

Avaliação de Métodos de Extração de Características Aplicadas à Classificação da Qualidade da Madeira.

Natália Fernandes Soares (Universidade Estadual Paulista - UNESP) - natalia.f.soares@unesp.br

Gustavo das Neves Ubeda (Universidade Estadual Paulista - UNESP) - gustavo.ubeda@unesp.br

André Luis Debiasio Rossi (Universidade Estadual Paulista - UNESP) - andre.rossi@unesp.br

Resumo: É imprescindível que as indústrias forneçam produtos e serviços de qualidade para sua sobrevivência e sucesso. Esse cenário também ocorre para pequenas e médias indústrias madeireiras, fornecedoras de matéria-prima. Neste setor, a classificação da qualidade da madeira é um fator decisivo para agregar valor ao seu produto e satisfazer as exigências dos clientes. Essa tarefa geralmente é realizada por especialistas humanos sujeitos a diferentes tipos de subjetividade. Portanto, atualmente, a automação desse processo é indispensável para as indústrias desse setor. Para esse propósito, técnicas de Aprendizado de Máquina (AM) têm sido usadas com sucesso para a inspeção visual automática de tábuas de madeira. Entretanto, o desempenho preditivo dessas técnicas depende das características que serão usadas para descrever as imagens, processo conhecido como extração de características. Portanto, o presente estudo tem como objetivo investigar métodos de extração de características para o problema da classificação da qualidade da madeira utilizando técnicas de AM. Para isso, foram analisados experimentalmente três métodos de extração e duas técnicas de AM para a classificação de 374 imagens de tábuas de madeira coletadas em uma indústria do setor. Essas imagens foram separadas por um especialista em três níveis de qualidade e para cada método de extração foi criada uma base de dados, em que cada atributo correspondeu a uma característica obtida. Os modelos gerados pelas técnicas de AM foram comparados em relação ao desempenho preditivo e os melhores resultados foram obtidos pela Máquina de Vetores de Suporte (SVM) para o método de extração de Histograma de Gradientes Orientados (HOG).

Palavras chave: Aprendizado de Máquina, Qualidade, Classificação, Extração de Características

Comparison of feature extraction methods applied to wood quality classification

Abstract: Products and services of high quality are imperative for the survival and success of industries. Current, this also arises for small and medium timber industries, suppliers of raw materials. In this sector, wood quality classification is a decisive factor in adding value to the product and meet customer requirements. This task is usually performed by human specialists subject to different kinds of subjectivity. Therefore, the automation of this process is currently essential for the industries of this sector. For this purpose, Machine Learning (ML) techniques have been successfully used for automatic visual inspection of wooden boards. However, the predictive performance of these techniques depends on the characteristics used to describe the images, a process known as feature extraction. Therefore, the present study aims to investigate feature extraction methods for the problem of wood quality classification using ML techniques. For such, three feature extraction methods and two ML techniques were analyzed for the classification of 374 wood board images collected in an industry of the sector. These images were separated by a specialist in three quality levels and a database was created for each extraction method, where each attribute corresponds to a characteristic. The models generated by the ML algorithms were compared concerning their predictive performance and the best results were achieved by a Support Vector Machine (SVM) using the Histogram of Oriented Gradients as the feature extraction method.

Key-words: Machine Learning, Quality, Classification, Feature Extraction

1. Introdução

A qualidade do produto é fundamental para o sucesso de qualquer empresa, incluindo indústrias fornecedoras de matéria prima. Portanto, é primordial que o processo de seleção desse material seja muito bem definido e que seja executado com grande precisão. Na indústria madeireira, setor importante da economia brasileira, a preocupação com esse processo é um dos pontos mais importantes para atender às expectativas do cliente. A análise das características físicas das superfícies das tábuas resultantes do desdobro da madeira constitui um dos pontos fundamentais para agregar valor ao produto.

Essa classificação é realizada pela identificação de defeitos da madeira, como nós, rachaduras e medulas, e em sua maioria é realizada por operadores humanos, estando sujeita a uma alta subjetividade. A automação da inspeção visual por meio de imagens tem sido implementada como forma de aprimorar esse processo reduzindo a subjetividade e os custos e aumentando a precisão e a eficiência. A inspeção visual automática tem sido realizada com sucesso em diferentes áreas com o uso de técnicas de Aprendizado de Máquina (AM) por atingir êxito nos processos de mineração de dados e reconhecimento de padrões.

Pode-se definir AM como um estudo de algoritmos e sistemas que são aprimorados automaticamente conforme a experiência advinda, geralmente, de uma base dados e gerando um modelo para posteriormente ser usado na predição de dados futuros, para outros tipos de tomada de decisão sob incerteza ou para a explicação ou compreensão dos padrões ou regularidades que foram detectados (FLACH, 2012). No entanto, a viabilidade das técnicas de AM e o seu desempenho preditivo dependem, em grande parte, de quais características das imagens são mais informativas para o problema em questão.

