

ANÁLISE DE COR PARA O RECONHECIMENTO DE ESPÉCIES FLORESTAIS¹

*Pedro Luiz de Paula Filho²
Ângelo Marcelo Tusset³*

Resumo: O presente trabalho busca demonstrar que o uso de cores, pode ser uma forma eficiente, rápida e com baixo custo computacional na pré-identificação de espécies florestais. Sendo consideradas imagens não tratadas de amostras de madeira da flora brasileira, serão extraídas informações de cor, buscando-se assim similaridades desta amostra com outras amostras de uma base de treinamento, identificando-se assim a qual espécie florestal ela pertence. Aborda-se também neste trabalho a teoria geral de processamento de imagens, enfocando canais de cor e histograma, reconhecimento de padrões, extração de características e classificadores. Para a base de treinamento e testes foram usadas imagens adquiridas junto ao laboratório de anatomia da madeira da Universidade Federal do Paraná (UFPR), sendo a aquisição das imagens feitas por meio de uma câmera fotográfica digital de baixo custo. Foram usadas para este estudo um total de 163 imagens de 14 espécies florestais distintas, e cada imagem foi subdividida em 540 sub-imagens, para aumentar eficiência do treinamento do classificador, perfazendo um total de 88.560 sub-imagens. Destas foram extraídas características baseando-se em áreas de interesse dos histogramas dos canais de cor RGB, HSV, Lab e XYZ, e gerados vetores de características usados para o treinamento e classificação usando-se uma rede neural artificial (RNA). Com a utilização da metodologia proposta obteve-se uma taxa de reconhecimento de 80,9%.

Palavras chave: Processamento de Imagens, Reconhecimento de Padrões, Identificação de Espécies Florestais.

INTRODUÇÃO

A identificação correta das espécies florestais é uma necessidade primordial para a atividade do manejo florestal e comércio seguro das espécies madeireiras. Diferente de quando as árvores estão na floresta onde se tem flores, frutas e folhas para identificá-las, saber a qual espécie uma tora pertence é bastante complexo [1].

Para determinar possíveis aplicações de diferentes espécies de madeira, é primordial um estudo detalhado de sua estrutura, tornando possível sua classificação e agrupamento em espécies [2], esta identificação é importante em varias áreas, como citam KHALID et al [1] e TOU et al [3], destacando-se sua aplicação em indústrias, construções, evitando fraudes onde algum revendedor de madeira possa misturar a uma espécie nobre uma espécie mais barata, ou ainda, tentar exportar madeiras de espécies que estão em extinção.

Em geral o reconhecimento é feito por especialistas muito bem treinados, porem poucos atingem uma boa precisão na classificação, devido ao tempo de treinamento, logo não são abundantes para atender a demanda da indústria [3]. Outro fator a ser levado em conta é que no processo de identificação manual consome-se bastante tempo, podendo gerar desvio de atenção por ser um processo repetitivo e conseqüentemente podendo levar a erros, o que pode tornar inviável para checar cargas de exportação. Com isso gera-se uma lacuna que a computação pode preencher.

O desenvolvimento de programas computacionais autônomos que consigam assemelhar-se ao sistema visual humano é ainda é um desafio, onde a meta é analisar e/ou interpretar imagens, obtendo informações suficientes para distinguir objetos de interesse de forma confiável, e esta área de estudo denomina-se visão computacional. Ela pode ser dividida em dois níveis de abstração, processamento digital de imagens (PDI) e análise de imagens. O PDI busca técnicas para capturar, representar e transformar imagens, permitindo extrair e identificar informações e melhorar a qualidade visual de certos aspectos, melhorando a extração de características que serão usadas posteriormente. A análise de imagens envolve técnicas como segmentação da imagem em regiões de interesse (ROI), descrições dos objetos, reconhecimento e classificação, usando imagens como entrada e produzindo outro tipo de saída [4][5][6].

