cor são efetivos apenas em imagens que não tem variação nas condições de iluminação.

Porebski et al. (2013) apontam que a seleção entre diversos descritores em múltiplos espaços de cores oferece vantagens no que se refere a aumentar a taxa de classificação correta e minimização do tempo de aprendizagem e processamento de texturas coloridas de cascas de árvores.

Bianconi et al. (2011), como proposição estrutural e organizacional para pesquisa científica neste tema, propuseram um sistema taxonômico baseado em estruturas matemáticas para classificar descritores de texturas coloridas.

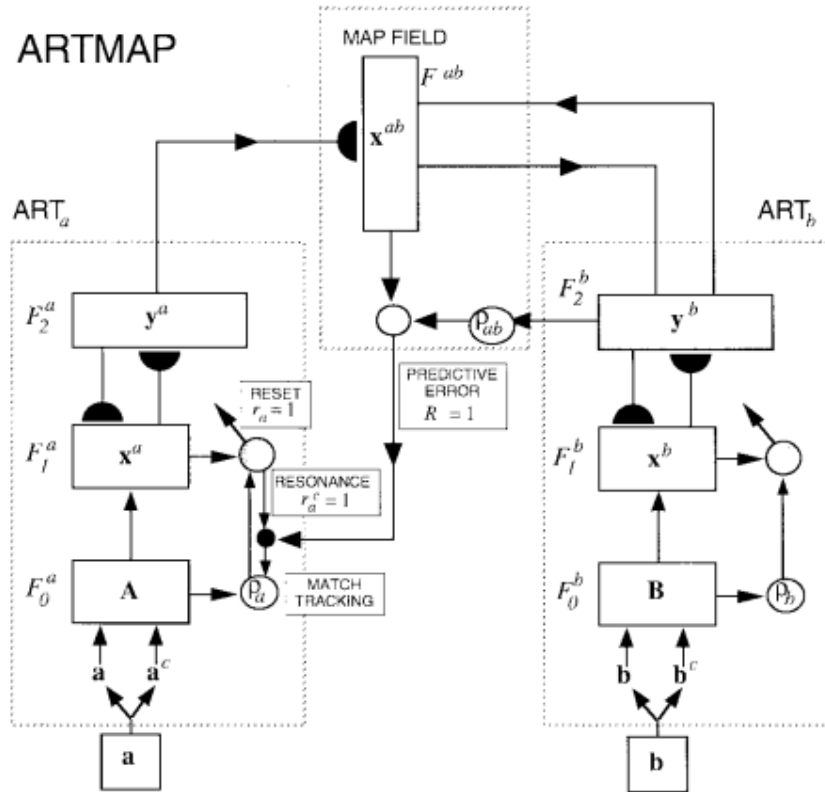
1.3 Sistemas classificadores de imagens com redes Neuro-Fuzzy

Dado um conjunto de descritores de uma imagem, a classificação automática pode ser realizada com o uso de metodologias computacionais que buscam o mimetismo com a cognição humana. Exemplos notórios são as redes neurais artificiais (RNA) que procuram mimetizar o funcionamento do cérebro humano e os sistemas de inferência Fuzzy, que permite a captura de conhecimento de especialistas sobre intervalos em que um fenômeno ocorre, fazendo uma interface entre palavras e funções matemáticas.

Os sistemas Neuro-Fuzzy buscam utilizar a característica da lógica fuzzy de associar valores a termos linguísticos juntamente com a propriedade de auto-organização das redes neurais (IZQUIERDO et al., 2001). A arquitetura fuzzy ARTMAP, cujos diagramas de blocos está representado na figura 6, tem dois módulos Fuzzy ART, ART_a e ART_b, que são conectados por uma rede de aprendizado associativo chamada de campo de mapeamento. Cada um destes módulos contém 2 camadas de processamento chamados F₁ (sinais de entrada) e F₂ (saída de categorias) que são interconectadas por ligações com pesos ajustáveis. O outro elemento desta arquitetura é controlador que usa uma regra de aprendizado mínimo para, simultaneamente, o erro preditivo e maximizar a generalização (Carpenter et al, 1997). A camada F₀, em ambos os módulos, transforma o vetor M_a em 2M_a adicionando a representação em complemento ao

processamento: $A=(a,a^c)$ o que ocorre analogamente no módulo ART_b (Carpenter et al, 1997) (Figura 6).

Figura 6- Diagrama de blocos da RNA Fuzzy ARTMAP



Fonte: Carpenter et al. (1997)

Carpenter et al. (1997) abordaram o problema da classificação de imagens de vegetação presentes em cenas de sensoriamento remoto, considerando que entre as maiores dificuldades encontradas estão aquelas relacionadas à fatores interferentes como: topografia local, refletância de fundo do solo e a vegetação denominada “*undestory vegetation*”. Neste problema a performance de algoritmos e arquiteturas tradicionais de RNA e aprendizado através do algoritmo *back propagation* não foi considerado satisfatório devido ao aprendizado lento e a necessidade de repetidas apresentações dos dados de treinamento. Em oposição, a arquitetura de RNA chamada Fuzzy ARTMAP apresenta aprendizado rápido e incremental (CARPENTER et al., 1996).

A classe de redes ARTMAP provê aprendizado supervisionado incremental de mapas multidimensionais e categorias de reconhecimento à medida que uma entrada vetorial é apresentada em ordem arbitrária. No caso específico das redes neurais artificiais Fuzzy ARTMAP, os descritores são relacionados a uma função de pertinência e a estratégia de votação proporciona minimização do efeito da ordem de apresentação das informações do conjunto de treinamento (PUGH; FAY, 2006). Baseando-se no cálculo de similaridade entre subconjuntos Fuzzy e seleção dinâmica, acumula méritos da lógica Fuzzy e da teoria adaptativa ressoante. A estrutura básica de uma rede inclui dois módulos ARTa e ARTb, que podem ser subdivididos em 2 subsistemas: atenção e orientação. A atenção gerencia eventos dentro do intervalo previsto, enquanto a orientação gerencia eventos inesperados permitindo a criação de novas representações que acomodam estes eventos. A vantagem mais importante das redes ARTMAP, é, provavelmente, o aprendizado baseado na similaridade (pares) e não no erro como em abordagens tradicionais. Novas categorias podem ser aprendidas sem afetar outras já existentes. Além disto, são auto organizáveis e não exigem definições prévias sobre a rede (PUGH; FAY, 2006).

Charlampidis et al. (1999) relataram que uma RNA Fuzzy ARTMAP foi usada para avaliar a relação entre dimensão fractal, ruído branco e a performance de classificadores de texturas de imagens em tons de cinza. Estes autores consideraram como principais características deste classificador a capacidade de mapear as entradas (vetores de dimensão M) em vetores de pesos chamados “*templates*” de modo que todas as entradas fossem etiquetadas, podendo mais de uma entrada estar armazenada sob a mesma etiqueta. Além disto, descreveram o *template* como uma forma comprimida da entrada e a sua interpretação geométrica como uma hipercaixa no espaço dimensional M_a . Na fase de teste, os *templates* são inicializados no valor que tinham na fase final de treinamento, uma entrada de teste será relacionada a um *template* e este a uma classificação específica (etiquetagem). Segundo os autores, a RNA Fuzzy ARTMAP converge com poucas interações e o processo de treinamento consome menos tempo que outras redes neurais convencionais. Na fase de teste consome-se menos tempo em comparação com o classificador KNN (“*k-nearest neighbourhood*”) por utilizar uma versão comprimida da informação de entrada original. Os autores testaram 4 algoritmos quanto a performance e concluíram que a RNA Fuzzy ARTMAP foi superior a outros classificadores.

2 JUSTIFICATIVA

2.1 Classificação automática de espécies arbóreas

A tarefa de identificação de espécies arbóreas é de grande complexidade. Realizada pelo ser humano é demorada e necessita de muito treinamento devido à grande variedade de espécies conforme descrito por Fiel e Sablatning (2011). Contudo, o estudo de métodos para a identificação automática de espécies ainda representa um campo recente e com significativo potencial de crescimento.

Nesta linha, destacam-se os trabalhos de Machado et al. (2013) e Rossato et al. (2011), que buscaram realizar a identificação de espécies arbóreas com base nas imagens de folhas. Com análises de fractais sobre a textura, Machado et al. (2013) alcançaram resultados considerados promissores com acerto de quase 50% na identificação de árvores da Europa, taxa destacada pelos autores como muito superior à de trabalhos relacionados (FAPESP, 2012). Ainda com base na análise de imagens de folhas, porém digitalizadas com uso de scanner, Rossato et al. (2011) obtiveram resultados com taxa de acerto de 100% no reconhecimento de espécies da família Melastomaceae.

Em geral, a identificação das espécies baseadas na análise de imagens de folhas é considerada um avanço em relação às técnicas morfológicas convencionais que se limitam a determinadas épocas do ano, pois são comumente realizadas a partir de flores e frutos. Contudo, no caso de espécies caducifólias, que perdem as folhas em épocas secas e frias nas quais as árvores também não florescem nem frutificam, as análises baseadas em imagens de folhas também são comprometidas. A limitação condicionada à presença de folhas, também restringe a aplicação destas técnicas nos casos de árvores que precisam ser identificados quando já não se dispõe destas estruturas morfológicas, tal como após serem cortadas.

Para se traspor esta limitação de classificação de árvores que não tenham as folhas, frutos ou flores presentes, pode-se desenvolver métodos que analisem os troncos das árvores, mais especificamente a textura e a cor.

No caso da análise de troncos de árvores, Sulc e Matas (2013) discutem que existem trabalhos que propõem métodos e apresentam os resultados usando bancos de imagens não disponíveis publicamente (CHI et al., 2003; SONG et al., 2004; WAN et al., 2004; HUANG et al., 2006), dificultando a avaliação da qualidade dos resultados bem como uma comparação de desempenho. No mesmo artigo, os autores usam para a análise do método proposto o banco de imagens de troncos de árvores da Österreichische Bundesforste AG introduzido por Fiel e Sablatnig (2011) que, no entanto, é composto por árvores comuns, mas exclusivas do território austríaco.

Ao abordarem a classificação de imagens de cascas de árvores, Porebski et al. (2013) argumentam que ao invés de se escolher parâmetros somente de cor ou textura, pode-se fazer uma seleção de diferentes descritores obtidos de várias formas para se criar o vetor de características e, assim, utilizar o que há de melhor em cada um para se maximizar o processo de classificação. Com esta abordagem, os autores obtiveram parâmetros de textura a partir das matrizes de co-ocorrência (HARALICK et al., 1973) de imagens em diversos espaços de cor e encontram aqueles mais relevantes usando o algoritmo “*Sequential Forward Selection - SFS*” (FUKUNAGA, 1990; PUDIL; NOVOVICOVA; KITTLER, 1994; SÁEZ et al., 2013).

Comparando a abordagem tradicional com a implementada, os autores concluem que as taxas de acerto nas classificações aumentam quando se utiliza a última. No entanto, deve-se destacar que apesar de Porebski et al. (2013) utilizarem diversos espaços para a representação de cor, ao caracterizarem as texturas presentes, usaram apenas a matriz de co-ocorrência. Os mesmos autores argumentam ainda que para a análise da relevância dos métodos de classificação de texturas coloridas é importante que o conjunto de imagens utilizados sejam dividido em subconjuntos de treinamento e validação da mesma textura oriundas de diferentes objetos originais e não de subdivisões de imagens de um mesmo objeto, garantindo, assim, a menor correlação entre as imagens.

Em outro trabalho, Porebski et al. (2014) discutem as limitações no uso de bancos de imagens para a avaliação de desempenho de métodos de análise de textura e cor, como o VisTex (PICARD et al., 2015) e OuTex (OJALA et al., 2002) e propõem o uso do banco BARKTEX (LAKMANN, 1998) que é composto de imagens divididas em 6 classes de troncos de árvores com 68 imagens por classe.

Utilizando-se a proposta de construção de um vetor de características a partir da escolha de parâmetros obtidos de vários métodos, uma abordagem que pode levar a uma melhora no desempenho do processo de classificação é a utilização de outras medidas da textura presente, como a estatística de primeira ordem para imagens de cascas de árvores (WAN et al., 2004), a análise no domínio de Fourier (MARTINS; SIMÕES; PRADO, 2007), de forma a se aumentar o conjunto de parâmetros candidatos.

2.2. Classificação automática de imagens aéreas

A classificação do uso e ocupação do solo através de imagens aéreas é uma área bastante ativa de pesquisa científica (CHENG; HAN, LU, 2017).