Para o reconhecimento automático de imagens, a representação em uma matriz de pixels, pode não ser a ideal, o que torna necessário o uso de um descritor de características para a extração das informações mais relevantes para do problema sob análise, simplificando a sua representação. Esse processo de obtenção de características é denominado extração de características, e como atualmente há uma abundante variedade de métodos, faz-se necessário identificar qual é o mais apropriado para a detecção de defeitos em produtos, uma vez que o desempenho de cada método está suscetível a muitos fatores.

Segundo Mahram *et. al* (2012) uma parte considerável dos métodos de extração de características propostos para a classificação de defeitos de madeira pode não ter habilidade de distinção suficiente para imagens com formas complexas, textura irregular e uma ampla variabilidade dentro da mesma classe de padrões. Destarte, é necessário investigar o conjunto de características usadas para descrever uma imagem, pois representa um dos principais fatores para o sucesso de um algoritmo de AM.

O objetivo do presente estudo é investigar e comparar a influência de diferentes métodos de extração de características de imagens digitais no desempenho de modelos de Aprendizado de Máquina aplicados para o problema da classificação da qualidade da madeira. Além de avaliar as características extraídas por cada método separadamente, este trabalho também avalia a combinação dessas informações.

Os métodos de extração estudados no presente trabalho foram selecionados devido ao sucesso em trabalhos relacionados, como Mahram et al. (2012). São eles: *Local Binary Patterns* (LBP) (OJALA et al.1996), Histograma de Gradientes Orientados (HOG, do inglês,

Histogram of Oriented Gradients) e as medidas baseadas nas matrizes de co-ocorrência de níveis de cinza (GLCM, do inglês, *Gray Level Co-occurrence Matrix*), como as propostas por (HARALICK et al. 1973). A partir das características geradas pelos diferentes métodos e pela combinação dessas, as técnicas de aprendizado de máquina Redes Neurais Artificiais (RNA) e Máquinas de Vetores de Suporte (SVM) foram investigadas para a classificação da qualidade da madeira.

2. Revisão da literatura

No contexto da Indústria 4.0, os sistemas de manufatura são atualizados a um novo nível de inteligência, onde estes passam a se comportar de modo quase que totalmente autônomo, necessitando da intervenção humana apenas para processos de manutenção e desenvolvimento. As técnicas de AM, uma das bases no qual se alicerça essas tecnologias, proporciona grande independência e flexibilidade nas mais variadas aplicações. Por exemplo, Kumar (2008) utilizou SVMs e redes neurais de múltiplas camadas (*Multi-Layer Perceptron*- MLP) para detectar defeitos em tecidos produzidos continuamente enquanto que Zhang *et. al* (2015) implementou as SVMs para classificar maçãs defeituosas.

Essas técnicas também têm sido investigadas para a classificação de defeitos da madeira. A importância do uso da madeira está cada vez mais evidenciada, como afirma Wang *et al.* (2010); uma vez que devido suas propriedades e sustentabilidade dos processos de fabricação, a madeira, ao longo dos anos, vem sendo muito utilizada como matéria prima em diversas finalidades como: combustível, construção de casas, ferramentas, armas, embalagens, papel e muitas outras. Deste modo, é imprescindível o reconhecimento de diferentes espécies de madeira, detecção de defeitos e classificação da qualidade para obter produto final de maior valor agregado.

É possível observar que, geralmente, o desempenho preditivo utilizando o extrator de características GLCM é menor quando comparado ao do LBP. Em Pramunendar *et al.* (2013), por exemplo, utilizando o classificador SVM e o extrator GLCM, a maior acurácia atingida foi de 78,82%, Utilizando o mesmo conjunto de dados, Mahram *et al.* (2012) obteve uma acurácia de 95,78% usando LBP enquanto que para o GLCM foi de 94,37%, ambos utilizando SVM como classificador. No entanto, ao se combinar os dois métodos de extração foi possível atingir uma marca de 100% de acerto, sendo que os mesmos resultados foram obtidos com o classificador K-Vizinhos-mais-próximos (*K-Nearest-Neighbor* - K-NN).

No trabalho de Khalid *et al.* (2010b), a conclusão de qual método seria o mais adequado para análise de madeira fundamentou-se em vários fatores, como complexidade computacional, taxa de classificação e tempo de execução, dado que a textura da madeira é considerada como uma textura natural, e sua variação é mais ampla do que outros padrões de textura, constatou-se que o extrator LBP (mais especificamente LBP-16 + 24) é apropriado para analisar a textura da madeira.

Zhang *et al.* (2008) propôs em seu trabalho a identificação da espécie de madeira utilizando métodos baseados em autocorrelação, pois o *gradient local auto-correlations* (GLAC), método utilizado, usa autocorrelações espaciais e orientacionais de gradientes locais para extrair informações mais ricas de estrutura de imagens e obter mais poder discriminativo do que métodos baseados em histogramas padrão, como HOG.

