

POLIANA MARIA DA COSTA BANDEIRA

**ESTIMATIVA DE PRODUTIVIDADE DA CULTURA DA SOJA UTILIZANDO
TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

Orientador: Flora Maria de Melo Villar

Coorientadores: Francisco de Assis de C. Pinto
Felipe Lopes da Silva

**VIÇOSA - MINAS GERAIS
2022**

**Ficha catalográfica elaborada pela Biblioteca Central da
Universidade Federal de Viçosa - Campus Viçosa**

T

B214e
2022

Bandeira, Poliana Maria da Costa, 1996-
Estimativa de produtividade da soja utilizando técnicas de
inteligência artificial / Poliana Maria da Costa Bandeira. - Viçosa, MG,
2022.

1 dissertação eletrônica (50 f.): il. (algumas color.).

Inclui apêndices.

Orientador: Flora Maria de Melo Villar.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Engenharia Agrícola, 2022.

Referências bibliográficas: f.42-44.

DOI: <https://doi.org/10.47328/ufvbbt.2022.102>

Modo de acesso: World Wide Web.

1. Aprendizado profundo (Aprendizado do computador).
2. Imagens digitais - Bancos de dados. 3. Smartphones. I. Villar, Flora
Maria de Melo, 1986-. II. Universidade Federal de Viçosa.
Departamento de Engenharia Agrícola. Programa de Pós-Graduação em
Engenharia Agrícola. III. Título.

CDD 22. ed. 006.31

Bibliotecário(a) responsável: Renata de Fátima Alves CRB6/2578


POLIANA MARIA DA COSTA BANDEIRA

**ESTIMATIVA DE PRODUTIVIDADE DA SOJA UTILIZANDO TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

APROVADA: 21 de fevereiro de 2022

Assentimento:



Poliana Maria da Costa Bandeira
Autora



Flora Maria de Melo Villar
Orientadora

*Aos meus pais, Jerônimo Rosado Bandeira Neto e
Kátia Maria da Costa Bandeira, por todo amor,
carinho, confiança, amor e investimento.*

Dedico.

AGRADECIMENTOS

Primeiramente a Deus, sem Ele nada disso seria possível. Por todos os momentos de aflição onde era a Ele que eu recorria e momentos de alegria que a Ele eu agradecia.

À Universidade Federal de Viçosa e ao Programa de Pós-Graduação em Engenharia Agrícola, pela oportunidade em aumentar o meu saber, por todo apoio para desenvolvimento desta pesquisa e obtenção do título de mestrado.

Ao departamento de Agronomia da Universidade Federal de Viçosa, pela área cedida para realização do experimento.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de estudos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos.

À Professora Dr^a. Flora Maria de Melo Villar, por todo ensinamento prestado, amizade, dedicação a este trabalho e paciência. Agradeço por me incentivar e buscar a melhor pesquisadora que há em mim, contribuindo, inclusive, para meu crescimento pessoal.

Aos Coorientadores, Professor Dr. Francisco de Assis de Carvalho Pinto e o Professor Dr. Felipe Lopes da Silva pelos conselhos, por todo conhecimento que me foi passado e por toda ajuda prestada para que a pesquisa fosse finalizada.

Ao membro externo da banca examinadora, Professor Dr. Elpídio, por aceitar o convite e por todo conhecimento depositado neste trabalho.

Aos meus pais, Jerônimo Rosado Bandeira Neto e Kátia Maria da Costa Bandeira, por todo investimento e sacrifício para que eu pudesse buscar meus sonhos. Obrigada pela confiança, incentivo e amor que me deram.

As minhas irmãs, Patrícia Bandeira e Priscila Bandeira, pela amizade, preocupação, apoio e incentivo. Obrigada por toda força e estímulo que me passaram!

A meus amigos que me incentivaram, mesmo de longe, a continuar e persistir durante esses dois anos. Em especial Tarcilany, Ana Luiza, Rutenny, Clícia e Diego.

Aos professores Dr. Suedêmio de Lima Silva e Dr. Joaquim Odilon, por me ajudarem durante a graduação e me incentivarem a vir realizar o mestrado na UFV.

A todos os colegas do laboratório de mecanização agrícola (LMA) que me ajudaram e contribuíram para o desenvolvimento desta pesquisa. Em especial Carol, Beatriz, Charles, Flávio, Pedro, Marcelo e Inglieth.

A todos os professores e funcionários desta universidade que, de alguma forma, colaboraram nesta conquista.

Muito obrigada a todos os colegas que, por um lapso de memória, não foram citados, mas que contribuíram para que eu pudesse chegar até o fim.

Por fim, a todos aqueles que prestaram ajuda em meus momentos de dificuldade e que ficaram felizes em meus momentos de alegria. Muito Obrigada!

“A competitividade de um país não começa nas indústrias ou nos laboratórios. Ela começa na sala de aula.”
(Lee Iacocca)

BIOGRAFIA

POLIANA MARIA DA COSTA BANDEIRA, filha de Kátia Maria da Costa Bandeira e Jeronimo Rosado Bandeira Neto, nasceu em Mossoró, Rio Grande do Norte, no dia 25 de setembro de 1996. Em fevereiro de 2020, concluiu o curso de Bacharel em Engenharia Agrícola e Ambiental na Universidade Federal Rural do SemiÁrido (UFERSA), Campus Mossoró. Em março de 2020, iniciou o curso de Mestrado em Engenharia Agrícola, área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa (UFV), submetendo-se à defesa de dissertação em fevereiro de 2022.

RESUMO

BANDEIRA, Poliana Maria da Costa, M.Sc., Universidade Federal de Viçosa, fevereiro de 2022. **Estimativa de produtividade da soja utilizando técnicas de inteligência artificial.** Orientadora: Flora Maria de Melo Villar. Coorientadores: Francisco de Assis de Carvalho Pinto e Felipe Lopes da Silva.

A estimativa de produtividade de culturas agrícolas visa as definições econômicas acerca da cultura, gestão agrícola, uso de terras, entre outros. Porém, é comum observar o uso de métodos convencionais para estimar a produtividade da cultura da soja, tornando o processo lento, oneroso e susceptível a erros humanos. Portanto, objetivou-se desenvolver um modelo, com base em aprendizagem profunda, para realizar a estimativa de produtividade da soja, utilizando imagens digitais obtidas por meio de um dispositivo móvel. Para isso, foi analisado a capacidade do modelo proposto de classificar corretamente as vagens que possuem diferentes números de grãos, realizar a contagem do número de vagens e grãos e, então, estimar a produtividade da cultura da soja. Para construção do banco de dados foram realizadas duas diferentes formas de aquisição de imagens, nomeadas como aquisição de imagens 1 (AI1) e aquisição de imagens 2 (AI2). Na AI1, foram obtidas imagens das plantas intactas e recém retiradas da área experimental, em que as mesmas apresentavam folhas, ramos e vagens. Para realizar a captura da imagem com a planta intacta foi construída uma estrutura para posicionar o dispositivo móvel e, logo a frente, a amostra (planta), com distância fixa de um metro entre o dispositivo móvel e a planta. Já as imagens obtidas por meio da AI2, foram oriundas de vagens destacadas da planta e depositadas em uma bandeja de fundo branco. Para uma mesma planta, imagens foram obtidas pelos métodos AI1 e AI2. O experimento foi realizado em duas cultivares de soja, TMG 7063 IPRO (cultivar 1) e TMG 7363 RR (cultivar 2). A fim de possibilitar o uso em campo do modelo desenvolvido, o procedimento de captura das imagens foi realizado em campo, a fim de expor as amostras às adversidades que não ocorreriam em ambiente com luminosidade controlada. Para estimar a produtividade da cultura da soja, o modelo deverá ser capaz de distinguir as vagens que possuem diferentes números de grãos, para, em seguida, contar o número de vagens e grãos presentes na planta. A avaliação do modelo se deu em três etapas, a primeira foi a avaliação quanto a classificação, utilizando as métricas de precisão, a sensibilidade e a pontuação F1. Na segunda etapa, foi avaliada a capacidade do modelo em contar corretamente o número de vagens e grãos em comparação

aos dados contados manualmente. A determinação do erro entre os dois valores, manuais e previstos, foi calculado pelo Erro Percentual Absoluto Médio (MAPE). De maneira semelhante, a validação da estimativa de produtividade ocorreu entre a comparação dos valores reais, que foi realizado com o método convencional e os valores previstos, que foi realizado pelo modelo. Em seguida, foi calculado o MAPE para determinar o erro presente na estimativa de produtividade determinada pelo modelo. Os resultados alcançados pelo modelo ao utilizar os dados obtidos pela AI1 na classificação para a métrica pontuação F1 foram de 22,22%, 52,31%, 65,93% e 3,13% para as classes “um”, “dois”, “três” e “quatro”, respectivamente. Já o valor do MAPE, para os dados da AI1, apresentado na contagem de vagens e grãos, bem como, na estimativa de produtividade foram de 34,69% (vagens) e 35,25% (grãos), 44,76% (cultivar 1) e 32,73% (cultivar 2). Os valores, para classificação, alcançados pelo modelo ao utilizar os dados obtidos pela AI2 foram de 31,58%, 75,63%, 90,51% e 21,62% para as classes “um”, “dois”, “três” e “quatro”, respectivamente. O MAPE para contagem de vagens e grãos e, também, estimativa de produtividade com os dados da AI2 foram de 7,50% (vagens) e 5,32% (grãos), 6,29% (cultivar 1) e 5,50% (cultivar2). Sendo assim, em todas as métricas empregues neste artigo, o modelo alcançou o melhor desempenho ao utilizar os dados obtidos por meio da AI2 se comparado com os dados da AI1. Além disso, entre as cultivares analisadas, a cultivar 2 (TMG 7363 RR) apresentou o menor erro na estimativa de produtividade em ambos métodos de aquisição de imagens analisadas neste trabalho.

Palavras-chave: Aprendizado profundo. Aquisição de imagens. Dispositivo móvel

ABSTRACT

BANDEIRA, Poliana Maria da Costa, M.Sc., Universidade Federal de Viçosa, February, 2022. **Soybean yield estimation using artificial intelligence techniques.** Adviser: Flora Maria de Melo Villar. Co-advisors: Francisco de Assis de Carvalho Pinto and Felipe Lopes da Silva.

