



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA

NATAN LENHARO LIMA

**Implementação de banco de imagens para classificação de
produtos agrícolas através de *machine learning***

Campinas

2019



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA

NATAN LENHARO LIMA

Implementação de banco de imagens para classificação de produtos agrícolas através de *machine learning*

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do título de **Engenheiro Agrícola** à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

Orientadora: Prof^a. Dr^a. Juliana Aparecida Fracarolli

Campinas

2019



Ficha Catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura



Implementação de banco de imagens para classificação de produtos agrícolas através de *machine learning*

NATAN LENHARO LIMA

BANCA EXAMINADORA

.....
Prof^a. Dr^a. Juliana Aparecida Fracarolli
Orientadora

.....
Prof^a. Dr^a. Franciane Colares Souza Usberti

.....
Prof^o. Dr. Zigomar Menezes de Souza



DEDICATORIA

Aos meus pais, Ilze Aparecida Lenharo Lima e Raul Veiga de Lima por nunca desistirem de mim.



AGRADECIMENTOS

À Faculdade de Engenharia agrícola - FEAGRI e a todos seus funcionários, professores e alunos que direta ou indiretamente contribuíram para a realização deste trabalho.

À Prof^a. Dr^a. Juliana Aparecida Fracarolli por aceitar o desafio de ser minha orientadora, dar todo o suporte, dedicação e paciência necessária para que este projeto fosse concluído da melhor maneira possível.



RESUMO

As ferramentas tecnológicas desenvolvidas pela humanidade nos tempos recentes têm mudado completamente a abordagem de diversos problemas encarados pelos mais diversos setores produtivos, desde a automação parcial ou completa de linhas produtivas, até o mapeamento de uma grande quantidade de dados de processo, comercialização e clientes. Essas inovações também atingem a agroindústria, e novas ferramentas podem influenciar positivamente o rendimento do processo, incentivar a redução de perdas e otimizar a utilização de recursos naturais. Neste trabalho será apresentado uma revisão bibliográfica sobre o projeto de criação de um banco de dados de imagens, a fim de possibilitar, através da interação de desenvolvedores, o desenvolvimento de algoritmos de detecção e classificação de produtos agrícolas, através da comparação com as imagens contidas no banco de dados, baseados em técnicas de *machine learning*. Serão abordadas as formas de funcionamento de dois grandes sistemas de detecção, classificação e busca de imagens por *machine learning* existentes hoje, o ImageNet e o Microsoft COCO, e avaliar qualitativamente como o banco de dados pode ser abordado e quais os potenciais ganhos provindos da utilização de sistema digital nas etapas de produção agrícola, principalmente na pós-colheita.

Palavras-chave: banco de imagens, *machine learning*, agricultura digital, pós-colheita.



ABSTRACT

The technological tools recently developed have completely changed the approach to various issues faced by the most diverse productive sectors, from the partial or complete automation of production facilities, to the large-scale data mapping of processes, commercialization and customers. These innovations also affect the agroindustry, and new tools can positively influence process performance, encourage waste reduction and optimize the use of natural resources. In this article, we will present a bibliographical review about the project of creating an image database, in order to enable, through the interaction of developers, the development of detection and classification algorithms of agricultural products, through the comparison with the images contained in the database, based on machine learning techniques. It will address the ways in which two major machine learning image detection, classification and search systems exist today, ImageNet and Microsoft COCO, and qualitatively access how the database can be approached, and the potential gains from using digital systems in the agricultural production stages, especially postharvest.

Keywords: image database, machine learning, digital agriculture, postharvest.



