



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
QUÍMICA**



**VISÃO COMPUTACIONAL E OUTRAS TÉCNICAS DE APRENDIZADO DE
MÁQUINA APLICADA AO PROCESSAMENTO DE FRUTAS NA
PRODUÇÃO DE SUCOS**

VICTÓRIA HEBLING ARROYO

Uberlândia - MG
2022



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA
**PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA QUÍMICA**



**VISÃO COMPUTACIONAL E OUTRAS TÉCNICAS DE APRENDIZADO DE
MÁQUINA APLICADA AO PROCESSAMENTO DE FRUTAS NA
PRODUÇÃO DE SUCOS**

Victória Hebling Arroyo

Orientador: Prof. Dr. Ubirajara Coutinho Filho

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Uberlândia como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Química.

Uberlândia - MG

2022



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Engenharia Química
Av. João Naves de Ávila, 2121, Bloco 1K, Sala 206 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
Telefone: (34)3239-4249 - www.ppgeq.feq.ufu.br - secppgeq@feq.ufu.br



Ficha Catalográfica Online do Sistema de Bibliotecas da UFU com dados informados pelo(a) próprio(a) autor(a).

A779 Arroyo, Victória Hebling, 1995-
2022 Visão computacional e outras técnicas de aprendizagem de máquina aplicada ao processamento de frutas na produção de sucos [recurso eletrônico] / Victória Hebling Arroyo. - 2022.

Orientador: Ubirajara Coutinho Filho.
Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Engenharia Química.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2022.71>
Inclui bibliografia.

I. Engenharia química. I. Coutinho Filho, Ubirajara, 1970-, (Orient.). II. Universidade Federal de Uberlândia. Pós-graduação em Engenharia Química. III. Título.

CDU: 66.0

Bibliotecários responsáveis pela estrutura de acordo com o AACR2: Gizele Cristine Nunes do

Couto - CRB6/2091

ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Química				
Defesa de:	Mestrado Acadêmico, 02/2022, PPGEQ				
Data:	03 de fevereiro de 2022	Hora de início:	14:30	Hora de encerramento:	17:30
Matrícula do Discente:	12012EQU009				
Nome do Discente:	Victória Hebling Arroyo				
Título do Trabalho:	Visão computacional e outras técnicas de aprendizado de máquina aplicada ao processamento de frutas na produção de sucos				
Área de concentração:	Desenvolvimento de Processos Químicos				
Linha de pesquisa:	Modelagem, Controle e Otimização de Processos Químicos				
Projeto de Pesquisa de vinculação:	Projeto auxiliado por computador de processos industriais				

-se por meio de webconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Química, assim composta: Professores Doutores: Leo Kunigk - CEFSA-Faculdade Engenheiro Salvador Arena e Universidade São Judas Tadeu; Rubens Gedraite - PPGEQ/UFU; Sergio Mauro da Silva Neiro - PPGEQ/UFU e Ubirajara Coutinho Filho - PPGEQ/UFU, orientador da candidata.

presidente da e Ubirajara Coutinho Filho, apresentou a candidata, agradeceu o público e concedeu à Discente a palavra para a exposição do seu trabalho. A duração da apresentação da Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

presidente palavra, examinadores, que passaram a arguir a candidata. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando a candidata:

aprovada.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Leo Kunigk, Usuário Externo**, em 03/02/2022, às 17:02, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

Documento assinado eletronicamente por **Rubens Gedraite, Professor(a) do Magistério Superior**, em 03/02/2022, às 17:02, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do



[Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Sergio Mauro da Silva Neiro, Professor(a) do Magistério Superior**, em 03/02/2022, às 17:03, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ubirajara Coutinho Filho, Professor(a) do Magistério Superior**, em 03/02/2022, às 17:04, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3345034** e o código CRC **74F265AB**.

AGRADECIMENTOS

Agradeço a Deus por ter me ajudado com que todos os meus objetivos fossem alcançados.

Aos meus pais Pedro e Meire por sempre me incentivarem durante toda minha vida acadêmica. Serei eternamente grata por tudo que fizeram e ainda fazem por mim.

À minha irmã Mariana, por todo o carinho e incentivo.

Ao meu Orientador Ubirajara Coutinho Filho, por todos os ensinamentos, por toda paciência e por ter confiado a mim este tema de pesquisa.

Aos companheiros de pós-graduação Farnanda, Mayara, Vinícius, Julia, Jussara, Nayana pela amizade construída e por terem me ajudado nessa jornada.

À Faculdade de Engenharia Química da Universidade Federal de Uberlândia.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo incentivo à pesquisa.

SUMÁRIO

1	INTRODUÇÃO E JUSTIFICATIVAS.....	16
1.1	Objetivos.....	17
1.1.1	Objetivo geral.....	17
1.1.2	Objetivos Específicos.....	17
2	PRODUÇÃO DE SUCO DE LARANJA.....	18
2.1	A história da laranja e do suco de laranja.....	18
2.2	Setor citrícola no Brasil.....	20
2.3	Variedades de laranjas.....	24
2.4	Classificação do suco.....	28
2.5	Qualidade do suco de laranja.....	28
3	REPRESENTAÇÃO DE IMAGENS.....	30
4	TEXTURAS DE IMAGENS.....	33
5	SEGMENTAÇÃO DE IMAGENS.....	35
6	REDES NEURAIS.....	38
6.1	Neurônio biológico.....	39
6.2	Modelo de Neurônio artificial.....	39
6.3	Funções de ativação.....	41
6.4	Coleta e divisão de dados em uma RNA.....	41
6.5	Rede neural <i>feedforward</i>	43
6.6	Rede Neural Convolucional.....	44
7	MATERIAIS E MÉTODOS.....	50
7.1	Aquisição das matéria prima.....	50
7.2	Aquisição de imagens.....	50
7.3	Dispositivos utilizados para avaliação de parâmetros do suco de laranja.....	51
7.3.1	Determinação da concentração de açúcares solúveis utilizando a escala Brix... 51	51
7.3.2	Medição do pH.....	53
7.3.3	Medição do Volume.....	54
7.3.4	Paquímetro.....	55
7.4	Outros materiais utilizados.....	55
7.5	Recursos computacionais.....	56
8	RESULTADOS.....	62
8.1	Regressão utilizando ANN <i>feedforward</i> com <i>backpropagation</i>	62
8.2	ANN <i>feedforward</i> com <i>backpropagation</i> para materiais poliméricos látex amarelo . 71	71
8.3	Classificação utilizando Redes neurais convolucionais.....	82

8.4	Classificação utilizando medidas estatísticas como sendo variáveis de entrada das redes neurais <i>feedforward</i> com <i>backpropagation</i>	89
9	CONCLUSÃO	92

LISTA DE TABELAS

Tabela 1 - Municípios do cinturão citrícola.....	22
Tabela 2 - Taxonomia da espécie <i>Citrus sinensis</i> (L.) Osbeck.....	24
Tabela 3 - Comparação entre algumas variedades de laranjas	27
Tabela 4 - medidas estatísticas	35
Tabela 5 - Redes neurais <i>feedforward</i> com <i>backpropagation</i>	57
Tabela 6 - Resultados obtidos a partir da análise das laranjas.....	62
Tabela 7 - Resultados de MSE e R^2 referente ao treino e ao teste para Rede Neural <i>feedforward</i> com <i>backpropagation</i> com entradas: comprimento e largura da laranja.	64
Tabela 8 - Diâmetro em cm referente a cada furo do dispositivo para seleção de laranjas.....	66
Tabela 9 - Abertura que cada uma das 60 laranjas atravessou.	67
Tabela 10 - Resultados de MSE e R^2 referente ao treino e ao teste para Rede Neural <i>feedforward</i> com <i>backpropagation</i> com entrada: dispositivo para seleção de laranjas.	68
Tabela 11 - Resultados de MSE e R^2 referente ao treino e ao teste para Rede Neural <i>feedforward</i> com <i>backpropagation</i> com entradas: comprimento da laranja, largura da laranja e dispositivo para seleção de laranjas.	70
Tabela 12 - Coeficiente de correlação e erro quadrático médio obtido para o treino e para o teste.....	81
Tabela 13 - Quantidade de neurônios na camada escondida, acurácia do treino e do teste para redes neurais <i>feedforward</i> com <i>backpropagation</i> utilizando medidas estatísticas como variáveis de entrada para avaliar o pH do suco das laranja	90
Tabela 14 - Quantidade de neurônios na camada escondida, acurácia do treino e do teste para redes neurais <i>feedforward</i> com <i>backpropagation</i> utilizando medidas estatísticas como variáveis de entrada para avaliar o grau Brix do suco das laranja.....	90

LISTA DE FIGURAS

Figura 1 - Produção mundial de frutas cítricas.....	18
Figura 2 - Principais regiões produtoras de laranja no mundo	19
Figura 3 - Cinturão citrícola brasileiro	21
Figura 4 - Laranja Pera	28
Figura 5 - Equipamentos para medir Brix	29
Figura 6 - Pixels de uma imagem	31
Figura 7 - Tons de cinza	31
Figura 8 - Representação matricial.....	31
Figura 9 - Cores obtidas a partir da adição de cores primárias	32
Figura 10 - Três matrizes, sendo que cada uma representa uma cor do sistema RGB.....	32
Figura 11 - Matriz de co-ocorrência de tons de cinza	34
Figura 12 - Detecção de bordas Canny.....	36
Figura 13 - Relação entre inteligência artificial, aprendizado de máquina, ciência de dados e aprendizado profundo	38
Figura 14 - Neurônio Biológico	39
Figura 15 - Neurônio artificial.....	40
Figura 16 - Funções de ativação	41
Figura 17- Divisão de dados no desenvolvimento de uma RNA	42
Figura 18 - Representação de uma ANN <i>feedforward</i> com <i>backpropagation</i>	43
Figura 19 - Localização dos lobos.....	44
Figura 20 - Localização das áreas visuais que são relacionadas ao reconhecimento de objetos	45
Figura 21 - Áreas visuais e características da imagem.....	46
Figura 22 - Aplicação dos kernels	47
Figura 23 - Função Relu	47
Figura 24 - Transformação não-linear e <i>pooling</i> máximo.....	48
Figura 25 - Camada densa	49
Figura 26 - Vista frontal do dispositivo de aquisição de imagens.....	51
Figura 27 - Vista superior do dispositivo de aquisição de imagens	51
Figura 28 - Refratômetro da marca Lorben	52
Figura 29 - Leitura do refratômetro	52

Figura 30 – pHmetro da marca 2Vintens.....	53
Figura 31 - Proveta graduada de 250mL	54
Figura 32 - Paquímetro	55
Figura 33- Objeto polimérico látex amarelo.....	56
Figura 34 - Fluxograma da rede neural <i>feedforward</i> para regressão.....	58
Figura 35- Fluxograma da Rede Neural <i>feedforward</i> com <i>backpropagation</i> para objetos poliméricos látex	58
Figura 36 - Fluxograma das redes neurais convolucionais.....	60
Figura 37 - Fluxograma da rede neural <i>feedforward</i> com <i>backpropagation</i> realizada para a classificação do pH e do grau Brix.....	61
Figura 38 - Rede Neural <i>feedforward</i> com <i>backpropagation</i> com entradas: comprimento e largura da laranja.	64
Figura 39 - Dispositivo para seleção de laranjas	66
Figura 40 - Rede Neural <i>feedforward</i> com <i>backpropagation</i> com dispositivo para seleção de laranjas como sendo entrada.....	68
Figura 41 - Rede Neural <i>feedforward</i> com <i>backpropagation</i> com entradas: comprimento da laranja, largura da laranja e dispositivo para seleção de laranjas	70
Figura 42 - Objetos poliméricos látex amarelo na posição horizontal	72
Figura 43 - Objetos poliméricos látex amarelo na posição vertical	73
Figura 44- Bordas de imagens de materiais poliméricos na posição horizontal detectadas pelo filtro Canny.....	74
Figura 45- Bordas de imagens de materiais poliméricos na posição vertical detectadas pelo filtro Canny.....	75
Figura 46- Rede Neural <i>feedforward</i> com <i>backpropagation</i> para os 100 materiais poliméricos látex de cor amarelo.....	79
Figura 47 - Fotografia das 60 laranjas obtidas a partir do dispositivo de aquisição de imagens	82
Figura 48 - Fotografias, obtidas a partir do dispositivo de aquisição de imagens, dos sucos de cada uma das 60 laranjas	83

LISTA DE GRÁFICOS

Gráfico 1 - Produção mundial de suco de laranja no mundo.....	20
Gráfico 2 - Porcentagem do fornecimento de suco mundial de acordo com as variedades de laranja	26
Gráfico 3 - Período de colheita por variedade e porcentagem de produção no Cinturão Citrícola	26
Gráfico 4 - Volumes de água para cada um dos ensaios	56
Gráfico 5 - Volume de suco calculado versus volume de suco observado para Rede Neural <i>feedforward</i> com <i>backpropagation</i> com entradas: largura e comprimento da laranja.	65
Gráfico 6 - Volume de suco calculado versus volume de suco observado para Rede Neural <i>feedforward</i> com <i>backpropagation</i> com dispositivo para seleção de laranjas como sendo entrada.	69
Gráfico 7 - Volume de suco calculado versus volume de suco observado para Rede Neural <i>feedforward</i> com <i>backpropagation</i> com entradas: comprimento da laranja, largura da laranja e dispositivo para seleção de laranjas.	71
Gráfico 8 - Diâmetro horizontal do objeto polimérico na posição vertical	76
Gráfico 9 - Diâmetro vertical do objeto polimérico na posição vertical	76
Gráfico 10 - Diâmetro horizontal do objeto polimérico na posição horizontal.....	77
Gráfico 11 - Diâmetro vertical do objeto polimérico na posição horizontal	77
Gráfico 12 - Área do objeto polimérico na posição horizontal	78
Gráfico 13 - Área do objeto polimérico na posição vertical.....	79
Gráfico 14 - Coeficiente de correlação vs números de neurônios.....	80
Gráfico 15 - Resultados obtidos para treino e teste para regressão realizada utilizando-se objetos poliméricos.....	80
Gráfico 16 - Boxplot referente aos dados de Brix das 60 laranjas	84
Gráfico 17 - <i>Boxplot</i> referente aos dados de pH das 60 laranjas	84
Gráfico 18 - Acurácia da rede convolucional utilizada para classificação do pH a partir de imagens dos sucos das laranjas.....	85
Gráfico 19 - Perda da rede convolucional utilizada para classificação do pH a partir de imagens dos sucos das laranjas.....	86
Gráfico 20 – Acurácia da rede convolucional utilizada para classificação do grau Brix a partir de imagens dos sucos das laranjas	86
Gráfico 21- Perda da rede convolucional utilizada para classificação do grau Brix a partir de	

imagens dos sucos das laranjas.....	87
Gráfico 22 - Acurácia da rede convolucional utilizada para classificação do pH a partir de imagens das cascas das laranjas.....	87
Gráfico 23 - Perda da rede convolucional utilizada para classificação do pH a partir de imagens das cascas das laranjas.....	88
Gráfico 24 - Acurácia da rede convolucional utilizada para classificação do grau Brix a partir de imagens das cascas das laranjas.....	88
Gráfico 25 - Perda da rede convolucional utilizada para classificação do grau Brix a partir de imagens das cascas das laranjas.....	89

RESUMO

Na indústria, avaliações como textura, cor e tamanho dos alimentos são realizadas manualmente, no entanto, esta forma de inspeção é subjetiva e tediosa, sendo assim, a fim de gerar consistência nos resultados, outras técnicas passaram a ser desenvolvidas, como a visão computacional e aprendizado de máquina. Deste modo, utilizando-se estas técnicas, o objetivo desta dissertação é desenvolver um sistema de aquisição de imagens destinado à avaliar Brix, Volume de suco e pH das laranjas. Portanto, a metodologia deste trabalho consistiu em fotografar laranjas Pera Rio, coletar informações relativas à estas laranjas e posteriormente configurar redes neurais *feedforward* com *backpropagation* e redes convolucionais. Os resultados mostram que é possível analisar o volume de suco a partir do comprimento das laranjas, largura das laranjas e dispositivo de seleção de laranjas. Além disso, observou-se que as redes convolucionais utilizadas para classificar laranjas quanto ao Brix e ao pH não se mostraram satisfatórias, enquanto que o uso de rede neurais do tipo *feedforward* com variáveis de entrada obtidas da análise de textura de matriz de co-ocorrência de escala cinza extraída da cor verde foram satisfatórias para classificar o pH e o Brix.

Palavras-chave: Visão Computacional, Aprendizado de Máquina, Redes Neurais.

ABSTRACT

In the industry, evaluations such as texture, color and size of foods are performed manually, however, this form of inspection is subjective and tedious, thus, in order to generate consistency in the results, and other techniques have been developed, such as computer vision and machine learning. Thus, using these techniques, the objective of this dissertation is to develop an image acquisition system to evaluate Brix, juice volume and pH of oranges. Therefore, the methodology of this work consisted in photographing Pera Rio oranges, collecting information about these oranges and then configuring feedforward neural networks with backpropagation and convolutional networks. The results show that it is possible to analyze the volume of juice from the length of the oranges, width of the oranges and orange selection device. Furthermore, it was observed that the convolutional networks used to classify oranges for Brix and pH were not satisfactory, while the use of feedforward type neural network with input variables obtained from gray scale co-occurrence matrix texture analysis extracted from green color were satisfactory to classify pH and Brix.

Keywords: Computer Vision, Machine Learning, Neural Networks.

1 INTRODUÇÃO E JUSTIFICATIVAS

Na indústria alimentícia, algumas avaliações de propriedades como tamanho, forma, cor e textura dos alimentos são feitas por inspetores de forma manual (DU; SUN, 2004). Na produção de suco de laranja, os frutos são escolhidos por operadores em mesas de seleção, e então, os frutos estragados por pragas, cortados e amassados são retirados enquanto que os demais seguem para classificadores que separam por tamanho e as encaminham às linhas de extração (YAMANAKA, 2005). O trabalho manual realizado em indústrias é tedioso e de natureza subjetiva, e como a demanda por objetividade, consistência e eficiência está em crescimento, técnicas mais precisas passaram a ser desenvolvidas (DU; SUN, 2004), sendo a visão computacional uma das ciências utilizadas para construção de novas tecnologias.

A visão computacional é a ciência responsável pela visão de uma máquina e que extrai informações a partir de imagens capturadas por câmeras de vídeo, sensores, scanners, entre outros dispositivos, sendo que estas informações permitem reconhecer, manipular e pensar sobre os objetos que compõem uma imagem (BALLARD e BROWN, 1982). Na indústria, a utilização da visão computacional aumentou nos últimos anos, sendo encontradas aplicações no controle de qualidade e na automação de processos (CUBERO *et al.*, 2011).

Com a visão computacional é possível reduzir o envolvimento humano nas tarefas (LI; TAN; MARTZ, 1997), de forma não destrutível (TAO *et al.*, 1995), obtendo-se respostas consistentes e rápidas (GERRARD; GAO; TAN, 1996) e possibilitando o armazenamento de dados para análises posteriores (TARBELL; REID, 1991).

Há vários exemplos de uso com sucesso da visão computacional no ramo alimentício como por exemplo, no trabalho de Kondo, Ahmad, Monta e Murase em que o teor de açúcar e o teor de ácido da fruta de laranja *Iyokan* foram avaliados usando uma visão de máquina (KONDO *et al.*, 2000). Além desse trabalho, é possível encontrar na literatura pesquisas desenvolvidas para outros alimentos como por exemplo a pesquisa de Calvo, Moreno-Armendáriz e Godoy-Calderón, em que foi estudada a classificação de abacate, manga manila e tortilhas por meio da visão computacional, sendo encontrada uma classificação correta de 93% em média para os alimentos estudados (CALVO *et al.*, 2016). Já com a pesquisa de Chen, Xiong, Guo, Bu, Zheng, Chen, Yang e Lin foi possível desenvolver a visão computacional para inspecionar grãos de arroz defeituosos, quebrados, farináceos ou manchados sendo que os resultados experimentais mostraram que a precisão para reconhecimento de grãos quebrados, danificados e áreas manchadas atingiram 99,3%, 96,3% e 93,6% respectivamente (CHEN *et al.*,

2019).

Além da importância do emprego de técnicas mais precisas como as obtidas através de redes neurais artificiais no âmbito alimentício, o setor citrícola é muito importante no Brasil, visto que o suco de laranja é um dos principais produtos da pauta agropecuária, sendo que o país representa 34% da produção mundial de laranja, 61% da produção mundial de suco bem como 75% do comércio mundial de suco de laranja, se consolidando portanto como o maior exportador de suco de laranja do mundo, exportando principalmente para países europeus, Estados Unidos e países da Ásia (CITRUSBR, 2019). Ou seja, estudos envolvendo o processamento de suco de laranja são de grande interesse devido a importância econômica deste setor para o Brasil.

1.1 Objetivos

1.1.1 Objetivo geral

Esta dissertação tem como objetivo geral desenvolver e utilizar um sistema de aquisição de informações de medidas de laranja que contempla imagens, dimensões e um *software* para avaliar os parâmetros de interesse na produção de suco de laranja a partir de técnicas de visão computacional e aprendizado de máquina.