A visão computacional tem sido usada na indústria madeireira, desde os anos 80, porem seu uso tem se restringido a identificar a qualidade da madeira, ou buscar por defeitos, e para isso tem sido usados dispositivos como ultra-sons, microondas, ressonância magnética, raios-X, laser, câmeras e espectrômetros, o que em geral é bastante caro [3].

Em KHALID et al [1] é apresentado um sistema de reconhecimento de espécies florestais, tendo como base mais de 1949 imagens de 20 diferentes espécies presentes na Malásia, as madeiras eram cortadas, fervidas e passadas em um micrótomo. Para a aquisição das imagens foi utilizada uma câmera de padrão industrial e alto desempenho (JAI CV-M50) e para a iluminação foi desenvolvido um *led array*.

Após a aquisição, a imagem foi realçada, passando por um filtro de passa alta, contraste e equalização de histograma, foi calculada uma matriz de co-ocorrência (GLCM). Os atributos extraídos foram aplicados em uma RNA. Foram usadas 1753 imagens para treinamento e 196 para teste. As taxas de reconhecimento chegaram a 95% de acerto entre as 20 espécies.

Em TOU et al [3] foram apresentados dois experimentos visando identificar boas características para diferenciar espécies florestais, através do uso de GLCM, sendo utilizada uma RNA. Para a realização dos experimentos foram utilizadas 360 imagens obtidas no Centro de Inteligência Artificial e Robótica (CAIRO), as mesmas usadas em [1].

No primeiro experimento obteve-se uma taxa de reconhecimento de 72%, e no segundo obteve-se o reconhecimento de 60%.

A quantidade de sistemas que visem efetivamente o reconhecimento de espécies florestais é pequeno, segundo [1] isso se dá devido aos seguintes fatores:

- Dificuldade na obtenção de uma base de imagens;
- Falta de técnicas comprovadas de reconhecimento de espécies florestais;
- As pesquisas atuais usam equipamentos caros;
- A falta de especialistas em classificação nos países em desenvolvimento.

Para esse estudo buscou-se desenvolver uma aplicação de baixo custo, para uma pré-identificação de espécies florestais baseando-se em cores de imagens macroscópicas (máximo 10 vezes de aumento) de madeiras. Para tanto, foram extraídos atributos das espécies por meio de reconhecimento de padrões usando-se a análise de características de cor, definindo-se protocolos desde a aquisição das imagens até técnicas computacionais que permitissem a diferenciação entre espécies.

RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões segundo DUDA et al [7] pode ser definido como a área que consiste no reconhecimento de regularidades significativas em meios ruidosos e complexos.

Para a análise e reconhecimento de padrões em imagens é necessário escolher características que devem ser extraídas da imagem selecionada e estabelecer quais são as informações relevantes para uma boa identificação [5]. Em CONCI et al. [5] são descritos dois grupos de descritores: de forma e aspecto. O descritor de forma considera a região inteira de objetos encontrados, o que não se aplica em imagens de espécies florestais onde, não necessariamente, existem objetos a serem identificados. Logo, o uso de características relacionadas ao aspecto da imagem são mais eficientes para este tipo de problema, e podem ser definidas como textura, cor, acabamento, rugosidade, etc.,

Segundo TUCERYAN et al. [8] a textura é a característica visual mais importante para identificação de estruturas homogêneas em uma imagem, pois suas propriedades representam a superfície ou estrutura de um objeto [9]. Segundo PARKER [10] ao se observar uma imagem, podemos facilmente conectar regiões com similaridade nos tons de cinza, ou ainda, objetos coloridos, mesmo com variações de luminosidade, ou sobreposição de objetos, e para buscar a definição de como descrever uma região dentro de uma imagem, a forma natural é interpretar como o sistema visual humano o faz, e ele usa a textura como sendo uma dessas formas [4].