The estimation of business productivity as business, among other uses of culture, management. However, the use of conventional methods to estimate soybean yield is observed, making the process slow, costly and common, susceptible to human errors. Therefore, the objective is to develop a model, based on deep learning, to perform an estimate of soybean productivity, using images projected through a mobile device. For this, they have the capacity of the proposed model to correctly classify as pods that different numbers of grains, perform the count of the number of pods and grains and, then, estimate soybean yield. To build the database, two different forms of image acquisition (AI1) and image acquisition 2 (AI2) were performed. In AI1, images of intact plants from the experimental area were taken, branches and images of the experimental area were drawn. To capture the image with the plant intact, a structure was built to position the mobile device and, immediately in front, the sample (plant), with a fixed distance of one meter between the mobile device and the plant. The images with a white background. For the same plant, images were found AI1 and AI methods. The experiment was carried out on two soybean cultivars, TMG 7063 IPRO (cultivar 1) and TMG 7363 RR (cultivar 2). In order to make possible the use in the field of the developed, the procedure of capturing the images was carried out in the field, an export purpose as it occurs with adversities in an environment with controlled luminosity. To estimate soybean yield, the model must be able to distinguish pods that have different numbers of grains, and then count the number of pods and grains in the plant. A three-step evaluation model, the first evaluation and classification, using sensitivity as a measure of precision and the F1 evaluation, which is the evaluation of precision and sensitivity. In the second operation, the model's ability to correctly count the number of variables compared to manually counted data was made. The determination of the error between the two values, manual and predicted, was by the Absolute Mean calculation (MAPE). Similarly, a validation of the estimation of reais, which was performed manually, with the conventional method and the predicted values, which was performed by the predicted model. Then, the MAPE was calculated to determine the error presented in the determination estimate determined by the model. The results selected by the model when using the data pela1 in the

classification for an evaluated metric F1 were 22.2%, 52.31% 65.93% and 3.1% for classes "two", "three" and " four", respectively. The MAPE presentation error, for AI1 data, in the count of pods and grains, as well as in the yield estimate were 34.69% (pods) and 35.25% (grains), 44.76% (cultivate 1) and 32.73% (cultivate 2). As for theOs, for classification, the data selected by the model to be used by the values obtained by AI2 were 31.58%, 75.6%, 90.51% and 21.62% for classes "one", "two", "Three" and "four", respectively. The MA for counting pods and grains and, also for the AI, yield estimation with the data were 7.50% (pods) and 5.32% (grains), 6.2% (cultivar 1) and 5.50 % (cultivate2). Thus, as measurements used in the article used, the model used reached the best performance obtained through AI2 when compared with the data from AI1. Furthermore, among cultivars in work, cultivar 2 (73633) presented the smallest error in the yield estimation of both image acquisition methods.

Keywords: Deep learning. Image acquisition. Mobile device

SUMÁRIO

1. INTRODUÇÃO.....	13
2. OBJETIVOS.....	15
2.1 Objetivo Geral	15
2.2 Objetivos Específicos	15
3. MATERIAL E MÉTODOS.....	15
3.1 Construção do banco de dados	16
3.2 Pré-processamento	18
3.3 Treinamento do modelo	21
3.4 Estimativa de produtividade	21
3.5 Avaliação do modelo	22
3.5.1 Classificação	22
3.5.2 Contagem do número de vagens e grãos e estimativa de produtividade	24
3.6 Ambiente de execução	24
4. RESULTADOS	25
4.1 Classificação e detecção de objetos	25
4.2 Avaliação da contagem do número de vagens e grãos.....	31
4.2 Estimativa de produtividade.....	35
5. DISCUSSÃO.....	36
6. CONCLUSÃO.....	41
7. REFERÊNCIAS	42
8. APÊNDICES	45

1. INTRODUÇÃO

A estimativa da produtividade de *commodities*, como a cultura da soja, é uma questão estratégica para empresas agroindustriais, agricultores e para o próprio governo, pois impactam diretamente na economia do País (RAMOS et al., 2017). A importância que a estimativa de produtividade possui se dá pelo papel que a mesma detém sobre o gerenciamento e segurança alimentar (TERLIKSIZ; ALTYLAR, 2019), estabelecendo, inclusive, definições de preços futuros para produções agrícolas.

Para estimar a produtividade da soja utiliza-se métodos convencionais, que podem ser realizados de formas diferentes. Um dos métodos seria a estimativa com base na massa a partir de uma área conhecida. As plantas dessa área são colhidas e os grãos pesados, porém, esse método é aconselhado apenas no estágio reprodutivo R8. Outro método, consiste na contagem manual do número de vagens por planta e de grãos por vagem, bem como, a massa de 1000 grãos determinada pela empresa detentora da cultivar, sendo esse método viável para realizar a estimativa de produtividade da soja nos estádios R6 e R7.

No entanto, ambos os métodos citados possuem limitações, pois realizar a estimativa em R8 se torna empecilho caso haja necessidade de antecipar a colheita. Já o método que é realizado com os estádios R6 e R7, torna-se uma atividade tediosa, cansativa e sujeita a erros humanos. Assim, a qualidade e rapidez da estimativa de produtividade da soja se tornam dependentes do estágio reprodutivo que a planta se encontra e da habilidade e cansaço humano. Dessa forma, o desenvolvimento de métodos não manuais que sejam precisos, torna-se necessário para que o processo de estimativa de produtividade da cultura da soja seja eficiente e que não dependa do operador ou estágio reprodutivo em que a planta se encontra.

Nos últimos anos, observa-se o surgimento de métodos não convencionais para realizar a estimativa de produtividade da soja (ALVES et al., 2018; CHAN; WEI; MOLIN, 2020; MILLER et al., 2018). Esses métodos, apesar de apresentarem eficiência, possuem limitações, pois necessitam de equipamentos específicos para obtenção dos dados, que podem apresentar custo elevado ao produtor quando comparado ao método convencional, ou dados que restringem o seu uso devido a necessidade de informações de safras anteriores.

Recentemente, observa-se um crescente uso do aprendizado profundo da máquina para solucionar problemas que compreendem a classificação de imagens, processamento de vídeos e reconhecimento de voz, entre outros (PERUGACHI-DIAZ; TOMCZAK; BHULAI, 2021). O aprendizado profundo da máquina extrai diversas características inerentes do objeto de interesse, possibilitando o reconhecimento e classificação de objetos. Esse tipo de recurso é

possível em virtude das redes neurais convolucionais (CNNs) presentes nos modelos de aprendizagem profundo. As CNNs surgiram como um método promissor para o reconhecimento de padrões em imagens, pois são capazes de produzir filtros que auxiliam na previsão de classes que estejam associadas às imagens de treino (MAXWELL; POURMOHAMMADI; POYNER, 2020). Para estimar a produtividade da soja, a partir do uso de modelos de aprendizagem profunda com base em CNNs alguns trabalhos já foram realizados (SUN et al., 2019; TERLIKSIZ; ALTYLAR, 2019). No entanto, para utilizar os modelos já existentes, são necessários dados de difícil acesso ou com custo econômico elevado, como imagens de satélites e dados de safras antecedentes.

Os modelos de aprendizagem profunda (GIRSHICK, 2015; HE et al., 2018; REN et al., 2016) já possuem predominância no âmbito agrícola e são utilizados para realizar, principalmente, classificação de objetos por meio de processamento de imagens digitais. Os procedimentos agrícolas são diversos, como detecção de doenças em culturas agrícolas (KAUR; PANDEY; GOEL, 2019; ZHANG et al., 2019), avaliação da qualidade e contagem de frutos (HAN et al., 2021; VASCONEZ et al., 2020), estimativa de produtividade de citrus, milho e soja (APOLO-APOLO et al., 2020; KHAKI; WANG; ARCHONTOULIS, 2020) e para realização da colheita com máquinas robotizadas, construindo equipamentos com visão computacional (GANESH et al., 2019; YU et al., 2019).

Dentre os diversos modelos de aprendizagem profunda, tem-se destacado o modelo *Mask R-CNN*. Este modelo apresenta alta eficiência na segmentação de instância sendo, inclusive, considerado o que representa o estado da arte na área de segmentação de instância (HE et al., 2018). Esse tipo de segmentação trata da detecção de um objeto individual dentro de um grupo de objetos similares, sendo importante quando é necessário detectar diferenças dentro de uma mesma classe. O algoritmo *Mask R-CNN* é uma extensão do modelo *Faster R-CNN*, porém, o *Mask R-CNN* possui um ramo de previsão de máscaras. Este ramo se trata de uma rede totalmente convolucional que é aplicada em cada região de interesse e, dessa forma, é gerada a máscara de segmentação para, em seguida, ocorrer a classificação do objeto. Assim, o modelo *Mask R-CNN* vem se consolidando na agricultura e mostrando o seu potencial para uso em processos agrícolas (DE CARVALHO et al., 2021; LEE et al., 2020; MEKHALFI et al., 2021; VALICHARLA, 2021).

Os modelos de aprendizagem profunda tendem a dar uma percepção humana à máquina, tornando-a capaz de realizar atividades que são comuns para a visão humana. Dessa forma, as imagens digitais são dados essenciais para treinamento do algoritmo e seu posterior uso. As imagens utilizadas como dados de entrada dos modelos, podem ser obtidas por câmeras

hiperespectrais e multiespectrais com um ou mais sensores. Os sensores utilizados em câmeras hiperespectrais e multiespectrais com mais de um sensor apresentam custo elevado em relação a câmeras multiespectrais de sensor único. Os dispositivos móveis (*smartphones*), por exemplo, possuem câmeras multiespectrais de sensor único, que são sensíveis apenas ao espectro visível e apresentam custo de aquisição inferior às câmeras multiespectrais que possuem mais de um sensor e hiperespectrais.

A utilização dos dispositivos móveis como ferramenta para realizar processos agrícolas gera facilidade, visto que a população em geral possui esse tipo de dispositivo. Os dispositivos móveis já apresentam aplicabilidade nos processos agrícolas, como o uso para estimar rendimento de culturas realizado por Tedesco-oliveira et al. (2020), que compararam modelos que necessitavam de diferentes níveis de demanda computacionais, entre os modelos analisados, o de baixa demanda utilizou um *smartphone* para realizar o processamento das imagens. Ngugi, Abelwahab e Abo-Zahhad (2020) fizeram uso de um dispositivo móvel para capturar imagens de folhas de tomate para realizar a classificação de doenças em folhas. Desta forma, os dispositivos móveis se apresentam como ferramentas capazes de gerar dados confiáveis e de baixo custo econômico para o produtor.

2. OBJETIVOS

2.1 Objetivo Geral:

- Desenvolver modelo, com base em aprendizado profundo, para realizar a estimativa da produtividade da soja em campo, utilizando imagens digitais obtidas por meio de um *Smartphone*.

2.2 Objetivos Específicos:

- Desenvolver e avaliar o desempenho do modelo de aprendizado profundo na classificação de vagens da cultura da soja em relação ao número de grãos que possuem;
- Desenvolver algoritmo para determinar o número médio de vagens e grãos por planta para estimar a produtividade;
- Comparar métodos de obtenção dos dados de entrada e identificar o método que gera o melhor desempenho no modelo.

