

ALGORITMO GENÉTICO PARA CLASSIFICAÇÃO TEMÁTICA DE IMAGENS MULTIESPECTRAIS

Éldman de Oliveira Nunes

Instituto de Computação - UFF

R. Passo da Pátria 156, 24.210-240, Niterói, RJ, Brasil

eldman@pop.com.br

Aura Conci

Instituto de Computação - UFF

R. Passo da Pátria 156, 24.210-240, Niterói, RJ, Brasil

aconci@ic.uff.br

Resumo

Diversos trabalhos em processamento digital de imagens abrangem a identificação e classificação de regiões. Esta tarefa apesar de básica envolve um elevado grau de complexidade. Este trabalho apresenta um modelo de algoritmos genéticos para classificação de imagens multiespectrais baseado na evolução genética de regras de associação a partir dos atributos de cor e textura de um conjunto de amostras de treinamento. A implementação de uma ferramenta denominada AGCIM (Algoritmo Genético de Classificação de Imagens Multiespectrais) permitiu avaliar o modelo do algoritmo genético proposto para o problema de classificação de imagens. Com a implementação do AGCIM foram realizados testes experimentais com diversas imagens e foram apresentados os resultados obtidos pela implementação desenvolvida. A partir desses testes, foi possível comprovar a viabilidade da utilização dos algoritmos genéticos na classificação de imagens multiespectrais. A classificação de imagens por evolução genética de regras abre caminho para uma gama de aplicações nos mais diversos campos do conhecimento, cuja identificação e classificação de regiões em imagens coloridas ou multibandas tornam-se necessárias. Tal possibilidade permite diversas alternativas de trabalhos futuros.

Palavras-Chaves: Algoritmos Genéticos; Classificação; Imagens Digitais; Segmentação.

Abstract

Diverse works in digital processing of images enclose the identification and classification of regions. This task, although basic, involves one high degree of complexity. This work presents a model of genetic algorithms for classification of multispectral images based in the genetic evolution of rules of association from the attributes of color and texture of a set of samples of training. The implementation of a called tool AGCIM (Genetic Algorithm of Classification of Multiespectrais Images) allowed to evaluate the model of the considered genetic algorithm for the problem of classification of images. With the implementation of the AGCIM experimental tests with diverse images had been carried through and had been presented the results gotten for the developed implementation. By these tests, it was possible to prove the viability of the use of the genetic algorithms in the classification of multispectral images. The classification of images for genetic evolution of rules opens way for a gamma of applications in the most diverse fields of the knowledge, whose identification and classification of regions in colorful images or multibands become necessary. Such possibility discloses diverse alternatives of future works.

Keywords: Genetic algorithms; Classification; Digital images; Segmentation.

1. INTRODUÇÃO

A Análise de Imagens é uma área que desperta crescente interesse por envolver as atividades de identificação e classificação de informações extraídas de uma cena. Métodos de reconhecimento e classificação de imagens são amplamente empregados em aplicações destinadas para o meio científico e industriais, e têm beneficiado áreas como medicina, microscopia, sensoriamento remoto, controle de qualidade, dentre outras.

Num sistema de classificação a análise de imagens tem por finalidade extrair informação suficiente para possibilitar a distinção entre regiões de interesse. Esta tarefa apesar de básica reveste-se de elevado grau de complexidade, pois tenta reproduzir o sofisticado processo de classificação e reconhecimento realizado pela visão humana.

No reconhecimento de padrões em imagens, algumas das características mais empregadas são: a cor e a textura. A boa quantificação destas características permitirá a identificação e a classificação de padrões. A classificação baseada apenas na cor é a forma mais simples. Já a classificação por textura envolve maior complexidade. Vários métodos para classificação de imagens empregando características de textura têm sido propostos. Porém, não existe um método genérico ou uma abordagem formal que seja útil para uma grande variedade de imagens.

Este trabalho descreve um método para classificação de imagens multiespectrais. Na abordagem adotada, cada pixel é representado por um vetor de características de cor e textura em cada banda espectral. Apesar da presença de componentes aleatórios, espera-se que os pixels de uma mesma classe apresentem um comportamento padrão nas diferentes bandas espectrais. O problema consiste em alocar cada um dos pixels da imagem nas classes correspondentes, de forma a maximizar acertos ou minimizar erros de classificação. Tal problema pode ser modelado como um problema de maximizar ou minimizar uma função cujas variáveis devem obedecer a certas restrições. Neste contexto, de vasto espaço de busca e de soluções sujeitas a restrições, surgem os algoritmos genéticos como uma forma de resolver problemas de busca adaptativa em que o conhecimento para controlar a procura é obtido dinamicamente.

A estratégia adotada foi empregar Algoritmos Genéticos na descoberta de regras de associação para as classes, a partir de um conjunto de amostras de cada classe de interesse, que permitissem atribuir os pixels da imagem nas classes correspondentes, minimizando os erros de classificação. Uma regra de associação, representada por um cromossomo, assume a forma **SE** $(C_1, C_2, C_3, \dots, C_n \text{ e/ou } T_1, T_2, T_3, \dots, T_n)$ então **P**, onde os atributos de cor e textura da imagem $(C_1, C_2, C_3, \dots, C_n \text{ e/ou } T_1, T_2, T_3, \dots, T_n)$ estão representado simbolicamente como condições para que a conclusão da regra, caracterizada por (**P**), seja verdadeira. Baseado nesta hipótese pode-se procurar obter regras que caracterizem uma classe através de evolução genética.