Como dentre as características de aspecto a mais simples de se extrair de uma imagem é a cor [5], buscando-se um sistema de classificação rápido e eficiente, idealizou-se um esquema que pode ser observado na Figura 1, em que a partir de uma imagem é feito uma pré-identificação e caso o resultado da classificação tenha ficado acima de um limiar, pré-estabelecido, ela será classificada sem depender de análises de textura. caso contrário ela passará por uma nova classificação usando classificadores mais complexos, como textura (Filtros Gabor, Wavelets, Matriz de co-ocorrência em tons de cinza, Fractais).

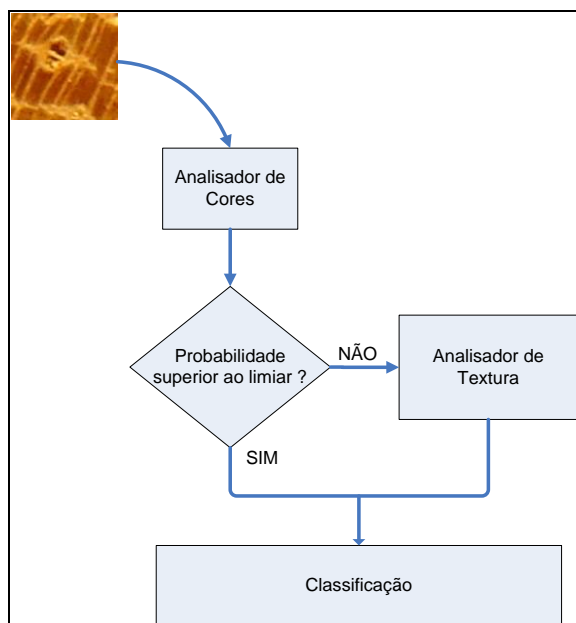


Figura 1 – Fluxo de classificação do sistema

Segundo PEDRINI *et al.* [4] e LIU *et al.* [11] a cor é uma propriedade importante na análise de imagens realizada pelos seres humanos, seja com ou sem o auxílio do computador, sendo a característica mais dominante e visualmente mais descritiva em uma imagem. Para se observar uma cor, frequentemente usa-se um histograma, que é uma das formas de se representar a distribuição de valores de pixel de uma imagem. Ao observá-lo, tem-se uma noção instantânea sobre as características de cor de uma imagem, visto que por sua forma é possível identificar informações relevantes, tais como intensidade média e distribuição dos valores de pixel [5].

De acordo com GONZALES e WOODS [6], o histograma é uma função discreta que pode ser representado pela equação 1, onde r_k = representa o k -ésimo elemento de cor, n_k = número de pixels na imagem cuja cor corresponde a r_k , n = número total de pixels na imagem e k é o número de valores de pixel da imagem digitalizada e p_k = resultado da função discreta representada por r_k . Obtendo-se assim, o número de ocorrências de uma determinada cor em uma imagem, representando a distribuição de probabilidade dos valores dos pixels [12][13], independente de variação quanto à posição, resolução ou rotação das imagens [14].

$$p_k(r_k) = \frac{n_k}{n} \quad (1)$$

A informação obtida através de histogramas em diferentes canais de cores permitirá a geração de um vetor de características, que tem por objetivo extrair informações de uma imagem com a finalidade de interpretar os dados e buscar similaridade entre objetos, ou seja, envolve a busca de padrões detectáveis [5][7]. Segundo OLIVEIRA *et al.* [15], o uso de histogramas extraídos a partir dos canais de cor é simples, mas muito discriminativo.

A partir de um vetor de características extraído de uma imagem, passa-se para uma nova etapa que permitirá a interpretação destes dados para classificar classes distintas. Para tanto usam-se classificadores, onde um classificador supervisionado passa por duas fases, o treinamento, onde são apresentados ao sistema exemplos dos padrões a serem reconhecidos, e a classificação, que é quando são apresentados ao sistema os padrões desconhecidos, que são comparados com os dados de treinamento, possibilitando o cálculo de sua similaridade e conseqüentemente sua classificação [5][7].

Para esse experimento foi usada uma rede neural artificial (RNA), que procura solucionar os problemas de reconhecimento de padrões, através da simulação do sistema nervoso humano, que possui a capacidade de aprender e agir perante situações desconhecidas, com base em experiências passadas. Entre suas vantagens estão a adaptatividade, velocidade, tolerância a falhas e a otimalidade [16].

