

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

**UM SISTEMA INTELIGENTE QUE PREVÊ A  
PRODUTIVIDADE DO ALGODÃO EM IMAGENS DE  
LAVOURAS COMERCIAIS**

**Danilo Tedesco de Oliveira**  
**Tecnólogo em Mecanização em Agricultura de Precisão**

**2019**

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP**

**CÂMPUS DE JABOTICABAL**

**UM SISTEMA INTELIGENTE QUE PREVÊ A  
PRODUTIVIDADE DO ALGODÃO EM IMAGENS DE  
LAVOURAS COMERCIAIS**

**Discente: Danilo Tedesco de Oliveira**

**Orientador: Prof. Dr. Rouverson Pereira da Silva**

**Co-orientadores: Prof. Dr. Walter Maldonado Jr.**

**Prof. Dr. Cristiano Zerbato**

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias – UNESP, Campus de Jaboticabal, como parte das exigências para obtenção do título de Mestre em Agronomia (Ciência do Solo)

**2019**

Oliveira, Danilo Tedesco de  
O48s Um sistema inteligente que prevê a produtividade do algodão em  
imagens de lavouras comerciais / Danilo Tedesco de Oliveira. --  
Jaboticabal, 2019  
56 f. : tabs., fotos

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp),  
Faculdade de Ciências Agrárias e Veterinárias, 2019  
Orientador: Rouverson Pereira da Silva  
Co-orientador: Walter Maldonado Junior

1. Agricultura Digital. 2. Visão Computacional. 3. Engenharia  
Agrícola. 4. Deep Learning I. Título.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal




**CERTIFICADO DE APROVAÇÃO**

TÍTULO DA DISSERTAÇÃO: UM SISTEMA INTELIGENTE QUE PREVÊ A PRODUTIVIDADE DO ALGODÃO EM IMAGENS DE LAVOURAS COMERCIAIS

**AUTOR: DANILO TEDESCO DE OLIVEIRA**  
**ORIENTADOR: ROVERSON PEREIRA DA SILVA**  
**COORIENTADOR: CRISTIANO ZERBATO**  
**COORIENTADOR: WALTER MALDONADO JUNIOR**

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

  
Prof. Dr. ROVERSON PEREIRA DA SILVA  
Departamento de Engenharia Rural / FCAV / UNESP - Jaboticabal

  
Pós-Doutorando GUILHERME MARTINELI SANCHES  
Departamento de Solos-ESALQ/USP / Piracicaba/SP

  
Prof. Dr. GLÁUCO DE SOUZA ROLIM  
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal

Jaboticabal, 01 de março de 2019

## **DADOS CURRICULARES DO AUTOR**

**DANILO TEDESCO DE OLIVEIRA**, filho de Lourival Bruno de Oliveira e Roseli Martins Tedesco de Oliveira, nasceu em Tupã no dia 11 de junho de 1995, município localizado no interior do Estado de São Paulo. cursou ensino fundamental e médio no município de Quintana – SP, no período entre 2002 a 2012. Durante o ensino médio cursou Técnico em Mecânica no SENAI “Shunji Nishimura” concluindo no ano de 2013. Em 2014 iniciou o curso de graduação em Tecnologia em Mecanização em Agricultura de Precisão na FATEC “Shunji Nishimura”. Durante o curso foi membro do Grupo de Estudos de Colheita Mecanizada - GECOM, onde realizou trabalhos e pesquisas em campo relacionadas a qualidade de operações agrícolas de semeadura e colheita mecanizada. Obteve o título de Tecnólogo em Mecanização em Agricultura de Precisão no ano de 2017. No mesmo ano ingressou no Programa de Pós-graduação em Agronomia (Ciência do Solo) na Universidade Estadual Paulista “Júlio de Mesquita Filho” Faculdade de Ciências Agrárias e Veterinárias Campus Jaboticabal – UNESP/FCAV, sob a orientação do Prof. Dr. Rouverson Pereira da Silva, participando de projetos relacionados a sistemas mecanizados de colheitas, agricultura de precisão, sensoriamento remoto e uso de inteligência artificial para monitoramento da qualidade em operações agrícolas. Em julho de 2017 organizou e ministrou o primeiro curso de QGIS aplicado para Agricultura de Precisão do Laboratório de Máquinas e Mecanização Agrícola - LAMMA.

*“Nada te perturbe, nada te espante, tudo passa! Deus não muda. A paciência, tudo alcança. Quem a Deus tem, nada lhe falta, pois só Deus basta”.*

**Santa Tereza D’Ávila**

Aos meus pais Lourival Bruno de Oliveira e Roseli Martins Tedesco de Oliveira e avós João Tedesco e Isabel Martins Tedesco.

A vocês,

**DEDICO!**

Aos meus irmãos Luana Tedesco de Oliveira e Vinicius Martins Tedesco, amigos Amanda Zagatti, Lucas Zagatti, Taina Valderramas, Leandro Augusto e Gabriel Sakuno.

**OFEREÇO!**

## **AGRADECIMENTOS**

Em primeiro lugar agradeço a Deus e Nossa Senhora Aparecida pela minha vida, família, amigos e por sempre me conceder sabedoria nas escolhas dos melhores caminhos, coragem para acreditar, força para não desistir e proteção para me amparar. Aos meus Pais Lourival Bruno de Oliveira e Roseli Martins Tedesco de Oliveira, meus Avós João Tedesco e Isabel Martins Tedesco e meus Irmãos Luana Tedesco de Oliveira e Vinicius Martins Tedesco por sempre estarem comigo.

A Fundação Shunji Nishimura de Tecnologia pela formação profissional (Curso Técnico em Mecânica - SENAI e Graduação em Tecnologia Mecanização em Agricultura de Precisão - FATEC) e pessoal, principalmente por todos valores adquiridos. Ao Prof. Mestre Edson Massao Tanaka pelo conhecimento adquirido no Grupo de Estudos de Colheita Mecanizada – GECOM, fundamental para ingressar em um curso de Pós-graduação.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Ciência do Solo). O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Aos membros do Grupo de Oração Universitário G.U.O da UNESP/FCAV. A comunidade da Paróquia de Santa Teresa do Menino Jesus e Mãe Rainha de Jaboticabal-SP, em especial à Regina Aparecida Faccini Leite e ao Padre Adilson Vieira.

A meu orientador Prof. Dr. Rouverson Pereira da Silva, que tenho grande admiração e consideração pelo seu trabalho. Por sua confiança e pela oportunidade de poder trabalhar com algo novo. Aos meus Co-orientadores Prof. Dr. Walter Maldonado Jr. e Prof. Dr. Cristiano Zerbato, por colaborar com o desenvolvimento desse trabalho.



Aos integrantes e parceiros do Laboratório de Máquinas e Mecanização Agrícola – LAMMA, em especial ao Mailson Freire de Oliveira e Rafael de Graaf Correa. Também ao estagiário Vinicius Trevisan pelo auxílio na execução de projetos e cursos. Estendo os agradecimentos a todos Professores e Funcionários do Departamento de Engenharia Rural.

Aos amigos da República Xicreti - 1992, Fabricio Faleiros de Castro (Totó), Cicero Antônio Mariano dos Santos (Zero-boi), Felipe Bardella do Carmo (Safadão), Vitor Bardella do Carmo (Frajelu), Rafael de Graaf Correa (Boka), Luís Angel Chicoma Rojas (Peruano), por poder fazer parte dessa família de republicas tradicionais da UNESP de Jaboticabal e a nossa “mãe” Izabel Cristina Giangrego de Oliveira (BeL) pela paciência e por cuidar de nós e de nossa república a 24 anos.

A todos aqueles que estiveram presentes nesta inesquecível fase de minha vida, compartilhando todos os momentos, bons ou ruins, mas que foram essenciais para minha formação acadêmica e pessoal.

A vocês, meu muito obrigado.

## SUMÁRIO

LISTA DE FIGURAS .....	i
LISTA DE TABELAS .....	ii
RESUMO .....	iii
ABSTRACT .....	iv
CAPÍTULO 1 – CONSIDERAÇÕES GERAIS .....	1
1. Introdução.....	1
1.1 Revisão de Literatura .....	2
1.1.1 Algodão e colheita mecanizada .....	2
1.1.2 Perdas na colheita do algodão.....	2
1.2 Visão Computacional.....	4
1.3 Inteligência artificial .....	5
1.3.1 Aprendizado de máquina .....	6
1.4 Redes Convolucionais.....	7
1.4.1 Redes neurais convolucionais de região mais rápidas .....	9
1.4.2 Detectores de disparo único SSD e SSDLITE .....	10
1.5 REFERÊNCIAS.....	12
CAPÍTULO 2 – SISTEMA INTELIGENTE PARA PREVISÃO DA PRODUTIVIDADE DE ALGODÃO EM IMAGENS DE LAVOURAS COMERCIAIS.....	16
2.1 Introdução .....	16
2.2 Trabalhos relacionados.....	18
2.3 Material e Métodos.....	19
2.3.1 Construindo o banco de dados.....	19
2.3.2 Divisão de dados e rotulagem de imagens.....	20
2.3.3 Detalhes da implementação .....	22
2.3.3.1 Algoritmos de detecção.....	22

2.3.3.2 Técnica de aumento de dados .....	23
2.3.3.3 Avaliação do desempenho .....	24
2.4 Resultados .....	25
2.4.1 Desempenho geral de treinamento .....	25
2.4.2 Teste em função dos modelos e horários de aquisição de imagens	27
2.4.2 Contagem de capulhos real x automática .....	29
2.4.2 Previsão da produtividade por imagem .....	34
2.5 Discussão e trabalhos futuros .....	35
2.6 Conclusões .....	36
2.7 Referências .....	37
CAPÍTULO 3 – CONSIDERAÇÕES FINAIS .....	41

---

## LISTA DE FIGURAS

<b>FIGURA 1.</b> EXEMPLO DE ESTRUTURA DE REDE NEURAL CONVOLUCIONAL .....	8
<b>FIGURA 2.</b> ESTRUTURA DA REDE NEURAL CONVOLUCIONAL DE REGIÃO MAIS RÁPIDA. ....	9
<b>FIGURA 3.</b> ESTRUTURA BÁSICA DA REDE SINGLE SHOT DETECTOR .....	11
<b>FIGURA 4.</b> EXEMPLO DOS EFEITOS DAS CONDIÇÕES AMBIENTAIS EM DIFERENTES HORÁRIOS DE AQUISIÇÃO DE IMAGENS. ....	17
<b>FIGURA 5.</b> COMPARAÇÃO DA ÁREA SOB AS CURVAS DE RECUPERAÇÃO E PRECISÃO COM DIFERENTES MODELOS PARA O CONJUNTO DE TREINAMENTO. ....	27
<b>FIGURA 6.</b> RESULTADOS DE RECUPERAÇÃO (A) E PRECISÃO (B) MÉDIA DOS MODELOS PROPOSTOS PARA O CONJUNTO DE DADOS DE TESTE EM FUNÇÃO DOS HORÁRIOS DE AQUISIÇÃO DE IMAGENS. ....	28
<b>FIGURA 7.</b> COMPARAÇÃO DOS RESULTADOS DA CONTAGEM DE CAPULHOS COM DIFERENTES MODELOS PARA O CONJUNTO DE DADOS DE TESTE EM FUNÇÃO DOS HORÁRIOS DE AQUISIÇÃO DE IMAGEM. A.M.: HORÁRIOS DO PERÍODO DA MANHÃ, P.M.: HORÁRIOS DO PERÍODO DA TARDE. ....	30
<b>FIGURA 8.</b> EXEMPLO DO DESEMPENHO DE CONTAGEM PARA DIFERENTES CONDIÇÕES AMBIENTAIS DAS IMAGENS PARA O CONJUNTO DE DADOS DE TESTE (A) NO INÍCIO DA MANHÃ 08:00 A.M. E (B) AO ENTARDECER 06:00 P.M.....	32
<b>FIGURA 9.</b> EXEMPLO DE IMAGENS APÓS A REALIZAÇÃO DAS CONTAGENS COM MARCAÇÕES DE CAIXAS DELIMITADORAS EM DIFERENTES CONDIÇÕES AMBIENTAIS DO CONJUNTO DE DADOS DE TESTE, (A) NO INÍCIO DA MANHÃ 08:00 A.M. E (B) AO ENTARDECER 06:00 P.M. .	33
<b>FIGURA 10.</b> REGRESSÃO LINEAR ENTRE A PRODUTIVIDADE OBSERVADA E ESTIMADA. O RESULTADO APRESENTADO É BASEADO NA PREVISÃO DE PRODUTIVIDADE POR MEIO DA CONTAGEM REALIZADA PELO MODELO SSD MOBILENET V1 PARA TODAS IMAGENS DO CONJUNTO DE DADOS DE TESTE. ....	35