Os Algoritmos Genéticos têm sido bem sucedidos em diversas aplicações, particularmente em problemas de otimização. Tais problemas são caracterizados pela busca de boas soluções dentre um número elevado de possíveis soluções (espaço de busca). Os Algoritmos Genéticos tornam-se atrativos devido ao fato de não ser necessário descrever como encontrar uma boa solução. Assim, a descoberta de padrões em forma de regras de associação, através de Algoritmos Genéticos, revela-se um método promissor de classificação de imagens.

2. DESCRIÇÃO DE REGIÕES

A segmentação é uma tarefa básica no processo de análise de imagens. Na segmentação, a imagem é dividida em regiões semelhantes (em um determinado contexto de

interesse) para uma aplicação específica. Talvez a característica mais importante de um método de segmentação seja a definição do que é uma região. Por exemplo, uma região pode ser definida como um conjunto de pixels conectados por meio de uma condição de uniformidade ou, ainda, uma região pode ser vista como um conjunto de pixels conectados envolvidos por uma borda de pixels criando um contorno. Na primeira definição, a segmentação é realizada com base na similaridade, enquanto na segunda definição, com base na descontinuidade [1].

Após a segmentação de uma imagem em regiões, os agrupamentos resultantes de pixels segmentados normalmente são representados e descritos em um formato apropriado para o processamento subsequente. A representação de uma região pode ser feita em termos de suas características externas (sua fronteira) ou em termos de suas características internas (os pixels que compõe a região). Uma representação externa normalmente ocorre quando as características de forma são mais relevantes. E uma representação interna quando propriedades como cor e textura forem mais importantes. Em ambos os casos, as características escolhidas como descritores devem ser o menos sensível possível a variações de tamanho, rotação e translação [2].

Concluída a representação, a próxima tarefa consiste na descrição da região a partir da forma como foi representada. Neste trabalho, priorizou-se a representação interna enfatizando as características de cor e textura na descrição de regiões [3].

2.1. DESCRITOR DE COR

A cor é uma resposta subjetiva a um estímulo luminoso que penetra nos olhos. Ela é uma das características mais utilizadas pelos seres humanos para conhecimento e discriminação visual. Para perceber a cor, o sistema visual humano possui células foto sensíveis que se subdividem em três categorias, com diferentes máximos de sensibilidade situados em torno do vermelho, verde e azul. As sensações de cor percebidas são baseadas na combinação das intensidades dos estímulos recebidos por estas células [4].

Devido à possibilidade de se obter qualquer outra cor a partir da combinação destas três, em diferentes proporções, elas passaram a ser denominadas de cores primárias aditivas. A combinação das cores primária duas a duas produz as chamadas cores secundárias: Ciano, Magenta e Amarelo. A combinação das três cores primárias aditivas produz a cor branca.

Vários modelos de representação de cores foram criados para permitir a especificação de cores em um formato padronizado. O modelo RGB, se baseia em um sistema de coordenadas cartesianas representado na forma de um cubo, onde três de seus vértices são cores primárias (R, G, B) e os outros três são cores secundárias (C, M, Y), a escala de cinza se estende pela diagonal do cubo que sai da origem (preto) até o vértice mais distante dela (branco).

2.2. DESCRITOR DE TEXTURA

Uma importante abordagem para descrição de regiões é a quantificação do seu conteúdo de textura [5]. A textura refere-se a um padrão visual que possui algumas propriedades de homogeneidade que não resultam simplesmente de uma cor ou intensidade. A textura, presente na maioria das imagens naturais, é fundamental para visão humana e serve como excelente descritor regional contribuindo na melhoria da exatidão do processo de reconhecimento, descrição e classificação de imagens [6]. Entretanto, o sofisticado processo de reconhecimento de textura, realizado intuitivamente pela visão humana, se reveste de grande complexidade computacional [7]. A Textura é uma expressão relacionada com as propriedades que representam a superfície de um objeto. É um termo intuitivo e de largo emprego, mas apesar de sua importância, não possui uma definição precisa [8].

Para quantificação da textura, os autores desenvolveram um coeficiente denominado Coeficiente de Variação Espacial que apresentou bons resultados na classificação de imagens coloridas permitindo distinguir satisfatoriamente diferentes classes de texturas [9].

3. RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões é um procedimento que tem por finalidade classificar ou descrever objetos através de um conjunto de características (padrão) com o objetivo de atribuí-los a um conjunto desconhecido de classes de padrões (clustering) ou identificar um objeto como membro de um conjunto conhecido de classes (classificação).

No reconhecimento de padrões busca-se uma classificação em que o grau de associação entre os objetos de mesma classe seja maior do que o grau de associação entre os objetos de classes distintas.

3.1. PADRÕES E CLASSE DE PADRÕES

Segundo Gonzalez [8] padrão é uma descrição quantitativa ou estrutural de um objeto. Um padrão normalmente é formado por um ou mais descritores. Assim, um padrão é um arranjo de descritores. Já uma classe de padrões é uma família de padrões que compartilham de algumas propriedades comuns. Na prática, os três principais arranjos de padrões utilizados são os vetores (para descrições quantitativas), cadeias e árvores (para descrições estruturais). Vetores de padrões são representados como colunas (matrizes $n \times 1$) com letras minúsculas em negrito, como x , y e z , tomando a forma:

$$x = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ \dots \\ x_n \end{pmatrix} \text{ onde, } x_1, x_2, x_3 \dots x_n \text{ são suas características (descritores).}$$

A natureza dos descritores de um vetor de padrões x depende da técnica de medida usada na descrição do próprio padrão físico. Uma vez que um conjunto de características tenha sido selecionado, um vetor de padrões representará cada amostra física. Portanto, cada objeto será representado por um ponto no espaço euclidiano, cuja dimensão espacial será igual ao número de características presentes no vetor.