3. MATERIAL E MÉTODOS

Neste trabalho foram utilizadas duas cultivares de soja, a TMG 7063 IPRO (cultivar 1) e TMG 7363 RR (cultivar 2). A cultivar 1 apresenta tipo de crescimento indeterminado, isto é, mesmo após o início da floração, as plantas ainda apresentam crescimento vegetativo. Além disso, possui excelente potencial produtivo, resistência à ferrugem e resistência moderada ao acamamento. A cultivar 2 apresenta crescimento indeterminado, possui resistência à ferrugem e ao acamamento.

As cultivares foram semeadas em área experimental da Universidade Federal de Viçosa (UFV) em Viçosa-MG. A cultivar 1 ocupou na área experimental um total de 420 m², enquanto a cultivar 2 ocupou 427 m² no total, ambas as cultivares foram semeadas com espaçamento entre linhas de 0,5 m, com média de 13 e 15 plantas por metro linear para a cultivar 1 e 2, respectivamente. A área, que apresentava formato em “L”, foi semeada na data de 02/12/2020, com média de 26 a 30 plantas por 1 m².

Para desenvolver o modelo capaz de realizar a estimativa de produtividade da cultura da soja a partir de imagens digitais obtidas por dispositivo móvel, foram necessárias as seguintes etapas: I) Adquirir imagens para construção do banco de dados, II) Realizar o pré-processamento nas imagens, III) realizar o treinamento do modelo de aprendizagem profunda, e VI) Avaliar modelo.

3.1 Construção do banco de dados

A aquisição das imagens digitais, para construção do banco de dados, ocorreu após 77 dias da semeadura, entre os dias 18 de fevereiro e 04 de março de 2021, com as plantas de soja nos estádios fenológicos entre R6 e R8. A captura das imagens ocorreu em campo, e foram as capturadas no período que compreendia das 8h até as 12h, assim, foi garantido que as imagens possuíam diferentes níveis de luminosidade. As plantas utilizadas no experimento foram selecionadas de forma aleatória, compreendendo plantas de pequeno a grande porte das duas cultivares.

Para aquisição de todas as imagens foi utilizado o mesmo dispositivo móvel (*Smartphone*). O dispositivo possui câmera dupla de 48 megapixels e 5 megapixels, com sensor de 1/2” e abertura de lente de 1.8, todas as outras configurações de câmera foram mantidas no automático. De acordo com as características do dispositivo móvel utilizado, as imagens geradas possuíam tamanho 3000 x 4000 pixels. As configurações do dispositivo móvel permaneceram nessas configurações durante todo o experimento.

Para comparar a eficiência da estimativa da produtividade da soja, dois métodos de aquisição de imagens foram realizados, a partir de imagens da planta contendo folhas e vagens (método AI1) e imagens das vagens isoladas da planta (método AI2). Assim, para a AI1 foram escolhidas, aleatoriamente, plantas na área experimental e, em seguida, as mesmas foram coletadas da área com auxílio de uma tesoura de poda. A escolha das plantas ocorreu de forma que compreendesse plantas de grande, médio e pequeno porte. Assim, o modelo possuiu dados de plantas que compreendem diversos portes para o treinamento. Posteriormente, cada planta (amostra) foi alocada em uma estrutura com fundo branco para ser realizada a captura das imagens (Figura 1a). A estrutura possuía local para posicionar o dispositivo móvel e a planta (Figura 1b). A distância entre a planta e o dispositivo móvel foi fixada em um metro no momento da aquisição das imagens.

Para o método AI2, as vagens foram retiradas da planta, de forma cuidadosa para evitar a abertura das mesmas e possível perda de grãos. Posteriormente, as vagens foram depositadas em uma bandeja branca (Figura 2) para efetuar a captura das imagens. Assim, na bandeja, foram alocadas as vagens de uma só planta por vez. Durante a aquisição das imagens para a AI2, não houve padronização da distância entre a câmera do dispositivo móvel e a bandeja. Então, primeiramente, foi realizada a captura das imagens para a AI1 e, logo após, a captura das imagens para a AI2, utilizando-se as mesmas plantas.




Figura 1. Imagem capturada de vagens de uma só planta com o método de aquisição de imagens 1 (AI1) (a). Estrutura utilizada para posicionamento de amostras com o método de aquisição de imagens 1 (AI1) (b).



Figura 2. Imagem capturada de vagens de uma só planta como método de aquisição de imagens 2 (AI2).

Para captura das imagens, totalizando ambas as cultivares, foram utilizadas 495 plantas da área experimental. Ao unir ambos os métodos de aquisição de imagens, foi gerado um total de 990 imagens. Desse total de imagens, considerando as duas cultivares e as duas formas de aquisição de imagens, foi construído um banco de dados com 46385 vagens.

3.2 Pré-processamento

Cada banco de dados, sendo um da AI1 e outro da AI2, foi, aleatoriamente, subdividido em conjuntos de imagens de treino (80%), teste (10%) e validação (10%). O conjunto de treino foi utilizado para a aprendizagem do modelo. Na etapa de treino, o algoritmo extraiu informações necessárias para ser capaz de classificar o objeto de interesse (vagem). Por isso, na subdivisão dos conjuntos de dados, foi estabelecida maior parcela dos dados para essa etapa, visto que é necessário grande quantidade de amostras para que o modelo se torne apto para classificar os objetos corretamente. Para evitar a tendência do modelo ao *overfitting*, foi utilizado o subconjunto de dados de validação. O *overfitting* ocorre quando o modelo se ajusta demais aos dados de treino, ao ponto de os decorar, se tornando incapaz de alcançar bons resultados em novos dados. Para avaliar o desempenho do modelo foi utilizado o subconjunto

de teste, composto por amostras que não foram usadas no treinamento do modelo, fornecendo um senso imparcial da competência do algoritmo.

O modelo *Mask R-CNN* possibilita o aumento de dados para o treinamento. A técnica de aumento de dados tende a melhorar o desempenho do algoritmo, visto que, gera artificialmente mais imagens para o treinamento (GONZALEZ, 2007). Para implementar o aumento de dados, o algoritmo realizou cópias das imagens. Essas cópias foram rotacionadas, transladadas, modificadas quanto a intensidade dos canais RGB e foram aplicados filtros que geraram ruídos nas imagens. Então, com esse procedimento, dobrou-se o número de dados para o treinamento, que é formado pelo subconjunto de treino e validação. Ao final do processo de aumento de dados, o subconjunto de treino e validação possuía, em sua totalidade, 1776 imagens e 84078 vagens.

Antes de realizar o treinamento do modelo, as imagens foram rotuladas manualmente, destacando os objetos de interesse (vagens), criando uma máscara delimitadora real ao seu redor. A máscara delimitadora real é um polígono que circunda o objeto de interesse, destacando-o do plano de fundo (objetos que não são de interesse). Com isso, o modelo identifica o que é plano de fundo e o que é objeto de interesse. As vagens foram classificadas quanto ao número de grãos que possuíam, assim, as classes foram distribuídas como classe “um”, “dois”, “três” e “quatro”, representando as vagens que possuíam até quatro grãos. A rotulagem foi realizada manualmente por meio do *software* on-line *VGG Image Annotator* (DUTTA; ZISSERMAN, 2019). Nas Figuras 3 e 4 é apresentado um exemplo de máscara gerada a partir dos dados rotulados para a AI1 e AI2, respectivamente.



Figura 3. Exemplo de máscara gerada (à direita) após rotulagem da imagem original (à esquerda) obtida por meio da AI1.




Figura 4. Exemplo de máscara gerada (à direita) após rotulagem da imagem original (à esquerda) obtida por meio da AI2.

3.3 Treinamento do modelo

O modelo desenvolvido, com base no *Mask R-CNN*, foi treinado para realizar a classificação das vagens quanto número de grãos que apresentavam. Em seguida, com base nessa classificação, foram desenvolvidas linhas de código para que o modelo fosse capaz de contar o número de vagens e grãos presentes nas imagens. Por fim, foi possível realizar a estimativa de produtividade das duas cultivares de soja para os dois procedimentos de aquisição de imagens adotados.

O algoritmo foi treinado com base nos dois bancos de dados, uma para a AI1 e outro para a AI2. Foi preparado um treinamento para cada banco de dados, em que todos os parâmetros e tempo de treinamento foram mantidos iguais nos dois treinamentos para a AI1 e AI2.

Para o treinamento do modelo foram necessários dois dados de entrada, o conjunto de dados de treino (imagens de treino e validação) e os rótulos dos dados de treino (rótulos de treino e validação). O treinamento do modelo foi inicializado por meio da técnica de transferência de aprendizagem. A técnica de transferência de aprendizagem é a reutilização de um modelo já treinado em um novo problema. Essa técnica reduz o tempo de treinamento e, na maioria dos casos, melhora o desempenho das redes neurais.

Para o treinamento do modelo, em ambas as aquisições de imagens, foi utilizada a rede residual *backbone* Resnet-101, sendo está uma rede neural profunda do tipo *Feature Pyramid Network* (FPN). A Resnet-101 possui uma arquitetura com 101 camadas de profundidade, sendo capaz de classificar mais de 1000 classes (GHOSAL et al., 2019).

3.4 Estimativa de produtividade

Para estimar a produtividade da soja foram necessárias informações das duas cultivares estudadas neste trabalho, como o número médio de vagens por planta, número médio de grãos por vagem, número de plantas de soja em um hectare e a massa de 100 grãos. O número médio de vagens por planta e o número médio de grãos por vagem foram obtidos a partir do modelo desenvolvido neste trabalho, que realizou a contagem a partir da classificação das vagens. A contagem manual do número de grãos e vagens foi realizada para validar o modelo.

O número de plantas em um hectare foi determinado por amostragem. Para isso, uma linha de plantio de cada cultivar foi selecionada, contando-se o número de plantas em um metro linear. Sabendo que o espaçamento entre linhas é de 0,5 m, foi então determinado o número de plantas para a área de 0,5 m². Em seguida, foi realizado o cálculo para estimativa do número de

plantas em um hectare. A massa de 100 grãos foi obtida por meio de uma balança de precisão, a partir de grãos coletados das plantas na área experimental. Os grãos foram retirados das plantas que já haviam atingido o estágio reprodutivo R8. Além disso, foi aferida a umidade em base úmida dos grãos para que fosse possível o ajuste da massa para a umidade de 13%, para isso foi utilizado a Equação 1. A estimativa da produtividade de soja, para cada cultivar, foi realizada de acordo com a Equação 2. Os valores encontrados para o número de plantas por hectare e a massa de 100 grãos foram igualmente utilizados para a AI1 e AI2.

$$MC \text{ (g)} = MU * \frac{100 - UA \text{ (\%)}}{100 - UD \text{ (\%)}} \quad (1)$$

em que,

MC – massa corrigida para umidade desejada, g;

MU- massa do grão na umidade atual;

UA – umidade atual, %;

UD – umidade desejada, 13%.

$$\text{Prod (sc/ha)} = \frac{\frac{\text{plt}}{\text{ha}} * \frac{\text{vagem}}{\text{plt}} * \frac{\text{grãos}}{\text{vagem}} * MC \text{ (g)}}{6000} \quad (1)$$

em que,

Prod - produtividade da cultura da soja, sc/ha;

plt/ha - número de plantas por hectare;

vagem/plt - valor médio do número de vagens por planta;

grãos/vagem - valor médio do número de grãos por vagem;

MC – massa corrigida para umidade desejada, g.