Uma comparação do desempenho de diferentes classificadores para o problema da qualidade de tábuas de madeira foi realizada por Affonso *et al.* (2017) usando duas

estratégias: usando descritor de textura como extrator de características e em seguida um classificador tradicional de AM, tais como K-NN, SVM e RNA; e a outra utilizando as imagens como matrizes de pixels em escala de cinza com o classificador Rede Neural Convolutiva (*Convolutional Neural Network* - CNN) sem passar por nenhum pré-processamento. Como resultado, foi possível observar que a acurácia do CNN sem o pré-processamento das imagens foi bem menor do que a das outras técnicas. Uma das hipóteses para esse desempenho inferior das CNN é a pequena quantidade de imagens utilizadas, menos de 400.

Nota-se, pois, que o desempenho dos classificadores está diretamente relacionado com as características selecionadas para a classificação, ressaltando, portanto a importância de se estudar as características e o método mais adequados para a finalidade em questão.

3. Métodos de extração e técnicas de AM

Nesta seção são apresentados os métodos de extração de características utilizados neste trabalho, incluindo GLCM, LBP e HOG (Seção 3.1). Além disso, são apresentadas as técnicas de AM utilizadas para a classificação da qualidade de madeira a partir das características extraídas pelos descritores.

3.1 Métodos de extração

Como o desempenho das técnicas de AM dependem de quais atributos estão sendo usados para descrever o problema sob análise, faz-se necessário investigar diferentes métodos de extração de características para o problema da classificação da qualidade da madeira. Esse estudo também se faz necessário porque, como muitas pesquisas indicam, nenhum método de extração é absolutamente melhor que outro, sendo que, muitas vezes, a combinação apropriada dos métodos pode resultar em melhor desempenho preditivo das técnicas de AM (ZHANG *et al.*, 2008). Nesta seção é apresentada uma breve descrição sobre os métodos de extração de características investigados no presente projeto de pesquisa.

Matriz de Co-ocorrência de Níveis de Cinza (GLCM)

Diferentes características podem ser obtidas a partir da GLCM, a qual pode ser entendida como uma tabulação de quantas combinações diferentes de valores de intensidade dos pixels (níveis de cinza) ocorrem em uma imagem. Substancialmente a função desse operador é identificar texturas em uma imagem através de um conjunto de estatísticas das ocorrências de cada nível de cinza nos diferentes pixels ao longo de diversas direções. Estas podem ser descritas por estatísticas de primeira ou segunda ordem para gerar a matriz de frequências relativas (HARALICK *et al.* 1973).

A co-ocorrência, na sua forma geral, pode ser especificada por uma matriz de frequências relativas $P(i, j, d, \theta)$, sendo i e j as propriedades encontradas na distância d e orientação θ ($0^\circ, 45^\circ, 90^\circ, 135^\circ$); ou seja, cada entrada (i, j) na matriz GLCM corresponde ao número de ocorrências do par de níveis de cinza.

Em suma, segundo a doutora Simone Vasconcelos, a matriz (obrigatoriamente quadrada) de co-ocorrência, representa em cada elemento a_{ij} o número de vezes que ocorreu uma transição do nível de cinza Z_i para Z_j considerando a distância d entre os pixels vizinhos i e j na direção θ .

Local Binary Pattern (LBP)

Proposto por Ojala *et al.* (1996), o LPB é um operador que classifica os pixels de uma imagem

pelo limiar da vizinhança de cada pixel e considera o resultado como um número binário. Inicialmente utilizado para reconhecimento facial e posteriormente na caracterização de texturas, ele é calculado a partir de um conjunto P de amostras igualmente espaçadas sendo elas distribuídas sobre uma circunferência de raio R com centro sobreposto no pixel. Uma sequência P de valores binários, $TP = S(g_0 - g_c), S(g_1 - g_c), \dots, S(g_{P-1} - g_c)$ (onde $S(x) = 1$ se x não for negativo e 0 caso ao contrário) é obtida a partir das intensidades de cada amostra, g_p , e do próprio pixel, g_c , em que $0 \leq p \leq P$.

Uma sequência de bits T_p é mapeada em um valor inteiro; foi determinado que uma sequência que possui no máximo duas transições, de 0 para 1 e de 1 para 0, são as mais importantes para a caracterização de texturas (OJALA *et al.*, 1996). Baseado nessa constatação um código invariante a rotação LBP_R é definido como sendo o número 1 da sequência.

O LBP uniforme invariante a rotação é igualmente invariante quanto a transformações monotônicas da escala de cinza, no entanto essa representação não captura a informação de contraste. Foi proposto, portanto, um descritor de contraste local, VAR_{p,R}, também invariante a rotação.