1.1.2 Objetivos Específicos

- Desenvolver dispositivo de aquisição de imagens e de avaliação de dimensões de laranjas destinado a obtenção de informações associadas as dimensões e características das laranjas destinadas à industrialização.
- Quantificar propriedades concentração de açúcares solúveis, volume de suco e pH em laranjas pera rio destinadas à produção de suco.
- Desenvolver modelos de visão computacional e outros modelos de Aprendizado de Máquina capazes de avaliar a qualidade de laranjas pera rio e de suco de laranja pera rio a partir das variáveis geradas pelo dispositivo desenvolvido.
- Desenvolver softwares capazes de processar as imagens e avaliar a produção de suco considerando o aprendizado associado as imagens para determinar as propriedades quantificadas.


2 PRODUÇÃO DE SUCO DE LARANJA

Neste capítulo é apresentada a história da laranja e do suco de laranja, um panorama da citricultura no Brasil, características e variedades de laranjas, bem como as etapas envolvidas ao longo da produção e de suco de laranja.

2.1 A história da laranja e do suco de laranja

De acordo com Salibe *et al.* (2002), as laranjas pertencem ao gênero *Citrus*, sendo que, a esse grupo de frutas, pertencem além das laranjas, as tangerinas (*Citrus reticulata* e *Citrus deliciosa*), os limões (*Citrus limon*), as limas ácidas como o Tahiti (*Citrus latifolia*) e o Galego (*Citrus aurantiifolia*), e limas doces como a lima da Pérsia (*Citrus limettioides*), pomelo (*Citrus paradisi*), cidra (*Citrus medica*), a laranja azeda (*Citrus aurantium*) e as toranjas (*Citrus grandis*). As laranjas correspondem mais da metade da produção mundial de todas as frutas cítricas como se pode ver na Figura 1.

Figura 1 - Produção mundial de frutas cítricas



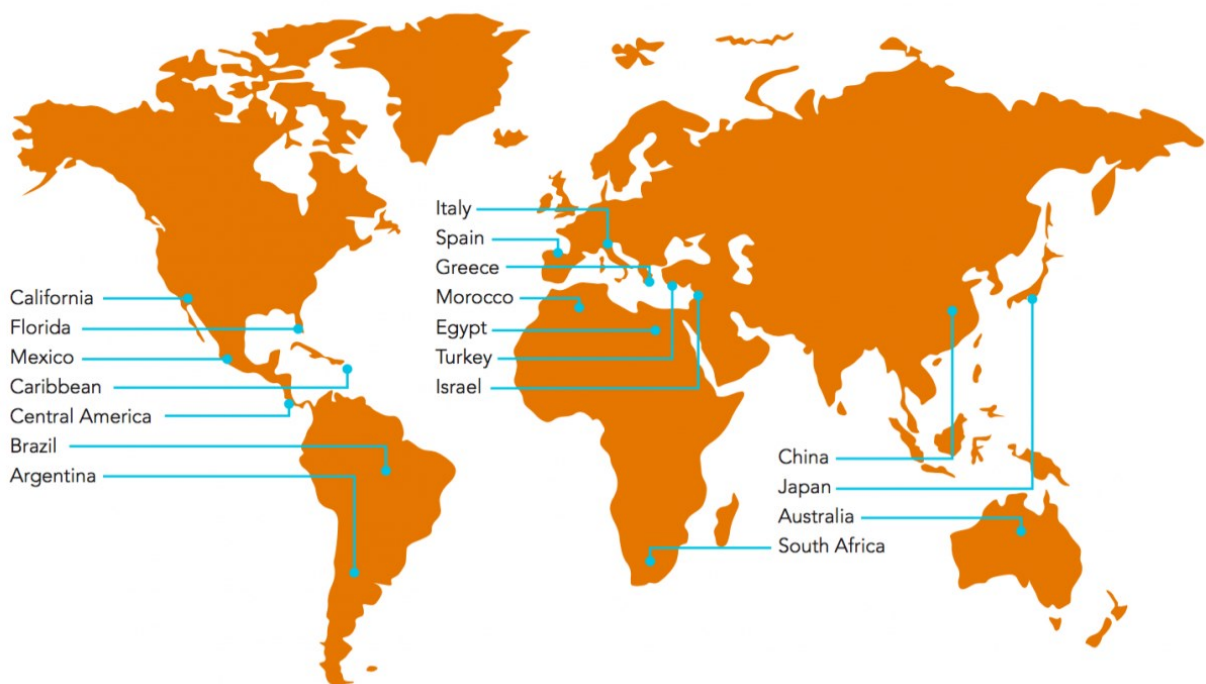
Fonte: Tetra pak (2017).

Segundo Jayaprakasha (2007), os citros são fonte de vitaminas, fibras bem como antioxidantes como ácido ascórbico, compostos fenólicos, flavonoides, limonoides que são

importantes para a nutrição humana, sendo que segundo Silva *et al* (2005), o suco de laranja é considerado como uma das melhores fontes de vitamina C (ácido ascórbico), que ajudam a compor uma alimentação saudável.

De acordo com Salibe *et al.* (2002), as laranjeiras são de porte médio, possuindo copa densa e em formato arredondado, possuindo folhas e flores aromáticas. Segundo Tetra Pak (2017), as laranjas são cultivadas em regiões tropicais e subtropicais em diversas partes do mundo e podem se desenvolver em diversos solos, desde arenosos até argilosos. As principais regiões produtoras de laranja são mostradas na Figura 2.

Figura 2 - Principais regiões produtoras de laranja no mundo



Fonte: Tetra pak (2017)

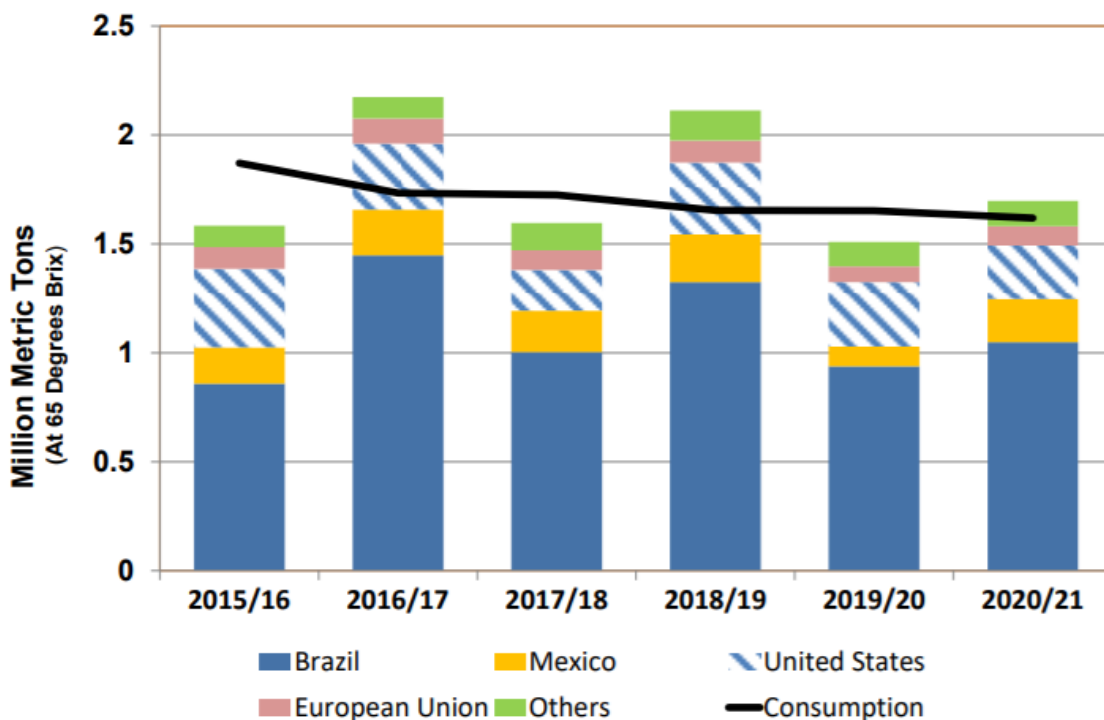
A laranja originou-se provavelmente na Ásia há cerca de 4000 anos e após um tempo a área de cultivo dos citros foi expandida devido ao comércio e as guerras, e portanto, os árabes levaram a laranja para a Europa. Com as grandes navegações, em 1500, Cristóvão Colombo carregou consigo mudas de frutas cítricas para o continente americano e desde a colonização laranjas foram cultivadas no Brasil (NEVES *et al.*, 2010).

Em 1950, a primeira indústria de suco de laranja foi instalada no Brasil (RAIMUNDO; FILHO, 2018). No entanto, a indústria cítrica brasileira começou a crescer em 1962, quando os Estados Unidos, maior produtor mundial de laranja e de suco na época,

teve seus pomares na Flórida atingidos por uma geada, sendo que após novas geadas em 1977, 1981, 1982, 1983, 1985 e 1989, houve a consolidação da indústria brasileira de suco de laranja (NEVES *et al.*, 2010).

Atualmente, o Brasil é considerado o líder mundial na produção de suco de laranja, sendo responsável por 61% da produção mundial de suco, ou seja, a participação do suco de laranja produzido no Brasil em relação ao suco de laranja consumido no mundo, se reflete em 3 em cada 5 copos consumidos ao redor do mundo laranja (CITRUSBR, 2019). A produção mundial de suco de laranja é mostrada no Gráfico 1.

Gráfico 1 - Produção mundial de suco de laranja no mundo



Fonte: UNITED STATES DEPARTMENT OF AGRICULTURE (2021)

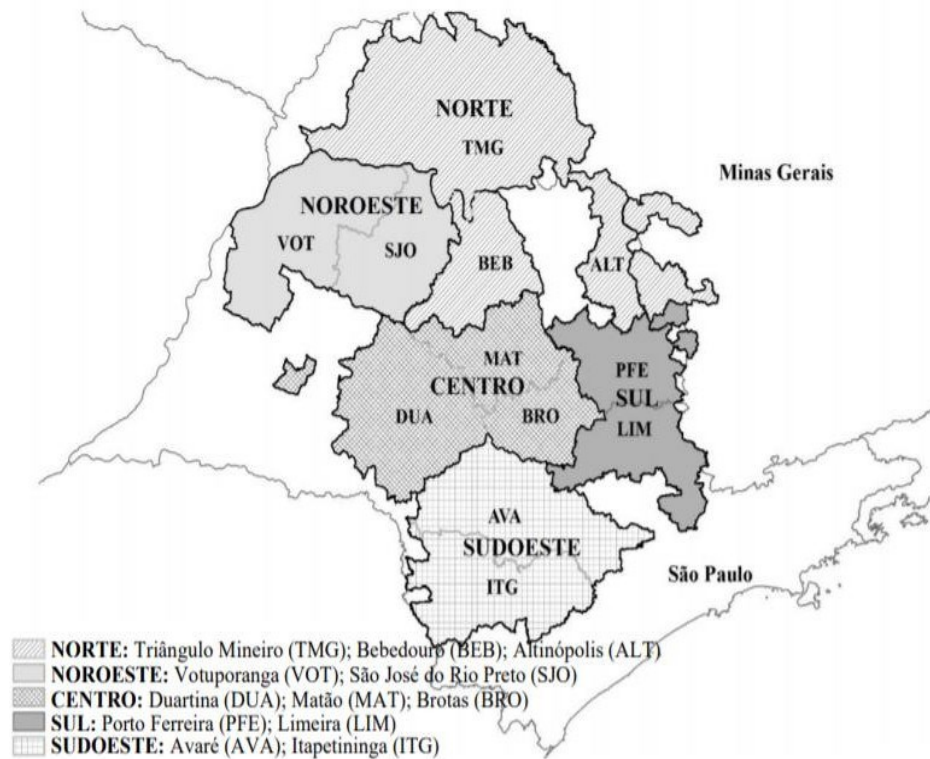
2.2 Setor citrícola no Brasil

No Brasil, a maior concentração de propriedades destinadas à produção comercial de laranja se localiza em uma região denominada cinturão citrícola, que abrange alguns municípios do estado de São Paulo e alguns no Triângulo Mineiro e na região Sudoeste do estado de Minas Gerais (FUNDECITRUS, 2017).

No cinturão citrícola, 482 mil hectares são dedicados à produção de citros, sendo que, 430,6 mil hectares são dedicados ao cultivo de laranja para processamento industrial

(BARROS; BARROS; CYPRIANO, 2016). O cinturão é dividido em 5 setores e 12 regiões como se pode ver na Figura 3.

Figura 3 - Cinturão citrícola brasileiro



Fonte: FUNDECITRUS (2019)

Observa-se portanto na Figura 3, que as 5 regiões do cinturão citrícola são denominados Norte, Noroeste, Centro, Sul e Sudoeste. Além disso, cada região é representada por uma sigla, sendo estas regiões: Triângulo Mineiro (TMG), Bebedouro (BEB), Altinópolis (ALT), Votuporanga (VOT), São José do Rio Preto (SJO), Duartina (DUA), Matão (MAT), Brotas (BRO), Porto Ferreira (PFE), Limeira (LIM), Avaré (AVA) e Itapetininga (ITG). É importante ressaltar que, essa divisão foi realizada levando-se em consideração alguns fatores tais como: clima e característica do solo. Além disso, cada uma das regiões recebeu o nome de um dos municípios da região. Ao todo, a região do cinturão citrícola possui 347 municípios com propriedades citrícolas como se pode observar na Tabela 1 (FUNDECITRUS, 2019).

Tabela 1 - Municípios do cinturão citrícola

Setor	Região	Municípios
Norte	Triângulo Mineiro (TMG)	Campina Verde, Campo Florido, Canápolis, Comendador Gomes, Conceição das Alagoas, Frutal, Gurinhata, Itagippe, Ituiutaba, Iturama, Monte Alegre de Minas, Planura, Prata São Francisco de Sales, Uberaba, Uberlândia
	Bebedouro (BEB)	Ariranha, Barretos, Bebedouro, Cajobi, Catanduva, Catiguá, Colina, Colômbia, Elisiário, Embaúba, Guaraci, Ibirá, Irapuã, Itajobi, Marapoama, Monte Azul Paulista, Novais, Olímpia, Palmares Paulista, Paraíso, Pindorama, Pirangi, Pitangueiras, Sales, Santa Adélia, Severínia, Tabapuã. Taiapuã, Taiúva, Taquaral, Terra roxa, Uchoa, Urupês, Viradouro, Vista Alegre do Alto.
	Altinópolis (ALT)	Altinópolis, Batatais, Brodowski, Cajuru, Cássia dos Coqueiros, Cristais Paulista, Fortaleza de Minas, Franca, Ibiraci, Igarapava, Itamogi, Jacuí, Jeriquara, Monte Santo de Minas, Nova Resende, Patrocínio Paulista, Pedregulho, Santo Antônio da Alegria, São Pedro da União, São Sebastião do Paraíso, São Tomás de Aquino.
Noroeste	Votuporanga (VOT)	Álvares Florence, Américo de Campos, Andradina, Aparecida d'Oeste, Aspásia, Auriflama, Cardoso, Dirce Reis, Dolcinópolis, Estrela d'Oeste, Fernandópolis, General Salgado, Guaraçaí, Guarani d'Oeste, Guzolândia, Indiaporã, Jales, Macedônia, Marinópolis, Meridiano, Mesópolis, Mira Estrela, Mirandópolis, Murutinga do Sul, Nova Canaã Paulista, Ouroeste, Palmeira d'Oeste, Paranapuã, Parisi, Pedranópolis, Pereira Barreto, Pontalinda, Pontes Gestal, Populina, Riolândia, Rubinéia, Santa Albertina, Santa Clara d'Oeste, Santa Fé do Sul, Santa Rita d'Oeste, Santa Salete, Santana da Ponte Pensa, Santo Antônio do Aracanguá, São Francisco, São João das Duas Pontes, São João de Iracema, Sud Mennucci, Suzanópolis, Três Fronteiras, Turmalina, Urânia, Valentim Gentil, Vitória Brasil, Votuporanga.
	São José do Rio Preto (SJO)	Adolfo, Altair, Bady Bassitt, Bálsamo, Cedral, Cosmorama, Floreal, Guapiaçu, Icém, Ipiúva, Jaci, José Bonifácio, Macaúbal, Magda, Mendonça, Mirassol, Mirassolândia, Monções, Monte Aprazível, Neves Paulista, Nhandeara, Nipoã, Nova Aliança, Nova Granada, Onda Verde, Orindiúva, Palestina, Paulo de Faria, Planalto, Poloni, Potirendaba

Tabela 1 – Municípios do cinturão citrícola (continuação)

Setor	Região	Municípios
Noroeste	São José do Rio Preto (SJO)	São José do Rio Preto, Sebastianópolis do Sul, Tanabi, Ubarana, União Paulista, Zacarias.
Centro	Matão (MAT)	Américo Brasiliense, Araraquara, Bariri, Boa Esperança do Sul, Borborema, Cândido Rodrigues, Fernando Prestes, Gavião Peixoto, Ibitinga, Itaju, Itápolis, Jaboticabal, Matão, Monte Alto, Motuca, Nova Europa, Novo Horizonte, Rincão, Santa Lúcia, Tabatinga, Taquaritinga.
	Duartina (DUA)	Agudos, Álvaro de Carvalho, Alvinlândia, Arealva, Avaí, Balbinos, Bastos, Bauru, Boracéia, Cabrália Paulista, Cafelândia, Campos Novos Paulista, Duartina, Echaporã, Espírito Santo do Turvo, Fernão, Gália, Garça, Getulina, Guaiçara, Guaimbê, Guarantã, Iacanga, Júlio Mesquita, Lins, Lucianópolis, Lupércio, Marília, Ocaçu, Parapuã, Paulistânia, Pederneiras, Pirajuí, Piratininga, Pongai, Presidente Alves, Promissão, Reginópolis, Sabino, Santa Cruz do Rio Pardo, São Pedro do Turvo, Ubirajara, Uru.
	Brotas (BRO)	Analândia, Bocaina, Brotas, Corumbataí, Dois Córregos, Dourado, Ibaté, Itirapina, Mineiros do Tietê, Ribeirão Bonito, Santa Maria da Serra, São Carlos, São Pedro, Torrinhã, Trabiju
Sul	Porto Ferreira (PFE)	Aguai, Caconde, Casa Branca, Descalvado, Guaraniésia, Guaxupé, Itobi, Luís Antônio, Mococa, Pirassununga, Porto Ferreira, Santa Cruz da Conceição, Santa Cruz das Palmeiras, Santa Rita do Passa Quatro, Santa Rosa de Viterbo, São João da Boa Vista, São José do Rio Pardo, São Simão, Tambaú, Vargem Grande do Sul
	Limeira (LIM)	Águas de Lindóia, Americana, Amparo, Araras, Artur Nogueira, Atibaia, Bragança Paulista, Charqueada, Conchal, Cordeirópolis, Cosmópolis, Engenheiro Coelho, Espírito Santo do Pinhal, Estiva Gerbi, Holambra, Ipeúna, Iracemápolis, Itapira, Itatiba, Jaguariúna, Jarinu, Leme, Limeira, Lindóia, Mogi Guaçu,
Sudoeste	Avaré (AVA)	Águas de Santa Bárbara, Angatuba, Anhembi, Araçoiaba da Serra, Arandu, Avaré, Bofete, Borebi, Botucatu, Cabreúva, Capela do Alto, Cerqueira César, Cesário Lange, Conchas, Guareí, Iaras, Iperó, Itatinga, Lençóis Paulista, Manduri, Óleo, Pardinho, Porangaba, Porto Feliz, Pratânia, Quadra, Salto de Pirapora, São Manuel, Sorocaba, Tatuí, Tietê.
	Itapetininga (ITG)	Alambari, Buri, Campina do Monte Alegre, Capão Bonito, Coronel Macedo, Itaberá, Itaí, Itapetininga, Itapeva, Itaporanga, Itararé, Nova Campina, Paranapanema, Pilar do Sul, São Miguel Arcanjo, Sarapuí, Sarutaiá, Taquarituba, Taquarivaí, Tejupá.

Fonte: FUNDECITRUS, 2019

A grande concentração da produção citrícola nesta região reflete a concentração de extratoras de suco, sendo que 1061 extratoras de processamento estão em São Paulo, enquanto que, apenas, 45 estão no Nordeste e 72 no Sul do Brasil. Além disto, grande parte da produção de laranjas do cinturão citrícola brasileiro é destinada para o processamento

industrial, sendo 98% exportado (BARROS; BARROS; CYPRIANO, 2016).

Observa-se portanto a importância da produção de suco de laranja, especialmente em São Paulo, sendo este responsável por 11,96% na pauta agropecuária paulista e o terceiro produto mais relevante do estado, atrás apenas da cana-de-açúcar (30%) e carnes (12,98%) (CITRUSBR, 2019).

2.3 Variedades de laranjas

A taxonomia referente à espécie *Citrus sinensis* (L.) Osbeck é mostrada na Tabela 2.

Tabela 2 - Taxonomia da espécie *Citrus sinensis* (L.) Osbeck

Reino	Plantae
Ordem	Geraniales
Subordem	Geraniineae
Classe	Dicotyledonea
Subclasse	Archichalmydeae
Divisão	Embryophyta
Subdivisão	Angiospermae
Família	Rutaceae
Subfamília	Auratiodeae
Gênero	<i>Citrus</i> L.
Subgênero	Citrus
Espécie	<i>Citrus sinensis</i> (L.) Osbeck

Fonte: Adaptado de Kimball (1999)

De acordo com Borges *et al.* (2008), as laranjas doces (*Citrus sinensis* (L.) Osbeck) são classificadas em quatro subgrupos, sendo estes: Brancas, Limas, Sanguineas e Baias.