3.5 Avaliação do modelo

3.5.1 Classificação

A partir da relação entre a classificação real, com base na rotulagem manual, e a prevista pelo modelo, foi possível desenvolver a matriz de confusão que nos informa o desempenho do

modelo, apresentando quantas vagens o modelo detectou corretamente, quantas ele detectou incorretamente e quantas ele foi incapaz de detectar. A partir da matriz de confusão foi possível calcular as métricas de precisão (Equação 2), sensibilidade (Equação 3) e pontuação F1 (Equação 4) para avaliar o desempenho do algoritmo na classificação. A precisão mede a proporção de valores previstos que são de fato valores reais. A sensibilidade mede a proporção de valores reais que o modelo foi capaz de classificar corretamente. Por fim, a pontuação F1 é a média harmônica entre os dois valores, a precisão e a sensibilidade, significando a média de desempenho de uma única classe.

$$P = \frac{VP}{VP + FP} \quad (2)$$

$$S = \frac{VP}{VP + FN} \quad (3)$$

$$F1 = 2 * \frac{P * S}{P + S} \quad (4)$$

em que,

P – Precisão;

S – Sensibilidade;

F1 – Pontuação F1;

VP – Verdadeiro-Positivo;

FP – Falso-Positivo;

FN – Falso-Negativo.

O verdadeiro-positivo (VP) é referente a previsão do modelo coincidindo positivamente com a previsão real. O falso-positivo (FP) ocorre quando o objeto não é de interesse, porém, é previsto como objeto de interesse. Por último, o falso-negativo (FN) ocorre quando há objeto de interesse na imagem, porém ele não é detectado ou é classificado de forma incorreta.

Para a detecção do modelo ser confirmada como positiva, foi estipulado um limiar para a relação entre máscara real e prevista. Assim, valores abaixo desse limiar foram considerados detecções negativas e valores a partir do limiar foram considerados detecções positivas. O valor limite estabelecido foi de 0,5, sendo este um valor mínimo para considerar uma detecção positiva (HE et al., 2018). Para determinar a relação entre máscara real e prevista, calculou-se a intersecção sobre a União (IoU). Os valores de IoU para cada detecção acima de 0,5, foram

considerados detecções positivas. O IoU (Equação 5) é determinado pela razão entre a área de sobreposição entre as máscaras delimitadoras reais e previstas e a sua área de união, representando a precisão da detecção a partir do limiar selecionado.

$$\text{IoU} = \frac{\text{Máscara da detecção} \cap \text{Máscara da Rotulagem}}{\text{Máscara da detecção} \cup \text{Máscara da Rotulagem}} \quad (5)$$

3.5.2 Contagem do número de vagens e grãos e estimativa de produtividade

Os resultados de contagem do número de vagens e grãos e a estimativa de produtividade são valores numéricos, portanto, foram avaliados com métrica de regressão linear por meio do Erro Percentual Absoluto Médio (MAPE). Essa métrica, MAPE, é uma métrica comumente utilizada para avaliar estimativa de produtividade em outras culturas agrícolas (NEVAVUORI; NARRA; LIPPING, 2019; TEDESCO-OLIVEIRA et al., 2020). O MAPE (Equação 6) fornece um valor em porcentagem e, quanto menor este valor, melhor o desempenho do modelo em realizar as estimativas de produtividade e contagem de vagens e grãos se comparado ao método convencional.

$$\text{MAPE} = \frac{100}{n} * \sum_{t=1}^n \left| \frac{C_{\text{real}} - C_{\text{prevista}}}{C_{\text{real}}} \right| \quad (6)$$

em que,

n - Número total de amostras;

C_{real} - valores reais de contagem de grãos e vagens e produtividade;

C_{prevista} - valores previstos pelo modelo da contagem de grãos e vagens e da produtividade.

3.6 Ambiente de execução

Por se tratar de modelo de aprendizagem profunda há grande necessidade de memória computacional. Por isso, o experimento foi conduzido no ambiente de execução do *Google Colaboratory* (Colab). O Colab é um serviço que possibilita a desenvolvimento de modelos de aprendizagem de máquina e aprendizado profundo da máquina e que proporciona o armazenamento em nuvem. Este é um serviço gratuito e com opções de *hardware*, como GPUs e TPUs (Bisong, 2019). Para o desenvolvimento deste trabalho, no momento de treinamento, foi utilizada a GPU Tesla T4 com 16 GB de memória RAM e processador EPYC 7V12 (Rome). Para a validação com o subconjunto de teste foi utilizada apenas a CPU disponibilizada pelo Colab.

4. RESULTADOS

Neste trabalho foi proposto o desenvolvimento de um modelo de aprendizagem profunda, com base no *Mask R-CNN*, que fosse capaz de estimar a produtividade de soja por meio de imagens de dispositivo móvel. Além disso, avaliou-se a capacidade do modelo em distinguir as classes determinadas de acordo com o número de grãos por vagem e a contagem de grãos e vagens. Ao final, com os dados da contagem, foi estimada a produtividade para as duas cultivares estudadas.

A avaliação dos resultados gerados pelo modelo foi realizada para os dois procedimentos de aquisição de imagens, AI1 e AI2. As mesmas métricas avaliativas foram aplicadas para ambos procedimentos. Assim, foi possível determinar aquele cujo modelo apresentou melhor desempenho. Ao final, observou-se que o modelo alcançou melhores resultados para a classificação, contagem do número de vagens e grãos e para estimativa de produtividade das duas cultivares de soja estudadas ao utilizar os dados obtidos por meio da AI2.

4.1 Classificação e detecção de objetos

Os dados resultantes das detecções do modelo, a partir dos dados da AI1 e AI2, foram sistematizados em forma de matriz de confusão (Tabelas 1 e 2). Por meio da matriz de confusão é possível identificar quantas vagens o modelo classificou corretamente e quantas ele não classificou corretamente para cada aquisição de imagens estudada neste trabalho. Os valores apresentados nas matrizes de confusão foram utilizados para realizar os cálculos da precisão e sensibilidade, para em seguida realizar o cálculo da pontuação F1.

Foi observado que, ao utilizar a AI1, o modelo apresentou diversas falhas para detecção das quatro classes (Tabela 1). Por outro lado, com a AI2 (Tabela 2), o modelo alcançou melhores resultados se comparado a AI1, atingindo valores melhores de classificação, principalmente, das classes “dois” e “três”.

Tabela 1. Matriz de confusão gerada a partir dos dados previstos e reais sobre o subconjunto de teste com AI1

Valores Reais	Valores Previstos			
	Um	Dois	Três	Quatro
Um	10	18	1	-
Dois	11	311	109	-
Três	5	133	961	7
Quatro	-	-	20	1

Tabela 2. Matriz de confusão gerada a partir dos dados previstos e reais sobre o subconjunto teste com AI2

Valores Reais	Valores Previstos			
	Um	Dois	Três	Quatro
Um	12	23	2	-
Dois	-	480	129	-
Três	-	48	1645	8
Quatro	-	-	46	8

Além dos dados localizados e classificados, foi possível determinar a quantidade de dados que o modelo não foi capaz de localizar na imagem e realizar a classificação, isto é, os falsos positivos. Para o procedimento da AI1 os valores não detectados para as classes “um”, “dois”, “três” e “quatro” foi de 54,68%, 40,72%, 39,36% e 62,50%, respectivamente. Enquanto os dados a partir da AI2, alcançou valores de não detectados para as classes “um”, “dois”, “três” e “quatro” de 42,19%, 15,18%, 6,18% e 6,89%, respectivamente.

Os resultados para AI1 e AI2 a partir das métricas de precisão, sensibilidade e pontuação F1 estão apresentados na Figura 5a, 5b e 5c, respectivamente. O modelo apresentou os melhores resultados para a AI2 se comparado a AI1. Esse fato pode ter sido provocado pela AI1 possuir objetos que cobrem as vagens, como as folhas e galhos, prejudicando a classificação correta.

Além disso, entre as quatro classes analisadas, observa-se que para as classes “dois” e “três” o modelo apresentou melhores desempenhos em ambas as formas de aquisição de imagens em todas as métricas analisadas.

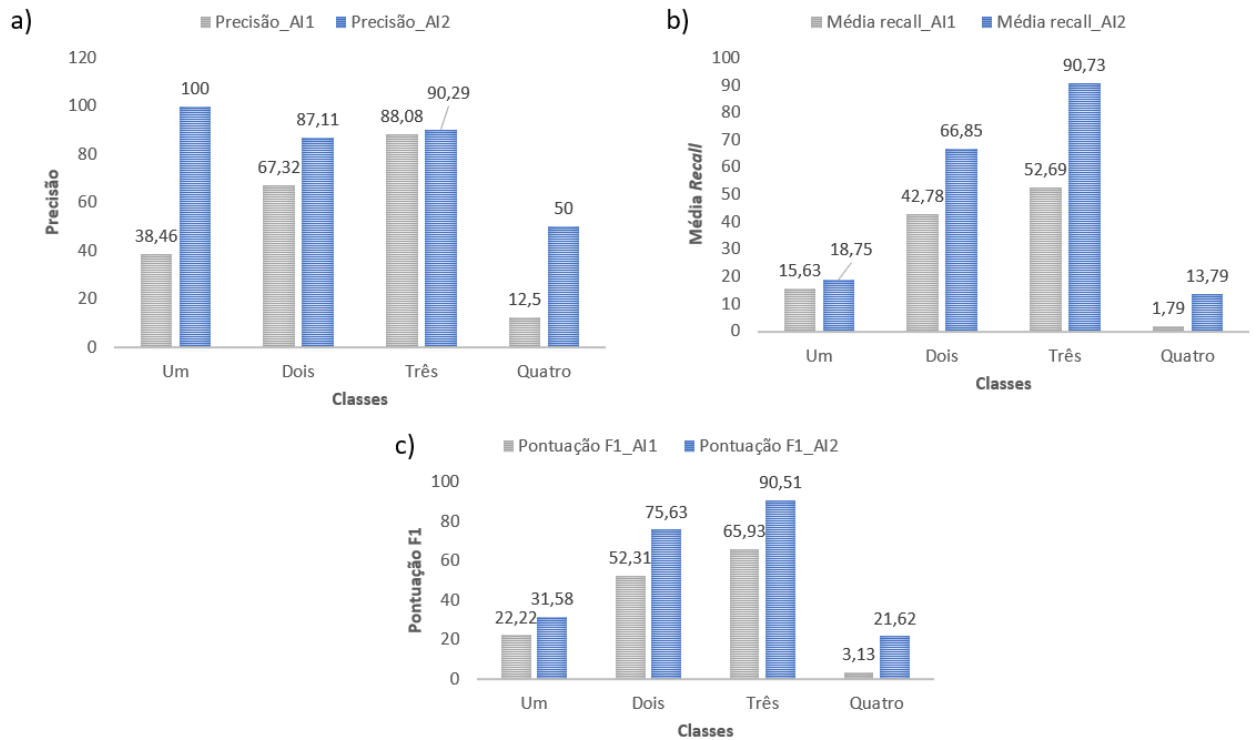


Figura 5. Desempenho do modelo quanto a classificação com base nas métricas de precisão (a), sensibilidade (b) e pontuação F1 (c) para ambos os métodos de aquisição de imagens, AI1 e AI2.

