

Utilizando análise de textura baseada em fractais na automação de sistemas de manufatura

André Luiz Marasca¹, Marcelo Teixeira¹, Dalcimar Casanova²

¹Programa de Pós-Graduação em Engenharia Elétrica (PPGEE)
Universidade Tecnológica Federal do Paraná (UTFPR)
Caixa Postal 571 – CEP 85.502-970 – Pato Branco – PR – Brazil

²Departamento Acadêmico de Informática (DAINF)
Universidade Tecnológica Federal do Paraná (UTFPR)
Caixa Postal 571 – CEP 85.502-970 – Pato Branco – PR – Brazil

eng.andremarasca@gmail.com

Abstract. *Manufacturing processes involving classification of items by visual inspection are often carried out by human experts that are subject to failure due to fatigue and inattention. This work proposes the use of a recent technique of texture analysis based on fractals for classification of manufacturing items. To validate the proposal, a case study involving the classification of 22 wood species was carried out. The results showed a correct classification rate of 99.86% using cross-validation by 10-fold and LDA classifier.*

Resumo. *Processos de manufatura que envolvem classificação de itens por meio de inspeção visual são frequentemente realizados por especialistas humanos, que estão sujeitos a falhas por cansaço e desatenção. Este trabalho propõe a utilização de uma técnica recente de análise de textura baseada em fractais para classificação de itens de manufatura. Para validação da proposta, realizou-se um estudo de caso envolvendo a classificação de 22 espécies de madeira. Os resultados mostraram uma taxa de classificação correta de 99,86% utilizando validação cruzada por 10-fold e classificador LDA.*

1. Introdução

Os Sistemas de manufatura (SM) vêm evoluindo continuamente, desde o seu conceito até ferramentas e métodos disponíveis no processo de produção. Atualmente, o conceito de manufatura envolve todos os níveis de fabricação, como máquinas, sistemas de produção e a nível comercial [Esmaeilian et al. 2016].

Dentre os sistemas de manufatura estão aqueles que necessitam ou podem evoluir positivamente com a inserção de estímulos visuais tanto no processo de produção quanto no controle de qualidade [Forsyth and Ponce 2011]. A utilização de visão computacional (VC) proporciona vantagens competitivas por permitir classificação automática mediante estímulos visuais. Segundo [Brosnan and Sun 2002] visão computacional é uma técnica de inspeção rápida, econômica, consistente e objetiva, que se expandiu para indústrias de diversos setores.

Exemplos de aplicações de VC na área de manufatura incluem fabricação de componentes eletrônicos delicados [Sanz and Petkovic 1988], análise da qualidade de granito

[Shafarenko et al. 1997] e cerâmica [Elbehiery et al. 2005], inspeção e classificação de frutas e vegetais [Zhang et al. 2014], análise das características de grãos e avaliação de alimentos como carnes, queijos e pizza [Brosnan and Sun 2002].

Dentre as grades áreas da VC está a análise de textura, que permite distinguir grupos de imagens com base em padrões repetitivos no posicionamento de primitivas ou elementos em uma imagem [Tamura et al. 1978]. A literatura provê vários métodos [Ojala et al. 2000, Barthélemy et al. 2015, Casanova et al. 2016] para análise de textura, a maioria com elevadas taxas de acerto em conhecidos *benchmarks*.

Mesmo que a VC venha há muito tempo mostrando seu potencial, tradicionalmente a classificação e a inspeção de qualidade é realizada por especialistas humanos que abordam o problema de duas maneiras: ver e sentir. O treinamento desses especialistas é um processo longo e custoso. Mesmo para alguém treinado, cansaço e desatenção podem gerar falhas na inspeção. As decisões nem sempre são consistentes entre inspetores ou mesmo dia a dia, tornando este método altamente variável [Sun 2016]. Outra desvantagem em manter humanos nessa tarefa é o perigo inerente em algumas atividades de inspeção visual (por exemplo, inspeção subaquática, indústria nuclear, indústria química, etc.) que podem gerar riscos à saúde e até mesmo levar à morte [Malamas et al. 2003].

