UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL

APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS PARA MEDIÇÃO DE PATINAGEM EM TRATORES AGRÍCOLAS

Rafael Rodrigues Feih
Engenheiro Eletricista

2021

UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL

APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS PARA MEDIÇÃO DE PATINAGEM EM TRATORES AGRÍCOLAS

Rafael Rodrigues Feih
Prof. Dr. Rouverson Pereira da Silva

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias - Unesp, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de Mestre em Agronomia (Produção Vegetal)

2021

F297a

Feih, Rafael Rodrigues
Aplicação de redes neurais convolucionais para medição de patinagem em tratores agrícolas. / Rafael Rodrigues Feih. – – Jaboticabal, 2021
59 p. : tabs., fotos

Dissertação (mestrado) – Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, 2021
Orientador: Prof. Dr. Rouverson Pereira da Silva

1. Agronomia. 2. IA (Inteligência artificial). 3. Agricultura de precisão. 4. Redes neurais (Computação). I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS PARA MEDIÇÃO DE PATINAGEM EM TRATORES AGRÍCOLAS

AUTOR: RAFAEL RODRIGUES FEIH

ORIENTADOR: ROUVERSON PEREIRA DA SILVA

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONOMIA (PRODUÇÃO VEGETAL), pela Comissão Examinadora:

Prof. Dr. ROUVERSON PEREIRA DA SILVA (Participaçao Virtual)
Departamento de Engenharia e Ciências Exatas (DECEx) / FCAV / UNESP - Jaboticabal

Prof. Dr. TIAGO RODRIGO FRANCETTO (Participaçao Virtual)
Departamento de Engenharia Agrícola / Universidade Federal de Santa Maria - Campus de Cachoeira do Sul/RS

Prof. Dr. MARCELO JOSE DA SILVA (Participaçao Virtual)
Campus Jandaia do Sul/PR / Universidade Federal do Paraná (UFPR)

Jaboticabal, 18 de junho de 2021

DADOS CURRICULARES DO AUTOR

RAFAEL RODRIGUES FEIH - nascido em 12 de maio de 1979, no município de Cachoeira do Sul, Rio Grande do Sul, possui formação no curso de Engenharia Elétrica (2003) pela Universidade Federal de Santa Maria – Câmpus Santa Maria. De 2003 a 20019 atuou em empresas fabricantes de máquinas (tratores, pulverizadores, colhedoras de cana-de-açúcar e grãos) e equipamentos agrícolas. Também atuou em um fabricante de guinastes e outros equipamentos para movimentação de cargas e pessoas. Ao longo de sua trajetória, trabalhou nos processos de Engenharia de Produto e Validação, Engenharia de Manufatura, Pós-Vendas, Gestão de Projetos e Produção na indústria. Em função das inovações constantemente demandadas pelo Agronegócio, ele está cursando o Mestrado em Produção Vegetal, sendo orientado pelo Prof. Dr. Rouverson Pereira da Silva, na UNESP Jaboticabal, buscando conhecimentos sobre Máquinas e Mecanização Agrícola, uso de plataformas digitais e tecnologias de inteligência artificial. Durante o Mestrado, conciliou suas atividades laborais com as acadêmicas. Não foi bolsista CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico). É integrante do Laboratório de Máquinas e Mecanização Agrícola – LAMMA, onde realizou pesquisas voltadas para a área de colhedoreas de cana-de-açúcar, telemetria e inteligência artificial voltada às operações agrícolas. É membro do Rouverson Silva Research Group (RSRG), ajudando em pesquisas relacionadas a sensoriamento remoto, mecanização e agricultura de precisão.

“Importante não é ver o que alguém nunca viu, mas sim, pensar o que alguém nunca pensou sobre algo que todo mundo vê.” Arthur Schopenhauer

Ao meu filho Luciano e minha esposa Carolina por serem os verdadeiros motivos para perseverar. Ao meu pai Gilberto e mãe Elizabeth (in memorian) pela educação, oportunidades e construção do meu caráter. Ao meu Orientador por todo o conhecimento transmitido e confiança. E por último, mas não menos imporante, a Deus, por me dar as condições alcançar mais esse objetivo.

AGRADECIMENTOS

Aos meus pais Gilberto e Elizabeth por me proverem as condições para estudar e escolher minha trajetória acadêmico-profissional.

Ao meu irmão Luciano (in memoriam), pelos exemplos de garra e superação.

À minha avó Elza pelos exemplos de humildade e sabedoria.

À Carolina, minha esposa, amiga e companheira. Ao meu filho Luciano, definitivamente, a maior bênção que Carolina e eu poderíamos receber.

Aos professores e amigos do Laboratório de Máquinas e Mecanização Agrícola (LAMMA) que pude conviver em diversos momentos: Carlos Eduardo Angelini Furlani, Cristiano Zerbato, Jean, Samira, Jarlyson, Armandinho, Caio e Maranhão.

Ao ilustre colega Danilo Tedesco que me apoiou e dedicou muitas horas do seu tempo na construção desse projeto.

Ao grande amigo Luan Oliveira que gentilmente permitiu que eu utilizasse suas ideias revolucionárias nessa dissertação.

Ao Prof. Dr. Rouverson Pereira da Silva, que me recebeu, orientou e muito ensinou ao longo dos últimos anos. Serei eternamente grato pelas oportunidades, experiências e ensinamentos que recebi. Um verdadeiro professor preocupado genuinamente com o aprendizado e desenvolvimento dos alunos. Nos momentos mais difíceis, ele sempre estava lá para estender a mão e buscar por alternativas.

À Universidade Estadual Paulista – Jaboticabal por toda a estrutura, investimento, educação, que fez com que eu conseguisse realizar a Pós-Graduação em Produção Vegetal.

SUMÁRIO

Página

1 Considerações gerais 1
1.1 Introdução 1
1.2 Revisão bibliográfica 5
1.2.1 Equilíbrio operacional e patinagem 5
1.2.2 Machine learning e redes neurais convolucionais 9
1.3 Referências 13

2 Concept proof: are convolutional neural networks able to detect and count marks on a turning wheel of agricultural tractor? 17
2.1 Abstract 17
2.2 Introduction 18
2.3 Related studies 20
2.4 Material and methods 21
2.4.1 Deep meta-architectures for object detection 21
2.4.1.1 Faster region-based convolutional neural network (Faster R-CNN) 22
2.4.1.2 Single shot detector (SSD) 23
2.4.1.3 Single shot detector lite (SSDLite) 23
2.4.1.4 Feature extractors 24
2.4.2 Database build 24
2.4.2.1 Data division, image labeling and data augmentation technique 25
2.4.3 Implementation details 27
2.4.3.1 Detection algorithms 27
2.4.3.2 Performance evaluation 28
2.5 Results and discussion 30
2.5.1 Overall training performance 30
2.5.2 Manual x automatic counting of tire markings 31
2.6 Conclusions and future directions 34
2.7 Referências 34

3 Redes neurais convolucionais podem ser aplicadas para medir patinagem de um trator agrícola? 39
3.1 Resumo 39
3.2 Introdução 40
3.3 Material e métodos 41

3.4 Resultados e discussão 48
3.4.1 Treinamento do modelo 48
3.4.2 Comparação entre contagem manual e modelo SSDLite 49
3.5 Conclusão 55
3.6 Referências 56

4 Considerações finais 59

APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS PARA MEDIÇÃO DE PATINAGEM EM TRATORES AGRÍCOLAS

RESUMO – Assim como na Indústria, a era 4.0 chegou na Agricultura. Técnicas, ferramentas, sistemas de tecnologia da informação e robótica passaram a contribuir ativamente para a digitalização da Agricultura. Além da evolução tecnológica, existe uma orientação à sustentabilidade da Agricultura e utilização racional dos recursos naturais renováveis e não renováveis. Os tratores agrícolas atuais são energeticamente mais eficientes e menos poluentes desde que estejam adequados a operação em curso. Caso o conjunto trator-implemento-solo (TIS) esteja mal equilibrado, haverá redução da eficiência operacional, aumento no consumo de combustível, incremento dos custos de manutenção, desgaste prematuro dos pneus entre outros efeitos na operação agrícola. O índice de patinagem é um dos entes a serem medidos e controlados para verificar o quão bem balanceado o TIS está. Nesse contexto misto de tradição e inovação, objetivou-se neste trabalho a verificação da aplicabilidade de redes neurais convolucionais para reconhecimento e contagem de padrões visuais para então, indiretamente, medir o deslocamento das rodas de um trator com e sem carga. De posse dessas informações, foi possível determinar os índices de patinagem de dois tratores agrícolas. Futuramente essa tecnologia poderá ser adaptada para aplicações em smartphones comerciais. De posse dos níveis de patinagem, os produtores agrícolas poderão fazer os ajustes necessários à operação e assim, usar mais racionalmente os recursos naturais, máquinas, implementos agrícolas e mão-de-obra com vistas à sustentabilidade do negócio.

Palavras-chave: Agricultura Digital, Agricultura de Precisão, Equilíbrio Operacional, Inteligência Artificial, Sustentabilidade, Visão Computacional, Rodados Agrícolas.

APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS TO MEASURE AGRICULTURAL TRACTOR SLIPAGGE INDEX

ABSTRACT – The 4.0 era has arrived to the Agriculture as it had happened into the Industry. Techniques, tools and information systems and robotics started contributing actively to the Agriculture digitalization. It is not only technological evolution, but also growing concern regarding sustainability and proper use of renewable and non-renewable resources. In general, current farm tractors are more energetically efficient and less polluter if they are properly adjusted to the ongoing operation. When the set tractor-implement-soil (TIS) is misbalanced, there will be reduction of operational efficiency, increase in fuel consumption and maintenance costs, premature wear to tires among other negative effects to the operation. The slippage index is one of the entity to be measured and controlled to know how well TIS is balanced. In the context of innovation and traditional concepts, this study aimed to evaluate the applicability of convolutional neural networks (CNNs) to recognize and count marked patterns into the tire sidewall to then, indirectly, measure the displacement of the rear wheel with and without load. Based on these pieces of information, it was possible to measure, with certain limitation, the slippage index of farm tractors. In the future, this technology may be adapted to commercial smartphones as an application. By knows the slippage index at a glance, farmers will be able to do the necessary adjustments to the operation. As a result, there will be a more rational use of natural resources, machinery, implements and labor while keeping business sustainability.

Keywords: Digital Agriculture, Precision Agriculture, Operational Balance, Artificial Intelligence, Sustainability, Computer Vision, Tractor Wheels.

LISTA DE TABELAS

Página

1.1 Valores de referência para patinagem. Fonte: (ASAE, 2003). 7

2.1 Details of the detection algorithms proposed in each scenario of computational demand. Ex.: Extractor, Res.: Resolution. 27
2.2 Comparative results of detection performance in scenarios for training and validation datasets. 30
2.3 Results summary of the three scenario performances (MAPE). 31
2.4 Comparison of Actual Sampling Rate versus Nyquist Theorem. M.C: manual couting, S.R: sampling rate, s: seconds. 33

3.1 Resultados de mAP, mAR e F1-Score obtidos após treinamento e validação. 49
3.2 Comparação de resultados entre contagem manual (referência) e modelo SSDLite com extrator MobileNet V2 49

LISTA DE FIGURAS

Página

1.1 Marcas típicas deixados por um trator agrícola em função da patinagem. (a) patinagem excessiva, (b) pouca patinagem e (c) patinagem adequada. Fonte: (MONTEIRO; ARBEX, 2009). 7

1.2 A inteligência artificial é uma designação mais ampla que engloba Machine Learning. Por sua vez, Deep Learning é uma das sub-áreas do Machine Learning. Fonte:(MIN, 2020) 9

1.3 Esquema representativo de rede neural simples (a), que apresenta uma camada intermediária, e rede neural profunda (b), que possui várias camadas nas quais as saídas de uma camada são entradas da próxima, favorecendo a classificação e busca por padrões. Fonte: (VÁZQUEZ, 2018). 10

1.4 (a) Declaração da matriz de entrada e do filtro (matriz de convolução) que fará a conversão da matriz original 5 $\times$ 5 para uma matriz 3 $\times$ 3. (b) Ilustração do filtro sendo aplicado nos elementos Aij com i e j variando de 1 a 3. O filtro seguirá fazendo a convolução na matriz ao j se deslocar até 5 o que preencherá a primeira linha da matriz 3x3. O processo vai acontecendo sucessivamente. (c) O filtro chega nos últimos elementos da matriz e retorna "4" para o elemento N_{33} Fonte: (CLAPPIS, 2019). 11

1.5 A imagem de entrada entrada é convertida em imagem RGB 64 $\times$ 64 $\times$ 3. A primeira camada convolucional conta com 4 filtros 5 $\times$ 5 $\times$ 3, processa a imagem RGB 64 $\times$ 64 $\times$ 3 e produz um tensor com 4 mapas de características; a segunda camada convolucional contém 5 filtros 3 $\times$ 3$\times$ 4 que filtram o tensor da camada anterior, produzindo um novo tensor de mapa de características com tamanho 64 $\times$ 64 $\times$ 5. As funções de ativação estão representadas pelos circulos amarelos. Os círculos após cada filtro funções de ativação, responsáveis por trazer a não linearidade ao sistema. Fonte: (PONTI, 2017). 12

2.1 General architecture of the evaluated systems in this work. Figure adapted from (VASCONEZ et al., 2020). 22

2.2 Faster R-CNN meta-architecture using Inception V2 as feature extractor. Figure adapted from (VASCONEZ et al., 2020). 23

2.3 SSD meta-architecture using MobileNet V2 as feature extractor. Figure adapted:(MONTEIRO; ARBEX, 2009). 23

2.4 (a) Tractor was lifted to allow the wheel turning under stationary condition. (b) Tyre sidewall prepared to be marked. 24

2.5 (a) 20 white-doted marks. (b) 10 white-doted and 10 red-doted marks. (c) 10 white-doted and 10 red-doted marks. (c) 20 “X” profile marks. (d) 20 “X” profile marks. 25
2.6 Experimental Design – Factorial 4 (illustrative image) x 3 (wheel turning) x 3 (architecture+extractor). 26
2.7 (a) AP achieved after 200.000 steps of model training. (b) AR achieved after 200.000 steps of model training. 31

3.1 Equipamentos utilizados no experimento. (a) Trator MF 660. (b) Trator Valmet 118. (c) Arado subsolador. 42
3.2 Distâncias de estabilização (Estab.), comprimento e espaço entre parcelas. Após o período de estabilização da velocidade de deslocamento, as repetições foram feitas em sequencia. Entre cada parcela foi deixado um espaço de 5 metros (I1 e I2) para melhor identificação do início e término de cada uma. 43
3.3 Ilustração do processo de filmagem em campo. 43
3.4 Cada ponto esquematicamente apontado na Figura 4 foi demarcado em campo por uma bandeirola (seta amarela) como mostrado nesta figura. As marcações em “X” no pneu traseiro serão os objetos a serem detectados e contados pelo sistema de inteligência artificial (seta laranja). 44
3.5 Fluxograma das principais etapas para processamento de dados para medição da patinagem em videos. 45
3.6 Marcação manual dos contornos nas imagens (frames) obtidas a partir dos vídeos feitos em campo. Deve-se buscar o melhor contorno possível para que o objeto a ser detectado seja englobado. 46
3.7 Curva da precisão média ao longo do período de aprendizado (a). Curva da revocação média ao longo do período de aprendizado (b). 48
3.8 Nuvem de pontos gerados pela comparação da contagem manual (referência) com a contagem automatizada na velocidade de 2 km h^{-1} (a), 5 km h^{-1} (b) e 8 km h^{-1} (c). Estão inclusos no gráfico a equação de regressão linear que melhor se ajusta aos pontos e o R^2 associado. 50
3.9 Durante o processo de filmagem, é difícil estabilizar e manter a velocidade relativa entre o filmador e o trator especialmente em velocidades acima de 2 km h^{-1}. A linha “ROI” é a referência adotada no arquivo de inferência para medir os objetos que cruzam por ela. Como existe oscilação, é possível que um mesmo ponto seja contado mais de uma vez ou não seja contado. Isso traz erros para a medição. 52

3.10 Tipicamente as detecções e contagens ocorrem com movimentos unidirecionais. Fonte: Adaptado de (OZLU, 2021) 53
3.11 Na aplicação em campo, as detecções e contagens precisam ocorrer em movimentos acontecendo em duas direções. 53

CAPÍTULO 1 – Considerações gerais

1.1 Introdução

É inegável a importância da Agricultura para a humanidade. Além de ser a responsável por alimentar uma população crescente ano após ano, ela possui participação relevante na economia global. Os reflexos da gestão agrícola aparecem em toda cadeia produtiva do agronegócio, nas populações e no meio-ambiente. Face aos desafios enfrentados no campo, novas tecnologias e processos são o caminho para atender às demandas crescentes de um planeta faminto. Nesse contexto, a Agricultura Digital desponta como uma forte contribuinte para operações agrícolas cada vez mais eficientes e orientadas ao uso intensivo de informações – sem descuidar dos impactos ambientais.

A Agricultura Digital combina técnicas tradicionais de Agricultura com Tecnologias da Informação, Ciência de Dados e Engenharia de Controle e Automação. As novas gerações de máquinas e implementos agrícolas já contam com recursos e tecnologias que anteriormente eram disponíveis apenas para indústria automotiva e aero-espacial. Sensores instalados em máquinas e implementos agrícolas, no solo e até câmeras em drones geram dados estruturados e representativos das operações agrícolas. Ao empregar algoritmos para processar quantidades enormes de dados adquiridos por sensores em campo, os sistemas digitais geram informações que podem ser direcionadas a melhorar a eficiência das lavouras e a gestão das propriedades rurais. Em outras palavras, tecnologias de informação associadas à capacidade computacional criam oportunidades de descobrir, quantificar e entender o que está por trás dos processos e ambientes de produção agrícola. Sistemas de inteligência artificial são uma importante ferramenta para análise, controle e determinação de padrões em tais processos e ambientes.

Embora necessária, a evolução tecnológica por si só não é capaz de mitigar os impactos ambientais causados pela agricultura. Frequentemente age-se sem considerar que a Terra possui uma quantidade limitada de recursos naturais renováveis e não renováveis. Apesar de existirem iniciativas para eletrificação de máquinas agrícolas, atualmente, combustíveis fósseis são a principal fonte de energia empregada no campo. Isso implica emissão de poluentes na atmosfera e aumento do aquecimento global. Os recursos naturais estão disponíveis e continuarão a ser consumidos, contudo, eles devem ser utilizados com sabedoria e de forma otimizada.