Histograma de Gradientes Orientados (HOG)

O histograma de gradientes orientados (HOG) foi proposto por Dalal *et al.* (2006) para reconhecimento de pessoas, mas também é empregado para o reconhecimento de diferentes objetos. A ideia básica consiste em informações locais da forma, frequentemente bem descritos pela distribuição (histogramas) de direção de gradientes, mesmo sem informações precisas sobre o local. Os gradientes (derivadas de x e y) de uma imagem são úteis porque a magnitude dos gradientes é grande ao redor dos contornos, regiões de mudanças abruptas de intensidade. Os contornos de uma imagem carregam muito mais informação sobre a forma do objeto do que regiões planas.

No HOG, uma imagem é dividida em diversas partes, chamadas de células (por exemplo de 8×8 pixels), que podem ser retangulares (R-HOG) ou circulares (H-HOG). Para cada pixel de uma célula o gradiente e sua orientação é calculado e um histograma das orientações das bordas de cada célula é armazenado. A combinação dos histogramas é usada como um vetor de característica da imagem. Portanto, o HOG captura a estrutura de gradientes ou bordas, que é uma característica da forma local. Como o método é sensível à variação da iluminação, cada célula é normalizada considerando uma região maior, denominada de bloco (por exemplo, 32×32 pixels). Como pode ocorrer uma sobreposição de blocos, as células podem pertencer a mais de um bloco. O HOG é relativamente invariante à rotação e translação dentro de cada célula.

Na Figura 1 é apresentado um exemplo do cálculo do HOG. Na Figura (a), a imagem original com uma pessoa no centro. Na imagem (b) são mostrados os gradientes e suas direções calculados para a partir da imagem original. Na imagem (c) é possível observar os pesos de um modelo de classificação treinado sobre os HOGs de pessoas. As regiões com maior destaque são as regiões de contorno, especialmente cabeça, ombros e pés.

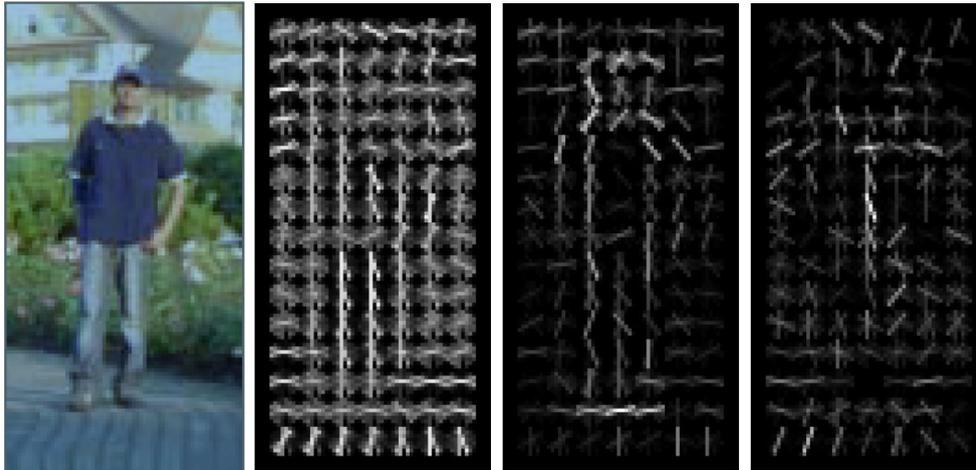


Figura 1 - Imagem original (a), o cálculo dos gradientes orientados (b) e o peso atribuído por um modelo treinado por um algoritmo de aprendizado de máquina.

3.2 Técnicas de AM

O método mais comum é o aprendizado indutivo, isto é, criação do modelo a partir de dados previamente observados. Assim, o modelo é induzido pelo conjunto de dados escolhidos para aquele determinado problema, esse conjunto de dados representa o domínio do problema a ser resolvido. As técnicas de AM que serão aplicadas para as bases de dados criadas com os diferentes métodos de extração de características serão as Máquinas de Vetores de Suporte (SVM, do inglês, *Support Vector Machines*) e as Redes Neurais Artificiais (RNA) (FLACH, 2012), haja vista que essas técnicas conseguiram ótimos resultados em trabalhos anteriores que utilizaram o mesmo conjunto de imagens (AFFONSO 2017; RODER 2017).

Máquinas de Vetores de Suporte (SVM)

As SVMs são baseadas na Teoria do Aprendizado Estatístico, mais especificamente, na Teoria de Minimização do Risco Estrutural (VAPNIK, 2013). Os vetores de suporte utilizados pelas SVMs são exemplos que estão próximos da superfície de decisão e portanto, são os mais difíceis de serem classificados. São esses exemplos que influenciam diretamente na localização da superfície de decisão. Para o problema de classificação, o princípio das SVMs está em encontrar um hiperplano ótimo que separa satisfatoriamente os dados de entrada. O hiperplano ótimo é definido como aquele para o qual a margem de separação entre as classes é maximizada. A fronteira de decisão de uma SVM é definida pela combinação linear dos vetores de suporte.