A Figura 6 apresenta o desempenho do modelo ao utilizar os dados obtidos pela AI1 em situações de difícil classificação. Em ambas as figuras (Figura 6a e 6b) os galhos impediam, praticamente, toda a visibilidade da vagem, fato esse que dificulta a classificação do modelo. Porém, para os casos expostos nas Figuras 6a e 6b, além de localizar a vagem, o modelo foi capaz de classificá-la corretamente com base no número de grãos.

a)



b)




Figura 6. Exemplos de classificação do modelo com interferência de galhos ou folhas ao utilizar o método AI1.

A Figura 7 apresenta as principais falhas do modelo ao classificar as imagens do método AI1. Por vezes, os objetos de fundo, como folhas e galhos, foram classificados pelo modelo como sendo objetos do primeiro plano, sendo assim, vagens.

a)



b)



Figura 7. Exemplo de falhas na classificação do modelo ao utilizar o método AI1.

4.2 Avaliação da contagem do número de vagens e grãos

Com os subconjuntos de teste de AI1 e AI2 foi realizada uma regressão linear entre as contagens de vagens e grãos observadas e as estimadas pelo modelo (Figura 6). O coeficiente de determinação (R^2) pode variar de 0 a 1. O R^2 próximo ao valor 1 aponta que, possivelmente, os valores previstos estão coincidindo com os valores reais.

Nas Figuras 8a e 8b, valores de R^2 de 0,4921 e 0,5062 para contagem do número de vagens e grãos, respectivamente, representam o quão distante foram os valores previstos dos reais quando o modelo utilizou as imagens da AI1. Em contrapartida, se comparado com a AI1, a AI2 obteve bons resultados do R^2 , como é exposto nas Figuras 8c e 8d, com valores de R^2 de

0,9615 e 0,9591 para vagens e grãos, respectivamente. Dessa forma, o modelo apresentou falha para contagem de vagens e grãos devido ao uso dos dados da AI1.

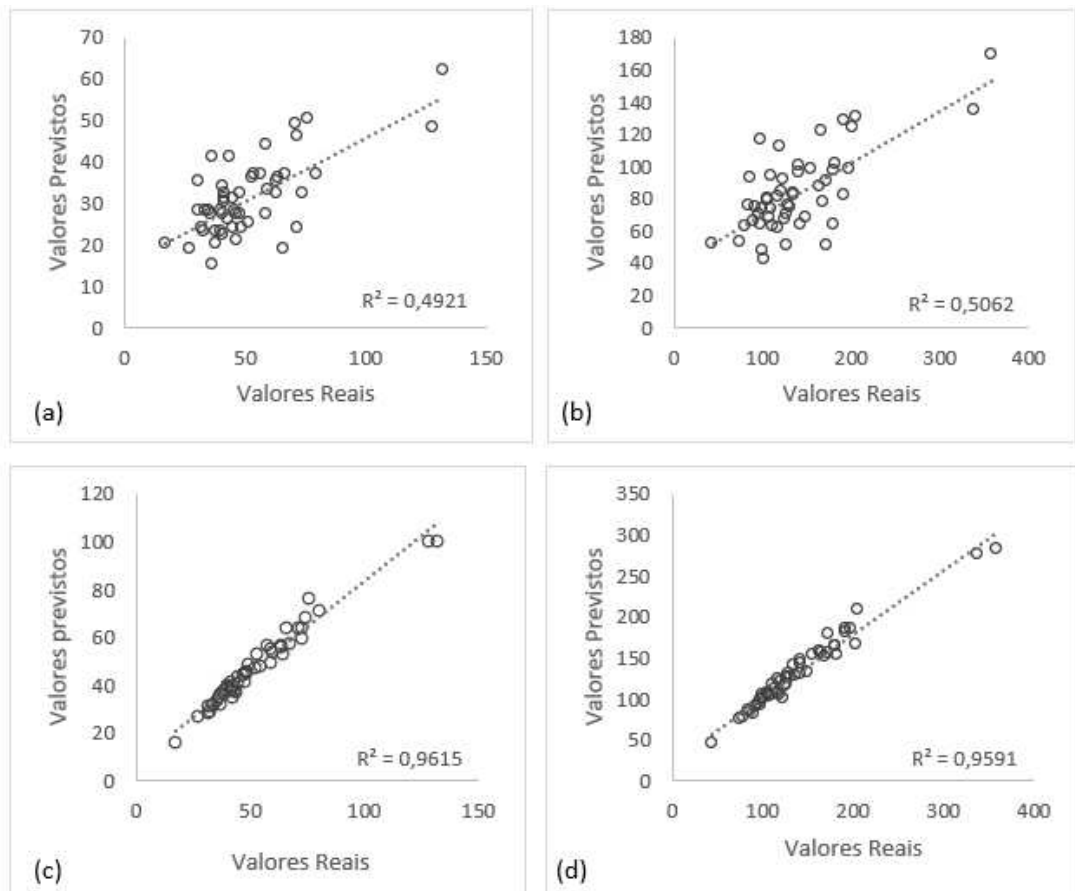


Figura 8. Regressão linear entre a contagem dos valores reais e previstos do número de vagens (a) e grãos (b) para AI1 e vagens (c) e grãos (d) para a AI2.

Na Figura 9 é apresentado, para cada imagem do subconjunto de teste, um erro percentual absoluto para os valores reais e previstos da contagem de grãos e vagens. Ao realizar o MAPE sobre todo o conjunto da AI1, tem-se os valores de 34,69% e 35,25% para vagens e grãos, respectivamente. Por outro lado, o modelo ao utilizar a AI2, apresentou sobre todo seu subconjunto de teste, o MAPE de 7,50% e 5,32% para vagens e grãos, respectivamente.

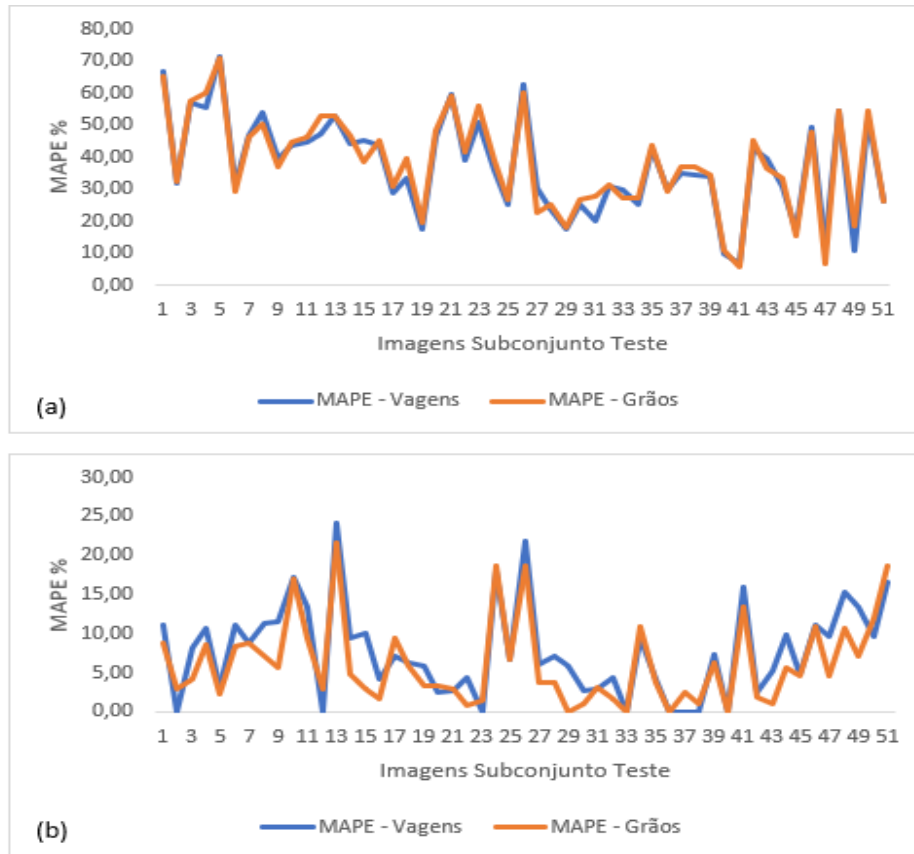


Figura 9. MAPE (Erro Percentual Absoluto Médio) das imagens do subconjunto de teste entre as contagens reais e previstas do número de vagens e grãos para a AI1 (a) e AI2 (b).

Nos dados gerados pelo método AI1, foi observado que algumas imagens apresentaram elevada diferença entre a contagem manual e prevista pelo modelo para o número de vagens e grãos, enquanto outras imagens apresentaram a diferença de forma branda. Na Figura 10a é apresentada uma planta no estágio reprodutivo R6, que possui grande quantidade de folhas e ramos, essa imagem apresentou elevado erro. Já a Figura 10b apresenta a planta em estágio R8, que possui menor quantidade de folhas e ramos, apresentando menor erro. Esse fato, confirma a ação negativa das folhas e ramos na classificação de vagens com base no número de grãos que possuem.

