



USO DA TI E MACHINE LEARNING PARA AJUDAR NO COMBATE AO PERCEVEJO MARROM

Submetido em: 23/11/2018

Aprovado em: 05/12/2021

ISSN 2965-3339

DOI: [10.29327/2384439.1.1-8](https://doi.org/10.29327/2384439.1.1-8)**Tamyris Alves de Souza**

Faculdade de Tecnologia Zona Leste

Luciano Francisco de Oliveira

Faculdade de Tecnologia Zona Leste

luciano.oliveira@fatec.sp.gov.br

Cristina Corrêa de Oliveira

TIPPA, Instituto Federal de São Paulo, Bragança Paulista

RESUMO.

O Brasil é o segundo maior exportador mundial de soja, porém produtores enfrentam desafios nesta cultura, especificamente as pragas que atacam a lavoura. É possível utilizar a Tecnologia da Informação para prover soluções que contribuam no combate ao Percevejo Marrom, dado que este é o inseto que mais causa perda da produção brasileira. A Inteligência Artificial, com Machine Learning e Redes Neurais, permite criar soluções que auxiliam na identificação a partir de imagens in loco do inseto nas plantas. Este artigo busca expender as técnicas disponíveis para a construção de aplicações na Agricultura 4.0 para reconhecimento de insetos, a fim de facilitar a identificação deles nas plantações, através do reconhecimento de padrões das partes aéreas da planta. A natureza desta pesquisa é tecnológica, com objetivo exploratório, abordagem qualitativa e procedimentos bibliográfico e documental. Foram utilizadas fontes como artigos científicos; pesquisa em sites institucionais internacionais e pesquisa de dados em instituições governamentais nacionais que trabalham com a produção, controle e exportação desta commodity. O maior desafio da Agricultura 4.0 é integrar tecnologias que possam contribuir ao agronegócio. Isto se deve ao fato de que os produtores enfrentam dificuldades ao acesso à internet no campo, o que prejudica o uso de dispositivos nas plantações. Este problema também afeta países da Europa, como a Alemanha, que precisa garantir internet com fibra ótica na área rural. Apesar dos desafios encontrados, existem soluções utilizando a Inteligência Artificial na área da agricultura que tem contribuído com o agronegócio brasileiro, porém ainda é uma vertente pouco explorada.

Palavras-chave. Reconhecimento de Imagem, Machine Learning, Inteligência Artificial, Agricultura 4.0, Redes Neurais.

ABSTRACT.

Brazil is the second largest soybean exporter, but producers face challenges with the crop, specifically regarding pests that prey on the crop. It is possible to use Information Technology to provide solutions that contribute to the control of the Percevejo Marrom, since this is the insect that causes most losses on Brazilian production. The Artificial Intelligence, with Machine Learning and Neural Networks, allows to create solutions that help the insect recognition through current local images of the plants. This article seeks to expend the available techniques for applications construction in Agriculture 4.0 for insect identification, helping to identify them in plantations, through the recognition of patterns in the plants top parts. The nature of this research is technological, with an exploratory objective, qualitative approach and bibliographic and documentary procedures. The sources used in the article were scientific articles; research on international institutional sites and data research in national government institutions which work with the production, control and export of this commodity. The biggest challenge of Agriculture 4.0 is to integrate technologies that can contribute to agribusiness, seeing that producers face difficulties with internet access in the field, which hinders the usage of devices in plantations. This issue also affects countries in Europe, such as Germany, that needs to ensure fiber-optic internet in rural areas. Despite these challenges, there are solutions using Artificial Intelligence in agriculture that has contributed to Brazilian agribusiness, although it is still a less explored trend.

Keywords. Machine Learning, Artificial Intelligence, Agriculture 4.0, Neural Networks.

1. INTRODUÇÃO E ESTRUTURA

A revolução da informação vem ganhando maior alcance nos últimos anos, possibilitando diversos benefícios para a constituição da sociedade em que vivemos. Na era da informação, não há dúvidas de que existe a possibilidade de transformar qualquer dado em fonte de informações úteis para a solução de problemas, configurando uma grande Ciência de Dados.

A agricultura nacional expandiu sua fronteira entre 1960 e 1990, denominada Revolução Verde, convertendo-se em um dos maiores exportadores de *commodities*. Neste período a característica do agronegócio era mecanização agrícola, monocultura com intenso preparo da terra e aplicação de insumos como fertilizantes e agrotóxicos. A segunda onda, denominada de Sistemas Integrados e iniciada em 1990 até o presente momento, diferencia-se da anterior pelo uso de sistemas integrados e rotacionados de produção, intensificando o cultivo da soja integrada a produção animal. Uma característica marcante nesta onda é permitir o balanceamento ambiental, otimizando o uso de recursos naturais. É uma fase que exige visão disciplinar na geração de novos conhecimentos e soluções tecnológicas (PILLON, 2016).