Apesar de nem sempre haver sincronia, fabricantes de máquinas agrícolas e orgãos governamentais vêm desenvolvendo estratégias para atenuar consumo excessivo de combustível e as emissões de poluentes na atmosfera. Tem-se motores mais eficientes com controles eletrônicos e sistemas para tratar os gases de escapamento

antes de lançá-los no meio-ambiente. São importantes ações, mas insuficientes se a execução das operações agrícolas não estiver adequadamente dimensionada.

Os pneus também possuem papel importante no melhor aproveitamento energético das operações agrícolas, pois eles são responsáveis pelo contato e transmissão de potência de tração entre a máquina e o solo. Suas características construtivas, pressão de inflação e condição de desgaste influenciam diretamente na capacidade operacional.

De certa forma, o equilíbrio operacional trata da correta adequação do conjunto trator-implemento-solo a determinada operação agrícola, e balisa a eficiência energética e operacional no campo. Os principais fatores que influenciam no equilíbrio operacional são: adequação do implemento e operação ao trator selecionado; lastragem líquida e sólida; condição e tipo construtivo dos pneus, além das suas calibragens; cobertura vegetal, teor de água, topografia, textura e mobilização do solo. Uma das formas de se medir a qualidade do equilíbrio operacional de um conjunto trator-implemento é por meio do índice de patinagem.

De uma forma simplificada, pode-se dizer que a patinagem é movimentar-se continuamente sobre uma superfície sem realizar tração. Geralmente ela é expressa em valores percentuais que devem estar dentro de faixas adequadas para operações leves, médias e pesadas. Quando os valores medidos estão fora dos níveis aceitáveis, é necessário ajustar o conjunto trator-implemento à operação. Como resolver o desequilíbrio vai depender do contexto operacional, comumente é necessário ajustar a lastragem do trator, rever as pressões dos pneus e modificar a carga aplicada pelo implemento – alterar profundidade, largura, elementos ativos e velocidade de operação, por exemplo.

Os tratores tecnologicamente mais avançados já contam com soluções de fábrica para a medição do índice de patinagem. Contudo, a maior parte da frota mundial não dispõe desse recurso. É possível medir a patinagem de um trator agrícola por meio de contagem manual, por um equipamento comercialmente conhecido como avançometro, ou por sistemas computadorizados nos quais a plataforma Arduino costuma ser empregada. As medições computadorizadas são precisas e confiáveis, entretanto, demandam um tempo de calibração e investimento em aquisição de equipamentos. Os métodos manuais são de custo virtualmente nulo, contudo, estes estão sucetíveis a erros humanos. Um sistema ideal teria o melhor dos dois mundos: alta confiabilidade, praticidade e baixíssimo custo de aquisição. Eis uma provocação: E se utilizássemos um equipamento popularmente disponível para fazer as medições com acurária sem erros humanos?

Controles eletro-eletrônicos e informatizados são um caminho sem volta nas máquinas agrícolas. Os tratores atuais podem contar com rede de comunicação padrão CAN-Bus, telemetria e diversos sensores para medição de grandezas em campo tais como consumo de combustível, pressão no sistema hidráulico, potência e rotação do motor entre outras. Mesmo em meio a toda essa tecnologia, conceitos agronômicos tradicionais como equilíbrio operacional seguem em voga. Nessa relação complementar entre tradição e tecnologia, existe espaço para máquinas e dispositivos inteligentes capazes de aprender continuamente.

O Aprendizado de Máquina (*Machine Learning* - ML) é um conjunto de técnicas e sistemas capazes de ensinar computadores a aprender com dados e experiências. O ML vem sendo aplicado em diversas áreas do conhecimento tais como Engenharia, Medicina, Negócios, Agricultura e Pecuária. Pesquisadores do Massachusetts Institute of Technology (MIT) empregaram técnicas de ML para detectar crises convulsivas ao enxergar padrões nas leituras de eletroencefalogramas. Na Universidade de Queensland, cientistas utilizaram técnicas de ML para monitorar comunidades de sapos por meio da análise dos sons emitidos pelos répteis. Existem também aplicações com drones dotados de algoritmos de ML capazes de contar cabeças de gado no pasto. Para a Agricultura, já existem aplicativos comerciais para detecção de pragas, plantas invasoras e doenças por meio do reconhecimento de imagens.

Atualmente, redes neurais convolucionais são o estado-da-arte no que tange à aplicação de ML à contagem e identificação de formas e objetos. Redes neurais convolucionais são algoritmos de aprendizado capazes de analisar uma imagem de entrada e retornar classes e características do(s) objeto(s) contidos na imagem e fazer as devidas diferenciações. Por exemplo, após ser adequadamente treinada, uma rede convolucional é capaz de detectar placas de veículos em movimento pois ela aprendeu o alfabeto e os digitos númericos na etapa de aprendizado. Mais do que isso, o aprendizado é retroalimentado, ou seja, quanto mais o algoritmo opera, mais ele consegue aprender diferentes nuances como placas desgastadas em ambientes com diversos níveis de luminosidade, por exemplo.

Tornar a medição de patinagem prática e assertiva por meio de redes neurais convolucionais evitará consumo excessivo de combustível, desgastes dos acentuado dos pneus, redução da vida útil conjuntos mecânicos do trator além de minimizar eficiência operacional. Durante uma condição real em campo, a adequação do equilíbrio operacional pode tomar certo tempo para alternar de uma operação de preparo de solo para pulverização, por exemplo. Nem sempre há pessoas suficientes ou equipamentos necessários para a determinação do índice patinagem. Com isso, a mesma lastragem é adotada para diversas operações. Consequentemente, tratores nem sempre trabalham na faixa ótima de patinagem.

Os tratores produzidos atualmente são dependentes da adição de lastro seja na forma sólida e/ou líquida. Associado a isso, tem-se as condições dinâmicas de campo relacionadas às diversas condições e operações agrícolas. Tornar a medição de patinagem prática e assertiva por meio de redes neurais convolucionais mostrará rapidamente um eventual desequilíbrio na operação que pode acarretar em consumo excessivo de combustível, desgastes dos acentuado dos pneus, redução da vida útil conjuntos mecânicos do trator além de minimizar eficiência operacional. Durante uma condicão real em campo, a adequacão do equilíbrio operacional pode tomar certo tempo para alternar de uma operacão de preparo de solo para pulverização, por exemplo. Como nem sempre os recursos necessários para determinação do índice de patinagem e posterior adequação do TIS, frequentemente a mesma lastragem é adotada para diversas operacões. Consequentemente, tratores nem sempre trabalham na faixa ótima de patinagem.

A proposta desse trabalho é desenvolver um sistema baseado em técnicas de aprendizado profundo de máquina para determinar o índice de patinagem em tratores agrícolas. Entende-se que uma tecnologia descomplicada e ágil possa identificar desvios nos limites de patinagem. De posse dessa informação, o produtor pode tomar as providências para reequilibrar o conjunto trator-implemento-ambiente e assim, aumentar a eficiência operacional, prolongar a vida útil dos pneus, reduzir o consumo de combustível e diminuir gastos com manutenção.

Assim, este trabalho parte do pressuposto que técnicas de aprendizado de máquina, como redes neurais convolucionais, são capazes de identificar e contar, por meio de reconhecimento de imagens, o número de revoluções da roda traseira de um trator agrícola. Objetivou-se nesta dissertação investigar a viabilidade da aplicação de redes neurais convolucionais em condições estacionárias (laboratório) e dinâmicas (em campo) para determinação do índice de patinagem de tratores agrícolas. Como objetivos específicos tem-se:

1. Identificar qual algoritmo de rede neural convolucional apresenta o melhor desempenho na medição do índice de patinagem.
2. Determinar qual o tipo de marcação nos pneus que melhor se adequa a aplicação em questão
3. Comparar os resultados do sistema de inteligência artificial com os valores obtidos pela contagem manual tradicional

Esta dissertação está estruturada em quatro capítulos. Inicia-se com as considerações gerais do trabalho e o referencial teórico no primeiro Capítulo. A prova de conceito realizada em condições estacionárias consta no Capítulo 2, enquanto a avaliação em condições dinâmicas (campo) é apresentada no Capítulo 3. Finalmente, no Capítulo 4 são apresentadas as considerações finais da dissertação.

1.2 Revisão bibliográfica

1.2.1 Equilíbrio operacional e patinagem

Embora a Agricultura esteja em constante evolução, ainda há oportunidades para melhorar as operações e processos. Um dos desafios que o produtor enfrenta no campo é obter o equilíbrio operacional adequado às mudanças constantes de operação que ocorrem em campo. Por mais que um trator esteja adequadamente lastreado e ajustado ao implemento, a dinâmica imposta pelas operações agrícolas pode fazer com que o equilíbrio seja perdido ao trocar de talhão (SENAR, 2017). A variabilidade das operações agrícolas, amplamente estudada pela Agricultura de Precisão, é reflexo, entre outras coisas, dos níveis de compactação, declividade do terreno, textura do solo e regulagens operacionais das máquinas e implementos.

A adequação do conjunto trator-implemento-solo é resultado de uma série de fatores, ajustes e configurações. Embora a lastragem tenha importância significativa no equilíbrio operacional, é preciso atentar para outros fatores antes de modificar o lastro do trator. Deve-se considerar também a adequação dos pneus para a operação; teor de

água, cobertura vegetal, relevo irregular e/ou variação da textura do solo dentro da área de trabalho; marcha ou rotação do motor inadequada para a operação; implemento incompatível com o trator; ou implemento mal ajustado para a operação (SENAR, 2017).

O exemplo típico do desequilíbrio do conjunto trator-implemento acontece durante o efeito galope (*power hop*), o que torna a operação impraticável. Esse efeito indesejado poderá causar desgaste acelerado do trator sem falar na redução de conforto, segurança e eficiência do operador (FRANCETTO, 2012).

A lastragem é o método para ajustar a massa do trator a fim de incrementar a aderência entre rodas motrizes e solo. Busca-se aumentar a capacidade de tração e melhorar a estabilidade do trator para evitar tombamentos (VIANA; ZAMBOLIM; SOUSA, 2017). A lastragem adequada proporciona redução de compactação do solo, aumento da vida útil dos pneus, reduz as perdas por tração, minimiza a patinagem e evita o consumo excessivo de combustível. Pode-se dizer que a lastragem adequada melhora significativamente o desempenho do trator nas operações em campo (MONTEIRO; LANÇAS; GUERRA, 2011; SPAGNOLO et al., 2012).

Os pneus são os elementos de transferência de energia motriz entre rodas e solo. Os fabricantes possuem uma série de classificações e formas construtitvas que melhor se adequam a cada operação. Além disso, a pressão de inflação dos pneus também influencia na tração aplicada pelo trator ao implemento por alterar a área de contato entre pneu e solo (FEITOSA et al., 2015). Em função disso, ela impacta na distribuição das tensões cisalhantes, compactação do solo e desempenho operacional do trator. Quando a pressão de inflação está adequada à operação, tem-se melhor distribuição das tensões de cisalhamento e da força normal associada ao peso do trator, redução do risco de compactação do solo e melhor desempenho quanto à tração útil na barra de tração (TAGHAVIFAR; MARDANI, 2013).

A patinagem dos rodados do trator agrícola é movimento relativo entre a superfície de contato do rodado e o solo. Embora a patinagem possa ser encarada como uma perda de potência (ASAE, 2003), ela é necessária para que o trator consiga tracionar os implementos (OIOLE et al., 2018). A patinagem das rodas motrizes dos tratores pode ser determinada pela diferença entre as suas rotações nas situações com e sem implemento em operação (carga) no trator. Essas duas medições são feitas em um trajeto representativo da operação a ser realizada. Na Figura 1.1, tem-se a ilustração das marcas impressas no solo em função do nível de patinagem (*foot print*). Embora seja uma avaliação mais subjetiva, ela consegue dar uma boa indicação se o trator está com patinagem baixa, adequada ou excessiva.

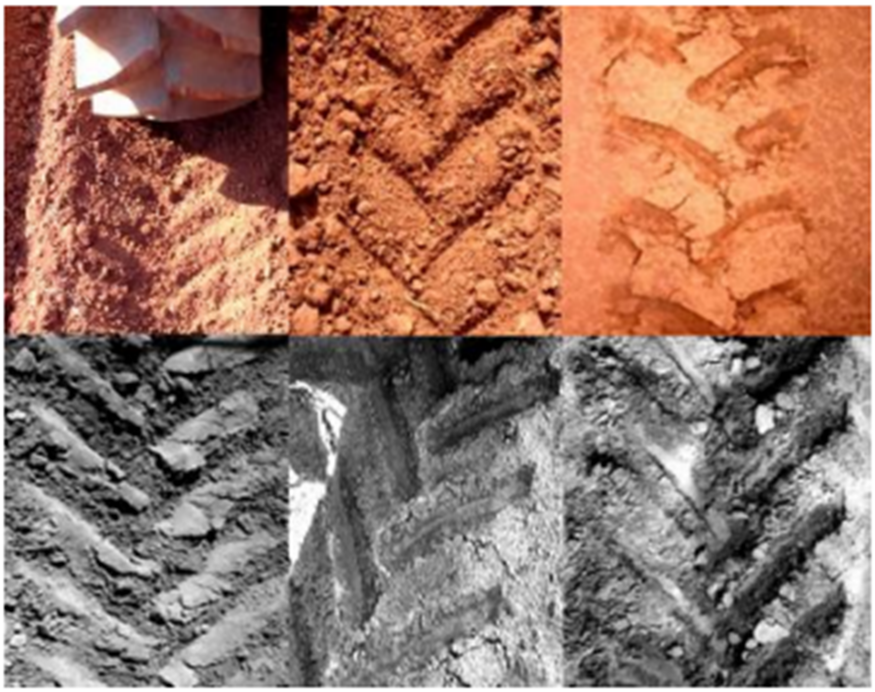


Figura 1.1: Marcas típicas deixados por um trator agrícola em função da patinagem. (a) patinagem excessiva, (b) pouca patinagem e (c) patinagem adequada. Fonte: (MONTEIRO; ARBEX, 2009).

Como referência para valores de patinagem, podem ser adotados os valores estabelecidos por (ASAE, 2003), apresentados na Tabela 1.1.

Tabela 1.1: Valores de referência para patinagem. Fonte: (ASAE, 2003).

Tipo de Solo	Patinagem (%)
Concreto	4 a 8
Solo não mobilizado	8 a 10
Solo mobilizado	11 a 13
Solos arenosos ou soltos	14 a 16

A patinagem pode ser obtida por meio da Equação 1.1, na qual se obtém valores percentuais (ASAE, 2003). O termo carga refere-se ao implemento acoplado na barra de tração:

$$S = ((A_n - A_1)/A_n)x100 \tag{1.1}$$

em que: S: patinagem do pneu (%) A_n: deslocamento percorrido em condições sem carga por revolução da roda (m); A_1: deslocamento percorrido em condições com carga por revolução da roda (m).

Além da forma sugerida pela ASAE, é possível calculcar a patinagem por outros métodos. Um método alternativo considera medir o tempo de deslocamento de uma distância fixa com o trator operando com e sem carga. Então é feito um cálculo similar ao da Equação 1.1, para determinar a patinagem (SENAR, 2017).

Outro método de medição da patinagem consiste na instalação de sensores de pulsos na roda dianteira para então deslocar o trator por uma distância fixa nas condições com carga e sem carga (CASADY, 1996; SOUZA et al., 2014). Uma vez que a distância percorrida em ambas as condições são as mesmas, o cálculo da patinagem percentual passa a ser função da quantidade de pulsos conforme Equação 1.2. Essa forma de medição, mais compatível com este trabalho, será melhor explorada no Capítulo 3.

$$Pat = ((N_1/N_0) - 1)x100 \tag{1.2}$$

Em que: Pat : Patinagem (%); N_0: Número de pulsos sem carga; N_1: Número de pulsos com carga.

Outra forma de medir a patinagem é por meio de sensoriamento. Os sensores são instalados nas rodas motrizes e se comunicam com o controlador por tecnologia sem fio. Após o processo de calibragem dos sensores ao trator, o instrumento está apto a medir a patinagem em tempo real (FINGER, 2006).

Quando o conjunto trator-implemento-solo não está adequadamente equilibrado, há reflexo direto no consumo de combustível e comprometimento da capacidade operacional e disponibilidade de potência na barra de tração. Se o trator está com excesso de lastro, há desperdício de combustível por conta do aumento da resistência ao rolamento, desgaste do pneu e compactação do solo. Quando o lastro é insuficiente, tem-se desperdício de combustível por patinagem excessiva desgaste prematuro dos pneus (CASADY, 1996).

A interação solo-pneu pode representar uma perda de 20 a 55% da potência útil do trator em função da patinagem e resistência de rolagem (TAGHAVIFAR; MARDANI, 2014). Além do impacto da eficiência energética da operação, o excesso de massa aumenta a compactação do solo o que implica prejuízos para a produção agrícola (LOURES, 2004).

O uso racional de lastro possibilita alcançar maior eficiência operacional do trator, reduzindo as perdas de energia pela resistência a rolagem, reduz perdas de tração, deslizamento e consumo de combustível (MONTEIRO; ARBEX, 2009).

1.2.2 Machine learning e redes neurais convolucionais

Os dados gerados nas operações agrícolas modernas são obtidos por meio de diversos tipos de sensores. Com esses dados é possível entender, por exemplo, a interação dinâmica com a planta e solo, condições climáticas e dados das máquinas (LIAKOS et al., 2018). Para tratar essa quantidade enorme de dados e convertê-los em informação, diversas tecnologias são empregadas, entre elas, Controle Estatístico de Processo, Inteligência Artificial (IA) e suas sub-áreas ML e Aprendizado Profundo (*Deep Learning* - DL). A Figura 1.2, mostra a hierarquia entre IA, ML e DL.