---

## LISTA DE TABELAS

<b>TABELA 1.</b> CLASSIFICAÇÃO DO TIPO DE PERDAS DURANTE A OPERAÇÃO DE COLHEITA MECANIZADA DE ALGODÃO. ....	3
<b>TABELA 2.</b> EXEMPLOS DE ANOTAÇÕES COM CAIXAS RETANGULARES E DIVISÃO DOS ARQUIVOS DE TREINAMENTO, VALIDAÇÃO E TESTE PARA CONFECÇÃO DO BANCO DE DADOS EM FUNÇÃO DAS CONDIÇÕES AMBIENTAIS.....	21
<b>TABELA 3.</b> DETALHES DOS MODELOS PROPOSTOS, INCLUINDO OS MÉTODOS PARA DETECÇÃO EM UM E DOIS ESTÁGIOS, EXTRATORES DE RECURSOS, BATH SIZE E RESOLUÇÃO DAS IMAGENS DE ENTRADA. ....	23
<b>TABELA 4.</b> EXEMPLO DO USO TÉCNICA DE AUMENTO DE DADOS. PRIMEIRA COLUNA REPRESENTA A IMAGEM DE ENTRADA ENQUANTO A SEGUNDA, TERCEIRA, QUARTA E QUINTA REPRESENTAM IMAGENS DE SAÍDA.....	24
<b>TABELA 5.</b> RESULTADOS COMPARATIVOS DO DESEMPENHO DA DETECÇÃO EM DIFERENTES MODELOS PARA O CONJUNTO DE DADOS DE TREINAMENTO E VALIDAÇÃO.....	26

---

## **UM SISTEMA INTELIGENTE QUE PREVÊ A PRODUTIVIDADE DO ALGODÃO EM IMAGENS DE LAVOURAS COMERCIAIS**

### **RESUMO**

Uma maneira de melhorar a qualidade da operação de colheita mecanizada do algodão é alterar as configurações e regulagens de colhedora ao longo do processo de acordo com informações que podem ser adquiridas durante a própria colheita. Acreditamos que a previsão da produtividade pode se tornar uma informação de grande importância no gerenciamento da qualidade da operação, visando ao aumento da eficiência e redução das perdas no processo. Portanto, nessa pesquisa apresentamos o desenvolvimento de um sistema inteligente capaz de prever a produtividade do algodão em imagens coloridas, adquiridas por um dispositivo mobile simples. Propomos uma abordagem robusta às condições ambientais, treinando algoritmos de detecção com imagens adquiridas em diferentes horários ao longo do dia. Os resultados experimentais para o modelo SSD Mobilenet V1 indicaram que é possível realizar a contagem dos capulhos presentes nas imagens adquiridas em diferentes horários ao longo do dia, com erros médios de 8.84% (~5 capulhos). Além disso, avaliando a previsão da produtividade em 205 imagens do conjunto de dados de teste, o erro foi igual à 17.86%. Esse valor representa variações de até 19.14 gramas entre cada previsão.

**PALAVRAS-CHAVE:** Aprendizagem de máquina; Detecção de objetos; Previsão de produtividade; Tendências para colheita inteligente.

## **AN INTELLIGENT SYSTEM THAT FORECASTING THE COTTON YIELD IN COMMERCIAL FIELDS IMAGES**

### **ABSTRACT**

One way to improve the quality of the mechanized cotton harvesting operation is to change settings and adjustments of the harvester throughout the process according to information acquired during the operation. We believe that yield prediction can become important information in managing the quality of the operation aiming at increasing efficiency and reducing losses in the process. Therefore, we present in this research the development of an intelligent system capable of predicting cotton yield from color images acquired by a simple mobile device. We propose a robust approach to environmental conditions, training detection algorithms with images acquired at different times throughout the day. The experimental results for the SSD MobileNet V1 model indicated the possibility of counting bolls present in the images acquired at different times throughout the day, with mean errors of 8.84% (~5 bolls). Also, the error was equal to 17.86% when evaluating yield prediction on 205 images from the test dataset. This value represents variations of up to 19.14 grams between each prediction.

**KEYWORDS:** Machine learning; Object detection; Yield forecasting; Trends for smart harvesting.

---

## **CAPÍTULO 1 – CONSIDERAÇÕES GERAIS**

### **1. Introdução**

A cultura do algodão é produzida em grandes áreas, exigindo grande investimento para a sua implantação e condução. No processo de colheita o produtor aguarda o retorno de todos os investimentos realizados. Contudo, a colheita do algodão é complexa e possui alto valor agregado, e se não for realizada com qualidade, perdas podem ocorrer, reduzindo a lucratividade.

A ocorrência de perdas está diretamente relacionada à variabilidade das condições do ambiente (e.g. estande de plantas, altura da planta, regulagens da colhedora, mão-de-obra, tratos culturais, umidade das plumas e principalmente a produtividade) durante a operação de colheita mecanizada (CM) Mas, no entanto, é um dos fatores mais difíceis de se ter uma visualização espacial antes da colheita mecanizada.

Sendo assim, surge a necessidade de se monitorar esses fatores, para estabelecer melhores condições para operação da CM. No entanto, para realizar esse monitoramento antes da CM, é necessária uma rigorosa coleta de dados em campo, inviabilizando sua aplicação em grandes áreas, devido à falta de mão de obra e tempo disponível para sua realização.

Acreditamos, que por meio da visualização espacial das condições ambientais de uma lavoura algodoeira anteriormente à realização da CM, futuramente melhores decisões poderão ser tomadas para aumentar a eficiência e reduzir as perdas na operação de CM. Atualmente não existem sistemas para monitoramento das condições da lavoura algodoeira previamente à CM.

Com base, nesse contexto aqui apresentaremos o desenvolvimento de um sistema capaz de prever a produtividade da cultura do algodão em imagens adquiridas em campos comerciais. Nossa abordagem é robusta e adaptável ao ambiente de produção, uma vez que as imagens que utilizamos para confecção do banco de dados foram adquiridas em diversas condições do ambiente ao longo do período do dia.



---

## **1.1 Revisão de Literatura**

### **1.1.1 Algodão e colheita mecanizada**

No Brasil o cultivo do algodão é realizado por produtores que utilizam os melhores pacotes tecnológicos desde a implantação da cultura até o processo colheita mecanizada. Na classificação mundial o País é o quinto maior produtor com área cultivada de 1.174,70 milhões de hectares e produtividade média em pluma de 1.708,00 kg há<sup>-1</sup> na safra 17/18 (CONAB, 2018).

O processo de colheita de cultura do algodão é complexo, pois, necessita de mão-de-obra qualificada, possui alto valor agregado e deve ser realizado com eficácia total para obter o retorno de todos investimentos. No entanto, em muitos casos não se obtém maiores retornos por falta de condições adequadas para realização da colheita (SILVA; FERREIRA; CASSIA, 2011).

Fatores que estão relacionados as condições do ambiente durante a operação de colheita influenciam diretamente a ocorrência das perdas e.g. o estande de plantas, altura da planta, tratamentos culturais, regulagens da colhedora e qualidade da mão-de-obra que se não forem levados em consideração podem reduzir a lucratividade.

### **1.1.2 Perdas na colheita do algodão**

Em todo processo de colheita mecanizada é normal a ocorrência de perdas. Portanto, é recomendável monitorar a operação de colheita de modo que seja possível realizá-la com máximo de eficiência. As perdas observadas durante a operação de colheita de algodão podem ser classificadas como qualitativas e quantitativas (KAZAMA et al., 2016). Alguns exemplos são demonstrados na Tabela 1.

**Tabela 1.** Classificação do tipo de perdas durante a operação de colheita mecanizada de algodão.

<b>Perdas Qualitativas</b>	<b>Perdas Quantitativas</b>
Maturidade da fibra	Plumas presente no solo antes da operação*
Excesso de umidade	Plumas presente no solo após operação
Redução da resistência da fibra	Plumas presente na planta após a operação
Variação no comprimento	
Redução da elasticidade	
Alteração na coloração da fibra	

\*perdas naturais.

Estudos relatam a ocorrência de perdas durante a operação de colheita e o limite máximo considerável é de 10% (VIEIRA; CUNHA; ZÓFOLI, 2001). No entanto, valores de até 20% são encontrados (BENNETT et al., 2015; KAZAMA et al., 2018; KAZAMA; FERREIRA, 2015; SILVA; FERREIRA; CASSIA, 2011; VIOTTO et al., 2018; ZHANG et al., 2013). Além disso, existe uma grande variabilidade dos valores de perdas que são encontrados.

A maioria das causas de acréscimo na porcentagem das perdas durante a operação estão relacionadas diretamente com regulagens inadequadas e velocidade de operação. Grande parte desses estudos verificaram que apenas com a utilização de regulagens adequadas da colhedora e operações realizadas por operadores capacitados podem reduzir as perdas durante a operação.

De acordo com (KAZAMA, 2016) uma maneira de melhorar a qualidade da operação da colheita de algodão seria tornar as regulagens da colhedora variáveis ao longo do processo com base em informações adquiridas através de sensores por meio da leitura da planta, com isso se aproveitaria o máximo do rendimento da lavoura com mínimo de perdas.

No entanto, para que isso seja realizado necessitamos de um banco de dados com informações de qualidade que possibilite o desenvolvimento de um sistema inteligente que possa ser embarcado na colhedora capaz de adquirir informações e analisá-las em tempo real.

---

Neste trabalho propomos uma forma para minimizar as perdas que é o desenvolvimento de um sistema inteligente através do uso de tecnologias de visão computacional e inteligência artificial.

## 1.2 Visão Computacional

A visão computacional é uma área de estudo que visa desenvolver sistemas computacionais inteligentes semelhantes a visão humana capaz de extrair informações de imagens digitais e vídeos através do processamento de dados em computadores (SZELISKI, 2010). Ela compreende métodos e técnicas através dos quais os sistemas de visão artificiais podem ser construídos e empregados de maneira razoável e aplicações práticas (PATRÍCIO; RIEDER, 2018).

Essa tecnologia pode ser utilizada em aplicações para monitoramento da qualidade de processos industriais (HUANG; PAN, 2015; SCHLÜTER et al., 2018), na área da saúde no auxílio para o diagnóstico de doenças em imagens (KERMANY et al., 2018), na setor automobilístico no desenvolvimento de veículos autônomos, capazes de identificar pedestres, sinais e placas de transito (IBADOV et al., 2017; LEIBE et al., 2008; YEE YONG; CHEE HAU; HIEW MOI, 2019), e recentemente, vem sendo, largamente empregada na agricultura moderna, principalmente para extração de informações de imagens, através do desenvolvimento de algoritmos e aplicativos para a identificação de pragas e doenças em grandes culturas como: soja (SHRIVASTAVA; SINGH; HOODA, 2017) e trigo (LIU et al., 2016a). Existem quatro áreas de conhecimento relacionadas ao desenvolvimento de sistemas de visão computacional, sendo elas classificadas:

- I. **Reconhecimento:** que estuda o desenvolvimento e aplicação de algoritmos para detecção, identificação e classificação de objetos em uma imagem.
- II. **Análise de movimento:** que realiza o rastreamento de objetos e calcula a velocidade de deslocamento em relação imagem adquirida por uma câmera.
- III. **Reconstrução 3D:** baseado em imagens objetos físicos adquiridas em diversas posições e ângulos de câmeras, são gerados modelos tridimensionais por meio de algoritmos de reconstrução e modelagem.

---

IV. **Restauração de imagens:** visa melhorar a qualidade de imagens digitais reduzindo fontes de ruídos por meio de filtros adaptativos e através do uso de técnicas de processamento avançando de padrões.