A terceira onda está prevista para ocorrer entre 2020 até 2030 com sistemas complexos, com a utilização de processos biológicos em vez de insumos químicos ou minerais. Desta forma o alimento se transformará em “promotor de qualidade de vida, saúde e bem-estar” (PILLON, 2016). Estudiosos apontam que soluções tecnológicas devam ser desenvolvidas e aplicadas na agricultura.


Dentro da segunda onda, surge na Alemanha em 2012 a Indústria 4.0 que trouxe inovação em toda indústria automobilística alemã e atualmente se expande para fábricas de diversos segmentos devido à completa

automatização proporcionada aos processos produtivos (VDMA-VERLAG, 2018). Esta revolução industrial engloba tecnologias como a Internet das Coisas, ou o termo em inglês *Internet of Thing* (IoT), definida como uma rede de objetos físicos que possuem tecnologia embarcada, sensores, conexão com rede que permitem coletar e transmitir dados; Sistemas Ciber-Físicos, caracterizados por elementos computacionais colaborativos com o intuito de controlar entidades físicas; Computação nas Nuvens, termo que define a computação em servidores disponíveis na Internet; e por fim, mas não menos importante, a Inteligência Artificial (IA) empregada na construção de soluções computacionais com objetivo de aplicar regras lógicas, aprendizagem e reconhecimento de padrões (EUROPEAN COMMISSION, 2017).

Os métodos da Indústria 4.0 têm sido investigados e aplicados no agronegócio, resultando no termo Agricultura 4.0, pois a produção agrícola está diretamente relacionada a produção agroindustrial e com o consumidor final, produzindo encadeamentos produtivos por meio da Agricultura 4.0 (PARRONCHI, 2018), que visa garantir o uso de tecnologia subsidiando a produção com o máximo de rendimento possível, através de variedades resistentes e monitoramento climático, necessários para que as aplicações em tecnologia da informação consigam ter o máximo de rendimento.

A aplicação de tecnologia na agricultura tem se intensificado nos últimos quatro anos, visto que uma pesquisa do termo “*Smart Farm*” na base do *Science Direct* demonstrou que este termo vem aumentando entre artigos relacionados à tecnologia em suas bases, como pode ser visto no Gráfico 1. O termo Agricultura 4.0 aparece com 3 artigos em 2016 e 2 artigos nos anos de 2017 e 2018.

GRÁFICO 1: Artigos Científicos com "Smart Farm"



Fonte: Autoria própria

A premissa para o rápido desenvolvimento de tecnologias digitais de ponta na agricultura é, acima de tudo, o uso de robôs inteligentes, sensores diversos, drones, uso de satélite com *softwares* em *smartphones*, *tablets* e sistemas integrados (BRAUN; COLANGELO; STECKEL, 2018). Desde robôs de ordenha nos galpões de gado leiteiro, até imagens de satélite para controle de pragas, agricultores encontram-se no meio de um rápido desenvolvimento tecnológico digital em direção à Agricultura 4.0. A soja é a principal cultura agrícola do país, contribuindo diretamente no agronegócio e no Produto

Interno Bruto (PIB). A previsão em 2017 foi de que o PIB do agronegócio crescerá cerca de 0.5% a 1%, segundo a Confederação da Agricultura e Pecuária do Brasil (2018), e que este cultivo corresponderá a 89% dos grãos produzidos no país, com um alcance entre 106,4 milhões de toneladas (MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO, 2017).

Esta pesquisa busca expender a problemática relacionada às pragas no cultivo da soja e nas técnicas disponíveis para a construção de aplicações futuras, a fim de auxiliar a identificação dos insetos presentes nas plantações, através do reconhecimento de padrões nas partes aéreas da planta, em especial o reconhecimento da presença do Percevejo Marrom. Sabe-se que os agricultores enfrentam milhares de desafios no que se

refere a trabalhos agrícolas e com o intuito de contribuir com a diminuição desses problemas, algumas técnicas de IA são apresentadas como *Machine Learning* e Redes Neurais.

2. SOJA

A soja é o grão mais presente na economia brasileira, crescendo a cada dia e que conquista não só o mercado brasileiro, mas também os consumidores europeus. Em 2017, a soja em grão liderou a exportação pelo terceiro ano consecutivo, tendo variações na receita de venda ao exterior e cotações médias em relação ao ano anterior. (ASSOCIAÇÃO DE COMÉRCIO EXTERIOR DO BRASIL, 2018).

No Brasil, a Empresa Brasileira de Pesquisa Agropecuária (Embrapa) auxilia os produtores agrícolas para fortalecer o suporte à tecnologia, principalmente nas plantações de trigo, milho, arroz, feijão e a soja, foco principal desta pesquisa. A Companhia Nacional do Abastecimento (CONAB) afirma que o Brasil é o segundo maior produtor mundial de soja, atrás apenas dos Estados Unidos da América. Entre as safras de 2015 e 2016, a cultura de soja ocupou uma área de 33,17 milhões de hectares, totalizando uma produção de 95,63 milhões de toneladas (MOTTA, 2015).