3.2. FASES DO RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões abrange as seguintes fases: a representação dos dados de entrada e sua mensuração, a extração das características e a identificação e classificação do objeto em estudo.

A fase de **representação dos dados** de entrada visa descrever padrões característicos do objeto, possibilitando a sua posterior classificação numa determinada classe. A fase de **extração de características** tem por objetivo selecionar, dentre infinitas características, as mais significativas para a tarefa de classificação. Busca-se reduzir a dimensionalidade do vetor padrão e conseqüentemente o esforço computacional, sem prejuízo de informação que prejudique a qualidade da classificação. Para um bom desempenho do classificador é fundamental uma escolha apropriada dessas características que normalmente envolve conhecimento específico sobre o problema em estudo. A última etapa envolve a determinação de procedimentos que permitam a identificação e classificação do objeto em uma classe de objetos (**algoritmo de classificação**). Ao contrário da etapa anterior, nesta etapa, o classificador pode ser concebido de forma independente da natureza do problema, e sua aplicação é possível em diferentes contextos, sem prejuízo de sua eficiência [10].

Algumas técnicas de reconhecimento de padrões possuem uma etapa de aprendizado que tem o propósito de ensinar o classificador a distinguir dentre as classes, aquela que for mais pertinente ao objeto. Este aprendizado é realizado por meio de um conjunto de amostras denominado de amostras de treinamento.

Existem basicamente duas formas de treinamento: supervisionado e não-supervisionado. No treinamento supervisionado, as classes são pré-definidas pelo usuário através das amostras de treinamento.

No treinamento não-supervisionado, o usuário utiliza algoritmos para reconhecer as classes presentes. Neste caso, o problema envolve, além da classificação propriamente dita, a identificação das classes existentes num conjunto de dados. Uma abordagem possível para solucionar tal problema seria a busca por aglomerados (clusters) de pontos no espaço. Estes aglomerados são formados por um grupo de pontos que podem ser considerados como semelhantes entre si, em função de um determinado critério (como uma medida de distância). Este processo é denominado de clustering ou análise de aglomerados.

4. O PROCESSO DE KDD (KNOWLEDGE DISCOVERY DATABASE)

O processo de descoberta de conhecimento em bancos de dados - Knowledge Discovery in Databases - KDD refere-se ao processo não trivial de identificação de padrões válidos, novos, potencialmente úteis e compreensíveis em conjuntos de dados. A descoberta de conhecimento em banco de dados tem ampla aplicação prática em diversos domínios da ciência, principalmente aplicações que envolvem a tecnologia da informação. Assim, os bancos de dados representam depósitos de conhecimento em potencial, que podem ser explorados para se descobrir relações, padrões e regras.

4.1. MINERAÇÃO DE DADOS (DATA MINING)

Das diversas fases que compõe o processo de KDD a mineração de dados é considerada a mais importante. Esta fase é a responsável pela transformação de dados em informações. A mineração de dados está relacionada com a descoberta de novos fatos, regularidades, restrições, padrões e relacionamentos e não apenas consultas complexas e elaboradas com a finalidade de confirmar uma hipótese em função dos relacionamentos existentes.

A fase de Mineração de Dados caracteriza-se pelo emprego de um algoritmo que, diante da tarefa especificada, busca extrair o conhecimento implícito e potencialmente útil dos dados. A mineração de dados, na verdade, é uma descoberta eficiente de informações válidas e não óbvias de uma grande coleção de dados [11].

4.2. CLASSIFICAÇÃO

Na tarefa de classificação cada tupla ou registro pertence a uma classe dentre um conjunto pré-definido de classes. As tuplas compõe-se de atributos preditivos e um atributo objetivo, cujo valor definido pelo usuário indica a que classe essa tupla pertence. O atributo objetivo é do tipo categórico, ou discreto, isto é, pode tomar apenas um valor dentro de um conjunto de valores discretos, determinando classes ou categorias. Esse atributo pode ter valores discretos como SIM ou NÃO, um valor pertencente a um intervalo de números inteiros, etc.

O propósito da tarefa de classificação é descobrir algum tipo de relacionamento entre os atributos preditivos e o atributo objetivo que permita encontrar um conhecimento que possa ser utilizado para prever a classe de uma tupla ainda não classificada.

Um algoritmo de classificação pode analisar estes dados e determinar que valores

dos atributos preditivos tendem a ser relacionados com cada um dos atributos objetivos. O conhecimento descoberto pode então ser aplicado para prever um determinado evento. Observe que esse conhecimento será aplicado no atributo preditivo para o qual o valor do atributo objetivo ainda é desconhecido.

O conhecimento descoberto é normalmente representado na forma de regras **SE - ENTÃO**. Essas regras são interpretadas da seguinte forma: “**SE** os atributos preditivos de uma tupla satisfazem as condições no antecedente da regra, **ENTÃO** a tupla tem a classe indicada no conseqüente da regra”.

5. ALGORITMOS GENÉTICOS

Algoritmos Genéticos são modelos estocásticos e probabilísticos de busca e otimização, inspirados na evolução natural e na genética, aplicados a problemas complexos de otimização [12]. Problemas desta natureza envolvem tipicamente três componentes: variáveis, restrições e funções objetivo. As variáveis descrevem os vários aspectos do problema. As restrições delimitam os valores válidos para as variáveis e as funções objetivo envolvem a minimização ou a maximização de algum tipo de recurso e são empregadas para medir a qualidade de uma solução gerada.