As laranjas brancas possuem boas características para produção de sucos, devido ao bom rendimento de volume de suco que pode ser obtido, boa coloração bem como acidez equilibrada. Além disso, este grupo de laranja se caracteriza por não apresentar “umbigo”, ou seja, não possui ponta mais acentuada em uma de suas extremidades, parecida com umbigo. Exemplos de variedades que pertencem à este subgrupo: Pêra, Valência, Natal, Hamlim e Westin.


As laranjas lima se caracterizam pela baixa acidez e não são utilizadas para produção de suco. Exemplos de variedades que pertencem à este subgrupo: laranja Lima e Lima Sorocaba.

As laranjas sanguíneas apresentam baixa produção no Brasil e além disso, a principal característica dessas laranjas é a coloração vermelha na polpa e no suco, sendo que os pigmentos (antocianinas) são sintetizados apenas na etapa de amadurecimento dos frutos juntamente com a baixa temperatura. Exemplos de variedades que pertencem à este subgrupo: laranja Moro, Sanguinelli, Doble Fina e Tarocco.

As laranjas baía não são muito indicadas para a produção de suco, pois, a presença de limonina, característica desse grupo, faz com que o suco após pouco tempo de processado apresente sabor amargo. Ademais, este tipo de laranja se caracteriza por apresentar “umbigo”. Exemplos de variedades que pertencem à este subgrupo: laranja Baía Cabula e Baianinha.

As variedades de cada um dos subgrupos (Branças, Limas, Sanguíneas e Baias) se diferenciam pela maturação, podendo ser precoce, meia-estação ou tardia. Além disso, algumas podem apresentar polpa com coloração mais intensa devido à presença de antocianinas (BASTOS *et al.*, 2014). Como o foco desta dissertação é voltado para a produção de suco e como as laranjas mais utilizadas para produção de sucos são as do subgrupo Brancas. No Gráfico 2 é mostrado a porcentagem de fornecimento das variedades de laranjas deste subgrupo para produção de suco de laranja no mundo e no Gráfico 3, é mostrado o período de colheita por variedade e percentual da produção no cinturão citrícola.

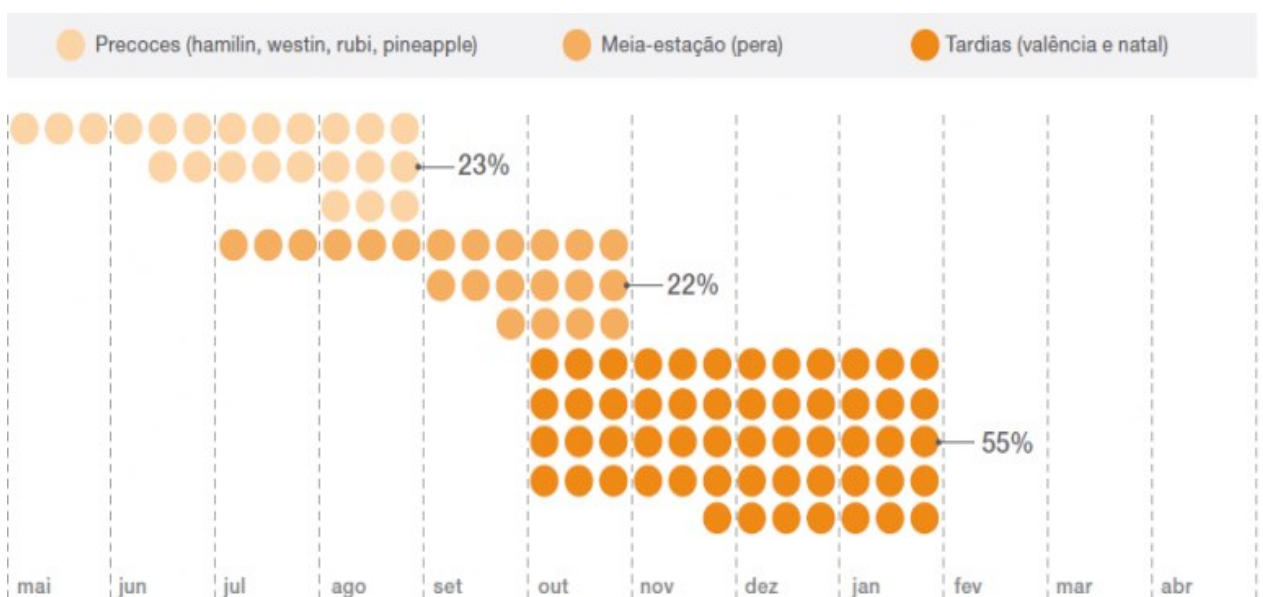
Gráfico 2 - Porcentagem do fornecimento de suco mundial de acordo com as variedades de laranja



Fonte: CITRUSBR (2009)

Observa-se portanto no Gráfico 2 que, a maior parte do suco de laranja no mundo é proveniente da laranja Pera, seguido por Valência, Natal e Hamlim.

Gráfico 3 - Período de colheita por variedade e porcentagem de produção no Cinturão Citrícola



Fonte: CITRUSBR (2009)

No Gráfico 3 pode-se observar que as laranjas hamlin, westin, rubi e pineapple são consideradas precoces, cuja safra inicia-se em maio e vai até agosto. Já a laranja pera é considerada como sendo de meia-estação, cuja safra inicia-se em julho e vai até outubro. Além

disso, nota-se que as laranjas valência e natal são consideradas como sendo tardias, e a safra destas iniciam-se em outubro e vai até janeiro.

Sendo assim, as laranjas utilizadas na produção de suco de laranja dependem de qual variedade está sendo mais produzida no momento, ou seja, em determinada época do ano, é mais comum que as indústrias utilizem mais determinada variedade, devido a disponibilidade das laranjas.

Segundo Kimball (1999), a classificação relativa mostrada na Tabela 3 é a melhor forma de comparar as variedades. No entanto, não deve ser interpretada como absolutas.

Tabela 3 - Comparação entre algumas variedades de laranjas

Variedade	Sabor	Cor
Hamlin	Doce Pouco ácida	Cor forte
Pera	Rico	Cor forte
Pera coroa	Bom	Bom
Pera Rio	Bom	Bom
Valência	Bom-ácido	
Westin	Bom	Cor forte
Rubi	Rico	Avermelhado
Pineapple	Rico Doce	Laranja claro

Fonte: Adaptado de Kimball (1999)

Neste trabalho, optou-se pela laranja Pera, visto que, de acordo com Salibe *et al.* (2002), esta variedade apresenta alto rendimento e qualidade de suco. Outro fator importante para a escolha foi que, esta variedade de laranja apresenta cerca de 38% do fornecimento do suco mundial, ou seja, de acordo com o Gráfico 2, esta é a variedade mais utilizada na produção de sucos. Esta variedade, de acordo com Mattos Junior *et al.* (2005), apresenta formato alongado, casca lisa e amarela como se pode ver na Figura 4.

Figura 4 - Laranja Pera



Fonte: Autor (2022)

2.4 Classificação do suco

Segundo Lima e Melo-Filho (2011), a lei Nº 8.918, de 14 de Julho de 1994, dispõe sobre a padronização, classificação, registro, inspeção, produção e fiscalização de bebidas. Os sucos podem ser classificados em função do processamento e constituição, sendo assim, o suco é classificado como:


- Suco integral: o suco é denominado integral quando é constituído pela extração do suco da fruta, com a concentração bem como a composição correspondente a fruta que foi utilizada. Além disto, neste tipo de suco é proibida a adição de açúcar.
- Suco concentrado: é o produto parcialmente concentrado por evaporação de forma que a concentração de sólidos solúveis seja 65°Brix
- Suco desidratado: este produto é apresentado na forma pulverizada com 3% de umidade máxima relativa.
- Suco processado: produto desidratado que é diluído até a sua concentração natural

2.5 Qualidade do suco de laranja

De acordo com Tetra Pak (2007), a qualidade do suco é subjetiva para cada indivíduo, sendo que, os consumidores relacionam a qualidade ao gosto, sensação na boca bem como a cor do produto. Entretanto, para que o produto seja comercializado, a qualidade não deve ser determinada por avaliações subjetivas, e por esta razão, é necessário a definição de parâmetros para avaliações mais objetivas. Importante destacar que a qualidade do suco é determinada pela qualidade da fruta que chega na recepção, bem como o tempo de armazenamento da fruta e a forma como suco é extraído, não sendo possível melhorar os parâmetros de qualidade nas posteriores etapas de processamento, e desta forma, as melhorias só são possíveis de serem alcançadas ao misturar determinado suco com outro suco de qualidade superior.

Segundo Kimball (1991), um dos parâmetros utilizados para se avaliar a qualidade do suco de laranja é o Brix. De acordo com Tetra Pak (2007), pode-se obter o Brix ao medir a densidade do suco com um hidrômetro, ou então, ao medir o índice de refração do suco em um refratômetro, sendo estes equipamentos mostrados na Figura 5.

Figura 5 - Equipamentos para medir Brix



Fonte: Tetra Pak (2007)


De acordo com Kimball (1991), apesar dos refratômetros serem mais caros do que os hidrômetros, estes apresentam vantagens, pois, a medição é mais rápida e necessita de menor quantidade de amostra. Além disto, possibilitam medição em uma faixa mais ampla, o que é importante para plantas de processamento que fabricam sucos concentrados. Desta forma, optou-se neste trabalho pela utilização do refratômetro para medir o Brix.

Segundo Tetra Pak (2007), além do Brix, o pH também é avaliado na qualidade do suco de laranja, sendo esta, uma escala numérica adimensional, obtida por meio de um pHmetro, que serve para saber qual a acidez ou basicidade de uma solução aquosa.

3 REPRESENTAÇÃO DE IMAGENS

Segundo Singh (2019), uma imagem digital é composta por diversos pixels, que são pequenos quadrados considerados como sendo os menores elementos de uma imagem. É possível ver na Figura 6 a exemplificação de como são os pixels de uma imagem.


Figura 6 - Pixels de uma imagem



Fonte: Monteiro (2012)

De acordo com Antonello (2018), em casos de imagens em preto e branco, as imagens podem ser entendidas como uma matriz de duas dimensões, em que, cada célula desta matriz representa um pixel que pode variar de 0 a 255, sendo que 0 representa a cor preta e 255 a cor branca. É possível ver a representação de tons de cinza na Figura 7.

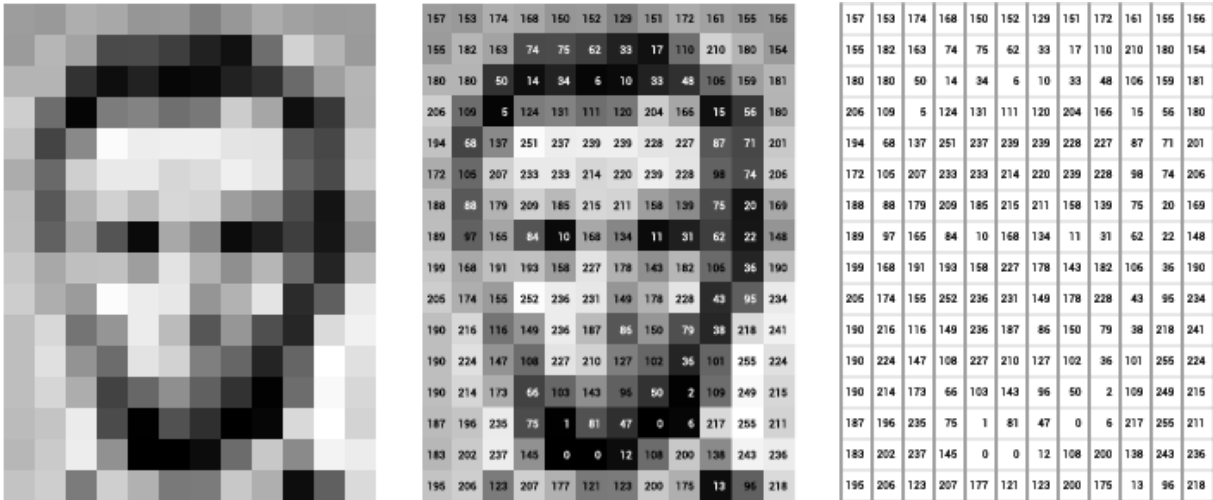
Figura 7 - Tons de cinza



Fonte: Corel (2021)

Sendo assim, a representação matricial da área delimitada por um quadrado vermelho na imagem de um grampeador é mostrada na Figura 8.


Figura 8 - Representação matricial



Fonte: Stanford (2021)

Para imagens coloridas, pode-se utilizar o sistema RGB, que de acordo com Russell e Norvig (1995), esta abreviação significa vermelho, verde e azul (do inglês: *red, green and blue*). Segundo Adobe Creative Team (2007), estas cores são consideradas aditivas. Este sistema obtém diferentes cores existentes ao se combinar estas três cores como se pode ver na Figura 9.

Figura 9 - Cores obtidas a partir da adição de cores primárias



Fonte: Santos (2012)

Segundo Antonello (2018), neste sistema, tem-se três matrizes de números inteiros que variam de 0 a 255, sendo que cada uma contém duas dimensões e representa uma das cores deste sistema como se pode ver na Figura 10.

Figura 10 - Três matrizes, sendo que cada uma representa uma cor do sistema RGB

		165	187	209	58	7
	14	125	233	201	98	159
253	144	120	251	41	147	204
67	100	32	241	23	165	30
209	118	124	27	59	201	79
210	236	105	169	19	218	156
35	178	199	197	4	14	218
115	104	34	111	19	196	
32	69	231	203	74		

Fonte: Courtney (2001)

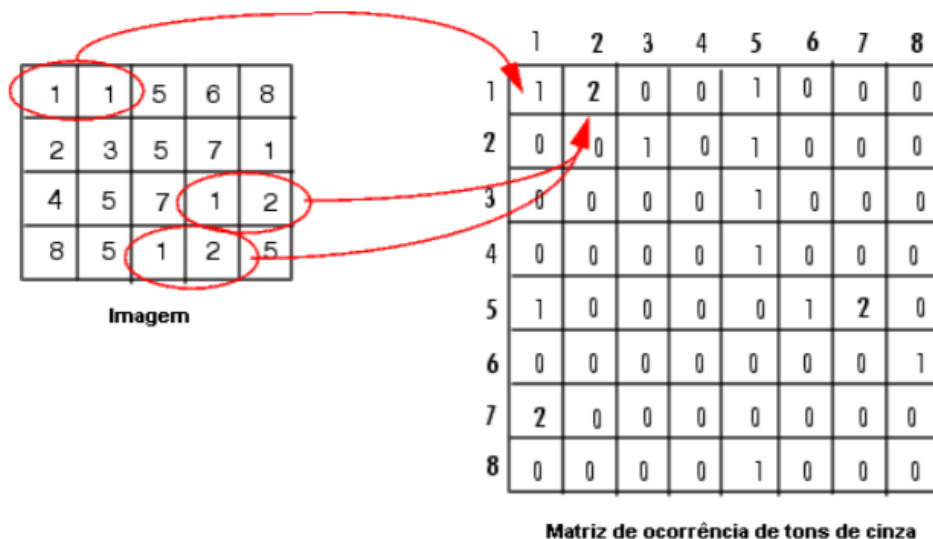
Portanto, conclui-se que uma imagem digital é interpretada como sendo uma matriz de duas dimensões no caso de imagens em escala de cinza e três matrizes no caso de imagens coloridas utilizando o sistema RGB.

4 TEXTURAS DE IMAGENS

As imagens utilizadas na matriz de co-ocorrência são em tons de cinza, pois, essa matriz

armazena informações de intensidades relativas dos pixels, servindo para analisar textura de imagens. (Haralick et al., 1973). Segundo Adonias e Regis (2022), os valores que se encontram na matriz de ocorrência se referem a quantidade em que o número de combinações de níveis de cinza foi encontrado como se pode ver na Figura 11, em que, (1,1) aparece uma única vez na imagem, logo na matriz de co-ocorrência essa combinação vem representado por 1, enquanto que (1,2) aparece duas vezes na imagem, logo na matriz de co-ocorrência essa combinação vem representada pelo número 2.

Figura 11 - Matriz de co-ocorrência de tons de cinza



Fonte: Adonias e Regis (2022)

A partir dessa matriz, medidas estatísticas são obtidas a fim de caracterizar a textura, ou seja, obter informações sobre a transição de níveis de cinza entre dois pixels. Entre essas medidas estão contraste, dissimilaridade, homogeneidade, ASM (do inglês: *Angular Second Moment*), correlação e energia. (MARTINS et al., 2011). A equação dessas medidas estatísticas são mostradas na Tabela 4.

A medidas estatísticas de textura representam (ITO; KIM; SALCEDO, 2009):

- a) ASM e contraste, referem-se a, respectivamente, a medidas da uniformidade da textura e a frequência espacial, ou seja, a diferença entre o maior e o menor valor de um determinado conjunto contíguo de pixels. Sendo que para ASM quando houver uma grande repetição na variação dos níveis de cinza, os valores da matriz de co-ocorrência serão elevados.
- b) Correlação e homogeneidade referem-se a, respectivamente, dependência linear dos tons de cinza em uma imagem e análise da homogeneidade de níveis de cinza de

uma imagem. Sendo que quando existe uma relação linear entre os níveis de cinza dos pares de pixels, observam-se valores altos de correlação;

- c) A dissimilaridade e energia, referem-se, respectivamente à análise da não homogeneidade níveis de cinza de uma imagem e análise da desordem da imagem.

Tabela 4 - medidas estatísticas

Medida estatística	Equação
Contraste	$\sum_{i,j=0}^{levels-1} P_{i,j}(i-j)^2$
Dissimilaridade	$\sum_{i,j=0}^{levels-1} P_{i,j} i-j $
Homogeneidade	$\sum_{i,j=0}^{levels-1} \frac{P_{i,j}}{1+(i-j)^2}$
ASM	$\sum_{i,j=0}^{levels-1} P_{i,j}^2$
Energia	\sqrt{ASM}
Correlação	$\sum_{i,j=0}^{levels-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$

Fonte: Adaptado de (ITO; KIM; SALCEDO, 2009).

Em que, a expressão $P_{i,j}$ é o valor da matriz de co ocorrência na posição $[i,j]$.

5 SEGMENTAÇÃO DE IMAGENS

De acordo com Roncero (2005), a segmentação é importante em sistemas automáticos visuais, pois, consiste na subdivisão de uma imagem em partes constituintes, ou então objetos, permitindo assim, o reconhecimento de partes de interesse de uma imagem.

Segundo Do vale e Dal Poz (2002), a geometria de objetos é passada à imagem, visto que, resultam em variações nos tons de cinza na imagem. Portanto, para detectar e extrair informações como geometria dos objetos, muitas técnicas de processamento de imagens podem ser utilizadas, sendo a detecção de bordas uma dessas técnicas.

De acordo com Shi e Ward (2002), uma das técnicas utilizadas para detecção de bordas é a de Canny, sendo esta uma boa técnica para detectar bordas devido aos seguintes aspectos:

- As bordas detectadas por esta técnica são próximas às bordas reais.
- As bordas que são detectadas por esta técnica possuem a largura de um pixel.
- O detector de borda Canny também pode detectar pequenos detalhes de um objeto com pouco ruído.

Na Figura 12, é possível ver a detecção de bordas de uma imagem em escala de cinzas utilizando-se a detecção Canny.

Figura 12 - Detecção de bordas Canny



Fonte: Cervantes e Gómez (2019)

Sendo que, de acordo com Cervantes e Gómez (2019), o valor σ que aparece na **Erro! Fonte de referência não encontrada.**, refere-se à um parâmetro utilizado para o efeito de desfoque. Quando o valor deste parâmetro é 1, observa-se que a imagem apresenta menos efeito

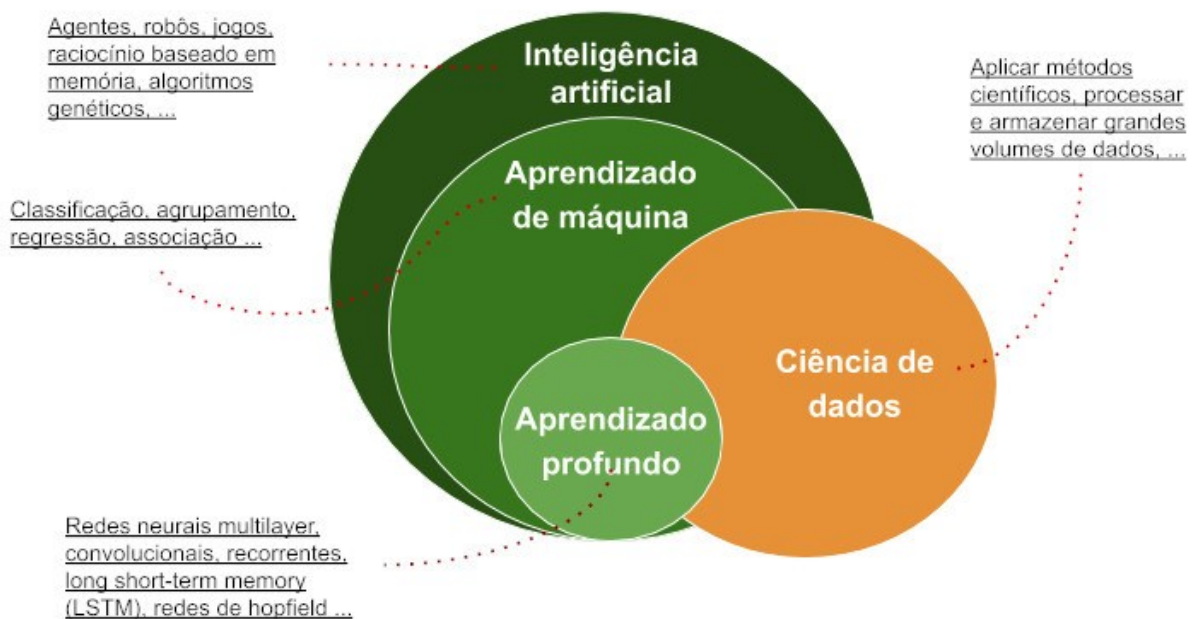
Gaussiano, ou seja, a imagem apresenta muitos detalhes, enquanto que, quando o valor do parâmetro é 3, nota-se que, a imagem possui mais efeito gaussiano e apresenta menos detalhes se comparado à $\sigma=1$. No entanto, apesar de possuir menos detalhes, é mais fácil a identificação do contorno.

