



DEPARTAMENTO DE ENGENHARIA AGRÍCOLA

MARIA CAROLINA FERRAZ GOMES MARCIANO

**PROTOTIPAÇÃO DE UM SOFTWARE UTILIZANDO
REDE NEURAL CONVOLUCIONAL PARA CONTAGEM
DE MUDAS**

Lavras – MG

2019

MARIA CAROLINA FERRAZ GOMES MARCIANO

**PROTOTIPAÇÃO DE UM SOFTWARE UTILIZANDO
REDE NEURAL CONVOLUCIONAL PARA CONTAGEM
DE MUDAS**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal de Lavras como parte
das exigências do Curso de Engenharia
Agrícola, para a obtenção do título de
Bacharel.

Prof. Dr. Gabriel Araújo e Silva Ferraz

Orientador

Lavras – MG

2019

AGRADECIMENTOS

Todos nós temos um sonho e por mais que nessa jornada para realizarmos esse anseio encontremos obstáculos da vida, ser engenheiro é começar a construí-los. A realização profissional é a maior vitória pessoal e advém se trabalharmos com paixão e resiliência, mas o reconhecimento dos demais é o que acarreta esse acontecimento ser tão especial. Esse sonho está prestes a se concretizar e tenho muito por agradecer a todos presentes nessa trajetória, pois tudo que este precisava para ser realizado era de pessoas que acreditassem que o mesmo era possível ser auferido.

Primeiramente agradeço aos meus familiares e amigos, que sempre me apoiaram e foram meu forte para que esse ideal se tornasse verídico. O meu maior orgulho é ter vocês, que sonharam comigo e ajudaram a realiza-lo com empenho e dedicação, pois esse esforço foi fundamental para que este objetivo fosse alcançado.

Agradeço também pelo auxílio e pelas singelas contribuições neste presente trabalho ao Professor Orientador Gabriel Araújo e Silva Ferraz, Mestrando Lucas Santos Santana e o Graduando Gabriel Henrique Ribeiro dos Santos. Este não seria realizado sem a suas colaborações, transformando os problemas em grandes oportunidades de aprendizado e evolução.

RESUMO

Pretendeu-se, neste trabalho validar a importância dos avanços da tecnologia de inovação e a agricultura de precisão que jornadas conjuntamente, sendo estes os principais elementos que confeccionam a futura revolução comumente conhecida como Agricultura 4.0. Objetivando atuar no polo industrial onde a Universidade Federal de Lavras está inserindo, a pesquisa visou auxiliar ainda mais a cafeicultura a tomada de decisões mais assertivas e o suporte a estruturação de medidas preditivas. Dessa forma a procura de novas tecnologias e a implementação de modelos matemáticos para solução de problemas, permite que a correlação de softwares como QGIS e a Rede Neural Convolutiva de Arquitetura YOLO atreladas a tecnologias aéreas como Aeronave Remotamente Pilotada (RPA), responsáveis pelo fornecimento de imagens que serviram como material de entrada a serem processadas e comparadas aos padrões estabelecidos, fossem usados para obtenção de resultados favoráveis que ainda necessitam de incentivo e aprimoramento antes de ser usados em larga escala na indústria do agronegócio.

Palavras-Chave: Agricultura de Precisão, Rede Neural Convolutiva, Contagem de Plantas, Cafeicultura.

ABSTRACT

The aim of this study was to validate the importance of advances in innovation technology and precision farming, which are the main factors that make up the future revolution commonly known as Agriculture 4.0. Aiming to act in the industrial pole where the Federal University of Lavras is inserting, the research was aimed at helping even more the coffee industry to make more assertive decisions and support the structuring of predictive measures. In this way, the search for new technologies and the implementation of mathematical models for problem solving, allows the correlation of software like QGIS and the Convolutional Neural Network of Architecture YOLO linked to aerial technologies like Remotely Piloted Aircraft (RPA), responsible for the supply of images that served as input material to be processed and compared to established standards were used to obtain favorable results that still need encouragement and refinement before being used on a large scale in the agribusiness industry.

Keywords: Precision Agriculture, Convolutional Neural Network, Plant Count, Coffee Cultivation.