Para tratar problemas não lineares, as SVMs usam funções de mapeamento, chamadas de kernels, que mapeiam o espaço de entrada para um outro espaço de maior dimensionalidade chamado espaço de características, onde os dados possivelmente podem ser classificados (FLACH, 2012).

Redes Neurais Artificiais (RNA)

As RNA são inspiradas no cérebro e no sistema nervoso e são compostas por unidades de processamento simples, denominados neurônios ou nós, dispostos em uma ou mais camadas e interligados por meio de conexões. Os neurônios artificiais são unidades de processamento de informação que realizam um trabalho relativamente simples: recebem

entradas de outros neurônios ou do meio externo e usam essas entradas para computar um sinal de saída, que é propagado para outras unidades ou para o meio externo (HAYKIN, 1994).

As arquiteturas mais conhecidas são a *feedforward* de camada simples (*Perceptron*) e de múltiplas camadas (*Perceptron* Multicamadas - MLP), redes totalmente recorrentes (Rede de Hopfield) e parcialmente recorrente (Rede de Elman). Os pesos associados a cada conexão entre os neurônios são responsáveis pelo armazenamento do conhecimento. Um algoritmo de aprendizado de RNA deve ser capaz de atribuir pesos a essas conexões durante o processo de treinamento, de maneira que a rede neural seja capaz de classificar corretamente o maior número de exemplos possíveis do conjunto de treinamento e seja capaz de generalizar para novos exemplos.

4. Experimentos

Foram realizados experimentos para avaliar diferentes métodos de extração de características para a tarefa de classificação da qualidade das imagens de tábuas de madeira usando diferentes técnicas de AM (Seção 3). As características extraídas por cada método geraram diferentes conjuntos de dados. Na apresentação dos resultados na seção seguinte, foi utilizada a abreviação de cada método: GLCM = G, HOG = H, LBP = L (Seção 3.1). Além disso, a combinação dos métodos e dos diferentes valores para os seus parâmetros, geraram outros conjuntos de dados: “L_G”, “L_G_H_3”, “L_H_2”, “G_H_2”, “G_H_3”, “L_H_3” e “L_G_H_3”. O nome “H_3” refere-se ao método HOG com (3,3) células por bloco e os nomes “H_1” e “H_2” representam o mesmo parâmetro com valor (1,1) e (2,2), respectivamente.

Posteriormente desenvolveu-se a automatização do código para avaliar diferentes parâmetros e combinações. Os métodos de extração de características investigados foram usados a partir do módulo *feature* do pacote *scikit-image*¹ (VANN DER WALT *et al.*, 2014).

Foram utilizadas 374 imagens para os experimentos, e em virtude dessa quantidade cada conjunto de dados possui 374 exemplos.

Para cada conjunto de dados, modelos foram induzidos utilizando as técnicas de aprendizado de máquina SVM e RNA para a tarefa de classificação da qualidade (Seção 3.2). Empregou-se SVM com o Kernel Gaussiano. Os parâmetros foram definidos de acordo com o pacote *scikit-learn*², ou seja, custo = 1, e largura do kernel = auto. A rede utilizada foi uma MLP, em que os parâmetros são: número de neurônios na camada oculta (50, 50) e taxa de aprendizado constante igual a 0,01. Os experimentos foram realizados utilizando-se o método de amostragem por validação cruzada com 10 partições (10-CV). Neste método, para cada iteração, 9 partições são usadas para treinamento do modelo e a partição restante é usada para teste, ou seja, estimar o desempenho preditivo dos modelos. Esse desempenho é dimensionado pela acurácia e pela acurácia balanceada para as 10 partições de teste. Dada uma matriz de confusão para duas classes, a acurácia é a taxa dos exemplos que são classificados corretamente pelo modelo de treinamento: VP+VN, em que VP são observações classificadas como positiva e que possuem o rótulo de classe positiva, denominadas verdadeiros positivos e o mesmo conceito para VN, só que para observações negativas, denominada verdadeiros negativos sobre o total de exemplos. Na matriz de confusão, as previsões são divididas naquelas classificadas corretamente (VP e VN) e

¹ <http://scikit-image.org>

² <http://scikit-learn.org>

incorretamente, que incluem os falsos positivos (FP) e falsos negativos (FN), sendo que TP+FP equivale a P, e a mesma lógica segue para TN+FN é igual a N. Essa relação é expressa na Equação 1.

$$acurácia = \frac{VP+VN}{P+N} \quad (1)$$

Todavia, a acurácia não é a medida mais adequada quando há um desbalanceamento de classes, ou seja, quando há prevalência de uma classe. Nesse caso, a acurácia balanceada, que considera esse desbalanceamento é mais adequada. Essa medida, proposta por Brodersen *et al.* (2010), é calculada como a média da proporção de classificações corretas de cada classe (P e N), conforme apresentado na Equação 2.

$$acurácia\ balanceada = \frac{1}{2} \left(\frac{TP}{P} + \frac{TN}{N} \right) \quad (2)$$

5. Resultados

Nas Figuras 2 e 3 são apresentados os desempenhos preditivo, acurácia e acurácia balanceada (*balanced accuracy* - BAC), dos classificadores a partir de diferentes conjuntos de dados gerados pelos métodos de extração. No eixo x estão os métodos de extração individualmente e a combinação entre eles (métodos híbridos).