Neste trabalho a área de estudo que abordamos é a do reconhecimento, que tem por objetivo principal a identificação de padrões com finalidade de extrair informações de regiões específicas em imagens digitais. Recentemente, os algoritmos de reconhecimento mais eficientes e utilizados para realizar essa operação são as redes neurais convolucionais, que é um subcampo da área de estudos de inteligência artificial.

### 1.3 Inteligência artificial

A inteligência humana pode ser compreendida como a capacidade de um indivíduo em aprender com a experiência, adaptando-se, entendendo e utilizando o conhecimento adquirido para tomada de decisões em diversas situações. Um campo de estudo que tem por objetivo o desenvolvimento de sistemas capazes de simular e desempenhar funções humanas é a Inteligência Artificial (IA) (RUSSELL; NORVIG, 1995).

A inteligência artificial (IA) é um termo que, em seu sentido mais amplo, indica a capacidade de um computador de realizar o mesmo tipo de funções que caracterizam o pensamento humano (MELLIT; KALOGIROU, 2008). O termo AI também tem sido aplicado a sistemas de computador e programas capazes de executar tarefas mais complexas do que a programação direta, embora ainda longe do domínio do pensamento real (MELLIT; KALOGIROU, 2008).

De acordo com (BARR; FEIGENBAUM, 1981) IA é uma área da ciência da computação preocupada com o desenvolvimento de projetos de sistemas computacionais inteligentes, capazes de reproduzir características básicas associadas à inteligência humana como:

- I. **Capacidade de raciocínio:** aplicar regras lógicas (deduzir, induzir, gerar hipóteses e inferir) em um conjunto de dados para extrair informações e obter conclusão.

- 
- II. **Aprendizagem:** aprender por meio dos erros e acertos alcançados, para melhorar resultados futuros.
  - III. **Reconhecer padrões:** visualizar informações de um conjunto de dados para detectar e classificar informações e objetos, com base em textura e padrões de comportamento.
  - IV. **Inferência:** capacidade de aplicar o conhecimento em condições adversas às utilizadas para adquirir o conhecimento, capacidade de generalizar as informações.

Num futuro próximo, as máquinas agrícolas poderão adotar sistemas inteligentes para monitoramento da qualidade da operação e auxílio para tomada de decisões. No caso específico de máquinas para colheita mecanizada, esses sistemas permitirão que a máquina consiga identificar se existe a ocorrência de perdas durante a operação, para que dessa maneira, automaticamente tome melhores decisões visando o aumento da qualidade e eficiência da operação.

### 1.3.1 Aprendizado de máquina

Um subcampo de estudo da inteligência artificial que estuda o desenvolvimento de algoritmos, que tem a capacidade de aprender com informações de um banco de dados, encontrando caminhos para solucionar problemas (KOHAVI, 1995).

Aprendizagem de máquina estuda o desenvolvimento de métodos computacionais para adquirir conhecimentos, habilidades e também métodos para organizar o conhecimento adquirido automaticamente (GÉRON, 2017), ou seja, são desenvolvidos algoritmos que possibilitem que o computador aprenda sem ser programado, permitindo análise de grandes números de dados com rapidez e precisão. Podemos classificar os algoritmos de aprendizado com base no princípio de aprendizado que são divididos em três métodos de aprendizagem: supervisionado, não-supervisionado e aprendizado por reforço. Portanto,

- I. **Aprendizado supervisionado:** é um sistema de aprendizado que é treinado sob supervisão, aprendendo por um professor, que tem por objetivo em alimentar o computador com informações de entrada

---

desejada (baseadas em regras e detalhes) e as informações de saída desejada.

- II. **Aprendizado não supervisionado:** diferente do aprendizado supervisionado, esse método não possui professor para ensinar o computador, ou seja, o treinamento é realizado com objetivo de automaticamente projetar ou encontrar padrões no banco de dados.
- III. **Aprendizado por reforço:** esse método é bastante diferente dos princípios de aprendizagem acima mencionados. Nesse método o computador aprende com base em sua experiência de acordo com as informações do banco de dados, na etapa de treinamento ele busca encontrar padrões por meio da tentativa e erro e assim busca concluir sua tarefa, esse processo é contínuo até que o computador receba máxima recompensa (menor erro) e conclua a tarefa.

Um dos principais fatores na popularização do uso de aprendizado de máquina foi o uso em larga escala de GPUs ( Graphic Processing Units ). Esse tipo de hardware especializado, inicialmente desenvolvido para atender as necessidades de renderização dos jogos digitais (melhorar o desempenho e jogabilidade), evoluiu para expandir seu uso de forma genérica em diversas áreas, como indústria, saúde, clima, modelagem computacional (PATRÍCIO; RIEDER, 2018).

Eles possuem enorme capacidade de realizar processamento paralelo devido à presença da grande quantidade e núcleos de processadores. Assim, eles podem oferecer desempenho muito superior quando comparados com as CPUs (Central Process Unit), dependendo do tipo de processo. Além disso, o advento da linguagem de programação CUDA e a inclusão de hardware dedicado para facilitar a programação paralela desses processadores, permitem os desenvolvedores a construir novas aplicações (PATRÍCIO; RIEDER, 2018).

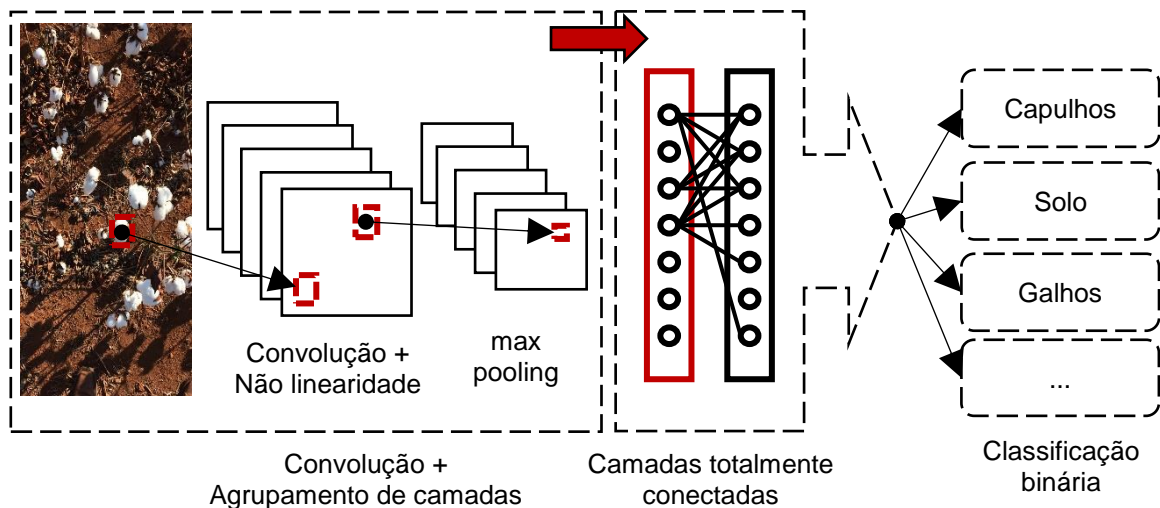
#### **1.4 Redes Convolucionais**

A Rede Neural Convolucional (CNN) é uma técnica de aprendizado profundo para processamento de imagem muito eficaz na classificação e identificação de padrões em imagens. A (CNN) foi proposta pela primeira vez pelo professor Yann LeCun e seus colegas da Universidade de Toronto, no Canadá (LECUN et al., 1998).

A CNN aproveita os conceitos de campos receptivos, compartilhamento de peso e subamostragem para reduzir a complexidade da estrutura da rede e o número de parâmetros (REN et al., 2017).

Portanto, embora existam poucas aplicações de CNN para agricultura em escala comercial, estudos recentemente começaram a ser realizados utilizando desta técnica, para criar algoritmos para colheita robótica e identificação de frutos com precisão e acurácia (JIDONG et al., 2016; SA et al., 2016; SILWAL et al., 2017). As Redes Neurais Convolucionais (CNN's) são um tipo de rede neural artificial que consiste em múltiplas camadas também conhecidas como neurônios. As CNN's são projetadas para o reconhecimento de padrões em imagens atuando diretamente nos pixels sem a necessidade de um pré-processamento.

Uma estrutura moderna de (CNN) consiste em um grande número de estruturas, contendo camadas convolucionais e subamostradas seguidas por uma ou mais camadas totalmente conectadas (HUTTUNEN, 2018; RODRIGUES, 2018). Um exemplo da estrutura de um modelo de rede neural convolucional é apresentado na Figura 1.



**Figura 1.** Exemplo de estrutura de rede neural convolucional

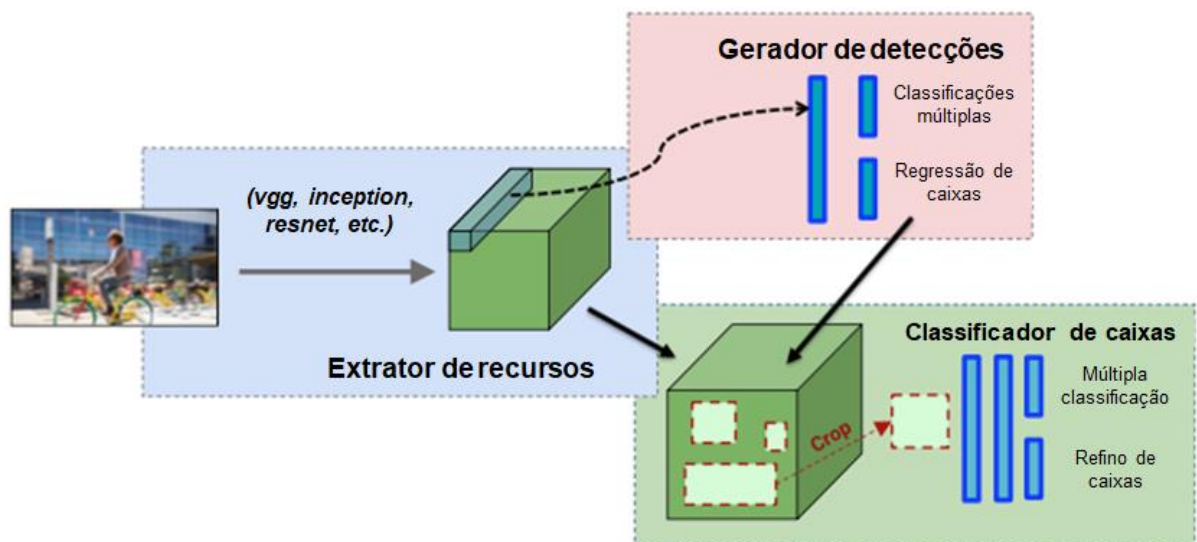
Fonte. Adaptado de (DHANUSH, 2018).

As Redes convolucionais, após seu treinamento, conseguem reconhecer padrões complexos em imagens, sendo facilmente adaptáveis a alterações nas imagens de entrada como resolução, distorções e mudanças de geometria. Essa característica é a maior vantagem de sua aplicação.

Existem diversas arquiteturas de redes neurais convolucionais. Neste trabalho, propomos a utilização de redes neurais convolucionais de região mais rápido (Faster R-CNN, na seção 1.4.1) e redes neurais convolucionais de detectores de disparo único (SSD e SSDLITE na seção 1.4.2).

#### 1.4.1 Redes neurais convolucionais de região mais rápidas

As redes neurais convolucionais de região mais rápida (Faster R-CNN) são modelos de redes neurais artificiais complexos para detecção e classificação de objetos com alta performance. É uma melhoria das versões antigas do R-CNN (REN et al., 2015). Os autores alteraram a estrutura do R-CNN complexo para adicionar mais desempenho e precisão ao Faster R-CNN. Na Figura 2, podemos visualizar uma estrutura de execução do Faster R-CNN, a rede possui dois estágios para adicionar mais precisão de detecção.



**Figura 2.** Estrutura da rede neural convolucional de região mais rápida.

Fonte. Adaptado de (LAU, 2017).