LISTA DE FIGURAS

Figura 1 — Métodos de modelagem matemática	10
Figura 2 — Rede neural convolucional por segmentação de imagens.....	12
Figura 3 — Esquematização Estrutural da Rede YOLO	12
Figura 4 — Drone Phaton 4 Advance.	13
Figura 5 — Processo de aprendizagem da rede neural convolucional	14
Figura 6 — Imagem ortomosaico das cenas capturadas por meio de drone	17
Figura 7 — Recorte da imagem e marcação das predições	18
Figura 8 — Reconhecimento das mudas em toda a área e marcação da predição	19
Figura 9 — Aprendizagem com a utilização de imagens de outra área de plantio de café e a marcação da predição	20

SUMÁRIO

1	INTRODUÇÃO.....	8
2	OBJETIVO.....	9
2.1	OBJETIVO GERAL.....	9
2.2	OBJETIVO ESPECIFICO.....	9
3	HIPÓTESE.....	9
4	REFERENCIAL TEÓRICO.....	9
4.1	QGIS.....	9
4.2	Qt DESIGNER.....	10
4.3	AERONAVE REMOTAMENTE PILOTADA (RPA).....	11
4.4	REDE NEURAL CONVOLUCIONAL.....	11
4.4.1	REDE YOLO (YOU ONLY LOOK ONCE).....	12
5	MATERIAIS E MÉTODOS.....	13
5.1	MATERIAIS.....	13
5.2	MÉTODOS.....	13
6	RESULTADOS E DISCUSSÕES.....	16
7	CONCLUSÃO.....	21
8	REFERÊNCIAS BIBLIOGRAFICAS.....	22

1 INTRODUÇÃO

A agricultura no Brasil atualmente vem obtendo crescimentos exponenciais de produção, um dos fatores responsáveis por esse crescimento é o desenvolvimento de novas tecnologias que colaboram com o fortalecimento de mercado da Agricultura de Precisão através do monitoramento e processamento de imagens. Esses recursos fazem com que ocorram a diminuição do tempo de resposta entre a coleta de informações e a tomada de decisão evitando assim os riscos presentes no cultivo possibilitando a ação de medidas preditivas.

A cafeicultura teve-se sua estimativa de área cultivada total para essa safra praticamente igual ao ano passado e vem apresentado redução em virtude do ganho de produtividade alcançada atualmente, tendo em vista a aplicação de novas tecnologias no mesmo (CONAB,2019). Um dos fatores para essa análise é o mapeamento do parque cafeeiro, realizado por meio de imagens de satélite e com auxílio também de Aeronaves Remotamente Pilotadas (RPA), popularmente conhecido como Veículos Aéreos Não Tripulados (VANT's) ou como DRONES, contribuindo com a estimativa de área cultivada e de produtividade.

A estimativa de área e de produtividade da safra resulta no mapeamento e reconhecimento da extensão do cultivo propiciando uma interpretação do panorama visual com grande cunho socioeconômico da atividade. Este oportunizou a quantificação, a averiguação em campo, a delimitando parâmetros indicativos de rendimento especializados e previsão das lavouras fundamentais para planejamento agrícola cafeeiro (MOREIRA et al., 2017).

Objetivando correlacionar a tecnologia e o cultivo cafeeiro, estritamente na dificuldade de investigação e identificação das linhas efetivas de plantio para o alcance de informes para detecção de falhas de plantio, reposição de mudas, contagem de mudas e alinhamento. Com este trabalho objetivou-se a utilização de Redes Neurais Convolutacional para a detecção direta de mudas de café por meio de dados obtidos por Aeronave Remotamente Pilotada (RPA) em áreas de monitoramento da agricultura acarretando assim da diminuição da porcentagem de compra de mudas no replante para o recobrimento de falhas.

2 OBJETIVO

2.1 OBJETIVO GERAL

Objetivou-se com este presente trabalho avaliar as áreas de trasplatio com as imagens áreas obtidas por Aeronave Remotamente Pilotada (RPA) de monitoramento a fim de determinar a quantidade estimada de população de plantas no presente local utilizando Rede Neural Convolutacional.