6 REDES NEURAIS

De acordo com Braga (2000), a área de Redes Neurais Artificiais (RNAs) também é conhecida por connexionismo. Segundo Osório e Bittencourt (2000), o connexionismo é baseado no estudo do funcionamento do cérebro humano. Desta forma, têm-se que as redes neurais biológicas serviram de motivação para as redes neurais artificiais, e portanto, para a devida compreensão do assunto. Neste capítulo será feita uma contextualização sobre neurônio biológico.

A inteligência artificial é um campo da ciência que estuda agentes, robos, jogos e etc. A inteligência artificial engloba o aprendizado de máquina que estuda classificação, agrupamento, regressão, associação etc., aprendizado profundo que estuda redes neurais multicamadas, convolucionais, e também a ciência de dados que aplica métodos científicos, processa e armazena grande volume de dados. Na Figura 13 é possível ver como estas áreas estão relacionadas.

Figura 13 - Relação entre inteligência artificial, aprendizado de máquina, ciência de dados e aprendizado profundo




Fonte: Dias (2021)

Sendo assim, o estudo deste capítulo é focado no aprendizado profundo, visto que, neste capítulo o objetivo é compreender como é o funcionamento das redes neurais multicamadas (rede neural *feedforward*) bem como das redes convolucionais que são utilizadas na visão computacional.

6.1 Neurônio biológico

Segundo Medeiros (2018), os neurônio biológicos foram descobertos no início do século XX pelo neurofisiologista Santiago Ramon y Cajal. Além disso de acordo com Loesch (1996), o neurônio biológico é composto pelo corpo, também chamado de soma, pelo axônio que serve para conduzir impulso nervoso entre os neurônios e possui ramificações que são denominadas dendritos. O esquema de um neurônio biológico é mostrado na Figura 14.

Figura 14 - Neurônio Biológico



Fonte: Data Science Academy (2021)

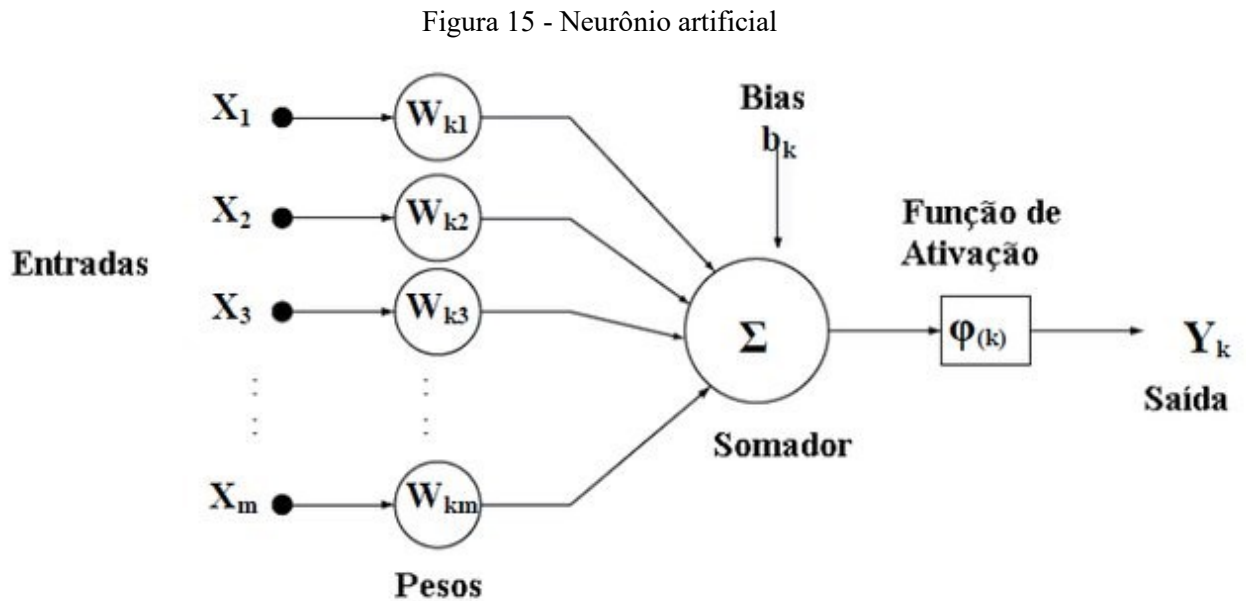
A transmissão do impulso nervoso de um neurônio para outro é feito por meio das sinapses (FURTADO, 2019). As sinapses, são regiões eletroquimicamente ativas, compreendidas entre a membrana que gera o estímulo para outra célula, sendo esta denominada membrana pré-sináptica e a membrana pós-sináptica que recebe o estímulo, sendo que este estímulo nervoso que chega à membrana dentrital é feito por meio de neurotransmissores.

A sinapse é chamada de excitatória quando o neurotransmissor que é liberado nas regiões da sinapse atua de forma a excitar a membrana pós-sináptica, fazendo com que impulsos nervosos sejam disparados por esta. Por outro lado, a sinapse é denominada inibitória quando dificulta o início de novos impulsos nervosos (COSENZA; GUERRA, 2011).

6.2 Modelo de Neurônio artificial

Em 1943, McCulloch e Pitts propuseram o primeiro modelo artificial de um neurônio

biológico (BRAGA; CARVALHO; LUDEMIR, 2010). Neste modelo proposto, os neurônios se caracterizam por estarem ativados ou desativados, sendo a ativação uma resposta à estimulação de neurônios vizinhos (NORVIG; RUSSELL, 2004). O modelo proposto por McCulloch e Pitts é mostrado na Figura 15.



Fonte: Souza *et al.* (2011)

Como o neurônio artificial é inspirado no neurônio biológico, é possível comparar as estruturas presentes em cada um deles, e portanto, ao comparar a Figura 14 com a Figura 15 tem-se que ramificações de um neurônio, dendritos, são representadas através das entradas (X_1, X_2, X_3 e X_m), as sinapses são representadas pelos pesos (W_{k1}, W_{k2}, W_{k3} e W_{km}), o corpo celular é representado pelo somador enquanto que o axônio é representado pela função de ativação (BARCA; SILVEIRA; MAGINI, 2005).

O somador no modelo de McCulloch e Pitts representa a soma ponderada, sendo que esta soma alimenta uma função de transferência (função de ativação). Segundo Haykin (2001), a equação do Somador (representado por u_k) é mostrada pela Equação 1.

$$u_k = \sum_{j=1}^m W_{kj} X_j = X_1 W_{k1} + X_2 W_{k2} + X_3 W_{k3} + \dots + X_m W_{km} \quad (1)$$

Após a função soma alimenta a função de ativação (MINUSSI; LOTUFO, 2008). Se o valor da função soma ultrapassar um limiar μ , o neurônio dispara o valor 1 na saída e se não ultrapassar este limiar, então a saída será 0. Portanto, conclui-se que este modelo se baseia na

hipótese de que a atividade de um neurônio é binária. (RAUBER, 2005).

Sendo assim, de acordo com Sanchez 2009, a função de ativação utilizada no modelo de McCulloch e Pitts (função Degrau) pode ser representada pela Equação 2.

$$F(\text{Somador}) = \begin{cases} 1 & \text{Se somador} \geq 0 \\ 0 & \text{Se somador} < 0 \end{cases} \quad (2)$$

É importante destacar ainda que, a função de ativação deste modelo proposto por McCulloch e Pitts não é o único capaz de produzir um valor de saída (RAUBER, 2005). Desta forma, serão discutidas mais a fundo a seguir sobre funções de ativação.

Além disso, observa-se ainda que o modelo de um neurônio artificial proposto na Figura 15, possui também bias (b_k), que de acordo com Haykin (2001), se este for positivo possui o efeito de aumentar a entrada líquida da função de ativação e se for negativo, possui o efeito de diminuir a entrada, de forma que a Equação do Sinal de saída é representada pela Equação 3.

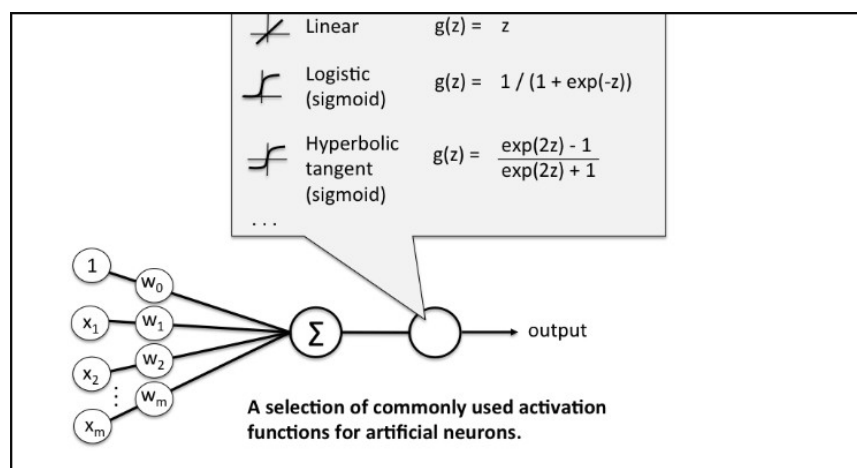
$$Y_k = \varphi(u_k + b_k) \quad (3)$$

onde, Y_k representa o sinal de saída do neurônio, φ representa a função de ativação, u_k o somador e b_k o bias.

6.3 Funções de ativação

De acordo com Haykin (2001), as funções de ativação servem para restringir a amplitude de saída de um neurônio. Alguns exemplos de funções de ativação são mostrados na Figura 16.

Figura 16 - Funções de ativação



Fonte: Walia (2020)

6.4 Coleta e divisão de dados em uma RNA

Segundo Furtado (2019), o desenvolvimento de redes neurais artificiais inicia-se com a coleta de dados relativos ao problema em questão. Após esta coleta de dados, os dados são separados em:

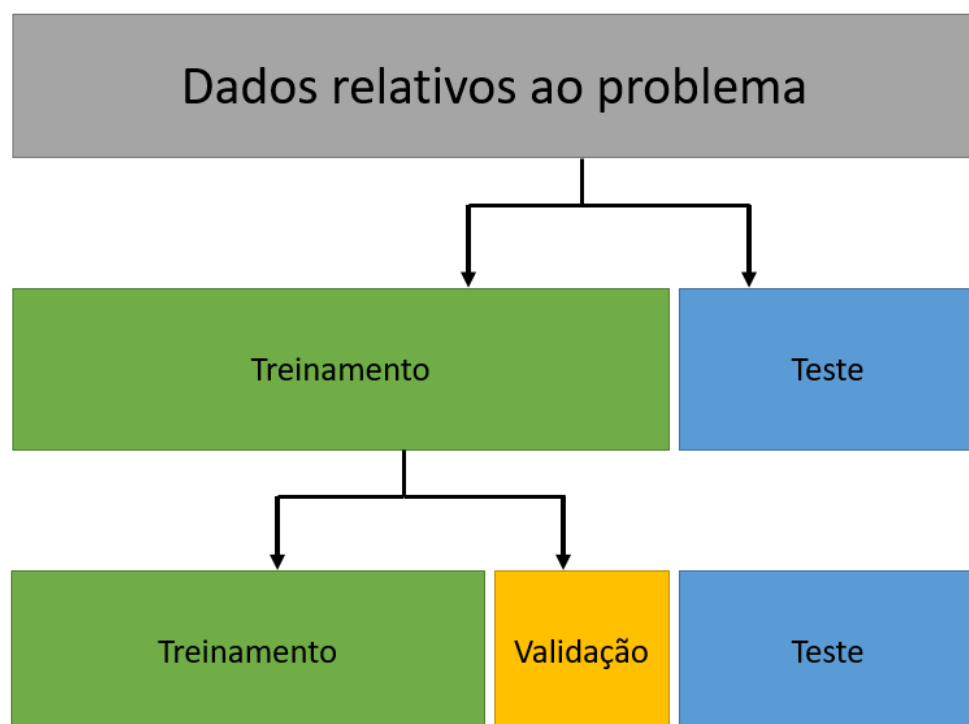
- Dados de treinamento: são utilizados para treinar a rede neural artificial
- Dados de teste: são utilizados com o objetivo de verificar a performance da rede neural artificial em condições reais de utilização

Ainda de acordo com Furtado (2019), além dos dados de treinamento e de teste, o conjunto de dados de treinamento pode ser classificado em:

- Validação: estes dados são utilizados para analisar a eficiência da capacidade de generalização da rede neural artificial durante o treinamento.

Sendo assim, a divisão dos dados no desenvolvimento de uma rede neural artificial é exemplificada na Figura 17.

Figura 17- Divisão de dados no desenvolvimento de uma RNA




Fonte: Autor (2022)

Após esta divisão dos dados, estes são aleatorizados para evitar tendências associadas à ordem com que estes dados são apresentados. Importante ressaltar também que pode ser necessário pré-processar os dados, por meio de normalizações e escalonamentos, pois, desta forma, podem se tornar mais apropriados para que sejam utilizados na rede (FURTADO, 2019).

6.5 Rede neural *feedforward*

De acordo com Ferreira *et al.* (2016), o *perceptron* de multicamadas (MLP) é constituído por uma camada de entrada, uma ou mais camadas ocultas, que são as camadas intermediárias e a camada de saída. Sendo que, segundo Alsmadi (2009) ao variar o número de camadas, a complexidade deste tipo de rede pode ser alterada. A representação de um *perceptron* multicamadas, também chamado de ANN *feedforward* com *backpropagation* é mostrado na Figura 18.

Figura 18 - Representação de uma ANN *feedforward* com *backpropagation*



Fonte: Fiorin (2011)

De acordo com González-Arjona, López-Pérez e Gustavo González (2002), *perceptrons* multicamadas são redes multicamadas *feedforward*, sendo que de acordo com Furtado (2019), uma rede neural é considerada do tipo *feedforward*, quando as conexões são sempre no sentido da camada de entrada para a camada de saída. Além disto, a rede neural é denominada conectada quando todos os nós de uma camada são conectados com todos os nós da camada posterior.

Segundo Aliaga *et al.* (2008), utiliza-se o algoritmo de retropropagação (do inglês: *backpropagation*) para treinar *perceptrons* multicamadas. De acordo com Rojas (1996), este algoritmo busca encontrar a combinação de pesos que minimiza a função erro.


Conforme Miguez, Maculan e Xavier (2012), ao se utilizar o algoritmo *backpropagation* durante o treinamento de redes neurais, primeiramente, apresenta-se um padrão à camada de entrada, e o sinal passa camada por camada, até que seja obtido o resultado da camada saída. Em seguida, compara-se esta saída com a saída desejada, obtendo-se o erro. Este erro propaga-se desde a camada de saída até a camada de entrada, e então, os pesos das camadas internas vão se modificando ao passo que o erro se propaga.

6.6 Rede Neural Convolutacional

O termo aprendizagem profunda (do inglês: *deep learning*), refere-se as redes neurais artificiais que apresentam múltiplas camadas. Estas redes começaram a ganhar destaque, devido a capacidade de serem utilizadas para problemas envolvendo grande quantidade de dados e por possuírem desempenho maior para reconhecimento de padrões. Uma das redes mais populares de aprendizagem profunda é a Rede Neural de Convolução (ALBAWI; MOHAMMED; AL-ZAWI, 2018).

Segundo Wang e Raj (2017), as Redes Neurais Convolucionais são inspiradas no córtex visual, sendo que, este é localizado no lobo occipital que é importante no processamento de imagens. A localização do lobo occipital é mostrada na Figura 19.

Figura 19 - Localização dos lobos



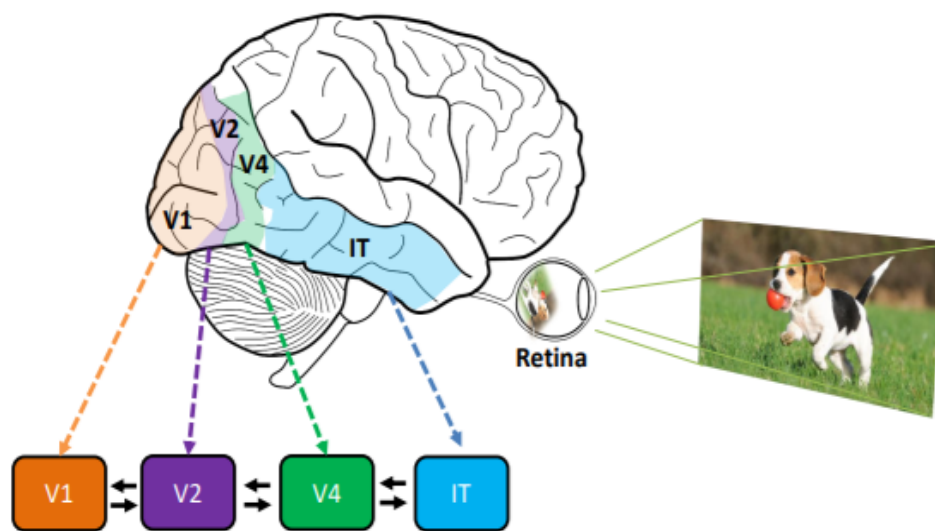
Fonte: Huang (2020)

Conforme Wang e Raj (2017) uma imagem é formada, de forma simplificada, através dos componentes:

- Retina: A energia proveniente da luz que é refletida por um objeto é convertida em energia química que é convertida em impulsos nervosos (ou potenciais de ação) que posteriormente são transferidos para o córtex visual primário.
- Córtex visual primário (V1): detecção de borda das imagens
- Córtex visual secundário (V2): detecção de formato e cor de objetos.
- V4: detecção de objetos
- Giro temporal inferior (TI): detecção de face

Ainda de acordo com Wang e Raj (2017), existem outras áreas visuais denominadas V3, V5 e V6, no entanto, as áreas visuais que são relacionadas ao reconhecimento de objetos são (V1, V2, V4 e TI). Sendo assim, as áreas visuais que são relacionadas ao reconhecimento de objetos são mostradas na Figura 20.

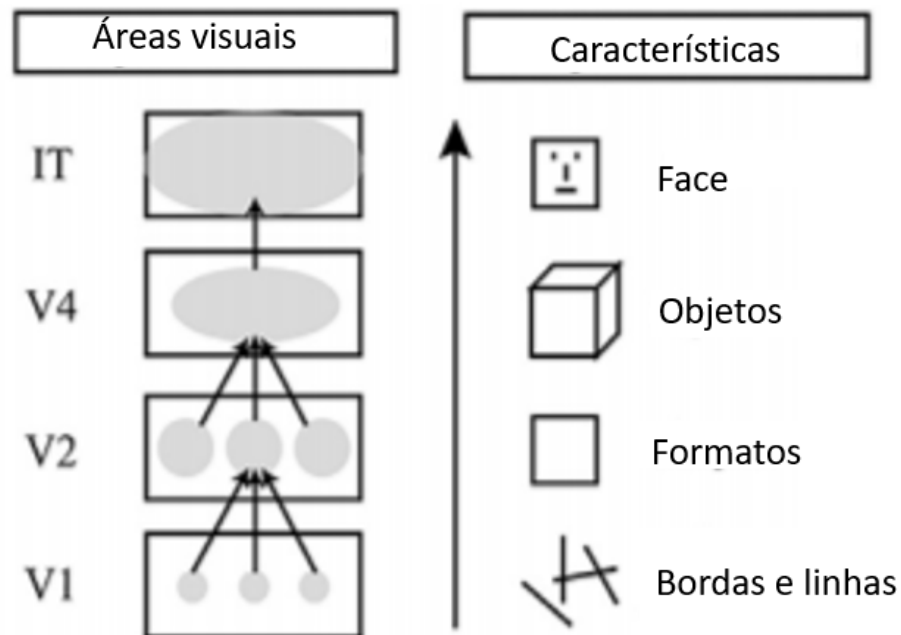
Figura 20 - Localização das áreas visuais que são relacionadas ao reconhecimento de objetos



Fonte: Roffo (2017)

Além disto, é mostrada na Figura 21, as áreas visuais e as respectivas características das imagens que são reconhecidas em cada área visual.