A previsão para as safras de 2018/2019 ainda faz parte de expectativas, uma vez que depende de condições climáticas durante todo o ciclo da cultura da soja. A previsão será de, aproximadamente, 62 milhões de hectares, com a soja e o milho ocupando mais de 80% desse espaço (CONAB, 2018). Com isso, a área cultivada com soja será superior a 36 milhões de hectares, cerca de 1,0 milhões de hectares maior do que a área do ciclo anterior (35,15 milhões de hectares), prevendo uma produção de 3 milhões de toneladas maior quando comparada com a produtividade atual da cultura (Embrapa, 2018).

Embora o cultivo de soja seja um ponto forte no desenvolvimento econômico, existem alguns fatores que requerem uma atenção maior: os insetos. Os insetos são um grande problema para os cultivadores de soja, levando-os, muitas das vezes, a perdas significativas na produção. O setor produtivo relacionado a cultura da soja é atacado por dezenas de pragas todos os anos. Existem muitos insetos que podem acabar com uma cultura inteira de soja se não forem combatidos. No entanto, identificar a espécie que está causando o comprometimento na plantação não é algo trivial, pois as pragas atacam de diversas formas e em uma miríade de espécies.

Por exemplo, as pragas de soja podem residir tanto no subsolo e atacar diretamente as raízes quanto no ar atacando o caule, as folhas e suas hastes. Em decorrência desse fato, existem também doenças que são causadas por estes insetos que atacam não só as plantações como também os seres humanos, dependendo das características da praga. A doença mais comum e que será abordada ao longo dessa pesquisa, é a soja louca.

A ocorrência desse problema nas lavouras, faz com que as folhas da soja fiquem rugosas e exista o engrossamento das suas nervuras, conforme pode ser visto na Figura 1, trazendo um grande prejuízo para os cultivadores (EMBRAPA, 2015). Há muitas maneiras de controlar as pragas que assolam as plantações, porém sem o reconhecimento delas por imagem, não é possível ter uma precisão exata para identificar o tipo de praga que está presente na produção e aplicar o procedimento necessário ao seu extermínio, uma vez que cada espécie possui um tratamento específico.

Dentre as pragas que destroem as plantações, segundo Popov (2016), o destaque maior fica com o percevejo-marrom, apresentado na Figura 2 e Figura 3, por ser um dos mais abundantes na cultura, requer maior atenção. Por isso

existe a necessidade de identificar essas pragas na soja em seus diversos estágios e entender um pouco melhor os desafios enfrentados pelos cultivadores desse grão.

Figura 1 – Soja louca causada pelo Percevejo Marrom



Fonte: EMBRAPA (2015)

Figura 2 – Percevejo Marrom



Fonte: Portal Syngenta (2017)

Figura 3 – Percevejo Marrom e o manejo integrado



Fonte: Revista Agrocampo (2018)

3.METODOLOGIA

Este artigo se propõe a realizar uma pesquisa científica de natureza tecnológica (BUNGE, 1983), baseada na tipologia proposta por Raupp e Beuren (2012)



composta por objetivos, abordagem do problema e procedimentos.

O objetivo é exploratório, cuja principal finalidade é desenvolver, esclarecer, modificar conceitos e ideias, tendo em vista a formulação de problemas mais precisos ou hipóteses pesquisáveis para estudos posteriores (GIL, 2008). Segundo Severino (2007), a pesquisa exploratória busca apenas levantar informações sobre um determinado objeto, delimitando assim um campo de trabalho, mapeando as condições de manifestação desse objeto. Na verdade, ela é uma preparação para a pesquisa explicativa. No entanto, de acordo com Appolinário (2011), a pesquisa ou estudo exploratório tem por objetivo “aumentar a compreensão de um fenômeno ainda pouco conhecido, ou de um problema de pesquisa ainda não perfeitamente delineado”.

A abordagem desta pesquisa se caracteriza como qualitativa. Para Zikmund et al. (2009), esta abordagem é utilizada para estudar um problema, não se preocupando com a representação numérica, buscando interpretar os dados para extrair seu significado transformando-o em informação.

Por fim, o procedimento desta pesquisa é bibliográfico e documental. Segundo Marconi e Lakatos (2010), a pesquisa documental recorre a fontes mais diversificadas e dispersas tais como: arquivos públicos, particulares, fontes estatísticas, podendo ser relatórios censitários, anuários, documentos oficiais, relatórios de empresas; denominadas fontes primárias. A pesquisa bibliográfica, denominada fonte secundária, foi realizada a partir do levantamento de referências teóricas já analisadas, publicadas por meios escritos e eletrônicos, como livros, páginas de *websites* e revistas eletrônicas. No desenvolvimento desta pesquisa foram realizados levantamentos de informações a respeito da produção da soja, estendendo-se ao agronegócio, utilizando procedimentos bibliográficos com pesquisas em bases

científicas, e documental com pesquisa de dados em instituições governamentais que trabalham com a produção, pesquisa em *sites* institucionais internacionais, controle e exportação deste *commodity*.