2.2 OBJETIVO ESPECIFICO

- Avaliar o melhor resultado de processamento de imagens para a utilização da rede neural.
- Estabelecer um padrão seletor de maior percepção das mudas de café plantadas.
- Comparar os valores obtidos pela rede neural com as estabelecidas manualmente.

3 HIPÓTESE

Estabelecer imagens de diversas áreas apenas com mudas de café plantadas até 6 meses e a elaboração de um processo no qual identifique melhor a contagem de mudas a fim de atingir a melhor acurácia possível.

4 REFERENCIAL TEÓRICO

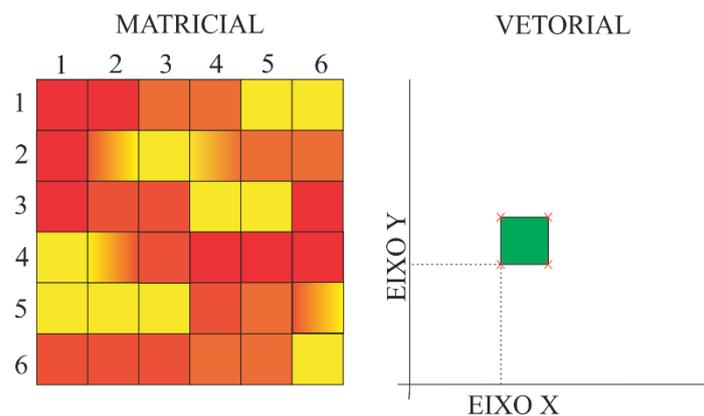
4.1 QGIS

O QGIS é um software gratuito de codificação aberta que se baseia em um Sistema de Informação Geográfica (SIG), amplamente compatível com diversos sistemas operacionais e suporta inúmeros formatos desde vetores, rasters e base de dados. O software também disponibiliza várias funcionalidades e ainda possibilita a criação de complementos, plugins podendo visualizar, ferir, editar, analisar dados e confeccionar mapas. A criação de plugins atende as necessidades de adequações do sistema sendo capaz de utilizar as linguagens de programação C++ ou Python, que fornicam no repositório presente no programa de fácil instalação. (Project, Q. 2019)

A finalidade principal do software é o geoprocessamento de imagens, onde o objeto recebe uma determinada nomeação de dados geográficos de forma a facilitar o armazenamento e a manipulação. O processo de manipulação de dados baseia-se em modelagem matemática na qual as coordenadas de entrada são a representações geométricas e numéricas.

Encontram-se dois métodos de arranjos sendo estes o vetorial e a matricial. O método vetorial requer tempo maior de processamento uma vez que reside em uma comparação da realidade por meio de linhas, pontos e área geométricas e precisas, obtendo-se eficácia na retenção dos dados preservando assim a qualidade cartográfica e a facilidade de manipulação de operações para análise integrada. Entretanto o método matricial organiza sistematicamente por meio de células uniformes os dados.

Figura 1 — Métodos de modelagem matemática.



Fonte: Do autor (2019).

4.2 Qt DESIGNER

O Qt Designer é um software na qual auxilia na projeção e na construção de interfaces gráfica de usuários, sendo capaz de realizar personalizações de diálogos, estilos e resoluções na janela interagindo acertadamente com o código programado. O mesmo é uma alternativa mais rápida para criação de plugins por permitir a customização de sua aparência. (Creator, Q.2019)

4.3 AERONAVE REMOTAMENTE PILOTADA (RPA)

A denominação “drone” segundo a normativa da nova regulamentação de regras sobre drones da Agência Nacional de Aviação Civil (ANAC) retrata qualquer aeronave automática devendo ser classificadas conforme ao tipo de uso, sendo estes o Aeromodelo com finalidade recreativa e a Remotamente Pilotadas (RPA) que tem por intuito atividades comerciais, corporativa e experimental. Esse equipamento por possuir uma versatilidade na atuação e um recurso tecnológico adjunto, tornou-se essencial para a captação de imagens georreferenciadas utilizadas na agricultura de precisão, adquirindo figuras de alta qualidade e de vista superior das áreas de monitoramento visto que foi projetado e construído especialmente para inspeções em áreas de difícil acesso e presteza na obtenção de informes (Inamasu e Jorge, 2014).