SUMÁRIO

1. INTRODUÇÃO.....	10
1.1 JUSTIFICATIVA.....	12
1.2 OBJETIVOS.....	12
2. REVISÃO DE LITERATURA	12
2.1 Ferramentas digitais na agricultura.....	12
2.2 Criação do banco de imagens	14
2.3 Bancos de dados de imagens: ImageNet	16
2.4 Bancos de dados de imagens: Microsoft COCO	17
2.5 <i>Machine Learning</i> e a utilização no pós-colheita	18
3. CONSIDERAÇÕES FINAIS.....	21
4. REFERÊNCIAS	22



1. INTRODUÇÃO

Devido aos grandes avanços tecnológicos recentes no mundo, e a ampla rede de comunicação e compartilhamento de dados, as formas de abordagem de problemas diversos no mercado de trabalho, além da transformação da cultura e do ambiente trabalhista, tem sido cada vez mais notáveis. Tecnologias de tratamento de dados, envio de dados em momento real, digitalização, entre outras, viabilizam novas formas de solucionar antigos problemas enfrentados pela humanidade, e no campo estas mudanças também são percebidas, devido à grande relevância do mercado agropecuário nas economias do mundo.

Pode-se destacar, dentre todas as tecnologias recentemente inseridas e aprimoradas na agricultura, técnicas como o monitoramento via drone, a agricultura de precisão, o gerenciamento 4.0 e a Internet das Coisas (IoT), e várias outras. Porém, entre todas estas tecnologias, a utilização de inteligência artificial talvez se apresente como a que carregue maior potencial de transformação da agricultura, podendo alterar significativamente a produtividade, eficiência, e novas possibilidades de análise e geração de informação.

No tocante à eficiência do processo produtivo rural, a fase de pós-colheita é uma das mais críticas em relação a perdas no processo por deterioração (RINALDI, 2011). Mesmo após a colheita, os frutos ainda são organismos vivos, e a deterioração pós-colheita depende das diferentes velocidades de senescência. Esse nível de perdas demanda que novas informações sobre o manejo adequado do produto sejam avaliadas, além das análises de qualidade física e química, e a medição da longevidade do produto durante o processo de comercialização (CUNHA, 2001); é constatado que, em média, as perdas pós-colheita nos Estados Unidos raramente ultrapassam os 10% do volume produzido, enquanto no Brasil a perda apresenta média de 35% sendo um dos países que mais perde alimentos durante o pós-colheita, apesar do grande volume produzido, de diversos cultivares diferentes (FAO, 2011).

Atualmente, um maior nível de exigência por produtos de melhor qualidade e com menos desperdício tem sido apresentado pela população de países menos industrializados; tal força de demanda incentiva as empresas a investirem em novas formas de controle do processo produtivo, passando diretamente pelo desenvolvimento de tecnologias mais



avançadas, e ajustadas ao mercado brasileiro e aos problemas enfrentados em território nacional, resultando em uma agregação de valor maior ao produto final.

As melhorias tecnológicas na cadeia de produção agrícola derivam da implementação de processos tecnológicos como a agricultura de precisão, aliados à renovação das máquinas por ferramentas mais sofisticadas, automação e digitalização dos processos, programação e uso de inteligência artificial, para que se tenha o máximo de controle sobre as etapas críticas do processo, evitando perdas e aumentando a qualidade.

Diante da vasta variedade de produtos agrícolas produzidos no Brasil, e do grande volume produzido, a precariedade encontrada em alguns processos dentro da cadeia produtiva, como por exemplo etapas de escolha de frutos feitas manualmente, se tornam um problema por ocasionar perdas e erros de produto no fim da cadeia. A partir de tais problemas, a implementação de bancos de dados de imagens para posterior utilização de sistemas de *machine learning* capazes de classificar e analisar os produtos com precisão, e em um curto espaço de tempo, tem sido amplamente discutidos.

É necessário um extenso volume de imagens em uma base de dados para que, através de algoritmos, possa haver computadores treinados para executar uma série de funções, criando padrões de reconhecimento digital. Ribeiro et al (2007) mostra a capacidade de treinamento de processadores de imagem, mostrando precisão e acurácia promissoras.

De acordo com Kader & Rolle (2004), apenas um terço dos produtos classificados como hortícolas produzidos são, de fato, consumidos pela população. Tais perdas severas impactam negativamente a formação do preço final, assim como as características quantitativas e qualitativas do produto final.