MATERIAIS E MÉTODOS

Para garantir que os dados usados nessa pesquisa possam ser reproduzidos nos mais diferentes locais de coleta de imagem, as amostras foram somente lixadas, técnica que não necessita de estrutura em campo, como as utilizadas em laboratório, que garantirão melhor visualização de estruturas, como por exemplo, cozimento da madeira, utilização de micrótomo, aplicação de corantes, entre outros.

Neste projeto foram utilizadas 164 imagens de 14 espécies florestais, adquiridas no Laboratório de Anatomia da Madeira da UFPR (Universidade Federal do Paraná). Na Figura 2 têm-se algumas amostras das imagens utilizadas.



Figura 2 – Imagens de algumas espécies

Para a aquisição das imagens foi definido um protocolo, que garantisse uma padronização de distância e iluminação, para tanto foi construído um suporte, onde a câmera era fixada e duas lâmpadas alógenas garantissem a constância de luz. Foi utilizada uma câmera fotográfica digital SONY DSC T20, com o modo macro e auto-foco ativados, onde a amostra de madeira estava distante aproximadamente a dois centímetros da lente. As fotos foram obtidas com uma resolução de 3264 x 2448 pixels.

As espécies utilizadas para o desenvolvimento do sistema foram selecionadas utilizando dois aspectos que poderiam gerar confusões no momento da classificação, a cor (claras, escuras e intermediárias), e similaridade, ou seja, amostras que normalmente podem gerar dúvidas em sua classificação a olho nu, como por exemplo, o Cumaru (*Dipteryx SP*) e o Ipê (*Tabebuia SP*).

Depois de adquiridas, as imagens receberam um número correspondente a qual espécie ela pertence, para sua identificação nos passos seguintes do desenvolvimento do aplicativo. Estas espécies estão descritas na Tabela 1.

Tabela 1 – Composição do Banco de Imagens

Id	Nome Popular	Nome Científico	No. de Imagens
0	Andiroba	<i>Carapa guianensis</i>	12
1	Angelim-Pedra	<i>Hymenolobium petraeum</i>	10
2	Cedrinho	<i>Erismia uncinatum</i>	13
3	Cumaru	<i>Dipteryx SP</i>	11
4	Eucalipto	<i>Eucalyptus SP</i>	11
5	Goiabão	<i>Planchonela pachycarpa</i>	12
6	Ipê	<i>Tabebuia SP</i>	12
7	Jatobá	<i>Hymenaea SP</i>	12
8	Marupá	<i>Simarouba amara</i>	11
9	Mogno	<i>Swietenia macrophyla</i>	15
10	Pau Amarelo	<i>Euxylophora paraenses</i>	10
11	Sucupira	<i>Bowdichia SP</i>	11
12	Tatajuba	<i>Bagassa guianensis</i>	12
13	Tuari	<i>Couratari SP</i>	12

Para que os conjuntos de padrões necessários para o treinamento e validação dos classificadores obtivessem robustez mesmo com um número reduzido de amostras disponíveis, as imagens foram recortadas, a fim de que cada pedaço fosse analisado individualmente, independente de sua posição espacial na imagem original. Após testes certificou-se que com imagens de 120 x 120 pixels apresentavam bons resultados, gerando um total de 540 recortes para cada uma das imagens, resultando um total de 88.560 sub-imagens que foram divididas igualmente para formar as bases de treinamento e validação.

Para a extração de características, que é a etapa em que os atributos da imagem são quantificados e a informação da imagem é transformada em números, com o objetivo de se buscar a similaridade entre as imagens através das informações colhidas [7]. Adotou-se uma estratégia baseando-se na cor, onde a orientação ou posição específica de algum objeto na imagem são informações irrelevantes.