---

No primeiro estágio, uma rede convencional propõe regiões na imagem de entrada e produz mapas de características (possíveis regiões de interesse). Na primeira ramificação, após as camadas convolucionais, uma rede de regiões propostas (RPN) desliza uma janela sobre um mapa de recursos de entrada e, em seguida, "ancorará" um conjunto de pontuações (ou seja, as probabilidades de caixas vinculadas dessa região) e conjunto de coordenadas de caixas delimitadoras para a janela de processamento.

Um RPN é uma rede que recebe um mapa de imagem como entrada e gera a proposta de objeto retangular, ou seja, possíveis objetos na imagem. O conjunto de regiões propostas passará então por uma camada de pool de Rol (Região de Interesse), que é uma operação de maxpooling para apenas as regiões propostas. Finalmente, a saída Rol será avaliada por uma camada totalmente conectada.

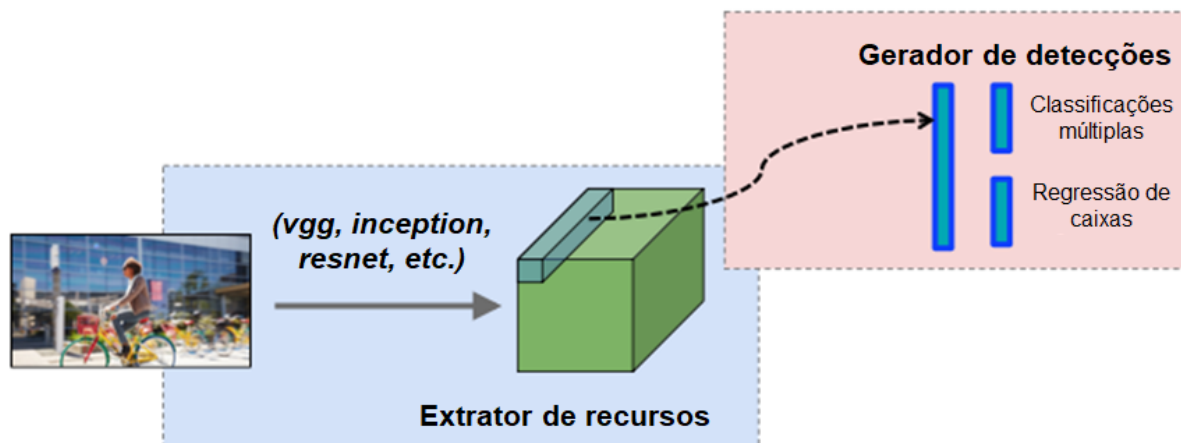
A segunda ramificação RCNN mais rápida obtém a saída de camadas convolucionais e a coloca como uma entrada para a camada de agrupamento Rol. Sua saída também será avaliada na camada totalmente conectada, portanto, as caixas delimitadoras e as pontuações serão uma combinação da classificação feita na camada totalmente conectada, usando as duas saídas de etapas anteriores.

#### **1.4.2 Detectores de disparo único SSD e SSDLITE**

Uma meta-arquitetura de detector multi-box (SSD) de único disparo resolve o problema de detecção de objetos usando uma única passagem de uma rede convolucional de feedforward (LIU et al., 2016b). Ao contrário de outros modelos, isso não gera propostas de região nem reamostragem de segmentos de imagem, economizando tempo computacional (FUENTES et al., 2017; LIU et al., 2016b).

Essa rede manipula objetos de tamanhos diferentes usando mapas de características de diferentes camadas convolucionais como entrada para o classificador. Essa rede produz muitas caixas delimitadoras com as pontuações da classe de objeto nessas caixas. A supressão não máxima é usada para eliminar caixas abaixo de um certo limite, de modo que apenas as caixas com valores de confiança mais altos procedam à classificação.

A meta-arquitetura SSD permite treinamento de ponta a ponta e melhora a velocidade do detector. Essa meta-arquitetura faz tudo de uma só vez, portanto, é mais rápida que outras metarquitecturas, mas fica abaixo da precisão de detecção (LIU et al., 2016b). Um exemplo dessa estrutura é apresentado na Figura 3.



**Figura 3.** Estrutura básica da rede Single Shot Detector

Fonte. Adaptado de (LAU, 2017).

O SSD Lite é uma nova arquitetura móvel chamada de MobilenetV2, que melhora o desempenho de última geração de modelos móveis em várias tarefas e benchmarks, bem como em um espectro de diferentes tamanhos de modelos (SANDLER et al., 2018). Diferente do SSD a arquitetura MobileNetV2 é baseada em uma estrutura residual invertida onde a entrada e saída do bloco residual são camadas finas de gargalo opostas a modelos residuais tradicionais que usam representações expandidas na entrada de um MobileNetV2 usa convoluções leves para filtrar recursos na camada de expansão intermediária (SANDLER et al., 2018).

---

## 1.5 REFERÊNCIAS

- BARR, A.; FEIGENBAUM, E. A. **The Handbook of artificial intelligence, volume 1**. Repr. ed. Stanford: Stanford, Calif.: HeurisTech Press ; Los Altos, Calif. : William Kaufmann, 1981. v. 1
- BENNETT, J. M. et al. Advances in Cotton Harvesting Technology: a Review and Implications for the John Deere Round Baler Cotton Picker. p. 27, 2015.
- CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento de safra brasileiro - grãos**: Terceiro levantamento, dezembro 2018 - safra 2018/19.: Brasília: Companhia Nacional de Abastecimento. 2018. Disponível em: [https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/23679\\_041c465fb71e41cf382825c6b8c43623](https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/23679_041c465fb71e41cf382825c6b8c43623). Acesso em: 17 dez. 2018.
- DHANUSH. **Convolutional Neural Network from Scratch**. **Data Driven Investor**, 13 jun. 2018. Disponível em: <<https://medium.com/datadriveninvestor/convolutional-neural-network-from-scratch-353b9331047b>>. Acesso em: 30 jan. 2019.
- FUENTES, A. et al. A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition. **Sensors**, v. 17, n. 9, p. 2022, 4 set. 2017.
- GÉRON, A. Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. n. 1, p. 718, 2017.
- HUANG, S.-H.; PAN, Y.-C. Automated visual inspection in the semiconductor industry: A survey. **Computers in Industry**, v. 66, p. 1–10, jan. 2015.
- HUTTUNEN, H. **BISHWO PRAKASH ADHIKARI CAMERA BASED OBJECT DETECTION FOR INDOOR SCENES**. Hervanta, Finland: Tampere University of Technology, 2018.
- IBADOV, S. et al. Algorithm for detecting violations of traffic rules based on computer vision approaches. **MATEC Web of Conferences**, v. 132, p. 05005, 2017.

---

JIDONG, L. et al. Recognition of apple fruit in natural environment. **Optik - International Journal for Light and Electron Optics**, v. 127, n. 3, p. 1354–1362, fev. 2016.

KAZAMA, E. H. PERDAS NA COLHEITA MECANIZADA DE ALGODÃO EM VARIABILIDADE ESPACIAL E EM FUNÇÃO DE VELOCIDADES DE COLHEITA. p. 73, 2016.

KAZAMA, E. H. et al. Influência do sistema de colheita nas características da fibra do algodão. **Revista Ceres**, v. 63, n. 5, p. 631–638, out. 2016.

KAZAMA, E. H. et al. Cotton and fiber quality in function of picker harvest speed. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 8, p. 583–588, ago. 2018.

KAZAMA, E. H.; FERREIRA, F. M. Multivariate analysis of fiber characteristics of dense cotton in different harvest systems. p. 7, 2015.

KERMANY, D. S. et al. Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. **Cell**, v. 172, n. 5, p. 1122- 1131.e9, 22 fev. 2018.

KOHAVI, R. **A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection**. . In: ARTIFICIAL INTELLIGENCE (IJCAI). Montreal, Quebec, Canada: 1995. Disponível em: <<http://ai.stanford.edu/~ronnyk/accEst.pdf>>. Acesso em: 29 jan. 2019

LAU, F. **Speed/accuracy trade-offs for modern convolutional object detectors**Medium, 9 mar. 2017. Disponível em: <<https://medium.com/@phelixlau/speed-accuracy-trade-offs-for-modern-convolutional-object-detectors-bbad4e4e0718>>. Acesso em: 29 jan. 2019

LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, nov. 1998.

LEIBE, B. et al. Coupled Object Detection and Tracking from Static Cameras and Moving Vehicles. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 30, n. 10, p. 1683–1698, out. 2008.

---

LIU, T. et al. Detection of aphids in wheat fields using a computer vision technique. **Biosystems Engineering**, v. 141, p. 82–93, jan. 2016a.

LIU, W. et al. SSD: Single Shot MultiBox Detector. **arXiv:1512.02325 [cs]**, v. 9905, p. 21–37, 2016b.

MELLIT, A.; KALOGIROU, S. A. Artificial intelligence techniques for photovoltaic applications: A review. **Progress in Energy and Combustion Science**, v. 34, n. 5, p. 574–632, out. 2008.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and Electronics in Agriculture**, v. 153, p. 69–81, out. 2018.

REN, S. et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. **arXiv:1506.01497 [cs]**, p. 1–14, 4 jun. 2015.

REN, X. et al. A Novel Image Classification Method with CNN-XGBoost Model. In: KRAETZER, C. et al. (Eds.). **Digital Forensics and Watermarking**. Cham: Springer International Publishing, 2017. v. 10431p. 378–390.

RODRIGUES, C. A. DE S. P. **Implementação de redes convolucionais para a segmentação de imagens em tempo real com vistas à aplicação em robôs autônomos com dispositivos de visão de baixo custo**. Goiânia, Goiás - Brasil: Universidade Federal do Goiás - UFG, 2018.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. Englewood Cliffs, N.J: Prentice Hall, 1995.

SA, I. et al. DeepFruits: A Fruit Detection System Using Deep Neural Networks. **Sensors**, v. 16, n. 8, p. 1222, 3 ago. 2016.

SANDLER, M. et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks. **arXiv:1801.04381 [cs]**, p. 1–14, 12 jan. 2018.

SCHLÜTER, M. et al. Vision-based Identification Service for Remanufacturing Sorting. **Procedia Manufacturing**, v. 21, p. 384–391, 2018.

---

SHRIVASTAVA, S.; SINGH, S. K.; HOODA, D. S. Soybean plant foliar disease detection using image retrieval approaches. **Multimedia Tools and Applications**, v. 76, n. 24, p. 26647–26674, dez. 2017.

SILVA, R. P.; FERREIRA, I. C.; CASSIA, M. T. Losses in cotton mechanized harvest. **Scientia agropecuaria**, v. 2, p. 07–12, 31 mar. 2011.

SILWAL, A. et al. Design, integration, and field evaluation of a robotic apple harvester. **Journal of Field Robotics**, v. 34, n. 6, p. 1140–1159, set. 2017.

SZELISKI, R. Computer Vision: Algorithms and Applications. p. 979, 9 mar. 2010.

VIEIRA, C. P.; CUNHA, L. J. C.; ZÓFOLI, R. C. **Algodão: tecnologia de produção**. 1. ed. Dourados: Embrapa Agropecuária Oeste, 2001. v. 1.

VIOTTO, G. F. V. et al. Evaluation of losses in the cotton harvest at different speeds. **Scientific Electronic Archives**, v. 11, p. 48–55, 2018.

YEE YONG, P.; CHEE HAU, O.; HIEW MOI, S. Deep learning Convolutional Neural Network for Unconstrained License Plate Recognition. **MATEC Web of Conferences**, v. 255, p. 05002, 2019.

ZHANG, Z. et al. Effect of Mechanical Stress on Cotton Growth and Development. **PLoS ONE**, v. 8, n. 12, p. e82256, 16 dez. 2013.

---

## CAPÍTULO 2 – SISTEMA INTELIGENTE PARA PREVISÃO DA PRODUTIVIDADE DE ALGODÃO EM IMAGENS DE LAVOURAS COMERCIAIS<sup>1</sup>

### 2.1 Introdução

O processo de colheita mecanizada da cultura do algodão é complexo, pois, necessita de mão-de-obra qualificada, possui alto valor agregado e deve ser realizado com eficácia total para obter o máximo retorno dos investimentos. No entanto, em muitos casos não se obtém maiores retornos por falta de condições adequadas para realização da colheita (SILVA; FERREIRA; CASSIA, 2011).