Segundo Xia et al. (2017), a atribuição de uma categoria semântica a uma imagem de alta resolução não tem o estado da arte claramente definido e propõem avanços nesta direção através da comparação de métodos tradicionais com aqueles chamados de “*deep learning*”. No mesmo artigo, os autores salientam que uma das dificuldades principais da abordagem via descritores “*hand-crafted*” é a falta de flexibilidade e adaptabilidade a diferentes cenas.

Em imagens aéreas de alta resolução a definição das estruturas é maior, o que aumenta o desafio da classificação. Objetos no mesmo tipo de cena podem aparecer em diversos tamanhos e orientação devido à alta complexidade da superfície terrestre. A aparência das cenas em questão é afetada por diversos fatores como altitude e direção de voo, além do ângulo de elevação solar que afeta a iluminação. Na classificação de imagens aéreas, considera-se que pode ocorrer de as classes serem muito próximas, o que por si só é desafiador (XIA et al., 2017).

Em aplicações reais há a necessidade do uso de vários descritores como textura, espectro e cor que, individualmente, descrevem apenas parcialmente as complexidades da cena o que implica na necessidade do uso agrupado de vários destes (CHENG; HAN; LU, 2017), sendo que a forma de se selecionar o melhor subconjunto é um campo ativo de pesquisa científica.

A classificação baseada em textura, espectro e estrutura é considerada de baixo nível no que se refere aos descritores visuais e permite performance satisfatória apenas quando há homogeneidade estrutural e em arranjos espaciais. Através da representação da extração de atributos visuais locais e representação estatística de ordens elevadas objetiva-se uma representação holística da cena na chamada abordagem de nível médio (XIA et al., 2017). Finalmente, denomina-se de nível alto as metodologias baseadas em “*deep learning*” que propõem múltiplos estágios de aprendizado adaptativo das qualidades globais das imagens conseguindo comparativamente melhores performance que os métodos anteriores através da extração de descritores mais abstratos e discriminativos de forma automática ou independente da interferência humana (XIA et al., 2017). Ressalva-se, no entanto, que para fins deste trabalho, em que as aplicações visam possibilitar o estudo do uso dos distintos tipos de descritores, as abordagens de nível baixo e médio são adequadas, destacando-se ainda que as de nível alto requerem uma quantidade expressiva de imagens, cuja disponibilidade não se verifica em muitas situações e, em especial, para cascas de árvores além de o processamento envolver um alto custo computacional.

3 OBJETIVOS

3.1 Objetivo geral

Este trabalho tem como objetivo geral o estudo e a identificação de descritores de cor e textura obtidos de diferentes representações e métodos para a classificação automática de imagens no contexto das ciências ambientais.

3.1 Objetivos específicos

- 1) Contribuir para a inserção mais ampla do processamento automático de imagens e de técnicas de inteligência artificial nas ciências ambientais;
- 2) Identificar descritores para a classificação automática de espécies arbóreas e de imagens aéreas da superfície terrestre;
- 3) Avaliar um processo de seleção automática de descritores de cor e textura para a representação de imagens;
- 4) Testar a performance da RNA Fuzzy ARTMAP como classificador na área ambiental;
- 5) Contextualizar e discutir esta investigação no contexto delimitado pela informática aplicada ao meio ambiente, notoriamente, no suporte e automação de subsistemas para diagnósticos ambientais;
- 6) Contribuir para a discussão do uso de descritores de textura e/ou cor no processo de análise de imagens.

4 MATERIAL E MÉTODOS

Para se alcançar os objetivos deste trabalho foram selecionados descritores candidatos de um conjunto de imagens para as duas aplicações ambientais (classificação de espécies arbóreas e da cobertura terrestre). A partir destes descritores, foi feita a seleção de um vetor de características com aqueles que apresentaram os melhores desempenhos no processo de classificação. A seguir, são detalhados os materiais e métodos utilizados.

4.1 Conjuntos de Imagens

4.1.1 Subconjunto Barktex - SB

O conjunto de imagens selecionado para o estudo de classificação de texturas coloridas de cascas de árvores foi obtido a partir do BARKTEX que possui 408 imagens (Tabela 1) disponibilizadas em 128 x 192 ou, alternativamente, 256 x 384 pixels, divididas igualmente em 6 classes relacionadas a imagens de cascas de árvores europeias, adquiridas sob condições naturais de iluminação e que é utilizado como benchmark.

Tabela 1 – Quantidades de imagens de casca de arvores e respectivos nomes científicos que constituem o BARKTEX

Quantidade de imagens	Nome científico
68	<i>Betula pendula</i>
68	<i>Fagus silvatica</i>
68	<i>Picea abies</i>
68	<i>Pinus silvestris</i>
68	<i>Quercus robur</i>
68	<i>Robinia pseudacia</i>

Utilizou-se um subconjunto de imagens da coleção BARKTEX (128 x 192 pixels), denominado neste trabalho de SB, de forma a se eliminar a presença de líquens, sombras de pessoas e outras perturbações visuais que podem ser facilmente evitadas em um processo de aquisição de imagens para uma aplicação real. Além disto, as imagens selecionadas foram recortadas de maneira a permanecer apenas a casca da árvore. A Tabela 2 apresenta os códigos originais BARKTEX das imagens selecionadas. Assim, o SB é formado por 48 imagens divididas


igualmente em 6 classes, (*Betula*, *Fagus*, *Quercus*, *Robinia*, *Pinus*, *Picea*). A Figura 7 mostra exemplos de imagens de cada categoria.

Tabela 2 – Códigos BARKTEX das imagens que compõem o subconjunto usado no estudo de classificação.

<i>Betula</i> <i>pendula</i>	<i>Quercus</i> <i>robur</i>	<i>Picea</i> <i>abies</i>	<i>Fagus</i> <i>silvatica</i>	<i>Robinia</i> <i>pseudacacia</i>	<i>Pinus</i> <i>silvestres</i>
ko04_043	ko05_087	ko06_034	ko04_081	ko06_036	ko04_001
ko04_045	ko05_099	ko06_042	ko04_089	ko06_048	ko04_006
ko04_048	ko06_001	ko06_053	ko04_096	ko06_083	ko04_011
ko04_065	ko06_008	ko06_060	ko05_004	ko06_087	ko04_016
ko04_046	ko06_011	ko06_064	ko05_010	ko07_001	ko04_020
ko04_073	ko06_015	ko06_067	ko05_014	ko07_004	ko04_022
ko04_076	ko06_019	ko06_077	ko05_018	ko07_090	ko04_030
ko07_024	ko06_022	ko06_080	ko05_022	ko07_095	ko04_034

Fonte: autoria própria

Figura 7 - Mosaico com uma imagem de cada categoria do SB.



1-

Betula pendula, 2- *Quercus robur*, 3 - *Picea abies*, 4 - *Fagus silvatica*, 5 - *Robinia pseudacacia*, 6 - *Pinus silvestres*

Fonte: autoria própria

4.1.2 Banco de imagens de usos e ocupação do solo UCMERCED

A coleção de imagens UCMERCED é frequentemente usada em estudos de classificação de imagens aéreas de alta resolução como benchmark uma vez que a variedade de classes e “*overlapping*” relacionadas à diferenciação de estruturas, torna desafiadora a tarefa de classificação automática (ZOU et al., 2016).

As imagens desta coleção foram adquiridas sob iluminação não controlada diretamente do local (“*ground truth*”) e divididas igualmente em 21 classes, que são originárias da coleção de imagens aéreas denominada “USGS National Map Urban Area Imagery collection”, apresentando tamanho de 256 x 256 pixels e resolução espacial 0.30 metros por pixel (YANG; NEWSAM, 2010). A Figura 8 apresenta exemplos de imagens das 21 categorias da coleção UCMERCED.

Devido à natureza e a resolução espacial, considera-se que o UCMERCED compartilha muitos descritores de baixo nível com imagens ópticas gerais, o que a torna a escolha adequada para o refinamento do desempenho de redes neurais convolucionais (CASTELUCCIO et al., 2015) e apresenta como vantagem adicional uma escala espacial apropriada para estudos de classificação (ZOU et al., 2016).

Neste trabalho foi utilizada a coleção completa de imagens do UC MERCED constituída por 2100 imagens, denominada UC.

Figura 8 - Mosaico com amostra de imagens das 21 categorias ordenadas da 1ª até 21ª



1 - agricultura, 2 - aviões, 3 - diamante (baseball), 4 - praia, 5 - construções (“buildings”), 6 - chaparral, 7 - residencial denso, 8 - floresta 9 - via expressa (freeway), 10 - campo de golfe, 11-porto, 12 - intersecção, 13 - residencial médio, 14 - estacionamento de trailer, 15 - viaduto, 16 - estacionamento, 17 - rio, 18 –pista de pouso (“runway”), 19 - residencial esparsa, 20 - tanques, 21 - quadras de tênis

Fonte: Yang; Newsam (2010)

4.2 Descritores candidatos

Foram obtidos descritores da versão em tons de cinza da imagem, que trazem a informação da textura presente, e dos canais de cor utilizando-se os seguintes modelos: XYZ, HSV, RGB, YCbCr, e Lab. Para isto, utilizou-se três abordagens: estatística dos valores dos pixels na imagem em tons de cinza e nos canais de cor, medidas estatísticas das matrizes de co-

ocorrência dos pixels e análise espectral, sendo as duas últimas obtidas a partir das versões em tons de cinza.

4.2.1 Descritores estatísticos de primeira ordem em tons de cinza (PEPOTC)

Dada uma imagem $p(i,j,k)$ com intensidades no intervalo $[1, L]$, onde $k=1,2,3$ se referem a cada um dos canais de cor e $k=4$ a versão em tons de cinza, pode-se calcular o histograma h_k de cada canal (cor e tons de cinza) por:

$$h_k(l) = \frac{n_l}{n_k} \quad (8)$$

onde n_l se refere ao número de valores do canal k iguais a l e n o número total de pixels da imagem no canal k .

A partir dos histogramas da imagem, pode-se obter, para cada canal k , a média aritmética (m_k), o desvio padrão (μ_k), a suavidade (S_k), o terceiro momento (T_k), a uniformidade (U_k) e a entropia (ET_k) por (GONZALEZ; WOODS, 2006):

$$m_k = \sum_{l=1}^L z_l h_k(z_l) \quad (9)$$

$$\mu_k = \sqrt{\sum_{l=1}^L z_l^2 h_k(z_l)} \quad (10)$$

$$S_k = 1 \frac{1}{1 + \mu_k^2} \quad (11)$$

$$T_k = \sum_{l=1}^L z_l^3 h_k(z_l) \quad (12)$$

$$U_k = \sum_{l=1}^L h_k(z_l)^2 \quad (13)$$

$$ET_k = \sum_{l=0}^L h_k(z_l) \log_2(h_k(z_l) + \delta) \quad (14)$$

onde z_l é um dos possíveis valores de intensidade de cada canal e δ é um número pequeno usado para se evitar o logaritmo de zero.

4.2.2 Descritores candidatos de Haralick

O subconjunto dos descritores candidatos de Haralick foi obtido a partir das matrizes de co-ocorrência $C(r,s,\theta)$ que trazem a informação de quantas vezes um valor r aparece a uma dada distância d e um ângulo θ de um valor s na versão em tons de cinza da imagem (HARALICK et al., 1973).

Os descritores candidatos de Haralick utilizados foram contraste ($H_{1,\theta}$), correlação ($H_{2,\theta}$), energia ($H_{3,\theta}$) e homogeneidade ($H_{4,\theta}$), dados por (GONZALEZ; WOODS; EDDINS, 2009):

$$H_{1,\theta} = \sum_{r=0}^{L-1} \sum_{s=0}^{L-1} |r - s|^2 C(r, s, \theta) \quad (15)$$

$$H_{2,\theta} = \sum_{r=0}^{L-1} \sum_{s=0}^{L-1} \frac{(r - \mu_r) \cdot (s - \mu_s)}{\sigma_r \cdot \sigma_s} C(r, s, \theta) \quad (16)$$

$$H_{3,\theta} = \sum_{r=0}^{L-1} \sum_{s=0}^{L-1} C(r, s, \theta)^2 \quad (17)$$

$$H_{4,\theta} = \sum_{r=0}^{L-1} \sum_{s=0}^{L-1} \frac{C(r, s, \theta)}{1 + |r - s|} \quad (18)$$

onde μ_r e σ_r são respectivamente a média e desvio padrão dos valores nas linhas e μ_s e σ_s nas colunas.

Neste trabalho, utilizou-se $d=1$ e $\theta= 0, 45^\circ, 90^\circ$ e 135° .