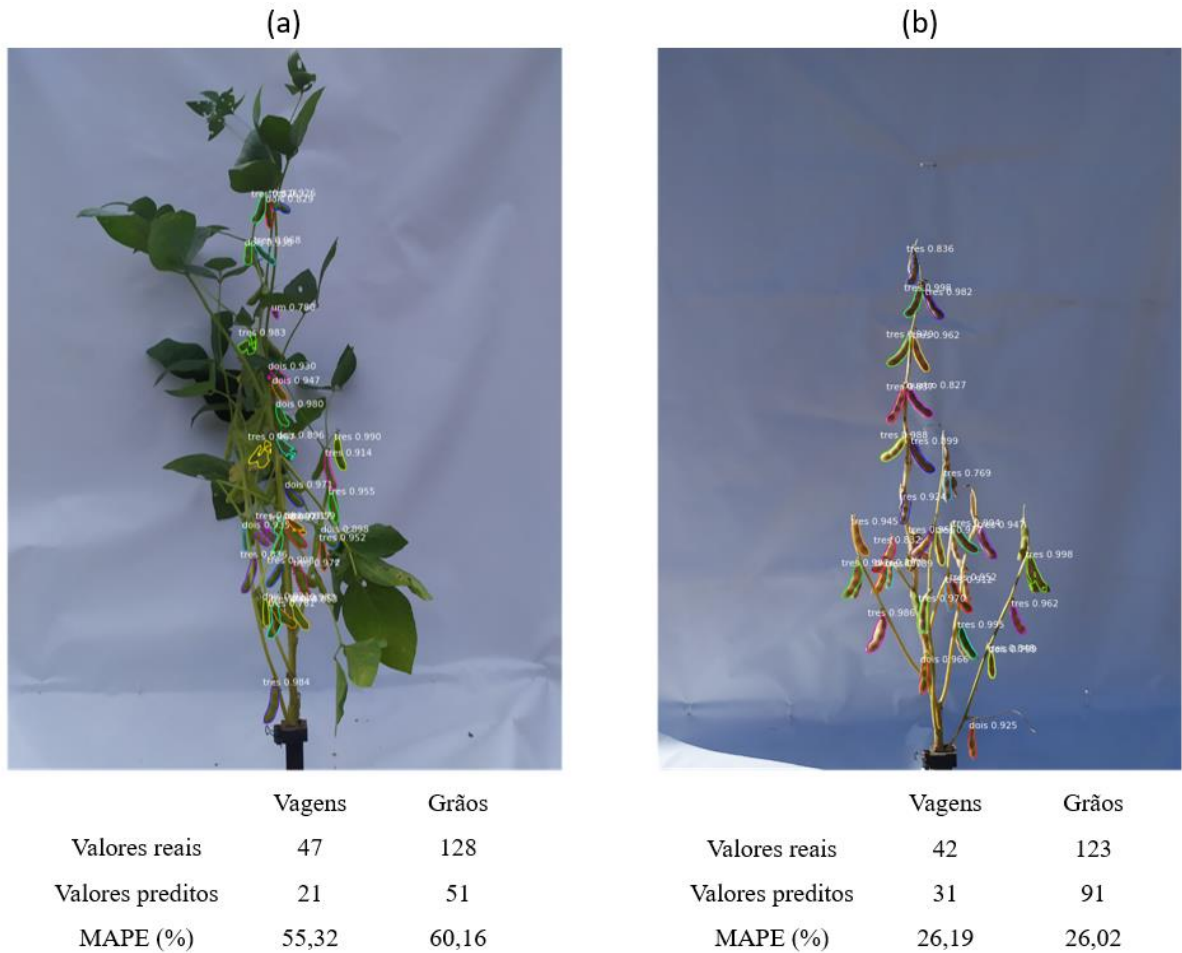



Figura 10. Calculo do MAPE sendo influenciado pelo estágio reprodutivo da planta: (a) planta no R6 com maior quantidade de folhas e ramos. (b) planta no R8 com menor quantidade de folhas e ramos.

Foi observado que a quantidade de vagens dentro do recipiente nos dados da AI2, contribuiu no aumento ou redução do erro para a contagem de vagens e grãos. A Figura 11a apresenta uma maior quantidade de vagens dentro da bandeja e um erro elevado, enquanto na Figura 11b a quantidade de vagens é reduzida, assim como o erro presente entre os valores reais e previstos para contagem de vagens e grãos.



	Vagens	Grãos		Vagens	Grãos
Valores reais	128	339	Valores reais	44	122
Valores previstos	100	279	Valores previstos	43	120
MAPE (%)	21,88	18,58	MAPE (%)	2,27	1,64

Figura 11. Bandeja com maior quantidade de vagens ocasionando maior erro na classificação do modelo(a) e com menor quantidade de vagens gerando menor erro na classificação do modelo (b).

4.3 Estimativa de produtividade

Na Tabela 3 são apresentados, para ambas as cultivares estudadas neste trabalho, os dados utilizados para realizar a estimativa com o método convencional e prevista de produtividade. É notório que os dados resultantes do modelo ao utilizar o método AI1 foram valores contrastantes do valor do método convencional, principalmente no número de vagens. Por outro lado, os valores que o modelo apresentou ao utilizar o método AI2 se aproximam do valor contado manualmente.

Convencional		Previsto AI1		Previsto AI2		Plantas/ha	Massa de 100 grãos (g)
V	G	V	G	V	G		

C1	59,67	2,54	32,44	2,58	53,26	2,67	256666,67	21,30
C2	42,83	2,78	29,54	2,71	40,08	2,81	316666,67	21,08

Tabela 3. Dados para cálculo da estimativa com método convencional e prevista da produtividade da cultura da soja para as cultivares 1 e 2.

V – número de vagens por planta; G – número de grãos por vagem; C 1 – cultivar TMG 7063 IPRO; C 2 – cultivar TMG 7363 RR; Previsto AI1 – Valores previstos com AI1; Previsto AI2 – Valores previstos com AI2.

A estimativa de produtividade para as duas cultivares, a partir da AI1 e AI2, bem como, o erro gerado pela diferença entre os valores obtidos por meio do método convencional e os valores previstos pelo modelo para a estimativa de produtividade são apresentados na Tabela 4. Como observado na Tabela 3, os dados da AI2 resultam em valores próximos da contagem manual, esse fato proporcionou, como observado na Tabela 4, valores de erro menor quando o modelo utilizou o AI2. No geral, para ambas as cultivares, o modelo ao utilizar o AI2 obteve os melhores resultados para estimativa de produtividade, pois obteve os menores valores do MAPE se comparado com os dados da AI1.

Tabela 4. Erro Percentual Absoluto Médio (MAPE) entre a estimativa de produtividade com método convencional e prevista pelo modelo para as duas cultivares da soja analisadas

Cultivares de soja	Produtividade			MAPE AI1 (%)	MAPE AI2 (%)
	Convencional (sacas/ha)	Prevista AI1 (sacas/ha)	Prevista AI2 (sacas/ha)		
C1	138,27	76,38	129,58	44,76	6,29
C2	125,47	84,40	118,58	32,73	5,50

C1 – cultivar TMG 7063 IPRO; C2 – cultivar TMG 7363 RR; Prevista M1 – Estimativa de produtividade utilizando AI1; Prevista M2 – Estimativa de produtividade utilizando AI2; MAPE M1 – Erro Percentual Absoluto Médio entre a estimativa de produtividade com método convencional e com AI1; MAPE M2 – Erro Percentual Absoluto Médio entre a estimativa de produtividade com método convencional e com AI2;

5. DISCUSSÃO

Neste trabalho foi desenvolvido um modelo que é capaz de realizar a classificação de vagens com diferentes números de grãos. Com base na classificação das vagens, o modelo foi capaz de contar o número de vagens e grãos e, a partir disso, foi possível estimar a produtividade da cultura da soja. O algoritmo foi desenvolvido para uso em campo, assim, durante a

construção do banco de dados, as imagens capturadas estavam sujeitas a alteração das condições ambiente. Logo, as condições de luminosidade não foram padronizadas para a aquisição das imagens.

Neste trabalho, a classificação das vagens, a partir do modelo *Mask R-CNN*, foi apresentada nas matrizes de confusão (Tabela 1 e 2). Os valores são referentes as vagens presentes nas imagens do subconjunto de teste para AI1 e AI2, e que foram classificadas pelo modelo. Com base nas matrizes de confusão, é perceptível a grande quantidade de objetos não detectados quando o modelo utiliza a AI1. Por outro lado, ao utilizar os dados da AI2, o modelo apresentou desempenho superior tanto na classificação, quanto na capacidade de detecção, diminuindo a quantidade de objetos não detectados. Esse fato acarretou o melhor desempenho do modelo sobre as métricas de classificação ao utilizar os dados provenientes da AI2 (Figura 6), visto que as métricas avaliativas são calculadas com base na matriz de confusão.

De modo geral, foi observado que, independentemente do procedimento utilizado para obtenção das imagens, as classes “dois” e “três” alcançaram melhores desempenhos se comparado as classes “um” e “quatro”. Esse resultado, possivelmente, é devido as cultivares analisadas possuírem maiores quantidades de vagens de dois e três grãos, esse fato ocasionou superioridade das classes “dois” e “três” em todos os subconjuntos de ambos os métodos, AI1 e AI2. A dominância das classes “dois” e “três” em todo o banco de dados alcançou 96,06% se comparado as classes “um” e “quatro”. Essa situação acarretou maiores quantidades de amostras para as classes “dois” e “três”, e menores quantidades de amostras para as classes “um” e “quatro” no momento de treinamento do modelo. Essa condição, provavelmente, gerou a disparidade presente nos desempenhos entre as classes, ocasionando a superioridade no desempenho das classes “dois” e “três” se comparado com as classes “um” e “quatro”.

Foi observado nas métricas avaliativas da AI2 que a classe “um” apresentou precisão discrepante, alcançando o valor de 100% (Figura 6a). Essa métrica informa a porcentagem de previsões que de fato correspondem com o valor real. Dessa forma, mesmo não havendo a previsão correta de todos os objetos desta classe, o que o modelo conseguiu classificar como classe “um” estava correto. No entanto, ao analisar a sensibilidade, ocorre o oposto, apresentando o valor de 18,75% (Figura 6b). Essa métrica informa a porcentagem de valores reais que foram previstos corretamente. E, como foi exposto, o modelo apresentou falhas, classificando de forma incorreta ou não detectando todas as vagens da classe “um”.

Apesar do baixo desempenho do modelo na classificação ao utilizar os dados da AI1 se comparado ao desempenho utilizando as imagens da AI2, observou-se que as imagens do AI1 apresentavam maiores quantidades de objetos que não são do interesse, como folhas e galhos.

Ainda assim, em certos momentos, o modelo foi capaz de superar essas dificuldades impostas pelos dados da AI1, se tornando capaz de localizar as vagens que possuíam obstrução e as classificar corretamente com base no número de grãos que possuía (Figura 7).

Entretanto, foi observado que o modelo ao utilizar os dados da AI1, por vezes se equivocou na classificação ao indicar como vagem os objetos do plano de fundo (Figura 8), como exemplo folhas e ramos. Como já mencionado, as imagens da AI1 possuíam em grande quantidade objetos considerados como plano de fundo, se comparado com as imagens da AI2. Possivelmente, uma solução para diminuir esse erro apresentado pelo modelo ao utilizar as imagens da AI1, seria, no momento da rotulagem, realizar a distinção dos diferentes objetos. Dessa forma, haveria as classes folhas, galhos e vagens com base no número de grãos.