A escolha de quais canais a utilizar foi feita através de percepção visual e estatística, buscando canais de cores que evidenciassem a diferença entre as espécies e a similaridade inter espécies, como pode ser visto na Figura 3, onde os histogramas do canal B (blue) do RGB demonstram uma grande diferença nos dois recortes da espécie A, e certa similaridade com a espécie B (destaque em vermelho), o que serve para descartar esse canal. Já o canal G (green) apresenta similaridades entre os histogramas da espécie A e diferenças, significativas, em relação a espécie B (destaque em verde).

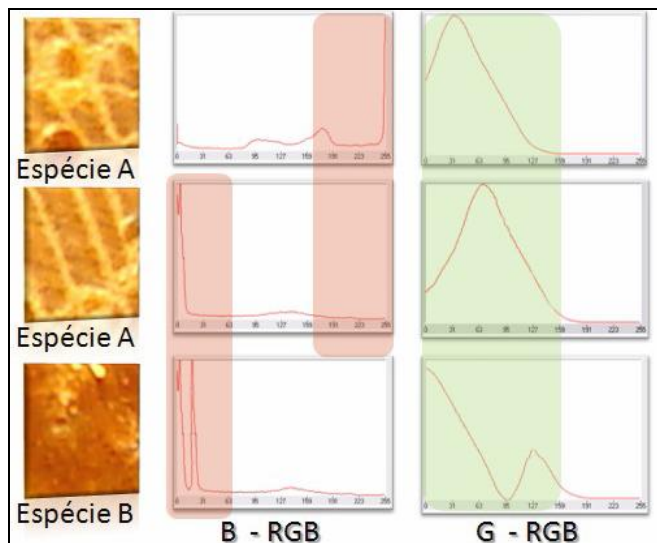


Figura 3 – Escolha dos canais de cores

No final da análise dos histogramas, optou-se por usar os canais de cores, G (verde) do RGB, S (saturação) do HSV, L (luminância) do CIELUV e X do XYZ. Como algumas áreas do histograma não apresentavam informações relevantes, ou ainda, geravam confusões de classificação, foram feitos “janelamentos”, que são particionamentos de faixas de cores no histograma, que permitirão ter representações de parte do histograma na tarefa de reconhecimento, sendo que para cada um dos canais de cores escolhidos foram definidos diferentes faixas, descritos na Tabela 2.

Tabela 2 – Janelamento dos Canais de Cores

Canal	Início	Final
L (LUV)	144	215
L (LUV)	216	255
S (HSV)	45	127
S (HSV)	128	255
G (RGB)	73	127
G (RGB)	128	255
X (XYZ)	51	115
X (XYZ)	128	255

Para cada uma das oito áreas de interesse, três características foram calculadas: quantidade de pixels, pixel médio e mediana, sendo estes, na seqüência normalizados entre 0 e 1, através da equação 2, onde max e min são os valores máximo e mínimo de saída (1 e 0), x_{max} e x_{min} são os maiores e menores valores presentes de cada uma das características e x o valor atual.

$$norm = \left(\frac{x - x_{min}}{x_{max} - x_{min}} * max - min \right) + min \quad (2)$$

Ao final deste processo cada imagem gera um vetor de característica composto por 24 atributos.

Uma rede neural foi construída usando-se como método de aprendizagem o algoritmo *Backpropagation*, que após receber o padrão de entrada propaga da entrada para a saída o resultado das unidades (neurônios), e após isso calcula o erro na camada de saída então retro-propaga os valores e pesos da camada de saída até a conexão da camada de entrada com a camada escondida [17]. As 24 características extraídas anteriormente formam a camada de entrada da rede neural, a camada

escondida é composta por 14 unidades e a camada de saída é formada pelas 14 espécies presentes nas amostras.

Na Tabela 3 pode-se observar em vermelho a relação entre o percentual de acerto e o número de amostras disponíveis, onde percebe-se que quanto menor o número de amostras gera-se menor treinamento e conseqüentemente mais confusão entre as espécies. Em azul mostra-se a confusão entre seis espécies onde a espécie 0 (Andiroba) tem amostras muito semelhantes com as espécies: Cedrinho, Jatobá, Mogno, Sucupira e Tatajuba, diminuindo consideravelmente o desempenho geral do classificador. Onde das 31.968 imagens que compunham a base de validação 20.971 imagens foram classificadas corretamente chegando a um percentual de acerto na classificação de 65,60%.