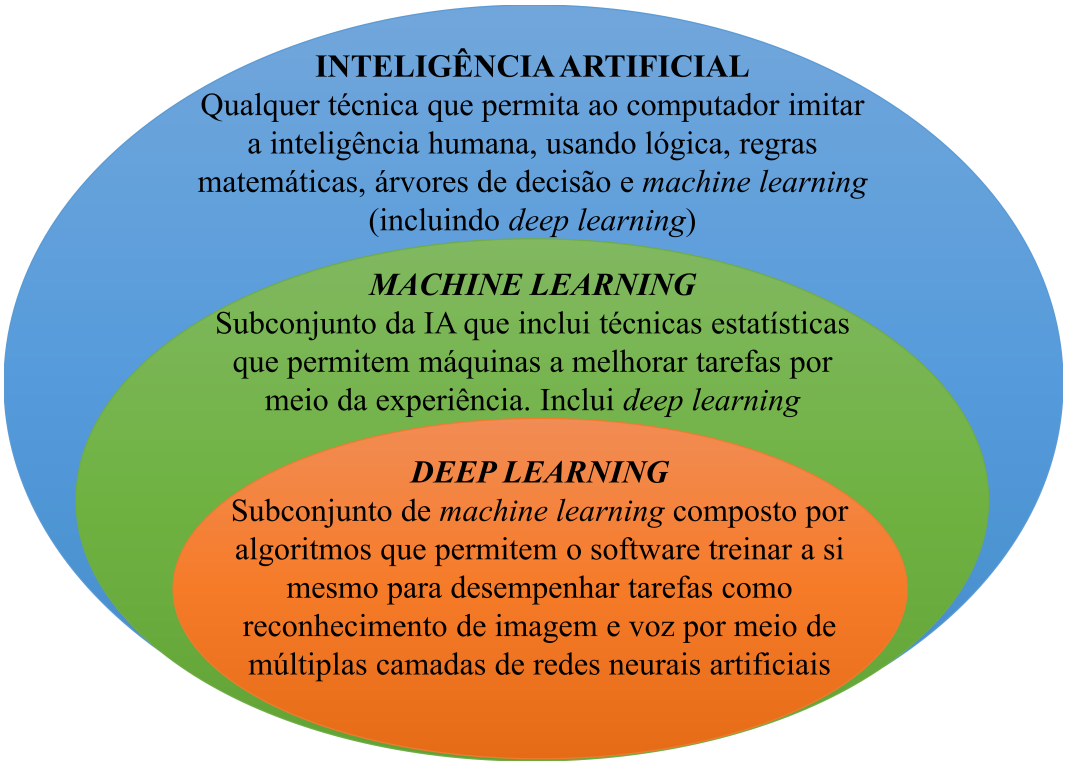


Figura 1.2: A inteligência artificial é uma designação mais ampla que engloba Machine Learning. Por sua vez, Deep Learning é uma das sub-áreas do Machine Learning. Fonte:(MIN, 2020)

O termo ML pode ser definido como a ciência e arte de programar computadores para que eles aprendam com os dados obtidos (GÉRON, 2017). Em outras palavras, ML é a utilização de algoritmos para processar dados, aprender com eles e tomar decisão baseado nos dados processados.

Desde o advento do ML, diferentes técnicas foram propostas, tais como árvores de decisão, programação lógica induzida, redes Bayesianas e DL. As ferramentas de DL são amplamente empregadas na análise de dados não categorizados tais como reconhecimento de voz, processamento e classificação de imagens (PACHECO; PEREIRA, 2018).

DL adota algoritmos mais complexos do que ML e seus fundamentos baseiam-se no princípio das redes neurais que buscam imitar o cérebro humano. Enquanto ML usualmente trabalha de forma linear, DL trabalha com diversas camadas conectadas hierarquicamente. Isso permite análises mais complexas e profundas (STEFANINI, 2020). Na Figura 1.3, tem-se uma ilustração da diferença básica entre uma rede neural simples e uma rede neural profunda.

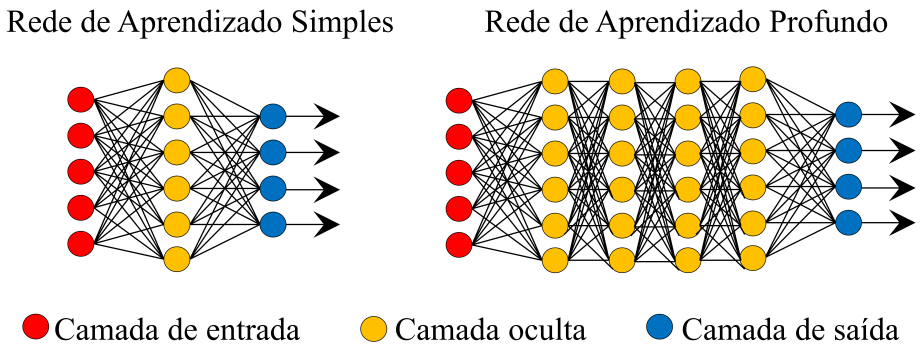


Figura 1.3: Esquema representativo de rede neural simples (a), que apresenta uma camada intermediária, e rede neural profunda (b), que possui várias camadas nas quais as saídas de uma camada são entradas da próxima, favorecendo a classificação e busca por padrões. Fonte: (VÁZQUEZ, 2018).

Uma Rede Neural Convolucional (RNC) é uma rede neural multicamadas capaz de detectar objetos, padrões, formas, animais e pessoas. Elas podem ser treinadas para reconhecer, adicionar e subtrair elementos de diferentes formas e cores (STROSKI, 2018). O termo convolução parte da operação linear matemática na qual, a partir de duas funções, se obtém uma terceira. Na Figura 1.4, tem-se a ilustração da transformação de uma matriz 5 $\times$ 5 interagindo com a matriz de filtro 3 $\times$ 3. O resultado da convolução é uma nova matriz 3 $\times$ 3, ou seja, menor que a original 5 $\times$ 5 (CLAPPIS, 2019). As redes neurais convolucionais possuem a capacidade de aprender automaticamente a partir de grande número de filtros referentes a um conjunto de dados de treinamento baseando-se em uma biblioteca padrão como MS-COCO nas imagens de entrada (ALIGER, 2019). Essa capacidade das redes neurais convolucionais de adaptação poderá ser empregada para contabilizar o número de voltas da roda do trator durante o percurso de determinação do índice de patinagem. O pós-processamento das quantidades de pulsos obtidos no percurso com e sem implemento em operação permitirá o cálculo do índice de patinagem de um trator agrícola.

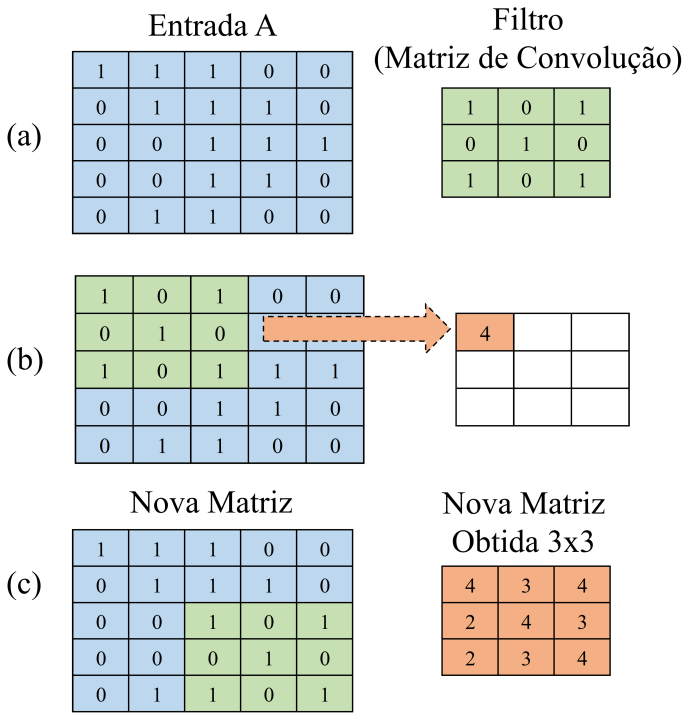


Figura 1.4: (a) Declaração da matriz de entrada e do filtro (matriz de convolução) que fará a conversão da matriz original 5 × 5 para uma matriz 3 × 3. (b) Ilustração do filtro sendo aplicado nos elementos Aij com i e j variando de 1 a 3. O filtro seguirá fazendo a convolução na matriz ao j se deslocar até 5 o que preencherá a primeira linha da matriz 3x3. O processo vai acontecendo sucessivamente. (c) O filtro chega nos últimos elementos da matriz e retorna "4" para o elemento N_{33} Fonte: (CLAPPIS, 2019).

Na Figura 1.5, é apresentado o modo como uma rede neural convolucional de duas camadas converte a imagem de um gato em mapas de características compreensiveis para os algoritmos fazem a detecção dos objetos, pessoas ou animais. A alta capacidade de processamento e classificação de imagens das Redes Neurais Convolucionais permitem sua aplicação direta em várias contextos agronômicos. Um algoritmo dotado de Redes Neurais Convolucionais obteve uma acurácia em torno de 97% na identificação de cultivares de guaranazeiro (FERREIRA, 2017; CARVALHO; GUEDES; SALAME, 2020; FERREIRA, 2017), aplicaram RNCs na detecção de plantas daninhas na soja e em outras culturas com precisão superior a 97%.

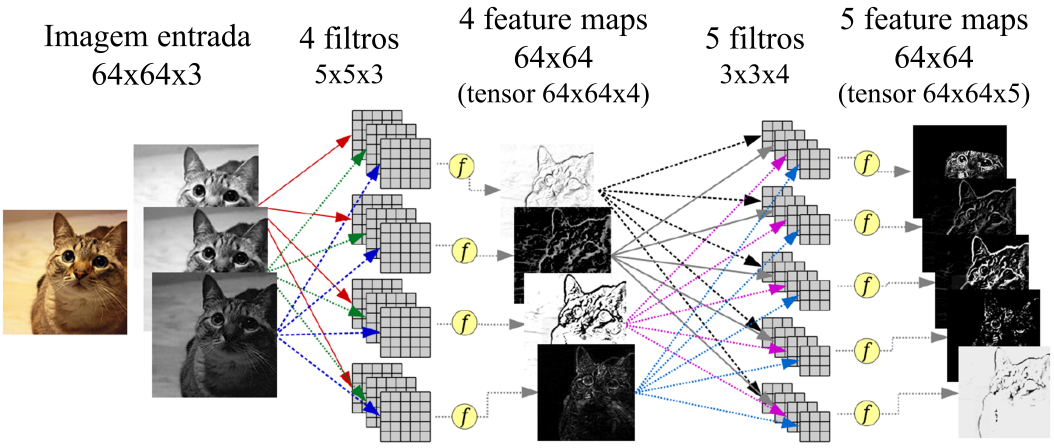


Figura 1.5: A imagem de entrada entrada é convertida em imagem RGB $64 \times 64 \times 3$. A primeira camada convolucional conta com 4 filtros $5 \times 5 \times 3$, processa a imagem RGB $64 \times 64 \times 3$ e produz um tensor com 4 mapas de características; a segunda camada convolucional contém 5 filtros $3 \times 3 \times 4$ que filtram o tensor da camada anterior, produzindo um novo tensor de mapa de características com tamanho $64 \times 64 \times 5$. As funções de ativação estão representadas pelos circulos amarelos. Os círculos após cada filtro funções de ativação, responsáveis por trazer a não linearidade ao sistema. Fonte: (PONTI, 2017).

Na fruticultura, (SILVA et al., 2004) avaliaram a recomendação de adubação em goiabeiras por meio de redes neurais artificiais. (NETO; TERNES; QUEIROS, 2019) utilizaram uma rede neural de aprendizado profundo para a detecção e contagem de frutos verdes a partir de imagens digitais de pés de laranja obtidas no campo com precisão e revocação superiores a 90%. Nos Capítulos 2 e 3 haverá revisão de literatura complementar mais direcionada ao contexto desse trabalho: aplicação de redes neurais convolucionais para determinar a patinagem de um trator agrícola por meio do reconhecimento e contagem de imagens.

1.3 Referências

ALIGER. **As Redes Neurais Convolucionais no Deep Learning — Aliger**. 2019. Disponível em: ⟨https://www.aliger.com.br/blog/as-redes-neuronais-convolutivas-no-deep-learning⟩. Acesso em: 13 abr. 2020.

ASAE. Agricultural Machinery Management - ASAE496.2. **ASAE Standards**, p. 397–372, 2003. Disponível em: ⟨http://www3.abe.iastate.edu/ast330/Project/AESE496.2.pdf⟩.

CARVALHO, V.; GUEDES, E.; SALAME, M. Classificação de Ervas Daninhas em Culturas Agrícolas com Comitês de Redes Neurais Convolucionais. In: . 2020. **Anais eletrônicos...**, [s.n.], 2020. p. 60–71. Disponível em: ⟨https://sol.sbc.org.br/index.php/eniac/article/view/9272/9174⟩.

CASADY, W. Tractor Tire and Ballast Managementtle.

1996.

CLAPPIS, A. **Uma introdução as redes neurais convolucionais utilizando o Keras**. 2019. Disponível em: ⟨https://medium.com/data-hackers/uma-introdu{\unhbox\voidb@x\setbox\z@\hbox{c}{\lineskiplimit-\maxdimen\unhbox\voidb@x\vtop{\baselineskip\z@skip\lineskip.25ex\everycr{}\tabskip\z@skip\halign{#\crcr\unhbox\z@\crcr\hskip\hideskip\char24\hskip\hideskip\crcr}}}}{~{a}}o-as-redes-neurais-convolucionais-utilizando-o-keras-⟩. Acesso em: 13 abr. 2020.

FEITOSA, J.; FERNANDES, H.; TEIXEIRA, M.; CECON, P. Influência da pressão interna dos pneus e da velocidade de deslocamento nos parâmetros operacionais de um trator agrícola e nas propriedades físicas do solo. **Journal of the Brazilian Association of Agricultural Engineering**, v. 35, n. 2, p. 302–312, 2015. Disponível em: ⟨http://dx.doi.org/10.1590/⟩.

FERREIRA, A. d. S. Redes Neurais Convolucionais Profundas na Detecção de Plantas Daninhas em Lavoura de Soja. **Master Thesis**, p. 70, 2017.

FINGER, F. **Avançometro, medidor dos índices de avanço e patinagem em tratores e distncias — Escavador**. 2006. Disponível em: ⟨https://www.escavador.com/patentes/393974/avancometro-medidor-dos-indices-de-avanco-e-patinagem-em-tratores-e-distncias⟩. Acesso em: 13 abr. 2020.

FRANCETTO, T. **Relação peso/potência dos tratores — Engenharia Agrícola**. 2012. Disponível em: ⟨https://tiagofrancetto.blogspot.com/2012/04/relacao-pesopotencia-dos-tratores.html⟩. Acesso em: 13 abr. 2020.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. [S.l.], 2017.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. **Machine learning in agriculture: A review**. 2018. Disponível em: ⟨www.mdpi.com/journal/sensors⟩.

LOURES, F. A. **Campos dos goytacazes – rj agosto de 2004**. 2004. Tese (Doutorado), 2004.

MIN, H. **Aplicações de Machine Learning em Marketing e Vendas — by Henrique Min — Medium**. 2020. Disponível em: ⟨https://medium.com/@henriqm01/aplica{\unhbox\voidb@x\setbox\z@\hbox{c}{\lineskiplimit-\maxdimen\unhbox\voidb@x\vtop{\baselineskip\z@skip\lineskip.25ex\everycr{}\tabskip\z@skip\halign{#\crcr\unhbox\z@\crcr\hskip\hideskip\char24\hskip\hideskip\crcr}}}}{~{o}}es-de-machine-learning-em-marketing-e-vendas-⟩. Acesso em: 08 fev. 2021.

MONTEIRO, L. d. A.; ARBEX, P. Operação com tratores agrícolas. **Botucatu: Ed. dos Autores**, 2009.

MONTEIRO, L. D. A.; LANÇAS, K. P.; GUERRA, S. P. Desempenho de um trator agrícola equipado com pneus radiais e diagonais com três níveis de lastros líquidos. **Engenharia Agricola**, v. 31, n. 3, p. 551–560, 2011.

NETO, J. C.; TERNES, S.; QUEIROS, L. R. Uso de redes neurais convolucionais para detecção de laranjas no campo. p. 11, 2019.

OIOLE, Y.; Leonidas Kmiecik, L.; Xavier Silva, T. D.; Cristiano Machioski, M.; Paulo Jasper, S.; AGRÔNOMO, E.; Doutor Adjunto, P. A. **DETERMINAÇÃO DA PATINAGEM DOS RODADOS DO TRATOR DE 92,67 KW ATRAVÉS DA INSTRUMENTAÇÃO ELETRÔNICA INSTALADA E EQUAÇÕES DA LITERATURA**. [S.l.], 2018.

PACHECO, C. A. R.; PEREIRA, N. S. Deep Learning: Conceitos e Utilização nas Diversas Áreas do Conhecimento. **Revista Ada Lovelace**, v. 2, p. 34–49, 2018. Disponível em: ⟨http://anais.unievangelica.edu.br/index.php/adalovelace/article/view/4132⟩.

PONTI, M. A. Como funciona o Deep Learning. p. 31, 2017.

SENAR. Operação de tratores agrícolas. **Serviço Nacional de Aprendizagem Rural**, p. 192, 2017.

SILVA, S. H.; CARVALHO, A. C. P. d. L. F.; ROMERO, R. A. F.; CRUVINEL, P. E.; NATALE, W. **Rdes neurais artificiais e agricultura de precisão para recomendação de adubação da cultura da goiabeira**. [S.l.], 2004. 37–42 p. Disponível em: ⟨http://www.agrocomputacao.uepg.br⟩.

SOUZA, F. H. D.; MONTEIRO, L. D. A.; MELLO, M. M. D.; FREITAS, L. A. DETERMINAÇÃO DA PATINAGEM DOS RODADOS DO TRATOR EM FUNÇÃO PRESSÃO DE INFLAÇÃO DOS PNEUS E FORÇA APLICADA NA BARRA DE TRAÇÃO EM PISTA DE CONCRETO. In: . 2014. **Anais...**, [S.l.: s.n.], 2014. p. 4.

SPAGNOLO, R. T.; VOLPATO, C. E.; BARBOSA, J. A.; PALMA, M. A.; De Barros, M. M. Fuel consumption of a tractor in function of wear, of ballasting and tire inflation

pressure. **Engenharia Agricola**, v. 32, n. 1, p. 131–139, jan 2012. Disponível em: ⟨http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162012000100014&lng=pt&nrm=iso&tlng=enhttp://www.scielo.br/scielo.php?script=sci_abstract&pid=S0100-69162012000100014&lng=pt&nrm=iso&tlng=en⟩.

STEFANINI, G. **Machine Learning Deep Learning: entenda a diferença**. 2020. Disponível em: ⟨https://stefanini.com/pt-br/trends/artigos/machine-learning-vs-deep-learning⟩. Acesso em: 08 fev. 2021.

STROSKI, P. **O que são redes neurais convolucionais? - Electrical e-Library.com**. 2018. Disponível em: ⟨http://www.electricalelibrary.com/2018/11/20/o-que-sao-redes-neurais-convolucionais/⟩. Acesso em: 13 abr. 2020.

TAGHAVIFAR, H.; MARDANI, A. Investigating the effect of velocity, inflation pressure, and vertical load on rolling resistance of a radial ply tire. **Journal of Terramechanics**, v. 50, n. 2, p. 99–106, 2013.