4.2.3 Descritores espectrais

Os descritores de Fourier F_a (MARTINS; SIMÕES; PRADO, 2007) são obtidos a partir da soma da distribuição angular do espectro de potência dividido em 9 intervalos, de forma que:

$$F_a = \sum_{\theta=\theta_a}^{\theta_a+20^\circ} | (p(i, j, 4)) | \quad (19)$$

onde p é a Transformada de Fourier da versão em tons de cinza da imagem, θ é o ângulo no domínio de frequência, $a = 1, 2, 3, \dots, 9$ e $\theta_a = 0^\circ, 20^\circ, 40^\circ, \dots, 160^\circ$.

4.3 Vetor de características

O vetor de características (vide analogia em Tabela 3) foi construído com os diversos os valores dos descritores calculados e objetiva caracterizar uma imagem digital.

Os descritores enumerados e grifados em cinza na Tabela 3 foram aqueles calculados a partir de informações exclusivamente da imagem em níveis de cinza, obtidas através da rotina `rgb2gray` do MATLAB[®]. O grupo formado pelos subgrupos de descritores de cada abordagem aplicada nas versões em tons de cinza das imagens, ou seja, sem utilizar qualquer informação de cor, foi denominado GNC. Os demais utilizaram à informação de um canal específico do multi espaços de cores, formando subgrupos de descritores para cada espaço de cor, que, juntos, denominou-se GC.

Tabela 3 - Representação do vetor de características com posição, descrição e agrupamentos a partir de canais de cor (GC) ou grupos de descritores a partir de níveis de cinza (GNC) que estão com fundo cinza.

Descritores	Subgrupo	Descrição pág inicial / continuação da mesma demais páginas
1	PEPOTC (GNC)	Média
2		Desvio padrão
3		Suavidade
4		Terceiro momento
5		Uniformidade
6		Entropia
7	XYZ (GC)	Entropia Z
8		Entropia Y
9	HSV (GC)	Média H
10		Média S
11		Média V
12	RGB (GC)	Média R
13		Média G
14		Média B
15		Desvio R
16		Desvio G
17		Desvio B
18		Suavidade R
19		Suavidade G
20		Suavidade B
21		Terceiro momento R
22		Terceiro momento G
23		Terceiro momento B
24		Uniformidade R
25		Uniformidade G
26		Uniformidade B
27		Entropia R
28		Entropia G
29		Entropia B
30	YCbCr (GC)	Média y
31		Média Cb
32		Média Cr
33	XYZ (GC)	Média X
34		Média Y
35		Média Z
36	Haralick Níveis de cinza (GNC)	Contraste 0°
37		Correlação 0°
38		Energia 0°

Descritores	Subgrupo	Descrição pág inicial / continuação da mesma demais páginas
39		Homegeneidade 0°
40		Contraste 45°
41		Correlação 45°
42		Energia 45°
43		Homegeneidade 45°
44		Contraste 90°
45		Correlação 90°
46		Energia 90°
47		Homegeneidade 90°
48		Contraste 135°
49		Correlação 135°
50		Energia 135°
51		Homegeneidade 135°
52	Lab (GC)	Média_A
53		Média_B
54		Desvio_A
55		Desvio_B
56		Suavidade_A
57		Suavidade_B
58		Terceiro momento_A
59		Terceiro momento_B
60		Uniformidade_A
61		Uniformidade_B
62		Entropia_A
63	Entropia_B	
64	XYZ (GC)	Desvio_Y
65		Desvio_Z
66		Suavidade_Y
67		Suavidade_Z
68	Descritores Fourier (GNC)	0 -20°
69		20°- 40°
70		40°-60°
71		60°-80°
72		80°-100°
73		100°-120°
74		120°-140°
75		140°-160°
76		160°-180°

4.4 Seleção dos descritores mínimos

A partir do vetor de características, é feita a seleção dos descritores mínimos referentes às duas aplicações: classificação de árvores pela textura da casca e uso e ocupação de solo a partir de imagens de alta resolução.

Para isto, ambas as coleções de imagens em cada uma de suas classes foram divididas aleatoriamente na proporção quantitativa de 50% para treinamento e 50% para teste, baseando-se na metodologia denominada “*Holdout*” (POREBSKI et al., 2010). Neste trabalho, denomina-se como experimento, cada execução do algoritmo de classificação automática das imagens após a divisão destas em treinamento e teste, tanto para SB bem como para UC.

Foram realizados 12 experimentos para cada subgrupo, totalizando 24 execuções distintas da rotina de classificação, o que está de acordo com XIA et al. (2017) no que se refere a um mínimo de 10 repetições adotado para se aumentar a confiabilidade dos resultados.

Para o computo dos descritores aplicou-se uma janela móvel de amostragem das imagens de 50 x 50 pixels para as imagens de cascas de árvores, e 150 x 150 pixels no que se refere às de uso e ocupação do solo. Ao final, utilizou-se as médias dos valores obtidos em cada janela de amostragem.

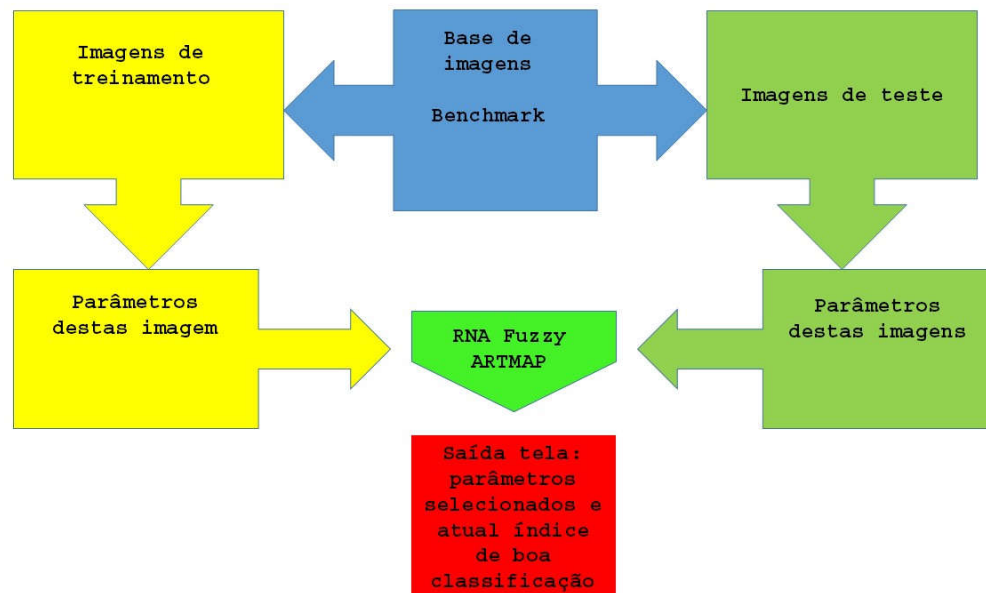
4.5 Classificador e pseudocódigo

Na tarefa de classificação das imagens utilizou-se o algoritmo: “*Sequential Forward Selection*” (SFS) (FUKUNAGA, 1990; PUDIL; NOVOVICOVA; KITTLER, 1994) que faz a adição de um descritor por vez, a um conjunto inicialmente vazio para a classificação das imagens e como decorrência é denominada como uma estratégia de baixo para cima. A adição visa minimizar o erro de classificação e a escolha é baseada somente na performance resultante da inclusão dos descritores não empregados até cada estágio da classificação em questão após cada etapa do ordenamento. Esta implementação foi associada a um classificador baseado em RNA Fuzzy-ARTMAP(CARPENTER et al., 1992) parametrizada com: $\beta = 1$, $\alpha = 0.001$, $\rho = 1$. Os códigos básicos de programação utilizados para se implementar a rede neural foram inicialmente desenvolvidos para aplicações em diagnóstico médico (SÁEZ, 2013).

4.5.1 Pseudocódigo

A figura 9 ilustra a rotina implementada iterativamente para 12 execuções

Figura 9- Diagrama esquemático de rotina implementada iterativamente em software



- 1) De Experimento = 1 a 12 faça, senão 15)
- 2) Divida aleatoriamente em 50% treino e 50% validação as imagens de todas as categorias da base de imagens benchmark
- 3) Calcule os 76 descritores e componha o vetor de características de treino VT e validação VV usando as respectivas imagens definidas em 2)
- 4) Seleção:= vazio
- 5) Enquanto tamanho de conjunto Seleção não for igual a 76 , faça:
- 6) Descritores disponíveis = descritores total – Seleção
- 7) Enquanto todos os descritores disponíveis não foram usados no treino e validação faça:
- 8) Treine RNA Fuzzy ARTMAP com Seleção + 1 parâmetro inédito daqueles disponíveis de VT
- 9) Valide Resultados com Seleção + parâmetro disponível
- 10) Armazena acurácia total obtida e parâmetro 8) usado
- 11) Se todos os descritores disponíveis usados: 12), senão 7)
- 12) Armazene e imprima melhor acurácia da classificação e o respectivo descritores disponível usado para tal
- 13) Seleção:=Seleção+ parâmetro que gerou melhor acurácia %% At Seleção

- 14) Verifica o tamanho de seleção: se 76 então $E=E+1$ e vai a 1), senão volta a 5)
 15) Fim **4.6 Análise de resultados**

Foi considerada a acurácia percentual da classificação $IBC_{n,E}$ avaliada em cada experimento, considerando todas as categorias (interclasses) e todas as execuções do algoritmo de classificação, tal que:

$$IBC_{n,E} = \left(\frac{A}{B} \right) \quad (20)$$

onde A é o número de imagens corretamente classificadas na n -ésima seleção de descritores pelo algoritmo de classificação no experimento E e B é o número total de tentativas de classificações e que é igual ao número de imagens usadas para teste usando n descritores no experimento E .

Para fins de obtenção de grandezas em comum para todas as execuções, visando a apresentação gráfica, normalizou-se o $IBC_{n,E}$ pelo máximo $IBC_{n,E}$ em cada experimento, gerando-se o $IBCN_{n,E}$ de um experimento E , após n seleções de descritores em função da dinâmica da inserção destes. Ressalta-se que o número mínimo de descritores que geraram o máximo $IBC_{n,E}$, bem como o próprio, são específicos de E e das imagens em questão.

Para fins de normalização do número de descritores selecionados em relação aos necessários para que se obtenha a máxima acurácia de classificação em cada experimento, definiu-se o $DNM_{n,E}$ dado por:

$$DNM_{n,E} = n/n_{max} \quad (21)$$

onde n é a quantidade de descritores selecionados pelo SFS no experimento E e n_{max} é a quantidade de descritores necessário para obtenção do máximo $IBC_{n,E}$. Desta forma, $DNM_{n,E}=1$ indica que o experimento atingiu a máxima acurácia de classificação.

Associou-se um incremento unitário (IU) positivo ou negativo para o uso de descritores, baseados em imagens em níveis de cinza (GNC), ou em canais de cores (GC), respectivamente, para fins de visualização da dinâmica qualitativa do SFS na classificação. O acúmulo deste incremento (AIU) em um eixo vertical de um gráfico de dispersão foi aplicado para ilustrar a dinâmica e o histórico de escolhas dentre os 2 grupos o GC ou GNC à medida que incrementou-se DNM até o valor máximo de 100%, indicando que o máximo $IBC_{n,E}$ fora atingido.

Desta maneira iniciou-se o AIU em 0 e $IU > 0$ indicando a inserção de descritores positivos (relacionados a níveis de cinza), e $IU < 0$ sinalizando inserção de descritores relativos a um canal de cor. O acumulo de IU , ou seja, AIU relaciona-se com o histórico qualitativo da seleção dos descritores.

Foram construídos gráficos de barras para cada experimento, sendo estas subdivididas com hachuras distintas para representar a razão GNC/GC cujo valor pode ser aferido em eixo vertical secundário.

Os índices n_{max} , n , foram omitidos quando foram feitas referência a resultados de múltiplos experimentos. A sigla IBC, para o uso de cada base de imagens, deve ser entendida como o resultado da média de 12 experimentos, salvo detalhamento específico apresentado.

Como plataforma computacional utilizou-se um PC equipado com processador: Intel® Core™ i7-4510U CPU em 2.00 GHz, Memória RAM de 8.00 GB, sistema operacional de 64 bits, processador com base em x64. Os programas foram desenvolvidos e executados no MATLAB® (2017a).

5 RESULTADOS

5.1 Experimentos com texturas coloridas de cascas de árvores – SB

A tabela 4 apresenta os descritores selecionados em cada experimento com as imagens SB para que se atingisse o máximo IBC.