O modelo *Mask R-CNN* vem sendo utilizado e apresentando bons resultados em trabalhos recentes, realizando a detecção e contagem de objetos em imagens. Como exemplo, Xu et al. (2020) utilizaram o *Mask R-CNN* para contagem de gado em pastagem, alcançando valores de erro entre 6 a 10%. Davis et al. (2020), que também fizeram uso do modelo *Mask R-CNN*, realizaram identificação e contagem de diversas espécies de ervas a partir de dados fenológicos de brotos, flores e frutos, alcançando valores do coeficiente de determinação (R^2) de 0,71, considerando todas as espécies utilizadas.

Especificamente para a soja, pesquisadores já desenvolveram métodos para realizar a contagem do número de vagens e grãos com o uso de tecnologias recentes, porém, essas soluções possuem algum tipo de limitação. No caso de Uzal et al. (2018) e Li et al. (2019), em que ambos utilizaram CNNs, foi alcançado a acurácia de 86,20% e o MAE (*Mean Absolute Error*) de 13,2, esses valores estão respectivos para os trabalhos citados. Se comparado com os resultados apresentados neste trabalho, ambos os artigos conquistaram bons desempenhos com seus respectivos modelos. Porém, os experimentos foram realizados em ambiente com luminosidade controlada, impossibilitando seu uso em campo.

Em trabalho desenvolvido em campo e apresentado por Riera et al. (2020), expõe um método robotizado para realizar a contagem de vagens de diferentes genótipos, permitindo a previsão de rendimento. No entanto, o experimento foi desenvolvido apenas no estádio reprodutivo R8, sendo esse um estádio muito próximo a colheita. Esse fato pode ocasionar prejuízos a estimativa de produtividade, caso seja necessário antecipar a colheita devido à algum imprevisto, como por exemplo, um imprevisto climático. A antecipação da colheita iria gerar a necessidade de estimar a produtividade em estádios reprodutivos anteriores, como R7 ou R6. Se comparado com o R8, os estádio R6 e R7 apresentam vagens de coloração diferente e alta presença de folhas nas plantas, isso iria ocasionar erros ao utilizar o modelo desenvolvido

por Riera et al. (2020), visto que o mesmo está apto apenas para as características presentes na planta do estágio reprodutivo R8. Por esse motivo, tornou-se importante desenvolver um modelo capaz de realizar a estimativa de produtividade em diferentes estádios reprodutivos. Portanto, potencializando um modelo capaz de realizar a estimativa de produtividade independente do estágio reprodutivo em que a planta de soja se encontra em campo.

No presente estudo, o modelo desenvolvido com base no *Mask R-CNN* foi utilizado testando dois diferentes procedimentos de aquisição de imagens, em duas cultivares da soja e em três estádios reprodutivos, sendo o experimento realizado em campo. Para a AI1, o modelo apresentou coeficiente de determinação (R^2) de 0,4921 e 0,5062 (Figura 9a e 9b) para vagens e grãos, respectivamente, e MAPE calculado para o subconjunto de teste de 34,64% e 35,25 % para vagens e grãos, respectivamente. Esses valores evidenciam o baixo desempenho do modelo ao utilizar a AI1 para realizar a contagem de vagens e grãos. Em contrapartida, os resultados obtidos com a AI2 foram significativamente melhores, alcançando R^2 de 0,9615 e 0,9591 (Figura 9c e 9d) para vagens e grãos, respectivamente, e o MAPE sobre o subconjunto de teste de 7,50% e 5,32% para vagens e grãos, respectivamente. Esses valores apresentados pelo modelo ao utilizar os dados obtidos pela AI2, intensificam a eficiência do modelo ao utilizar o procedimento da AI2 para contagem de vagens e grãos da soja.

Na Figura 10a observa-se variação no erro das imagens, em que algumas ultrapassam 70% e outras com erro abaixo de 10%. A diferença entre as imagens que possuem erros contrastantes são os estádios reprodutivos, os que apresentaram os menores erros são plantas que estavam no estágio R8, assim, com nenhuma ou poucas folhas e ramos. Já as que apresentaram os maiores erros, ultrapassando 70%, são plantas no estágio reprodutivo R6, plantas que possuíam muitas folhas e ramos. Este fato, da diferença no erro em comparação aos estádios reprodutivos, reforça como os ramos e folhas podem interferir negativamente para uma melhor detecção e contagem do número de vagens e grãos que o modelo pode realizar sobre os dados da AI1. Porém, é necessário realizar uma melhor análise, gerando um modelo de forma individual para cada estágio reprodutivo e determinando a progressão do desempenho do modelo nos diferentes estádios. Essa avaliação deve ocorrer principalmente entre o R7 e R8, visto que o R7 também possui uma quantidade de folhas e ramos reduzida assim como o R8.

Apesar do bom desempenho do modelo ao utilizar a AI2 para contagem de vagens e grãos, foi observado que as bandejas que possuíam as maiores quantidades de vagens (Figura 11a), foram as que apresentaram os maiores erros. Esse fato pode ter ocorrido pela quantidade de sobreposições das vagens, impondo dificuldade ao modelo em identificar e classificar as vagens que estavam abaixo de outras vagens. Por outro lado, esse fato foi observado de forma

reduzida em bandejas que possuíam menor número de vagens e que apresentavam maior espaço entre vagens (Figura 11b) Dessa forma, no momento de aquisição das imagens, o desempenho do modelo pode ser melhorado, posicionando as vagens em uma bandeja ou fundo branco que possua maiores dimensões, proporcionando maior espaçamento entre vagens.

Por fim, foi possível estimar a produtividade para as duas cultivares de soja por meio dos dados obtidos pelo modelo. Novamente, para estimativa de produtividade da cultura da soja, a AI2 apresentou melhor resultado se comparado com a AI1 (Tabela 4). Os erros percentuais absolutos médios foram de, 6,29% e 5,50% para a AI2 para as cultivares 1 e 2, respectivamente, enquanto a AI1 atingiu erros de 44, 76% e 32,73% para as cultivares 1 e 2, respectivamente.

Ao analisarmos as duas cultivares, é notório o maior número de vagens por planta e também a maior quantidade de ramos presentes nas plantas que a cultivar 1 apresenta em comparação a cultivar 2 (Tabela 3). O menor número de vagens e, também, a menor quantidade de ramos nas plantas, podem ter ocasionado o melhor desempenho para a cultivar 2 em ambos os métodos de aquisição. A quantidade reduzida de vagens e ramos da cultivar 2 em comparação com a cultivar 1, podem ter facilitado o modelo realizar a localização e classificação das vagens, visto que, havia menos ruído nas imagens, levando em consideração os dados da AI1, e menor quantidade de objetos para classificação, favorecendo a detecção com os dados da AI2. De forma geral, ao utilizar os dados da AI2, o modelo desenvolvido apresentou-se como uma ferramenta viável e precisa para estimar a produtividade das duas cultivares da cultura da soja apresentadas neste artigo.

Os resultados apresentados pelo modelo ao utilizar os dados obtidos pela AI2, abre uma possibilidade de trabalho futuro. Como exemplo, o desenvolvimento de aplicativo para dispositivo móvel, sendo essa uma ferramenta simples e de baixo custo. Com a criação de um aplicativo para dispositivo móvel, a estimativa de produtividade da soja se tornaria um procedimento acessível, compreendendo pesquisadores da área acadêmica como também os produtores rurais.

6. CONCLUSÃO

- Com os resultados e discussões expostos neste trabalho, concluiu-se que o modelo de aprendizagem profunda desenvolvido com base no *Mask R-CNN* para realizar a estimativa de produtividade da cultura da soja, obteve melhores resultados ao utilizar os dados obtidos pelo procedimento de AI2 se comparado com AI1. Os dados obtidos pelo modelo ao utilizar a AI2 apresentou os melhores resultados na classificação, na contagem de vagens e grãos e, também, na estimativa de produtividade. Dessa forma, o modelo, ao utilizar a AI2, se torna uma ferramenta viável e eficiente para realizar a estimativa de produtividade da soja em campo.
- Entre as cultivares a que apresentou melhor desempenho, em ambos os métodos, AI1 e AI2, foi a cultivar 2 (TMG 7363 RR). Com valores de MAPE para estimativa de produtividade de 32,73% (AI1) e 5,50% (AI2), enquanto a cultivar 1 (TMG 7063 IPRO) alcançou para estimativa de produtividade valores de 44,76% e 6,29%.

7. REFERÊNCIAS

- ALVES, G. R. et al. Estimativa da produtividade de soja com redes neurais artificiais. **Acta Scientiarum - Agronomy**, v. 40, n. 1, p. 1–9, 2018.
- APOLO-APOLO, O. E. et al. Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. **European Journal of Agronomy**, v. 115, n. August 2019, p. 126030, 2020.
- CHAN, M.; WEI, F.; MOLIN, P. Soybean Yield Estimation and Its Components : A Linear Regression Approach. n. MI, 2020.
- DAVIS, C. C. et al. A New Method for Counting Reproductive Structures in Digitized Herbarium Specimens Using Mask R-CNN. **Frontiers in Plant Science**, v. 11, n. July, p. 1–13, 2020.
- DE CARVALHO, O. L. F. et al. Instance segmentation for large, multi-channel remote sensing imagery using mask-RCNN and a mosaicking approach. **Remote Sensing**, v. 13, n. 1, p. 1–24, 2021.
- DUTTA, A.; ZISSERMAN, A. The VIA annotation software for images, audio and video. **MM 2019 - Proceedings of the 27th ACM International Conference on Multimedia**, p. 2276–2279, 2019.
- GANESH, P. et al. Deep Orange: Mask R-CNN based Orange Detection and Segmentation. **IFAC-PapersOnLine**, v. 52, n. 30, p. 70–75, 2019.
- GHOSAL, P. et al. Brain tumor classification using ResNet-101 based squeeze and excitation deep neural network. **2019 2nd International Conference on Advanced Computational and Communication Paradigms, ICACCP 2019**, n. May 2020, 2019.
- GIRSHICK, R. **Fast R-CNN**. [s.l.: s.n.]. Disponível em: <<https://github.com/rbgirshick/>>.
- GONZALEZ, T. F. Handbook of approximation algorithms and metaheuristics. **Handbook of Approximation Algorithms and Metaheuristics**, p. 1–1432, 2007.
- HAN, Y. et al. Quality estimation of nuts using deep learning classification of hyperspectral imagery. **Computers and Electronics in Agriculture**, v. 180, p. 105868, 14 nov. 2021.
- HE, K. et al. Mask R-CNN. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 42, n. 2, p. 386–397, 2018.
- KAUR, S.; PANDEY, S.; GOEL, S. Plants Disease Identification and Classification Through Leaf Images: A Survey. **Archives of Computational Methods in Engineering**, v. 26, n. 2, p. 507–530, 2019.
- KHAKI, S.; WANG, L.; ARCHONTOULIS, S. V. A CNN-RNN Framework for Crop Yield Prediction. **Frontiers in Plant Science**, v. 10, n. January, p. 1–14, 2020.