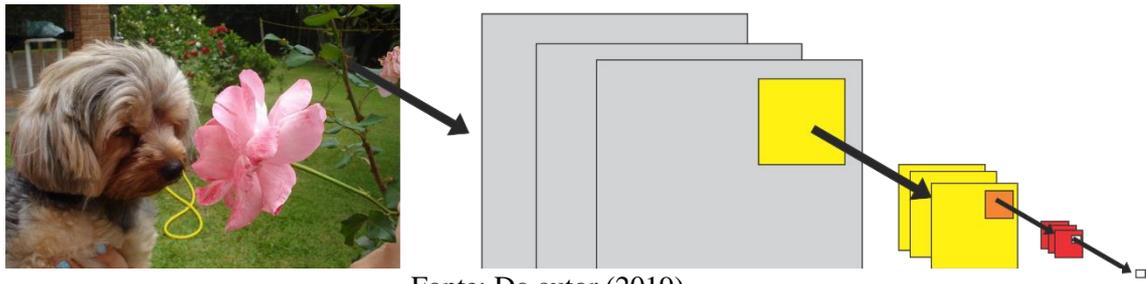
4.4 REDE NEURAL CONVOLUCIONAL

A convolução é um modelo matemático que deu origem as Redes Neural Convolucionais (CNNs) por executar qualificadamente o mesmo em processamento de dados organizados por topologia especificamente em imagens. As camadas convolução permitem a recepção de um dado de entrada que possuem camadas com neurônios interligados capazes de gerar pesos consecutivos nas camadas subsequentes classificando a imagem.

Esses neurônios estão posicionados com relação tridimensional (altura, largura e profundidade), postos estrategicamente em regiões da imagem que proporcionem o fácil estabelecimento de padrões e detectados em diferentes locais promovendo assim o enriquecimento do banco de dados da rede atualmente usadas para detecção e localização de objetos, classificação e segmentação de imagens.

A segmentação de imagens é intitulada como segmentação semântica capazes de categorizar e relacionar individualmente os pixels presentes de acordo com conceito do objeto representativo, este é composto por etapas de decodificação e catalogação norteados por mapeamento regressivo do pixel por meio da amostragem (upsampling) (Busson et al. (2018); Bah et al. (2019); Silva (2018);Sainton (2013)).

Figura 2 — Rede neural convolucional por segmentação de imagens.



Fonte: Do autor (2019).

4.4.1 REDE YOLO (YOU ONLY LOOK ONCE)

A Rede YOLO (You Only Look Once), uma das vertentes formadas pela Rede Convolutacional, constata em tempo real itens recordados na imagem de entrada indicando a sua localização por meio de caixas delimitadoras mais conhecido pelo termo em inglês bowding boxes. Sua estruturação baseou-se na rede GoogleLeNet, tendo como funções sagazes a remoção de indicadores da imagem, predição de caixas delimitadoras e a padronização e seriação de conjuntos mais prováveis. Dessa forma a divisão por grades (grids) de tamanhos pré-definidos permite que esse âmbito obtenha apenas duas caixas delimitadoras por grade, correlacionando o grau de confiança que corresponde o quão certo a rede afirma conter o objeto existente aproximando seu valor a zero e a probabilidade de ocorrência seguida de uma junção dos mesmos evitando a recorrência da identificação de um mesmo item, em outros termos possui um vetor de probabilidade de ocorrência e a altura e largura representativa por coordenadas espaciais no objeto (Busson et al. (2018);Silva (2018)).

Figura 3 — Esquemmatização estrutural da rede YOLO.



Fonte: Do autor (2019).