Tabela 4 – Resultados dos experimentos com SB. A primeira coluna traz o número do experimento em ordem de execução, a segunda e terceira colunas apresentam, respectivamente, a sequência e o número de descritores selecionados para se obter o máximo IBC e a última coluna traz o máximo valor de IBC obtido em cada experimento

Experimento	Sequência dos descritores selecionados	Número de descritores selecionados	IBC do teste
1	73-58-70-50-60-76-46-74-69-47-62-75-56-53-68-54-66-52-43-63-64-51-67-42-39-41	26	87,5
2	26-58-38-62-60-56-53-52-7-5-12-67-45-47-51-29	16	95,8
3	17-45-51-56-76-74-10-65-63-50-58-59-62-37	14	95,8
4	38-45-9-49-62-61-47-53	8	91,7
5	46-55-49-71-53-63-23-61-57-47-28	11	91,7
6	16-53-4-41-42-39-65-50	8	91,7
7	26-39-52-72-45-62-58-50-56-46-60-15-71-54-18-63-59-69-68-61-76-47-43	23	87,5
8	6-17-45-12-53-41-62-60-48-37-16	11	95,8
9	2-48-18-28-38-19-6-75-74-29-16-5-66-47-44-27-26-76-20-45-72	21	87,5
10	50-26-58-20-29-73-76-60-17	9	91,7
11	46-3-51-24-188-50-58-63-47-60-42-43-49-61-76-53-14-54	19	75,0
12	50-45-58-67-38-59-37-62-60-65-63-56-55-54-76-40	16	100,0

Fonte: autoria própria

Qualitativamente, a máxima acurácia (IBC máximo) foi obtida sem a necessidade do uso de todos os 76 descritores. A Figura 10 apresenta um comportamento típico de um experimento deste subgrupo.

Figura10 - Exemplo típico da relação de IBC com o número de descritores selecionados pelo SFS



Fonte: autoria própria

Como pode-se notar da Figura 8, no processo de agregação de descritores, alguns não contribuem para aumentar o IBC e outros podem até diminuir o índice. Este comportamento foi encontrado em todos os experimentos tanto para SB como para UC.


Considerando-se apenas aqueles descritores que aumentam o IBC, criou-se um subconjunto, denominado Contribuintes, do total de descritores mínimos selecionados para se obter o máximo de IBC, identificado por Total. A tabela 5 e a Figura 11 apresentam os números totais de descritores selecionados (Total) para cada subgrupo de descritores (ver Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de SB.

Tabela 5 – Número total de descritores selecionados (Total) para cada grupo de descritores (Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de SB

	Total	Contribuintes
Níveis de cinza	7	4
XYZ	11	0
HSV	2	2
RGB	28	14
YCbCr	0	0
Haralick	55	28
Lab	56	15
Fourier	23	6

Fonte: autoria própria

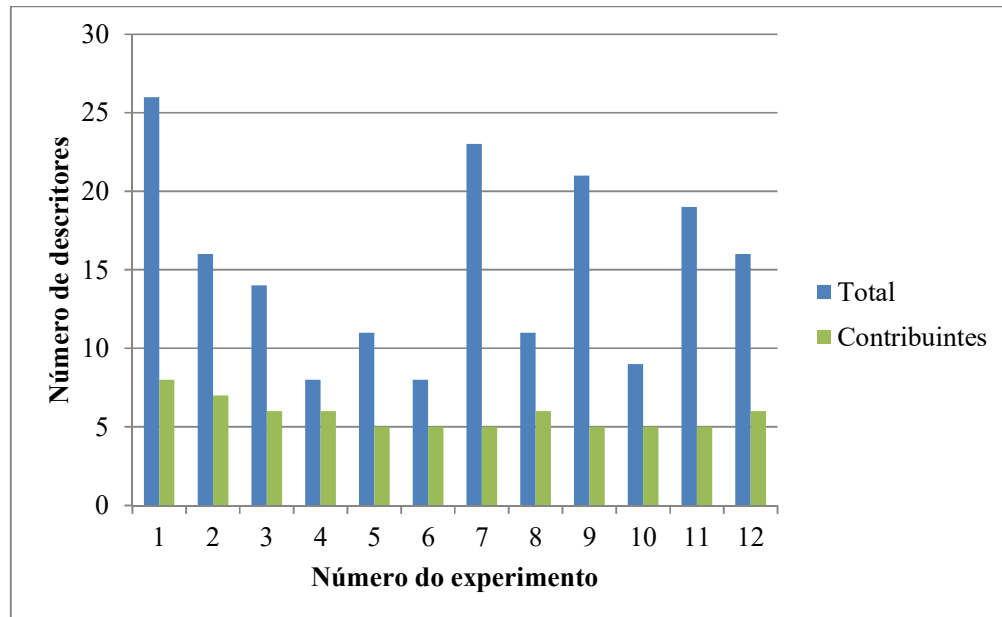
Figura 11 - Número total de descritores selecionados (Total) para cada subgrupo de descritores (Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de SB.



Fonte: autoria própria

A Figura 12 traz a informação do número total mínimo de descritores selecionado para se atingir o máximo IBC (Total) e o número de descritores que aumentam o IBC (Contribuintes) para cada experimento de SB.


Figura 12 - Número total mínimo de descritores selecionado para se atingir o máximo IBC (Total) e o número de descritores que aumentam o IBC (Contribuintes) para cada experimento de SB



Fonte: autoria própria

O IBC máximo médio considerando-se todos os experimentos foi de 90,97% e o DNM médio de 22%, indicando que a máxima classificação foi obtida pela seleção sequencial de um conjunto de aproximadamente 17 descritores, pertencentes ao GC ou GCN, com um valor máximo de 37 e mínimo de 8 descritores (Figura 13).


Figura 13 – IBC versus n_{max} relacionados a E=12 experimentos de classificação de imagens.



Fonte: autoria própria

A Figura 14 apresenta o número de descritores n_{max} para cada experimento de classificação com o SB.

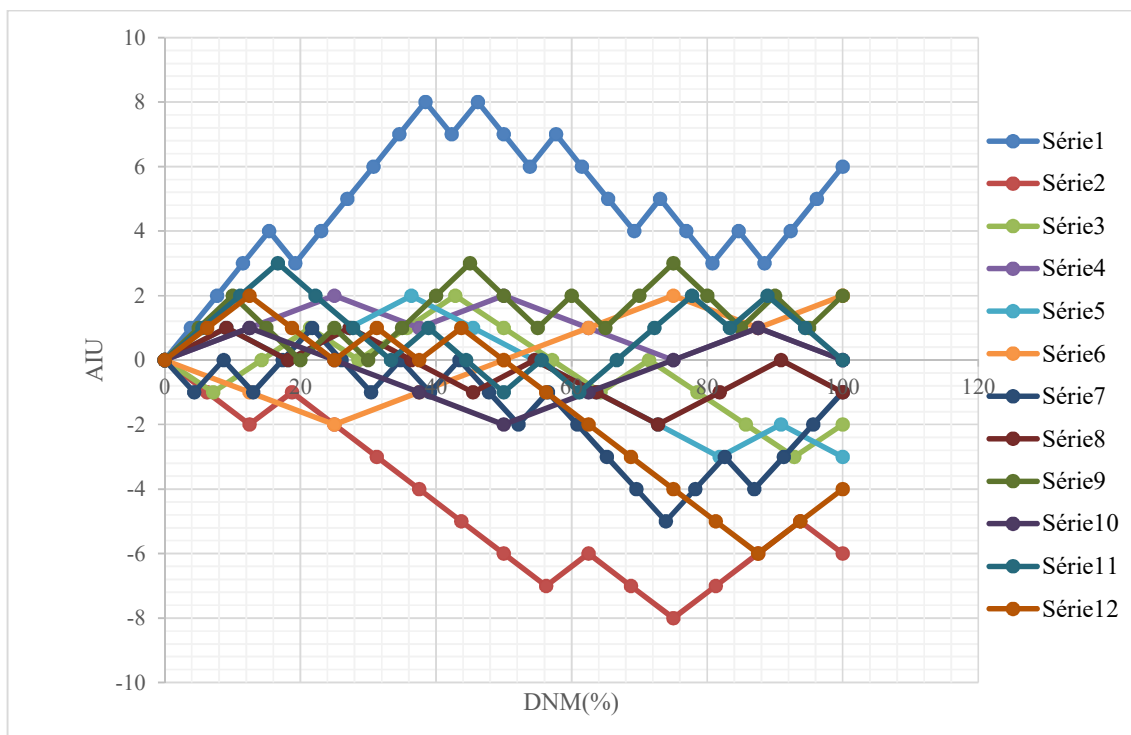
Figura 14 - Número de descritores n_{max} e a razão GNC/GC entre a quantidade de descritores: barras em hachura escura (GNC), e em hachura clara (GC) para cada experimento. A razão é observável na projeção dos marcadores circulares à direita em preto no eixo vertical secundário.



Fonte: autoria própria

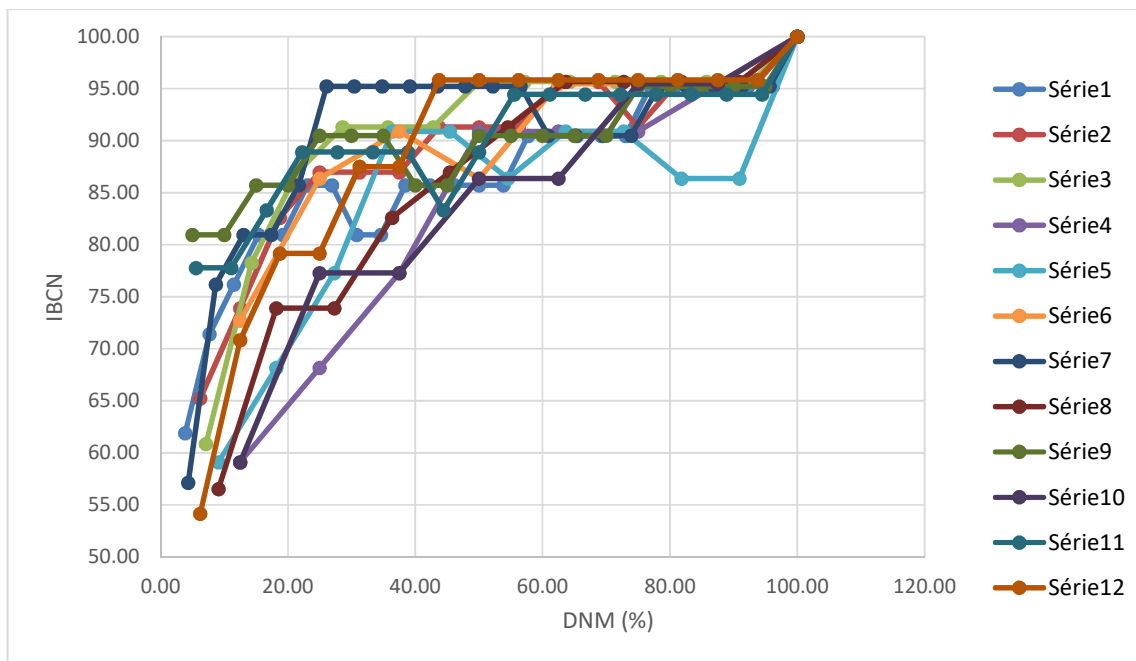
A Figura 15 apresenta a dinâmica qualitativa da seleção feita pelo SFS, mostrada até o IBCN máximo (100%) obtido em cada experimento executado.

Figura 15 - Acumulo de incrementos unitários (AIU) indica a dinâmica qualitativa da seleção de descritores GC ($IU < 0$) ou GNC ($IU > 0$) de cada um dos 12 experimentos e respectivas séries de dados.



A figura 16 apresenta a dinâmica do IBCN da classificação em relação ao DMN relativos a n=12 execuções do algoritmo SFS.

Figura 16- Dinâmica do IBCN da classificação em relação ao DMN para os 12 experimentos



Fonte: autoria própria

5.2 Experimentos com a coleção de imagens UC

A tabela 6 apresenta os descritores selecionados em cada experimento com as imagens UC para que se atingisse o máximo IBC.