Sendo o Brasil um país com grande potencial de desenvolvimento agrícola devido à sua extensão, variedade de climas e fertilidade de diversos solos, a utilização da agricultura digital tende a ser uma força propulsora de desenvolvimento direto e indireto no setor.

Através de um processo que envolve a captura de milhares de fotos de produtos agrícolas, será criado um grande banco de dados que será inserido em um site e que permitirá no futuro criar demanda por projetos independentes de *machine learning*, promovendo um grande número de interações por parte de outros pesquisadores, trazendo maior visibilidade para as instituições de pesquisa da Universidade.



1.1 JUSTIFICATIVA

Dada a quantidade de processos dentro da cadeia produtiva agrícola que ainda acontecem de forma precária, não garantindo ou não melhorando a qualidade do produto final ao consumidor, e tendo em vista que a inteligência artificial e as ferramentas digitais de monitoramento já estão sendo desenvolvidas e testadas em vários países, o mercado nacional não pode ficar defasado, mais ainda diante do grande potencial agrícola brasileiro.

O campo de estudo agrícola é um dos campos mais difíceis para quantificação estatística e tratamento de dados. O que foi desenvolvido na área de *machine learning* e inteligência artificial ainda não é capaz de processar de forma eficaz a complexidade de cenários e possibilidades da agricultura (VIEIRA, 2017).

Deste modo, com a criação de um banco de dados robusto com diversos produtos agrícolas, pessoas do mundo inteiro poderão desenvolver algoritmos de tratamento de dados via *machine learning*, solucionando problemas atuais e potenciais problemas futuros, democratizando a qualidade do processo produtivo como um todo, impactando positivamente a qualidade e o preço para o consumidor.

1.2 OBJETIVOS

A fim de mostrar a importância dos avanços tecnológicos de inteligência artificial e *machine learning* em relação ao potencial impacto econômico e social na agricultura, este trabalho tem como objetivo apresentar uma revisão bibliográfica sobre o tema a fim de elucidar as principais formas de reconhecimento de imagem e *machine learning* presentes hoje.

2. REVISÃO DE LITERATURA

2.1 Ferramentas digitais na agricultura

Os avanços tecnológicos sempre trazem consigo uma grande gama de possibilidades de desenvolvimento. Estes avanços também atingem a produção agrícola;



a partir da utilização de ferramentas mais tecnológicas, maior é a produtividade global do processo produtivo, e melhor é a alocação de recursos naturais, trazendo benefícios sinérgicos para o mercado consumidor.

Devido às particularidades da agricultura e da agroindústria, desafios diferentes são propostos aos desenvolvedores de algoritmos e processos digitais. Estando na era das inovações digitais, ferramentas como o armazenamento em nuvem, tratamento de big data, internet das coisas (IoT), entre outras novas tecnologias e formas de trabalho, contribuem com o desenvolvimento industrial e social, e a agricultura é um dos potenciais beneficiários destas transformações (EMBRAPA, 2018).

As implementações de ferramentas digitais irão possibilitar uma grande autonomia das fazendas e propriedades produtivas menores, demandando menos serviços externos e terceirizados para o processo de triagem de dados e tomada de decisão, otimizando o gerenciamento de dados e a produção. Havendo contínuo desenvolvimento de algoritmos eficazes e implementação em mais localidades, caminha-se para uma grande evolução em toda a cadeia de produção agropecuária (EMBRAPA, 2018).

A Figura 1 ilustra potenciais ganhos com a modernização das cadeias de produção rurais.




Figura 1. Benefícios diretos da digitalização da produção agrícola (EMBRAPA, 2018)

2.2 Criação do banco de imagens

De acordo com Deng et al. (2009), já se pode encontrar inúmeros bancos de dados de imagens, com as mais variadas finalidades, dado que as estimativas de 2009 apontava mais de 3 bilhões de fotos contidas no Flickr, uma grandeza similar de vídeo encontrada no YouTube, e uma quantidade ainda maior de imagens alcançadas pelo Google Imagens. A partir disso surgem propostas diferentes de algoritmos para retirar informações eficientes dessa quantidade enorme de dados gráficos, possibilitando o surgimento de tecnologias como o reconhecimento fácil, por exemplo.

