

# ANAIIS

## EICTI 2017

6° Encontro de  
Iniciação Científica

2° Encontro de Iniciação  
ao Desenvolvimento  
Tecnológico e Inovação

4 a 6 de outubro de 2017

Universidade Federal da Integração Latino-Americana (UNILA)  
Av. Tarquínio Joslin dos Santos, nº 1000  
Foz do Iguaçu, Paraná – Brasil



Realização:



Apoio:



# EXTRAÇÃO DE CARACTERÍSTICAS E RECONHECIMENTO AUTOMÁTICO DE ESPÉCIES FLORESTAIS

**Manuely da Silva de Souza, Skarlat.**

Estudante do Curso de saúde coletiva, bolsista, IC-UNILA - ILACVN – UNILA;  
E-mail: smdsd.souza.2016.@aluno.unila.edu.br;

**Kapp, Marcelo N.**

ILATIT – UNILA.  
E-mail: marcelo.kapp@unila.edu.br.

## 1 INTRODUÇÃO

As espécies florestais podem ser facilmente reconhecidas quando se encontram em seu habitat natural, porém depois que a árvore é extraída e cortada em tábuas, apenas um especialista é capaz de afirmar de qual espécie a referida tábua está relacionada. Com isso, a falta de fiscalização apropriada, pode fazer com que madeiras de uma determinada espécie sejam comercializadas como se pertencessem a outra, ou espécies mais valorizadas podem ser trocadas por outras de menor valor, podendo acarretar prejuízo ao comprador, até mesmo um problema ambiental, com o comércio de madeiras extraídas de espécies ilegais.

Embora, as autoridades se esforcem cada vez mais para obter um controle nesse tipo de indústria, o controle apropriado para a comercialização dependeria de um grande número de especialistas. Entretanto, o orçamento do governo é geralmente limitado, não sendo assim possível. Nesse contexto, busca-se uma alternativa com menores custos, fazendo-se um estudo para o desenvolvimento de softwares que sejam capazes de reconhecer uma espécie florestal a partir da imagem capturada de uma madeira, auxiliando o ser humano no processo de classificação.

## 2 METODOLOGIA

A metodologia de estudo está relacionada a aplicação de técnicas de conjuntos de classificadores para a categorização de diferentes espécies florestais. Está organizada em 4 partes principais de acordo com cada técnica utilizada.

**1) EoC Simples:** Primeiramente, uma imagem digital de uma determinada espécie florestal, denotada  $im$ , é apresentada ao sistema. Em seguida, são aplicadas algumas etapas para converter esta imagem em níveis de cinza e posteriormente, em um conjunto de quadrantes que será usado para alimentar um conjunto de classificadores. Isto é, a imagem é dividida em um número  $N$  de quadrantes com a mesma dimensão, gerando um conjunto de sub-imagens denotado  $im^i$ , sendo  $1 \leq i \leq N$ . Para cada  $im^i$  é extraído um vetor de características  $vi$  para representar a informação contida nesta imagem com um número reduzido de variáveis. Cada vetor

vi e então passado como entrada para o classificador  $c_i$ , sendo que  $C$  consiste no conjunto de todos os classificadores do sistema, e cada classificador  $c_i$  produz um resultado de reconhecimento distinto. Finalmente, os dados apresentadas por todos  $c_i$  são usadas para selecionar quais os membros de  $C$  (ou seja, quais classificadores) são os mais competentes para reconhecer a imagem  $im$ . Os resultados destes classificadores são então combinados e o reconhecimento final de  $im$  é concretizado.

**2) EoC Heterogêneo:** Da mesma forma que na técnica anterior, uma imagem  $im$  também é dividada em sub-imagens  $im^i$ , entretanto, classificadores  $c_i$  distintos são gerados de cada sub-imagem, de acordo com diferentes conjuntos de características realizadas em cada quadrante da imagem  $im$ . Finalmente, o conjunto de classificadores heterogêneos gerado é usado para a realizar a classificação final das amostras.

**3) Bagging:** A partir da extração de características realizada para cada quadrante da imagem, a técnica de geração de classificadores Bagging é aplicada para a geração de um conjunto de classificadores  $C$ . Nessa técnica as amostras surgem por amostragem aleatória, a diversidade é obtida com o uso de diferentes subconjuntos de dados aleatoriamente criados com reposição, sendo que, cada subconjunto é usado para treinar um classificador do mesmo tipo.

**4) Random Subspace:** Da mesma forma como ocorre na técnica supracitada, a partir de uma base de treinamento composta por amostras geradas com características extraídas de cada sub-imagem  $im^i$ , a técnica de geração de conjuntos de classificadores Random Subspace é utilizada. Na técnica de Random Subspaces, além de embaralhar as amostras, há uma redução das dimensões dos vetores de entrada, pois em alguns casos, os vetores possuem grande dimensionalidade. Com isso, busca-se aumentar a diversidade das amostras para aumentar a precisão na decisão.

Em todas as técnicas estudadas, as saídas dos classificadores são combinadas por meio de voto majoritário com base em suas decisões individuais, sendo que, a classe que tiver o maior número de votos, será a resposta final. Buscando assim, criar um sistema de classificação com desempenho melhor por meio da combinação apropriada de diversos classificadores.