Fatores relacionados às condições ambientais durante a operação de colheita influenciam diretamente a ocorrência das perdas (e.g. estande de plantas, altura da planta, regulagens da colhedora, mão-de-obra, tratos culturais, umidade das plumas e produtividade) que podem reduzir drasticamente a lucratividade, sendo o valor máximo considerável de perdas na colheita de até 10% (KAZAMA et al., 2018). No entanto, valores de até 20% são encontrados (SILVA et al., 2007; VIOTTO et al., 2018). Por outro lado, as condições de colheita em que se encontra uma lavoura algodoeira, anteriormente à operação de colheita, é um dos fatores mais difíceis de se ter uma visualização espacial em grandes áreas.

A previsão da produtividade pode se tornar uma informação de grande importância no gerenciamento da qualidade da operação, permitindo que futuramente melhores decisões sejam tomadas para adequar as regulagens da colhedora com base na produtividade da cultura. Portanto, esta pesquisa apresenta um sistema inteligente para previsão da produtividade do algodão com base na contagem de capulhos em imagens, por meio do aprendizado profundo.

Um dos maiores problemas na tarefa de detecção de objetos é a capacidade que um modelo tem para generalizar as informações de aprendizado em condições adversas. Uma das vantagens deste trabalho é que as imagens utilizadas para gerar o banco de dados foram adquiridas em diferentes horários ao longo do dia, em um campo de produção comercial. Exemplos de imagens utilizadas são demonstrados na Figura 4, nas quais observamos as variações das condições ambientais.

---

<sup>1</sup> Elaborado de acordo com as normas da revista [SENSORS](#).



**Figura 4.** Exemplo dos efeitos das condições ambientais em diferentes horários de aquisição de imagens, nas quais podemos observar as variações das condições ambientais, como o efeito da luminosidade e sombras ocasionadas pelo porte das plantas sobre as imagens adquiridas.

Desenvolvemos um sistema inteligente baseado em aprendizado profundo para previsão da produtividade do algodão, que funciona em menos de um segundo, tempo suficiente para obter informações em tempo real. A seguir estão algumas contribuições deste trabalho:

Nossa abordagem, é robusta às condições ambientais, onde podemos obter informações com precisão em qualquer horário ao longo do período do dia.

O melhor resultado encontrado para identificação dos capulhos apresentou erro médio absoluto percentual (MAPE) de 8.84%, enquanto que para previsão da produtividade o erro foi igual a 17.82% em 205 imagens do conjunto de dados de teste.

Esta pesquisa, contribui com inovação no campo de estudo de colheita mecanizada, confirmando que o uso de inteligência artificial aplicado para obter informações e gerar conhecimento em sistemas mecanizados de colheita, constitui-se em um novo horizonte para pesquisas.



## 2.2 Trabalhos relacionados

A previsão da produtividade de culturas depende da rigorosa coleta de dados em campo (AL-GAADI et al., 2016), inviabilizando sua aplicação em grandes áreas (RAHNEMOONFAR; SHEPPARD, 2017). Especificamente para cultura do algodão, a produtividade da cultura pode ser definida por meio da contagem do número de capulhos produzidos e pela massa das plumas de cada capulho ou por unidade de área (XU et al., 2018). Porém, a visão de máquina está cada vez mais presente no meio agrícola (LIU et al., 2017; MALDONADO; BARBOSA, 2016; RAMOS et al., 2017).

Estudos recentes desenvolveram algoritmos para localização e contagem de frutos, de modo a obter informações para estabelecer previsões de produtividade de culturas (JIDONG et al., 2016; SA et al., 2016; STEIN; BARGOTI; UNDERWOOD, 2016), classificações dos níveis de maturação (RAMOS et al., 2017; TU et al., 2018; WAN et al., 2018) e para o desenvolvimento de sistemas para colheita robótica (FENG et al., 2018; SILWAL et al., 2017). Para a cultura do algodão, diversos métodos baseados em manipulações das informações dos pixels foram propostos para segmentação das regiões onde estão localizados os capulhos em imagens (CHEN et al., 2013; LIU; LAI; JIA, 2011; WEI et al., 2008). Outro método para segmentação das regiões de capulhos de algodão em imagens foi proposta por (LI et al., 2016) por meio da segmentação de imagens semânticas baseada na região. Essa abordagem superou os resultados das pesquisas citadas anteriormente.

Recentemente, com os avanços em pesquisas de visão computacional e com a popularização do uso em larga escala de GPUs (*Graph Processing Units*) (PATRÍCIO; RIEDER, 2018). Estudos (FUE; PORTER; RAINS, 2018; XU et al., 2018; YEOM et al., 2018) propuseram métodos baseados em aprendizado profundo para identificação de regiões de interesse em imagens de algodão (e.g. características morfológicas). (XU et al., 2018) desenvolveram uma metodologia utilizando uma rede neural convolucional para detectar e contar o número de flores recém-abertas de algodão em imagens aéreas. (FUE; PORTER; RAINS, 2018) desenvolveram um sistema que possibilitou o rastreamento e contagem de capulhos de algodão cultivados em vasos, por meio de imagens em movimento. (YEOM et al., 2018)

---

desenvolveram um algoritmo para identificação e contagem de capulhos para estimar a produtividade do algodão usando imagens aéreas adquiridas durante o período da colheita em campo experimental. Essas informações obtidas podem se tornar úteis para melhor gerenciamento da produção.

Propomos, uma abordagem diferente para utilização das informações obtidas por meio da contagem dos capulhos de algodão em lavouras comerciais. Nosso método estima a produtividade a partir da contagem de capulhos de imagens adquiridas em diferentes horários ao longo do dia. Com esta abordagem será possível aumentar a eficiência e reduzir as perdas na colheita mecanizada do algodão a partir de um monitoramento da produtividade realizado antes da operação. Essa informação permite que melhores configurações e regulagens da colhedora sejam utilizadas.

## **2.3 Material e Métodos**

Nesta seção, apresentamos de maneira detalhada a construção do banco de dados, incluindo o trabalho que realizamos em campo para aquisição das imagens da cultura ([Seção 2.3.1](#)) como anotamos as caixas delimitadoras nas imagens e os critérios adotados para separação dos arquivos de treinamento, validação e teste ([Seção 2.3.2](#)) e, por fim, a implementação dos modelos propostos ([Seção 2.3.3](#)).

### **2.3.1 Construindo o banco de dados**

A etapa de aquisição dos dados foi realizada nos dias 03 e 04 de setembro de 2017, dois dias antes do início processo de colheita mecanizada de uma área comercial para produção de algodão, localizada na região do município de Chapadão do Céu, interior do Estado de Goiás, Brasil, próximo à latitude 18°23' Sul e longitude 52°39' Oeste, com altitude de 725 metros. Neste campo, a cultura foi implantada em Sistema Plantio Direto com 0.13 metros de espaçamento entre plantas e 0.76 metros entre linhas. A variedade cultivada FM 975 WS tem por características ciclo tardio (160 a 190 dias) rendimento de fibra (40 a 41%) e massa média de capulhos de 5 gramas.

---






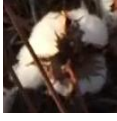

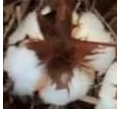
Aleatoriamente escolhemos 63 unidades amostrais distanciadas ~50 metros entre si, para coleta das informações, sendo cada unidade amostral composta por uma linha da cultura com 5 metros de comprimento. Adotamos como critério para etapa de aquisição das imagens as variações das condições ambientais ao longo do dia (e.g., mudanças na disposição da luz do sol, ventos em diferentes sentidos e sombras ocasionadas pelo porte das plantas). Coletamos imagens em diferentes horários do dia, de 8h às 18h.

Para facilitar a aquisição das imagens realizamos manualmente uma [filmagem](#) com uso de um dispositivo mobile simples (câmera de 8Mp na resolução de 1080P a 30FPS) com altura padronizada de ~0.5 metros acima do dossel, de tal modo que permitisse a identificação de todos capulhos presentes nas plantas. Em cada arquivo de filmagem foram selecionadas em torno de 25 imagens diferentes para que não houvesse imagens semelhantes no banco de dados, totalizando assim, 1389 imagens nas 63 unidades amostrais.

### **2.3.2 Divisão de dados e rotulagem de imagens**

A divisão dos arquivos de filmagem foi realizada em função dos horários de aquisição ao longo do dia, utilizando 47 filmes (948 imagens) para etapa de treinamento, oito para validação (236 imagens) e oito para teste (205 imagens). Em geral, para melhorar a robustez de um modelo é necessário que as imagens possuam as mais diferentes condições possíveis. Levando isto em consideração, as imagens adquiridas em diferentes horários foram distribuídas para as etapas de treinamento (68%), validação (18%) e teste (14%). O próximo passo foi demarcar manualmente as regiões de interesse por meio de caixas retangulares em todos capulhos presentes nas imagens para separar o conjunto de dados de treinamento e validação por meio da implementação em Python da ferramenta Labellmg (TZUTALIN, 2015). O número de total de caixa retangulares anotadas manualmente foi de 24.580. Exemplos de anotações com caixas retangulares e os números de dados utilizados em cada etapa são apresentados na Tabela 2.

**Tabela 2.** Exemplos de anotações com caixas retangulares e divisão dos arquivos de treinamento, validação e teste para confecção do banco de dados em função das condições ambientais.

Exemplos de Anotações	Horário de Aquisição	Número de Imagens*		Caixas Retangulares	Número de Imagens de Teste*
		Treinamento	Validação		
	8:00 a.m.	101 <sup>4</sup>	30 <sup>1</sup>	2.335	27 <sup>1</sup>
	10:00 a.m.	82 <sup>4</sup>	27 <sup>1</sup>	1.729	24 <sup>1</sup>
	11:00 a.m.	87 <sup>4</sup>	23 <sup>1</sup>	1.766	30 <sup>1</sup>
	02:00 p.m.	108 <sup>4</sup>	23 <sup>1</sup>	2.355	25 <sup>1</sup>
	03:00 p.m.	107 <sup>4</sup>	24 <sup>1</sup>	2.065	18 <sup>1</sup>
	04:00 p.m.	87 <sup>4</sup>	23 <sup>1</sup>	2.489	24 <sup>1</sup>
	05:00 p.m.	283 <sup>11</sup>	22 <sup>1</sup>	8.866	26 <sup>1</sup>
	06:00 p.m.	93 <sup>4</sup>	64 <sup>1</sup>	2.975	31 <sup>1</sup>
<b>Total</b>		948 <sup>47</sup>	236 <sup>8</sup>	24.580	205 <sup>8</sup>

### 2.3.3 Detalhes da implementação

Propomos aqui, uma implementação que é baseada em uma versão modificada da API Object Detection do [TensorFlow](#) para identificação dos capulhos de algodão nas imagens do conjunto de dados, incluindo os modelos e algoritmos de detecção de um e dois estágios utilizados ([Seção 2.3.3.1](#)), acrescentamos técnicas de aumento de dados ([Seção 2.3.3.2](#)) e as métricas utilizadas para avaliação do desempenho ([Seção 2.3.3.3](#)). Os algoritmos de detecção foram treinados e testados em Windows 10 com processador Intel Core I7 de 3,5 GHz e GPU NVIDIA GeForce GTX 960 (4GB).

#### 2.3.3.1 Algoritmos de detecção

O algoritmo de detecção de dois estágios foi implementado por meio do Faster Region-based Convolutional Neural Network (Faster R-CNN) (REN et al., 2015) que basicamente possui duas redes: a primeira é a rede de região proposta (RPN) que recebe as imagens de entrada do conjunto de dados e tem por finalidade gerar propostas das regiões de interesse na imagem. A segunda rede utiliza essas propostas para detectar os objetos (capulhos).

Para a detecção em uma única etapa implementamos o modelo Single Shot Detector (SSD) (LIU et al., 2016), que lida com o problema de reconhecimento de objetos usando uma rede convolucional de feed-forward, que produz uma coleção de tamanho fixo de caixas delimitadoras e pontuações para a presença de uma classe de objeto em cada caixa delimitadora encontrada pelo modelo. E também utilizamos uma derivação do SSD mais recente, desenvolvida para aplicação em dispositivos mobile com nova arquitetura que foi chamada de Single Shot Detector Lite (SSDLITE) (SANDLER et al., 2018), sendo baseada em uma estrutura residual invertida em que a entrada e saída do bloco residual são camadas finas de gargalo. Ambos, os modelos, geralmente são considerados mais rápidos que o Faster R-CNN (Tabela 3). Mais informações sobre os modelos podem ser visualizadas no ([Apêndice 1](#)).