No decorrer da história do desenvolvimento da pesquisa computacional, os bancos de dados desempenham uma função fundamental, não apesar sendo um meio de avaliação e análise através, de algoritmos, mas também conduzindo os novos passos do desenvolvimento tecnológico (LIN et al., 2015)



Diversas variáveis devem ser observadas ao se criar um banco de imagens a ser avaliado através de *machine learning*. A finalidade da criação é uma das variáveis mais importantes, dado que o computador interpretará as imagens como cenas visuais, identificando objetos e seres em 2D e 3D, porém não direciona a triagem de dados sozinho (LIN et al., 2015)

Os primeiros passos na evolução de reconhecimento de objetos facilitou a comparação direta entre centenas de algoritmos diferentes focados em reconhecimento de imagens, ao mesmo tempo em que direciona a criação de algoritmos para problemas mais complexos (DALAL & TRIGGS, 2005)

Os bancos de imagens direcionados ao reconhecimento de seres e objetos podem ser divididos em três grandes grupos: os bancos de imagens para classificação, os bancos de imagens para detecção, e os que fazem marcações de cenas semânticas (LIN et al., 2015). Os de classificação requerem rótulos binários, uma vez que o objetivo é dizer se um objeto, característica ou ente está presente na imagem. Os bancos de imagens para detecção precisam saber se o objeto está presente e, através de uma caixa delimitadora, dizer a localização do objeto detectado. O grupo de bancos de imagens para marcação de cena semântica requerem que cada um dos pixels da imagem seja “etiquetado”, categorizando a imagem.

Outra variável é a classificação dos objetos quanto a “Thing” e “Stuff”, onde “Things” se aplica a objetos para os quais delimitações individuais podem ser facilmente rotuladas (pessoa, carro, cadeira, cachorro), e “Stuff” se aplica a objetos sem um limite definido (céu, mar, grama) (HEITZ & KOLLER, 2008).

As imagens também podem ser classificadas como: “imagens de objetos icônicos” (onde exista um único objeto claro, centralizado e em evidência), “imagens de cenas icônicas” (tiradas de pontos de vista canônicos e, geralmente, sem pessoas), e “imagens não icônicas” (permitem uma busca combinada como, por exemplo, “banana + maçã”). As duas primeiras formas de classificação possuem a vantagem de poderem ser facilmente encontradas em ferramentas de busca, em comparação com as imagens não-icônicas (LIN et al., 2015).



2.3 Bancos de dados de imagens: ImageNet

A base de dados ImageNet é um banco de imagens cujos componentes são hierarquizados de acordo com a ordenação da WordNet, onde em cada ponto da hierarquia existem milhares de imagens contendo objetos pré-estabelecidos. Este banco de dados permite reconhecimento visual de grande escala, avaliando algoritmos de classificação e detecção de imagens amplamente diversificadas, com alto grau de precisão (DENG et al., 2009). A grande escala do banco de imagens possibilita diversas ferramentas de reconhecimento de objetos, classificação de imagens e localização de seres, objetos e características.

A estrutura de hierarquização da ImageNet é definida a partir de cada conceito da WordNet. O principal conceito desse processo é o conceito de *synsets*, este sendo um conjunto de sinônimos que possa ser contido em uma única definição, por haver similaridade no significado entre eles. Os *synsets* registram também as relações entre os conjuntos de sinônimos e seus membros.

Cada definição inserida tem cerca de 500 a 1000 imagens para ilustrá-la, e o seu sistema atinge a acurácia de oferecer dezenas de milhares de outras imagens classificadas de forma correta (DENG et al., 2009). A Figura 2 apresenta um fluxograma de construção de conceitos em bancos de imagens.