Tabela 3 – Percentuais de acerto da matriz de confusão gerada usando-se as sub-imagens

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	Nº de Imagens
0	17%	0%	15%	1%	4%	2%	6%	13%	1%	12%	5%	13%	13%	1%	2024
1	0%	76%	12%	1%	0%	0%	0%	0%	1%	2%	1%	8%	1%	0%	1457
2	1%	5%	81%	0%	2%	1%	1%	4%	0%	2%	0%	1%	1%	0%	3494
3	4%	1%	5%	64%	3%	0%	1%	4%	0%	1%	1%	11%	6%	0%	2321
4	1%	0%	4%	1%	85%	4%	0%	0%	0%	1%	1%	0%	1%	2%	2700
5	1%	0%	6%	0%	7%	62%	10%	0%	5%	1%	4%	2%	1%	1%	2539
6	2%	0%	5%	0%	2%	2%	62%	0%	2%	0%	2%	15%	5%	2%	2375
7	2%	1%	8%	7%	1%	1%	0%	72%	0%	4%	1%	0%	4%	0%	2577
8	0%	0%	0%	0%	1%	0%	1%	0%	87%	7%	0%	0%	0%	2%	2399
9	4%	1%	7%	1%	4%	1%	1%	4%	7%	61%	1%	2%	3%	3%	2184
10	3%	0%	3%	1%	11%	15%	6%	1%	3%	3%	47%	3%	3%	1%	1929
11	0%	4%	4%	1%	0%	0%	8%	0%	0%	1%	1%	74%	6%	0%	2296
12	3%	1%	5%	1%	1%	0%	7%	1%	1%	3%	0%	21%	52%	4%	1941
13	1%	0%	2%	0%	8%	0%	10%	0%	15%	3%	1%	0%	5%	55%	1732

DESENVOLVIMENTO

O desenvolvimento do software foi realizado na linguagem de programação C++ sendo utilizado o ambiente C++ Builder, para a realização do pré-processamento, extração de características e reconhecimento. No pré-processamento da imagem foi utilizado a biblioteca “Opencv” (*Open Source Computer Vision Library*), que consiste de várias funções e classes que implementam algoritmos de PDI. Para realizar o reconhecimento de padrões, foi utilizado o “JavaNNS v1.1” para fazer a simulação, e o SNNS que contém um aplicativo chamado SNNS2C que converte a rede neural em um programa C ANSI, que foi anexado ao programa.

Um aplicativo foi desenvolvido com o objetivo de identificar a espécie florestal a qual uma imagem pertence, trazendo ao usuário o percentual de confiabilidade do acerto, além da percentagem de que tal imagem pertença a outras espécies. Tal percentual e interatividade foram possíveis através do recorte da imagem em pedaços menores.

A demonstração do processo de classificação, usado pelo sistema, pode ser observado através da Figura 4, onde, após a escolha de uma imagem no sistema, essa é dividida em sub-imagens e extraída as características de cor descritas anteriormente, permitindo assim a análise de cada pedaço da imagem por uma rede neural individualmente, retornando assim sua classificação, como foi feito no processo de aprendizado. Após esse processo, uma contagem de votos é realizada, e os resultados com percentuais mais relevantes serão exibidos, destacando-se o maior percentual. Tal processo pode ser observado na Figura 5, que exibe a interface do sistema.