4. ANÁLISE DOS RESULTADOS

4. INTELIGÊNCIA ARTIFICIAL

Diante da diversidade existente entre as técnicas e algoritmos de aprendizado de máquina existe um grande desafio no que se refere a escolha do melhor algoritmo para tratar de um problema específico. Para que esse processo seja realizado de forma simples, é importante ter a ciência de como esses algoritmos se subdividem dentro da TI. Os algoritmos de *Machine Learning* costumam ser divididos em três categorias: algoritmos supervisionados, algoritmos não supervisionados e algoritmos de esforço. Os algoritmos supervisionados são utilizados para os conjuntos de dados de treino que possuem entradas e mapeia uma ou mais saídas desejadas. Dessa forma, durante todo o processo de treino e aprendizagem o modelo preditivo irá adequar as variáveis para que satisfaçam a saída desejada. Os algoritmos não supervisionados não possuem estruturas completamente definidas como os algoritmos supervisionados, nesse caso o modelo gerado após a sessão de treino será aplicado para diferentes grupos, desconsiderando a existência de um resultado esperado. Por fim, os algoritmos de esforço foram construídos para auxiliar na tomada de decisão. Deste modo, todo o processo de treino e aprendizado é feito para que a partir das entradas e saídas fornecidas, seja possível tomar decisões com base nos dados apresentados e realizar previsões futuras acerca de um contexto passado. A aprendizagem por esforço é uma abordagem de IA que permite a uma entidade aprender, a partir de sua interação com o ambiente, por meio do conhecimento sobre o estado do indivíduo, das ações efetuadas e das

mudanças de estado que ocorreram devido a essas ações. (SUTTON; BARTO, 2017)

Dentro dessas categorias de algoritmos, existem diversas técnicas que podem ser aplicadas durante o processo de aprendizagem em conjunto com as Redes Neurais, como pode ser visto na Tabela 1.

Tabela 1: Categorias de Algoritmos de Machine Learning

Algoritmos Supervisionados	Algoritmos Não Supervisionados	Algoritmos de Esforço
Árvores de decisão	Algoritmos de Agrupamento	<i>Q-Learning</i>
Classificação Naïve Bayes	Análise de componentes principais	Decisão de Markov (MDP)
Regressão Logística	Análise de componentes independentes	<i>Balancer Exploration and Exploitation</i>

Fonte: KDnuggets (2017)

4.1 MACHINE LEARNING

O aprendizado de máquina, do inglês *Machine Learning*, está contido na Inteligência Artificial cujo principal objetivo é desenvolver técnicas computacionais sobre o aprendizado e estruturação de sistemas capazes de adquirir conhecimento e possa tomar decisões de maneira automática. Por ser uma área da IA, sua base é constituída em aprender sobre algum problema para identificar um padrão comportamental através de uma base de dados fornecida e a partir daí construir um modelo que consiga tomar decisões guiadas por dados. Os diversos sistemas de aprendizado de máquina existentes possuem características particulares e comuns que possibilitam sua classificação, como paradigmas, formas de aprendizado e afins.

É indiscutível que, com estudos e testes, a máquina chega a ser mais eficiente que os humanos. Existem algumas aplicações na área da saúde e entretenimento que utilizam

a aprendizagem de máquina para solucionar problemas relacionados. Um sistema para auxiliar na identificação de câncer de pele em pacientes foi desenvolvido com base na técnica das Redes Neurais Convolucionais. Foram realizadas comparações entre dermatologistas experientes com os resultados obtidos por meio da IA sendo comprovado que, por meio dos resultados apresentados, os médicos foram menos eficientes que a máquina treinada. Em um dos testes foi comprovado que os médicos detectaram cerca de 86,6% dos melanomas enquanto o sistema conseguiu acertar 95% dos casos evidenciando que a IA pode ser mais eficiente. (BARBOSA, 2018).

Dessa forma, é possível considerar que essa área é uma espécie de campo de estudo que possibilita aos computadores a habilidade de aprenderem padrões para que possam executar atividades complexas e dinâmicas, prevendo com maior assertividade resultados baseados em exemplos passados, experiência direta ou simplesmente uma série de instruções em conjunto com modelos computacionais como Redes Neurais a fim de construir soluções completas e robustas.

4.2 REDE NEURAL CONVOLUCIONAL


As Redes Neurais são modelos computacionais inspirados no funcionamento do sistema nervoso central utilizando modelos matemáticos que adquirem conhecimento através da experiência. As Redes Neurais fazem parte de um campo da ciência da computação que também é ligado à IA com objetivo de implementar modelos matemáticos semelhantes ao funcionamento das estruturas neurais biológicas do ser humano. Essas redes são compostas por várias unidades de processamento que possuem um funcionamento bastante simples, pois quando suas unidades são conectadas, diversas interações entre as

unidades de processamento da rede são realizadas para que ela consiga realizar o processo de aprendizagem. (CARVALHO, 2009) A utilização de Redes Neurais permite que os sistemas computacionais possuam um caráter dinâmico quando unido ao *Machine Learning*.