De acordo com Deng et al. (2009), a construção do projeto da ImageNet começou pela coleta de imagens por meio de ferramentas de busca. As pesquisas foram feitas usando os *synsets* e, para que o poder de busca fosse aumentado, foram utilizados sinônimos em outros idiomas para aumentar a diversificação do grupo de imagens compondo o mesmo significado. A segunda etapa consistiu na limpeza das imagens postulantes à entrada no sistema. Foi utilizado o *Amazon Mechanical Turk* (AMT), uma plataforma onde os usuários do sistema executam tarefas como a limpeza e análise de imagens. Uma vez que os usuários precisavam opinar sobre as imagens pedidas no projeto, era possível encontrar o objeto da *synset* correspondente. Foi instaurado um controle de julgamentos dos usuários, aumentando a acurácia do processo através de um sistema de votos.

De acordo com Deng et al. (2009), o objetivo principal da criação do ImageNet é servir como um banco de dados de treinamento, potencialmente se tornando um *benchmark*

desafiador, tendo uma função essencial no futuro dos sistemas de reconhecimento e categorização de imagens.




Figura 2. Hierarquização de imagem em um banco de dados de larga escala (DENG et al., 2009)


2.4 Bancos de dados de imagens: Microsoft COCO

Outro banco de dados de imagem conhecido é o *Microsoft Common Objects in Context* (ou Microsoft COCO), constituído, assim como o ImageNet, de um sistema de detecção de imagens de larga escala (LIN et al., 2015).


O Microsoft COCO insere novas indagações no reconhecimento de um objeto em contexto. A avaliação é feita em imagens cotidianas que apresentam certo grau de complexidade, contendo objetos comuns em seu contexto esperado. A definição de rótulos dos objetos é feita por segmentação por instância, ajudando na localização de alta precisão dos objetos rotulados (LIN et al., 2015). A detecção nas cenas apresentadas pode ser executadas por uma ferramenta niveladora de pixels, ou por caixas delimitadoras. Uma vez que as caixas limitam mais a precisão da análise, a proposta da Microsoft é otimizar a precisão, utilizando instâncias totalmente segmentadas. Para a composição do acervo de imagens, um grande esforço foi feito para que imagens ricas em informação contextual fossem encontradas. A Figura 3 ilustra o processo de segmentação dos objetos da imagem em questão.




(a) Image classification



(b) Object localization



(c) Semantic segmentation



(d) This work

Figura 3. Processo de classificação, detecção e segmentação no Microsoft COCO (LIN et al., 2015)

2.5 Machine Learning e a utilização no pós-colheita

A utilização da visão computacional é uma ferramenta relevante na verificação da qualidade dos alimentos, tanto científica quanto comercial. No processo pós-colheita, pode ser utilizada para otimizar a classificação de frutos comerciais, e também como uma inspeção de qualidade externa do produto, de forma automatizada (CUBERO et al., 2016).

Uma das características sensoriais mais importantes para se verificar a qualidade do alimento é a aparência, tendo relevante influência na constituição do preço de mercado e na preferência do consumidor final. Para avaliação de frutos, por exemplo, os principais atributos escolhidos para se avaliar a aparência são: cor, textura, forma e defeitos visuais. Historicamente, o processo de inspeção da qualidade de frutas, legumes, etc. manualmente é um processo demorado e custoso. No entanto, o uso recente de sistemas computacionais hiperespectrais, ligados a um sistema de leitura multiespectral, tem sido usado amplamente na agroindústria de países desenvolvidos, provando-se ferramentas eficazes de inspeção automática (ZHANG et al., 2014).