Nesse sentido esse trabalho propõe a utilização de um procedimento de visão computacional como parte de um processo de manufatura. O objetivo é utilizar o método de análise de textura baseada em fractais [Casanova et al. 2016] para analisar e classificar imagens. Esse processo integrado com automação industrial permite que uma tarefa que antes necessitaria de intervenção humana possa ser realizada de forma automática. Isso melhora a eficiência, a segurança e a autonomia do controlador, que coordena o esquema de atuação sem a necessidade de interrupções de aplicativos ou de ações externas.

Um estudo de caso de manufatura que utiliza diferentes espécies de madeiras é realizado. A ideia principal é classificar peças de madeira de acordo com sua espécie e, após essa identificação, cada peça segue para um determinado destino na linha de produção. Embora seja um estudo de caso pontual, o mesmo *framework* poderia ser expandido para outros problemas semelhantes.

1.1. Processo de manufatura

A arquitetura simplificada de uma fábrica que manufatura componentes de madeira pode ser vista na Figura 1. O processo é composto por uma esteira central sobre a qual são depositadas peças de madeira bruta que são inspecionadas a fim de determinar o seu tipo. Na sequência, cada componente migra da esteira central para esteiras secundárias, por influência de pistões auxiliares que atuam conforme o tipo da madeira. O objetivo é decidir qual pistão será acionado para cada peça que cruza a linha de manufatura.

Como pode ser facilmente observado na Figura 1, cada pistão no processo de produção opera individualmente, não dependendo de informações encontradas em outros pistões. Nesse estudo, considera-se que um pistão, i , recebe um estímulo, e_i , e estende-se ao máximo, em sequência, retrai-se automaticamente. Ao fim do processo de retração, o mesmo gera um sinal, f_i , de final de curso.

Em relação a esteira central, a mesma deve parar no momento que é enviado a um ou mais pistões o sinal e_i , e só deve voltar a se movimentar no momento que recebe todos

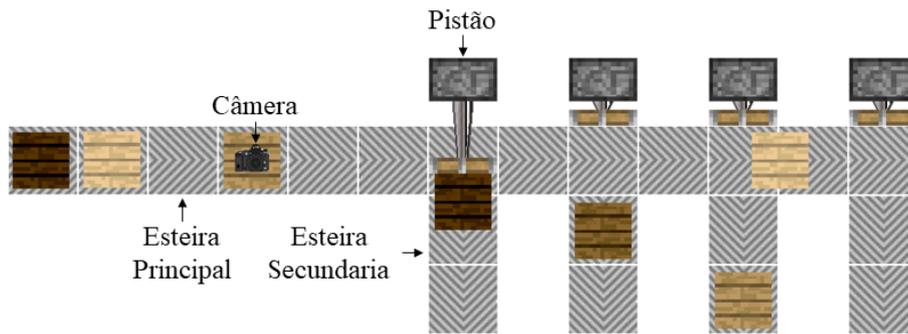


Figura 1. Planta do sistema com textura extraídas de [Minecraft].

respectivos sinais f_i , isso evita que as peças sobre a esteira colidam com os braços dos pistões.

O sinal e_i só deve ser gerado quando uma dada peça de madeira estiver posicionada em frente a esteira projetada para receber o dado tipo de madeira. Para isso, propõe-se um sistema que denomina-se sensor virtual. Ele pode ser visto como a interpretação que na planta real existe um sensor em frente a cada pistão, de forma que o sensor virtual i posicionado em frente ao pistão i só identifique a espécie de madeira que deve ser empurrado pelo seu respectivo pistão, gerando um sinal e_i .

Esse sensor virtual pode ser implementado utilizando a câmera no início da esteira. No momento em que o material (e.g. madeira) passa pela câmera, um sistema inteligente baseado em visão computacional é acionado com objetivo de identificar a espécie de madeira. Uma vez identificada, o sistema se utiliza da velocidade da esteira e tempo decorrido para gerar o sinal e_i , emulando assim o sensor virtual. O código da implementação do sensor virtual está disponível em <https://github.com/andremarasca/SensorInteligente/blob/master/SensorInteligente.c>.