**Tabela 3.** Detalhes dos modelos propostos, incluindo os métodos para detecção em um e dois estágios, extratores de recursos, Bath Size e resolução das imagens de entrada.











<b>Método</b>	<b>Modelo</b>	<b>Extrator de Recursos</b>	<b>Bath Size</b>	<b>Resolução de Entrada</b>
<b>Dois estágios</b>	Faster R-CNN	Inception V2	1	1024 x 1024
	(REN et al., 2015)	(SZEGEDY et al., 2015)		
<b>Um estágio</b>	SSD	Mobilenet V1	4	640 x 640
	(LIU et al., 2016)	(HOWARD et al., 2017)		
<b>Um estágio</b>	SSDLITE	Mobilenet V2	4	300 x 300
	(SANDLER et al., 2018)	(SANDLER et al., 2018)		

Bath Size: Tamanho do lote.

### 2.3.3.2 Técnica de aumento de dados

Aumento de dados é um processo para geração de imagens artificialmente, que são alteradas a partir de cada imagem de instância, dentro do conjunto de dados de treinamento. Essa técnica resulta na obtenção de maior quantidade de dados para treinamento, evitando ajustes excessivos e aumentando o desempenho do modelo proposto (TAYARA; CHONG, 2018). Para ambos modelos utilizados neste estudo foram incluídos, aumento de escala aleatório, rotações aleatórias de 90°, inversão vertical e horizontal (espelhamento) e distorção de cor. Exemplos de aumento de dados são apresentados na Tabela 4, que foram extraídos de imagens adquiridas às 11:00 p.m.

**Tabela 4.** Exemplo do uso técnica de aumento de dados. Primeira coluna representa a imagem de entrada enquanto a segunda, terceira, quarta e quinta representam imagens de saída.

Imagem de entrada	Imagens de saída			
	Rotação aleatória	Inversão aleatória	Escala aleatória	Distorção de cor
	90° 	Horizontalmente 	Redução 	
	180° 	Verticalmente 	Aumento 	
	270° 		Aumento 	

### 2.3.3.3 Avaliação do desempenho

Os resultados de nossa pesquisa serão apresentados com base nas métricas de avaliação de detecção do desafio proposto para o conjunto de dados MS COCO (LIN et al., 2014), que calcula a recuperação (AR) e precisão média (AP) em diferentes limites de intersecção sobre união (IoU) de 0.50 a 0.95 (@[IoU=0.50:0.95]).

Para avaliar o desempenho de contagem dos capulhos, utilizamos a curva de recuperação e precisão no intervalo de 0 a 1. A precisão mede a porcentagem de um objeto detectado ser de fato um capulho e a recuperação mede a capacidade que o classificador tem para localizar os capulhos nas imagens.

Portanto,

$$AP = \frac{VP}{VP + FP} \quad (1)$$

$$AR = \frac{VP}{VP + FN} \quad (2)$$

em que, VP: verdadeiro positivo, FP: falso positivo e FN: falso negativo. Os valores verdadeiro positivos representam a sobreposição entre a verdade fundamental (anotações que realizamos para imagens do conjunto de dados) e a caixa delimitadora predita (anotações identificadas por meio dos modelos propostos). Os valores falso positivos representam a existência da verdade fundamental não encontrada pelo modelo, enquanto que falso negativos representam identificações de objetos que não correspondem à verdade fundamental.

## 2.4 Resultados

Nesta seção, avaliamos o desempenho dos modelos propostos para detecção e contagens de capulhos de algodão, incluindo o desempenho geral de treinamento e validação ([Seção 2.4.1](#)) comparamos o desempenho da detecção ([Seção 2.4.2](#)) e contagem ([Seção 2.4.3](#)) dos capulhos para o conjunto de dados de testes em função dos horários de aquisição de imagem e por fim avaliamos o por meio de regressão linear a quantificação da produtividade por imagem o modelo com melhor desempenho ([Seção 2.4.4](#)).

### 2.4.1 Desempenho geral de treinamento

Nosso sistema foi implementado por diferentes modelos para lidar com a detecção dos capulhos de algodão, nas imagens adquiridas ao longo dos períodos do dia (Tabela 5). A rede treinada pelo algoritmo de detecção em dois estágios apresentou melhor desempenho que as redes de detecção um único estágio, como é no caso do modelo Faster R-CNN Inception V2. O detector de um único estágio SSD Mobilenet V1 apresentou pequena diferença comparado ao melhor resultado com AR média de 0.01 e AP média de 0.05, entretanto, para o modelo SSDLITE o



desempenho foi inferior, com diferença para AR média de 0.14 e AP média de 0.20, sendo considerado este o pior resultado entre os modelos.

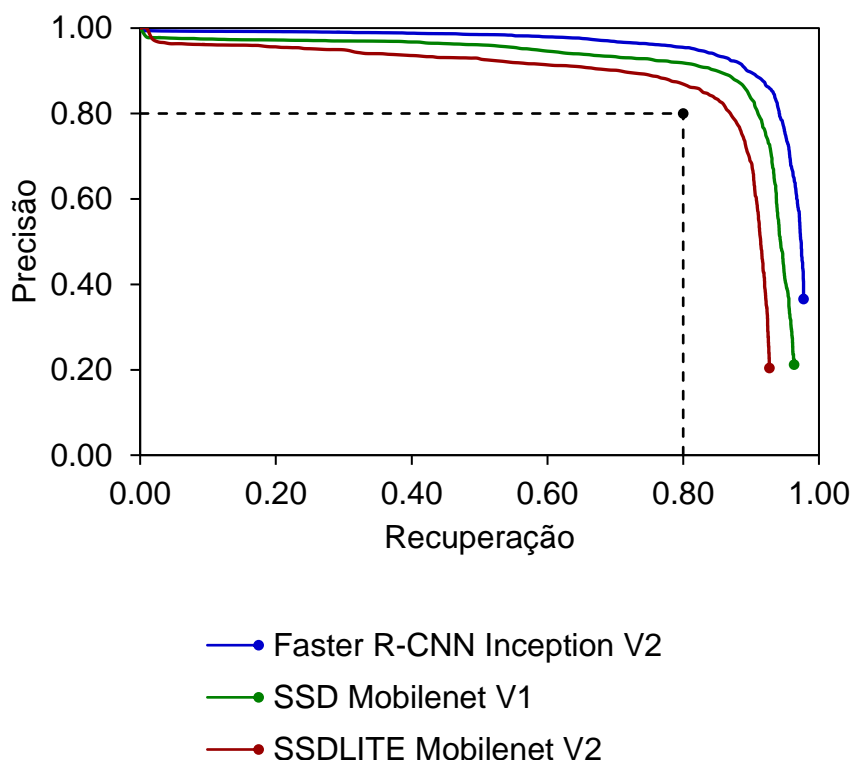
De maneira geral, a AR e AP médias apresentaram desempenho superior a 50%, indicando que ambos os modelos podem ser utilizados para localização e identificação de capulhos nas imagens do conjunto de dados de treinamento.

**Tabela 5.** Resultados comparativos do desempenho da detecção em diferentes modelos para o conjunto de dados de treinamento e validação.

Método	Modelos	AR	AP
Dois estágios	Faster R-CNN Inception V2	0.66	0.59
Um estágio	SSD Mobilenet V1	0.65	0.54
	SSDLITE Mobilenet V2	0.52	0.39

AR.: Recuperação média, AP.: Precisão média.

Os resultados das curvas de recuperação-precisão destacam que os modelos avaliados obtiveram resultados promissores, com pontuações de recuperação e precisão superiores a 0.80, ou seja, isso significa que, a possibilidade de localização e identificação de um objeto encontrado pelo modelo ser de fato um capulho de algodão é superior a 80% (Figura 5). Portanto, adotamos esse valor como limite mínimo para contagem dos capulhos nas imagens do conjunto de dados de teste que serão apresentados nas próximas seções.



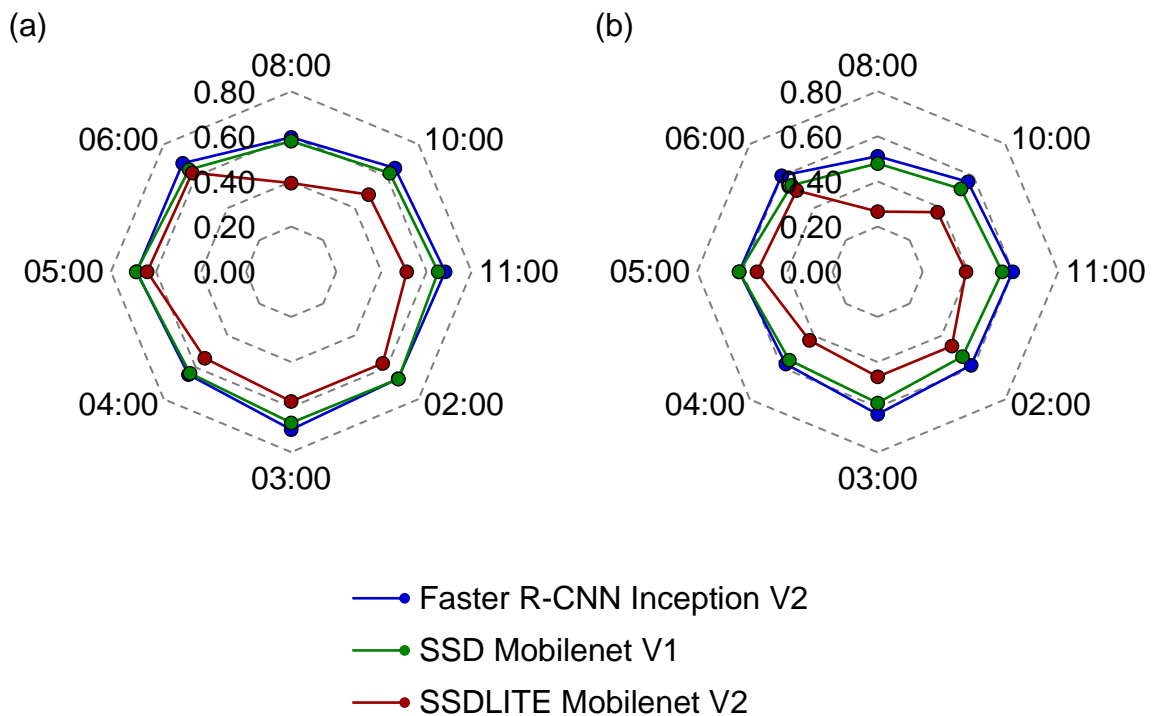
**Figura 5.** Comparação da área sob as curvas de recuperação e precisão com diferentes modelos para o conjunto de treinamento. Uma vez que todas as curvas têm ponto de inflexão acima de 80%, adotamos como critério o limite mínimo de 0.80 para contagem dos capulhos de algodão.

#### 2.4.2 Teste em função dos modelos e horários de aquisição de imagens

O desempenho geral para o conjunto de dados de teste é apresentado na Figura 6. Os modelos propostos avaliados em função das condições ambientais apresentaram diferenças para todos horários de aquisição de imagens ao longo do dia, tanto para valores de recuperação média quanto para valores de precisão média.

Com relação à recuperação média (Figura 6a), os modelos Faster R-CNN Inception V2 e SSD Mobilenet V1, apresentaram o desempenho semelhante para a identificação e localização dos capulhos de algodão com pequenas variações em função dos horários de aquisição de imagem, com valores superiores a 0.60, mostrando que esses modelos têm melhor generalização e boa robustez às condições ambientais ao longo do dia, diferindo do modelo SSDLITE Mobilenet V2 que apenas para o período das 05:00 às 06:00 p.m. obteve valores semelhantes, e para os demais períodos de aquisição de imagem foi observado um decréscimo dos

valores, principalmente para as primeiras horas do início do dia (08:00 às 11:00 a.m.) o que sugere que esse modelo é sensível às condições ambientais, não sendo considerado robusto, com baixa possibilidade de generalização. Observamos o mesmo comportamento para os valores de precisão média (Figura 6b). De maneira geral, podemos observar que imagens adquiridas no período do início da manhã 08:00 a.m. apresentaram desempenho inferior para todos modelos propostos e que as imagens adquiridas ao entardecer as 05:00 p.m. e 06:00 p.m. apresentaram melhor desempenho.