Existem diversos tipos de arquiteturas de Redes Neurais, no entanto é abordada apenas a arquitetura que possui a melhor performance no que se refere ao reconhecimento de imagens, que é a Rede Neural Convolutiva, oriundas do inglês *Convolutional Neural Networks (CNN)*.

A CNN, que é uma das arquiteturas de Redes Neurais, é muito utilizada no processamento e análise de imagens digitais, pois ela é capaz de aprender mais rapidamente a partir de imagens e melhorar o seu desempenho ao longo do processo a partir desse aprendizado. Esse modelo se tornou uma referência para o tratamento de imagens principalmente por ser fácil de treinar um grande volume de amostras que possuem diferentes características. As CNNs são formadas por sequências de camadas principais e essenciais no processo de treino, além de suas três principais camadas necessárias no processo: camadas convolutivas, camadas de *pooling* e camada totalmente conectada.

Figura 4 – Arquitetura Rede Neural Convolutiva

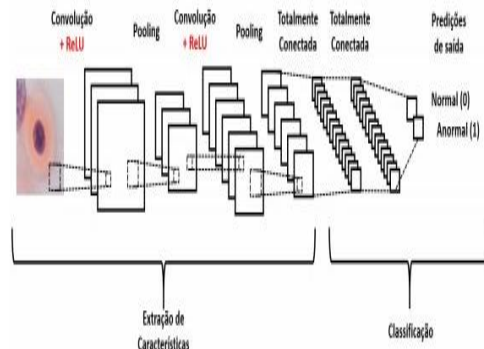


Fonte: Araújo et al. (2017)

A Figura 4 ilustra a arquitetura de uma CNN, detalhando também suas três principais camadas. De maneira sucinta, as

camadas convolutivas são as mais importantes da rede, pois são compostas por um conjunto de filtros e condições a serem atendidas capazes de aprender de acordo com o treinamento posterior. Elas possuem a responsabilidade de extrair as características dos dados de entradas, como a identificação de cores em imagens digitais ou até mesmo medidas de altura e largura das entradas. A camada de *pooling* é a camada posterior ao processo realizado na camada convolutiva onde é utilizada para reduzir o tamanho espacial da matriz da imagem resultante da convolução. Ou seja, ela reduz a dimensionalidade das imagens de modo que facilite a representação de pequenas partes dos dados de entrada fornecidos. Por fim, a camada totalmente conectada é responsável por disseminar o resultado pela multiplicação de cada ponto das imagens de entradas. Como o próprio nome sugere, ela se une a camada anterior (camada de *pooling*) de modo que seja possível conectar todos os elementos da matriz anterior, comumente chamados de neurônios. O objetivo das camadas totalmente conectadas é utilizar essas características levantadas ao longo do processo de treino para classificar a imagem em uma classe pré-determinada para verificar se a saída satisfaz os resultados do estudo. A Figura 5 a seguir demonstra as responsabilidades de cada camada dentro do procedimento de treino.

Figura 5 – Processo de treinamento usando CNNs



Fonte: Araújo et al. (2017)

5. FERRAMENTAS E SOLUÇÕES ATUAIS

O *TensorFlow* é uma biblioteca de código aberto, do inglês *open source*, ou seja, é uma biblioteca que além de gratuita possibilita a realização de modificações em seu código fonte, dependendo do tipo de licença dessas ferramentas. Essa biblioteca foi desenvolvida pela Google para ser utilizado com a IA e todo o seu projeto foi feito pelo estudo de Redes Neurais, sendo a base de diversos serviços como o Google Tradutor, Google Fotos e até mesmo o buscador Google (GOOGLE, 2018). A base dessa biblioteca é a computação numérica utilizando grafos computacionais, que é uma estrutura de dados que descreve completamente a computação que se deseja executar. Por ser de código aberto, o TensorFlow vem se tornando a biblioteca padrão para o desenvolvimento em *Deep Learning* e aplicações e conta com muitos colaboradores externos. O ponto de maior relevância é o fato de que o TensorFlow possui uma capacidade de gerar um produto a partir de um modelo preditivo, o que elimina totalmente a necessidade de reimplementar o modelo, uma vez criado ele pode ser aproveitado por diversas frentes

(DATASCIENCE ACADEMY, 2018). Por utilizar *Machine Learning*, essa biblioteca consegue auxiliar no desenvolvimento de modelos analíticos utilizando algoritmos para gerar *insights* e ampliar a capacidade de decisão e ações computacionais.