A grande dificuldade desse processo de manufatura está na correta identificação das peças de madeira. Identificações incorretas e/ou demoradas podem causar falhas indesejáveis no processo de manufatura. Nesse contexto a próxima seção modela esse sistema de visão. Os resultados de acurácia são mostrados na seção 4.

2. Sistema Inteligente para identificação de espécies de madeira

2.1. Extração de características de textura

Para classificação de imagens de textura utilizou-se o método de descritores fractais (FD_{MIC}) [Casanova et al. 2016]. Este método analisa textura por meio de técnicas de estimativa da dimensão fractal sobre a interação dos canais de cores.

O primeiro passo a ser realizado no método FD_{MIC} é o mapeamento de cada canal de uma imagem de textura no espaço de cores RGB para uma nuvem de pontos S^c em comum, de forma que, um pixel de posição i, j e intensidade k , seja convertido em um *voxel* de coordenadas i, j, k , rotulado de acordo com seu canal de cor de origem. A equação (1) formaliza esse processo.

$$S^c = \{i, j, k | (i, j) \in [1 : M] \times [1 : N], k = I^c(i, j)\}, \quad (1)$$

em que S^c , $c \in \{R, G, B\}$, são os canais de cores, I^c é a respectiva intensidade de cor em cada pixel e M e N são o tamanho da imagem.

No segundo passo, essa nuvem de pontos é dilatada por meio de um algoritmo de Transformada Exata de Distância com métrica Euclidiana [Saito and Toriwaki 1994], mantendo as informações dos canais de cores de cada *pixel*. A distância de um dado ponto qualquer até um raio r , é dado pela equação (2), de modo que seu domínio seja o conjunto de pontos mais próximos dos pontos com uma determinada cor.

$$\mathcal{D}^c(r) = \{(x, y, z) | (P_x, P_y, P_z) \in S^c, [(x - P_x)^2 + (y - P_y)^2 + (z - P_z)^2]^{1/2} \leq r\}. \quad (2)$$

À medida que o raio de dilatação cresce, os pontos que compõem a dilatação de cada cor c são aqueles que satisfazem a equação(3).

$$\mathcal{D}^c(r) = \mathcal{D}^c(r) \setminus \mathcal{D}^{\{R, G, B\} \setminus c}(r), \quad (3)$$

em que \setminus denota o operador complemento de conjuntos.

Em seguida, são calculados os denominados descritores, para cada canal de cor por meio da equação (4),

$$D^c(r) = \log\left(\sum \chi_{\mathcal{D}^c(r)}[(i, j, k)]\right). \quad (4)$$

O vetor de características é obtido por meio da concatenação dos descritores de cada canal de cor, conforme a equação (5).

$$D(r) = [D^R(1), \dots, D^R(r_{max}), D^G(1), \dots, D^G(r_{max}), D^B(1), \dots, D^B(r_{max})]. \quad (5)$$

2.2. Método de classificação

O método FD_{MIC} possui um vetor de características que apresenta alta correlação entre suas características, sendo assim, um dos métodos de classificação (aprendizagem de máquina) mais recomendados para esse cenário é o *Linear Discriminant Analysis* (LDA). Este é a maneira clássica para realizar análise discriminante (*Discriminant Analysis*) e foi introduzida por *R. Fisher* [Guo et al. 2006].

Dadas G populações numéricas, cada uma possuindo uma distribuição normal multivariada com uma matriz de covariância em comum, Σ , com dimensões $p \times p$ e vetores de média μ_g ($g = 1, \dots, G$) [Guo et al. 2006]. Dada uma amostra aleatória x_i de n observações, com rótulo de classe desconhecida, a tarefa é descobrir de qual grupo g essa amostra x_i pertence.