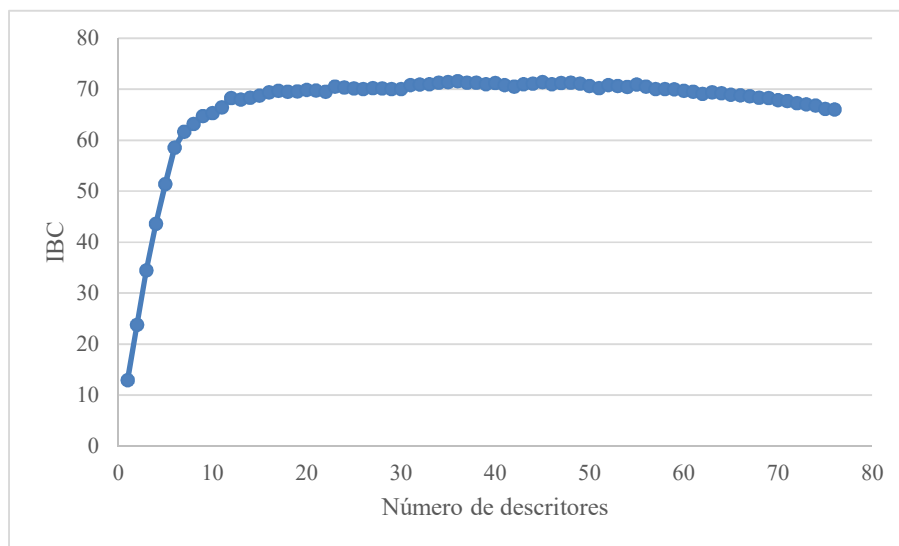
Tabela 6 – Resultados dos experimentos com UC. A primeira coluna é o número do experimento em ordem de execução, a segunda e terceira colunas apresentam, respectivamente, a sequência e o número de descritores selecionados para se obter o máximo IBC e a última coluna traz o máximo valor de IBC obtido em cada experimento.

Experimento	Sequência dos descritores selecionados	Número de descritores selecionados	IBC do teste
1	8-49-2-73-43-52-44-4-37-55-29-10-75-41-38-11-40-50-42-46-26-45-25-48-58-64-76-28-70-21-7-39-62-53-36-16	36	72,3
2	9-49-52-3-32-51-23-26-40-5-10-44-28-21-36-73-38-46-50-25-48-47-58-42-8-16-37-19-41-62-55-43-20-45-6-24	36	71,6
3	15-49-53-52-43-69-44-29-67-48-21-41-51-9-66-54-63-8-40-24-50-42-46-38-37-45-25-2-62-39-18-26-36	33	71,5
4	49-52-44-9-43-29-35-23-18-36-48-10-8-46-39-24-45-76-2637	20	71,9
5	41-65-13-52-53-43-72-49-29-18-51-7-36-21-45-39-63-54-26-10-23-32-9-69-27	25	73,3
6	49-9-3-43-69-62-10-4-55-37-41-39-44-22-24-32-50-51-48-73-5-40-46-8-38-52-36-26-45-42-47-20-21-75-7-71-65-61	38	70,5
7	49-52-40-72-51-9-17-10-23-47-69-26-53-43-37-5-50-45-21-48-41-44-11-36-29-42-39-4-22-24-38	31	73,1
8	66-40-12-9-51-60-22-49-44-10-28-43-41-5-38-48-8-46-26-24-50-42-45-52-70-21-37-72-47-69-63-74-36-54-71-39	36	73,1
9	67-48-52-9-51-35-41-17-21-44-49-18-62-24-47-36-55-42-40-39-27-45-26-50-38-5-25	27	74,3
10	3-40-59-43-73-52-10-27-22-49-63-44-25-5-24-36-23-39-14-48-45-54-26-61-35-47-46-34-37-42-50-38-62-64-69-20-18-51-41-75-67-7-58-21	54	73,0
11	48-39-52-6-53-73-2-41-51-10-44-40-21-62-9-24-47-49-32-45-50-46-72-42-20-75-8-43-37-25-26-35-29-38	34	72,7
12	49-52-9-44-43-32-18-26-23-40-10-39-56-37-50-24-41-51-63-38-45-48-5-62-35-42-21-47-36-27-20-53	32	73,7

Fonte: autoria própria

A relação típica obtida entre a quantidade de descritores usados pelo SFS e o IBC, apresenta um máximo apontando que são necessários menos que os 76 descritores totais, para que a máxima acurácia do classificador seja obtida (Figura 17).

Figura 17 - Exemplo típico da relação de IBC com o número de descritores selecionados pelo SFS



Fonte: autoria própria


A tabela 7 e a Figura 18 apresentam os números totais de descritores selecionados (Total) para cada subgrupo de descritores (Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de UC.

Tabela 7 – Número total de descritores selecionados (Total) para cada subgrupo de descritores (Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de UC

	Total	Contribuintes
Níveis de cinza	20	18
XYZ	27	17
HSV	24	21
RGB	85	57
YCbCr	5	5
Haralick	166	114
Lab	47	40
Fourier	28	22

Fonte: autoria própria

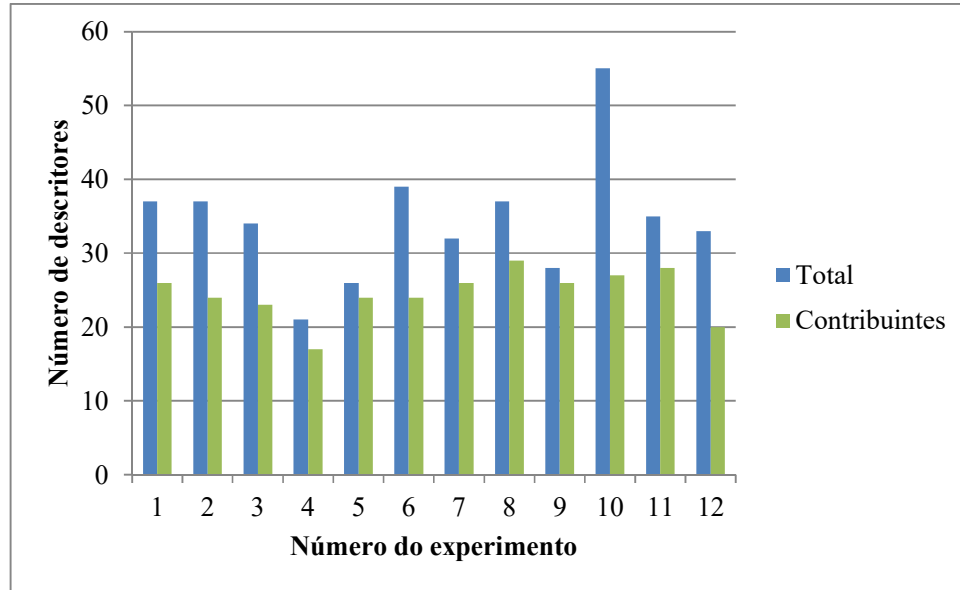
Figura 18 - Números totais de descritores selecionados (Total) para cada subgrupo de descritores (Tabela 3) e o número de descritores que aumentam o IBC (Contribuintes) considerando-se todos os experimentos de UC



Fonte: autoria própria

A Figura 19 traz a informação do número total mínimo de descritores selecionado para se atingir o máximo IBC (Total) e o número de descritores que aumentam o IBC (Contribuintes) para cada experimento de UC.


Figura 19 - Número total mínimo de descritores selecionado para se atingir o máximo IBC (Total) e o número de descritores que aumentam o IBC (Contribuintes) para cada experimento de UC



Fonte: autoria própria

O IBC médio considerando-se todos os experimentos foi de 72,6% e o DNM médio de 44% (Figura 20) indicando que a máxima classificação foi obtida pela seleção sequencial de um conjunto de aproximadamente 34 descritores pertencentes ao GC ou GCN, perfazendo 22% daqueles disponíveis, sendo 54 a quantidade máxima verificada e 20 a quantidade mínima.


Figura 209 - Dispersão obtida do IBC versus n_{max} relacionados a E=12 experimentos de classificação de imagens



Fonte: autoria própria

A Figura 21 apresenta o número de descritores n_{max} para cada experimento de classificação com o UC.

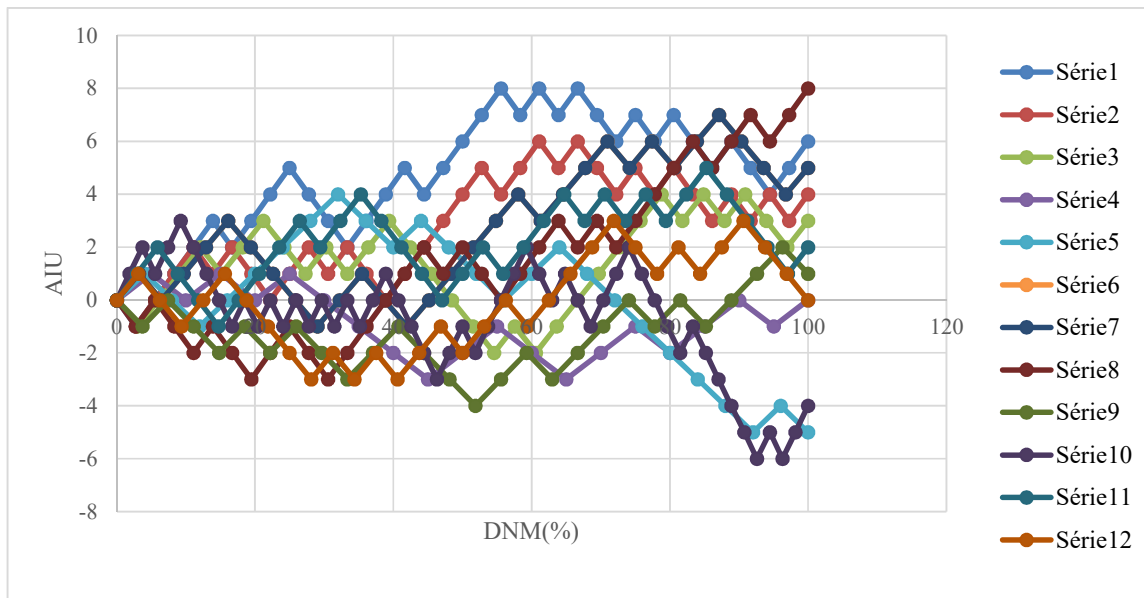
Figura 21 - Número de descritores n_{max} e a razão GNC/GC entre a quantidade de descritores: barras em hachura escura (GNC) e em hachura clara (GC). A razão é observável na projeção dos marcadores circulares à direita em preto no eixo vertical secundário



Fonte: autoria própria

A Figura 22 apresenta a dinâmica qualitativa da seleção feita pelo SFS, mostrada até o IBCN máximo (100%) obtido em cada experimento executado.


Figura 22 - O acumulo de incrementos unitários (AIU) indica a dinâmica qualitativa da seleção de descritores GC ($IU < 0$) ou GNC ($IU > 0$) de cada um dos 12 experimentos e respectivas séries de dados



Fonte: autoria própria

A Figura 23 apresenta a dinâmica do IBCN em relação ao DMN relativos aos 12 experimentos e execuções do algoritmo SFS.

Figura 23 - Dinâmica do IBCN da classificação em relação ao DMN para os 12 experimentos e respectivas séries de dados



Fonte: autoria própria

6. DISCUSSÃO

6.1 Resultados gerais

Inicialmente pode-se destacar que a seleção de descritores mínimos é altamente relacionada ao conjunto de imagens utilizadas na fase de treinamento (Tabelas 4 e 6), embora no caso de UC, exista um comportamento muito similar na variação do IBCN ao se agregar novos descritores (Figura 23).

Em SB as imagens são formadas por texturas aleatórias e alguma direcionalidade (Figura 7) ao passo que em UC as imagens são bastante diversas entre si, apresentando estruturas e subestruturas formadas por texturas que vão das aleatórias às ordenadas. Esta diferença torna o processo de classificação mais complexa para UC quando comparada a SB e este fato fica evidente no número mínimo de descritores selecionados em cada caso, como pode-se ver nas Tabelas 4 e 6. Embora o número de descritores selecionados se altere, para SB varia principalmente entre 10 e 25 e para UC entre 20 e 40, desconsiderando-se *outlayers*.

Como pode-se observar das Figuras 10 e 17, o aumento indiscriminado do número de descritores não leva a um melhor desempenho de classificação, podendo ocorrer um decréscimo do IBC, provavelmente devido à complexidade em se analisar muitos descritores. Neste sentido, deve-se determinar o número mínimo de descritores que levam ao melhor desempenho.

Com relação aos subgrupos de descritores, a partir de uma análise mais detalhada das Tabelas 4 e 6 pode-se perceber que em nenhum experimento foram selecionados todos os descritores de um mesmo subgrupo, tendo-se selecionado descritores de vários subgrupos, indicando que o uso de vários subgrupos é uma estratégia interessante para se fazer a classificação.

No entanto, nota-se das Figuras 11 e 18 que os subgrupos de RGB, Haralick, Lab e Fourier se destacam pelo número de descritores selecionados (Total) em SB ao passo que no caso de UC, têm-se destaque para RGB e Haralick.