**Figura 6.** Resultados de recuperação (a) e precisão (b) média dos modelos propostos para o conjunto de dados de teste em função dos horários de aquisição de imagens.

Para que nosso sistema seja robusto às condições ambientais, os modelos propostos devem realizar a contagem dos capulhos nas imagens em qualquer horário ao longo do dia com o mínimo de variabilidade entre os valores de contagem real e da contagem realizada pelo modelo, pois essa informação é a principal utilizada no cálculo de previsão da produtividade por imagem. Dessa maneira, apresentamos na próxima seção o desempenho entre as contagens realizadas por meio dos modelos propostos.

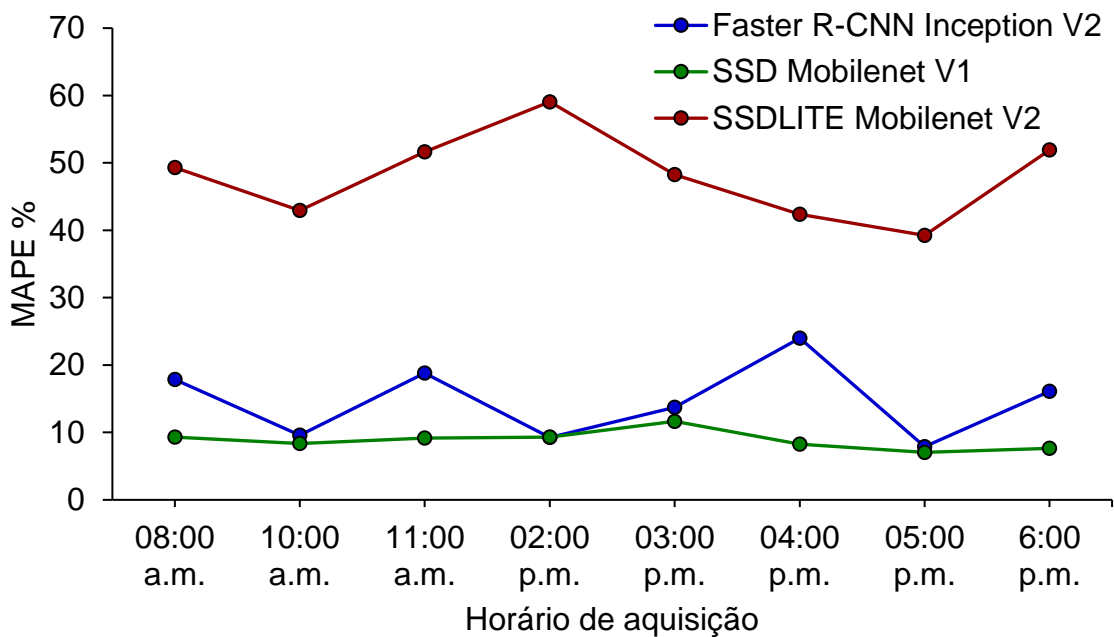
### 2.4.3 Contagem de capulhos real x automática

Para avaliar o melhor modelo para realizar a contagem dos capulhos nas imagens, comparamos os resultados da contagem realizada pelos modelos propostos com os resultados da contagem real, por meio do cálculo do erro absoluto percentual médio (MAPE):

$$MAPE (\%) = \frac{\sum_{i=1}^n \left( \left| \frac{C_{modelo} - C_{manual}}{C_{manual}} \right| * 100 \right)}{n} \quad (3)$$

em que,  $n$  é o número total de imagens,  $C_{modelo}$  é número de capulhos contados através dos modelos propostos,  $C_{manual}$  é o número real de capulhos presente na imagem.

Podemos observar que existiu diferença das contagens manuais e das contagens realizadas por meio dos modelos propostos, em todos horários de aquisição de imagens (Figura 7). Nós adotamos por critério, três padrões de erro para classificar a qualidade de contagem dos capulhos: excelente (erros menores que 10%), intermediário (11 a 20%) e insatisfatório (acima de 20%), levamos em consideração a variabilidade da produtividade de algodão. O resultado excelente foi considerado para o modelo SSD Mobilenet V1 que apresentou MAPE de 8.84% com pequena variação entre os horários de aquisição, indicando que para esse modelo é possível obter contagens em qualquer período do dia.



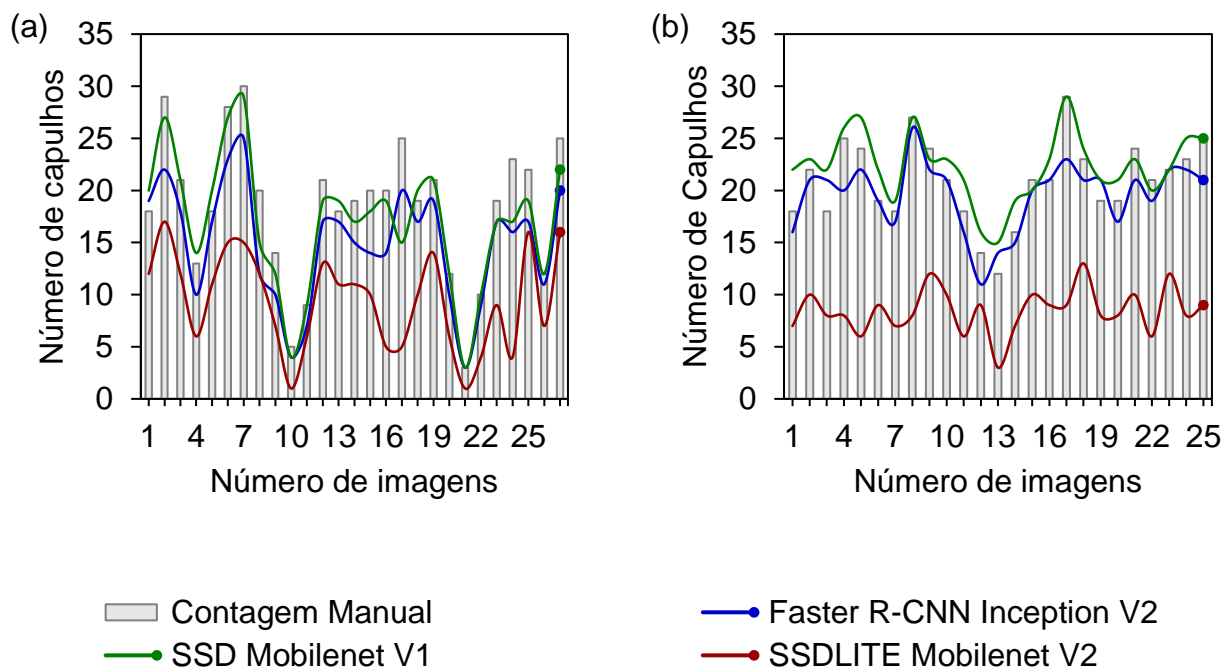
**Figura 7.** Comparação dos resultados da contagem de capulhos com diferentes modelos para o conjunto de dados de teste em função dos horários de aquisição de imagem. a.m.: horários do período da manhã, p.m.: horários do período da tarde.

O modelo Faster R-CNN Inception V2 com MAPE de 14.65% apresentou um resultado intermediário, porém, para esse modelo houve grandes variações em função dos horários de aquisição de imagem, sendo que o período das 04:00 p.m. apresentou MAPE de até 23.99%. Para esse modelo os períodos que poderiam ser considerados para quantificação do número de capulhos seriam apenas para os horários das (10:00 a.m., 02:00 p.m. e 05:00 p.m.). O pior desempenho de contagem, classificado como insatisfatório, foi obtido pelo modelo SSDLITE Mobilenet V2, com MAPE de 48.09%, não sendo indicado para contagem de capulhos em nenhum horário ao decorrer do período do dia. Embora esse modelo não tenha apresentado resultado promissor, devemos levar em consideração que a resolução das imagens de entrada é inferior, comparada aos demais modelos, o que pode ter prejudicado o aprendizado da rede e a capacidade de generalização das informações em condições adversas ao banco de dados de treinamento e validação.

---

Outro fator importante para ser observado é o número utilizado para o tamanho de lote (batch size) na etapa de treinamento dos modelos SSD Mobilenet V1 e SSDLITE Mobilenet V2. Em nossa pesquisa utilizamos o maior valor possível, de acordo com a capacidade computacional do nosso sistema. Sugerimos para estudos futuros a avaliação do desempenho com maiores valores para tamanho de lote.

Exemplos do desempenho da contagem realizada por ambos modelos em imagens adquiridas no início da manhã 08:00 a.m. e ao entardecer às 06:00 p.m. são apresentados na Figura 8. Os resultados confirmam a capacidade do modelo SSD Mobilenet V1 em se ajustar de acordo com a variação da contagem em função das imagens utilizadas, o que não foi possível observar para o modelo Faster R-CNN Inception V2, que para maioria das imagens apresentadas no exemplo superestimam ou subestimam as quantidades de capulhos presentes nas imagens, e para o modelo SSDLITE Mobilenet V2 que foi considerado com desempenho insatisfatório. Através das linhas sequenciais foi possível observar que o modelo subestima a contagem de capulhos em todas imagens.




**Figura 8.** Exemplo do desempenho de contagem para diferentes condições ambientais das imagens para o conjunto de dados de teste (a) no início da manhã 08:00 a.m. e (b) ao entardecer 06:00 p.m. As linhas representam as contagens dos capulhos realizadas por meio dos modelos propostos e as colunas representam as contagens reais em cada imagem avaliada. Exemplos para os demais horários de aquisição de imagem podem ser visualizados no ([Apêndice 2](#)).

Podemos observar o mesmo comportamento apresentado nos resultados anteriores na (Figura 9). O modelo SSD Mobilenet V1 que foi considerado robusto às condições ambientais, apresentou a mesma porcentagem de erro (MAPE) para ambos os períodos exemplificados; já para os modelos Faster R-CNN Inception V2 e SSDLITE Mobilenet V2 entre os períodos houve diferenças de 11% e 18%, respectivamente. Essa diferença de valores entre as contagens para diferentes horários de aquisição pode comprometer drasticamente a acurácia da previsão da produtividade, visto que o número de capulhos por imagem é o fator mais importante no cálculo da produtividade do algodão.

**(a) início da manhã (08:00 a.m.)**

Faster R-CNN Inception V2  
 Contagem manual = 21  
 Modelo = 14  
 MAPE (%) = 30%



SSD Mobilenet V1  
 Contagem manual = 21  
 Modelo = 19  
 MAPE (%) = 5%



SSDLITE Mobilenet V2  
 Contagem manual = 21  
 Modelo = 15  
 MAPE (%) = 75%

**(b) entardecer (06:00 p.m.)**

Faster R-CNN Inception V2  
 Contagem manual = 21  
 Modelo = 17  
 MAPE (%) = 19%



SSD Mobilenet V1  
 Contagem manual = 21  
 Modelo = 20  
 MAPE (%) = 5%



SSDLITE Mobilenet V2  
 Contagem manual = 21  
 Modelo = 9  
 MAPE (%) = 57%



**Figura 9.** Exemplo de imagens após a realização das contagens com marcações de caixas delimitadoras em diferentes condições ambientais do conjunto de dados de teste, (a) no início da manhã 08:00 a.m. e (b) ao entardecer 06:00 p.m.



Mais exemplos de imagens após a realização das contagens para os demais horários de aquisição podem ser visualizados no ([Apêndice 3](#)). Pensando na operação de colheita, que é realizada em diferentes horários ao longo do dia, não é recomendável considerar a utilização de modelos que apresentem grandes variações entre as contagens para diferentes horários, pois, dessa maneira podemos superestimar ou subestimar os valores de produtividade da cultura. Na próxima seção apresentaremos a previsão de produtividade por imagem para o resultado de contagem obtido pelo melhor modelo proposto.