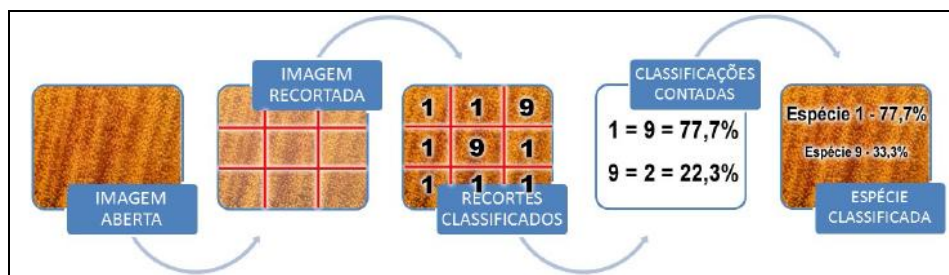


Figura 4 – Funcionamento do sistema, usando recorte fictício de nove partes



Figura 5 – Interface do sistema demonstrando o percentual de acerto

Para a verificação final do sistema foram usadas 68 imagens de sete espécies florestais diferentes (Tabela 4). Onde 55 das 68 imagens foram classificadas de forma correta, obtendo-se um percentual de acerto de 80,9%, sendo que das sete espécies testadas duas apresentaram 100% de acerto, o que pode ser verificado na Tabela 5, que exhibe a matriz de confusão do aplicativo final.

Tabela 4 – Espécies utilizadas para a avaliação do Software final com interface para usuário

Id.	Nome Popular	Nome Científico
0	Cumaru	<i>Dipteryx SP</i>
1	Eucalipto	<i>Eucalyptus SP</i>
2	Ipê	<i>Tabebuia SP</i>
3	Marupá	<i>Simarouba amara</i>
4	Sucupira	<i>Bowdichia SP</i>
5	Tatajuba	<i>Bagassa guianensis</i>
6	Tuari	<i>Couratari SP</i>

Tabela 5 – Matriz de Confusão do Sistema final de Interface com o Usuário (em percentuais)

	0	1	2	3	4	5	6
0	60%	0%	0%	10%	0%	30%	0%
1	0%	100%	0%	0%	0%	0%	0%
2	0%	0%	100%	0%	0%	0%	0%
3	10%	0%	0%	70%	0%	20%	0%
4	0%	0%	10%	0%	90%	0%	0%
5	0%	0%	0%	0%	0%	100%	0%
6	10%	30%	0%	10%	0%	0%	50%

CONCLUSÕES

Como optou-se em usar uma forma de captura com baixo custo e que pudessem ser reproduzidas em qualquer local de coleta, as amostras apresentam problemas o que podem prejudicar a classificação como pode ser mostrado nos detalhes das Figuras 6 e 7, onde na primeira aparece a queimadura da madeira devido a fricção da serra e na segunda aparecem as marcas de navalha na imagem.



Figura 6 – Marca da serra mostrando uma “queimadura” na imagem. Espécie Pau-Amarelo




Figura 7 – Marcas da navalha, fazendo sulcos na madeira. Espécie Marupá

Neste trabalho foi demonstrada a proposta de usar a cor como elemento pré-classificador de espécies florestais. Foi feito o desenvolvimento de um sistema desde o protocolo de obtenção das imagens, em campo, até o desenvolvimento da aplicação final. O uso da cor, que apesar de ser a forma mais simples de se extrair características, mostrou-se um bom delimitador de espécies, onde espécies como Eucalipto (1), Ipê (2) e Tatajuba (5) obtiveram 100% de acerto, já outras como Andiroba tiveram uma margem de reconhecimento bastante baixa, demonstrando a necessidade de classificadores mais robustos, como de textura.

Sugere-se que esta seja a primeira etapa de um classificador mais eficiente, sendo a cor um descritor rápido para uma pré-avaliação e quando o percentual de certeza deste classificador atingir um limiar de certeza pré-definido esta imagem é classificada. Quando o classificador não conseguir ter certeza absoluta de seu resultado (abaixo do limiar), a imagem seria encaminhada a um classificador de textura, usando-se técnicas como: matriz de co-ocorrência em níveis de cinza (GLCM), matriz de co-ocorrência de texton (TCM), filtros Gabor, Wavelets e Fractais.