A classificação de imagens pode ser supervisionada ou não. Na classificação não supervisionada, os pixels são agrupados em clusters e, a partir da determinação de parâmetros como média, variância e covariância, e processos computacionais de iterações e definição do máximo e mínimo de classes, pode-se obter resultados eficazes, apesar da dificuldade computacional do processo (EASTMAN, 1994). Na classificação supervisionada, o sistema treina a máquina através de um conjunto inicial de imagens que, com a entrada de novos bancos de imagens, possam ser utilizadas como padrão de referência pelos algoritmos, promovendo alta precisão com mais eficácia. O processo mais utilizado em análise de imagens, fazendo uso de *machine learning*, é a classificação supervisionada (LIBERMAN, 1997).

Uma importante ferramenta, utilizada em conjunto com o *machine learning*, é o conjunto de redes neurais que armazena o conhecimento gerado através do processo de aprendizado; as redes modificam os pesos sinápticos das comparações ordenadas, tornando possível a classificação de imagens com exatidão (HAYKIN, 1998). Havendo o mapeamento de entrada e saída, a aprendizagem é resolvida quando é feita a aplicação de um conjunto de imagens de treinamento rotuladas, simulando possíveis entradas futuras. Este treinamento é repetido diversas vezes, até o ponto onde a rede alcance uma estabilidade onde não haja imagens com tonalidades diferentes que possam prejudicar a leitura e a classificação. De acordo com Haikyn (1998), devido à grande quantidade de imagens de frutos diferentes, as redes neurais podem ser retreinadas para que detectem modificações que possam ocorrer no processo, mostrando uma alta adaptabilidade em sistemas construídos de forma robusta.

A robustez do banco de dados apresentado é fundamental para que o erro apresentado na detecção e classificação pelas redes neurais não comprometa o processo. Gottschall et al. (2018), ao tentar classificar mangas no pós-colheita em três classes: verde, magenta e madura, não conseguiu classificar corretamente as mangas maduras em seu protótipo, uma vez que banco de dados utilizado foi escasso, a fim de avaliar os limites de funcionamento da leitura do protótipo.

Além da robustez, outro parâmetro importante a ser avaliado é o método de triagem de dados escolhido, e a variável a ser ordenada e classificada. Fukai et al. (2018) comparou dois algoritmos de triagem de banco de dados de imagens em relação à sua eficácia na classificação de grãos de café em seis classes: *fade* (desbotado), *black* (preto), *sour*

(fermentado), *broken* (quebrado), *peaberry* (pequeno), e *no defect* (sem defeitos), mostrado na Figura 4. O modelo a ser testado foi o de convolução de redes neurais (CNN), e sua acurácia foi comparada ao modelo convencional de vetorização linear (SVM). Os resultados obtidos estão expostos na Figura 5. O modelo construído por redes neurais alcançou melhores resultados na classificação de todas as classes, comparado ao modelo SVM.




Figura 4. Exemplos das classes de grãos de café (FUKAI et al., 2018)




Figura 5. Acurácia dos métodos CNN e SVM na classificação de grãos de café (FUKAI et al., 2018)



Na pós-colheita de laranjas, Santiago et al. (2019) comparou dois métodos de classificação de imagens para avaliar a eficiência da classificação das laranjas por calibre (pequeno, médio, grande). Utilizando um banco de 204 imagens, o método mais eficaz apresentou uma precisão global de 82%, sendo que a classificação de laranjas pequenas e grandes obteve melhores resultados em comparação com as médias. Outras pesquisas (RASEKHI & RAOUFAT, 2013; JHAWAR, 2016) também estudaram a eficiência de métodos baseados em *machine learning* na classificação de laranjas.

Com o crescimento da relevância do machine learning nos estudos da área, é notado que um dos processos importantes no reconhecimento de imagens é o chamado *deep learning*, onde o reconhecimento de frutas, legumes, entre outros, tem grande similaridade com o processo desenvolvido para detecção de faces pela visão computacional.

3. CONSIDERAÇÕES FINAIS

As ferramentas de digitalização, mapeamento digital, detecção e classificação de imagens serão de fundamental importância para diversos setores produtivos em um futuro breve; essa revolução passa também pelo setor agrícola e seus desafios próprios.