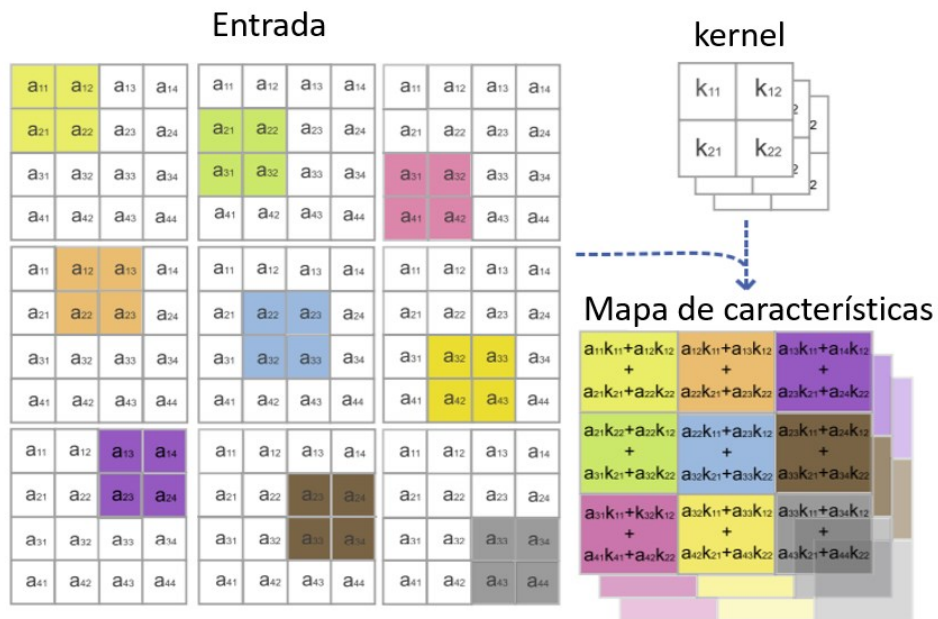
Figura 21 - Áreas visuais e características da imagem



Fonte: Xu *et al.* (2019)

Para compreender como é realizada a rede neural convolucional, é necessário relembrar que, como mencionado no Capítulo 3, para o computador, as imagens são vistas como matrizes, sendo assim, na Figura 22, têm-se que a entrada da rede convolucional é uma matriz genérica que representa uma imagem. Após fornecer essa imagem como entrada para a rede convolucional, aplica-se o kernel, sendo que o kernel é uma matriz utilizada para uma operação de multiplicação de matrizes. Para aplicar o kernel na matriz entrada, segundo Singh (2020), multiplica-se cada pixel de um subconjunto da matriz entrada pelo valor correspondente do kernel, sendo esse processo realizado de forma a percorrer todos os subconjuntos da matriz, formando um mapa de características.


Figura 22 - Aplicação dos kernels



Fonte: Cao *et al.* (2018)

Segundo Singh (2020), após ser formado o mapa de características, é aplicada uma função de ativação, sendo que geralmente opta-se por aplicar a função ReLu (unidade linear retificada), sendo que ao utilizar esta função de ativação, os valores maiores ou iguais a zero permanecem com o mesmo valor, enquanto valores negativos se tornam zero. A função ReLu é mostrada na Figura 23.

Figura 23 - Função Relu



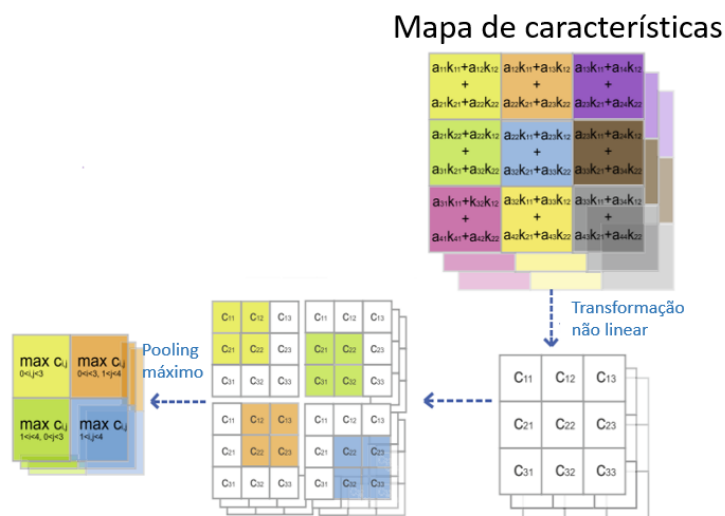
Fonte: Singh (2020)

De acordo com Cao *et al.* (2018), depois de aplicar a função ReLu, existe uma camada

de *pooling* que serve para capturar características essenciais do mapa de características, sendo que, segundo Yu et al. (2014), os tipos mais comuns de *pooling* médio e *pooling* máximo. Conforme Eberman e Krohling (2018), no *pooling* médio, calcula-se a média dos valores presentes nas regiões do mapa de característica, enquanto o *pooling* máximo apenas seleciona o maior valor nessas regiões.

Após a multiplicação de cada pixel de um subconjunto da matriz entrada pelo valor correspondente do kernel (Figura 22), e após a aplicação da função Relu, têm-se na Figura 24, o *pooling* máximo, que seleciona o maior valor de cada subconjunto.

Figura 24 - Transformação não-linear e *pooling* máximo

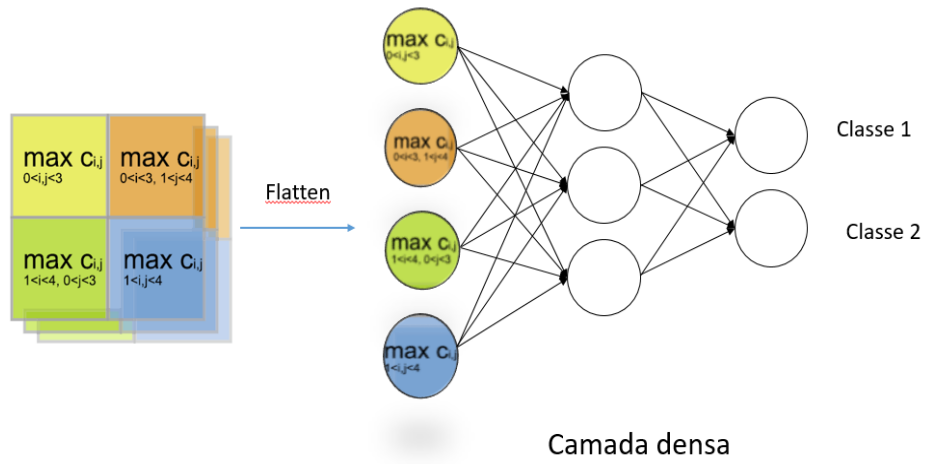


Fonte: Cao *et al.* (2018)

De acordo com Taqi *et al.* (2018), em uma rede neural convolucional, após a camada de *pooling* utiliza-se o *flatten* para criar um vetor coluna. Ou seja, a matriz após o *pooling* máximo, que contém duas linhas e duas colunas, com o *flatten* passará a ter quatro linhas e apenas uma coluna como se pode ver na Figura 25.

Em seguida, existe uma camada denominada camada densa (do inglês: *Fully Connected Layer*), que de acordo com Singh (2020), esta é igual a uma rede neural artificial (ANN) em que os neurônios possuem completa conexão com as ativações das camadas anteriores, sendo que conforme Janke, Castelli e Popovič (2019), na classificação de imagens, é na camada densa que surgem os resultados finais de classificação.

Figura 25 - Camada densa



Fonte: Autor (2022)

7 MATERIAIS E MÉTODOS

7.1 Aquisição das matéria prima

Adquiriu-se em setores produtores de frutas na região de Araraquara-SP (cidade pertencente ao Cinturão Citrícola), laranjas de uso industrial de suco, com estágio ideal de maturação. Importante ressaltar que a variedade escolhida para ser matéria prima desta pesquisa foi a laranja pera e o suco utilizado destas frutas foi do tipo integral.


7.2 Aquisição de imagens

Para a análise das imagens, construiu-se um dispositivo para aquisição das imagens associadas ao estudo, para que dessa forma pudesse garantir a ausência de efeitos de sombra e a uniformidade da iluminação nas imagens obtidas. O dispositivo para aquisição de imagens é composto por:

- Uma caixa plástica vazada preta.
- Iluminação: Utilizou-se uma iluminação Led em formato de anel, possuindo 16 cm de diâmetro, com tom de branco neutro. Colocou-se esta iluminação na parte interna superior da caixa plástica vazada preta.
- Furo centrado na parte superior da caixa plástica vazada preta: utilizou-se este furo para o encaixe do celular que foi utilizado para obter as imagens. Importante ressaltar que a iluminação utilizada, por ser em formato de anel, ficou posicionada simetricamente ao redor deste furo, garantindo, portanto, a ausência de sombra nas imagens adquiridas.
- Plataforma para colocação da fruta, sendo montada a 19 do furo onde o celular foi posicionado. Esta distância entre o furo centrado na parte superior da caixa plástica vazada preta e a plataforma para colocação da fruta foi mantida constante durante a aquisição das imagens, com o objetivo de padronizar a forma com que as imagens foram obtidas;
- Celular utilizado para obter as imagens: Utilizou-se um celular da marca iPhone modelo 7, com câmera de 12 megapixels para aquisição das imagens. Destaca-se ainda que, não se utilizou flash para fotografar, ou seja, a iluminação utilizada foi unicamente proveniente da iluminação em formato de anel utilizada no dispositivo de aquisição de imagens.


É possível ver o dispositivo utilizado para aquisição das imagens na Figura 26 e na Figura 27.

Figura 26 - Vista frontal do dispositivo de aquisição de imagens



Fonte: Autor (2022)

Figura 27 - Vista superior do dispositivo de aquisição de imagens



Fonte: Autor (2022)

7.3 Dispositivos utilizados para avaliação de parâmetros do suco de laranja

- 7.3.1 Determinação da concentração de açúcares solúveis utilizando a escala Brix
Para determinar a concentração de açúcares solúveis utilizando-se a escala Brix,

utilizou-se um refratômetro da marca Lorben, modelo GT427, com leitura na Faixa 0 a 32% e com precisão de 0,2 graus BRIX, possuindo a opção ATC (Compensação de temperatura automática) de 10°C a 30°C. O refratômetro utilizado é mostrado na Figura 28.


Figura 28 - Refratômetro da marca Lorben



Fonte: Autor (2022)

Para a medição do grau Brix, primeiramente calibrou-se o refratômetro, sendo que para esta calibração abriu-se a tampa do dispositivo e colocou-se 2 gotas de água destilada deionizada (pura) e fechou-se a tampa. Em seguida, apontou-se a extremidade frontal do dispositivo em direção a luz branca e com o auxílio de uma chave de fenda no parafuso de calibração, ajustou-se o zero, colocando-se a faixa escura sobre o zero, como se pode ver na Figura 29.

Figura 29 - Leitura do refratômetro



Fonte: Autor (2022)

Após a calibração foi possível medir o grau Brix dos sucos 60 laranjas, abrindo-se a tampa e colocando-se duas gotas de cada suco, e em seguida, fechando-se a tampa e fazendo a leitura correspondente entre o limite de luz clara/escuro. Importante destacar que se limpou o refratômetro com água destilada entre as medidas de sucos provenientes de laranjas diferentes.

7.3.2 Medição do pH

Para medição do pH dos sucos obtidos das 60 laranjas utilizadas, utilizou-se um pHmetro da marca 2 Vintens com precisão de $\pm 0,01$ pH. O pHmetro utilizado pode ser visto na Figura 30.

Figura 30 – pHmetro da marca 2Vintens



Fonte: Autor (2022)

Para medição do pH, primeiramente preparam-se soluções tampões de $\text{pH} = 6,86$, $\text{pH} = 4,00$ e $\text{pH} = 9,18$. Em seguida, tirou-se a tampa e limpou-se o eletrodo com água destilada para

fazer leitura da solução de $\text{pH} = 6,86$ e pressionou-se cal durante 5 segundos e conferiu-se a leitura do pHmetro. Depois, limpou-se novamente o eletrodo com água destilada e repetiu-se o mesmo procedimento para a solução de $\text{pH} = 4,00$ e para solução de $\text{pH} = 9,18$.

Após a calibração foi possível medir o pH do suco de laranja ao se inserir o eletrodo no suco. Importante destacar que entre uma medição e outra, limpou-se o eletrodo com água destilada, para evitar erros na medição.

7.3.3 Medição do Volume

Para medição do volume dos sucos obtidos das laranjas, utilizou-se uma proveta graduada de 250mL da marca Nalgon é mostrada na Figura 31.

Figura 31 - Proveta graduada de 250mL



Fonte: Autor (2022)

Para medição dos volumes referentes aos sucos de laranjas analisados, colocou-se a proveta graduada na bancada, encheu-se com suco de laranja e com os olhos na direção da

proveta, analisou-se o menisco, obtendo o volume. Repetiu-se o processo para o suco de todas as laranjas.

7.3.4 Paquímetro

Para medir o comprimento e largura das laranjas utilizou-se o paquímetro digital. Para a medição, ligou-se o paquímetro, abriram-se as pinças, e então, colocaram-se as laranjas entre as pinças, obtendo-se assim as medidas no visor do paquímetro. O paquímetro utilizado pode ser visto na Figura 32.

Figura 32 - Paquímetro




Fonte: Autor (2022)

7.4 Outros materiais utilizados


A fim de simular laranjas, utilizaram-se 100 objetos poliméricos látex de cor amarela (Figura 33), preenchidos com diferentes volumes de água, como se pode ver no Gráfico 4.

Figura 33- Objeto polimérico látex amarelo



Fonte: Autor (2022)

Gráfico 4 - Volumes de água para cada um dos ensaios



Fonte: Autor (2022)

7.5 Recursos computacionais

Para a elaboração desta pesquisa, optou-se pela linguagem Python, visto que esta linguagem possui sintaxe intuitiva. Além disto, a sua utilização possui vantagens como extensa documentação, código aberto, comunidade ativa e colaborativa. Nesta pesquisa utilizaram-se:

- Biblioteca pandas: serve para manipular e analisar dados.

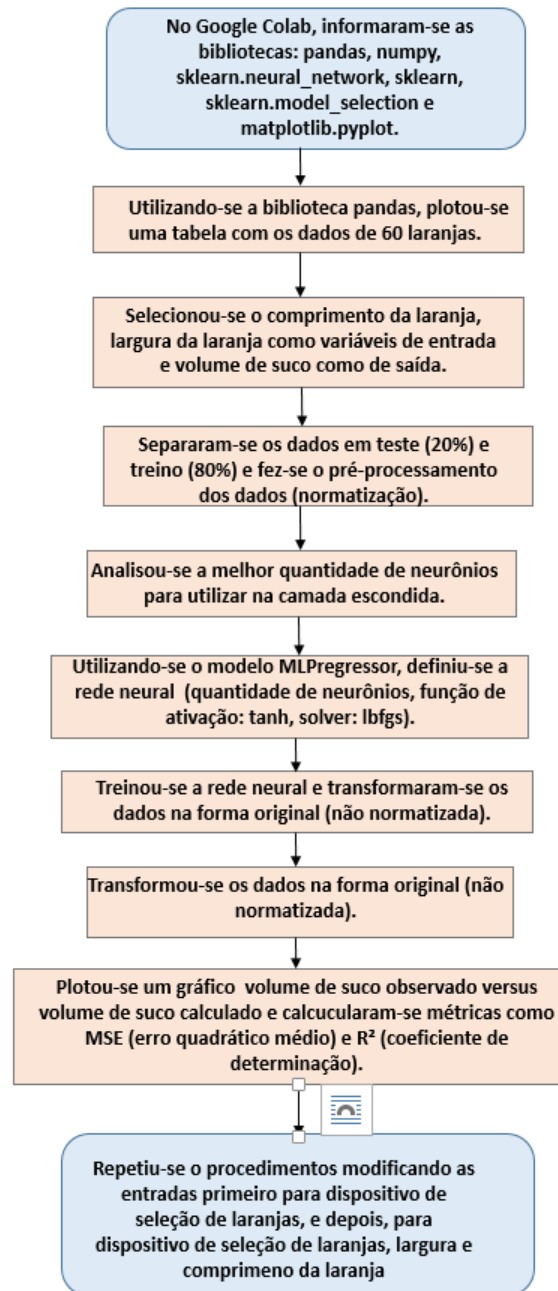
- Biblioteca numpy: esta biblioteca permite a utilização de funções para computação numérica.
- Biblioteca sklearn.neural_network: esta biblioteca permite a definição da rede neural, permitindo a utilização do MLPRegressor, sendo este utilizado para definir a rede neural de regressão para um *perceptron* de multicamadas (rede neural *feedforward*), ou ainda, a utilização do MLPClassifier, utilizado para a classificação.
- Biblioteca Sklearn: esta biblioteca permite utilizar o *preprocessing*, para normalizar os dados para que estes se tornem apropriados para serem utilizados na rede neural
- Biblioteca Sklearn.model_selection: esta função da biblioteca sklearn permite separar os dados em dados de treino e dados de teste .
- Biblioteca Matplotlib.pyplot: permite plotar gráficos
- Biblioteca keras.models: permite importar a função *Sequential* que possibilita definir cada camada da rede neural de convolução.
- Biblioteca keras.layers: permite utilizar o comando *Activation* (função de ativação), Cov2D (camada de convolução), *flatten* e etc.
- Biblioteca cv2: biblioteca utilizada para processamento de imagens
- Biblioteca random: biblioteca que permite o fornecimento de números aleatórios.
- Biblioteca Zipfile: permite criar, extrair e abrir arquivos no formato .zip
- Biblioteca skimage: permite utilizar o filtro Canny para detecção de bordas e permite também a utilização de medidas estatísticas para analisar a textura de imagens.

Utilizando-se estes recursos computacionais mencionados acima, fizeram-se três redes neurais do tipo *feedforward* com *backpropagation* como mostra a Tabela 5. Sendo mostrado na Figura 34 o fluxograma de como foram feitas essas redes neurais.

Tabela 5 - Redes neurais *feedforward* com *backpropagation*

Rede neural	Entradas	Saída
Primeira rede neural	Comprimento da laranja e largura da laranja	Volume de suco
Segunda rede neural	Dispositivo de seleção	Volume de suco
Terceira rede neural	Comprimento da laranja largura da laranja e dispositivo de seleção	Volume de suco

Fonte: Autor (2022)

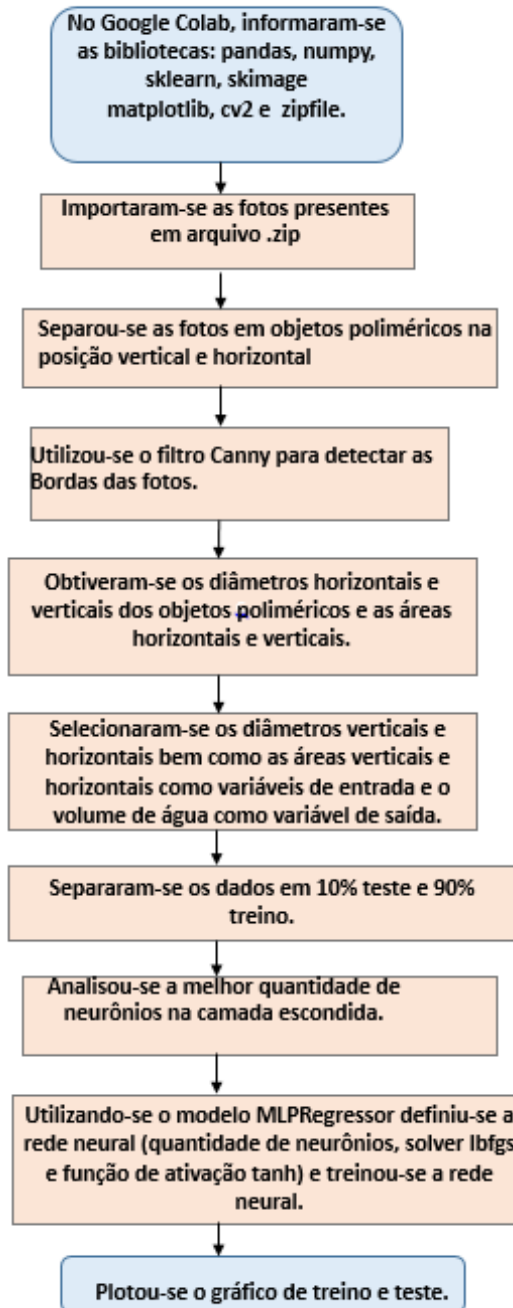
Figura 34 - Fluxograma da rede neural *feedforward* para regressão

Fonte: Autor (2022)

O fluxograma de como elaborou-se uma rede neural *feedforward* com *backpropagation* para regressão utilizando-se fotografias de objetos poliméricos látex é mostrado na Figura 35.