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
SVM	0.8181	0.8904	0.8423	0.8811	0.9043	0.914	0.921	0.9305	0.9376	0.9401	0.9453
RNA	0.9066	0.9333	0.9083	0.9219	0.9305	0.9341	0.9389	0.9409	0.9278	0.9326	0.9351

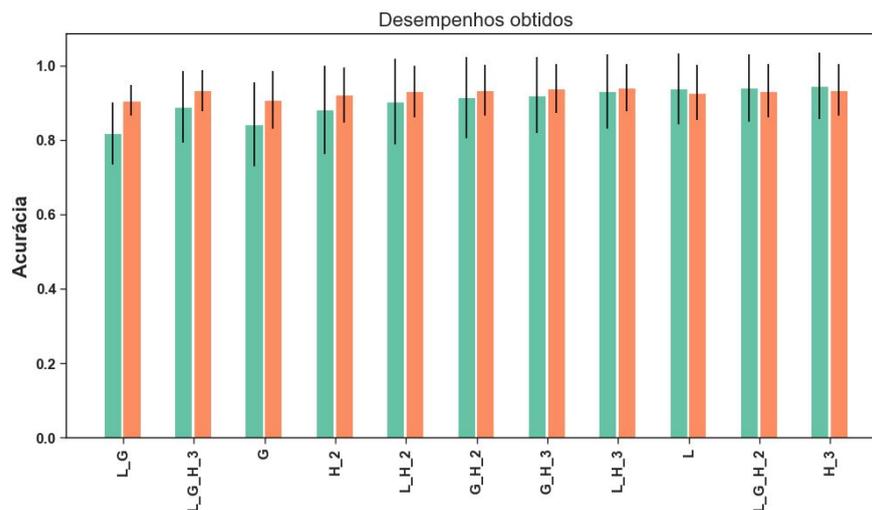


Figura 2 - Acurácia dos modelos gerados pelas técnicas SVM e RNA para os conjuntos de dados com as características extraídas por cada método e pelos extratores combinados

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
SVM	0.6712	0.8049	0.7365	0.8019	0.8412	0.8574	0.869	0.8851	0.897	0.9012	0.91
RNA	0.8156	0.8826	0.8474	0.8726	0.888	0.8918	0.9004	0.9063	0.8876	0.896	0.9007

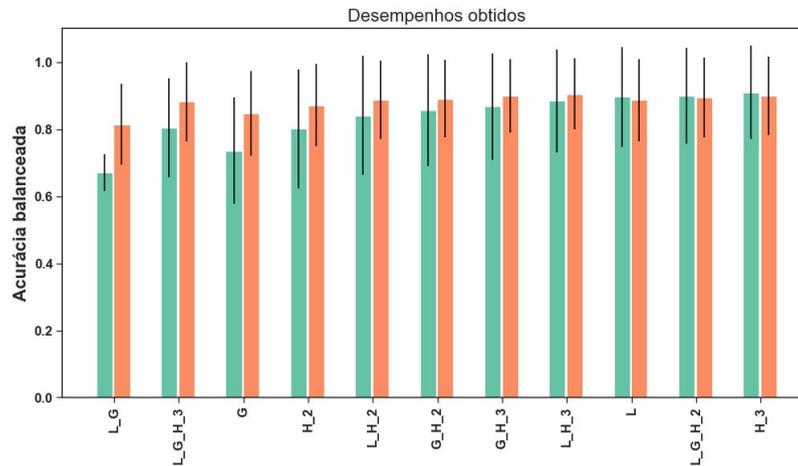


Figura 3 - Acurácia balanceada dos modelos gerados pelas técnicas SVM e RNA para os conjuntos de dados com as características extraídas por cada método e pelos extratores combinados

Observando-se as acurácias das duas técnicas de AM, SVM e RNA, para o conjunto de dados com as características obtidas pelo método de extração de características (Figura 2), é notável o ótimo desempenho de predição, uma vez que para ambas as técnicas as acurácias apresentaram-se todas próximas de 90%. Nota-se também que o classificador RNA, apesar dos comportamentos muito parecidos, apresentou melhores resultados que a técnica SVM para a maioria dos casos. No entanto, o melhor desempenho se deu com a SVM utilizando o descritor HOG com três células por bloco (H_3). A pior acurácia, de aproximadamente 82%, também aconteceu com a SVM para a combinação dos extratores L_G.