5 MATERIAIS E MÉTODOS

5.1 MATERIAIS

O estudo vigente teve como parâmetro de escolha imagens logradas por meio de um Drone Remotamente Pilotado (RPA), com especificações técnicas de: modelo Phaton 4 Advance (Figura 4), peso 1338g, tamanho 350 mm, velocidade máxima alcance 72km/h, ângulo de inclinação máxima 42°, tempo máximo de voo de 30 minutos. O aparelho apresentado detém de uma câmera de bordo igualmente equipada de um sensor CMOS de 1 polegada permitindo a captação de vídeos de até 4096x 16 p a 60 fps e fotografias de até 20 megapixels utilizando do Sistema de Posicionamento Geográficos GPS/GLONASS.

Figura 4 — Drone Phaton 4 Advance.



Fonte: Site DJI (2019).

5.2 MÉTODOS

As imagens capturadas, obtidas mediante a colaboração do Mestrando Lucas Santos Santana da Universidade Federal de Lavras, visavam abranger áreas que englobavam mudas de café de até 6 meses de idade com suas ruas limpas preconizando a diminuição da interferência entre plantas e plantas daninhas presentes nos locais, facilitando assim a delimitação e a determinação do parâmetro de entrada.

Inicialmente estabeleceu-se um código de programação em Python e com o auxílio do QtDesigner criou-se uma plataforma interativa de um espécime de plugin que

tinha como finalidade a inserção bem como seu o funcionamento no software de geoprocessamento de imagens QGIS. O mesmo dispõe ferramentas complementares para instalação de plugins experimentais, outro fator de predileção do utilitário é o seu o fácil manuseio e acesso, sendo a ferramenta mais usual na atualidade e por possuir um código aberto. No entanto mesmo consistindo de código aberto e funcionando através de modelos matemáticos, a linguagem do plugin não compatibilizava com o software apresentando erros de performance.

Tal falha foi percebida após os testes realizados no qual o processamento de imagens não apresentava deliberações favoráveis. Quando executado a mudança da programação para a inserção manual das coordenadas geografias e a criação de um ponto de marcação, a execução ocorria normalmente, porém igualava-se com a contagem manual que já vinha sendo realizada. Dessa forma como o propósito era a identificação e contagem automática de muda de planta, depois de perder-se um tempo substancial e não encontrar um método de compatibilidade com o QGIS, viu-se a necessidade descartar esse método utilizando-se assim a Rede Neural Convolutiva da seguinte forma arquitetônica de YOLO (You Only Look Once).

Preliminarmente foi necessário do conhecimento técnico na área de processamento de imagens do colaborador Graduando Gabriel Henrique Ribeiro dos Santos da Universidade Federal de Lavras responsável por toda a formação da rede para o andamento deste trabalho.

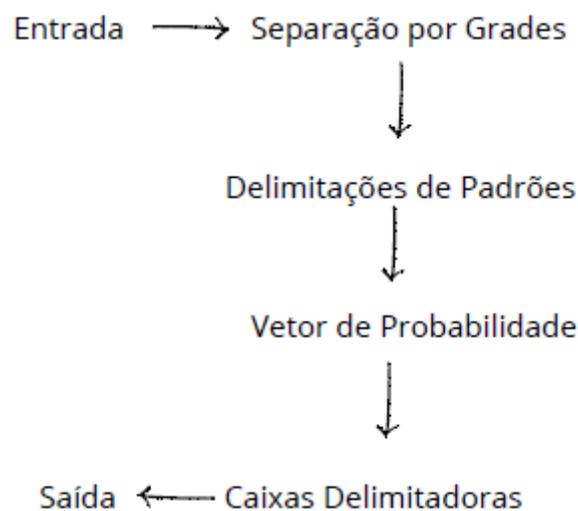
A princípio para fomentação da rede necessitou-se da elaboração de um banco de dados onde o sistema de alimentação requer uma série de imagens para que seja implementado o processo de treinamento da rede, essa aprendizagem permite que a rede aprenda o padrão de identificação da muda de café reconhecendo-a na imagem como um todo.

As imagens de entrada possuíam devido a qualidade e precisão dos dados um tamanho grande para ser inserido diretamente a rede, por ser um ortomosaico gerado no processamento de imagem no software QGIS. Dessa forma viu-se a necessidade de recortar as imagens em várias parcelas menores priorizando e preservando a igualdade de tamanhos garantindo a veracidade dos dados.