A finalidade da otimização é encontrar, num espaço de busca multidimensional, onde são consideradas todas as possibilidades de solução de um determinado problema, um tal conjunto de valores que, ao serem aplicados às variáveis do problema, permitam minimizar (ou maximizar) uma função cujas variáveis devem obedecer às restrições impostas.

Encontrar soluções ótimas ou aproximadas para problemas de otimização NP-árduos está longe de ser uma tarefa fácil. Problemas desta complexidade são caracterizados por não linearidade, ruídos, descontinuidades ou espaço de busca extremamente grande. O emprego de métodos convencionais normalmente torna-se inviável em virtude do enorme esforço computacional exigido para sua solução.

Metaheurísticas como os Algoritmos genéticos (AG's) são estratégias adequadas para solução de problemas desta natureza [13]. Estas estratégias empregam mecanismos de busca que combinam escolhas aleatórias com o conhecimento obtido em resultados anteriores. Guiando-se através do espaço de pesquisa do problema evitam paradas prematuras em ótimos locais e proporcionam, conseqüentemente, melhores soluções. Os Algoritmos Genéticos não garantem a solução ótima, mas fornecem soluções próximas, ou aceitáveis (sub-ótimas). Além de serem mais facilmente aplicados em problemas complexos com muitas variáveis e restrições ou com grandes espaços de busca [14].

5.1. MODELAGEM DO ALGORITMO GENÉTICO

A abordagem proposta utiliza uma imagem multiespectral como fonte de dados para mineração de dados. Neste caso, cada pixel da imagem é tratado como um registro do banco de dados. O padrão é representado por um vetor de características para cada pixel, composto por um descritor local de cor e um descritor regional de textura, em cada uma das bandas visíveis (RGB), figura 1.

Uma vez selecionado as medidas de cor e textura, um vetor de padrões torna-se a completa representação de cada amostra física. Assim, cada amostra torna-se um ponto no espaço euclidiano bidimensional.

Como as medidas de cor e textura variam para cada amostra, variarão também os vetores de padrões que descrevem os objetos, esta variação ocorre não somente entre diferentes classes, mas também dentro de cada classe. Entretanto, considerando que o usuário tenha selecionado pixels representativos das classes A e B (classificação supervisionada), o

grau de associação entre os pixels de mesma classe será maior do que o grau de associação entre os pixels de classes distintas. A seleção adequada das características é um fator relevante, pois, o grau de separação entre as classes depende fortemente da escolha das medidas dos padrões selecionadas para uma aplicação.

O algoritmo genético empregará, então, este conjunto de treinamento como banco de dados, a fim de evoluir uma regra de associação que permita representar cada vez melhor as características dos pixels que pertençam a cada classe.

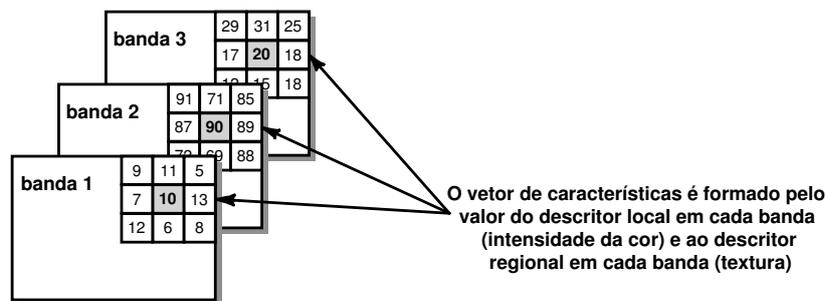


FIGURA 1 - Formação do vetor de características

A Tabela 1 apresenta, de forma ilustrativa, as medidas de textura e cor de 20 pixels selecionados como conjunto de treinamento. Foram escolhidos dez pixels de amostra para classe A e dez pixels de amostra para classe B.

TABELA 1 – Medidas de textura e cor

Classe	Pixel	Textura	Cor
A	1	1	2
	2	2	2
	3	3	4
	4	4	3
	5	2	1
	6	1	3
	7	2	4
	8	2	3
	9	3	2
	10	4	1
B	11	4	5
	12	3	6
	13	6	5
	14	5	3
	15	5	4
	16	3	3
	17	4	6
	18	4	4
	19	4	2
	20	5	5

Uma regra de associação define um relacionamento entre atributos preditivos (A condição de uma regra - parte **SE**) composto pelos descritores de cor e textura; e um atributo objetivo (consequência - parte **ENTÃO**) que define a classe a que pertence o pixel.

A partir dos dados da Tabela 1 seriam geradas duas regras de decisão, uma para cada classe:

Regra de associação 1

SE (Textura ≥ 1 E Textura ≤ 4) E (Cor ≥ 1 E Cor ≤ 4)
ENTÃO CLASSE1 \Downarrow Pixel n

Regra de associação 2

SE (Textura ≥ 3 E Textura ≤ 6) E (Cor ≥ 2 E Cor ≤ 6)
ENTÃO CLASSE2 \Downarrow Pixel n

Assim, é possível criar uma imagem temática através da aplicação destas regras sobre cada pixel da imagem. As figuras 2 e 3 demonstram que a ordem de aplicação destas regras pode produzir diferentes fronteiras de decisão.