A montagem de um banco de dados vasto, de larga escala, com variedade, é essencial para que a ideia do site possa ser levada adiante, e pesquisadores diversos possam testar algoritmos de classificação, reconhecimento e detecção de imagens de frutos, legumes, entre outros. O banco de imagens da prof^a Dr^a Juliana apresenta uma boa fundação inicial para os futuros projetos. A padronização e a definição das imagens pode ser um desafio.

No decorrer de posteriores projetos, e com o tempo, os bancos de dados de imagens tendem a se desenvolver mais. Quanto maior a escala do banco, e maior a quantidade de categorias e subcategorias, melhor a eficácia do processo.

A utilização racional da inteligência artificial pode contribuir grandemente para o desenvolvimento da agricultura e do setor agroindustrial, e a discussão desse tema pode abrir caminhos para novas soluções.



4. REFERÊNCIAS

CUNHA, A.R. **Parâmetros agrometeorológicos de cultura de pimentão (*Capsicum annuum* L.) em ambientes protegido e campo**. Botucatu, SP: UNESP, 2001. 128p. Tese (Doutorado em Agronomia).

CUBERO S., LEE W.S., ALEIXOS N., ALBERT F., BLASCO J. **Automated systems based on machine vision for inspecting citrus fruits from the field to postharvest: a review**. Food Bioproc Tech, 2016, 9:1623–1639.

DALAL, N., TRIGGS, B. **Histograms of oriented gradients for human detection**. Conferência sobre Visão Computacional e Reconhecimento de Padrões, 2005.

DENG, J., DONG, W., SOCHER, R., LI, L., LI, K., FEI-FEI, L. **ImageNet: A Large-Scale Hierarchical Image Database**. Dept. of Computer Science, Pinceton University, USA, 2009.

EASTMAN, J.R. **Idrisi: exercícios tutorais**. Porto Alegre: UFRGS, 1994. 109 p.

EMBRAPA. **Visão 2030: O Futuro da Agricultura Brasileira**. Disponível em: <<https://www.embrapa.br/visao/convergencia-tecnologica-e-de-conhecimentos-na-agricultura>> Acesso em : 19 nov 2019.

FAO. **Global food losses and food waste**. Disponível em <<http://www.fao.org/docrep/014/mb060e/mb060e00.pdf>> Internacional Congress Save Food. Rome, 2011. Acesso em: 19 nov 2019.

FUKAI, H. FURUKAWA, J. KATSURAGAWA, H. PINTO, C. AFONSO, C. **Classification of green coffee beans by convolutional neural network and its implementation on Raspberry Pi and camera module**. TAJST – Vol. 1, 2018. Faculty of Engineering, University of Gifu, Japan.

GOTTSCHALL, C.R.A. LIMA, D.S. MARQUES, J.E.S. AMADO, J.A.D. LIBARINO, C.S. **Seleção de qualidade de frutas do tipo manga utilizando visão computacional com redes neurais aplicada a um processo de manufatura robotizada**. Anais da Mostra Nacional de Robótica – MNR, 2018.

HAYKIN, S. **Neural networks: A Comprehensive Foundation**. 2nd ed. [S.L.]: Prentice Hall, 1998.

HEITZ, G., KOLLER, D. **Learning spatial context: Using Stuff to find things**. ECCV, 2008.

JHAWAR, J. **Orange Sorting by Applying Pattern Recognition on Colour Image**. Procedia Computer Science. Volume 78, Pages 691-697, 2016.



KADER, A.A.; ROLLE, R.S. **The role of postharvest management in assuring the quality and safety of horticultural produce.** Rome, FAO Agric. Serv. Bull., 152. p.51. 2004.

LIBERMAN, F. **Classificação de imagens digitais por textura usando redes Neurais.** Rio Grande do Sul: Universidade Federal do Rio Grande do Sul. Instituto de Informática. Curso de Pós-Graduação em Ciência da Computação, 1997.