Figura 35- Fluxograma da Rede Neural *feedforward* com *backpropagation* para objetos poliméricos

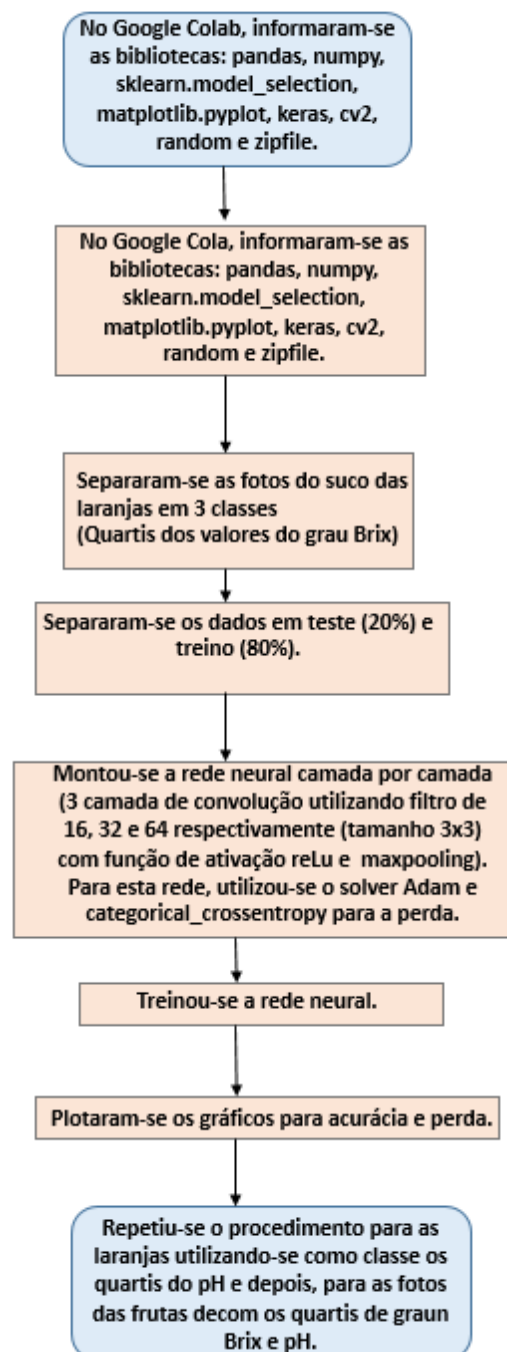
látex



Fonte: Autor (2022)

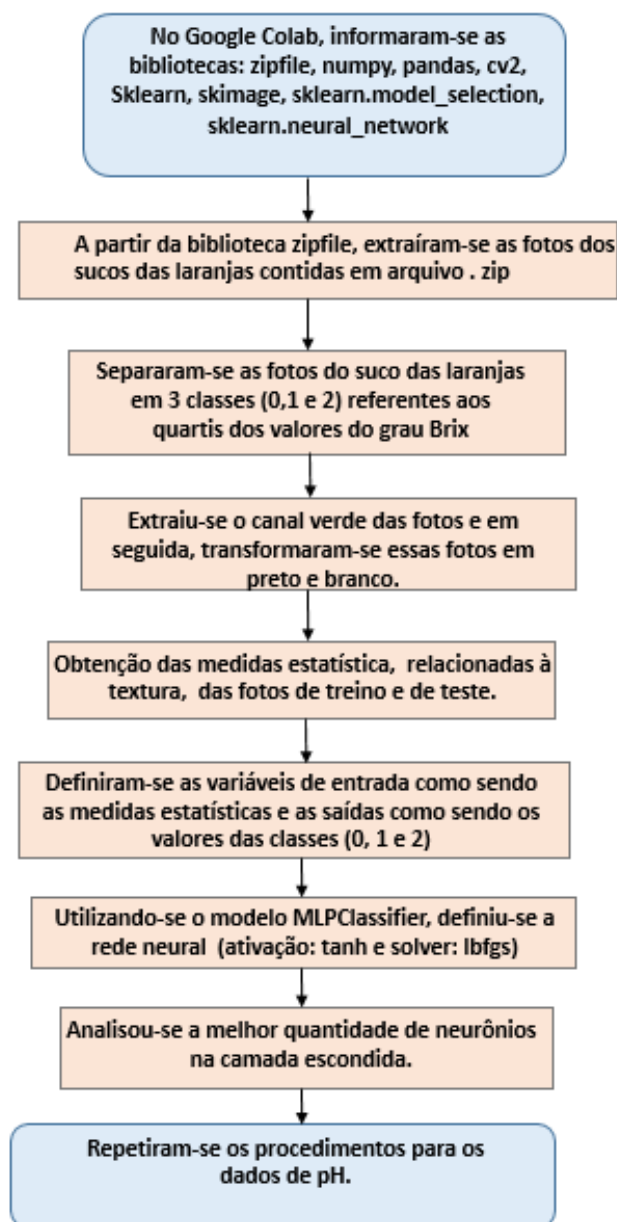
Utilizando-se estes recursos computacionais, também foram feitas redes neurais convolucionais tanto para o grau Brix quanto para o pH para fotografias do suco de laranja bem como das cascas das laranjas. O fluxograma de como foram feitas estas redes neurais é apresentado na Figura 36.

Figura 36 - Fluxograma das redes neurais convolucionais



Utilizando-se estes recursos computacionais, foram feitas redes neurais *feedforward* com *backpropagation* tanto para o grau Brix quanto para o pH para as fotografias do suco de laranja. O fluxograma de como foram feitas estas redes neurais é apresentado na Figura 37.

Figura 37 - Fluxograma da rede neural *feedforward* com *backpropagation* realizada para a classificação do pH e do grau Brix.



Fonte: Autor (2022)

8 RESULTADOS

8.1 Regressão utilizando ANN *feedforward* com *backpropagation*

Os resultados de volume (utilizando-se a proveta), pH (obtidos utilizando-se o pHmetro), grau Brix (obtido utilizando-se o refratômetro), comprimento da laranja e largura da laranja (obtidos com paquímetro) das 60 laranjas analisadas são mostrados na Tabela 6.

Tabela 6 - Resultados obtidos a partir da análise das laranjas

Laranja	Volume de suco (mL)	pH suco	Brix suco	Comprimento da laranja (cm)	Largura da laranja (cm)
1	46,00	3,90	11,40	5,74	5,96
2	84,00	3,88	10,20	6,67	6,88
3	50,00	4,16	10,10	6,04	5,71
4	90,00	4,02	11,10	6,71	6,67
5	52,00	4,04	11,40	5,52	5,56
6	116,00	3,90	9,30	7,02	6,90
7	37,00	4,34	8,90	5,82	5,57
8	94,00	4,27	8,60	6,89	6,96
9	59,00	4,01	10,2	5,68	5,60
10	116,00	4,03	8,60	7,04	6,83
11	50,00	4,16	9,40	5,48	6,06
12	85,00	3,97	9,00	6,33	6,03
13	48,00	4,43	9,20	5,53	5,73
14	51,00	4,28	9,60	6,21	5,69
15	84,00	4,21	10,00	6,39	6,70
16	58,00	4,42	9,00	5,72	5,98
17	79,00	4,25	9,00	6,00	6,12
18	54,00	4,04	8,90	6,33	6,05
19	66,00	4,09	11,80	5,83	6,05
20	102,00	4,29	10,00	7,08	6,87
21	88,00	4,04	10,00	6,40	6,23
22	95,00	3,97	9,00	6,41	6,53
23	62,00	4,26	10,00	6,46	6,40
24	96,00	4,19	9,90	6,81	7,09
25	66,00	3,88	10,40	6,15	6,27
26	90,00	3,73	10,30	6,44	6,67
27	65,00	4,05	8,70	6,29	6,02
28	116,00	3,98	9,30	7,06	6,97
29	74,00	3,84	9,30	5,86	6,06
30	95,90	4,06	9,20	6,65	6,66

Fonte: Autor (2022)

Tabela 6 – Resultados obtidos a partir da análise das laranjas (continuação)

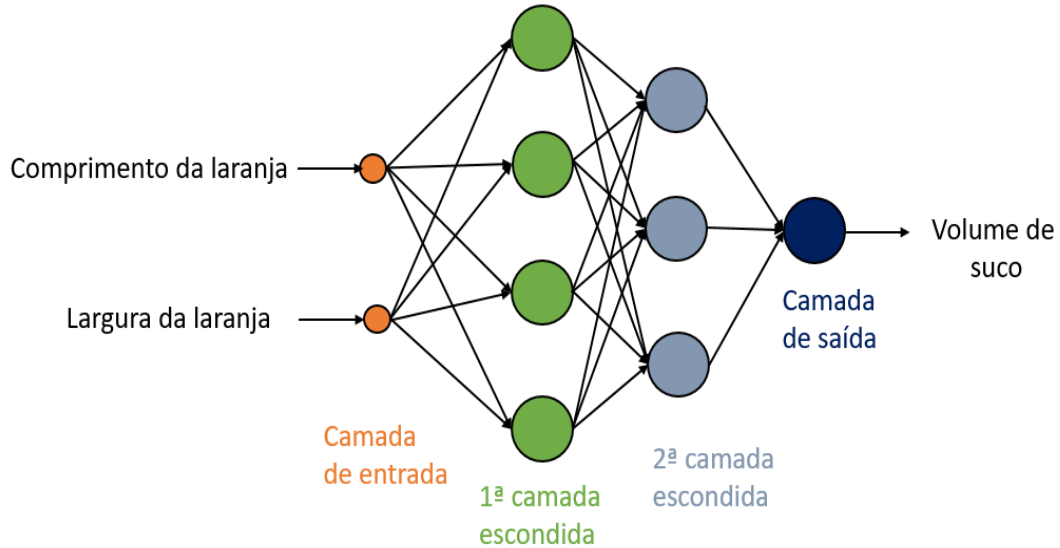
Laranja	Volume de suco (mL)	pH do suco	Brix suco	Comprimento da laranja (cm)	Largura da laranja (cm)
31	90,00	3,90	9,00	6,20	6,17
32	130,00	3,95	9,00	7,54	7,12
33	80,00	4,10	8,90	6,04	6,29
34	97,00	3,91	10,20	6,75	6,78
35	118,00	3,90	9,40	7,19	7,02
36	85,00	3,98	10,30	6,92	6,33
37	104,00	3,90	9,60	7,07	7,11
38	74,00	3,64	12,40	6,36	6,13
39	110,00	3,89	10,00	7,57	7,10
40	108,00	3,84	9,20	6,98	7,07
41	66,00	4,60	8,00	6,98	6,78
42	61,00	3,71	10,10	5,96	6,04
43	100,00	3,94	9,30	6,52	6,83
44	113,00	3,97	8,00	6,81	7,03
45	62,00	4,03	9,5	6,40	6,20
46	94,00	4,12	10,10	6,89	6,54
47	84,00	4,20	9,00	6,73	6,33
48	98,00	4,20	9,00	6,77	6,75
49	101,00	4,14	7,00	7,09	6,52
50	98,00	4,05	8,40	6,94	7,04
51	86,00	4,04	10,00	6,45	6,59
52	73,00	3,68	10,30	6,84	6,67
53	83,00	3,94	9,40	6,51	6,30
54	86,00	4,22	11,40	6,42	6,70
55	88,00	4,07	9,50	6,60	6,14
56	90,00	4,06	9,60	6,61	6,52
57	88,00	4,09	9,40	6,83	6,41
58	70,00	4,26	10,00	6,81	6,65
59	91,00	4,20	9,20	6,91	6,60
60	89,00	4,06	9,30	6,44	6,38

Fonte: Autor (2022)

De acordo com a Figura 34, apresentada no Capítulo de Materiais e Métodos, foram elaboradas redes neurais *feedforward* com *backpropagation* para realizar regressão, utilizando-se a linguagem de programação Python. Analisaram-se o desempenho de três redes neurais do tipo *feedforward* com *backpropagation*, sendo que a diferença entre estas está apenas nas variáveis utilizadas como entrada. Sendo assim, para dados de 60 laranjas apresentados na Tabela 6 elaborou-se a primeira rede com entradas: comprimento e largura da laranja e como saída o volume de suco, sendo esta variável com unidade de medida em mL), esta rede neural

é mostrada na Figura 38.

Figura 38 - Rede Neural *feedforward* com *backpropagation* com entradas: comprimento e largura da laranja.



Fonte: Autor (2022)


Analisou-se que seria melhor utilizar 4 neurônios na primeira camada escondida e 3 neurônios na segunda camada escondida, visto que com essa quantidade de neurônios obteve-se maior R^2 referente ao treino e ao teste. O resultado da regressão utilizando-se esta rede neural é apresentada na Tabela 7 e no Gráfico 5.

Tabela 7 - Resultados de MSE e R^2 referente ao treino e ao teste para Rede Neural *feedforward* com *backpropagation* com entradas: comprimento e largura da laranja.

MSE do treino	R^2 do treino	MSE do teste	R^2 do teste
103,4891	0,7503	142,3742	0,5941

Fonte: Autor (2022)


Gráfico 5 - Volume de suco calculado versus volume de suco observado para Rede Neural *feedforward* com *backpropagation* com entradas: largura e comprimento da laranja.



Fonte: Autor (2022)

Buscando-se melhorias no valor do coeficiente de determinação (R^2), elaborou-se um dispositivo para classificar laranjas pelo tamanho. Para isto, utilizou-se uma caixa de papelão contendo 6 aberturas em formato de círculos, com diferentes diâmetros como se pode ver na Figura 39 e na Tabela 8.

Figura 39 - Dispositivo para seleção de laranjas



Fonte: Autor (2022)

Tabela 8 - Diâmetro em cm referente a cada furo do dispositivo para seleção de laranjas.

Número da Abertura	Diâmetro da Abertura (cm)
1	5,50
2	6,00
3	6,50
4	7,00
5	7,50
6	8,00

Fonte: Autor (2022)

Cada uma das 60 laranjas foi testada a fim de determinar qual a abertura com menor diâmetro possível pelo qual cada laranja foi capaz de passar, e anotou-se o valor de abertura referente a cada laranja. Os resultados obtidos são mostrados na Tabela 9.


Tabela 9 - Abertura que cada uma das 60 laranjas atravessou.

Laranja	Abertura	Laranja	Abertura
1	3	31	3
2	5	32	5
3	2	33	3
4	4	34	4
5	2	35	5
6	5	36	3
7	2	37	5
8	6	38	3
9	2	39	5
10	5	40	5
11	3	41	4
12	3	42	3
13	2	43	4
14	2	44	5
15	4	45	3
16	3	46	4
17	3	47	3
18	3	48	4
19	3	49	4
20	5	50	5
21	3	51	4
22	4	52	4
23	4	53	3
24	5	54	4
25	3	55	3
26	4	56	4
27	3	57	4
28	5	58	4
29	3	59	4
30	4	60	3

Fonte: Autor (2022)

A partir dos dados da Tabela 9, elaborou-se uma rede neural *feedforward* com *backpropagation* para dispositivo para seleção de laranjas como entrada (sendo os as aberturas os valores fornecidos) como se pode ver na Figura 40.

Figura 40 - Rede Neural *feedforward* com *backpropagation* com dispositivo para seleção de laranjas como sendo entrada.



Fonte: Autor (2022)

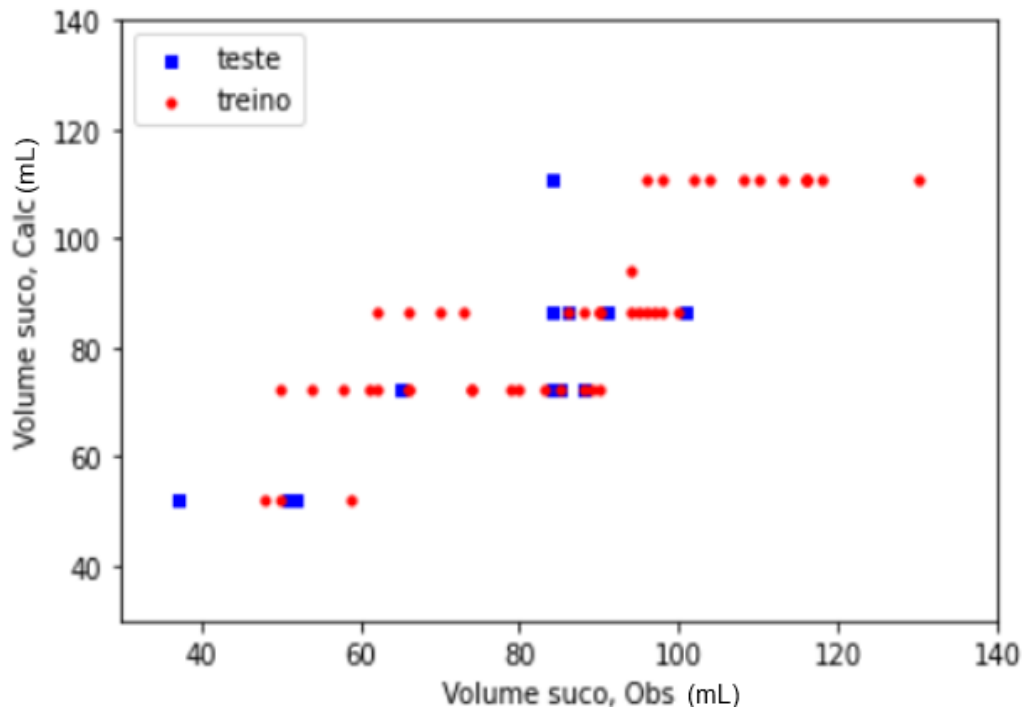
Analisou-se que nesta rede neural seria melhor utilizar 4 neurônios na primeira camada escondida e 3 neurônios na segunda camada escondida. O resultado da regressão para as 60 laranjas utilizando-se esta rede neural é apresentada na Tabela 10 e no Gráfico 6.

Tabela 10 - Resultados de MSE e R^2 referente ao treino e ao teste para Rede Neural *feedforward* com *backpropagation* com entrada: dispositivo para seleção de laranjas.

MSE do treino	R^2 do treino	MSE do teste	R^2 do teste
123,8072	0,70125	148,0903	0,5778

Fonte: Autor (2022)

Gráfico 6 - Volume de suco calculado versus volume de suco observado para Rede Neural *feedforward* com *backpropagation* com dispositivo para seleção de laranjas como sendo entrada.

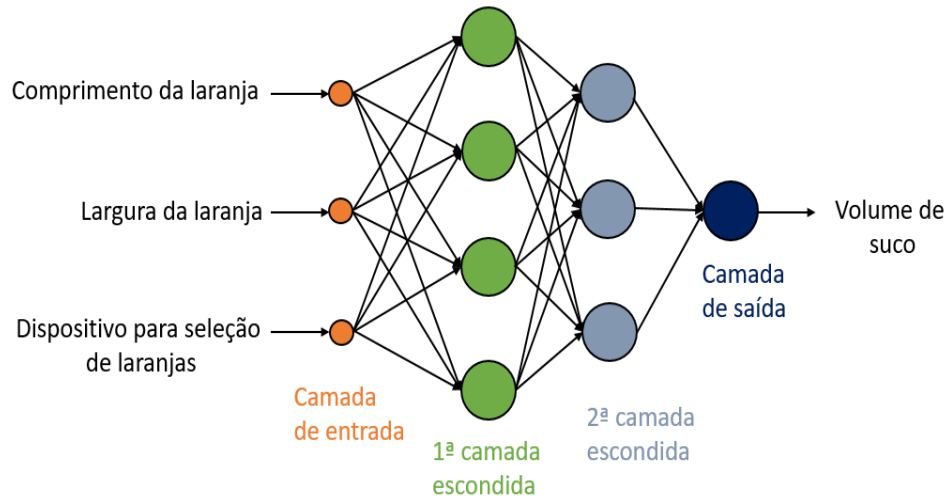


Fonte: Autor (2022)

Portanto, a partir da Tabela 10, observa-se que esta rede neural apresentou $R^2 = 0,5778$ para o teste, ou seja, representou R^2 se comparado com a rede neural *feedforward* com *backpropagation* com entradas: comprimento e largura da laranja.

Sendo assim, resolveu-se testar uma nova rede neural *feedforward* com *backpropagation*, sendo essa com entradas: dispositivo para seleção de laranjas, comprimento e largura da laranja como se pode ver na Figura 41.

Figura 41 - Rede Neural *feedforward* com *backpropagation* com entradas: comprimento da laranja, largura da laranja e dispositivo para seleção de laranjas



Fonte: Autor (2022)


Analisou-se que nesta rede neural seria melhor utilizar 4 neurônios na primeira camada escondida e 3 neurônios na segunda camada escondida. O resultado da regressão para as 60 laranjas utilizando-se esta rede neural é apresentada na Tabela 11 e no Gráfico 7.

Tabela 11 - Resultados de MSE e R^2 referente ao treino e ao teste para Rede Neural *feedforward* com *backpropagation* com entradas: comprimento da laranja, largura da laranja e dispositivo para seleção de laranjas.

MSE do treino	R^2 do treino	MSE do teste	R^2 do teste
53,8415	0,8709	79,9731	0,7720

Fonte: Autor (2022)

Gráfico 7 - Volume de suco calculado versus volume de suco observado para Rede Neural *feedforward* com *backpropagation* com entradas: comprimento da laranja, largura da laranja e dispositivo para seleção de laranjas.