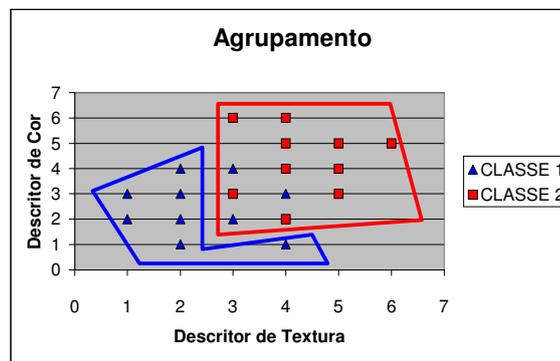


FIGURA 2 – Fronteira de decisão aplicando a regra de decisão (1 – 2)

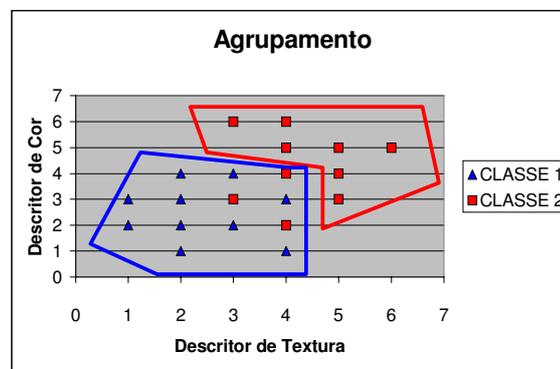


FIGURA 3 – Fronteira de decisão aplicando a regra de decisão (2 – 1)

6. TESTE E RESULTADOS

Esta seção apresenta diversos testes realizados com a finalidade de observar o desempenho da metodologia adotada. Foram realizados testes com texturas naturais, testes com imagens de satélites e testes com imagens médicas. Nestes testes, examinou-se o desempenho do descritor de cor e do descritor de textura proposto.

6.1. TESTE DE PRECISÃO

A Figura 4 apresenta um mosaico de texturas de cenas naturais extraídas de imagens de satélite (Landsat -7 TM) construída com a finalidade de verificar o desempenho do método

na presença de outras texturas. Cada textura que compõe o mosaico possui 32x32 pixels e demonstram a complexidade de variação tonal existente.

Foram selecionadas vinte amostras com janela de dimensão 3x3 pixels das quatro classes centrais da imagem. A Tabela 2 apresenta o coeficiente de variação para o conjunto de amostras selecionadas utilizando os descritores de cor e textura em cada um dos três canais (RGB).

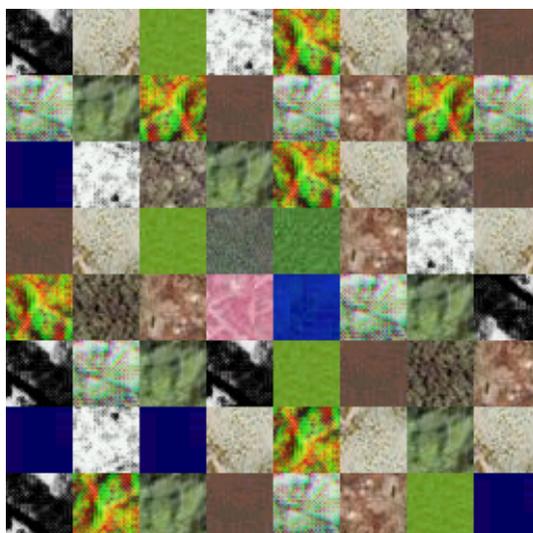


FIGURA 4. Mosaico de texturas naturais

TABELA 2 – Coeficiente de variação das amostras da figura 4.

Coeficiente de Variação das Amostras						
Classe	Cor			Textura		
	R	G	B	R	G	B
1	4,70	4,83	6,73	4,71	5,18	5,49
2	5,79	3,31	7,69	4,00	2,83	5,94
3	4,03	5,53	4,14	2,65	4,20	2,50
4	18,00	15,52	6,43	26,60	25,75	15,40

A Tabela 3 apresenta a Matriz de classificação para as regras de associação geradas pelo algoritmo genético. Verifica-se, neste exemplo, que a aplicação de cada regra definida para uma determinada classe não causaram omissões nem erros de classificação.

TABELA 3 – Matriz de de classificação para as regras de associação do AG

CLASSES	1	2	3	4	Desconhecida
1	100,00	0	0	0	0
2	0	100,00	0	0	0
3	0	0	100,00	0	0
4	0	0	0	100,00	0

A Figura 5 apresenta o percentual de pixels classificados corretamente, erroneamente e não classificados, para o conjunto de teste (figura 4), pelo critério de classificação por cor e textura. Pode-se observar também que a filtragem realizada pós-classificação, permitiu melhorar ainda mais o resultado.

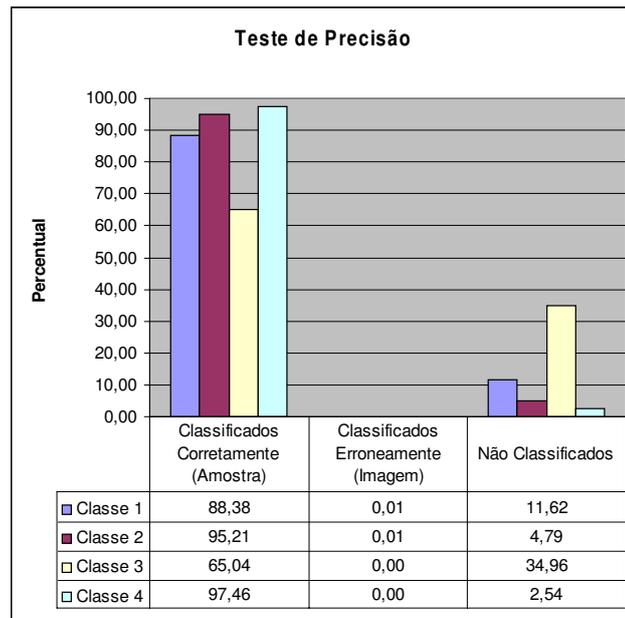


FIGURA 5. Resultado após a filtragem

A figura 6a. apresenta o resultado da classificação pelo critério de cor ou textura da imagem da figura 4. Pode-se notar ao centro as quatro texturas de onde foram extraídas as amostras (nas cores vermelho, laranja, roxo e verde). A figura 6b. apresenta o resultado da filtragem pela mediana da figura 6a. Pode-se notar o preenchimento das regiões interiores e eliminação de arestas e ruídos.