O TensorFlow utiliza Python e C++ como linguagens principais, por serem fáceis de programar, possuem documentações atualizadas, comunidade de desenvolvimento ativa e por ter um alto desempenho. Através de gráficos de fluxo de dados e computação numérica, é possível implantar e executar algoritmos de aprendizagem da máquina, onde são considerados dois pilares: os nós, que são as operações matemáticas e as arestas, que são os *tensors*, conhecidos também como


matrizes de dados multidimensionais (GOOGLE, 2018). Basicamente um usuário constrói o grafo e escreve os algoritmos que são executados em cada nó. O TensorFlow cuida da execução do código assincronamente nos diferentes dispositivos, núcleos e *threads*.

A segunda biblioteca, o Keras, é uma Interface de Programação de Aplicações, oriunda do inglês *Application Programming Interface* (API), que é um grupo de instruções lógicas passadas utilizando-se padrões computacionais que permitem a integração de dados e segurança para que aplicativos móveis ou sistemas *web* sejam acessados (KERAS, 2018). Essa API de alto nível é mais simples que o TensorFlow para utilização, porém o seu mecanismo de *back-end*, ou seja, o servidor que buscará as informações necessárias ao seu funcionamento, é baseado no TensorFlow. Ela foi desenvolvida com o foco de experimentação rápida, focada em testes mais otimizados e que não necessitam de processamento de dados avançado. O Keras é utilizado para estruturação de redes neurais e pode ser utilizado para a mesma finalidade que o TensorFlow, a diferença é que ela foi desenvolvida para facilitar as experimentações rápidas de modo que não seja necessário domínio de alguma ferramenta para criar modelos preditivos (WILLEMS, 2017). Essa biblioteca possibilita a prototipagem rápida à redes convolucionais e recorrentes, incluindo a combinação das duas. Por sua base ser o TensorFlow, com o Keras também é possível utilizar como linguagem principal o Python. Ela oferece APIs mais simples e consistentes para minimizar e reduzir a carga cognitiva de processamento, isto é, o nível de uso dos recursos computacionais que serão explorados em conjunto com as redes neurais para resolução de problemas. Essa facilidade de uso não acarreta em novos custos de flexibilidade, pois como o Keras integra-se a linguagens de aprendizagem profundas de nível inferior (em particular o TensorFlow), ele permite

implementar qualquer coisa que se tenha construído no idioma base (KERAS, 2018). Em particular, a API Keras integra-se perfeitamente aos fluxos de trabalho do TensorFlow, ou seja, é possível criar modelos preditivos já treinados no TensorFlow e em seguida executá-los no Keras devido a integração entre eles.

Tendo em vista o estudo apresentado sobre as bibliotecas mais utilizadas, a melhor abordagem para o reconhecimento das pragas nas plantações de soja em trabalhos futuros é a utilização da biblioteca Keras, apesar de mais simples e menos sofisticada, possui uma vasta gama de recursos que atendem perfeitamente o contexto, uma vez que o foco principal é a identificação do Percevejo Marrom (Euschistus Heros). Isso se deve ao fato de que tanto o Keras quanto o TensorFlow estão entre as bibliotecas de *Deep Learning* mais utilizadas em 2018.

Gráfico 2: Deep Learning Frameworks Power Scores



Fonte: Keras Documentation (2018)


6. APLICAÇÕES UTILIZANDO MACHINE LEARNING

De acordo com as técnicas e algoritmos de *Machine Learning*, será descrito alguns exemplos de aplicações utilizando essas tecnologias dentro e fora do contexto do agronegócio a fim de demonstrar a

importância e os resultados que podem ser obtidos e otimizados por meio da IA.

Para a identificação de câncer de pele, a CNN foi utilizada para todo o processo de aprendizagem. Basicamente, para esse procedimento, foram utilizadas aproximadamente 100 mil imagens de melanomas, do tipo mais agressivo de câncer de pele, a fim de realizar o processo de treinamento onde diferencia-se tumores malignos e benignos. Através desse conjunto de imagens utilizadas, foram separadas as imagens dermatoscópicas ampliando o tamanho das lesões na pele em 10 vezes. A partir de cada imagem recebida pela CNN, ela melhora gradualmente a sua capacidade de diferenciar as lesões malignas e benignas (CASTRO, 2018).

Figura 6 – Melanomas benignos e Pragas nas Folhas



Fonte: Universidade Stanford (2018) e Barbedo (2016)

As imagens à esquerda na Figura 6 representam as lesões na pele, enquanto as últimas são imagens que foram segmentadas pelo computador, correspondendo ao processo de identificação dos melanomas benignos e malignos. Nesse caso, de acordo com a

decisão dos médicos a precisão de identificação foi de 86,6% considerando melanomas malignos e 71,3% de melanomas benignos. Já a CNN conseguiu identificar 95% dos tumores malignos e 82,5% de melanomas benignos. Ou seja, com base na pesquisa feita é factível que as CNNs tiveram um desempenho maior que os especialistas, diminuindo os erros em diagnósticos de melanomas malignos.