### 3 FUNDAMENTAÇÃO TEÓRICA

Na literatura, observamos que o desenvolvimento de sistemas de reconhecimento espécies florestais tem atraído o interesse de vários centros de pesquisa nos últimos anos [Connors et al, 1997; Khalid, 2008]. Em muitas das soluções propostas, entretanto, os requisitos em termos de pré-processos aplicados a madeira antes que esta seja processada computacionalmente faz com que estas abordagens sejam de difícil aplicação na prática [Khalid et al, 2008; Muniz et al, 2008]. Mas recentemente, em [Paula Filho et al, 2010] foi proposto um sistema de reconhecimento capaz de reconhecer espécies de madeiras a partir de câmeras de

baixo custo, demonstrando que é possível resolver este problema sem necessariamente investir em equipamentos de custo elevado. Ainda, em [Martins et al, 2012] foi demonstrado que o uso de imagens capturadas com câmeras microscópicas possibilita que a tarefa envolva um número grande de espécies florestais (112 contra 20 em [Paula Filho et al,2010b]), mantendo o mesmo nível de desempenho de reconhecimento (por volta de 80% de acerto). Os resultados supracitados indicam que é possível desenvolver um sistema automático para reconhecer espécies florestais, e que as taxas de reconhecimento atuais estão próxima de um nível aceitável de performance (próximo ao desempenho dos especialistas humanos). Consequentemente, acreditamos que a aplicação de técnicas avançadas de reconhecimento de padrões que se demonstraram eficazes para melhorar o desempenho deste tipo de sistema, tais quais múltiplos classificadores que podem contribuir para diminuir o nível de erro no reconhecimento de espécies florestais.

#### **4 RESULTADOS**

Considerando a metodologia apresentada na Seção 3, os seguintes parâmetros foram utilizados nesta pesquisa. Classificador base: K-NN com parâmetros 1-NN, 3-NN e 5-NN. As técnicas de extração de características: GLCM, LPQ, LBP. Diferentes números de classificadores base foram gerados para compor os conjuntos de classificadores de acordo com as diferentes técnicas de geração.

A base de imagens original de 2240 amostras foi dividida em 3 conjuntos independentes: treinamento, validação e teste. O conjunto de treinamento continha 10 amostras por classe, já os conjuntos de validação e teste, 6 e 4 respectivamente. As bases de treinamento e validação foram utilizadas para a coleta de resultados e análises dependendo dos diferentes parâmetros aplicados. Ao final, a técnica que apresentou os melhores resultados sobre o conjunto de validação foi utilizada para a obtenção dos resultados finais sobre o conjunto de teste. As imagens originais, durante as extrações de características, foram divididas em três diferentes quantidades de quadrantes diferentes: 1, 4, e 16. Os resultados estão listados na Tabelas 1 para o conjunto de teste com as imagens divididas em 16 quadrantes, pois obtiveram melhores resultados em validação, e as diferentes técnicas testadas. Cada resultado foi obtido após uma média de 10 repetições de cada experimento, nas quais cada repetição está relacionada à diferentes repartições aleatórias dos conjuntos de treinamento, validação e teste.

**Tabela 1** - Resultados com EoC de 16 membros dividindo a imagem em 16 quadrantes sobre o Conjunto de Teste.

<b>Técnica de Extração de Características</b>	<b>1-NN</b>
GLCM	46,53 (0,99)
LBP	67,20 (1,88)
CLBP (R=1, N=8)	61,25 (1,86)
LPQ - Uniform window- windows size 9	82,96 (1,26)
LPQ - Gaussian window - window size 9	81,92 (1,46)
LPQ - Blackman -window size 9	83,93 (1,35)
GLCM+LBP+CLBP+LPQU+LPQG+LPQB	84,03 (1,12)
LBP+LPQU+LPQG+LPQB	85,93 (1,05)
LPQU+LPQG+LPQB	87,05 (0,95)
Bagging LPQ (16 membros)	89,90 (0,70)
<b>Random Subspaces (16 membros)</b>	<b>90,46 (0,81)</b>

## 5 CONCLUSÕES

Os resultados demonstraram que a utilização de conjunto de classificadores produz resultados superiores, mesmos nos casos mais simples de apenas dividir as imagens em mais quadrantes. Conjunto de classificadores heterôgeneos, i.e., formados com classificadores gerados de diferentes conjuntos de características obtiveram resultados melhores em relação a conjunto de classificadores construídos a partir da criação de membros apenas por quadrantes. Finalmente, utilizando a técnica de construção de conjunto de classificadores Random Subspaces com LPQ obteve o mais alto desempenho de reconhecimento.

## 6 PRINCIPAIS REFERÊNCIAS BIBLIOGRÁFICAS

R. Conners, D. Kline, P. Araman e T. Drayer. Machinevision technology for the forest products industry. IEEE Computer, 30:43, 1997.

P. L. Paula Filho, L. S. Oliveira, A. Britto Jr e R. Sabourin, Forest Species Recognition using Color-based Features, 20th International Conference on Pattern Recognition, Istanbul, Turkey, 23-26 October, 2010.

G. I. B. Muniz, M. E. Carneiro e T. Silva. The use of the infrared and multivariate analytic for identification of species of timber. IV Congresso Florestal Latinoamericano, 2008.

J. Martins, L. S. Oliveira, S. Nisgoski e R. Sabourin, A Database for Automatic Classification of Forest Species, Machine Vision and Applications, doi:10.1007/s00138-012-0417-5, 2012.

Kapp, M. N.; Bloot, R. ; Cavalin, P. R. ; Oliveira, L. E. S. . Automatic Forest Species Recognition based on Multiple Feature Sets. In: International Joint Conference on Neural Networks, 2014, Beijing-China. Proceedings of the International Joint Conference on Neural Networks (IJCNN2014), 2014.