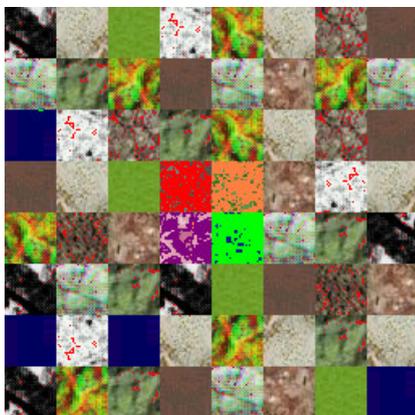


FIGURA 6a. Classificação pelo critério de cor ou textura da imagem da figura 4

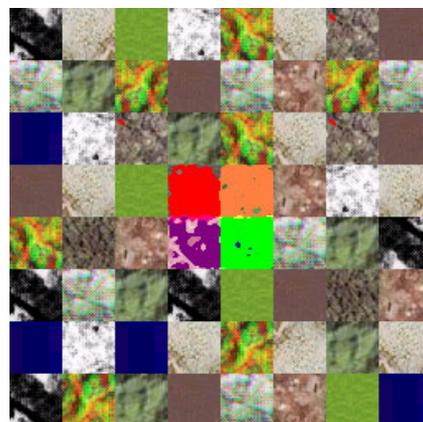


FIGURA 6b. Imagem filtrada

Percebe-se, a partir da Figura 6b. que a metodologia empregada permitiu distinguir de modo satisfatório as diferentes classes de texturas presentes na imagem.

6.2. TESTE COM IMAGEM DE SATÉLITE

A Figura 7 apresenta uma composição colorida das bandas 2/3/5, da região do parque Nacional, próximo a Brasília – DF, registrada em 14 de junho de 1985, pelo satélite Landsat-5 TM (DGI/INPE - <http://www.dgi.inpe.br/html/gal-1.htm>), utilizada com o propósito de verificar o desempenho do método com este tipo de imagem. Foram selecionadas vinte amostras com janela de dimensão 3x3 pixels.

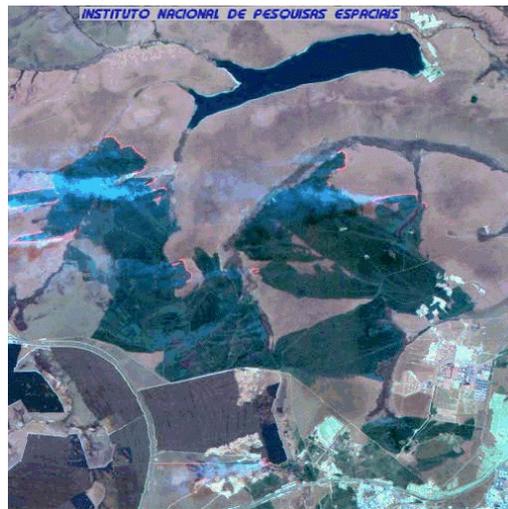


FIGURA 7. Composição colorida bandas 2/3/5 – Parque Nacional

A Tabela 4 apresenta a Matriz de classificação para as regras de associação geradas pelo algoritmo genético. Verifica-se, neste exemplo que, com exceção da classe 3, as demais classes obtiveram resultados maiores ou iguais a 90% de acerto.

TABELA 4 – Matriz de de classificação para as regras de associação do AG

CLASSES	1	2	3	4	Desconhecida
1	95,00	0	0	0	0
2	5,00	90,00	0	0	0
3	0	0	75,00	0	25,00
4	0	0	0	100,00	0

A figura 8a. apresenta o resultado da classificação pelo critério de cor e textura da imagem da figura 7. A figura 8b. apresenta o resultado da filtragem da figura 8a. Pode-se notar o preenchimento das regiões interiores e eliminação de arestas e ruídos. Nota-se uma correta classificação dos temas e boa definição dos limites.

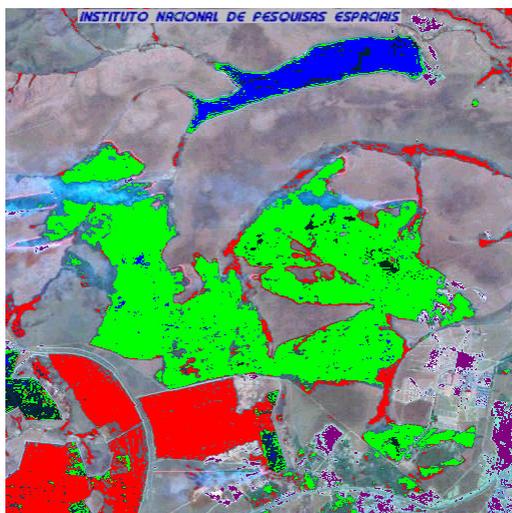


FIGURA 8a. Imagem da figura 7 classificada

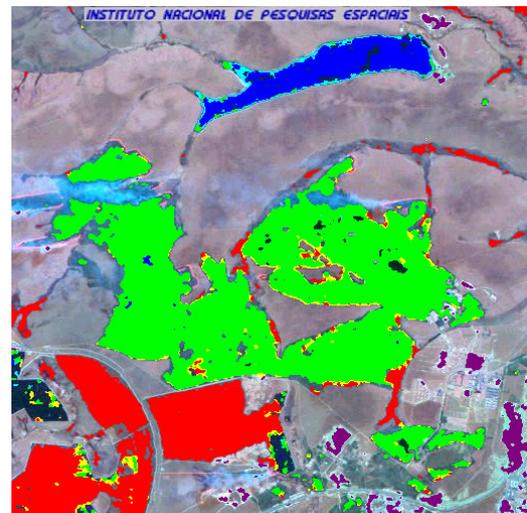


FIGURA 8b. Imagem da figura 8a. filtrada.