Conclui-se que além de mais sensível, a CNN também é mais específica, o que significa que o método resultaria em um número menor de cirurgias desnecessárias para o problema de câncer de pele. Embora tenha tido um resultado bastante positivo para o problema enfrentado, ainda existe um longo caminho a ser percorrido para que essa tecnologia seja implementada de forma segura no atendimento clínico (CASTRO, 2018).

Considerando o cenário voltado ao agronegócio, à direita, na Figura 6, estão as imagens de folhas e sua transformação em imagens digitais utilizadas para o diagnóstico de doenças nas plantas. Imagens digitais do café, cana de açúcar e fruteiras foram transferidas para um banco de dados de imagens que são armazenadas e processadas, de modo que se torne um apoio à tomada de decisão para o controle adequado (TORDIN, 2016). Com isso, é possível estruturar uma base de dados contendo imagens de culturas, doenças e condições encontradas em campo e construir ferramentas capazes de ajudar na identificação de doenças com sintomas semelhantes por meio de sistemas especialistas (TORDIN, 2016).

A correlação destes cenários demonstra o uso de IA para resolução de problema do público-alvo em questão, possibilitando não só a integração de sistemas de decisão baseado em dados, mas também o aumento de assertividade e eficiência nos processos realizados.

Outra abordagem no contexto do agronegócio é a aplicação do aprendizado de máquina para o reconhecimento de bagas de café em imagens de campo (SANTOS, 2015). Utilizou-se cerca de 3.393 imagens manuais rotuladas como café e não-café, que possibilitou a realização de testes quantitativos e a detecção das bagas de café tiveram uma precisão de 90% por meio de Máquinas de Vetores de Suporte e descritores de Histograma de Gradientes Orientados.

A detecção desse fruto em campo foi feita via sensoriamento proximal, devido ao seu tamanho, utilizou-se uma câmera comum para coleta das imagens. Após estruturar a base de imagens, um classificador atribuído nas fotos pôde determinar se na região em questão havia o fruto desejado.

O algoritmo empregado foi aplicado em cada pixel das imagens para realizar uma varredura completa em todas as possíveis localizações e caso não fosse utilizado técnicas de *Machine Learning* o processamento dessas imagens teria um alto custo computacional e tornaria a pesquisa inviável. Os classificadores envolvidos para o estudo foram: Determinante da Hessiana, Laplaciano da Gaussiana e Diferença de Gaussianas. (TUYTELAARS; MIKOLAJCZYK, 2007)

A detecção teve como foco principal a identificação das regiões com bagas de café, permitindo também que mesmo os frutos ainda verdes, onde a cor pode se assemelhar a folhagem do cafeeiro, fossem identificados. A precisão da detecção obtida nesse estudo torna o método uma alternativa para metodologias de predições para a agricultura, contribuindo para diversas pesquisas e aplicações nesta área. Com base nos exemplos de aplicações apresentados, é possível notar a importância das tecnologias utilizadas, demonstrando que a Inteligência Artificial é capaz de resolver problemas complexos com maior assertividade através do *Machine Learning*.

7. DISCUSSÃO

Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE) somente o setor agropecuário contribui com aproximadamente 22,5% do PIB e 37% da força de trabalho. Considerando que durante pelo menos 50 anos o Brasil era um dos grandes importadores de alimentos, produzindo em quantidade consideravelmente menor que nos dias de hoje e devido aos avanços em soluções tecnológicas aplicadas ao longo deste percurso, é possível observar claramente os resultados econômicos na atualidade. A automatização dos processos agrícolas se tornou uma tendência promissora devido a evolução das tecnologias como a agro informática, bioinformática e a agricultura de precisão. A agricultura mundial encontra-se sob forte influência da tecnologia para contribuição de sua evolução. A tecnologia empregada no campo agrícola vem consolidando a nova era dentro do cenário do campo para otimização de processos. Seu grande potencial reside na sua transversalidade, podendo agregar valor e benefício para as diversas áreas de negócios, mercado, agricultura e meio ambiente (MASSRUHÁ; LEITE; MOURA, 2014).

O maior desafio da Agricultura 4.0 consiste em realizar pesquisas de modo que todas essas tecnologias sejam integradas e produzam conhecimento para que o Brasil prossiga como um dos principais exportadores e produtor da agropecuária. Para que isso seja feito, é necessário levar em consideração que, apesar das oportunidades, existem muitas dificuldades para acessar a internet no meio rural, limitando o avanço de aplicativos para uso em campo.