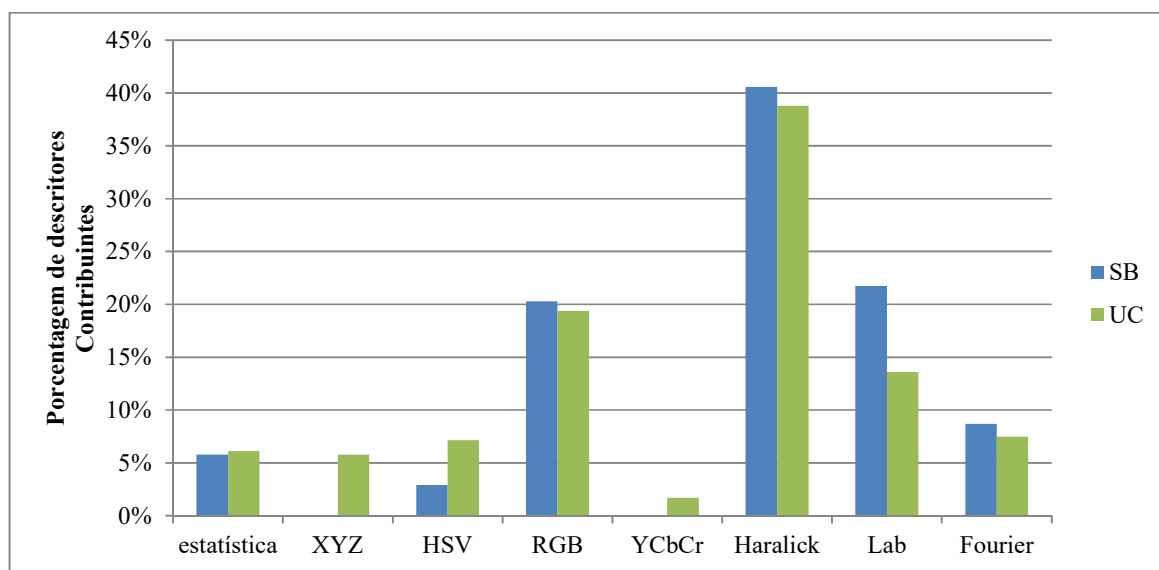
Quando se considera os descritores Contribuintes, percebe-se inicialmente que existe um número maior de descritores que não levaram a uma melhora de desempenho no caso de SB (Figura 12) quando comparado a UC (Figura 19). Este fato, novamente, deve-se a maior complexidade das imagens de UC em relação a SB.

Ainda das Figuras 11 e 18, pode-se notar a baixa contribuição dos subgrupos formados pela estatística de primeira ordem, XYZ, HSV e YCbCr. No caso SB (Figura 11) não houve

nenhuma contribuição de YCbCr e, em se considerando os descritores Contribuintes, nenhuma de XYZ. Tanto em SB bem como UC, o subgrupo que mais se destaca, pelo número de descritores Totais e Contribuintes é Haralick. Deve-se notar ainda o desempenho praticamente equivalente do subgrupo RGB quando comparado ao Lab no caso de SB ao se considerar os Contribuintes e que o subgrupo RGB é superior a Lab no caso de UC.

A Figura 24 apresenta a porcentagem de descritores Contribuintes de cada subgrupo, considerando-se todos os experimentos, para SB e UC, corroborando as discussões feitas no parágrafo anterior e evidenciando a importância dos descritores de Haralick, RGB e Lab, sendo que no caso de Haralick e RGB os resultados para SB e UC são muito semelhantes. Deve-se ainda notar a maior contribuição de HSV no caso de UC.

Figura 24 - Porcentagem de descritores Contribuintes de cada grupo, considerando-se todos os experimentos, para SB e UC



Fonte: autoria própria

6.2 Resultados dos experimentos usando SB e a literatura

O número de descritores utilizados no presente trabalho foi em média de 17 para obtenção de média dos máximos IBC (90,97%). Porebski et al. (2010) em uma abordagem com dicionários de descritores calculados a partir de matrizes reduzidas cromáticas de co-ocorrência atingiu 93,9% de IBC médio com 50 descritores.

Foi verificada a importância dos descritores Haralick para a classificação bem como a relevância do RGB. Ambas as observações são consistentes com o descrito por Porebski et al.

(2011) que partindo de um múltiplo espaço de cores (total de 28), obteve com 6 descritores em imagens BARKTEX, um IBC de 70,8%, sendo que o primeiro e mais importante descritor selecionado foi o integrante do conjunto dos descritores Haralick relativo ao canal B do espaço RGB (POREBSKI et al., 2011).

O algoritmo SFS priorizou os descritores Haralick relativos a imagens em tons de cinza. Dale et al. (2014) observaram que a relação causal dos padrões de cascas de árvores com geometria de “cicatrices” em geral pode ser devido ao crescimento da árvore, o que é consistente com os resultados de Smith et al. (2002) que descreve o uso de descritores Haralick para identificar “cicatrices” resultante de queimadas em imagens de baixa resolução do sensoriamento remoto de savana.

O primeiro descritor escolhido neste trabalho propiciou, em média, classificação de 54% a 80%, sendo superior quando comparado aos 48,3% relatado anteriormente (POREBSKI et al., 2011).

No contexto deste trabalho e especificamente da SB, pôde-se notar que as informações mais relevantes para a classificação estão nas imagens em níveis de cinza. Adiciona-se a esta evidência os resultados de Wan et al. (2004) que pesquisaram vários métodos de análise de textura baseados em níveis de cinza e cor, com quantidade variável de descritores, utilizando 160 imagens de cascas de árvores divididas em 9 classes. Estes autores obtiveram IBC entre 62 e 77 % com descritores extraídos somente de imagens em níveis de cinza. A adição de descritores extraídos de imagens coloridas resultou em IBC entre 73 e 89%. Nota-se que o incremento máximo foi de 15% usando-se imagens coloridas e o mesmo classificador 1-NN.

Em outro trabalho, Porebski et al. (2014) subdividiram as imagens do BARKTEX e usando essas diversas subimagens igualmente para treinamento ou teste, obtiveram 75,9% de IBC médio usando o classificador 1-NN e descritores Haralick a partir de informações representadas nos espaços de cores HSV e $I_1I_2I_3$ e mínimo de 48,3 % com o classificador “*Rank Sum*”.

Segundo Hoang et al. (2017) a extensão dos padrões binários locais para classificar texturas naturais é considerada promissora e com esta metodologia obteve-se uma IBC médio usando BARKTEX de 81,37 % com base no espaço de cores YIQ.

Segunda Samanta et al (2015) a discriminação de superfícies com IBC de 94,1 % entre duas categorias: madeira ou não foi obtida com classificador baseado em rede neural multicamadas (*feedforward*) e descritores de textura Haralick. Esse IBC foi considerado por estes autores uma acurácia alta, enfatizando que as imagens de cascas de arvores não eram o único foco do estudo.

A elevada incidência de seleção de descritores de textura relacionados aos canais ab do espaço Lab observada neste trabalho, está em acordo com observações realizadas por Martinez et al. (2015) sobre o incremento do IBC decorrente do uso de descritores relativos a análise da diferenças de cores neste espaço.

A razão do número de descritores GNC/GC relativas às classificações de imagens se adequam aos resultados obtidos por Mäenpää; Pietikäinen (2004), Cusano, Napoletano e Schettini (2016), na classificação de imagens adquiridas sob iluminação natural não controlada. Os descritores baseados em cores, nestas condições, têm menor capacidade discriminativa e seus usos oferecem ganhos secundários que são justificáveis apenas em algumas aplicações.

A iluminação não controlada é comum à muitas atividades nas práticas de campo em ciências ambientais, que baseiam-se intensamente em inspeções visuais em ambientes naturais e sequente registro da imagem no espectro visível com câmeras fotográficas. Mäenpää; Pietikäinen (2004) observaram que as cores são relacionadas apenas às distinções de baixa acurácia em nosso sistema visual.

6.3 Resultados dos experimentos usando UC e a literatura

No caso do UC, obteve-se um resultado médio de IBC em 72,57% utilizando 34 descritores. Em comparação, Xia et al. (2017), utilizando métodos comparáveis com o deste trabalho, obtiveram IBC variando de 28 a 44% e utilizando métodos baseados em misturas gaussianas, relataram IBC superior a 72,6%.

Castellucio et al. (2015) elencaram resultados de experimentos de classificação baseados na base UCMERGED com IBC variando entre 73% e 97%.

A classificação supervisionada de imagens aéreas de alta resolução é considerada um problema totalmente em aberto devido a sua complexidade. Existe uma intensa demanda por este tipo de classificação automática para monitorar o desenvolvimento urbano.

Yang e Newsam (2010), estenderam o conceito intrínseco à definição das matrizes de co-ocorrência em níveis de cinza e propuseram a análise da ocorrência espacial de palavras visuais através do método denominado *Spatial Pyramida co-ocurrence Kernel* (SPCK), obtendo um IBC resultante entre 73,8% e 76% com imagens do UCMERGED baseando-se em mais de 1 milhão de descritores locais SIFT.

6. 4 Análise comparativa dos resultados SB e UC

Em ambos os experimentos, SB e UC, houve uma tendência à seleção de descritores iniciais dentro o GNC (Haralick), indicando que a distribuição de intensidade dos pixels é a informação mais relevante na caracterização das imagens em estudo.

Além do IBC menor em UC, houve a necessidade de mais descritores para se obter o valor máximo, em média 44% do total disponível em relação a 21% no caso de SB. A análise comparativa sugere que a classificação de imagens UC é uma tarefa mais complexa, devido a maior variedade de texturas, com ocorrências distribuídas ao longo do intervalo que se estende desde as desordenadas até as fortemente ordenadas.

Verifica-se em UC maiores razões GNC/GC na seleção de descritores até DMN 100% comparativamente a SB devido ao fato de que os descritores de GNC, em UC, apresentarem menos redundância entre si para a realização da tarefa de categorização. Isso é observado na seleção mais recorrente de descritores relativos ao GC no SB, principalmente quando DMN está próximo a 100%, sugerindo um esgotamento do potencial de discriminação dos GNC em SB.

As maiores magnitudes de AIU observadas, +8 e -8, relativas a SB também constituem possível indicação de redundância, interpretando-as como maior flexibilidade gerando distintas variações nas sequências de seleção de descritores que inclusive podem incorrer fortemente apenas a GC ou GNC sequencialmente.

As oscilações observadas no IBCN de SB foram mais intensas do que em UC. Essa oscilação pode ser atribuída ao efeito da redundância (aninhamento) entre os descritores GNC. Idealmente o IBCN não diminuiria com a adição de um descritor (SCHULERUD; ALBREFTSEN, 2004). O algoritmo usado no presente trabalho não é robusto ao aninhamento e por isso é denominado como método de busca oscilante (PUDIL; NOVICOVA; KITTLER, 1994).

Nos experimentos UC, a maior frequência da orientação oblíqua (135°) dos descritores Haralick não foi totalmente concordante com o observado para cenas naturais (TORRALBA; OLIVA; 2003). Porém, além do grau de ação antrópica das imagens, também há de ser considerar a possível inexistência de direções preferenciais de aquisição nas imagens, como discutido sobre imagens de cobertura de solo por radar (RAO et al., 2015).

Torralba e Oliva (2003) analisaram a orientação do espectro de energia em imagens de cenas naturais sem e com elementos antrópicos. Nesse trabalho os autores apontaram que as imagens de cenas naturais apresentam uma distribuição que atinge todo o intervalo 0-360°, enquanto que as imagens com influência antrópica são caracterizadas pelo espectro de energia, no domínio da frequência, mais concentrado nas orientações horizontal e vertical.

7 CONCLUSÕES

Com o desenvolvimento deste trabalho e os resultados obtidos foi possível se avaliar um conjunto de descritores de caracterização de cor e textura em imagens digitais no contexto das Ciências Ambientais, visando a classificação automática através de uma Rede Neural Fuzzy ARTMAP.

Trabalhou-se com dois conjuntos de banco de dados relacionados a diagnósticos ambientais com fins de inventário de espécies arbóreas (SB) e de usos e cobertura do solo por inspeção de imagens (UC), tendo-se obtido descritores que permitiram taxas de acerto entre 87 e 100% no primeiro caso e entre 70 e 74% no segundo caso.

O IBC considerável em ambos os desafios de classificação aponta para a possível inserção do sistema de classificação proposto em um único software. Este poderia receber entradas de dois tipos de inspeções visuais aéreas, voo baixo coletando imagens de cascas de tronco de árvores e coletando imagens de usos de solo em maior altitude, como parte integrante de uma solução que envolveria também um VANT para aquisição flexível e processamento de dados e treinamento em tempo real.

Os resultados de SB foram o mais próximo do estado da arte do que os de UC e, considerando a complexidade da implementação e da metodologia em geral, os IBCs obtidos são relevantes em SB. Os resultados obtidos com experimentos UC comparados com os métodos da literatura foram satisfatórios.