TAGHAVIFAR, H.; MARDANI, A. Applying a supervised ANN (artificial neural network) approach to the prognostication of driven wheel energy efficiency indices. **Energy**, Elsevier Ltd, v. 68, p. 651–657, apr 2014. Disponível em: ⟨http://dx.doi.org/10.1016/j.energy.2014.01.048⟩.

VÁZQUEZ, F. **A "weird" introduction to Deep Learning**. 2018. Disponível em: ⟨https://towardsdatascience.com/a-conversation-about-deep-learning-9a915983107https://towardsdatascience.com/a-weird-introduction-to-deep-learning-7828803693b0⟩. Acesso em: 08 fev. 2021.

VIANA, L. d. A.; ZAMBOLIM, L.; SOUSA, T. V. LASTRAGEM COMO FORMA DE MELHORAR A EFICIÊNCIA DE TRAÇÃO DE TRATOR AGRÍCOLA. p. 6, 2017.

CAPÍTULO 2 – Concept proof: are convolutional neural networks able to detect and count marks on a turning wheel of agricultural tractor?

2.1 Abstract

One of the most relevant factors for a fuel consumption optimization is the operational balance. Slippage of an agricultural tractor is the percentage difference of wheel advance under no load and the wheel advance under load conditions. It indicates how well the set tractor-implement (STI) is adjusted to the operation. When STI is out of the slippage range, many unwanted effects arise such as excessive fuel consumption, increase of maintenance costs, premature tire wear and poor operational performance. Based on this context, this a concept evaluation study that aimed to evaluate the utilization of machine learning techniques based on convolutional neural networks to detect and count objects on a turning wheel of an agricultural tractor under controlled and stationary conditions. By knowing the amount of objects under load and no load, it is possible to calculate slippage. This work considered three different speeds, four different sort of objects (marks) and three different CNN architectures. We evaluate three different models of detectors and its respective feature extractors: Faster Region-based Convolutional Neural Network (Faster R-CNN) with extractor Inception V2, Single Shot Multibox Detector (SSD) with extractor MobileNet V2 and Single Shot Multibox Detector Lite (SSD-Lite) with extractor MobileNet V2. Our research has shown that CNNs have a high potential for object detection and counting. Architecture “Faster R-CNN + Inception V2” combined with “X” chalk had MAPE 1.49% and MAPE 2.5% for red dots. Architecture “SSD Lite + MobileNet V2” combined with “X” chalk delivered MAPE 4.48% and MAPE 3.75% for red dots at low speed. All three models delivered F1-Score equal or higher than 0.65. The scheme SSD Lite + MobileNet V2 plus “X” chalk markings has led to encouraging results while demands low computational resource. Therefore, this is the chosen scheme to move forward in future research. There is room for improvement as the CNNs performance was not satisfactory at higher speeds. These findings will be the foundation to develop a mobile application based on Machine Learning techniques to recognize visual patterns and then measure the slippage of farm tractors on the field.

Keywords: tractor performance, operational balance, fuel efficiency, deep learning, object detection, cost reduction, environment sustainability, digital agriculture, computer vision.

2.2 Introduction

The continuous population growth pressures the food supply chain for more and better-quality food. As a result, agricultural management and its operations shall be efficient and productive while sustainability and eco-friendly standards, regulations and best practices shall be met. Over the last decades, technology applied to Agriculture has been playing an important role to achieve such population growing needs. The terminology Digital Agriculture is used to describe the intense amount of data and technological tools applied to increase efficiency of agricultural processes without ignoring environmental impacts (LIAKOS et al., 2018).

In terms of environment, two of the top concerns are the emissions from machinery engines and burn of non-renewable fossil fuels. The operational balance of tractor-implement-soil (TIS) shall be adjusted according to field operation dynamics. In other words, it is necessary that the tractor and implement are properly adjusted to agricultural operation (tillage, planting, spraying and so on). Otherwise, the fuel consumption and operation performance will be jeopardized. It is time consuming to adjust the operational balance of the set tractor-implement when the operation changes, for instance, from tillage to spraying. Prior starting a new operation, it is necessary to check the ballasting, tire inflating pressure, tire wear condition, soil texture compaction and its biomass superficial layer. Implement adjustments and its configuration also affect the operational balance. The slippage index of a wheel tractor is currently used to evaluate the overall operational balance of the set tractor-implement.

The combination of traditional agriculture and digital technology seems to be an alternative to current slippage index measurement methodology. Digital Agriculture refers to the combination of agriculture, information technology, data science and control and automation engineering. It uses algorithms to process enormous amount of data from field sensors. These data are analyzed and converted into information that can be used to improve management efficiency of rural properties (SILVA et al., 2019).

Machine Learning (ML) is one of these technological packages which have been applied not only in Agriculture but also in other areas of knowledge. ML is application of computer systems that are able to learn and adjust without receiving defined instructions, by using algorithms and statistical models to analyze and present inferences from patterns in data (LIAKOS et al., 2018). It consists to the science and art to program computers to learn from data (GÉRON, 2017).

One typical application of Machine Learning is the computer vision tasks that use deep learning techniques such as Convolutional Neural Networks (CNNs). Usually, CNNs are used for object recognition, classification and counting. They are able to achieve high degree of accuracy (RAHNEMOONFAR; SHEPPARD, 2017). The CNNs are a sort of multiple layer neural network which is able to detect objects, patterns, shapes, animals and people (STROSKI, 2018). They can be taught to recognize, add and subtract elements of different shapes and colors.

The slippage of drive wheels on soil surfaces is a power loss (ASAE, 2003). The slippage index is the percentage of the difference of wheel advance under no load conditions and the wheel advance under load. Our hypothesis is that it is possible to calculate indirectly the slippage index if:

1. The evaluation distance is fixed.

2. Computer vision system is able to count the amount of marks that pass through the reference line for both no load and under load condition.

These findings will be the foundation to develop a mobile application based on Machine Learning techniques to recognize visual patterns and then measure the slippage of an agricultural tractor on the field.

Instead of using expensive equipment or manual counting and calculation to measure the operational balance, we propose a new concept to do it in this paper: develop an artificial vision system based on a convolutional neural networks to measure tractor wheel displacement under stationary conditions. It is the first step towards the slippage index measurement by using computer vision.

To the best of our knowledge, there is no similar initiative such ours: vision-based tasks to measure slippage index without any sensors but a smart phone. Hereafter, we will present studies on convolutional neural networks techniques for object counting and recognition; moreover, we will introduce related works on slippage index measurement (Section 2.3). We will bring general architecture of this work: data set acquisition, the CNN approaches under evaluation, different testing conditions and the testing procedures (Section 2.4). Our findings, experimental results and discussion (Section 2.5). Eventually, we will state our conclusions, learnt lessons and future work proposals (Section 2.6).

2.3 Related studies

Over the years, some different approaches to measure the tractor slippage index have been proposed. The most common method is to mark a reference point on the rear wheel and measure the displacement (meters) of the tractor after 20 turns without load and then 20 turns under load. The percentage between the respective displacements “without load” and “under load” is the slippage index (FURLANI, 2014). There is a variance of this method: instead of using the 20 turns and calculate the slippage index from the displacements, a fixed distance of 50 m is used. It is necessary to stop the watch to measure how long it takes to the tractor runs the fixed distance without load and then the same under load. This method uses the time difference from the condition under load and without load to calculate the slippage index (SENAR, 2017).

There is a piece of commercial equipment called “slippage meter” that uses sensors, HMI and microprocessor system (FINGER, 2006). Despite being expensive and some setup time is required, this option is very accurate and user friendly. There are also some research on low cost systems to measure slippage index and other key performance indicators of tractor operations. Usually, these systems use Arduino platform and low cost sensors (JÚNIOR, 2017; LOURES, 2004). Although the technological platforms are different, the concept is very much the same: use sensors and data acquisition systems to count the displacement of wheels and then a computer system calculates the slippage index. What if an artificial intelligence system could analyze image and videos and return the slippage of an agricultural tractor?

Artificial intelligence is already in place in the Industry, Information Technology, Medicine and other areas of knowledge. It is not different with Agriculture. For instance, artificial vision systems help farmers to understand problems and look for answers. There are some mobile applications which can identify weed just by taking a photo of a leaf. There is also a similar app for insect identification (BASF, 2018; HINDY, 2019).

Some research has been done on yield measurement of different crops like apples, avocados and cherry tomatoes (RAHNEMOONFAR; SHEPPARD, 2017; YUAN et al., 2020; VASCONEZ et al., 2020), cotton on commercial fields (TEDESCO-OLIVEIRA et al., 2020) and soybeans (SUN et al., 2019) using deep-learning-based detectors. It is a tough application since the artificial systems have to deal with real world situations such as illumination variation, occlusion cause by leaves and steams, different colors from unripe to ripe and a diversity of shapes and sizes. Despite these complexities, CNNs are flexible to deal with field dynamics.

Measurement of speed and distance is another application of artificial vision systems. It is possible to use deep learning architectures to surveillance of traffic speed (KUMARADHEVAN, 2016; AFIFAH; NASRIN; MUKIT, 2019; SURESH et al., 2016). We are not aware of similar initiative to use computer vision to measure turning wheel displacement and slippage index as a consequence. However, the cited literature provides the fundaments of object counting, recognition e classification that are crucial for us. It is a matter of define our methodology enriched by these important contributions.

2.4 Material and methods

In this section, we explain the concepts behind CNNs architectures and the reason to choose Inception V2 and MobileNet as extractors (Section 2.4.1). We present how database construction was built and detail field work for image acquisition (Section 2.4.2), location of image bounding boxes, criteria for training separation, validation, and testing files (Section 2.4.2.1). Eventually, we determine the proposed algorithms implementation (Section 2.4.3).

2.4.1 Deep meta-architectures for object detection

Currently, CNNs the state-of-the-art method in terms of object detection, counting and classification. The technological progress of software and hardware have been allowed major advances in the deeper networks performance (FUENTES et al., 2017). Hereafter, we deal with three main architectures: Faster Region-Based Convolutional Neural Network (Faster R-CNN) (REN et al., 2017), Single ShotMultibox Detector (SSD) (LIU et al., 2016) and Single ShotMultibox Detector Lite (SSD-Lite) (FAN et al., 2018). These modern architectures will be applied with two different feature extractors: Inception V2 and MobileNet V2 (VASCONEZ et al., 2020; YUAN et al., 2020). Figure 2.1, summarizes these three adopted architectures.

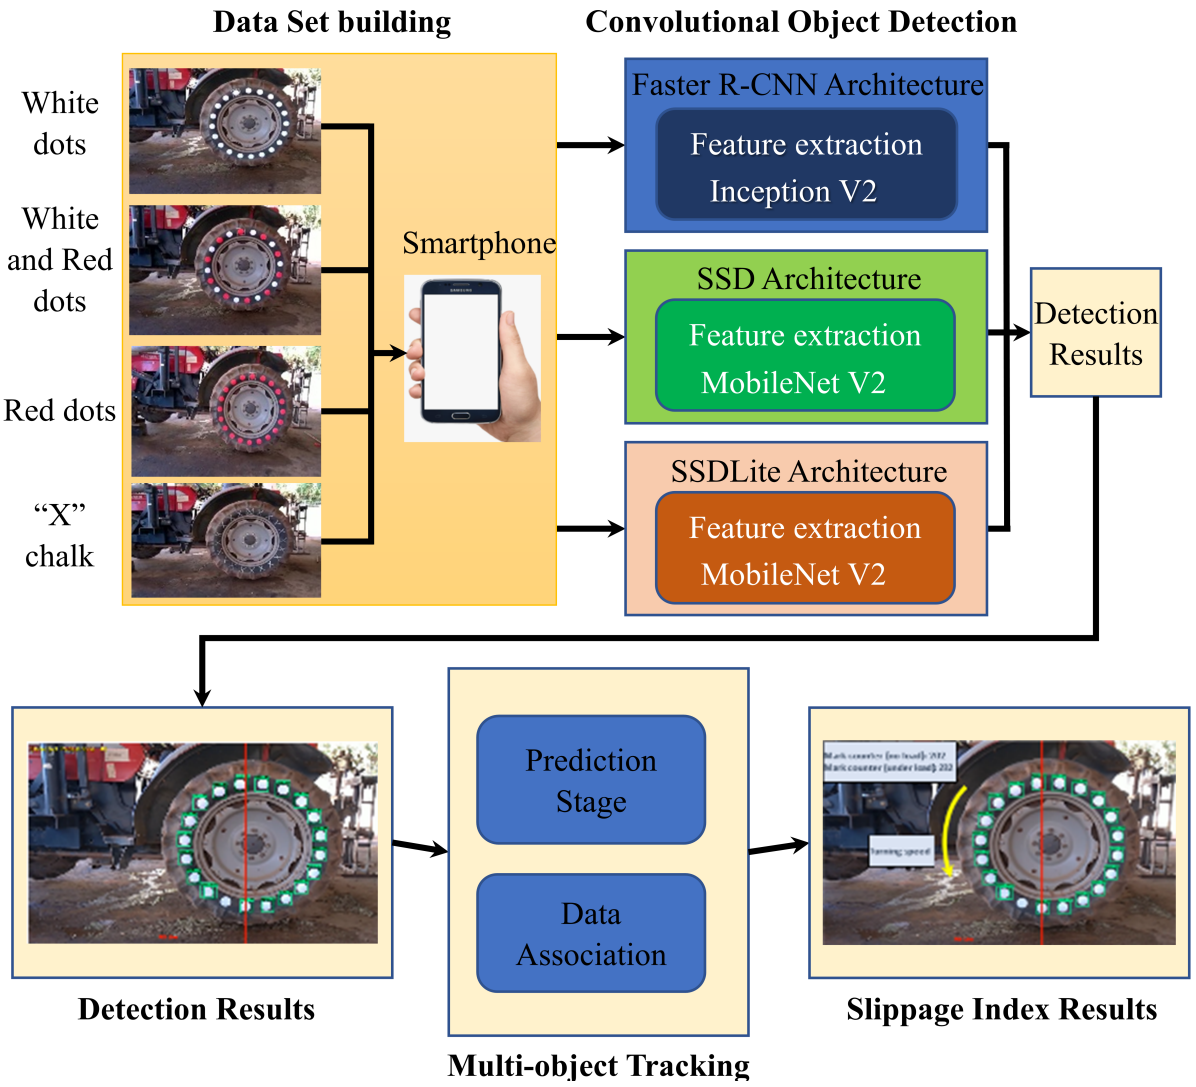


Figura 2.1: General architecture of the evaluated systems in this work. Figure adapted from (VASCONEZ et al., 2020).

2.4.1.1 Faster region-based convolutional neural network (Faster R-CNN)

Faster R-CNN has two modules. The first module is a deep fully convolutional network that proposes regions. The RPN module tells the Fast R-CNN module where to look. The second module the Fast R-CNN detector that uses the proposed regions. The full system is a united network for object detection as shown in Figure 2.2, (VASCONEZ et al., 2020; YUAN et al., 2020). Anchor box is group of predefined bounding boxes of a certain height and width to capture the scale and aspect ratio of object type. Non-maximum Suppression (NMS) is used to filter out redundant prediction boxes (LIU et al., 2016). The advent of Faster R-CNN has promoted applications that deliver high performance on difficult object recognition and classification (FUENTES et al., 2017).

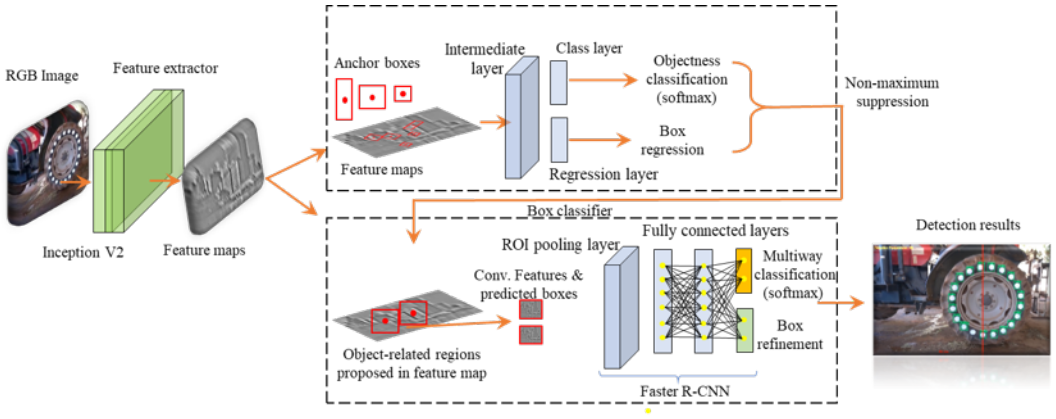


Figura 2.2: Faster R-CNN meta-architecture using Inception V2 as feature extractor. Figure adapted from (VASCONEZ et al., 2020).

2.4.1.2 Single shot detector (SSD)

The SSD meta-architecture adopts a feed-forward convolutional network that creates a fixed-size group of bounding boxes and scores. This network can cope with different size objects and resolutions even from multiple feature maps. Since SSD avoids proposal generation, it is able to save computational time (FUENTES et al., 2017). Figure 2.3, illustrates SSD architecture.

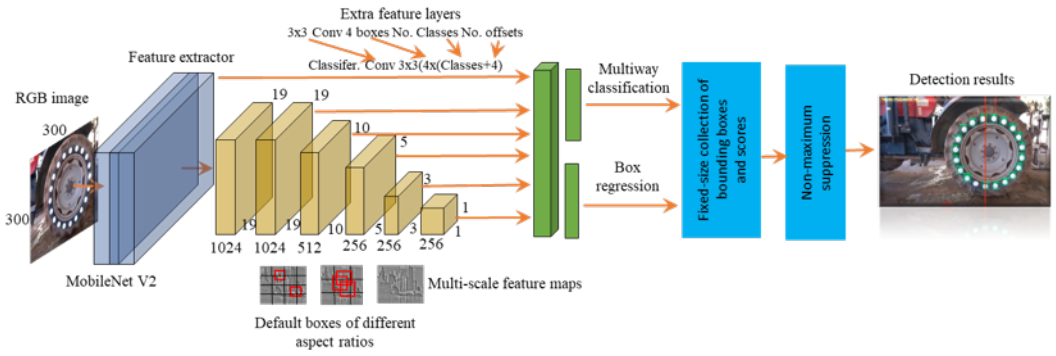


Figura 2.3: SSD meta-architecture using MobileNet V2 as feature extractor. Figure adapted:(MONTEIRO; ARBEX, 2009).

2.4.1.3 Single shot detector lite (SSDLite)

The SSDLite is lighter version of SSD standard. Since it requires lower processing capacity, it is suitable to mobile platforms. In SSD-Lite, regular convolutions in bounding box predictor are substituted by depth-wise convolutions (FAN et al., 2018).