Em seguida pode-se gerar a classificação de cada recorte, ou seja, para cada pedaço gerado no recorte existe uma respectiva especificação que contém as

coordenadas em pixel na qual as mudas estão localizadas na imagem. Brevemente podemos assumir que o banco de dados é constituído de imagens com suas respectivas especificações, sendo de suma importância pois estes foram usados como resultado alvo na saída da rede no decorrer do processo de aprendizagem devidamente representado na Figura 5.

Figura 5 — Processo de aprendizagem da rede neural convolucional.



Fonte: Do autor (2019).

Com intuito de constituição dos rótulos foi usado novamente a linguagem Python, com subvenção da biblioteca Tkinter (respectiva para criação de interfaces gráficas), a prototipação de um algoritmo que permitiu o acesso as pastas que continham os recortes e possibilitavam abri-las uma a uma. Após aberta a imagem o programador encarregado pelo processo de aprimoramento impreterivelmente marca na imagem o posicionamento das mudas, criando-se retângulos em torno de cada uma salvando-os automaticamente em arquivos de formato .txt a uma pasta designada apenas para esse fim concluindo o banco de dados da rede.

O treinamento da rede foi efetuado através de linhas de comando no terminal, durante cada relação de treinamento foram tirados retratos da tela a fim de demonstrar a perda média gerada pelo mesmo procurando atingir a melhor faixa de valor aceitável de acurácia. Acarretando assim, quanto maior for a quantidade de treinamento da rede

melhor será o valor de faixa encontrado, podendo chegar a mais de 1000 interações e facilmente passar de 5 horas de duração conforme o hardware utilizado.

Por fim de todas as etapas de elaboração foi possível passar a testar a rede com imagens de outras áreas de mesmo padrão determinado inicialmente, este processo também utiliza a linha de comando terminal e estabelece a saída da rede ser a predição, que não deixa de ser a imagem de entrada conjuntamente com as caixas de detecção contornando as mudas de café.

6 RESULTADOS E DISCUSSÕES

O primeiro método apresentado neste trabalho não obteve resultados favoráveis acarretando assim a não geração das imagens finais. Ou seja, a saída almejada abstinha-se de demarcações do posicionamento e identificação das mudas de café, mediante a ausência de produção de caixas delimitadoras para sua contagem posterior, em consequência não atendeu a nenhuma das expectativas propostas inicialmente.

Dessa forma como a previsão é a identificação e a contagem automatizada de plantas, foi necessário partir para a elaboração e execução do segundo método resultando nas imagens a abaixo.

Onde percebe-se na Figura 6 a imagem ortomosaico capturada por meio de Drone empregue na entrada da Rede Neural Convolutiva responsável pela geração inicial do banco de dados, logo em seguida a Figura 7 reflete no recorte executado adjunto da criação de retângulos para demarcação do posicionamento e identificação da muda de café.

Já a Figura 8 constitui o reconhecimento total na área de referência caracterizando assim a rotulação da saída desejada e por fim a Figura 9 configura a utilização de uma nova imagem de entrada com intuito de iniciar a aprendizagem da Rede Neural Convolutiva.

Figura 6 — Imagem ortomosaico das cenas capturada por meio de drone.



Fonte: Lucas S. Santana (2019).

Figura 7 — Recorte da imagem e marcação das predições.



Fonte: Gabriel Henrique R. dos Santos (2019).

Figura 8 — Reconhecimento das mudas em toda a área e marcação da predição.



Fonte: Gabriel Henrique R. dos Santos (2019).

Figura 9 — Aprendizagem com a utilização de imagens de outra área de plantio de café e a marcação da predição.



Fonte: Gabriel Henrique R. dos Santos (2019).

O segundo método demonstrou mais satisfatoriamente, em comparação com a primeira metodologia, deliberações pois houveram a concepção das imagens de saída que apresentaram coerência com os elementos visuais de reconhecimento da muda de café nos materiais adquiridos na captura por meio da Aeronave Remotamente Pilotada (RPA).