A ideia do LDA é classificar a amostra x_i para uma população \tilde{g} que minimiza $\tilde{g} = (x_i - \mu_g)^T \Sigma^{-1} (x_i - \mu_g)$, isso equivale a encontrar a população que maximiza a probabilidade de observação, conforme a equação (6).

$$\tilde{g} = \operatorname{argmin}_{\tilde{g}} (x_i - \mu_g)^T \Sigma^{-1} (x_i - \mu_g) \quad (6)$$

2.3. Validação cruzada

É importante estimar de maneira confiável a acurácia de um determinado classificador sobre um conjunto de dados. Isso além de ajudar a escolher um classificador com alto poder de discriminação, garante a segurança da aplicação na prática [Wolpert 1992].

O desempenho de um classificador é geralmente medido em termos de erro de predição. Na maioria dos problemas do mundo real, o erro não pode ser calculado com exatidão, dessa forma deve ser estimado. Um estimador de erro de um dado classificador é uma variável aleatória, e sua qualidade é medida geralmente por meio de seu viés e variância [Rodriguez et al. 2010].

A validação cruzada por *k-fold* é uma técnica de estimativa de erro de predição e provavelmente é a mais popular [Rodriguez et al. 2010]. Resumidamente, este método consiste em dividir o conjunto total de dados de treinamento em k subconjuntos mutuamente exclusivos de igual tamanho, então o algoritmo de classificação é treinado utilizando $k - 1$ subconjuntos, e o subconjunto, i , restante é utilizado como instâncias de teste. Este processo é repetido k vezes, em cada repetição é escolhido outro subconjunto de teste i , de forma que $i = 1, \dots, k$.

A estimativa de erro é o valor médio dos erros cometidos em cada etapa. Assim, o estimador de erro da validação cruzada por *k-fold*, depende de dois fatores: o conjunto de treinamento e a forma com que são criados os k subconjuntos [Rodriguez et al. 2010]. Nesse trabalho utilizou-se o parâmetro $k = 10$.

Adicionalmente o método *Z-score* é utilizado para normalização de cada índice do vetor de características, objetivando igualar a influência para todos os elementos deste vetor em momento de classificação [Devore 2011]. Consiste em utilizar a equação (7),

$$z = \frac{x - \mu}{\sigma}, \quad (7)$$

em que x é a variável à ser normalizada e μ e σ são a média e o desvio padrão respectivamente de todas as instâncias de treino em relação a característica à qual pertence a variável analisada.

3. Classificação automática de peças de madeira

A classificação de madeiras ajuda a indústria de móveis, produção de painéis de madeira, construção civil, em aspectos visuais, identificação de fraude, utilização da espécie de madeira correta para construções, dentre outros [Khalid et al. 2008]. No entanto, as espécies de madeira são difíceis de classificar corretamente por uma pessoa não especialista. Isso se deve a complexidade das composições de madeira e a alta diversidade das espécies existentes [Francisco-Fernández et al. 2012]. Essa dificuldade pode ser observada na Figura 3.

Atualmente, o reconhecimento da espécie de uma dada madeira depende quase exclusivamente de especialistas humanos, que baseiam seu julgamento em características visíveis como cor, odor, densidade, dentre outros [Wang et al. 2013]. Entretanto, o treinamento de um especialista demanda tempo, e mesmo para um sujeito experiente podem existir falhas por atenção e cansaço.

Uma maneira rápida e barata para classificação de madeira pela espécie se dá mediante análise de textura. Existem várias formas de se obter imagens de madeira, cada uma com níveis de detalhes que permitem maior precisão na classificação. Dentre elas estão as imagens da estrutura macroscópica, micrografia e estereograma [Wang et al. 2013], como mostrado na Figura 2. Sendo que o objetivo deste trabalho é a separação da madeira em tempo real em um ambiente industrial foram estudadas apenas as imagens da estrutura macroscópica da madeira que por sua simplicidade é de mais rápida e fácil aquisição.