2.4.1.4 Feature extractors

For all meta-architectures, the main part of the system is the “feature extractor”. It purposes to reduce the number of features in a dataset by creating new features from the existing ones and then discarding the original features. Moreover, feature extractors foster accuracy improvements, overfitting risk reduction, speed up in training and improved data visualization (IPPOLITO, 2019). Different feature extractors have been projected to deal with specific attributes, however, all of them aim for accuracy increase and computational simplicity (FUENTES et al., 2017). The extractor MobileNet V2 was chosen because this sort of network offers efficient architecture that can easily adapted to mobile and embedded applications (LU; WENG, 2007). Moreover, MobileNet V2 is a fast architecture. Its performance is the fastest in the current literature (HUANG et al., 2017; VASCONEZ et al., 2020).

Our second extractor is Inception V2 because it performed average precision over 98.8% in some studies (YUAN et al., 2020; HOWARD et al., 2017). However, its processing performance is a little slower compared to MobileNet V2 (HUANG et al., 2017; VASCONEZ et al., 2020).

2.4.2 Database build

Data was collected on 2020, June 25th in the farm workshop in Monte Santo de Minas – Minas Gerais, Brazil (W 46°83′ S 21°16′). All images and movies were taken under stationary conditions. The tractor chosen was a Massey Ferguson model MF 4265 FWD 8x2 compact version for coffee crop. The marks for object detection were done into the left rear tire Malhotra MRT-329 12.4 24 R1. Figure 2.4, show the tractor setup for video shooting. The differential lock was not active.



(a) (b)

Figura 2.4: (a) Tractor was lifted to allow the wheel turning under stationary condition. (b) Tyre sidewall prepared to be marked.

We have chosen 4 configurations of markings. The round ones (dots) were made of contact paper. The ”X”shape was done by yellow chalk. They were evenly distributed on the tire sidewall at end of each tread: 20 white circles diameter 0,065m round format (Figure 2.5 a), alternately distribution of 10 white circles and 10 red circles (Figure 2.5 b), 20 red circles diameter 0,065 m round (Figure 2.5 c), and, 20 “X” marks made of chalk (Figure 2.5 d).



(a) (b) (c) (d)

Figura 2.5: (a) 20 white-doted marks. (b) 10 white-doted and 10 red-doted marks. (c) 10 white-doted and 10 red-doted marks. (c) 20 “X” profile marks. (d) 20 “X” profile marks.

All movies have been shot by a Smart Phone Asus Zenfone 4 ZE554KL with 12 MP camera. The shooting resolution was in high definition 1980x1080 at 60 FPS. Each movie lasted around 30 seconds, the shooting distance was approximately 2.5 m while shooting height was approximately 1.2 m.

2.4.2.1 Data division, image labeling and data augmentation technique

From one video of each marking, 30 random frames were extracted to train purposes (75%) more 10 random frames for validation purposes (25%). Train and Validation images were saved in different folders to prevent mixing them up. As the shooting conditions were static, the pictures were basically the same but with some degree of rotation. The total of 120 train images plus 40 validation images were manually labelled to define the bounding boxes. The free software LabellMg supported us in this task (LIN, 2015). All these images were used in the dataset for Python implementation. In Figure 2.6, it illustrates the treatments carried out in this study: four different markings x three different rated speeds according the the gear engagement sticker x three different CNN architectures. These three different speeds were chosen as they are the closest to the most common speeds on field operations such as ploughing, tillage and planting.

Type of marking	Illustrative image	Wheel turning Speed (km h^{-1})	Architecture + Extractor
White dots		2.6; 6.2; 7.6	Faster RCNN + Inception V2 SSD + MobileNet V2 SSD Lite + MobileNet V2
Red dots		2.6; 6.2; 7.6	Faster RCNN + Inception V2 SSD + MobileNet V2 SSD Lite + MobileNet V2
Alternated With and Red dots		2.6; 6.2; 7.6	Faster RCNN + Inception V2 SSD + MobileNet V2 SSD Lite + MobileNet V2
“X” chalk		2.6; 6.2; 7.6	Faster RCNN + Inception V2 SSD + MobileNet V2 SSD Lite + MobileNet V2

Figura 2.6: Experimental Design – Factorial 4 (illustrative image) x 3 (wheel turning) x 3 (architecture+extractor).

Nominal speed according to tractor manufacturer specification. Speed 1 (gear Low 1) = 2.3 km h^{-1}, Speed 2 (gear Low 3) = 6.2 km h^{-1}, and Speed 3 (gear Low 4) = 7.6 km h^{-1}, @2200 engine speed (AGCO DO BRASIL, 2017). In order to increase image dataset, we adopted data augmentation techniques. They consist in a process of generating new artificial images based on the original dataset. By applying random rotations, mirroring and color distortion to the original images, it was possible to increase the image dataset. Moreover, this image dataset increment prevents excessive adjustments and improve algorithm performance (TAYARA; CHONG, 2018).

2.4.3 Implementation details

We adopt the implementation based on a modified version of the TensorFlow Object Detection API to identify the four different markings in the dataset images. Some additional information regarding detection algorithms are presented in Section 2.4.3.1 The metrics used for performance evaluation are defined in Section 2.4.3.2. All data processing was carried on Google Colaboratory (Colab) cloud computing. It operates under Windows 64 bits. Its hardware is powered by Intel Xeon processor with two cores @2.2 GHz, 13Gb RAM and NVIDIA Tesla K80 with 12 GB RAM (CARNEIRO et al., 2018; Google Colab, 2020).

2.4.3.1 Detection algorithms

As stated in Section 2.4.1, we considered three architectures in our work. The main difference among them is the computation capacity required for object identification and counting. We aimed not only to evaluate their capabilities but also check their suitability to embedded systems. All detection algorithms were pre-trained on the MS-COCO dataset to elaborate these three configurations. Table 2.1 summarizes these three scenarios.

Tabela 2.1: Details of the detection algorithms proposed in each scenario of computational demand. Ex.: Extractor, Res.: Resolution.

Scenario	**Method**	**Algorithm**	**Feature Ex.**	**Input Res.**
High	Two-stage	Faster R-CNN	Inception V2	600 x 1024
Average	One-stage	SSD	MobileNet V2	300 x 300
Low	One-stage	SSDLITE	MobileNet V2	300 x 300

Faster R-CNN usually has high performance in object identification and classification, as it does it in two-stage. However, it demands high computational power. As a result, it is necessary to run this architecture in powerful GPUs. SSD has an average computational demand. In other words, it is an application that can run on intermediate mobile devices such as Smartphones, Raspberry Pi, Jetson Nano and so on. SSD uses feed-forward convolutional network to manage object recognition. It results in fixed-size collection of bounding boxes and scores for presence of an object marking in each bounding box found by the algorithm (TEDESCO-OLIVEIRA et al., 2020). Eventually, SSDLite has low computational demand what allows image processing on low cost mobile devices such as low spec smartphones. For further commercial applications, SSDLite would be the most suitable architecture.

2.4.3.2 Performance evaluation

The results of our research were presented based on the proposed challenge detection metrics for the MS COCO dataset (LIN, 2015), which calculates average recall (AR) and average precision (AP) at different limits of intersection over union (IoU) from 0.50 to 0.95 (@[IoU=0.50:0.95]). The precision score then tells us how the model performed relative to how many object it detected in total (decreases if FP increases) and recall indicates how the model performed relative to the total amount of object it should have recognized (ABDERRAZIK; VAN GEMERT; LENGYEL, 2020).

Precision-Recall curve with values ranging from 0 to 1 was used to evaluate marking detection performance. The higher precision and recall, the better. Precision measures how many of the detected objects are in fact markings and Recall measures algorithm ability in locating markings in images. Therefore,

$$AR = TP/(TP + FN) \tag{2.1}$$

$$AP = TP/(TP + FP) \tag{2.2}$$

Key: TP = true-positive, FP = false-positive, and FN = false-negative. True-positive values represent the overlap between the fundamental truth (notes we made for images in the dataset) and the predicted bounding box (notes identified through the proposed scenarios). False-positive values represent the existence of the fundamental truth not found by the scenarios, while false-negative values represent identifications of objects that do not correspond to the fundamental truth.

The general accuracy of each method was estimated by MAPE. The CNN object counting were compared to the manual counting. Then, it was calculated the mean absolute percentage error (MAPE) (RIBERA et al., 2018):

$$MAPE\ (\%) = \frac{100}{n} \sum_{t=1}^{n} \left| \frac{Cautomated - Cmanual}{Cmanual} \right| \tag{2.3}$$

Key: n is the total number of images, Cautomated is the number of automatically counted objects, and Cmanual is the real number of manually counted objects on the image.

The F1-Score is the harmonic mean of AR and AP as defined in Equation 2.4. It is the metric chosen to evaluate the overall quality of the models.

$$F1 - Score = \frac{2 * Precision * Recall}{Precision + Recall} \tag{2.4}$$

The highest value possible is 1 which is reached only if AP and AR are equal to 1. A F1-Score near zero means that AP and/or AR is/are low.

2.5 Results and discussion

As far as we know, our study is a pioneer to use deep learning for identification and counting applied to slippage index measurement. Therefore, comparison to similar works is limited. As defined before, we evaluated three scenarios based on Faster R-CNN, SSD, and SSDLite that demand, respectively, high, average and low computing capacity for object counting and classification. In Section 2.5.1, we evaluated the performance of the proposed scenarios in detecting and counting markings, including overall training and validation performance. Then, we compared marking detection and counting as well as evaluate MAPE and F1-Scores results in Section 2.5.2.

2.5.1 Overall training performance

In the training stage, the best performance was achieved in the high demand scenario, using the Faster R-CNN algorithm for identification and classification (Table 2.2). Among other factors, this was mainly because single-stage algorithms are simpler than two-stage ones, and require object proposals, including their marking and box coordinates, besides having fewer parameters (LIU et al., 2016).

Tabela 2.2: Comparative results of detection performance in scenarios for training and validation datasets.

Scenario	Algorithm	Average Precision	Average Recall	F1-Score
High	Faster R-CNN	0.72	0.77	0.74
Average	SSD	0.62	0.68	0.65
Low	SSDLite	0.67	0.73	0.70

Table 2.2 shows that in terms of AP and AR, Faster R-CNN architecture has delivered the best results - ideally, the higher AP and AR the better. However, SSDLite and SSD have also performed well. For reference, these figures shown in Table 2.2 are similar to the ones of related studies (TEDESCO-OLIVEIRA et al., 2020; VASCONEZ et al., 2020). As showed in Figure 2.7a, the difference between high and low demand scenarios is insignificant in terms of average precision. Regarding average recall, the low demand scenario delivered almost the same as the high demand one (Figure 2.7b). For mobile application, it is an evidence that SSDLite has been consistent performance while demands low computing capacity.

Regarding F1-Score, Faster R-CNN returned the best results. The results of the three algorithms are compatible with the ones found by other works (ESPINOSA; VELASTIN; BRANCH, 2017; CASADO-GARCÍA; HERAS, 2020). It shows that there is an adequate balance between AP and AR figures. Moreover, even SSD F1-Score (0.65) is higher than the threshold of 0.6 adopted by (LI et al., 2019).

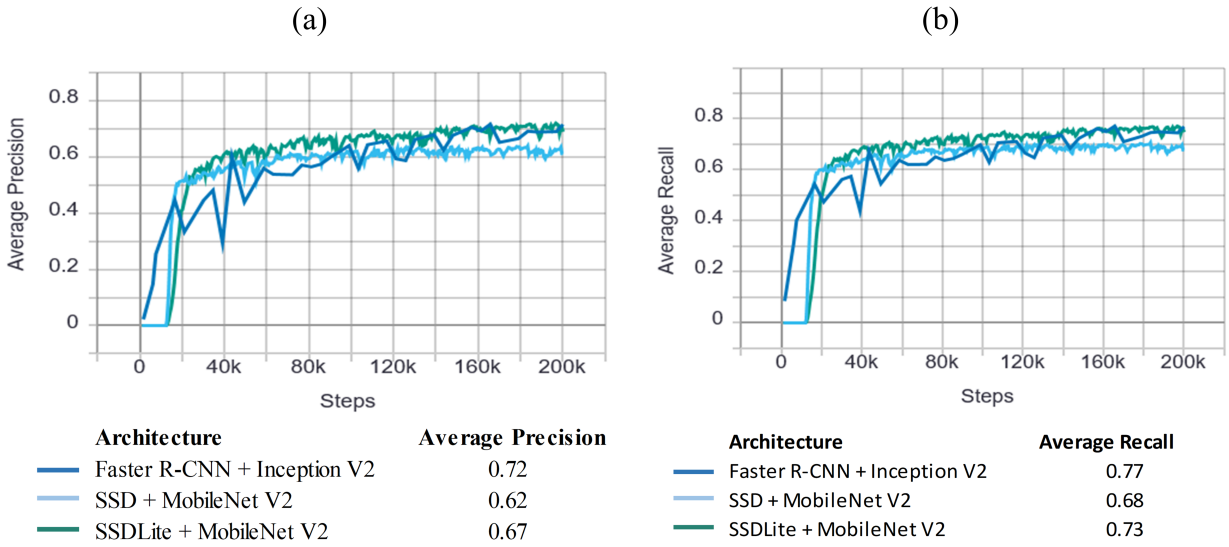


Figura 2.7: (a) AP achieved after 200.000 steps of model training. (b) AR achieved after 200.000 steps of model training.

2.5.2 Manual x automatic counting of tire markings

Three error ranges were adopted as the criteria to classify counting quality: excellent (below 10%), intermediate (11-20%), and unsatisfactory (above 20%) (TEDESCO-OLIVEIRA et al., 2020). To do so, we evaluated the object counting variability. Therefore, we analyzed the differences between manual and automatic counting in all 16 treatments (Table 2.3).

Tabela 2.3: Results summary of the three scenario performances (MAPE).

Marking	Speed (km h^{-1})	Faster RCNN	SSD	SSDLite
White dots	2.3	30.12	18.07	21.69
White dots	6.2	76.82	63.64	69.55
White dots	7.6	81.30	67.56	68.32
"X"Chalk	2.3	1.49	53.73	4.48
"X"Chalk	6.2	67.46	65.55	67.46
"X"Chalk	7.6	73.74	76.98	90.65
White and Red dots	2.3	35.44	12.66	8.86
White and Red dots	6.2	82.44	74.15	68.29
White and Red dots	7.6	71.83	59.13	53.97
Red dots	2.3	2.50	40.00	3.75
Red dots	6.2	68.47	50.25	49.26
Red dots	7.6	58.30	68.73	69.50

In terms of overall MAPE, the SSDLite+MobileNet V2 architecture has delivered the best results (47.98%). Compared to the second best performer Faster RCNN, the MAPE difference was 6.18 pp. According to each architecture overall figures, SSLITE has achieve grade “excellent” for S1 (MAPE 9.69%) and Faster RCNN has hit “intermediate” (MAPE 17.39%). For all other combinations of speed and architectures, the results were classified as unsatisfactory. There are four individual results that need to be highlighted: Faster RNCC – Chalk “X” - S1 (MAPE 1.49%), Faster RNCC – Red dots - S1 (MAPE 2.5%), SSDLite Chalk “X” - S1 (MAPE 4.48%) and SSDLite Red dots - S1 (MAPE 3%). These figures clearly demonstrate the potential of RNC architectures to be applied to slippage tractor index calculation. Moreover, based on the results shown in Table 2.3, we can infer that the white dots not only had a poor performance but also jeopardized the results of alternated “White and Red” treatments.

There’s a hypothesis that the chosen architectures do not have an appropriate sampling rate mainly for speeds S2 and S3. According to Harris Nyquist’s sampling theorem (1929), the sampling rate shall be at least twice as fast as the phenomenon under analysis (LÉVESQUE, 2014). It may answer why three architectures had a poor performance at higher speeds (S2 and S3). For instance, the shooting video of “S3 White” lasts 32 seconds and 262 markings crossed the reference line. It results in 8.19 markings each second. The acquisition system shall cope with, at least, 2 times the event frequency. In other words, the CNN architecture may take at most 61.05 ms (1 second / (8.19 x 2)) to detect and count the object. The same thinking applies to all treatments and these calculations are shown in Table 2.4.

Tabela 2.4: Comparison of Actual Sampling Rate versus Nyquist Theorem. M.C: manual couting, S.R: sampling rate, s: seconds.

Class	Speed	M.C	Video(s)	Actual(S.R)	Nyquist(S.R)	Period(s)
White	V1	83	32	2.6	5.2	0.19
	V2	220	32	6.9	13.8	0.07
	V3	262	32	8.2	16.4	0.06
"X"Chalk	V1	67	30	2.2	4.5	0.22
	V2	209	32	6.5	13.1	0.08
	V3	278	36	7.7	15.4	0.06
White and Red	V1	79	31	2.5	5.1	0.20
	V2	205	31	6.6	13.2	0.08
	V3	252	32	7.9	15.8	0.06
Red	V1	80	31	2.6	5.2	0.19
	V2	203	31	6.5	13.1	0.08
	V3	259	33	7.8	15.7	0.06

To sum up, the higher the turning speed, the faster the RNC shall be to deal with the requested higher sampling rate. Column “Period” is another way to state the same: the faster the speed the less time the system has to do the counting process.

If this hypothesis about the sampling rate is true, it would be possible to reduce the amount of markings in the tire sidewall. By doing so, the CNNs would have extra time to do the recognition and counting process. In our case, it could be reduced, for instance, from 20 to 10 markings. However, it may have a negative impact into the measurement resolution. It is important to say that it is a compromise since the more points in the tire sidewall, the better. Any way, it is an alternative to provide extra time to the deep learning system to do its duties.

Another hypothesis for the poor performance at S2 and S3 speeds is the high resolution of movies and images. The deep learning system may spend too much time to process high input quality dataset. It shall be a subject for further investigation.

2.6 Conclusions and future directions

Our research has shown that CNNs have a high potential for tractor tire slippage measurement. Architecture “Faster R-CNN + Inception V2” combined with “X” chalk had MAPE 1.49% and MAPE 2.5% for red dots. Architecture “SSDLite + MobileNet V2” combined with “X” chalk delivered MAPE 4.48% and MAPE 3.75% for red dots. Although its MAPEs are a little higher, SSDLite + MobileNet V2 has the advantage of being built specially designed for mobile applications that have lower computational capacity. In terms of F1-Score, all three models delivered good quality results as their figures were compatible to similar figures of other studies.

Two out of four different markings have shown promising performance: “X” chalk and red dots. As previously discussed, the white dots not only had a poor performance themselves but also delivered low results when mixed up with white dots.