#### 2.4.4 Previsão da produtividade por imagem

Aqui apresentaremos os resultados da quantificação de produtividade das imagens do conjunto de teste, realizada por meio das informações de contagem obtida pelo modelo SSD Mobilenet V1, que se apresentou robusto às condições ambientais com erros médios de 8,84% na identificação dos capulhos de algodão. Foi utilizado como referência a massa de 5 gramas para cada capulho. Portanto,


$$\textit{Produtividade observada} = \textit{PMC} \times \textit{NRCI} \quad (4)$$

$$\textit{Produtividade estimada} = \textit{PMC} \times \textit{NCCM} \quad (5)$$

em que, PMC, é a massa média em gramas de cada capulho, NRCI, é o número real de capulhos presente na imagem de teste, NCCM, é o número de capulhos contado pelo modelo.

Uma regressão linear foi realizada utilizando todas imagens do conjunto de dados de teste, entre os valores da quantificação da produtividade observada e produtividade estimada (Figura 10). O valor de  $R^2$  de 0.93, indica que 93% da produtividade observada na imagem pode ser representada por meio das previsões realizadas com as informações do modelo proposto, o que significa que a quantificação da produtividade estimada a partir da contagem realizada pelo modelo é semelhante à quantificação observada. O erro médio percentual para 205 imagens adquiridas ao longo do período do dia é igual a 17.82%.

Analisando a produtividade média do conjunto de dados de teste, que foi igual a 107.12 gramas por imagem, observamos que, esse valor de erro indica que as previsões realizadas por meio do modelo proposto, podem apresentar variações de produtividade de até 19.14 gramas para cada imagem analisada.



**Figura 10.** Regressão linear entre a produtividade observada e estimada. O resultado apresentado é baseado na previsão de produtividade por meio da contagem realizada pelo modelo SSD MobileNet V1 para todas imagens do conjunto de dados de teste.

## 2.5 Discussão e trabalhos futuros

Até onde sabemos, este é um dos primeiros trabalhos a utilizar a inteligência artificial para reconhecimento de capulhos de algodão em imagens adquiridas próximas ao dossel da cultura, para diferentes horários, em lavouras comerciais, dificultando a comparação com estudos prévios. Há muitas direções para trabalhos futuros, mas aqui mencionamos três particularmente promissoras.

A primeira é utilizar os resultados do melhor modelo para desenvolver um sistema inteligente que possa ser embarcado na colhedora e, durante a operação,

---

seja capaz de realizar a contagem dos capulhos em tempo real. O estudo dessa implementação possibilitará, além de uma previsão de produtividade, também a avaliação do desempenho desse sistema em condições reais de colheita mecanizada, bem como as possíveis melhorias que poderão ser realizadas.

Uma segunda direção, como maneira de complementar a aquisição das informações durante a operação de colheita, seria a necessidade do desenvolvimento de um sistema para monitorar e quantificar a porcentagem de perdas que ocorrem durante a operação de colheita mecanizada.

Por fim, uma terceira direção promissora que poderá ser implementada, mas desta vez, se apresentando mais relacionada ao tratamento e mineração dessas informações adquiridas por meio dos sistemas inteligentes mencionados. Trata-se do estabelecimento de relações funcionais entre a produtividade da cultura em campo, regulagens da colhedora, e perdas existentes após a operação de colheita. Dessa maneira, seria possível estabelecer as melhores configurações e regulagens para realizar a operação com base na produtividade, regulagens e perdas na operação, e por meio do aprendizado por reforço, em um futuro próximo seria o possível desenvolvimento de uma inteligência de máquina capaz de alterar as regulagens automaticamente durante a operação, visando sempre reduzir ao máximo as perdas e aumentar a eficiência da operação.

## **2.6 Conclusões**

Propusemos uma abordagem diferente para utilização das informações de contagens de capulhos em imagens. Acreditamos, que é possível aumentar a eficiência e reduzir as perdas na colheita de algodão, apenas tornando a operação não dependente de mão-de-obra. Nesta pesquisa, utilizamos imagens adquiridas em diversas condições ambientais no decorrer do período do dia.

O melhor resultado foi encontrado para o modelo SSD Mobilenet V1, onde encontramos valores de erro médio percentual para contagem de capulhos de 8.84 %, com capacidade de generalização das informações e sendo considerado robusto as condições ambientais, indicando que podemos obter valores para previsão da produtividade em qualquer horário ao longo do dia.

---

## 2.7 Referências

AL-GAADI, K. A. et al. Prediction of Potato Crop Yield Using Precision Agriculture Techniques. **PLOS ONE**, v. 11, n. 9, p. 1–16, 9 set. 2016.

CHEN, Q. et al. An cotton image segmentation algorithm based on support vector machine. **An cotton image segmentation algorithm based on support vector machine**, n. 39, p. 266–269, 2013.

FENG, Q. et al. Design and test of robotic harvesting system for cherry tomato. **International Journal of Agricultural and Biological Engineering**, v. 11, n. 1, p. 96–100, 2018.

FUE, K. G.; PORTER, W. M.; RAINS, G. C. **Deep Learning based Real-time GPU-accelerated Tracking and Counting of Cotton Bolls under Field Conditions using a Moving Camera**. 2018 Detroit, Michigan July 29 - August 1, 2018. **Anais...** In: 2018 DETROIT, MICHIGAN JULY 29 - AUGUST 1, 2018. American Society of Agricultural and Biological Engineers, 2018Disponível em: <<http://elibrary.asabe.org/abstract.asp?JID=5&AID=49298&CID=det2018&T=1>>. Acesso em: 9 nov. 2018

HOWARD, A. G. et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. **arXiv:1704.04861 [cs]**, p. 1–9, 16 abr. 2017.

JIDONG, L. et al. Recognition of apple fruit in natural environment. **Optik - International Journal for Light and Electron Optics**, v. 127, n. 3, p. 1354–1362, fev. 2016.

KAZAMA, E. H. et al. Cotton and fiber quality in function of picker harvest speed. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 8, p. 583–588, ago. 2018.

LI, Y. et al. In-field cotton detection via region-based semantic image segmentation. **Computers and Electronics in Agriculture**, v. 127, p. 475–486, set. 2016.

---

LIN, T.-Y. et al. Microsoft COCO: Common Objects in Context. **arXiv:1405.0312 [cs]**, 1 maio 2014.

LIU, J.-S.; LAI, H.-C.; JIA, Z.-H. Image Segmentation of Cotton Based on YCbCcr Color Space and Fisher Discrimination Analysis. **Image Segmentation of Cotton Based on YCbCcr Color Space and Fisher Discrimination Analysis**, v. 37, n. 07, p. 1274–1279, 2011.

LIU, S. et al. A computer vision system for early stage grape yield estimation based on shoot detection. **Computers and Electronics in Agriculture**, v. 137, p. 88–101, maio 2017.

LIU, W. et al. SSD: Single Shot MultiBox Detector. **arXiv:1512.02325 [cs]**, v. 9905, p. 21–37, 2016.

MALDONADO, W.; BARBOSA, J. C. Automatic green fruit counting in orange trees using digital images. **Computers and Electronics in Agriculture**, v. 127, p. 572–581, set. 2016.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and Electronics in Agriculture**, v. 153, p. 69–81, out. 2018.

RAHNEMOONFAR, M.; SHEPPARD, C. Deep Count: Fruit Counting Based on Deep Simulated Learning. **Sensors**, v. 17, n. 4, p. 1–12, 20 abr. 2017.

RAMOS, P. J. et al. Automatic fruit count on coffee branches using computer vision. **Computers and Electronics in Agriculture**, v. 137, p. 9–22, maio 2017.

REN, S. et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. **arXiv:1506.01497 [cs]**, p. 1–14, 4 jun. 2015.

SA, I. et al. DeepFruits: A Fruit Detection System Using Deep Neural Networks. **Sensors**, v. 16, n. 8, p. 1–22, 3 ago. 2016.

---

SANDLER, M. et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks. **arXiv:1801.04381 [cs]**, p. 1–14, 12 jan. 2018.

SILVA, R. P. et al. Variabilidade espacial e controle estatístico do processo de perdas na colheita mecanizada do algodoeiro. **Engenharia Agrícola**, v. 27, n. 3, p. 742–752, dez. 2007.

SILVA, R. P.; FERREIRA, I. C.; CASSIA, M. T. Losses in cotton mechanized harvest. **Scientia agropecuaria**, v. 2, p. 07–12, 31 mar. 2011.

SILWAL, A. et al. Design, integration, and field evaluation of a robotic apple harvester. **Journal of Field Robotics**, v. 34, n. 6, p. 1140–1159, set. 2017.

STEIN, M.; BARGOTI, S.; UNDERWOOD, J. Image Based Mango Fruit Detection, Localisation and Yield Estimation Using Multiple View Geometry. **Sensors**, v. 16, n. 11, p. 1–25, 15 nov. 2016.

SZEGEDY, C. et al. Rethinking the Inception Architecture for Computer Vision. **arXiv:1512.00567 [cs]**, p. 1–10, 1 dez. 2015.

TAYARA, H.; CHONG, K. Object Detection in Very High-Resolution Aerial Images Using One-Stage Densely Connected Feature Pyramid Network. **Sensors**, v. 18, n. 10, p. 1–18, 6 out. 2018.

TU, S. et al. Detection of passion fruits and maturity classification using Red-Green-Blue Depth images. **Biosystems Engineering**, v. 175, p. 156–167, nov. 2018.

TZUTALIN. **Labellmg**. Git code (2015). <https://github.com/tzutalin/labellmg>.

VIOTTO, G. F. V. et al. Evaluation of losses in the cotton harvest at different speeds. **Scientific Electronic Archives**, v. 11, p. 48–55, 2018.

WAN, P. et al. A methodology for fresh tomato maturity detection using computer vision. **Computers and Electronics in Agriculture**, v. 146, p. 43–50, mar. 2018.

WEI, J. et al. Research on the Segmentation Strategy of the Cotton Images on the Natural Condition Based upon the HSV Color-Space Model. v. 1, n. 20, p. 34–38, 2008.

XU, R. et al. Aerial Images and Convolutional Neural Network for Cotton Bloom Detection. **Frontiers in Plant Science**, v. 8, p. 1–17, 16 fev. 2018.

YEOM, J. et al. Automated Open Cotton Boll Detection for Yield Estimation Using Unmanned Aircraft Vehicle (UAV) Data. **Remote Sensing**, v. 10, n. 12, p. 1–20, 27 nov. 2018.

---

### **CAPÍTULO 3 – CONSIDERAÇÕES FINAIS**

Com base nos resultados obtidos, pode-se considerar que:

É possível contar a quantidade de capulhos presentes em uma imagem adquirida do dossel da cultura do algodão e, assim, prever a produtividade por meio da utilização de redes neurais convolucionais. No trabalho proposto conseguimos através do uso do modelo SSD Mobilenet V1 prever a produtividade da cultura do algodão, independente das condições do ambiente e horário de aquisição de imagens. Esses resultados são bastante promissores quando se vislumbra a possibilidade de se trabalhar com regulagem das colhedoras de algodão em tempo real. Aqui apresentamos algumas sugestões para o desenvolvimento de trabalhos futuros:

- Obter informações da massa média de capulhos para variedades de algodão em função dos terços, inferior, médio e superior.
- Aumentar o número de imagens do conjunto de dados, principalmente adicionando imagens de variedades de algodão.
- Incluir o ajuste aleatório de brilho, contraste e saturação no aumento de dados para o treinamento do modelo.
- Para o monitoramento da operação de colheita mecanizada no período noturno, verificar a viabilidade da utilização de imagens adquiridas com flash ou luz negra para destacar os capulhos.
- Desenvolvimento de algoritmos capazes de medir as dimensões e a profundidade de capulhos de algodão nas imagens, visto que a massa de cada capulho é maior no terço inferior da planta.
- Para o modelo SSDLITE Mobilenet V2 na etapa de treinamento utilizar maiores valores do tamanho de lote, pois acreditamos que poderá melhorar o desempenho da detecção.

Por fim, em estudos futuros avaliaremos o desempenho do nosso sistema para realizar a contagem dos capulhos durante a operação de colheita mecanizada e prever a produtividade da cultura do algodão em tempo real, possibilitando a regulagem da colhedora de forma mais efetiva, de modo a minimizar as perdas durante a operação.