Fonte: Autor (2022)

Portanto, a partir da Tabela 11, observa-se que esta rede neural apresentou $R^2 = 0,7720$ para o teste, ou seja, apresentou um R^2 de teste maior do que o da rede neural contendo comprimento e largura da laranja como sendo as entradas ($R^2 = 0,5841$) e também maior do que a rede neural contendo o dispositivo de seleção de laranjas como sendo a entrada ($R^2 = 0,5778$), ou seja, para estimar o volume de suco é necessário tanto o comprimento da laranja, largura da laranja bem como o dispositivo de seleção de laranjas

8.2 ANN *feedforward* com *backpropagation* para materiais poliméricos látex amarelo


No dispositivo de aquisição de imagens, capturaram-se fotos de 100 objetos poliméricos látex amarelo na posição horizontal e vertical, preenchidos com volumes de água diferentes (Gráfico 4), como se pode ver na Figura 42 e Figura 43

Figura 42 - Objetos poliméricos látex amarelo na posição horizontal



Fonte: Autor (2022)


Figura 43 - Objetos poliméricos látex amarelo na posição vertical



Fonte: Autor (2022)


De acordo com a Figura 35, após a obtenção das imagens dos objetos poliméricos, utilizando-se a linguagem de programação Python, utilizou-se o filtro Canny, que possibilitou obter as bordas das imagens dos objetos poliméricos como se pode ver na Figura 44 e Figura 45.

Figura 44- Bordas de imagens de materiais poliméricos na posição horizontal detectadas pelo filtro Canny



Fonte: Autor (2022)

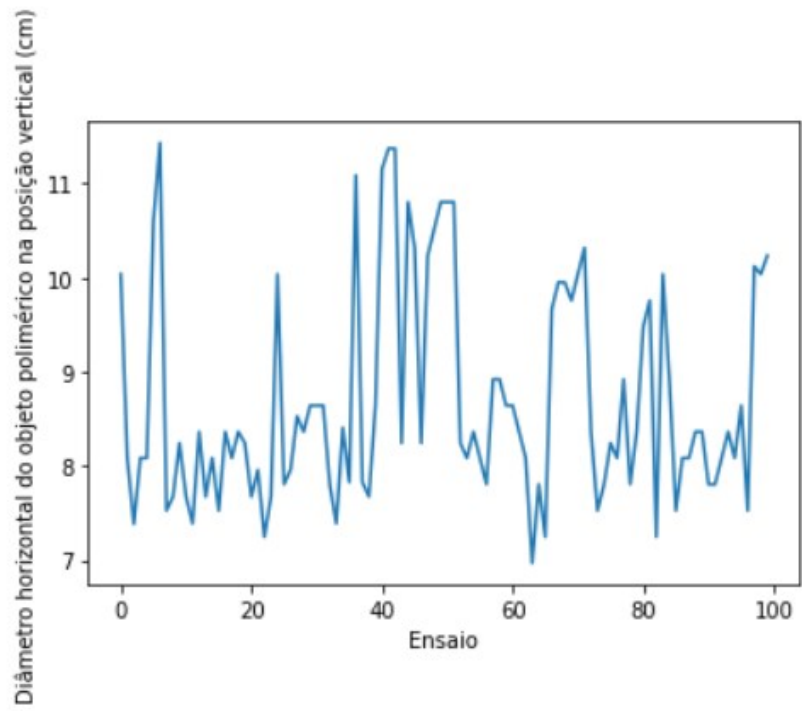
Figura 45- Bordas de imagens de materiais poliméricos na posição vertical detectadas pelo filtro Canny



Fonte: Autor (2022)


A partir das bordas detectadas pelo filtro Canny, foi possível obter os diâmetros horizontais e verticais tanto das imagens de objetos poliméricos látex amarelos na posição vertical quanto na posição horizontal como se pode ver no Gráfico 8, Gráfico 9, Gráfico 10 e Gráfico 11.

Gráfico 8 - Diâmetro horizontal do objeto polimérico na posição vertical




Fonte: Autor (2022)

Gráfico 9 - Diâmetro vertical do objeto polimérico na posição vertical




Fonte: Autor (2022)

Gráfico 10 - Diâmetro horizontal do objeto polimérico na posição horizontal



Fonte: Autor (2022)

Gráfico 11 - Diâmetro vertical do objeto polimérico na posição horizontal




Fonte: Autor (2022)

A partir dos Gráfico 8 referente ao diâmetro horizontal do objeto polimérico na posição vertical têm-se média 8,69 e desvio padrão 1,14, para o Gráfico 9 referente ao diâmetro vertical do objeto polimérico na posição vertical têm-se média 8,37 e desvio padrão 0,44, para o Gráfico 10 do diâmetro horizontal do objeto polimérico na posição horizontal têm-se média 8,45 e desvio padrão 0,93, para o Gráfico 11 do diâmetro vertical do objeto polimérico na posição horizontal têm-se média 8,26 e desvio padrão 0,52.


Além disto, a partir da extração das dimensões do eixo horizontal e vertical, foi possível encontrar as áreas tanto para os objetos na posição horizontal (média 0,10 e desvio padrão 0,03) quanto para a posição vertical (média 0,12 e desvio padrão 0,04) como se pode ver no Gráfico 12 e no Gráfico 13.

Gráfico 12 - Área do objeto polimérico na posição horizontal



Fonte: Autor (2022)


Gráfico 13 - Área do objeto polimérico na posição vertical



Fonte: Autor (2022)


Para avaliação do volume de água, elaborou-se uma rede neural *feedforward* com *backpropagation*, como mostrada na Figura 46, com função de ativação tangente hiperbólica e *purelin* para as camadas oculta e saída, com dados divididos em 90% treino e 10% teste. Além disto, para se determinar o número de neurônios na camada escondida, realizou-se uma busca no espaço amostral (*grid Search*) e variou-se entre 2 a 30 neurônios na camada escondida afim de se avaliar os respectivos coeficientes de correlação como se pode ver no Gráfico 14.

Figura 46- Rede Neural *feedforward* com *backpropagation* para os 100 materiais poliméricos látex de



Fonte: Autor (2022)

Gráfico 14 - Coeficiente de correlação vs números de neurônios




Fonte: Autor (2022)

Observa-se a partir do Gráfico 14 que 5 neurônios na camada escondida fornece coeficiente de correlação maior do que 0.9 tanto para o treino quanto para o teste, sendo assim, construiu-se a rede neural *feedforward* com *backpropagation* utilizando-se 5 neurônios na camada escondida. O resultado obtido para esta rede neural é mostrado no Gráfico 15 e na Tabela 12.

Gráfico 15 - Resultados obtidos para treino e teste para regressão realizada utilizando-se objetos

poliméricos



Fonte: Autor (2022)

Tabela 12 - Coeficiente de correlação e erro quadrático médio obtido para o treino e para o teste

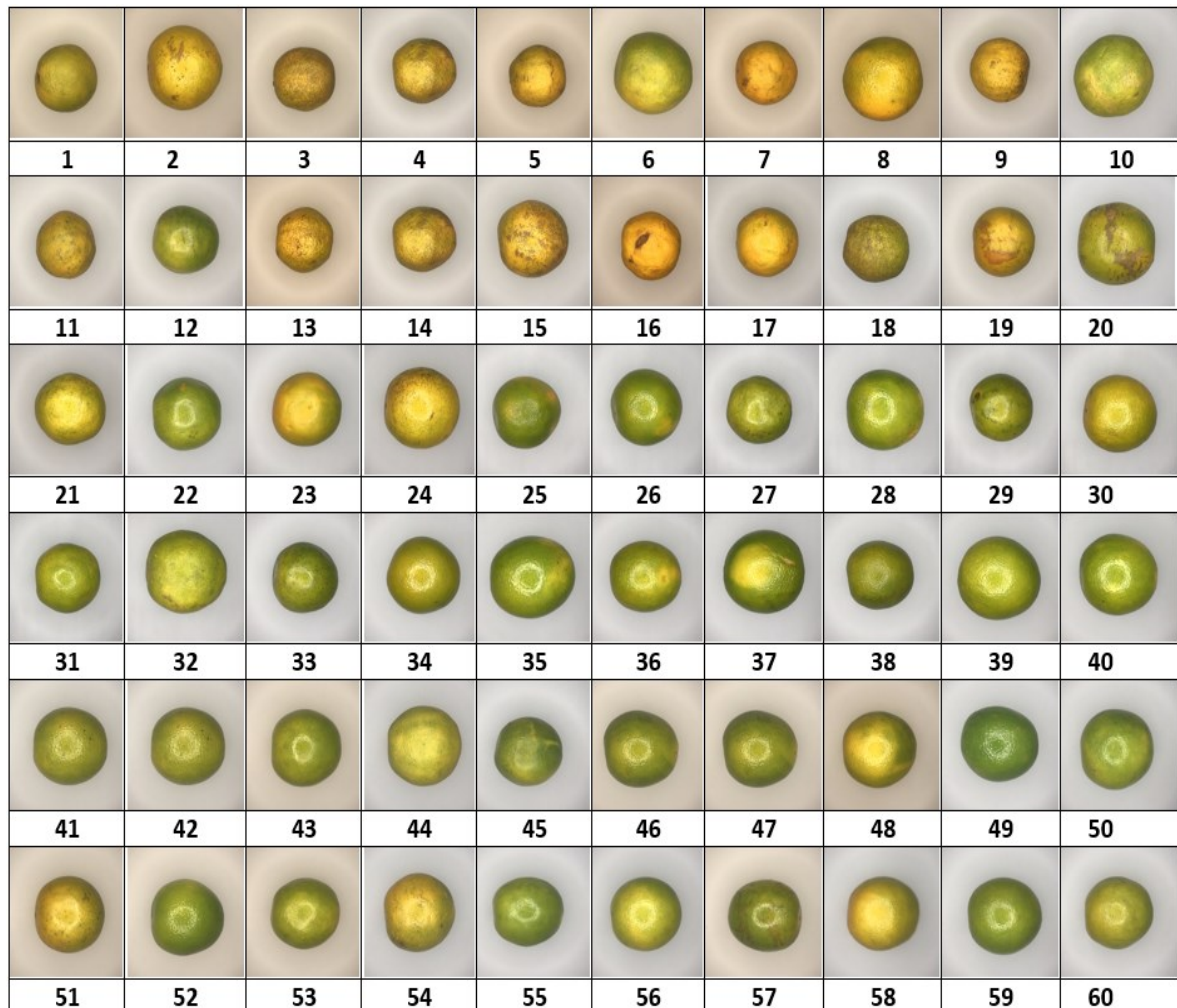
	Coeficiente de correlação (R^2)	Erro Quadrático médio (MSE)
Treino	0,99	8,42
Teste	0,91	35,58

Fonte: Autor (2022)

8.3 Classificação utilizando Redes neurais convolucionais

Para a rede neural convolucional, utilizou-se um dispositivo de aquisição de imagens como mostrada na no capítulo denominado Materiais e Métodos. Utilizou-se, portanto, este dispositivo para obter fotos de 60 laranjas como se pode ver na Figura 47.


Figura 47 - Fotografia das 60 laranjas obtidas a partir do dispositivo de aquisição de imagens



Fonte: Autor (2022)


No dispositivo de aquisição de imagens, capturaram-se além das fotos das 60 laranjas, fotos do suco de cada uma dessas laranjas. É importante destacar que, recortaram-se estas fotos, afim de se obter apenas a região referente à cor de cada suco, visto que, quando as laranjas foram espremidas, o seu suco apresentou espuma. O resultado das fotos dos sucos destas laranjas é mostrado na Figura 48.

Figura 48 - Fotografias, obtidas a partir do dispositivo de aquisição de imagens, dos sucos de cada uma das 60 laranjas




Fonte: Autor (2022)

Para a elaboração da rede neural convolucional, utilizaram-se os dados de Brix e os dados de pH, sendo estes dados mostrados na Tabela 6. Para elaborar uma rede neural convolucional para classificação, é necessário especificar as classes, sendo assim primeiro dividiram-se os valores de pH e de Brix em classes, para isso, optou-se por analisar estatisticamente quais os quartis dos dados referentes tanto ao Brix quanto ao pH destas laranjas, para que se pudesse classificar as laranjas segundo estes quartis, ou seja, laranjas cujos valores de pH e Brix foram menores do que os valores do primeiro quartil foram classificadas como sendo pertencentes ao grupo 0, laranjas cujos valores pH e brix se encontraram entre o primeiro quartil e a mediana, foram consideradas como sendo pertencentes ao grupo 1, e por fim, laranjas cujos valores de pH e brix foram maiores do que o valor da mediana, foram consideradas como sendo pertencentes ao grupo 2. Sendo assim, os dados de quartis utilizados para esses critérios de qual grupo cada laranja pertence são mostrados no Gráfico 16 e no Gráfico 17.

Gráfico 16 - *Boxplot* referente aos dados de Brix das 60 laranjas

Fonte: Autor (2022)

Gráfico 17 - *Boxplot* referente aos dados de pH das 60 laranjas

Fonte: Autor (2022)

Portanto, com os resultados estatísticos dos dados separaram-se os dados de Brix em 3 classes, sendo uma das classes para laranjas com Brix menores do que 9 (primeiro quartil, Q1, do Gráfico 16), outro com laranjas com Brix entre 9 e 9,4 (sendo o valor de 9,4 referente ao segundo quartil, mediana, no Gráfico 16) e por último, com laranjas com Brix maiores do que 9,4.


Além disto, separou-se os dados de pH em 3 classes, sendo uma das classes para laranjas com pH menores do que 3,93 (primeiro quartil, Q1 no Gráfico 17), outro com laranjas com pH entre 3,93 e 4,04 (sendo o valor 4,04 referente ao segundo quartil, mediana, no Gráfico 17) e por último, com laranjas com pH maiores do que 4,04.

Utilizando-se 3 camadas de convolução, 400 neurônios na primeira camada densa e 200 neurônios na segunda camada densa e de acordo com os procedimentos mostrados na Figura 36, obteve-se a acurácia para o pH dos sucos das laranjas como se pode ver no Gráfico 18, e a perda como se pode ver no

Gráfico 19.


Gráfico 18 - Acurácia da rede convolucional utilizada para classificação do pH a partir de imagens dos

sucos das laranjas




Fonte: Autor (2022)

Gráfico 19 - Perda da rede convolucional utilizada para classificação do pH a partir de imagens dos sucos das laranjas




Fonte: Autor (2022)

Gráfico 20 – Acurácia da rede convolucional utilizada para classificação do grau Brix a partir de imagens dos sucos das laranjas




Fonte: Autor (2022)

Gráfico 21- Perda da rede convolucional utilizada para classificação do grau Brix a partir de imagens dos sucos das laranjas




Fonte: Autor (2022)

Gráfico 22 - Acurácia da rede convolucional utilizada para classificação do pH a partir de imagens das cascas das laranjas




Fonte: Autor (2022)

Gráfico 23 - Perda da rede convolucional utilizada para classificação do pH a partir de imagens das cascas das laranjas




Fonte: Autor (2022)

Gráfico 24 - Acurácia da rede convolucional utilizada para classificação do grau Brix a partir de imagens das cascas das laranjas



Fonte: Autor (2022)

Gráfico 25 - Perda da rede convolucional utilizada para classificação do grau Brix a partir de imagens das cascas das laranjas



Fonte: Autor (2022)

Observa-se a partir do Gráfico 18, Gráfico 19, Gráfico 20, Gráfico 21, Gráfico 22, Gráfico 23, Gráfico 24 e Gráfico 25 que o resultado não se mostrou satisfatório utilizando-se redes convolucionais, visto que a validação não se aproximou dos resultados de acurácia e de perda.

8.4 Classificação utilizando medidas estatísticas como sendo variáveis de entrada das redes neurais *feedforward* com *backpropagation*

Para avaliar o pH, além das redes neurais convolucionais mencionadas anteriormente, foram feitas redes neurais *feedforward* com *backpropagation*, como mostrado na Figura 37, para medidas estatísticas (contraste, homogeneidade, ASM, energia, dissimilaridade e correlação) como entradas das redes neurais e as classes obtidas a partir dos quartis como sendo as saídas, em seguida foram avaliadas a quantidade de neurônios que a camada escondida deveria ter para cada uma das redes neurais bem como o resultado da acurácia do treino e do teste de cada rede neural como se pode ver na

Tabela 13. Além disso, o mesmo foi realizado para avaliar o grau Brix como se pode observar na Tabela 14.

Tabela 13 - Quantidade de neurônios na camada escondida, acurácia do treino e do teste para redes neurais *feedforward* com *backpropagation* utilizando medidas estatísticas como variáveis de entrada para avaliar o pH do suco das laranja

Medidas estatísticas utilizadas como entradas da rede neural <i>feedforward</i> com <i>backpropagation</i>	Quantidade de Neurônios	Acurácia treino	Acurácia teste
Contraste, homogeneidade e ASM	8.0	0.812500	0.666667
Contraste, homogeneidade e energia	4.0	0.770833	0.500000
Contraste, dissimilaridade e ASM	9.0	0.937500	0.500000
Contraste, homogeneidade, correlação e ASM	18.0	0.979167	0.583333
Contraste, homogeneidade, correlação e energia	11.0	0.937500	0.583333
Contraste, dissimilaridade, correlação e ASM	8.0	0.812500	0.583333
Homogeneidade, correlação e ASM	15.0	0.895833	0.583333
Homogeneidade, correlação e energia	11.0	0.791667	0.583333
Dissimilaridade, correlação e ASM	14.0	0.937500	0.583333
Homogeneidade e ASM	18.0	1.000.000	0.500000
Homogeneidade e energia	13.0	0.854167	0.583333
Dissimilaridade e ASM	19.0	0.854167	0.500000

Fonte: Autor (2022)

Tabela 14 - Quantidade de neurônios na camada escondida, acurácia do treino e do teste para redes neurais *feedforward* com *backpropagation* utilizando medidas estatísticas como variáveis de entrada para avaliar o grau Brix do suco das laranja

Medidas estatísticas utilizadas como entradas da rede neural <i>feedforward</i> com <i>backpropagation</i>	Quantidade de Neurônios	Acurácia treino	Acurácia teste
Contraste, homogeneidade e ASM	19.0	0.895833	0.750000
Contraste, homogeneidade e energia	17.0	0.916667	0.833333
Contraste, dissimilaridade e ASM	16.0	0.833333	0.750000
Contraste, homogeneidade, correlação e ASM	18.0	1.000.000	0.666667
Contraste, homogeneidade, correlação e energia	13.0	1.000.000	0.666667
Contraste, dissimilaridade, correlação e ASM	17.0	1.000.000	0.583333
Homogeneidade, correlação e ASM	11.0	0.916667	0.666667
Homogeneidade, correlação e energia	13.0	0.958333	0.666667
Dissimilaridade, correlação e ASM	23.0	1.000.000	0.666667
Homogeneidade e ASM	29.0	0.854167	0.750000
Homogeneidade e energia	24.0	0.916667	0.750000
Dissimilaridade e ASM	27.0	0.979167	0.583333

Fonte: Autor (2022)

De acordo com as informações apresentadas Tabela 13, observa-se que para o pH, o melhor resultado de rede neural *feedforward* corresponde à rede neural contendo entradas: contraste, homogeneidade e ASM, contendo 8 neurônios na camada oculta e apresentando $R^2 = 0,812500$ para o treino e $R^2 = 0,666667$ para o teste. Segundo a Tabela 14, nota-se que para o grau Brix, o melhor resultado de rede neural *feedforward* correspondente à rede neural contendo entradas: contraste, homogeneidade e energia, contendo, 17 neurônios na camada oculta, apresentando $R^2 = 0,915567$ para o treino e $R^2 = 0,833333$ para o teste.

9 CONCLUSÃO

O uso de visão computacional associado a medidas de dimensões de laranja mostrou-se capaz de avaliar a quantidade de suco extraído de laranja assim como as propriedades Brix e acidez do suco.

Relativo a determinação do volume de suco para laranjas reais e objetos poliméricos que simulam as dimensões de laranjas foi observado que o uso redes neurais é uma forma adequada para quantificar o volume de suco extraído.

Para o caso particular do volume de suco associado aos objetos poliméricos látex foi constatado que a partir das medidas do diâmetro vertical e horizontal dos objetos bem como das áreas destes objetos de projeção horizontal e vertical é possível gerar modelos que determinam o teor de suco com coeficiente de correlação de 99% para o treino e 91% para o teste.

Para o volume de suco associado a laranjas reais foi constatado que é possível estimar o volume de suco de laranja a partir das dimensões das laranjas (comprimento e largura) e do dispositivo de seleção de laranjas, visto que, a partir destas três variáveis como sendo entrada da rede neural *feedforward* com *backpropagation* obteve-se o melhor coeficiente de correlação para o treino ($R^2 = 0,8709$) e para o teste ($R^2 = 0,7720$).