Em relação à BAC (Figura 3), nota-se que, de uma forma geral, as comparações entre os métodos de extração de característica e os classificadores SVM e RNA são muito similares em relação à acurácia. Entretanto, há grandes diferenças para alguns extratores. Por exemplo, para o caso L_G, as acurácias dos classificadores SVM e RNA foram de 82% e 91%, respectivamente. Por outro lado, as acurácias balanceadas foram 67% e 82%, respectivamente, ou seja, bem abaixo da acurácia. Como a acurácia balanceada é mais adequada para problemas de desbalanceamento de classes, podemos afirmar que os valores obtidos com essa medida são estimativas mais confiáveis do desempenho dos classificadores.

Analisando cada método separadamente para a acurácia balanceada, nota-se que o HOG com três células por bloco (H_3) também gerou o modelo com maior desempenho preditivo (91%) utilizando-se a SVM. Entretanto, a combinação das características desse método com os demais influenciou negativamente nos modelos. Por outro lado, nota-se que a combinação dos extratores LBP, GLCM e HOG com duas células por bloco (L_G_H_2) resultou no modelo com melhor desempenho em comparação aos desempenhos individuais. Em relação aos classificadores, as RNAs novamente apresentaram desempenho superior para a maioria dos casos, mas o melhor desempenho, como mencionado, foi obtido pela SVM. Por último, é interessante observar como a combinação de extratores prejudica no desempenho dos modelos. Por exemplo, quando as características obtidas pelo LBP são combinadas com as do GLCM (L_G), a acurácia balanceada dos dois classificadores é degradada quando comparada ao uso apenas do LBP (L).

6. Conclusão

O presente estudo realizou uma comparação de diferentes métodos de extração de características para a classificação da qualidade da madeira por meio de imagens digitais. Para esse propósito utilizou-se as técnicas de aprendizado e máquina RNA e SVM. Os resultados experimentais para um conjunto de 374 imagens permitiram observar que a maioria dos métodos analisados resultaram em informações relevantes para a tarefa de classificação das técnicas de AM. Entre os métodos de extração, o HOG, o qual não havia sido investigado em trabalhos anteriores (AFFONSO et al., 2017), não só é adequado para o problema da classificação da qualidade da madeira como apresentou o melhor desempenho em relação aos outros extratores. Adicionalmente, alguns conjuntos de características que possuem resultados inferiores à média quando utilizadas separadamente, resultaram em melhores acurácias balanceadas quando combinados com outros extratores. Ademais, verificou-se que, em geral a técnica RNA, se destacou com melhor desempenho preditivo para a tarefa de classificação das imagens em relação aos resultados da técnica SVM. Porém, a melhor acurácia balanceada, de 91%, foi obtida com a SVM para o extrator de características HOG.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo apoio financeiro para a realização dessa pesquisa sob os processos de número 2018/11852-1 e 2019/07248-4.

REFERÊNCIAS

AFFONSO, C. et al. Deep learning for biological image classification. **Expert Systems with Applications**, v. 85, p. 114–122, 2017.

ALMEIDA, O. C. P. DE. **Classificação de tábuas de madeira usando processamento de imagens digitais e aprendizado de máquina**. PhD Thesis—[s.l.] Universidade Estadual Paulista (UNESP), 2014.

BRODERSEN, K.H.; ONG, C.S.; STEPHAN, K.E.; BUHMANN, J.M.. **The balanced accuracy and its posterior distribution**. Proceedings of the 20th International Conference on Pattern Recognition, 3121-24, 2010.

DALAL, N.; TRIGGS, B. **Histograms of oriented gradients for human detection**. international Conference on computer vision & Pattern Recognition (CVPR'05). **Anais...IEEE Computer Society**, 2005

DALAL, N.; TRIGGS, B.; SCHMID, C. **Human Detection Using Oriented Histograms of Flow and Appearance**. (A. Leonardis, H. Bischof, A. Pinz, Eds.)Computer Vision – ECCV 2006. **Anais...Berlin, Heidelberg: Springer Berlin Heidelberg**, 2006

FLACH, P. **Machine learning: the art and science of algorithms that make sense of data**. Cambridge: Cambridge University Press, 2012.

GOPALAKRISHNAN, K. et al. Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection. **Construction and Building Materials**, v. 157, p. 322–330, 2017.

HARALICK, R. M.; SHANMUGAM, K.; OTHERS. Textural features for image classification. **IEEE Transactions on systems, man, and cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973a.

HARALICK, R. M.; SHANMUGAM, K.; OTHERS. Textural features for image classification. **IEEE Transactions on systems, man, and cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973b.

HAYKIN, S. **Neural networks**. [s.l.] Prentice hall New York, 1994. v. 2

HAYKIN, S. S. **Neural Networks: A Comprehensive Foundation**. [s.l.] Prentice Hall, 1999.