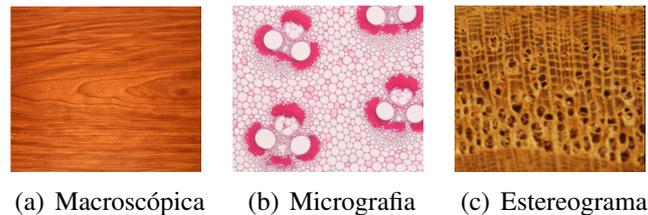


Figura 2. Tipos de fotos de madeira [Wang et al. 2013].

Imagens da estrutura macroscópica da madeira nada mais são do que fotografias obtidas por meio da vista superior. Em um sistema de manufatura isso significa posicionar uma câmera logo acima de uma esteira, mantendo a câmera fixa (distância e rotação) e iluminação controlada (de preferência utilizando apenas, ou predominantemente, iluminação artificial).

3.1. Base de imagens

Segundo [Khalid et al. 2008], o reconhecimento automático de madeira ainda não foi bem estabelecido principalmente devido à falta de pesquisa nessa área e à dificuldade em se obter um bom banco de dados desse material.

Para criação de uma base de imagens, selecionou-se 22 espécies das madeiras mais utilizadas para fabricação de móveis segundo [howstuffworks]. Em seguida, extraiu-se de [Meier] uma imagem para cada espécie de madeira, resultando em 22 imagens distintas de textura. As imagens são próximas às adquiridas em um ambiente industrial controlado, em que o método de aquisição para testes é o mesmo para treino.

Cada espécie de madeira, em termos de aprendizagem de máquina, é denominada de *classe*. Dessa forma, Nesse conjunto de imagens, tem-se 22 classes diferentes. E ainda, cada classe necessita de uma série de amostras diferentes. Portanto, cada uma dessas 22 imagens foi subdividida em várias subimagens, sem interseções, de dimensões 100×100 . Como as dimensões das imagens de [Meier] não seguem um padrão, cada classe obteve com um número diferente de amostras. A Tabela 1 compara o nome da classe, sua identificação e o número de amostras da mesma, no total foram obtidas 726 imagens distintas e sem sobreposição.

A Figura 3 apresenta uma amostra aleatória de tamanho 100×100 cada uma das classes.

4. Resultados

Após a aquisição da base de imagens de textura, as mesmas foram avaliadas utilizando o técnica FD_{MIC} juntamente com a metodologia adotada em [Casanova et al. 2016],

Tabela 1. Nomes, identificação (Id) e número de instancias de cada classe (Ni)

Classe	Id	Ni	Classe	Id	Ni
Mogno africano	1	36	Carvalho vermelho	12	36
Ulmus americana	2	36	Pinus resinosa	13	24
Fraxinus	3	36	Pau brasil	14	36
Tília	4	36	Ulmus thomasii	15	24
Cerejeira negra	5	36	Castanheira americana	16	36
Nogueira preta	6	24	Sicômoro	17	36
Jacarandá da Bahia	7	18	Teca	18	36
Faia europeia	8	36	Zanthoxylum flavum	19	36
Bordo açucareiro	9	36	Thuja plicata	20	36
Nogueira pecã	10	24	Carvalho branco	21	36
Eucalyptus camaldulensis	11	36	Bétula amarela	22	36



Figura 3. Imagens de textura das espécies de madeira estudadas Nesse artigo. O nome das espécies (a)-(v) podem ser consultados na Tabela 1

utilizando validação cruzada *10-fold* [Rodriguez et al. 2010], normalização *Z-score* [Devore 2011] e classificador *linear discriminant analysis* [Guo et al. 2006].

Utilizaram-se vários níveis de quantização (amostragem *Z*, conforme equação (8)) da escala de cores como forma de verificar se, em quantizações menores, os resultados mantinham-se constantes. Os resultados são mostrados na Tabela 2.

$$I_z = \frac{z-1}{255} I_{256} \quad (8)$$

Em que I_{256} é a imagem com 256 níveis de intensidade luminosa e I_z é a imagem com z níveis de intensidade luminosa.