Na determinação das propriedades brix e acidez o uso de processamento de imagem

utilizando matriz de convolução não se mostrou satisfatório ao passo que o uso de rede neurais do tipo *feedforward* com variáveis de entrada obtidas da análise de textura de matriz de co-ocorrência de escala cinza extraída da cor verde foram satisfatórias. Para o Brix, o melhor resultado de rede neural *feedforward* correspondente à rede neural contendo entradas: contraste, homogeneidade e energia, contendo, também, 17 neurônios na camada oculta, apresentando $R^2 = 0,915567$ para o treino e $R^2 = 0,833333$ para o teste, ou seja, mostrou a habilidade de classificar corretamente o grau Brix nas 3 faixas categóricas, sendo a primeira, com valores de grau Brix menores do que 9,0, a segunda com valores de grau Brix entre 9,0 e 9,4 e a terceira com valores de grau Brix maiores do que 9,4. Já para o pH, os melhor resultado de rede neural *feedforward* corresponde à rede neural contendo entradas: contraste, homogeneidade e ASM, contendo, também, 8 neurônios na camada oculta e apresentando $R^2 = 0,812500$ para o treino e $R^2 = 0,666667$ para o teste, ou seja, mostrou a habilidade de classificar corretamente o pH nas 3 faixas categóricas, sendo a primeira, com valores de pH menores do que 3,93, a segunda com valores de pH entre 3,93 e 4,04 e a terceira com valores de pH maiores do que 4,04.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADOBE CREATIVE TEAM. **Adobe Illustrator CS3**. Berkeley: Peachpit, 2007.
- ADONIAS, G. L.; REGIS, C. D. M. **Avaliação de manchas de pele usando processamento de imagens**. Revista principia, João Pessoa, ed. 27, p. 111-117, 10 jan. 2022. DOI: <https://doi.org/10.18265/1517-03062015v1n27p9-15>
- ALBAWI, S.; MOHAMMED, T.A e AL-ZAWI S.. **Understanding of a convolutional neural network**. 2017 International Conference on Engineering and Technology, ICET 2017, 2018, vol. 2018-Janua, pp. 1–6. DOI: [10.1109/ICEngTechnol.2017.8308186](https://doi.org/10.1109/ICEngTechnol.2017.8308186)
- ALIAGA, R.J. et al. **SoC-Based Implementation of the Backpropagation Algorithm for MLP**. Eighth International Conference on Hybrid Intelligent Systems, Barcelona, p. 744-749, 2008. Disponível em: <<http://dx.doi.org/10.1109/his.2008.56>>. Acesso em: 24 ago. 2021. DOI: <https://doi.org/10.1109/HIS.2008.56>
- Alsmadi, M. khalil, Omar, K. B., Noah, S. A., & Almarashdah, I. (2009). **Performance Comparison of Multi-layer Perceptron (Back Propagation, Delta Rule and Perceptron) algorithms in Neural Networks**. 2009 IEEE International Advance Computing Conference. DOI: <https://doi.org/10.1109/IADCC.2009.4809024>
- ANTONELLO, R. **Introdução a Visão Computacional com Python e OpenCV**. Santa Catarina; 2018.
- BALLARD D. H; BROWN C. M. **Computer Vision**. Englewood Cliffs, NJ: Prentice Hall, 1982.

BARCA, M. C. S.; SILVEIRA, T. R. D S.; MAGINI, M. **Treinamento de redes neurais artificiais: o algoritmo backpropagation**. IX Encontro Latino Americano de Iniciação Científica, V Encontro Latino Americano de Pós-Graduação–Universidade do Vale do Paraíba, Anais. Jacareí, 2005. Disponível em: http://www.inicepg.univap.br/cd/INIC_2005/inic/IC1%20anais/IC1-17.pdf Acesso em: 26 de julho 2021.

BARROS, J. R. M.; BARROS, A, L. M.; CYPRIANO, M.P. (2016). **O mercado da citricultura no Brasil e as suas novas perspectivas**. Disponível em: <<https://citrusbr.com/biblioteca/publicacoes-citrusbr/>>. Acesso em: 09 de ago. 2021.

BASTOS. D. C.; FERREIRA, E. A.; PASSOS, O. S.; SÁ, J. F. DE; ATAÍDE, E. M.; CALGARO, M. **Cultivares copa e porta-enxertos para a citricultura brasileira**. Informe Agropecuário, Belo Horizonte, v.35, n.281, p.36-45, jul./ago. 2014.

BORGES, R. S.; OLIVEIRA, R. P.; PIO, R. M.; FARIA, A. P. **Catálogo de cultivares de citros de mesa** Pelotas: Embrapa Clima Temperado, 2008. 40 p. (Documentos, 223).

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T.B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Editora Livros Técnicos e Científicos, 2000. 3p.

CALVO, H; MORENO-ARMENDÁRIZ, M.A; GODOY-CALDERÓN, S. et al. (2016). **A practical framework for automatic food products classification using computer vision and inductive characterization**. Neurocomputing, 175, 911–923.DOI: <https://doi.org/10.1016/j.gpb>.

2017.07.003

CAO, C.; LIU, F.; TAN, H.; SONG, D.; SHU, W.; LI, W.; ZHOU, Y.; BO, X.; XIE, Z. **Deep Learning and Its Applications in Biomedicine**. Genomics Proteomics Bioinformatics, [s.l.], v. 16, p. 17-32, 6 mar. 2018. DOI: <https://doi.org/10.1016/j.gpb.2017.07.003>

CHEN S. et al. (2019). **Colored rice quality inspection system using machine vision**. Journal of Cereal Science. DOI: <https://doi.org/10.1016/j.jcs.2019.05.010>

CITRUSBR. **A Cadeia do Suco de Laranja Brasileiro**. São Paulo. 2019. Disponível em: <https://citrusbr.com/biblioteca/publicacoes-citrusbr/>. Acesso em: 01 jun. 2021.

COREL. **Modelo de cores**, 2021. Disponível em: <http://product.corel.com/help/CorelDRAW/540111130/Main/BR/Documentation/wwhelp/wwhimpl/common/html/wwhelp.htm#href=CorelDRAW-Understanding-color-models.html&single=true>. Acesso em: 29 Nov. 2021.

COSENZA, Ramon; GUERRA, Leonor. **Neurociência e Educação**. Porto Alegre: Artmed, 2011.

CUBERO S. et al. (2011). **Advances in machine vision applications for automatic inspection and quality evaluation of fruits and vegetables**. Food and Bioprocess Technology, 4(4), 487-504. DOI: <https://doi.org/10.1007/s11947-010-0411-8>

COURTNEY, Jane. **Application of Digital Image Processing to Marker-free Analysis of Human Gait**. 2001. Thesis (Master of Engineering Science) - The National University of Ireland, Dublin, 2001. DOI: <https://doi.org/10.13140/2.1.1046.7847>

DA SILVA, I.N.; SPATTI, D.H; FLAUZINO, R.A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. 1º edição. São Paulo, SP: Artliber, 2010.

DATA SCIENCE ACADEMY. **Deep Learning Book**, 2021. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em: 29 Nov. 2021.

DIAS, S. M. **Democratizando a inteligência artificial**, 2021. Disponível em: <https://www.serpro.gov.br/menu/noticias/noticias-2019/democratizando-a-inteligencia-artificial>. Acesso: 07 Dez. 2021.

DO VALE, G. M.; DAL POZ, A. P. **O processo de detecção de bordas de Canny: Fundamentos, algoritmos e avaliação experimental**. Anais do Simpósio Brasileiro de Geomática, Presidente Prudente - SP, p. 292-303, 13 jul. 2002.

DU C.; SUN, D. **Recent developments in the applications of image processing techniques for food quality evaluation**. Trends in Food Science & Technology, Cambridge, v. 15, n. 5, p. 230-249, 2004. DOI: <https://doi.org/10.1016/j.tifs.2003.10.006>

EBERMAM, E.; KROHLING, R. A. **Uma introdução compreensiva às redes neurais convolucionais: Um estudo de caso para reconhecimento de caracteres alfabéticos**. Revista de Sistemas de Informação da FSMA, p. 49–59, 2018.

ELIZONDO, D. **The Linear Separability Problem: Some Testing Methods**. IEEE Transactions on Neural Networks, 17(2), 330–344. 2006.

DOI: <https://doi.org/10.1109/TNN.2005.860871>

FUNDECITRUS. **Inventário de árvores do cinturão citrícola de São Paulo e Triângulo/Sudoeste Mineiro: retrato dos pomares em março de 2017**. Araraquara, São Paulo: Fundecitrus, 2017. Disponível em: https://www.fundecitrus.com.br/pdf/pes_relatorios/2020_05_26_Invent%C3%A1rio_e_Estimativa_do_Cinturao_Citricola_2020-20212.pdf. Acesso: 09 jun. 2021.

FURTADO, M. I. V. **Redes Neurais Artificiais: Uma Abordagem para Sala de Aula**. Editora Atena, 2019.

FERREIRA, A.; FERREIRA, R. P.; DA SILVA, A. M.; FERREIRA, A.; SASSI, R. J. (2016). **Um estudo sobre previsão de demanda de encomendas utilizando uma rede neural artificial**. Blucher Marine Engineering Proceedings, 2(1), 353-364. DOI: <https://doi.org/10.5151/marine-spolm2015-140481>

FIORIN, D. V. *et al.* **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Revista Brasileira de Ensino de Física, v. 33, n. 1, p. 1309 1 – 1309 20, 2011. DOI: <https://doi.org/10.1590/S1806-11172011000100009>

GERRARD, D. E.; GAO, X.; TAN, J. (1996). **Beef marbling and colour score determination by image processing**. Journal of Food Science, 61(1), 145–148. DOI: <https://doi.org/10.1111/j.1365-2621.1996.tb14745.x>

GONZÁLEZ-ARJONA, D; LÓPEZ-PÉREZ, G; GUSTAVO GONZÁLEZ, A. **Non-linear QSAR modeling by using multilayer perceptron feedforward neural networks trained by back-propagation**. Talanta, [S. l.], p. 79-90, 2002. Disponível em: [http://dx.doi.org/10.1016/S0039-9140\(01\)00537-9](http://dx.doi.org/10.1016/S0039-9140(01)00537-9). Acesso em: 24 ago. 2021. DOI: [https://doi.org/10.1016/S0039-9140\(01\)00537-9](https://doi.org/10.1016/S0039-9140(01)00537-9)

GUYON, I. **Neural Networks and Applications Tutorial**, Physics Reports 3(5), 215-259 (1991). DOI: [https://doi.org/10.1016/0370-1573\(91\)90146-D](https://doi.org/10.1016/0370-1573(91)90146-D)

HAASE, V.F; LACERDA, S. S. **Neuroplasticidade, variação interindividual e recuperação funcional em neuropsicologia**. Temas Psicol SBP. Ribeirão Preto. ISSN 1413-389X. Vol. 12, n.1, 2004

HARALICL, R. M.; SHANMUGAM, K; DISTEIN, I. **Textural features for image classification**. IEEE Transactions on Systems, man and cybernetics, n. 6, p. 610-621, 1973. DOI: <https://doi.org/10.1109/TSMC.1973.4309314>

HAYKIN, S., **Redes Neurais: Princípios e Práticas**. Ed. Bookman, 2001

HUANG, J. **Visão geral da função cerebral**, 2020. Disponível em: <https://www.msdsmanuais.com/pt-br/profissional/dist%C3%BArbios-neurol%C3%B3gicos/fun%C3%A7%C3%A3o-e-disfun%C3%A7%C3%A3o-dos-lobos-cerebrais/vis%C3%A3o-geral-da-fun%C3%A7%C3%A3o-cerebral>. Acesso em: 29 Nov. 2021.

ITO, R. H; KIM, H. Y.; SALCEDO, W. J. **Classificação de texturas invariante a**

rotação usando matriz de co-ocorrência. 8th International Information and Telecommunication Technologies Symposium, 2009.

JANKE, J., CASTELLI, M., & POPOVIC, A. **Analysis of the proficiency of fully connected neural networks in the process of classifying digital images.** Expert Systems with Applications, 135, 12–38, 2019. DOI: <https://doi.org/10.1016/j.eswa.2019.05.058>

JAYAPRAKASHA, G. K.; PATIL, B. S. **In vitro evaluation of the antioxidant activities in fruit extracts from citron and blood orange.** Food Chemistry, v. 101, n. 1, p. 410-418, 2007. DOI: <https://doi.org/10.1016/j.foodchem.2005.12.038>

KIMBALL, D.A. **Citrus processing: quality control and technology.** New York: Van Nostrand, 1991.

KIMBALL D.A. **Citrus Processing: A Complete Guide**, 2nd edn. New York: Kluwer Academic/Plenum Publishers, 1999.

KOLB, B.; WHISHAW, I. Q. **Fundamentals of human neuropsychology.** 5 ed. New York: Worth Publishers, 2003.

KONDO, N.; AHMAD, U.; MONTA, M., MURASE, H. (2000). **Machine vision based quality evaluation of Iyokan orange fruit using neural networks.** Computers and Electronics in Agriculture, 29(1-2), 135–147. DOI: [https://doi.org/10.1016/S0168-1699\(00\)00141-1](https://doi.org/10.1016/S0168-1699(00)00141-1).

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações.** 2.ed. São Paulo: Colledium Cognitio, 1996. 15p.

LI, J.; TAN, J.; MARTZ, F. A. (1997). **Predicting beef tenderness from image texture features.** In 1997 ASAE Annual International Meeting, Paper No. 973124. St. Joseph, Michigan, USA: ASAE

LIMA, L. L. A.; MELO-FILHO, A.B. de. **Tecnologia de bebidas.** 1 ed. Recife: EDUFRPE, 2011.

LOESCH, C. **Redes neurais artificiais, fundamentos e modelos.** Blumenau: Editora da FURB, 1996, p. 166.

MARTINS, J. G; DA COSTA, Y. M. G; GONÇALVES, D. B; OLIVEIRA, L. E. S. **Uso de descritores de textura extraídos de glcm para o reconhecimento de padrões em diferentes domínios de aplicação.** In: XXXVII Conferencia Latinoamericana de Informática. 2011. p. 637-652. Acesso em: 05 de jan. 2021.

MATTOS JÚNIOR, D.; NEGRI, J. D. de; Pio, R. S; POMPEU JUNIOR, J. **Citros: principais informações e recomendações de cultivo.** Campinas: Instituto Agrônômico de Campinas, 2005. p.19-36, Boletim Técnico 200

MEDEIROS, L. F. de. **Inteligência artificial aplicada: uma abordagem introdutória**. Curitiba: InterSaber, 2018

MIGUEZ, G.A.; MACULAN, N.; XAVIER, A.E. **Desempenho do Algoritmo de Backpropagation com a Função de Ativação Bi-Hiperbólica**. XVI Latin-Ibero-American Conference on Operations Research and XLIV Brazilian ´ Symposium on Operations Research, Rio de Janeiro, Brazil, pp. 3539–3550, 2012.

MINUSSI, C. R.; LOTUFO, A. D. P. **Redes neurais: introdução e principais conceitos**. Ilha Solteira: [s. n.], 2008.

MONTEIRO, O. **Noções de pixel e cores digitais**, 2012. Disponível em: <https://oliviamonteiro.wordpress.com/2012/10/12/nocoos-de-pixel-e-cores-digitais/>. Acesso em: 29 Nov. 2021.

NEVES, M. F.; TROMBIN, V. G.; MILAN, P.; LOPES, F. F.; CRESSONI, F.; KALAKI, R. **O retrato da citricultura Brasileira**. Ribeirão Preto: FEA/USP, 2010. 12p. Disponível em: <<https://citrusbr.com/biblioteca/publicacoes-citrusbr/>>. Acesso em: 01 jun. 2021.

NORVIG, P.; RUSSELL, S. **Inteligência Artificial, un enfoque moderno**, 2a Edição. Madrid: Pearson/Prentice Hall, 2004.

OSÓRIO, F.; BITTENCOURT, J.R. **Sistemas Inteligentes baseados em RNAs aplicados ao Processamento de Imagens**. I Workshop de Int. Artificial, UNISC, 2000.

QUEIROZ, J. E. R.; GOMES, H. M. **Introdução ao Processamento Digital de Imagens**, Revista RITA, vol. VIII, 2001.

RAUBER, T. W. **Redes Neurais Artificiais**. Departamento de informática - Universidade Federal do Espírito Santo, 2005.

ROFFO, G. **Ranking to Learn and Learning to Rank: On the Role of Ranking in Pattern Recognition Applications**. 2017. Tese (Doutorado) - Università degli Studi di Verona, [S. l.], 2017.

ROJAS, Raul. **Neural Networks: A Systematic Introduction**. 1. ed. Berlim: Springer, 1996.

RONCERO, V. G. **Um estudo de segmentação de imagens baseado em um método de computação evolucionária**. 2005. Tese (Mestrado em Ciências em Engenharia Elétrica) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005. Disponível em: <http://www.pee.ufrj.br/index.php/pt/producao-academica/dissertacoes-de-mestrado/2005-1/2005062702-2005062702/file>. Acesso em: 27 set. 2021.

SALIBE, A. A.; SOBRINHO, J. T.; MULLER, G. W. **Fitotecnia - Artigo Técnico Sinopse de Conhecimentos e Pesquisas Sobre a Laranja ‘Pêra’**. LARANJA, Cordeirópolis, v.23, n.1, p.231-245, 2002.

SANCHEZ, E.C.M. **Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência**. Dissertação (Mestrado em Engenharia Mecânica) – Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, p 39. 2009.

SANTOS, C. A. M. **Análise de características para detecção de nudez em imagens**. 2012. Dissertação (Mestrado) - Curso de Ciência da Computação, Universidade Federal do Amazonas, Manaus, 2012.

SHI, H.; WARD, R. **Canny edge based image expansion**. IEEE International Symposium on Circuits and Systems, Vancouver, 2002.

SILVA, P. T.; FIALHO, E.; LOPES, M. L. M. e VALENTEMESQUITA, V. L. **Sucos de laranja industrializados e preparados sólidos para refrescos: estabilidade química e físico-química**. Ciência e Tecnologia de Alimentos, 25(3), 401-622. 2005.

SINGH, H. **Practical Machine Learning and Image Processing**. Allahabad, Uttar Pradesh, India: Apress, 2019.

SINGH, P. **Learn TensorFlow 2.0: Implement Machine Learning and Deep Learning Models with Python**. Bangalore, Karnataka, India: Apress, 2020. ISBN 978-1-4842-5558-2. E-book.

SOUZA, Y. N.; SIMAS FILHO E. F.; FARIAS C. T. T.; LEITE V. L. C.; SOUZA I. S.; LOPES J. L. S.; ARAUJO P. R. A. **Avaliação Não Destrutiva da Integridade Estrutural de Compósitos de Alumínio e Epoxi Utilizando Processamento Estatístico e Redes Neurais Artificiais como Ferramenta de Auxílio**. In: CONFERÊNCIA SOBRE TECNOLOGIA DE EQUIPAMENTOS. 11º COTEQ, Ipojuca/PE, 2011.

STANDFORD. **Tutorial 1: Image Filtering**, 2021. Disponível em: https://ai.stanford.edu/~syueung/cvweb/tutorial1.html?fbclid=IwAR3rB_W7HdOha55nOmtBHC6sVtpn5fEmZlopwMQqCM2XGzZ8Yxx6mhmWYI. Acesso em: 29 Nov. 2021;

TAO, Y et al. (1995). **Machine vision for colour inspection of potatoes and apples**. Transactions of the ASAE, 38(5), 1555–1561. DOI: <https://doi.org/10.13031/2013.27982>.

TAQUI, A. M; AWAD, A.; AL-AZZO, F, MILANOVA, M. **The impact of multi-optimizers and data augmentation on TensorFlow convolutional neural network performance**. In 2018 IEE Conference on Multimedia Information Processing and Retrieval (MIPR). IEEE, 2018. DOI: <https://doi.org/10.13031/2013.27982>

TARBELL, K. A.; REID, J. F. (1991). **A computer vision system for characterising corn growth and development**. Transactions of the ASAE, 34(5), 2245–2249. DOI: <https://doi.org/10.13031/2013.31864>.

TETRA PAK. **Orange book**, [S. l.], 2017. Disponível em: <https://orangebook.tetrapak.com/>. Acesso em: 9 ago. 2021.

UNITED STATES DEPARTMENT OF AGRICULTURE. **Citrus: World Markets and Trade: U.S. Production and Exports Forecast Down Despite Global Gains**. [S. l.], 2021. Disponível em: <https://downloads.usda.library.cornell.edu/usdaesmis/files/w66343603/b8516k98g/2514ph35q/citrus.pdf> Acesso em: 9 ago. 2021.

XU, Q.; PENG, J.; SHEN, J.; TANG, H.; PAN, G. **Deep CovDenseSNN: A hierarchical event-driven dynamic framework with spiking neurons in noisy environment**. *Neural Networks*, [S. l.], p. 512-519, 28 set. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0893608019302618>. Acesso em: 16 ago. 2021. DOI: <https://doi.org/10.1016/j.neunet.2019.08.034>.

WALIA, A. S. **Activation functions used in Neural Networks-Which is better?**,2020. Disponível em: <https://anishsinghwalia.medium.com/activation-functions-used-in-neural-networks-which-is-better-d4817d91199a>. Acesso em: 29 Nov. 2021.

WANG, H.; RAJ, B. **On the Origin of Deep Learning**. ArXiv e-prints, fev. 2017

YAMANAKA, Hélio Tadashi. **Sucos cítricos**. São Paulo:CETESB, 2005. 45p. (Série P+L).

YU, D., WANG, H., CHEN, P., & WEI, Z. **Mixed Pooling for Convolutional Neural Networks**. *Lecture Notes in Computer Science*, p. 364–375, 2014. DOI: https://doi.org/10.1007/978-3-319-11740-9_34.