Com relação aos descritores selecionados a partir de metodologias de caracterização das imagens de tons de cinza que salientam a informação de textura presente, pode-se destacar aqueles relacionados a análise das matrizes de co-ocorrência e no caso dos descritores obtidos a partir dos modelos de cor estudados, salienta-se o RGB e o Lab em ambas as aplicações consideradas.

Com relação ao processo de seleção automática dos descritores de cor e distribuição dos tons de cinza para a representação das imagens, pode-se argumentar que o método de Sequential Forward Selection agregou diversos descritores que não contribuíram para uma melhora do desempenho de classificação e, em alguns casos, até mesmo o diminuí. Este comportamento é mais evidente no caso do SB, possivelmente devido a menor complexidade quando comparado ao UC que necessita de mais descritores para se obter o máximo IBC.

No que se refere a avaliação de outros descritores computados a partir de níveis de cinza, nota-se que os relacionados à matriz de co-ocorrência (descritores de Haralick) se mostraram superiores aos de estatística de primeira ordem e do domínio de Fourier, corroborando a estratégia utilizada por Porebski et al. (2013). A relevância dos descritores Haralick também é condizente com outros resultados presentes na literatura e relaciona-se com propriedades de estatística de segunda ordem capturadas na matriz de co-ocorrência de níveis de cinza.

O uso da RNA Fuzzy ARTMAP se mostrou adequado e bastante apropriado para o desenvolvimento de metodologias aplicadas ao meio ambiente que geram grandes quantidades de dados, uma vez que mostrou-se bastante eficiente tanto no quesito de classificação bem como no curto tempo para a obtenção dos resultados, mesmo não sendo utilizado um equipamento de alto desempenho computacional.

Dos resultados obtidos, nota-se a grande contribuição que a informática aplicada ao meio ambiente pode trazer para o processo de suporte aos diagnósticos ambientais que, notadamente nos casos estudados, levam a classificação automação das imagens, permitindo que o especialista ambiental possa utilizar esta informação para analisar possíveis impactos ou estimar riscos de forma mais eficiente.

Como já salientado anteriormente, não houve em qualquer dos experimentos realizados a seleção de todos os descritores de um mesmo subgrupo e, embora se possa notar uma predominância dos descritores de níveis de cinza, a utilização de um conjunto formado por descritores de cor e distribuição dos níveis de cinza levam a melhores resultados no processo de classificação.

Considerando-se que a seleção de descritores mínimos é altamente relacionada ao conjunto de imagens utilizadas na fase de treinamento, a expansão deste estudo para outros métodos de caracterização de distribuições dos tons de cinza tais como os baseados em dimensões fractais e campos de Markov e a análise das distribuições dos diversos canais de cores utilizando a matriz de co-ocorrência podem levar a um conjunto mínimo de descritores que permitam um processo menos dependente das imagens de treinamento.

8 PERSPECTIVAS FUTURAS

Potencialmente e adicionalmente, deste estudo apresentado, emerge um programa de pesquisa focado no aprofundamento da importância de descritores, com um enfoque oposto ao tradicional da automação de tarefas, que busca identificar os descritores. Nesta proposição alternativa, em que estes, ou sequências destes, estão fixados previamente e relacionadas a bases de imagens, como um código ou padrões atomizados, em analogia próxima a bases nitrogenadas do DNA e dos estudos de genética.

Todo um ramo da bioinformática e de processamento de sequências de strings, está desenvolvido e potencialmente poderia ser adaptado para tratar sequências de descritores de imagens ao invés das bases que formam o DNA. Isto exigiria um grande trabalho relativo a banco de dados e padronização de identificação de descritores que seriam individualmente associados a análogos das letras como o A-G-C-T-U que representa respectivamente Adenina, Guanina, Citosina, Timina e Uracila.

O estudo georreferenciado da frequência destas sequências poderia explicitar importantes similaridades em ciências ambientais não aventadas anteriormente dada a aparente dissimilaridade das origens e escalas e das imagens. Sob o viés da dinâmica destas frequências ao longo do tempo, esta iniciativa poderia potencialmente sugerir mapear tendências de estagnação ou mudança relevantes e servir como componentes de diversos indicadores que agregadas aos resultados de abordagens mais convencionais e consolidadas.

Para ilustrar e exemplificar esta reflexão, uma pergunta prática seria como a sociedade cujas as imagens aéreas (em uma dada escala) de uso do solo poderiam ser devidamente classificadas com os mesmos descritores de cascas de árvores. Qual o significado do cenário sob o viés de organização social, uso de materiais e sustentabilidade da arquitetura vigente entre outras, enfim se seria possível estudar a realidade com uma espécie de códigos de descritores “visual-genéticos” e desta abordagem extrair "insights" fundamentais sobre o meio ambiente esta questão soa ao menos intrigante ao autor deste trabalho.

9 REFERENCIAS

ACHA, B., SERRANO, C.; FONDÓN, I.; GÓMEZ-CÌA, T. Burn Depth Analysis Using Multidimensional Scaling Applied to Psychophysical Experiment Data. *IEEE Transactions on Medical Imaging*, v. 32, n. 6, p. 1111-1120, 2013.

BECKER, M. W. et al. Magnetic resonance imaging of dense and light non-aqueous phase liquid in a rock fracture. *Geophysical Research Letters*, v. 30, n. 12, p. 1646, 2003.

BERGAMASCO, A. F. F. et al. Aplicabilidade do Modelo de Balanço de Nitrogênio para Previsão de Resposta da Cana-de-Açúcar ao Fertilizante Nitrogenado. Embrapa. 2002, Campinas, p.1-8.

BIANCONI, F. et al. Theoretical and experimental comparison of different approaches for color texture classification. *Journal of Electronic Imaging*, v.20, n.4, 043006, 2011.

CARPENTER, G. A. et al. A neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, v. 3, n. 5, p. 698-713, 1992.

CARPENTER, G. A. et al. ART neural networks for remote sensing: vegetation classification from Landsat TM and terrain data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 35, n. 2, p. 308-325, 1997.

CASTELLUCCIO, M. et al. Land Use Classification in Remote Sensing Images by Convolutional Neural Networks. *CoRR abs/1508.00092* (2015)

CERNADAS, E. et al. Influence of normalization and color space to color texture classification, *Pattern Recognit*, v. 61, p. 120-138, 2017.

CHARLAMPIDIS, D. et al. A fuzzy ARTMAP based classification technique of natural textures. In: 18th International Conference of the North American Fuzzy Information Processing Society 1999, NAFIPS (Cat. No.99TH8397).

CHEN, Z. et al. A texture-based method for classifying cracked concrete surfaces from digital images using neural networks. In: International Joint Conference on Neural Networks, 2011. San Jose, California. *Anais do 2011 International Joint Conference on Neural Networks*. pag. 2632-2637.

- CHEN, C. et al. Land-use scene classification using multi-scale completed local binary patterns. *Signal, Image and Video Processing*, v. 10, n 4, p. 745- 752, 2016
- CHENG, G.; HAN, J.; LU, X. Remote Sensing Image Scene Classification: Benchmark and State of the Art. *Proceedings of the IEEE*, v. 105, n. 10, p. 1865-1883, 2017.
- CHI Z.; HOUQIANG, L.; CHAO, W. Plant species recognition based on bark patterns using novel gabor filter banks. In: *International Conference on Neural Networks and Signal Processing*, Nanjing, 2003. *Anais International Conference on Neural Networks and Signal Processing*. v. 2. p. 1035-1038.
- CLERY, S.; BLOJ, M.; HARRIS, J. M. Interactions between luminance and color signals: Effects on shape. *Journal of Vision*, v. 13, p. 16-21, 2013.
- COLLINS R. T., LIU Y.; LEORDEANU, M. Online selection of discriminative tracking descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 27. p. 1631-1643, 2005.
- CORBALAN-FUERTE, M. et al. Color pattern recognition with CIELAB coordinates. *Optical Engineering*, v. 41, n. 1, 2002 não paginado.
- CUNHA, B. A. Estudo comparativo entre abordagens estatísticas e redes neurais artificiais na classificação de imagens de grãos de cereais. Monografia , São Paulo, FATEC 2012
- CUSANO, C.; NAPOLETANO, P.; SCHETTINI, R. Evaluating color texture descriptors under large variations of controlled lighting conditions. *J. Opt. Soc. Am. A*, v. 33, p. 17-30, 2016.
- DADAM, J. et al. Morphological Patterns and Their Colour. *Perceptual and Motor Skills*, v. 114, n. 2, p. 363-377, 2017
- DALE, H. et al. Modelling biomechanics of bark patterning in grasstrees. *Annals of Botany*, v.114, n. 4, p.629–641, 2014
- DELL, A. I., et al. Automated image-based tracking and its application in ecology. *Trends in Ecology & Evolution*, v. 29, n. 7, p. 417-428, 2014.
- FUKUNAGA, K. *Statistical pattern recognition (second edition)*. 1990, San Diego, CA: Academic Press.

EZEQUIEL, C. A. F. *et al.* UAV aerial imaging applications for post-disaster assessment, environmental management and infrastructure development. In: International Conference on Unmanned Aircraft Systems (ICUAS), 2014, Orlando, EUA, pp. 274-283.

FAPESP. FUNDAÇÃO DE AMPARO A PESQUISA DO ESTADO DE SÃO PAULO. 2012. Pesquisadores da USP vencem desafio de identificação de plantas. Disponível em: <<http://agencia.fapesp.br/15185>>. Acesso em: 11 de maio de 2015.

FIEL, S.; SABLATNIG R. Automated identification of tree species from images of the bark, leaves and needles. In: 16th Computer Vision Winter Workshop, 2011, Mitterberg, Austria, Anais do 16th Computer Vision Winter Workshop. p. 1–6.

FONGARO, L.; KVAAL, K. Surface texture characterization of an Italian pasta by means of univariate and multivariate feature extraction from their texture images. *Food Research International*, v. 51, n. 2, p. 693-705, 2013.

FORESTIER, G.; WEMMERT, C.; PUISSANT, A. Coastal image interpretation using background knowledge and semantics. *Computers & Geosciences*, v. 54, n. 0, p. 88-96, 2013.

FREITAS, M. R.; MACEDO, R. L. G.; FERREIRA, E. B.; FREITAS, M. P. Em busca da conservação ambiental: a contribuição da percepção ambiental para a formação e atuação dos profissionais da Química. *Quimica Nova*, v. 33, n., p. 988-993, 2010.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 3rd edition. Prentice-Hall; 2006.

GONZALEZ, R. C; WOODS, R.E.; EDDINS, S. L. *Digital Image Processing using Matlab*. 2nd edition. Gatesmark Publishing. 2009.

HARALICK, K.; ROBERT M.; SHANMUGAM, K.; DINSTEIN, ITS'HAK. Textural Descriptors for Image Classification. *IEEE Transactions on Systems. Man and Cybernetics*, v. 3:6, p. 610 – 621, 1973.

HILTY, L.M. *et al.* Environmental Informatics as a new discipline of applied computer science. N.M. Avouris and B. Page (eds.), *Environmental Informatics* (1995), pp. 1-11. Kluwer Academic Publishers. The Netherlands. ISBN 0-7923-3445-0

HOANG, V. T. et al. Histogram selection based on sparse representation for color texture classification. International Conference on Computer Vision Theory and Applications (VISAPP'17), 27 February - 1 March, 2017, Porto, Portugal

HODGSON, J. C. et al. Precision wildlife monitoring using unmanned aerial vehicles. Scientific Reports 6, Article number: 22574, p.1-6, 2016.

HUANG, Z. K. et al. Bark classification based on textural descriptors using artificial neural networks. Advances in Neural Networks. Springer, 2006.

HUANG, Z. K. et al. Bark Classification Based on Textural Features Using Artificial Neural Networks. In: Wang J., Yi Z., Zurada J.M., Lu BL., Yin H. (eds) Advances in Neural Networks - ISNN 2006. ISNN 2006. Lecture Notes in Computer Science, vol 3972. Springer, Berlin, Heidelberg.

IZQUIERDO, J. M. C. et al. Learning from noisy information in FasArt and FasBack neuro-fuzzy systems. Neural Netw, v. 14, n. 4-5, p. 407-425, 2001.

JORGENSEN, S. E.; VOLLENWEIDER, R. A. Eds. Princípios para o gerenciamento de lagos. Diretrizes para o gerenciamento de lagos. São Carlos: ILEC; IIE; UNEP, 2000, v.I, p.202-208.

KADIR, A. et al. Leaf Classification Using Shape, Color, and Texture Descriptors. International Journal of Computer Trends and Technology, p. 225-230, 2011.

KARRABI, M. et al. Investigation of hydrodynamic/biomass growth coupling in a pilot scale granular bioreactor at low pore Reynolds number. Chemical Engineering Science, v. 66, n. 8, p. 1765-1782, 2011.