HINTON, G. et al. Deep neural networks for acoustic modeling in speech recognition. **IEEE Signal processing magazine**, v. 29, 2012.

INCE, T. et al. Real-time motor fault detection by 1-D convolutional neural networks. **IEEE Transactions on Industrial Electronics**, v. 63, n. 11, p. 7067–7075, 2016.

JING, L. et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox. **Measurement**, v. 111, p. 1–10, 2017.

KHALID, M. et al. **A comparative study of feature extraction methods for wood texture classification**. 2010 Sixth International Conference on Signal-Image Technology and Internet Based Systems. **Anais...IEEE**, 2010a

KHALID, M. et al. **A comparative study of feature extraction methods for wood texture classification**. 2010 Sixth International Conference on Signal-Image Technology and Internet Based Systems. **Anais...IEEE**, 2010b

KUMAR, A. Computer-vision-based fabric defect detection: A survey. **IEEE transactions on industrial electronics**, v. 55, n. 1, p. 348–363, 2008.

MAHRAM, A.; SHAYESTEH, M. G.; JAFARPOUR, S. **Classification of wood surface defects with hybrid usage of statistical and textural features**. 2012 35th International Conference on Telecommunications and Signal Processing (TSP). **Anais...IEEE**, 2012

MAKANTASIS, K. et al. **Deep convolutional neural networks for efficient vision based tunnel inspection**. 2015 IEEE International Conference on Intelligent Computer Communication and Processing (ICCP). **Anais...Cluj-Napoca, Romênia: IEEE**, 2015

MASCI, J. et al. **Steel defect classification with max-pooling convolutional neural networks**. The 2012 International Joint Conference on Neural Networks (IJCNN). **Anais...IEEE**, 2012

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern Recognition**, v. 29, n. 1, p. 51–59, 1996a.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with

classification based on featured distributions. **Pattern recognition**, v. 29, n. 1, p. 51–59, 1996b.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern recognition**, v. 29, n. 1, p. 51–59, 1996c.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis & Machine Intelligence**, v. 24, n. 7, p. 971–987, 2002.

PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PRAMUNENDAR, R. A. et al. **A classification method of coconut wood quality based on Gray Level Co-occurrence matrices**. 2013 International Conference on Robotics, Biomimetics, Intelligent Computational Systems. **Anais...IEEE**, 2013

RODER, M.; ROSSI, A. L. D. ; AFFONSO, C. O. . **Boosting machine learning techniques for wood quality classification by particle swarm optimization**. In: Encontro Nacional de Inteligência Artificial e Computacional, 2017, Uberlândia, MG. Anais do 14o Encontro Nacional de Inteligência Artificial e Computacional, 2017. Disponível em: <http://comissoes.sbc.org.br/ce-ia/pg/historico/base/ENIAC-2017/Anais-ENIAC-2017.pdf>

ROSSI, A. L. D. **Meta-aprendizado aplicado a fluxos contínuos de dados**. PhD Thesis—[s.l.] Universidade de São Paulo, 2014.

ROSSI, A. L. D. et al. MetaStream: A meta-learning based method for periodic algorithm selection in time-changing data. **Neurocomputing**, v. 127, p. 52–64, 2014.

ROSSI, A. L. D.; DE CARVALHO, A. C. **Bio-inspired optimization techniques for svm parameter tuning**. 2008 10th Brazilian Symposium on Neural Networks. **Anais...Salvador - BA: IEEE**, 2008

RUSSAKOVSKY, O. et al. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision (IJCV)**, v. 115, n. 3, p. 211–252, 2015.

VAN DER WALT, S. et al. scikit-image: image processing in Python. **PeerJ**, v. 2, p. e453, 2014.

VAPNIK, V. **The nature of statistical learning theory**. [s.l.] Springer science & business media, 2013.

VIEIRA, F. H. A. **Image processing through machine learning for wood quality classification**. PhD Thesis—[s.l.] Universidade Estadual Paulista (UNESP), 2016.

WANG, B.; WANG, H.; QI, H. **Wood recognition based on grey-level co-occurrence matrix**. 2010 International Conference on Computer Application and System Modeling (ICCSM 2010). **Anais...IEEE**, 2010

XIE, X. A review of recent advances in surface defect detection using texture analysis

techniques. **ELCVIA: electronic letters on computer vision and image analysis**, v. 7, n. 3, p. 1–22, 2008.

ZHANG, B. et al. Computer vision detection of defective apples using automatic lightness correction and weighted RVM classifier. **Journal of Food Engineering**, v. 146, p. 143–151, 2015.

ZHANG, Z. et al. **Locating the wood defects with typical features and SVM**. Int. Conf. Comput. Vis., Pattern Recognit. Image Process., Shenzhen, China. **Anais...2008**

ZHONG, R. Y. et al. Intelligent manufacturing in the context of industry 4.0: a review. **Engineering**, v. 3, n. 5, p. 616–630, 2017.