Observando-se na Tabela 2 que o nível de quantização não tem grande influência na taxa de acerto. Isso traz benefícios computacionais, um menor nível de quantização significa menor complexidade computacional utilizando o método FD_{MIC} de

[Casanova et al. 2016]. A velocidade computacional deve ser levada em conta uma vez que, em um processo de manufatura, é prejudicial parar as máquinas esperando que o computador dê uma resposta, pois isso pode atrasar a produção. Outro fator que também influencia na velocidade do processamento é o número de características, pois em etapa de classificação cada característica está relacionada a uma dimensão em um espaço analisado.

Tabela 2. Resultados para aplicação do método FD_{MIC} sobre a base de imagens de madeira. Foram efetuadas análises em diferentes níveis de amostragem Z, alterando assim a taxa de sucesso % do método. Seguindo a metodologia de [Casanova et al. 2016], foram variados também o número de características utilizados, e selecionado a quantidade com melhores resultados.

Amostragem Z	Taxa de Sucesso (%)	N_Características
256	98,898	045
224	99,174	051
192	99,174	042
160	99,587	045
128	99,174	048
096	99,862	051
064	99,587	033
032	99,311	042
016	93,939	048

Nota-se na Tabela 2, que ao utilizar Amostragem Z igual a 96 obteve-se uma taxa de sucesso de classificação de 99,862%, validando assim a abordagem da utilização desta técnica de análise de textura como instrumento para automação industrial.

Para o caso acima (Amostragem Z igual a 96), observou-se apenas 1 erro de classificação (0,138% de 726 instâncias), em que uma amostra foi classificada pertencente à classe 2, sendo na realidade da classe 3. Portanto, apenas uma subimagem de uma fotografia foi classificada incorretamente, isso implica que, dependendo da forma de implementação do sistema, uma peça de madeira tomaria destino incorreto em um processo de produção.

Para resolver esse problema, cada fotografia poderia ser subdividida em subimagens, e cada uma delas ser classificada individualmente. Com base nisso, a decisão a qual classe pertence a fotografia seria realizada escolhendo a classificação mais frequente entre suas subimagens. Outra possível solução para o problema de classificação incorreta é analisar a probabilidade a posteriori que o classificador *linear discriminant analysis* retorna, caso ela seja inferior a um determinado limiar, deve-se descartar a subimagem atual e estimar a classificação em outra.

As elevadas taxas de classificação revelam a aplicabilidade deste método de análise de textura. Os requisitos seriam: (1) Instalação de uma câmera de boa qualidade fixada acima da esteira do sistema de produção com iluminação controlada; (2) A utilização de um computador que, conectado a essa câmera, execute em tempo real o método FD_{MIC} dentro de uma janela de tempo que de preferência evite parar o sistema de produção.

5. Conclusão

Este trabalho avaliou a aplicação da técnica de análise de textura FD_{MIC} em uma base de imagens constituída de fotografias da estrutura macroscópica de 22 espécies de madeira. Utilizando validação cruzada *10-fold* e classificador *linear discriminant analysis* obteve-se uma taxa de classificação de 99,862%, validando a utilização de análise de textura em indústrias de manufatura que utilizam madeira como matéria-prima.

Considerando que os pré-requisitos necessários à implementação desse sistema inteligente são poucos (i.e. câmera, ambiente controlado e sistema computacional) conclui-se que é uma abordagem válida pelo menos para o caso de teste acima descrito. Entretanto o mesmo *framework* pode ser expandido (com as devidas alterações necessárias) para outros problemas semelhantes.