KHALIL, M. S.; KHAN, M. K.; RAZZAK, M.I. Co-occurrence matrix descriptors for fingerprint verification. In: IEEE International Conference on Anti-Counterfeiting, Security and Identification (ASID). 2011. Anais IEEE International Conference on Anti-Counterfeiting, Security and Identification (ASID). p. 43-46.

KHAN, F.S. et al. Compact color–texture description for texture classification. Pattern Recog. Lett. v. 51, p. 16-22, 2015.

KUTSCHERA, F. et al. Induction and the Empiricist Model of Knowledge. In: (Ed.). *Studies in Logic and the Foundations of Mathematics*, Elsevier, 1973, v. 74, p.345-356.

LAKMANN, R. Barktex benchmark database of color textured images, 1998. Disponível em: <ftp://ftphost.uni-koblenz.de/outgoing/vision/Lakmann/BarkTex.>. Acessado em 15 de dezembro de 2016.

LAMIT, L. J. et al. Genotype variation in bark texture drives lichen community assembly across multiple environments. *Ecology*, v. 96, n. 4, p. 960-971. 2015

LAOFOR, C.; PEANSUPAP, V. Defect detection and quantification system to support subjective visual quality inspection via a digital image processing: A tiling work case study. *Automation in Construction*, v. 24, p. 160-174, 2012.

LIN, T.J.; CHEN, P.C. Studies on hydrodynamics of an internal-loop airlift reactor in gas entrainment regime by particle image analyzer. *Chemical Engineering Journal*, v. 108, n. 1-2, p. 69-79, 2005.

MACHADO, B. B.; CASANOVA, D.; GONÇALVES, W. N.; BRUNO, O. M. Partial differential equations and fractal analysis to plant leaf identification. *Journal of Physics: Conference Series*. IOP Publishing, p. 012-066, 2013

MADDEN, M. et al. The future of Unmanned Aerial System (UAS) for monitoring natural and cultural resources. Pag 369- 385 Dieter Fritsch (Ed). *Photogrammetric Week*. (2015)

MÄENPÄÄ, T.; PIETIKÄINEN, M. Classification with color and texture: jointly or separately? *Pattern Recognition*, v. 37, n. 8, p. 1629-1640, 2004.

MARTINEZ, A.; RICHARD, N.; FERNANDEZ-MALOIGNE, C. Colour Contrast Occurrence matrix: a vector and perceptual texture feature. IS&T. *Color imaging Conference*, Oct 2015, Darmstadt, Germany. IS&T, Color and imaging Conference (23)

MARTINS, A. C. G.; SIMÕES, A.S.; PRADO, G. I. Classificação de texturas usando redes neurais artificiais e o modelo de Spot Noise. In: VI ENIA - Encontro Nacional de Inteligência Artificial, Rio de Janeiro, 2007. Anais do VI ENIA - Encontro Nacional de Inteligência Artificial. CD-ROM.

MCCRORY, C.; COOPER, C. Overlap between visual inspection time tasks and general intelligence. *Learning and Individual Differences*, v. 17, n. 2, p. 187-192, 2007.

MIDDLETON, E.M. et al. Optical properties of canopy elements in black spruce, Jack Pine and Aspen Stands in Saskatchewan, Canada. *Canadian Journal of Remote Sensing*, v. 24, n. 2, p. 169-186, 1998.

MOHD SAAD, N. et al. Brain lesion segmentation of Diffusion-weighted MRI using gray level co-occurrence matrix. In: *IEEE International Conference on Imaging Systems and Techniques (IST)*. 2011. Anais *IEEE International Conference on Imaging Systems and Techniques*. p. 284-289.

MOVAHED, Z. et al. Formation evaluation in Dezful embayment of Iran using oil-based-mud imaging techniques. *Journal of Petroleum Science and Engineering [S.I.]*, v. 121, n. Supplement C, p. 23-37, 2014.

NEVALAINEN, O. et al. Individual Tree Detection and Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. *Remote Sens.* V. 9, p. 185, 2017.

ÇALISKAN, N. Virtual field trips in education of earth and environmental sciences. *Procedia Social and Behavioral Sciences*, v.15, p. 3239-3243, 2011.

OJALA, T. et al. Outex new framework for empirical evaluation of texture analysis algorithms. In: *16th International Conference on Pattern Recognition, Quebec, Canada, 2002*, Anais *16th International Conference on Pattern Recognition*. v. 1. p. 701-706.

OLIVA, A.; ITTI, L.; REES, G.; TSOTSOS, J. K. Chapter 41 - Gist of the Scene. In: (Ed.). *Neurobiology of Attention*. Burlington, Academic Press, p.251-256. 2005

OLIVA, A.; TORRALBA, A. The role of context in object recognition. *Trends in Cognitive Sciences*, v. 11, n. 12, p. 520-527, 2007.

OSMON, D. C.; JACKSON, R. Inspection time and IQ: Fluid or perceptual aspects of intelligence? *Intelligence*, v. 30, n. 2, p. 119-127, 2002.

PICARD, R. et al. Vision texture database. Media Laboratory, Massachusetts Institute of Technology (MIT), Cambridge. Disponível em: <http://vismod.média.mit.edu/vismod/imagery/VisionTexture/distribution.html>.>. Acessado em: 11 de maio de 2015.

PICKUP L. C. *et al.* Seeing the Arrow of Time, 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, 2014, pp. 2043-2050.

POREBSKI, A.; VANDENBROUCKE, N.; MACAIRE, L. Comparison of feature selection schemes for color texture classification. 2nd International Conference on Image Processing Theory, Tools and Applications, 2010. Paris, pp. 32-37.

POREBSKI, A.; VANDENBROUCKE, N.; MACAIRE, L. Iterative Feature Selection for Color Texture Classification. IEEE International Conference on Image Processing, San Antonio, TX, 2007, pp. III - 509-III - 512.

POREBSKI, A.; VANDENBROUCKE, N.; MACAIRE, L. Supervised texture classification: color space or texture feature selection? Pattern Analysis and Applications, v. 16, n. 1, p. 1-18, 2013.

POREBSKI, A.; VANDENBROUCKE, N.; MACAIRE, L.; HAMAD, D. A new benchmark image test suite for evaluating colour texture classification schemes. Multimedia Tools and Applications, v. 70, n. 1, p. 543-556, 2014.

PRABHU, P.; DRURY, C. G. A framework for the design of the aircraft inspection information environment. In: Proceedings of the 7th FAA Meeting on Human Factors Issues in Aircraft Maintenance and Inspection (pp. 54-60), 1992.

PRASEITIO; K., M. *et al.* Comparative Study of Feature Extraction Methods for Wood Texture Classification. In: Sixth International Conference on Signal-Image Technology and Internet-Based Systems (SITIS). 2010. Kuala Lumpur, Malaysia. p. 15-18. Anais Sixth International Conference on Signal-Image Technology and Internet-Based Systems (SITIS). p. 23–29.

PUDIL, P; NOVOVICOVA, J; KITTLER, J. Floating search methods in feature selection. Pattern Recognition Letters, v. 15, p. 1119-1125, 1994.

PUGH, A, M.; FAY, W. D. Assessment of Multi-Sensor Neural Image Fusion and Fused Data Mining for Land Cover Classification. In: 9th International Conference on Information Fusion, 2006, p. 1-8.

RANGAYAN, R.M.; ACHA, B.; SERRANO, C. Color image processing with biomedical applications. Bellingham: SPIE Press. 2011

- RAO, A.; RAVISHANKAR, A. A taxonomy for texture description and identification. Springer series in perception engineering. 1990, Springer –Verlag, New York
- RAO, A. R.; LOHSE, G. Towards a texture naming system: Identifying relevant dimensions of texture. *Visualization*, 1993. Visualization Proceedings., IEEE Conference on, San Jose, CA, 1993, pp. 220-227.
- RAO, D.S.; PRASAD, A.V.V.; NAIR, T. Application of Texture Characteristics for Urban Feature Extraction from Optical Satellite Images, *IJIGSP*, v.7, n.1, pp.16-24, 2015.
- RIJNKS, R. H.; STRIJKER, D. Spatial effects on the image and identity of a rural area. *Journal of Environmental Psychology*, v. 36, n., p. 103-111, 2013.
- RITCHIE, S. J.; TUCKER-DROB, E. M.; DEARY, I. J. A strong link between speed of visual discrimination and cognitive ageing. *Current Biology*, v. 24, n. 15, p. R681-R683, 2014.
- ROSSATO, D. R. et al. Fractal analysis of leaf-texture properties as a tool for taxonomic and identification purposes: a case study with species from Neotropical Melastomataceae (Miconieae tribe). *Plant Systematics and Evolution*, v. 291, n. 1-2, p. 103-116, 2011.
- SADASIVAN, S.; GRAMOPADHYE, A. K. Technology to support inspection training in the general aviation industry: Specification and design. *International Journal of Industrial Ergonomics*, v. 39, n. 4, p. 608-620, 2009.
- SÁEZ, A. et al. Quantifiable diagnosis of muscular dystrophies and neurogenic atrophies through network analysis. *BMC medicine*, v. 11, n. 1, p. 77, 2013.
- SAMANTA, S. et al. Wooden Surface Classification based on Haralick and The Neural Networks. Fourth International Conference on Information Science and Industrial Applications (ISI), 2015, Busan, pp. 33-39.
- SCHULERUD, H.; ALBREGTSEN, F. Many are called, but few are chosen. Feature selection and error estimation in high dimensional spaces. In: *Computer Methods and Programs in Biomedicine*, 2004, v.73, n.2, p. 91-99. ISSN 0169-2607.
- SEE, J. E. *Visual Inspection: A Review of the Literature*. U.S. Department of Energy. New Mexico. 2012 SANDIA REPORT SAND2012-8590 Unlimited Release Printed October 2012

SMITH, A. M. S. et al. Texture based feature extraction: application to burn scar detection in Earth observation satellite sensor imagery. *International Journal of Remote Sensing*, v. 23, n.8, 1733-1739, 2002.

SNYDER, G. M. et al. Effectiveness of visual inspection compared with non-microbiologic methods to determine the thoroughness of post-discharge cleaning. *Antimicrobial Resistance and Infection Control*, v.2, p. 1-8, 2013.

SONG, J. et al. Bark classification by combining grayscale and binary texture descriptors. In: *International Symposium on Intelligent Multimedia, Video and Speech*, 2004, Hong Kong. *Anais International Symposium on Intelligent Multimedia, Video and Speech*. p. 450-453.

SULC, M.; MATAS, J. Kernel-mapped histograms of multi-scale LBPs for tree bark recognition. In: *International Conference of Image and Vision Computing New Zealand (IVCNZ)*, 2013. *Anais International Conference of Image and Vision Computing New Zealand*. p. 82-87.

TARTAVEL, G. Variational Texture Synthesis with Sparsity and Spectrum Constraints. *Journal of Mathematical Imaging and Vision. Math Imaging Vis.* v. 52, p.124. 2014.

TOK, S. Y.; KAPLAN, I.; TANELI, Y. Photography in architectural education: A tool for assessing social aspects of the built environment. *Procedia - Social and Behavioral Sciences*, v. 2, n. 2, p. 2583-2588, 2010.

TORRALBA, A.; OLIVA, A. Statistics of natural image categories, Network: Computation in Neural Systems, v.14, n.3, p; 391-412, 2003.

VAN DER STEEN, A. J.; DIRKSEN, J.; CLEMENS, F. H. L. R. Visual sewer inspection: detail of coding system versus data quality? *Structure and Infrastructure Engineering*, v. 10, n. 11, p. 1385-1393, 2014.

WAN, Y.Y. et al. Bark texture feature extraction based on statistical texture analysis. In: *International Symposium on Intelligent Multimedia, Video and Speech*, 2004, Hong Kong *Anais da 2004 International Symposium on Intelligent Multimedia, Video and Speech*. p. 482-485

XIA G. S. et al. AID: A Benchmark Data Set for Performance Evaluation of Aerial Scene Classification. In *IEEE Transactions on Geoscience and Remote Sensing*, 2017, p.1-17.

YANG, Y.; NEWSAM, S. Bag-Of-Visual-Words and Spatial Extensions for Land-Use Classification. In: ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems (ACM GIS), 2010, San Jose, USA.

ZHANG, J.; HUANG, W.; ZHOU, Q. Reflectance Variation within the In-Chlorophyll Centre Waveband for Robust Retrieval of Leaf Chlorophyll Content. PLoS ONE, v. 11, p. 1-13, 2014.

ZOU, J. et al. Scene classification using local and global features with collaborative representation fusion. Information Sciences, v. 348, p. 209-226, 2016.