LIN, T. -Y., MAIRE, M., BELONGIE, S., BOURDEV, L., GIRSHIK, R., HAYS, H. **Microsoft COCO: Common Objects in Context.** Cornell University Library, 2015, p. 1-5.

RASEKHI, R.; RAOUFAT, M.H. **Design, Development and Evaluation of an Orange Sorter Based on Machine Vision and Artificial Neural Network Techniques.** Iran Agricultural Research, Vol. 32, No. 2, 2013.

RIBEIRO, W. S.; ALMEIDA, E. I. B.; COSTA, L. C.; CARNEIRO, G. G.; BARBOSA, J. A. **Perdas pós-colheita de pimentão (*Capsicum annuum*) no mercado atacadista da EMPASA-CG.** Tecnologia e Ciência agropecuária, v. 5, p. 53-56, 2011.

RINALDI, M. M. **Perdas pós-colheita devem ser consideradas.** Planaltina: Embrapa Cerrados, 2011.

SANTIAGO, W.E. LOPES, G.D. FACETO, A.D. LOBO JUNIOR, A.R. CALDEIRA, R.F. **Classificação de laranjas por meio de processamento digital de imagens.** Acta Iguazu, Cascavel, v.8, n.2, p. 49-58, 2019.

VIEIRA, D. **Inteligência Artificial na Agricultura: Sonho Distante ou Realidade?** Start Agro, 2017. Disponível em: < <http://www.startagro.agr.br/inteligencia-artificial-na-agricultura-sonho-distante-ou-realidade/> > Acesso em: 19 nov 2019.

ZHANG, Z.; LIU, L.; ZHANG, M.; et al. **Effect of carbon dioxide enrichment on healthpromoting compounds and organoleptic properties of tomato fruits grown in greenhouse, Food Chemistry, Barking, v.153, p.157-163, jun. 2014.**





ANEXO A

TERMO DE AUTORIZAÇÃO DE USO DE IMAGEM

Eu, Natan Lenharo Lima, brasileiro, portador da cédula de identidade RG nº 34.682.007-8, e do CPF nº 358.799.868-02, aluno da Universidade Estadual de Campinas Registro Acadêmico nº 140846, domiciliado na Rua Almirante Tamandaré, nº 300, Bairro Jardim Fortaleza, cidade Paulínia/SP nos termos da legislação de direitos autorais, especialmente os arts. 29 a 45 da Lei Federal nº 9610/98, autorizo a Juliana Aparecida Fracarolli, brasileira, Solteira, portadora da cédula de identidade RG nº 32761362-2 e do CPF nº 32932402838, Professora da Universidade Estadual de Campinas Matrícula nº 307168, domiciliada na Rua Maria Luiza, nº 201 Bairro Vila Pereira, Itapira/SP, a utilizar as minhas imagens referentes a produtos agrícolas, assim como, veicula-las em qualquer meio de comunicação, sem quaisquer ônus e restrições. Autorizo principalmente a utilização das imagens para elaboração de um banco de imagens, para posterior utilização em projetos envolvendo competições de algoritmos, da Faculdade de Engenharia Agrícola – FEAGRI, sob coordenação da Profa. Dra. Juliana Aparecida Fracarolli.

A autorização inclui a veiculação das imagens para a utilização no Trabalho de Conclusão de Curso em mídia impressa (livros, catálogos, revista, jornal, entre outros) como também em mídia eletrônica (programas de rádio, *podcasts*, vídeos e filmes para televisão aberta e/ou fechada, documentários para cinema ou televisão, entre outros), Internet, Banco de Dados Informatizado Multimídia, “home vídeo” e DVD (*digital vídeo disc.*). Outrossim, autorizo, de livre e espontânea vontade, a cessão de direitos da veiculação por qualquer mídia ou meio de comunicação, não recebendo para tanto qualquer tipo de remuneração.

Campinas 17 de dezembro de 2019

NOME e assinatura

1. Testemunha

2. Testemunha

Nome e RG

Nome e RG