Further research shall investigate the real impacts of image quality into the computational timing for object detection and counting. Moreover, the sample rate of CNNs shall be also subject of additional investigation as it may be the cause of poor performance at higher speeds.

Although this study has been carried out under still and controlled condition, it have proved that it is worth moving on the development of CNNs to measure not only tractor tire slippage index but also tractor tire advance index.

Regarding the tractor tire advance index, this study presented two configurations that work properly at 2 km h^{-1}, which is the typical value for this sort of evaluation. Next steps shall also consider this index measurement.

The “X” chalk markings have the advantage of being simple and very cost-accessible to be adopted. Moreover, its combination with SSDLite + MobileNet V2 has led to encouraging results while demanding low computational resource. Therefore, this is the chosen scheme to move forward in future research.

2.7 Referências

ABDERRAZIK, H.; VAN GEMERT, J.; LENGYEL, A. **Faster R-CNN as an Application for Object Detection of Scattered LEGO Pieces**. [S.l.], 2020. Disponível em: ⟨https://gitlab.com/lego-⟩.

AFIFAH, F.; NASRIN, S.; MUKIT, A. Vehicle Speed Estimation using Image Processing. **Journal of Advanced Research in Applied Mechanics Journal homepage**, v. 1, n. 1, p. 9–16, 2019. Disponível em: ⟨www.akademiabaru.com/aram.html⟩.

AGCO DO BRASIL. MF 4265 Specs. p. 33–34, 2017.

ASAE. Agricultural Machinery Management - ASAE496.2. **ASAE Standards**, p. 397–372, 2003. Disponível em: ⟨http://www3.abe.iastate.edu/ast330/Project/AESE496.2.pdf⟩.

BASF. **Weed ID App for iPhone**. 2018. Disponível em: ⟨https://www.agricentre.basf.co.uk/en/Services/Mobile-Tools/Weed-ID-app/⟩. Acesso em: 03 set. 2020.

CARNEIRO, T.; Da Nobrega, R. V. M.; NEPOMUCENO, T.; BIAN, G. B.; De Albuquerque, V. H. C.; FILHO, P. P. R. Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications. **IEEE Access**, v. 6, p. 61677–61685, 2018.

CASADO-GARCÍA, Á.; HERAS, J. Ensemble methods for object detection. In: FRONTIERS IN ARTIFICIAL INTELLIGENCE AND APPLICATIONS. 325., 2020. **Anais eletrônicos...**, [s.n.], 2020. p. 2688–2695. ISBN 9781643681009. ISSN 09226389. Disponível em: ⟨https://github.com/ancasag/⟩.

ESPINOSA, J. E.; VELASTIN, S. A.; BRANCH, J. W. Vehicle detection using alex net and faster R-CNN deep learning models: A comparative study. In: LECTURE NOTES IN COMPUTER SCIENCE (INCLUDING SUBSERIES LECTURE NOTES IN ARTIFICIAL INTELLIGENCE AND LECTURE NOTES IN BIOINFORMATICS). 10645 LNCS., 2017. **Anais eletrônicos...**, [s.n.], 2017. p. 3–15. ISBN 9783319700090. ISSN 16113349. Disponível em: ⟨https://doi.org/10.1007/978-3-319-70010-6_1⟩.

FAN, H.; LIU, S.; FERIANC, M.; NG, H.-C.; QUE, Z.; LIU, S.; NIU, X.; LUK, W. A Real-Time Object Detection Accelerator with Compressed SSDLite on FPGA. In: 2018 INTERNATIONAL CONFERENCE ON FIELD-PROGRAMMABLE TECHNOLOGY (FPT). 2018. **Anais eletrônicos...**, IEEE, 2018. p. 14–21. ISBN 978-1-7281-0214-6. Disponível em: ⟨https://ieeexplore.ieee.org/document/8742299/⟩.

FINGER, F. **Avançometro, medidor dos índices de avanço e patinagem em tratores e distncias — Escavador**. 2006. Disponível em: ⟨https://www.escavador.com/patentes/393974/avancometro-medidor-dos-indices-de-avanco-e-patinagem-em-tratores-e-distncias⟩. Acesso em: 13 abr. 2020.

FUENTES, A.; YOON, S.; KIM, S. C.; PARK, D. S. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. **Sensors (Switzerland)**, v. 17, n. 9, 2017.

FURLANI, C. E. **EQUILÍBRIO OPERACIONAL EM TRATORES**. [S.l.], 2014.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. [S.l.], 2017.

Google Colab. **Google Colaboratory**. 2020. Disponível em: ⟨https://colab.research.google.com/notebooks/intro.ipynb⟩. Acesso em: 06 set. 2020.

HINDY, J. **10 best plant apps and flower identification apps for Android!** 2019. Disponível em: ⟨https://www.androidauthority.com/best-plant-apps-flower-identification-apps-android-806167/⟩. Acesso em: 03 set. 2020.

HOWARD, A. G.; ZHU, M.; CHEN, B.; KALENICHENKO, D.; WANG, W.; WEYAND, T.; ANDREETTO, M. **MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications**. [S.l.], 2017.

HUANG, J.; RATHOD, V.; SUN, C.; ZHU, M.; KORATTIKARA, A.; FATHI, A.; FISCHER, I.; WOJNA, Z.; SONG, Y.; GUADARRAMA, S.; MURPHY, K. Speed/accuracy trade-offs for modern convolutional object detectors. In: PROCEEDINGS - 30TH IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, CVPR 2017. 2017-Janua., 2017. **Anais...**, [S.l.: s.n.], 2017. p. 3296–3305. ISBN 9781538604571.

IPPOLITO, P. P. **Feature Extraction Techniques**. 2019. Disponível em: ⟨https://towardsdatascience.com/feature-extraction-techniques-d619b56e31be⟩. Acesso em: 02 set. 2020.

JÚNIOR, D. C. **Desenvolvimento e validação de um sistema embarcado para monitoramento de operações agrícolas com tratores**. 2017. 1–87 p. Tese (Doutorado), 2017.

KUMARADHEVAN, R. R. **Estimation of speed of object using computer vision**. 2016. 44 p. Tese (Doutorado) — California State University, Sacramento, 2016.

LÉVESQUE, L. Nyquist sampling theorem: Understanding the illusion of a spinning wheel captured with a video camera. **Physics Education**, Institute of Physics Publishing, v. 49, n. 6, p. 697–705, nov 2014.

LI, W.; CHEN, P.; WANG, B.; XIE, C. Automatic Localization and Count of Agricultural Crop Pests Based on an Improved Deep Learning Pipeline. **Scientific Reports**, Nature Publishing Group, v. 9, n. 1, dec 2019.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. **Machine learning in agriculture: A review**. 2018. Disponível em: ⟨www.mdpi.com/journal/sensors⟩.

LIN, T. T. **LabelImg is a graphical image annotation tool and label object bounding boxes in images**. 2015. Disponível em: ⟨https://github.com/tzutalin/labelImg⟩. Acesso em: 06 set. 2020.

LIU, W.; ANGUELOV, D.; ERHAN, D.; SZEGEDY, C.; REED, S.; FU, C. Y.; BERG, A. C. SSD: Single shot multibox detector. In: LECTURE NOTES IN COMPUTER SCIENCE (INCLUDING SUBSERIES LECTURE NOTES IN ARTIFICIAL INTELLIGENCE AND LECTURE NOTES IN BIOINFORMATICS). 9905 LNCS., 2016. **Anais eletrônicos...**, [s.n.], 2016. p. 21–37. ISBN 9783319464473. ISSN 16113349. Disponível em: ⟨https://ieeexplore.ieee.org/document/8742299/⟩.

LOURES, F. A. **Campos dos goytacazes – rj agosto de 2004**. 2004. Tese (Doutorado), 2004.

LU, D.; WENG, Q. **A survey of image classification methods and techniques for improving classification performance**. Elsevier B.V., 2007. 823–870 p. Disponível em: ⟨https://doi.org/10.1016/j.procs.2019.08.147⟩.

MONTEIRO, L. d. A.; ARBEX, P. Operação com tratores agrícolas. **Botucatu: Ed. dos Autores**, 2009.

RAHNEMOONFAR, M.; SHEPPARD, C. Deep count: Fruit counting based on deep simulated learning. **Sensors (Switzerland)**, v. 17, n. 4, p. 1–12, 2017.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 39, n. 6, p. 1137–1149, 2017. Disponível em: ⟨https://github.com/⟩.

RIBERA, J.; CHEN, Y.; BOOMSMA, C.; DELP, E. J. Counting plants using deep learning. In: 2017 IEEE GLOBAL CONFERENCE ON SIGNAL AND INFORMATION PROCESSING, GLOBALSIP 2017 - PROCEEDINGS. 2018-Janua., 2018. **Anais eletrônicos...**, Institute of Electrical and Electronics Engineers Inc., 2018. p. 1344–1348. ISBN 9781509059904. Disponível em: ⟨http://ieeexplore.ieee.org/document/8309180/⟩.

SENAR. Operação de tratores agrícolas. **Serviço Nacional de Aprendizagem Rural**, p. 192, 2017.

SILVA, R.; TEDESCO, D.; JUNIOR, A. L.; FILHO, A.; SOUZA, J.; PAIXÃO, C.; VOLTARELLI, M.; ANGELO, E.; OLIVEIRA, J.; CORRÊA, R.; NICOLAU, F.; ANGELIFURLANI, C.; Pereira de Oliveira, L.; ORTIZ, B.; LENA, B.; MORATA, G. **NOVAS TECNOLOGIAS DA ENGENHARIA PARA APROVEITAMENTO DO AMENDOIM**. [S.l.: s.n.], 2019.

STROSKI, P. **O que são redes neurais convolucionais? - Electrical e-Library.com**. 2018. Disponível em: ⟨http://www.electricalelibrary.com/2018/11/20/o-que-sao-redes-neurais-convolucionais/⟩. Acesso em: 13 abr. 2020.

SUN, J.; DI, L.; SUN, Z.; SHEN, Y.; LAI, Z. County-level soybean yield prediction using deep CNN-LSTM model. **Sensors (Switzerland)**, MDPI AG, v. 19, n. 20, p. 4363, oct 2019. Disponível em: ⟨https://www.mdpi.com/1424-8220/19/20/4363⟩.

SURESH, B.; TECH, M.; SARITHA, P.; TRIVENI, K.; SRIHARSHA, K.; LAKSHMI, Y. V.; REDDY, D. S. Determination of Moving Vehicle Speed using Image Processing. 2016. Disponível em: ⟨www.ijert.org⟩.

TAYARA, H.; CHONG, K. T. Object detection in very high-resolution aerial images using one-stage densely connected feature pyramid network. **Sensors (Switzerland)**, MDPI AG, v. 18, n. 10, p. 3341, oct 2018. Disponível em: ⟨http://www.mdpi.com/1424-8220/18/10/3341⟩.

TEDESCO-OLIVEIRA, D.; Pereira da Silva, R.; MALDONADO, W.; ZERBATO, C. Convolutional neural networks in predicting cotton yield from images of commercial fields. **Computers and Electronics in Agriculture**, Elsevier, v. 171, p. 105307, apr 2020. Disponível em: ⟨https://linkinghub.elsevier.com/retrieve/pii/S0168169919319878⟩.

VASCONEZ, J. P.; DELPIANO, J.; VOUGIOUKAS, S.; Auat Cheein, F. Comparison of convolutional neural networks in fruit detection and counting: A comprehensive evaluation. **Computers and Electronics in Agriculture**, Elsevier, v. 173, n. March, p. 105348, 2020. Disponível em: ⟨https://doi.org/10.1016/j.compag.2020.105348⟩.

YUAN, T.; LV, L.; ZHANG, F.; FU, J.; GAO, J.; ZHANG, J.; LI, W.; ZHANG, C.; ZHANG, W. Robust cherry tomatoes detection algorithm in greenhouse scene based on ssd. **Agriculture (Switzerland)**, v. 10, n. 5, 2020.

CAPÍTULO 3 – Redes neurais convolucionais podem ser aplicadas para medir patinagem de um trator agrícola?

3.1 Resumo

Após a prova de conceito realizada conforme o Capítulo 2, iniciou-se a etapa de aplicação em campo. Nesse contexto, técnicas de *Deep Learning* (Aprendizado Profundo) foram empregadas para reconhecer padrões visuais em vídeos e medir indiretamente o deslocamento dos rodados motrizes de um trator com carga e sem carga, pressupondo-se que, de posse dessas informacões, seja possível determinar os índices de patinagem de tratores agrícolas. Diante disso, objetivou-se neste trabalho, verificar a aplicabilidade de redes neurais convolucionais SSDLite e extrator MobileNet V2, à medição do índice de patinagem de tratores agrícolas. Foram realizados testes com dois tratores distintos e três faixas de velocidade nas condições com e sem carga. Os resultados medidos pelo sistema de inteligência artifical foram comparados com o método manual de determinação do índice de patinagem. Os resultados monstraram que as redes convolucionais podem ser aplicadas para identificação e contagem de objetos em uma roda girante de trator. Contudo, o sistema avaliado apresentou níveis de erros insatisfatórios. É necessário aprofundar a pesquisa e superar alguns desafios associados a dinâmica desse processo.
Keywords: agricultura digital, mecanização agrícola, equilíbrio operacional, sustentabilidade, aprendizado profundo, visão computacional.

3.2 Introdução

Os tratores agrícolas são máquinas versáteis que são empregadas em diversas operações, tais como descompactação e preparo de solo, semeadura e plantio, pulverização e colheita (JANULEVIČIUS; JUOSTAS; PUPINIS, 2013). Em função dessa versatilidade, os tratores agrícolas enfrentam condições dinâmicas de carga em função de, por exemplo, velocidade de operação, tipo de implemento, topografia e textura do solo (PITLA et al., 2016).

Para os tratores trabalharem eficientemente, é necessário que eles estejam adequados às operações agrícolas. Isso resulta em economia de combustível e diminuição de emissões de gases poluentes para a atmosfera. Contudo, o ajuste fino das operações no conjunto trator-implemento-solo demanda conhecimento subjetivo e experiência do operador (JANULEVIČIUS; JUOSTAS; PUPINIS, 2013).

O trator agrícola é uma máquina que converte energia química presente no combustível por meio do motor em energia motriz. Por sua vez, essa energia motriz é convertida nos subsistemas da máquina em outras formas de energia tais como elétrica, hidráulica e de tração. A eficiência de conversão de energia de tração um trator é função do desempenho do sistema de tração e sua interação com o solo. A interação pneu-solo depende da cobertura superficial e teor de água do solo, tipo de pneu e pressão de de inflação, velocidade de deslocamento e lastro do trator (SENAR, 2017).

O nível de patinagem do trator é considerado uma perda energética (ASAE, 2003), o que afeta o consumo de combustível do trator. Pode-se diminuir a patinagem dos pneus por meio do lastro adequado, ajuste da pressão de inflação, utilização de pneus de alta flexão, adequação da força de tração e posição dos implementos (STOILOV; KOSTADINOV, 2009).

Assim como a interação entre pneu e solo pode afetar a eficiência de tração de um trator agrícola, a máquina com excesso de lastro também apresenta inconvenientes como, por exemplo, maior consumo horário de combustível, redução da capacidade operacional, maior desgaste mecânico e maior compactação do solo. Por um lado, a correta adequação do lastro pode reduzir em até 15% o consumo de combustível (FURLANI, 2014). Por outro lado, a falta de lastro, ocasiona: maior escorregamento do pneu na lavoura, maior desgaste dos pneus, efeito galope entre outros problemas que comprometem os sistemas mecânicos do trator (FARM ENERGY INNOVATION PROGRAM, 2013).

Entende-se, portanto, que a patinagem é um parâmetro a ser controlado pois ela é uma das formas mais diretas para se avaliar o equilíbrio operacional de um trator agrícola. Ao adequar o TSI a cada operação mitiga-se os efeitos negativos do desbalanceamento. Partindo do pressuposto que técnicas de aprendizado profundo possam ser empregadas para reconhecer padrões visuais e medir indiretamente os índices de patinagem de tratores agrícolas, objetivou-se com este trabalho propor uma nova metodologia e ferramenta de medição do índice de patinagem por meio de redes neurais convolucionais de baixa demanda computacional, bem como comparar os resultados sistema de inteligência artificial com o método manual.

3.3 Material e métodos

O experimento foi realizado na Fazenda de Ensino, Pesquisa e Extensão (FEPE-UNESP/Jaboticabal), no estado de São Paulo, localizada em torno das coordenadas (W 48°17′ S 21°14′), com altitude média de 568 m e declividade média de 3%. O solo da área foi classificado como Latossolo Vermelho Eutroférrico típico, A moderado, textura argilosa e relevo suave ondulado (EMBRAPA SOLOS, 2018). As avaliações foram realizadas no mês de novembro de 2020 com comprimento médio de linha de 100 m e largura de 4 m pertencente às áreas produtivas da fazenda. Milho foi a última cultura colhida antes do experimento.

Utilizou-se dois tratores e um implemento no experimento. O primeiro trator foi um Massey Ferguson modelo MF 660 (Figura 3.1 a) com potência de 110 kW (150 cv) no motor, tração 4x2 TDA acionada, massa total de 8.560 kg, com seleção de velocidade de acordo com as especificações do fabricante. O segundo foi um Valmet 118 (Figura 3.1 b) com potência de 81 kW (110 cv) no motor, tração 4x2 TDA acionada, massa total 7.120 kg, com a seleção de marchas também conforme informação do fabricante. O implemento utilizado em todos os testes com carga foi um subsolador marca Badan modelo AS-DADR de 7 hastes com profundidade de 0,45 m, espaçamento entre hastes de 0,365 m, ponteira sem asa de 0,0762 m, largura de trabalho 2,65 m e massa própria de 1480 kg (Figura 3.1 c).