Outra abordagem é fazer o agrupamento de imagens através das cores, onde este primeiro classificador filtraria a qual grupos de espécies a amostra pertence (claras, escuras, intermediárias) e este resultado seria aplicado a novo classificador que, ao invés de buscar entre todas as espécies, buscaria a similaridade em um grupo reduzido, garantindo assim, melhor precisão.

REFERÊNCIAS

- [1] KHALID M., LEE, E.L.Y., YUSOF, R., NADARAJ, M. Design Of An Intelligent Wood Species Recognition System. **IJSSST**, Vol. 9, No. 3, September 2008.
- [2] PAULA, J. E., SILVA JÚNIOR, F. G.; SILVA, A. P. P. Caracterização anatômica de madeiras nativas de matas ciliares do centro-oeste brasileiro. In: **Scientia Forestalis**, n.º 58, p. 73-89, IPEF. Piracicaba, 2000.
- [3] TOU, J. Y.; LAU, P. Y.; TAY, Y. H. **Computer Vision-based Wood Recognition System**. Proceedings of International Workshop on Advanced Image Technology (IWAIT 2007), (pp. 197-202). Bangkok, 2007.
- [4] PEDRINI, H., SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. São Paulo: Ed. Thomson, 2008.
- [5] CONCI, A., AZEVEDO, E. LETA, F. R. **Computação Gráfica: Teoria e Prática**. Rio de Janeiro: Elsevier, 2008. v. 2
- [6] GONZALEZ, R. C., WOODS, R. E. **Processamento de Imagens Digitais**. Ed. Edgard Blucher, 2000.
- [7] DUDA, R. O., HART, P. E., STORK, D. G. **Pattern Classification: Second Edition**, Wiley, 2000.
- [8] TUCERYAN, M., JAIN, A. K. Texture Analysis. In: CHEN, C.H.; PAU, L.F.; WANG, P.S.P. **The Handbook of Pattern Recognition and Computer Vision** (2nd Edition). World Scientific Publishing Co., 1998.
- [9] SONKA, M., HLAVAC, V., BOYLE. R. **Image Processing, Analysis, and Machine Vision**. Third Edition. Thomson Learning, 2008.
- [10] PARKER, J. R. **Algorithms for Image Processing and Computer Vision**. John Wiley & Sons Inc., 1997.
- [11] LIU, G., YANG, J. **Image retrieval based on the texton co-occurrence matrix**. Pattern Recognition, 2008.
- [12] SWAIN, M. J., BALLARD, D. H. **Color Indexing**. **International Journal of Computer Vision**, Ed.7, 1991.
- [13] BANON, G. J. F. **Formal introduction to digital image processing**. Disponível em: <<http://urlib.net/dpi.inpe.br/banon/1998/07.02.12.54>>. Acesso em: fev. 2009.
- [14] BENDER, T. C. **Classificação e recuperação de imagens por cor utilizando técnicas de inteligência artificial**. Dissertação em Computação Aplicada – Universidade do Vale dos Sinos. São Leopoldo / RS, 2003.
- [15] OLIVEIRA, L. E. S., CAVALIN, P. E., BRITTO, A. S., KOERICH, A. L. Inspeção Automática de Defeitos em Madeiras de Pinus usando Visão Computacional. **Revista de Informática Teórica e Aplicada**, 2008.

[16] BLUM, A. **Neural networks in C++ Object-oriented framework for building connectionist system**. Wiley, 1992.

[17] **SNNS. Stuttgart Neural Network Simulator**. Disponível em: <www.ra.cs.uni-tuebingen.de/SNNS/>. Acesso em: out. 2008.

¹ Projeto apresentado no DINCON 2009 – 8th Brazilian Conference on Dynamics, Control and Applications. Auxiliado através de capacitação docente Universidade do Contestado – Canoinhas / Porto União. Curso de Ciência da Computação

² Universidade do Contestado - UnC, Porto União, Brasil, pedro@pu.unc.br

³ Universidade do Contestado - UnC, Porto União, Brasil, a.m.tusset@gmail.com