6.3. TESTE COM IMAGENS MÉDICAS

Dois novos testes foram realizados com imagens de emprego na medicina. Em ambos os casos, foram utilizados vinte amostras com janelas de extração com dimensão de 3x3 pixels. A figura 9a. apresenta a imagem de um melanoma (câncer de pele). A figura 9b. apresenta a mesma imagem após a aplicação de um filtro para localização das bordas. Pode-se observar que o resultado não foi satisfatório, pois a complexidade das texturas presentes não permitiu uma boa definição dos limites.



FIGURA 9a. Melanoma

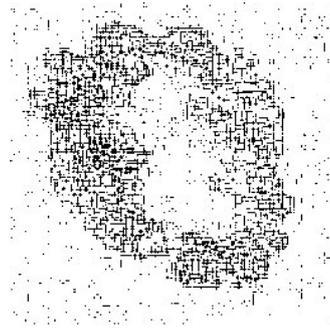


FIGURA 9b. Resultado da detecção das bordas

A figura 10a. apresenta o resultado da classificação da imagem da figura 9a., pelo critério de cor e textura, sem a preservação do fundo, para uma classe (melanoma). A figura 9b. mostra o resultado após a aplicação do filtro de mediana sobre a imagem 10a.



FIGURA 10a. Classificação pelo critério de cor e textura sem o fundo

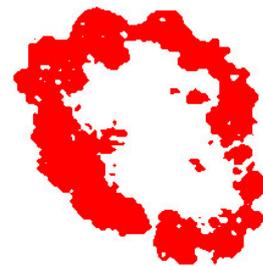


FIGURA 10b. Resultado da filtragem da figura 10a.

A figura 11a. apresenta o resultado da detecção de borda aplicada sobre a figura 10b. Nota-se uma definição de limites muito superior ao da figura 9b. A figura 11b. mostra a associação da imagem da figura 9a. com a imagem da figura 10b. Pode-se verificar a perfeita classificação do melanoma.

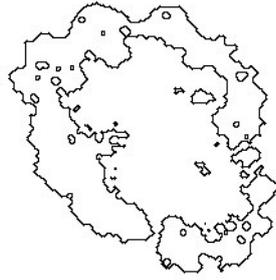


FIGURA 11a. Detecção das bordas da figura 10b.

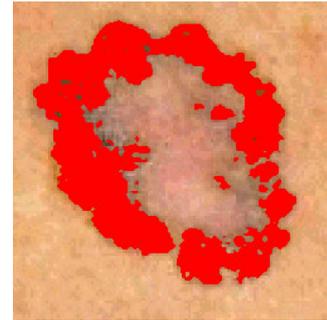


FIGURA 11b. Associação da figura 9a. com a figura 10b.

A figura 12a. apresenta uma imagem com amostras de células do sangue. Foram consideradas duas classes (roxo escuro e roxo claro). A figura 12b. apresenta o resultado da classificação utilizando o critério de cor e textura, onde nota-se que as células presentes foram corretamente classificadas.

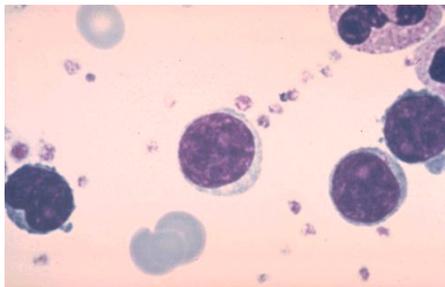


FIGURA 12a. Amostra de células do sangue

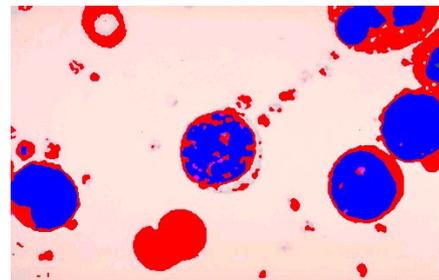


FIGURA 12b. Imagem classificada

7. CONCLUSÕES

Diversos trabalhos em processamento digital de imagens envolvem a identificação e classificação de regiões. Esta tarefa apesar de básica, envolve um elevado grau de complexidade, pois tenta reproduzir o sofisticado processo de classificação e reconhecimento feito pela visão humana.

A cor e a textura são importantes descritores utilizados no reconhecimento de padrões em imagens. Uma boa caracterização destes, permite identificar padrões ou realizar descrições sobre o conteúdo da imagem. A textura refere-se a um padrão visual que possui propriedades de homogeneidade que não resultam simplesmente de uma cor ou intensidade. A extração de suas características é considerada uma importante fonte de informação para segmentação de imagens.

Um modelo de Algoritmos Genéticos para classificação de pixels em uma imagem multiespectral foi desenvolvido. Este modelo, baseado em conceitos de mineração de dados por regras de associação, permitiu a evolução de regras que melhor caracterizassem um conjunto de pixels da imagem.