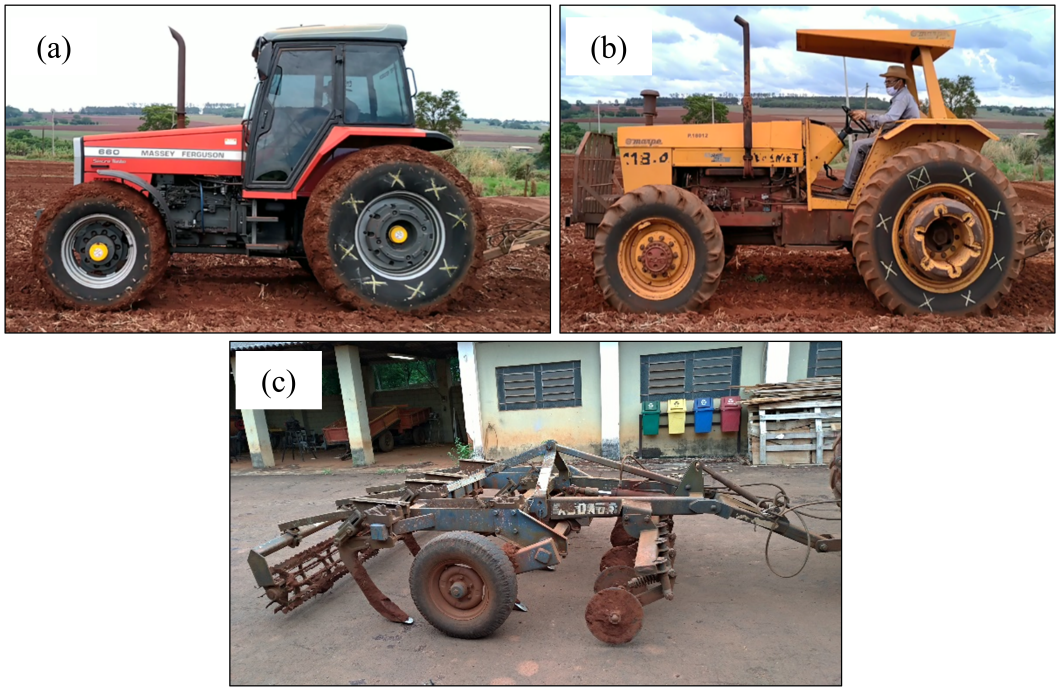


Figura 3.1: Equipamentos utilizados no experimento. (a) Trator MF 660. (b) Trator Valmet 118. (c) Arado subsolador.

Uma única pessoa operou o trator em todas as parcelas. Para os registros em imagem, utilizou-se um smartphone marca Asus ZenFone 4 em resolução HD 1280 x 720 dpi. Utilizou-se a plataforma computacional Google Colab (idêntica a do Capítulo 2) para treinamento das redes convolucionais, geração das métricas de avaliação AP e AR e processamento dos vídeos.

Delimitou-se uma faixa de solo para a realização das parcelas (Figura 3.2), com intervalo compreendido entre 0 a 20 metros para estabilização da velocidade o que foi indicado como “Estab.”. Então iniciou-se a primeira parcela (P1) de 20 metros. Houve um espaço de 5 metros para separação da parcela 2 (P2). Após um segundo espaço de 5 metros (I1 e I2), iniciou-se a última parcela (P3). Ao concluir P3, as filmagens foram encerradas (Figura 3.2). Uma única filmagem foi feita ao longo dos 90 metros. Posteriormente, os vídeos foram fracionados utilizando um editor de vídeo nativo do Windows 10.

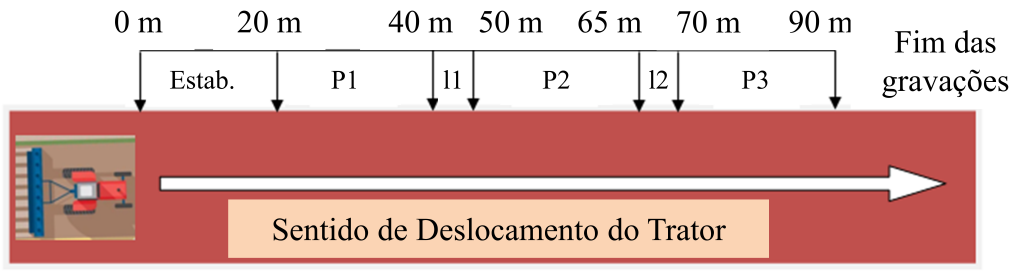


Figura 3.2: Distâncias de estabilização (Estab.), comprimento e espaço entre parcelas. Após o período de estabilização da velocidade de deslocamento, as repetições foram feitas em sequencia. Entre cada parcela foi deixado um espaço de 5 metros (I1 e I2) para melhor identificação do início e término de cada uma.

Na Figura 3.3 tem-se a ilustração da filmagem sendo realizada em campo. Enquanto o trator se deslocava, uma pessoa ia ao lado do trator filmando a operação. O intuito era manter a distância e altura de filmagem o mais estáveis possível, assim como a velocidade relativa entre trator e aparelho celular.



Figura 3.3: Ilustração do processo de filmagem em campo.

As filmagens foram feitas para ambos tratores, pela parte da manhã (das 10:00 às 11:30) e da tarde (14:00 às 15:30) para captar diferentes níveis e ângulos de luminosidade, em três velocidades de deslocamento (2 km h^{-1}, 5 km h^{-1} e 8 km h^{-1}), com e sem implemento em operação. Isso resultou em 24 parcelas, com 3 repetições. Posteriormente, os dados obtidos foram agrupados por velocidade sem fazer distinção entre os tratores e período de realização da leitura.

Na Figura 3.4 encontra-se ilustrado como bandeirolas foram empregadas para identificar os pontos de início e fim das parcelas. Ela também mostra a 8 marcações em giz no formato de “X” defasadas de 45º entre si.



Figura 3.4: Cada ponto esquematicamente apontado na Figura 4 foi demarcado em campo por uma bandeirola (seta amarela) como mostrado nesta figura. As marcações em “X” no pneu traseiro serão os objetos a serem detectados e contados pelo sistema de inteligência artificial (seta laranja).

Como o tamanho da parcela neste experimento é de 20 metros, ao termos a contagem de objetos que passam por uma linha de referência, sabemos indiretamente qual foi o deslocamento linear da roda seja com ou sem carga. Para esse método de cálculo, o índice de patinagem pode ser definido pela Equação 1.2 (ver, Capítulo 1).

Para cada vídeo associado a parcela, foi realizada uma contagem manual em câmera lenta para contar quantos pulsos passaram pela linha de referência. Os valores da contagem manual foram considerados como padrão de comparação. O fluxo de informações e principais etapas desde a entrada (vídeos) até o arquivo executável resultante para reconhecimento e contagem são apresentados na Figura 3.5.

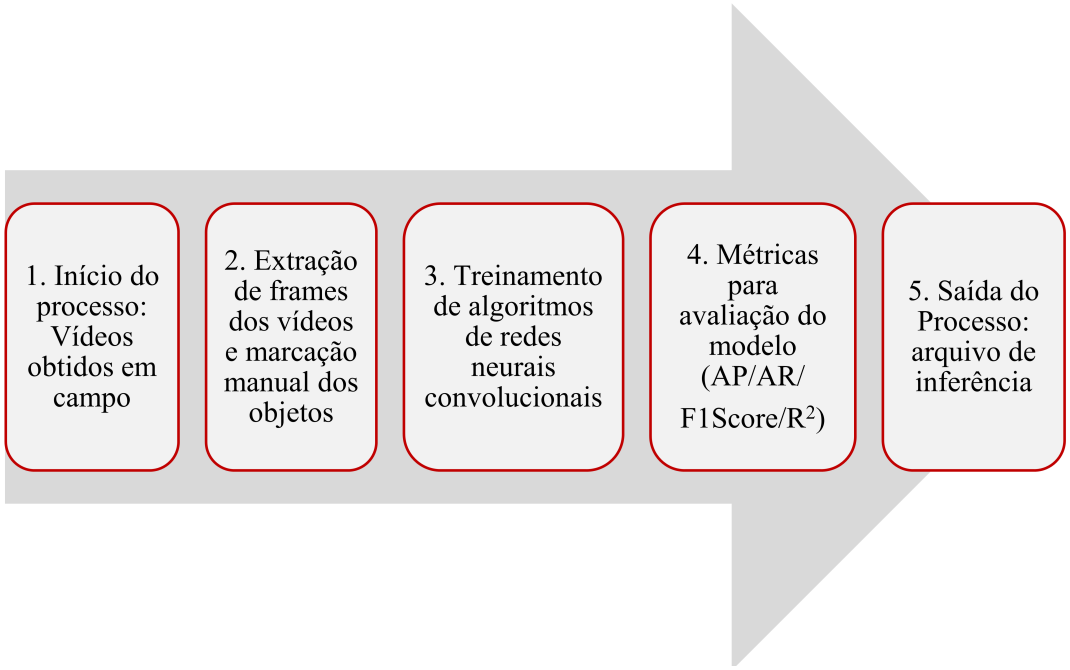


Figura 3.5: Fluxograma das principais etapas para processamento de dados para medição da patinagem em videos.

Cada um dos blocos da Figura 3.5 é descrito a seguir para melhor entendimento:

1. Início do processo - Vídeos obtidos em campo: a gravação dos vídeos em campo registra digitalmente o deslocamento de uma roda traseira do trator. Os vídeos precisam ser feitos nas condições com carga e sem carga para que se possa calcular a diferença entre essas duas condições e consequentemente, o índice de patinagem.

2. Extração de frames dos vídeos: a partir dos vídeos obtidos em campo, pode-se extrair imagens usando software de edição. De posse dessas imagens e com auxílio de software específico, é necessário marcar, manualmente em cada imagem, o contorno dos objetos a serem detectados e contados. Além dos frames obtidos a partir dos vídeos de campo, incluiu-se no banco de dados de treinamento frames de vídeos feitos fora do ambiente de campo e com caligrafia de outras 5 pessoas distintas, de modo a permitir um processo de aprendizado melhor. Neste experimento, o banco de imagens totalizou 737 imagens distribuídas em treinamento (80%) e validação (20%). Na Figura 3.6 tem-se a ilustração de como ficou a imagem após receber as caixas de contorno (*bounding boxes*).



Figura 3.6: Marcação manual dos contornos nas imagens (frames) obtidas a partir dos vídeos feitos em campo. Deve-se buscar o melhor contorno possível para que o objeto a ser detectado seja englobado.

3. Treinamento de algoritmos de redes neurais convolucionais: os frames com as bounding boxes obtidos no passo 2 foram então carregados para a plataforma computacional Google Colab. Por meio da aplicação TensorFlow (domínio público), foi possível acionar a biblioteca API Object Detection para carregar os frames com as marcações de contorno e o algoritmo de rede neural escolhido, respectivo extrator e função de ativação. Neste trabalho foi adotado o algoritmo SDDLite, extrator MobileNet V2 e função de ativação RELU_6 conforme conclusão do Capítulo 2. O algoritmo é, por padrão, pré-treinado no conjunto de dados MS-COCO que é composta por uma série de objetos e padrões comuns. O conteúdo dessa biblioteca serve de base para todas as iterações que ocorrem durante o aprendizado e validação. Assim como feito no Capítulo 2, técnicas de aumento de dados foram incluídas para incrementar as imagens do banco de dados, com a finalidade de evitar o ajustes excessivos e melhorar a capacidade de generalização na etapa de inferência. No final desta etapa, obtem-se o arquivo de infererência (*check-point*).

4. Métricas para avaliação do modelo (AP/AR/F1Score): As métricas AP e AR fazem parte da biblioteca MS-COCO e pode-se obter gráficos de resultados diretamente na plataforma. A função F1-Score precisa ser calculada fora do ambiente TensowFlow. As métricas foram devidamente conceituadas no subitem 2.4.3.2 do Capítulo 2. Para avaliar o quão próximos os valores medidos pelo sistema de inteligência artificial estão da referência, adotou-se o coeficiente de determinação (R^2). Idealmente busca uma relação linear perfeita o que seria representado por $R^2 = 1$ e uma equção do tipo $y = x$. Ou seja, o valor medido pelo sistema de inteligência artificial seria idêntico ao valor de referência.

5. Saída do Processo - arquivo de inferência: Quando se tem o arquivo de inferência, é o momento de aplicá-lo por meio da API Object Counting na Plafaforma Tensorflow para efetivamente contar a quantidade de objetos que cruzam pela linha de referência em cada um dos 72 vídeos gravados em campo. Para que a contagem fosse possível, foi necessário definir uma referência (região de interesse ou ROI). Como a filmagem em campo apresenta oscilações tanto no eixo vertical quanto horizontal, é preciso definir uma linha média que melhor se adeque a cada vídeo. Por meio de uma avaliação visual, verificou-se que a oscilação no eixo horizontal era mais branda que no eixo vertical. Por isso adotou-se a linha na horizontal para os diferentes ROIs. Aplicou-se um fator de velocidade individual a cada vídeo para extração de foram normalizados para 34 segundos. Ou seja, idependentemente do tamanho do vídeo feito em campo, ele foi levado para 34 s. Com isso foi possível extrair 8 frames melhor espaçados para então definir as melhores coordenadas para as linhas ROIs por meio de uma média simples. De posse dessa informação, é possível comparar com o valor adotado como padrão (neste experimento a contagem manual) e saber o quão bem o sistema de inteligência artificial com algoritmos de redes neurais convolucionais desempenhou.

3.4 Resultados e discussão

3.4.1 Treinamento do modelo

A Figura 3.7 a, ilustra a curva da precisão média (mAP) ao longo do aprendizado, enquanto, a Figura 3.7 b, ilustra a curva da revocação média (mAR). Ambas foram obtidas após treinamento com 200.000 passos (*steps*) de aprendizado. Pode-se notar que ambas atingem o nível de estabilidade após a etapa de treinamento conforme esperado. Os valores finais de mAP, mAR e F1-Score são indicados na Tabela 3.1. Embora não se possa fazer uma comparação direta de mAP e mAR com outros estudos, pode-se dizer que que os valores são compatíveis com trabalhos relacionados (TEDESCO-OLIVEIRA et al., 2020; VASCONEZ et al., 2020). O valor obtido para F1-Score foi 0,59 que está na mesma ordem de grandeza do valor limítrofe de 0,6 (LI et al., 2019).

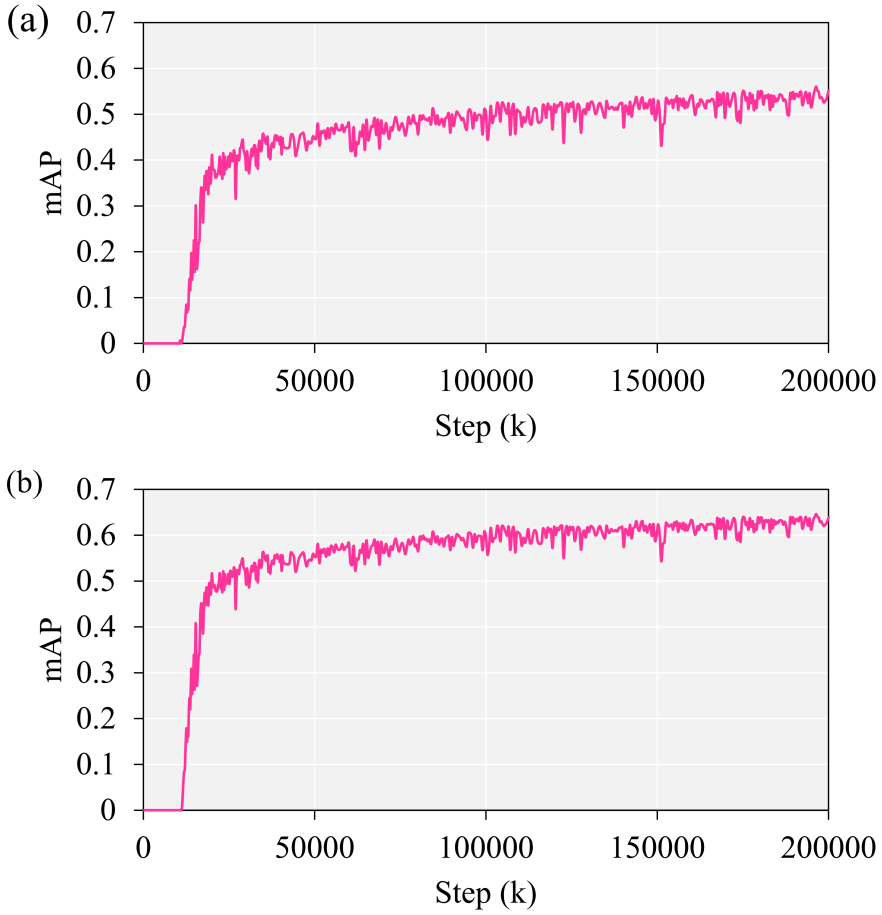


Figura 3.7: Curva da precisão média ao longo do período de aprendizado (a). Curva da revocação média ao longo do período de aprendizado (b).

Tabela 3.1: Resultados de mAP, mAR e F1-Score obtidos após treinamento e validação.

Modelo e Extrator	**mAP**	**mAR**	**F1-Score**
SSDLITE + MobileNet V2	0.55	0.64	0.59

3.4.2 Comparação entre contagem manual e modelo SSDLite

Ao final do treinamento, gerou-se o arquivo de inferência. Baseado nele, processou-se os 72 vídeos feitos em campo e cada vídeo gerou um valor de contagem automatizado. Os resultados foram agrupados por velocidade independentemente do trator e horário do teste. Para medida de comparação, entre a contagem manual e automatizada, foram incluídas: medidas de patinagem de referência e métricas MAPE e R^2 (Tabela 3.2.).

Tabela 3.2: Comparação de resultados entre contagem manual (referência) e modelo SSDLite com extrator MobileNet V2

Avaliações	2 (km h^{-1})	5 (km h^{-1})	8 (km h^{-1})
Contagem manual (Média)	33.4	33.40	33.70
Contagem automatizada (Média)	22.40	21.30	21.30
Patinagem de referência (%)	6.98	5.38	5.85
Patinagem automatizada (%)	-3.30	22.60	28.60
MAPE(%)	34.00	40.10	39.70
R^2	0.21	0.22	0.05

A Figura 8 apresenta a disperção entre os valores de referencia e valor observados pelo método automático. Nota-se nas Figuras 3.8a, 3.8b e 3.8c que existem discrepâncias consideráveis entre o valor de referência e o valor medido pelo algoritmo SSDLite.