Referências

- [Barthélemy et al. 2015] Barthélemy, Q., Larue, A., and Mars, J. I. (2015). Color sparse representations for image processing: review, models, and prospects. *IEEE Transactions on Image Processing*, 24(11):3978–3989.
- [Brosnan and Sun 2002] Brosnan, T. and Sun, D.-W. (2002). Inspection and grading of agricultural and food products by computer vision systems—a review. *Computers and electronics in agriculture*, 36(2):193–213.
- [Casanova et al. 2016] Casanova, D., Florindo, J. B., Falvo, M., and Bruno, O. M. (2016). Texture analysis using fractal descriptors estimated by the mutual interference of color channels. *Information Sciences*, 346:58–72.
- [Devore 2011] Devore, J. L. (2011). *Probability and Statistics for Engineering and the Sciences*. Cengage learning.
- [Elbehiery et al. 2005] Elbehiery, H., Hefnawy, A., and Elewa, M. (2005). Surface defects detection for ceramic tiles using image processing and morphological techniques. In *WEC (5)*, pages 158–162.
- [Esmailian et al. 2016] Esmailian, B., Behdad, S., and Wang, B. (2016). The evolution and future of manufacturing: A review. *Journal of Manufacturing Systems*, 39:79 – 100.
- [Forsyth and Ponce 2011] Forsyth, D. and Ponce, J. (2011). *Computer vision: a modern approach*. Upper Saddle River, NJ; London: Prentice Hall.
- [Francisco-Fernández et al. 2012] Francisco-Fernández, M., Tarrío-Saavedra, J., Mallik, A., and Naya, S. (2012). A comprehensive classification of wood from thermogravimetric curves. *Chemometrics and Intelligent Laboratory Systems*, 118:159–172.
- [Guo et al. 2006] Guo, Y., Hastie, T., and Tibshirani, R. (2006). Regularized linear discriminant analysis and its application in microarrays. *Biostatistics*, 8(1):86–100.
- [howstuffworks] howstuffworks. A guide to furniture woods. <http://home.howstuffworks.com/home-improvement/home-diy/furniture-restoration/guide-to-furniture-woods-gal.htm>. acessado em 08/09/2017.

- [Khalid et al. 2008] Khalid, M., Lee, E. L. Y., Yusof, R., and Nadaraj, M. (2008). Design of an intelligent wood species recognition system. *International Journal of Simulation System, Science and Technology*, 9(3):9–19.
- [Malamas et al. 2003] Malamas, E. N., Petrakis, E. G., Zervakis, M., Petit, L., and Legat, J.-D. (2003). A survey on industrial vision systems, applications and tools. *Image and vision computing*, 21(2):171–188.
- [Meier] Meier, E. The wood database. <http://www.wood-database.com/>". acessado em 08/09/2017.
- [Minecraft] Minecraft. Textura de minecraft. <https://minecraft.net>". acessado em 08/09/2017.
- [Ojala et al. 2000] Ojala, T., Pietikäinen, M., and Mäenpää, T. (2000). Gray scale and rotation invariant texture classification with local binary patterns. In *European Conference on Computer Vision*, pages 404–420. Springer.
- [Rodriguez et al. 2010] Rodriguez, J. D., Perez, A., and Lozano, J. A. (2010). Sensitivity analysis of k-fold cross validation in prediction error estimation. *IEEE transactions on pattern analysis and machine intelligence*, 32(3):569–575.
- [Saito and Toriwaki 1994] Saito, T. and Toriwaki, J.-i. (1994). New algorithms for Euclidean distance transformation of an n-dimensional digitised picture with applications. 27(11).
- [Sanz and Petkovic 1988] Sanz, J. L. and Petkovic, D. (1988). Machine vision algorithms for automated inspection thin-film disk heads. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(6):830–848.
- [Shafarenko et al. 1997] Shafarenko, L., Petrou, M., and Kittler, J. (1997). Automatic watershed segmentation of randomly textured color images. *IEEE transactions on Image Processing*, 6(11):1530–1544.
- [Sun 2016] Sun, D.-W. (2016). *Computer vision technology for food quality evaluation*. Academic Press.
- [Tamura et al. 1978] Tamura, H., Mori, S., and Yamawaki, T. (1978). Textural features corresponding to visual perception. *IEEE Transactions on Systems, Man, and Cybernetics*, 8(6):460–473.
- [Wang et al. 2013] Wang, H.-j., Zhang, G.-q., and Qi, H.-n. (2013). Wood recognition using image texture features. *PloS one*, 8(10):e76101.
- [Wolpert 1992] Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2):241–259.
- [Zhang et al. 2014] Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., and Liu, C. (2014). Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Research International*, 62:326–343.