O funcionamento da Rede Neural Convolutiva previamente concluiu apenas um dos prognósticos, em razão do mesmo ainda requerer de quantidades maiores de imagens granjeadas a fim de empreender a aprendizagem da rede e o aperfeiçoamento da saída almejada. Dessa forma a determinação da faixa de valor aceitável de acurácia e a comparação dos valores, manuais e automáticas, da contagem populacional de mudas de café das áreas, até o presente momento não tinham sido obtidos posto que este não apresentava qualificações para isso. Visto que, o refinamento visual das imagens de saída na identificação dos parâmetros e eliminação das possíveis falhas de reconhecimento já teriam que ter sido completado para a determinação dos mesmos.

7 CONCLUSÃO

O presente trabalho previamente não possuiu resultados favoráveis quanto a adoção ao primeiro método o que levou posteriormente a mudança de metodologia. No entanto com a modificação para o segundo método os resultados obtidos nas imagens de saída apresentaram coerência com os materiais adquiridos manualmente. Contudo a determinação da faixa de valor aceitável de acurácia, até o atual momento de confecção do mesmo, ainda não tinha sido obtida devido ao andamento de aprendizagem da Rede Neural com o maior quantidades de imagens possíveis adquiridas e a que estavam em processo de serem granjeadas.

8 REFERÊNCIAS BIBLIOGRÁFICAS

Bah, M.D., Hafiane, A, Canals, R., Dericquebourg E. **Deep Learning Based Classification System for Identifying Weeds Using High-Resolution UAV Imagery**. 2019. Springer Nature Switzerland AG 2019,176–187.p, 2019.

Silva, L. P. da. **Leannet: uma arquitetura que utiliza o contexto da cena para melhorar o reconhecimento de objetos**. 2018. 81p. Dissertação (Mestre em Ciência da Computação) – Universidade Católica do Rio Grande do Sul, Porto Alegre, 2018.

Busson, A.J.G., Figueiredo,L. C., Santos, G. P. dos, Damasceno, A. L. de B.,Colcher, S., Milidui,R. L. **Desenvolvendo Modelos de Deep Learning para Aplicações Multimídia no Tensorflow**. Anais do XXIV Simpósio Brasileiro de Sistemas Multimídia e Web: Minicursos, 50p, 2018.

Hirakuri, M. H. **Aplicação da Rede Neural Neocognitron para Reconhecimento de Atributos Faciais**. 2003. 99p. Dissertação (Mestre em Ciência da Computação)- Universidade Federal de São Carlos, Agosto, 2018.

Ferreira, A. dos. **Rede Neural Convolucionais Profundas na Detecção de Plantas Daninhas em Lavouras de Soja**. 2017. 80p. Dissertação (Mestre em Ciência da Computação)- Universidade Federal de Mato Grosso do Sul, Março, 2017.

Oliveira, H. C.,GuiziliniI, V. C., Nunes, I. P., Souza, J.R. **Failure Detection in Row Crops From UAV Images Using Morphological Operators**.2018. *EEE Geoscience and Remote Sensing Letters*, 5p, Outubro, 2018.

Bernardi, A. C. de C., Naime, J. de M., Resende, A. V. de, Bassoi, L. H., Inamasu, R. Y. **Agricultura de precisão resultados de um novo olhar**. Embrapa, Brasília DF,2014.

Inamasu, R. Y., Jorge, L. A. de C. **Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão**. Embrapa Instrumentação, São Carlos, 2014.

Project, Q. **QGIS User Guide Release 3.4**. QGIS, 2019.

Creator, Q. **Qt Creator Manual**. Qt Design, 2019.

ANAC. **Regras Sobre Drones ANAC**. Brasília, 2017.

CONAB. **Acomp. safra brasileira de café, v. 6– Safra 2019, n. 1 - Primeiro levantamento.** Brasília, p. 1-62, Maio, 2019.

Moreira, M. A., Barros, M. A., Faria, V.G.C. de, Adami, M. **Tecnologia de Informação: imagem de satélite para o mapeamento de áreas de café de Minas Gerais.** 2007. Informe Agropecuário Belo Horizonte, 27-37 .p, Dezembro, 2007.