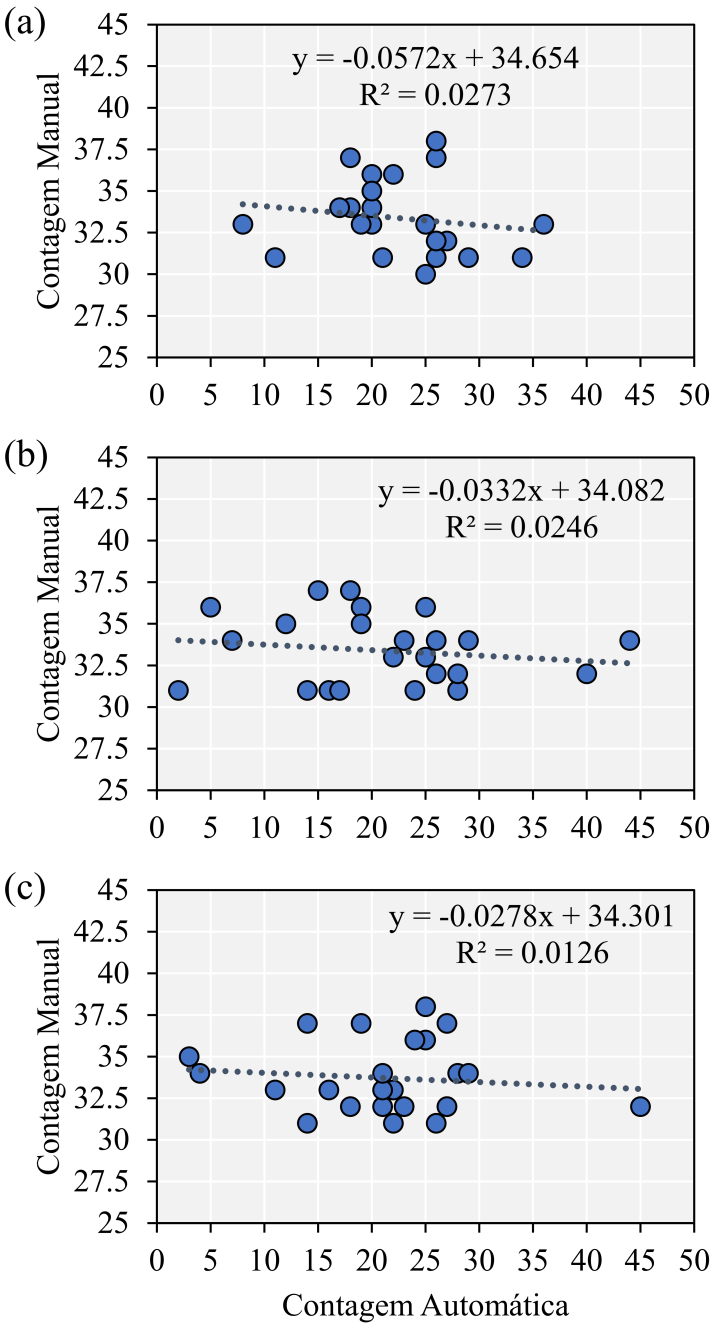


Figura 3.8: Nuvem de pontos gerados pela comparação da contagem manual (referência) com a contagem automatizada na velocidade de 2 km h^{-1} (a), 5 km h^{-1} (b) e 8 km h^{-1} (c). Estão inclusos no gráfico a equação de regressão linear que melhor se ajusta aos pontos e o R^2 associado.

Idealmente, a equação de regressão deveria ser do tipo y = x. No entanto, visualmente observa-se a dispersão acentuada em torno da linha de regressão – o que é representado quantitativamente pelo R^2 distante de 1. Além disso, o MAPE aponta níveis elevados de erro nas leituras. Pelo critério adotado no item 2.5.2, os níveis obtidos foram insatisfatórios por estarem acima de 20%. (MURRAY, 2017) observou que dependendo das condições do teste e taxas de amostragem, o desempenho de algumas métricas foi reduzido de 50 até 90%. Verificou-se neste trabalho que os erros na contagem automatizada foram aumentando conforme a velocidade do trator incrementava, o que resultou em um MAPE de 40,1% na velocidade de 5 km h^{-1}, conforme indicado na Tabela 3.2. Na velocidade de 2 km h^{-1}, obteve-se a melhor medição, o que é evidenciado pela ocorrência de menor MAPE (0.34) e R^2 (0,21). Estudos com sistemas de aquisição baseados em Arduíno também encontraram valores discrepantes entre as leituras de referência e o sistema proposto. Dependendo das condições do tratamento, divergências de até 540% entre o valor real e valor medido (LOURES, 2004). Ao comparar metodos de patinagem, diferenças significativas foram relatadas entre o sistema de aquisição de dados e as medições de referência (JÚNIOR, 2017).

As filmagens realizadas em campo possuem algumas características que afetam a qualidade do vídeo obtido, tais como diferentes níveis de luminosidade, plano de fundo e irregularidade do solo na região onde o filmador se desloca. Conforme a velocidade aumenta, torna-se mais difícil de acompanhar o trator em deslocamento. Nota-se pela Tabela 3.2 que, quanto maior a velocidade de deslocamento do trator, maior o MAPE e menor o R^2. Na velocidade de 8 km h^{-1} é necessário que o filmador desloque-se praticamente correndo. Além de problemas de segurança, pois a pessoa pode tropeçar ou torcer o pé, por exemplo, existe uma flutuação indesejada causada pelo movimento relativo entre o celular e o trator. O processo de contagem dos objetos no vídeo precisa de uma linha de referência definida. Como o vídeo oscila na horizontal e na vertical, a referência flutua, e isso acarreta falsas contagens. Nota-se na Figura 3.9 a dificuldade em posicionar e manter a posição definida com as condições dinâmicas de campo. Uma alternativa para minimizar os efeitos indesejados de uma pessoa se deslocando ao lado do trator seria manter o celular estático. Ou seja, defini-se um campo de visão e então filma-se o trator em deslocamento. Essa possibilidade precisa ser explorada em campo para saber se o ângulo da câmera conseguirá cobrir uma distância suficiente para a medição da patinagem.

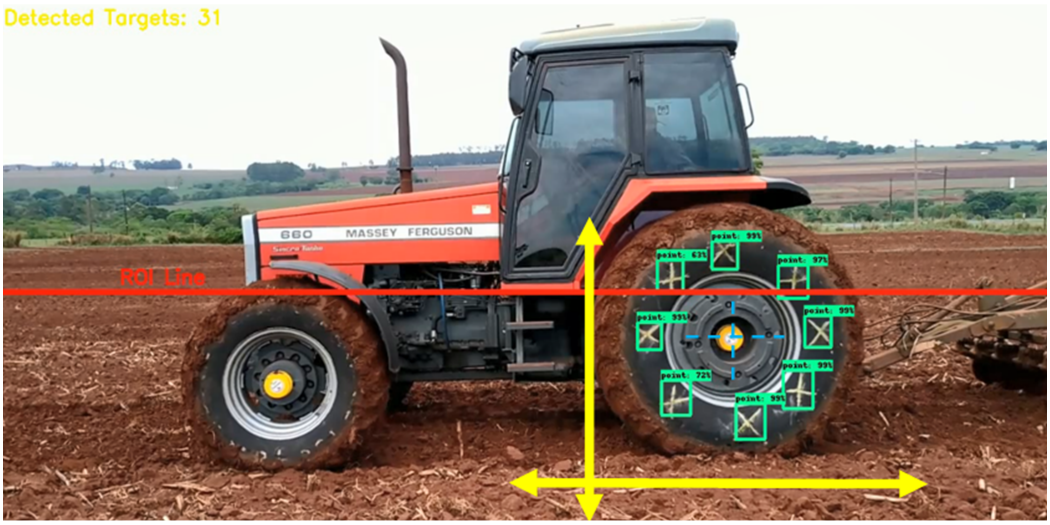


Figura 3.9: Durante o processo de filmagem, é difícil estabilizar e manter a velocidade relativa entre o filmador e o trator especialmente em velocidades acima de 2 km h^{-1}. A linha "ROI" é a referência adotada no arquivo de inferência para medir os objetos que cruzam por ela. Como existe oscilação, é possível que um mesmo ponto seja contado mais de uma vez ou não seja contado. Isso traz erros para a medição.

Diversas avaliações foram feitas ao longo do tratamento, processamento e análise dos dados. Os primeiros resultados apontaram MAPEs da ordem de 75%. Então, embora fora do escopo inicial, outros dois modelos de redes neurais foram treinados para verficar se eles responderiam melhor à aplicação de campo. O banco de imagens para treinamento e validação também foi incrementado de 386 para 737 imagens. Outro ponto considerado foi a normalização da velocidade dos vídeos. Como é necessário identificar e contar o objeto no momento que ele cruza pela referência, também tentou-se reduzir a velocidade dos vídeos, mas os resultados não foram promissores. A melhor configuração foi obtida ao normalizar os vídeos para 34 s (duração mais longa de uma das parcelas em campo), para então extrair oito frames para definição dos ROIs de cada um dos 72 vídeos. Outro ponto que observou-se em outros trabalhos é que a detecção e contagem de objetos geralmente acontece em movimentos unidirecionais conforme Figura 3.10.

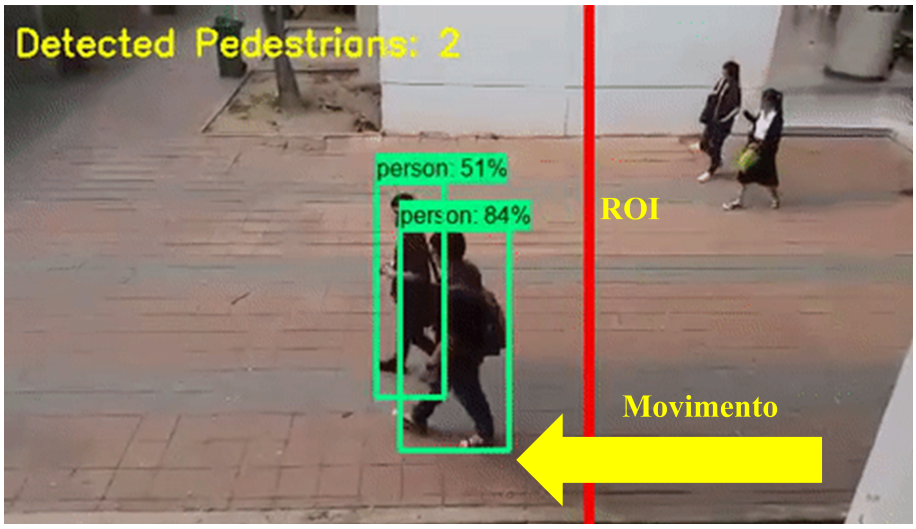


Figura 3.10: Tipicamente as detecções e contagens ocorrem com movimentos unidirecionais. Fonte: Adaptado de (OZLU, 2021)

Neste trabalho o modelo RNC foi aplicado para identificar objetos em movimento circular para então contá-los ao cruzar por uma referência com movimento relativo ao vídeo como mostrado na Figura 3.11.



Figura 3.11: Na aplicação em campo, as detecções e contagens precisam ocorrer em movimentos acontecendo em duas direções.

Como houve significativa dispersão entre os valores de referência e os contados pelo modelo SSD, avaliou-se a possibilidade de expurgar eventuais pontos discrepantes (*outliers*) da avaliação.

Pelo critério de Chauvenet apenas um único ponto seria descartado, optou-se por não eliminá-lo, pois o impacto seria ínfimo. (NI et al., 2019) obtiveram 99,63% de acurácia ao aplicar o critério de Chauvenet na análise de pulsos. Contudo, trata-se de uma aplicação com uma população em torno de 10.000 pontos. (LIMB et al., 2017) também concluiram que o critério de Chauvenet possui limitações quando a população é reduzida. Mesmo em situações com populações acima de 100.000 pontos, as estimativas melhorariam no máximo 50%.

Adotou-se nesse estudo, também, algumas sugestões provenientes da prova de conceito (Capítulo 2), tais como reduzir o número de objetos “X” marcados em giz de 20 para 8. Também reduziu-se a resolução dos vídeos para não sobrecarregar o processamento do algoritmo SSDLite. Contudo, essas medidas não se mostraram suficientes ao ponto de reduzir os erros de contagem ao nível satisfatório.

Pensando em pesquisas futuras, seria necessário a adoção de dispositivos e meios para cancelar essa flutuação indesejada durante a filmagem em campo. Poderia ser adaptado um suporte fixado no trator para segurar o celular ao estilo “pau de selfie”. Também existem outros dispositivos estabilizadores e câmeras dotadas de sistema antivibração. Outra alternativa seria a edição do vídeo de forma a manter apenas a roda em movimento e eliminar todo o restante do ambiente.

Seria conveniente prolongar a pesquisa em outras condições de velocidade, ambiente, tamanhos de tratores para compreender melhor a relação existente entre o sistema de detecção e contagem automatizado e a contagem manual ou com instrumentos. Ao entender melhor a relação guardada entre eles, seria possível ajustar os erros, por exemplo, por uma equação linear ou exponencial. Uma vez que essa relação seja claramente identificada, é possível corrigir os erros matematicamente e assim melhorar a leitura de saída.

3.5 Conclusão

De maneira geral, nota-se que existe potencial para aplicação de redes neurais convolucionais para medição do índice de patinagem. Contudo, a comparação dos valores de referência com os valores indicados pelo sistema de inteligência artificial indica que é necessário superar alguns obstáculos principalmente no que tange a técnicas de programação, determinação do algoritmo mais adequado à aplicação e recursos de estabilização de imagem. O incremento de velocidade resulta em erros crescentes. É necessário investigar formas de contornar essa característica do sistema testado. Os níveis de erros encontrados nesse trabalho estão acima do aceitável. Faz-se necessário aprofundar a pesquisa em busca de meios que permitam uma melhor contagem dos objetos em movimento.

Esse trabalho é um passo importante da pesquisa em direção a construção de um nova metodologia e ferramenta para medição do índice de patinagem por meio de redes neurais convolucionais. Entretanto, é necessário aprofundar a pesquisa para tornar o sistema mais confiável e preciso.

3.6 Referências

ASAE. Agricultural Machinery Management - ASAE496.2. **ASAE Standards**, p. 397–372, 2003. Disponível em: ⟨http://www3.abe.iastate.edu/ast330/Project/AESE496.2.pdf⟩.

EMBRAPA SOLOS. **Sistema brasileiro de classificação de solos**. [s.n.], 2018. 353 p. ISBN 978-85-7035-198-2. Disponível em: ⟨https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1094003/sistema-brasileiro-de-classificacao-de-solos⟩.

FARM ENERGY INNOVATION PROGRAM. Tractor ballasting. **Farm Energy Innovation Program**, p. 1–5, 2013. Disponível em: ⟨https://www.aginnovators.org.au/sites/default/files/EfficientFarmVehicles-Tractorballasting.pdf⟩.

FURLANI, C. E. **EQUILÍBRIO OPERACIONAL EM TRATORES**. [S.l.], 2014.

JANULEVIČIUS, A.; JUOSTAS, A.; PUPINIS, G. Engine performance during tractor operational period. **Energy Conversion and Management**, v. 68, p. 11–19, 2013.

JÚNIOR, D. C. **Desenvolvimento e validação de um sistema embarcado para monitoramento de operações agrícolas com tratores**. 2017. 1–87 p. Tese (Doutorado), 2017.

LI, W.; CHEN, P.; WANG, B.; XIE, C. Automatic Localization and Count of Agricultural Crop Pests Based on an Improved Deep Learning Pipeline. **Scientific Reports**, Nature Publishing Group, v. 9, n. 1, dec 2019.

LIMB, B. J.; WORK, D. G.; HODSON, J.; SMITH, B. L. The Inefficacy of Chauvenet's Criterion for Elimination of Data Points. **Journal of Fluids Engineering**, American Society of Mechanical Engineers Digital Collection, v. 139, n. 5, 2017.

LOURES, F. A. **Campos dos goytacazes – rj agosto de 2004**. 2004. Tese (Doutorado), 2004.

MURRAY, S. **Real-Time Multiple Object Tracking A Study on the Importance of Speed**. 2017.

NI, W.; QI, J.; LIU, L.; LI, S. A Pulse Signal Preprocessing Method Based on the Chauvenet Criterion. **Computational and mathematical methods in medicine**, Hindawi, v. 2019, 2019.

OZLU. **TensorFlow Object Counting API**. 2021.

PITLA, S. K.; LUCK, J. D.; WERNER, J.; LIN, N.; SHEARER, S. A. In-field fuel use and load states of agricultural field machinery. **Computers and Electronics in Agriculture**, Elsevier B.V., v. 121, p. 290–300, 2016. Disponível em: ⟨http://dx.doi.org/10.1016/j.compag.2015.12.023⟩.

SENAR. Operação de tratores agrícolas. **Serviço Nacional de Aprendizagem Rural**, p. 192, 2017.

STOILOV, S.; KOSTADINOV, G. D. Effect of weight distribution on the slip efficiency of a four-wheel-drive skidder. **Biosystems Engineering**, IAgrE, v. 104, n. 4, p. 486–492, 2009. Disponível em: ⟨http://dx.doi.org/10.1016/j.biosystemseng.2009.08.011⟩.

TEDESCO-OLIVEIRA, D.; Pereira da Silva, R.; MALDONADO, W.; ZERBATO, C. Convolutional neural networks in predicting cotton yield from images of commercial fields. **Computers and Electronics in Agriculture**, Elsevier, v. 171, p. 105307, apr 2020. Disponível em: ⟨https://linkinghub.elsevier.com/retrieve/pii/S0168169919319878⟩.

VASCONEZ, J. P.; DELPIANO, J.; VOUGIOUKAS, S.; Auat Cheein, F. Comparison of convolutional neural networks in fruit detection and counting: A comprehensive evaluation. **Computers and Electronics in Agriculture**, Elsevier, v. 173, n. March, p. 105348, 2020. Disponível em: ⟨https://doi.org/10.1016/j.compag.2020.105348⟩.

CAPÍTULO 4 – Considerações finais

A utlização de inteligência artificial em processos e operações agrícolas está em voga. Máquinas programadas são capazes de perceber padrões que passariam despercebido aos olhos humanos. Mais do que isso, os sistemas de inteligência artificial possuem elevadas velocidades de processamento mesmo lidando com grandes quantidades de dados. Essas características podem revolucionar a forma que a Agricultura será conduzida no futuro.

As redes neurais convolucionais já são aplicadas em operações agrícolas voltadas a contagem e reconhecimento desde o plantio/semeadura, tratos culturais e colheita. Contudo, neste trabalho enfrentamos dificuldades de aplicação de algoritmos RNC em aplicação em vídeos. A verificação em vídeos é um passo importante na direção de medir em tempo real um determinado fenômeno.'

Ao longo desse trabalho, identificou-se que o modelo SSD-Lite com extrator MobileNet V2 foi o mais adequado para aplicação proposta. Os resultados da prova de conceito (Capítulo 2) apontam que o melhor tipo de marcação é feita no formato de X com giz comum.

Embora os resultados propriamente ditos tenham apresentado diferenças frente aos números de referência, este trabalho conseguiu mostrar que as redes neurais convolucionais apresentam potencial para serem aplicadas a medição de patinagem de tratores agrícolas.

Em suma, este trabalho atingiu os objetivos ao aplicar redes neurais convolucionais a detecção e contagem de objetos em movimento e consequentemente, medição de patinagem em campo. Neste momento, os resultados apontam que é necessário aprofundar a pesquisa e superar alguns desafios associados a dinâmica desse processo.