A implementação de uma ferramenta denominada AGCIM (Algoritmo Genético de Classificação de Imagens Multiespectrais) permitiu avaliar o modelo proposto para o problema de classificação de imagens. O AGCIM analisa um conjunto de amostras de diferentes classes e extrai a regra que melhor diferencie um grupo de pixels em relação a

odos os pixels da imagem. Visando otimizar o processo de busca de regras e obter melhor qualidade, foram implementadas técnicas evolutivas (método de inicialização, normalização linear, elitismo, busca local e interpolação adaptativa). Com a implementação do AGCIM, foram realizados testes experimentais com diversas imagens e foram apresentados os resultados obtidos. A partir desses testes, foi possível comprovar a viabilidade da utilização do Algoritmo Genético na classificação de imagens multiespectrais.

Outra contribuição do método proposto está na ampliação da capacidade de distinção de regiões. A associação de cor e textura amplia as possibilidades de identificação, através da análise de sua informação combinada nas diversas bandas.

Este trabalho empregou imagens multiespectrais que podem ser visualizadas na forma de composições coloridas de três bandas associadas aos canais Red, Green e Blue. Tais composições, capazes de sintetizar numa única imagem uma grande quantidade de informação, facilitam a interpretação dos objetos através da representação dessa informação em diferentes cores. Mas o método não se limita a apenas três bandas, podendo futuramente ampliar o número de bandas consideradas e aumentar em muito as possibilidades de análise (imagens hiperespectrais).

A classificação de imagens multiespectrais por evolução genética de regras abre caminho para uma gama de aplicações nos mais diversos campos do conhecimento, cuja identificação e classificação de regiões em imagens coloridas ou multibandas tornam-se necessárias. Tal possibilidade descortina diversas alternativas de trabalhos futuros.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Nunes, E.O. Emprego da Dimensão Fractal para Análise de Texturas em Imagens Multiespectrais. 2001. 103f. Dissertação (Mestrado em Ciência da Computação) Universidade Federal Fluminense, Niterói.
- [2] Nunes, E.O.; Conci, A. Texture Segmentation Considering Multi Band, Multi Scale Resolution and Affine Invariant Roughness. In: XVI Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens (SIBGRAPI). Anais, ISBN:1530-1834, São Carlos, 2003. pp.254-261.
- [3] Nunes, E.O.; Conci, A. Segmenting Multi Bands Images by Color and Texture Analysis. In: 10th International Workshop on Systems, Signals and Image Processing IWSSIP' 03 , Prague, Czech Republic - Czech Technical University in Prague, 2003.[3]
- [4] Conci, A.; Nunes, E.O. Multi-bands Image Analysis Using Local Fractal Dimension. Proceedings of SIBIGRAPI Brazilian Symposio on Computation Graphics, october 15-20, 2001, Florianópolis, SC. Image Proc. and Vision, 2001. p. 91-98.
- [5] Nunes, E.O.; Conci, A. Técnicas De Descrição Regional Baseadas em Textura. In: 2º Congresso Temático de Aplicações de Dinâmica e Controle da Sociedade Brasileira de Matemática Aplicada e Computacional (SBMAC). São José dos Campos. Anais, ISBN: Editores: J. M. Balthazar, G. N. da Silva, M. Tsuchida, M. Boaventura, L. S. Goes e J. D. S. Silva, Série Arquimedes, Volume 2 , 2003.
- [6] Nunes, E.O.; Conci, A. Determinação da Dimensão Fractal de Conjunto de Pontos à Imagens de Satélites”, Anais do 1º Congresso Temático de Aplicações de Dinâmica e Controle (APPLICON) da Sociedade Brasileira de Matemática Aplicada e Computacional (SBMAC), São Carlos, Anais, 2001.[2]
- [7] Parker, J. R. Algorithms for Image Processing and Computer Vision. John Wiley & Sons, Toronto, 1997.
- [8] Gonzalez, R. C.; Woods, R. E. Processamento de Imagens Digitais. São Paulo: Edgard Blucher, 2000.

- [9] Nunes, E.O.; Conci, A. O Coeficiente de Hurst e o Coeficiente de Variação Espacial na Segmentação de Texturas Multiespectrais. In: 4º Congresso Temático de Aplicações de Dinâmica e Controle da Sociedade Brasileira de Matemática Aplicada e Computacional (DINCON). Bauru, 2005.
- [10] Marques, J. S. Reconhecimento de Padrões Métodos Estatísticos e Neurais. IST Press, Portugal, 1999.
- [11] Bigus, J. P. Data Mining with Neural Network – Solving Business Problems from Application Development to Decision Support. McGraw-Hill, 1996.
- [12] Goldberg, D. E. Genetic Algorithms in Search, Optimization, and Machine Learning. Reading, MA: Addison-Wesley Publishing Company, Inc., 1989.
- [13] Nunes, E.O.; Conci, A. Implementação de Algoritmos Genéticos no Balanceamento Interativo de Linhas de Montagem. In: VI Simpósio de Pesquisa Operacional da Marinha/VII Simpósio de Logística da Marinha (SPOLM). Escola de Guerra Naval, Rio de Janeiro, 2003.[1]
- [14] Nunes, E.O.; Conci, A. Otimização de Linhas de Montagem por Algoritmos Genéticos: Análise, Aperfeiçoamento e Implementação. Pôster In: XXXV Simpósio Brasileiro de Pesquisa Operacional da Sociedade Brasileira de Pesquisa Operacional (SOBRAPO), Natal, 2003.[2]