- LEE, J. et al. Artificial intelligence approach for tomato detection and mass estimation in precision agriculture. **Sustainability (Switzerland)**, v. 12, n. 21, p. 1–15, 2020.
- LI, Y. U. E. et al. Soybean Seed Counting Based on Pod Image Using Two-Column Convolution Neural Network. **IEEE Access**, v. 7, p. 64177–64185, 2019.
- MAXWELL, A. E.; POURMOHAMMADI, P.; POYNER, J. D. Mapping the topographic features of mining-related valley fills using mask R-CNN deep learning and digital elevation data. **Remote Sensing**, v. 12, n. 3, p. 1–23, 2020.
- MEKHALFI, M. L. et al. Detecting crop circles in google earth images with mask R-CNN and YOLOv3. **Applied Sciences (Switzerland)**, v. 11, n. 5, p. 1–12, 2021.
- MILLER, J. J. et al. Characterizing soybean vigor and productivity using multiple crop canopy sensor readings. **Field Crops Research**, v. 216, n. November 2017, p. 22–31, 2018.
- NEVAVUORI, P.; NARRA, N.; LIPPING, T. Crop yield prediction with deep convolutional neural networks. **Computers and Electronics in Agriculture**, v. 163, n. June, p. 104859, 2019.
- NGUGI, L. C.; ABELWAHAB, M.; ABO-ZAHHAD, M. Tomato leaf segmentation algorithms for mobile phone applications using deep learning. **Computers and Electronics in Agriculture**, v. 178, n. September, p. 105788, 2020.
- PERUGACHI-DIAZ, Y.; TOMCZAK, J. M.; BHULAI, S. Deep learning for white cabbage seedling prediction. **Computers and Electronics in Agriculture**, v. 184, n. December 2020, p. 106059, 2021.
- RAMOS, P. J. et al. Automatic fruit count on coffee branches using computer vision. **Computers and Electronics in Agriculture**, v. 137, p. 9–22, 2017.
- REN, S. et al. Faster R-CNN : Towards Real-Time Object Detection with Region Proposal Networks. p. 1–14, [s.d.].
- RIERA, L. G. et al. Deep multiview image fusion for Soybean yield estimation in breeding applications. **Plant Phenomics**, v. 2021, 2020.
- SUN, J. et al. County-level soybean yield prediction using deep CNN-LSTM model. **Sensors (Switzerland)**, v. 19, n. 20, p. 1–21, 2019.
- TEDESCO-OLIVEIRA, D. et al. Convolutional neural networks in predicting cotton yield from images of commercial fields. **Computers and Electronics in Agriculture**, v. 171, n. October 2019, p. 105307, 2020.
- TERLIKSIZ, A. S.; ALTYLAR, D. T. Use of deep neural networks for crop yield prediction: A case study of soybean yield in lauderdale county, Alabama, USA. **2019 8th International Conference on Agro-Geoinformatics, Agro-Geoinformatics 2019**, p. 9–12, 2019.
- UZAL, L. C. et al. Seed-per-pod estimation for plant breeding using deep learning. **Computers and Electronics in Agriculture**, v. 150, n. April, p. 196–204, 2018.
- VALICHARLA, S. K. Weed Recognition in Agriculture : A Mask R-CNN Approach Weed

Recognition in Agriculture : A Mask R-CNN Approach. 2021.

VASCONEZ, J. P. et al. Comparison of convolutional neural networks in fruit detection and counting: A comprehensive evaluation. **Computers and Electronics in Agriculture**, v. 173, n. March, p. 105348, 2020.

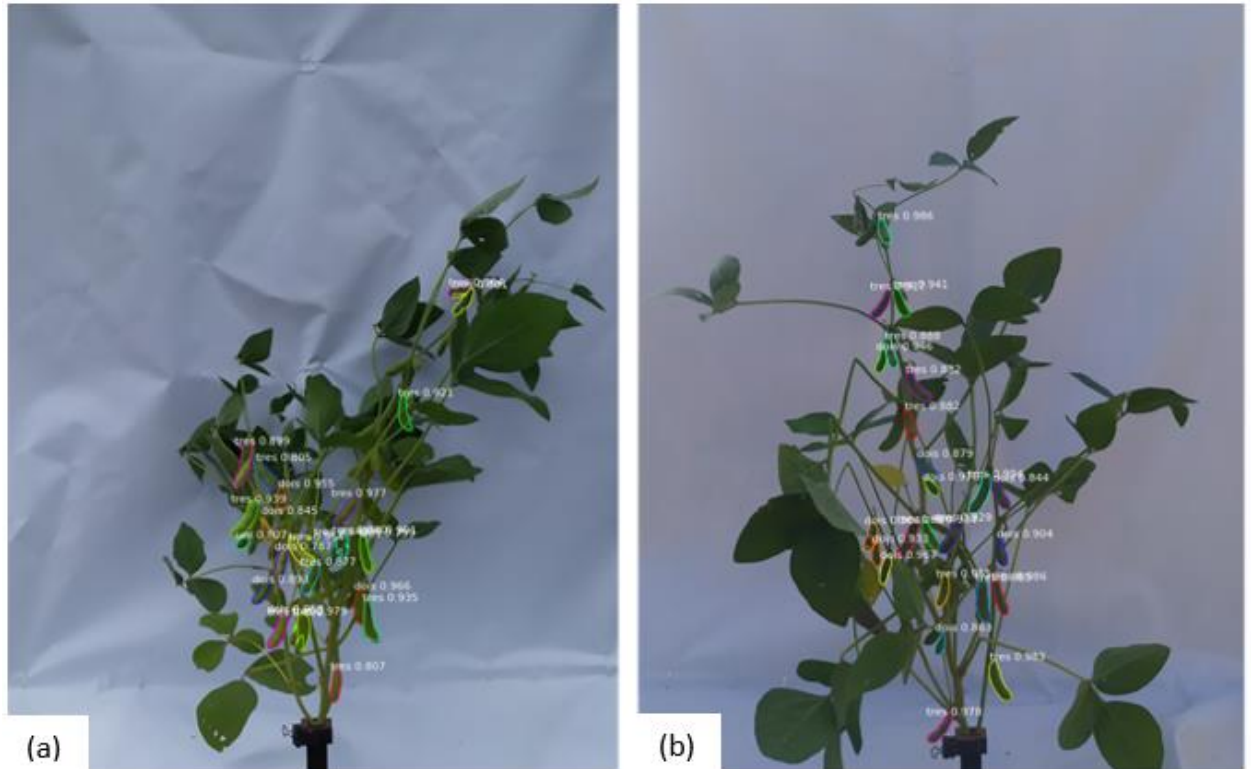
XU, B. et al. Automated cattle counting using Mask R-CNN in quadcopter vision system. **Computers and Electronics in Agriculture**, v. 171, n. October 2019, p. 105300, 2020.

YU, Y. et al. Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN. **Computers and Electronics in Agriculture**, v. 163, n. June, p. 104846, 2019.

ZHANG, S. et al. Cucumber leaf disease identification with global pooling dilated convolutional neural network. **Computers and Electronics in Agriculture**, v. 162, n. March, p. 422–430, 2019.

8. APÊNDICES


APÊNDICE A - Exemplo da detecção do modelo para o estágio R6 com a TMG 7063 I PRO (a) e TMG 7363 RR (b) a partir da AI1, bem como, valores referentes a contagem de grãos e vagens



	Vagens (a)	Grãos (a)	Vagens (b)	Grãos (b)
Valores Reais	53	142	49	143
Valores Previstos	36	96	24	63
MAPE (%)	32,08	32,39	51,02	55,94

Vagens (a) e Grãos (a) são valores referentes ao APÊNDICE A (a). Vagens (b) e Grãos (b) são valores referentes a APÊNDICE A (b).

APÊNDICE B - Exemplo da detecção do modelo para o estágio R6 com a TMG 7063 I PRO (a) e TMG 7363 RR (b) a partir da AI2



	Vagens (a)	Grãos (a)	Vagens (b)	Grãos (b)
Valores Reais	128	339	45	122
Valores Previstos	100	279	43	120
MAPE (%)	21,88	18,58	4,44	1,64

Vagens (a) e Grãos (a) são valores referentes a APÊNDICE B (a). Vagens (b) e Grãos (b) são valores referentes a APÊNDICE B (b).


APÊNDICE C - Exemplo da detecção do modelo para o estágio R7 com a TMG 7063 I PRO (a) e TMG 7363 RR (b) a partir da AI1



	Vagens (a)	Grãos (a)	Vagens (b)	Grãos (b)
Valores Reais	80	198	57	156
Valores Previstos	37	98	37	98
MAPE (%)	53,75	50,51	35,09	37,18

Vagens (a) e Grãos (a) são valores referentes a APÊNDICE C (a). Vagens (b) e Grãos (b) são valores referentes a APÊNDICE C (b).

APÊNDICE D - Exemplo da detecção do modelo para o estágio R7 com a TMG 7063 I PRO (a) e TMG 7363 RR (b) a partir da AI2



	Vagens (a)	Grãos (a)	Vagens (b)	Grãos (b)
Valores Reais	38	100	76	206
Valores Previstos	38	103	76	208
MAPE (%)	0,00	3,00	0,00	0,96

Vagens (a) e Grãos (a) são valores referentes ao APÊNDICE D (a). Vagens (b) e Grãos (b) são valores referentes ao APÊNDICE D (b).


APÊNDICE E - Exemplo da detecção do modelo para o estágio R8 com a TMG 7063 I PRO (a) e TMG 7363 RR (b) a partir da AI1



	Vagens (a)	Grãos (a)	Vagens (b)	Grãos (b)
Valores Reais	54	142	41	111
Valores Previstos	37	100	27	73
MAPE (%)	31,48	29,58	34,15	34,23

Vagens (a) e Grãos (a) são valores referentes ao APÊNDICE E (a). Vagens (b) e Grãos (b) são valores referentes ao APÊNDICE E (b).

APÊNDICE F - Exemplo da detecção do modelo para o estágio R8 com a TMG 7063 I PRO (a) e TMG 7363 RR (b) a partir da AI2



	Vagens (a)	Grãos (a)	Vagens (b)	Grãos (b)
Valores Reais	71	192	52	150
Valores Previstos	64	181	47	132
MAPE (%)	9,86	5,73	9,62	12,00

Vagens (a) e Grãos (a) são valores referentes ao APÊNDICE F (a). Vagens (b) e Grãos (b) são valores referentes ao APÊNDICE F (b).