

RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo desta dissertação será disponibilizado somente a partir de 18/06/2023.

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

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

Rafael Rodrigues Feih
Engenheiro Eletricista

**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)

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.

CERTIFICADO DE APROVAÇÃO

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


AUTOR: RAFAEL RODRIGUES FEIH

ORIENTADOR: ROVERSON PEREIRA DA SILVA


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



Prof. Dr. ROVERSON PEREIRA DA SILVA (Participação Virtual)
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal



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



Prof. Dr. MARCELO JOSE DA SILVA (Participação 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 memoriam) pela educação, oportunidades e construção do meu caráter. Ao meu Orientador por todo o conhecimento transmitido e confiança. E por último, mas não menos importante, 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 <i>Equilíbrio operacional e patinagem</i>	5
1.2.2 <i>Machine learning e redes neurais convolucionais</i>	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 <i>Deep meta-architectures for object detection</i>	21
2.4.1.1 <i>Faster region-based convolutional neural network (Faster R-CNN)</i>	22
2.4.1.2 <i>Single shot detector (SSD)</i>	23
2.4.1.3 <i>Single shot detector lite (SSDLite)</i>	23
2.4.1.4 <i>Feature extractors</i>	24
2.4.2 <i>Database build</i>	24
2.4.2.1 <i>Data division, image labeling and data augmentation technique</i>	25
2.4.3 <i>Implementation details</i>	27
2.4.3.1 <i>Detection algorithms</i>	27
2.4.3.2 <i>Performance evaluation</i>	28
2.5 Results and discussion	30
2.5.1 <i>Overall training performance</i>	30
2.5.2 <i>Manual x automatic counting of tire markings</i>	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	<i>Treinamento do modelo</i>	48
3.4.2	<i>Comparação entre contagem manual e modelo SSDLite</i>	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 SLIPPAGE 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 counting, 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 5×5 para uma matriz 3×3 . (b) Ilustração do filtro sendo aplicado nos elementos A_{ij} 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 3×3 . 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 círculos 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 órgãos 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 calibrações; 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 suscetíveis 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 acurácia 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 agrônômicos 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 dígitos numéricos 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 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. 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 operações. 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.

1.3 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 Management. 1996.

CLAPPIS, A. **Uma introdução as redes neurais convolucionais utilizando o Keras**. 2019. Disponível em: <https://medium.com/data-hackers/uma-introducao-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 distâncias — Escavador**. 2006. Disponível em: <https://www.escavador.com/patentes/393974/avancometro-medidor-dos-indices-de-avanco-e-patinagem-em-tratores-e-distancias>. Acesso em: 13 abr. 2020.

FRANCETTO, T. **Relação peso/potência dos tratores — Engenharia Agrícola**. 2012. Disponível em: <https://tiago francetto.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/aplicações-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 Agrícola**, 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.electricalibrary.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 4 – Considerações finais

A utilização 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.