Uma pesquisa realizada pela Associação Brasileira de Marketing Rural e Agronegócio (2017) com uma amostra com 2.853 entrevistados, sendo que 2.110 são

agricultores em estados brasileiros e dentre estes, 557 são produtores de soja. Um item questionado nesta pesquisa foi a exposição aos meios de comunicação variados existentes, sendo os três mais utilizados a TV aberta, o rádio e a internet. Os entrevistados possuem celular pessoal (n=96%) e smartphone (n=67%). As atividades da agricultura de precisão são para a preparação do solo (n=78%), análise do solo (n=72%), uso de GPS (n=49%) e coleta e análise de dados do plantio (n=44%). Um dado importante é a intenção de compra para os próximos 12 meses com respostas sobre equipamentos como tratores (n=11%), sistema de irrigação (n=1,6%). Nenhuma das respostas apresenta sistemas computacionais para a melhoria da produção ou mesmo determinados equipamentos que possam agregar valor na produção agrícola. A Agricultura 4.0 ainda é um desafio grande, pois o acesso à internet, segundo censo agropecuário (IBGE, 2017), apresenta 1.42 milhões produtores acessando a internet por banda larga (n=46,2%) e internet móvel (n=63,77%), mas o sinal do 4G não cobre todo o território, dificultando a utilização de aplicações com IoT.

Estes problemas também são enfrentados por países na Europa. A Alemanha está sendo cobrada pelo fornecimento de internet com fibra ótica na área rural, com técnicas inovadoras e econômicas para as instalações de infraestrutura de dados. Outra demanda dos produtores é o incentivo financeiro para o agronegócio; segurança de dados para que os agricultores tenham soberania dos seus dados.

Considerando o avanço da Agricultura 4.0 e suas abordagens de tecnologias utilizadas nesta era, atualmente existem alguns sistemas voltados para a identificação de insetos em plantações. O maior problema para os produtores de grãos é identificar as pragas que atacam as lavouras para que seja aplicado um método de controle, uma vez

que estes podem ser confundidos com os inimigos naturais destes insetos.

Tendo em vista esta problemática, especialistas da Embrapa Agrobiologia do Rio de Janeiro desenvolveram um aplicativo que possibilita identificar através de fotografias os agentes que comprometem as plantações. Através do aplicativo é possível comparar as imagens tiradas em campo com as existentes no aplicativo a fim de identificar a espécie do inseto. O principal objetivo desse aplicativo é auxiliar ao agricultor a possibilidade de distinguir entre as pragas que são benéficas às suas plantações com os inimigos naturais, pois não adianta a presença de insetos benéficos na lavoura, se o agricultor os confundir com os que podem causar danos à planta (SILVA, 2018). Este aplicativo apenas mostra a imagem existente em um catálogo, não realizando a identificação da figura coletada diretamente na planta.

Aplicações podem ser incorporadas à problemática da soja em trabalhos futuros, uma vez que a identificação do Percevejo Marrom se daria através de fotografias *in loco* do inseto nas plantações, bem como os danos causados por ele nas folhas e raízes e a partir da imagem fotografada, seria possível reconhecer a espécie e fase da praga. Com isso, pode-se facilitar o manejo da soja e mitigar os prejuízos para os agricultores de soja, uma vez que o Percevejo Marrom implica na perda de rendimento e qualidade da semente da soja, principalmente por não existirem soluções utilizando a tecnologia para tratar o problema de maneira eficiente, de modo que o mesmo procedimento envolvendo o Percevejo Marrom poderia ser aplicado para as demais pragas da soja, otimizando e padronizando a colheita desse grão tão importante para a economia.

8. CONSIDERAÇÕES

O estudo realizado teve o intuito de identificar alternativas para auxiliar os

produtores de soja no combate ao Percevejo Marrom, utilizando a Inteligência Artificial para detectar o aparecimento deste inseto nas plantações de soja a fim de que possam aplicar pesticidas específicos para a praga encontrada. Primeiramente foi feito um levantamento da importância da soja para economia brasileira e mundial, bem como o motivo para que a pesquisa fosse embasada neste grão. Analisou-se também a existência de outras soluções tecnológicas aplicadas na Agricultura 4.0 que são utilizadas na otimização de processos.

Em relação as tecnologias já existentes, é possível perceber que apesar dos investimentos já existentes na Agricultura 4.0 ainda existe um longo caminho a ser percorrido, principalmente no plantio de soja, que proporciona resultados líquidos bastante vantajosos para a economia, possibilitando um retorno dos investimentos de forma rápida a médio prazo. Independente da safra ocorrida no ano, a cultura da soja apresenta resultados acima da média e confiáveis para futuros investimentos.

Através da análise de soluções existentes para o ramo da agricultura foi possível perceber que as alternativas para utilização da IA dentro da agricultura ainda é realizada de maneira genérica, considerando não só diversos insetos, mas também outras culturas de grãos. É importante que exista uma especificidade para as diferentes abordagens, de modo que seja possível tratar de maneira única os problemas da soja. Desta forma, por meio da identificação do Percevejo Marrom nas plantações seria possível aplicar procedimentos específicos para combater esta praga

Como trabalhos futuros, sugere-se que seja feito um sistema para reconhecimento do Percevejo Marrom, reaproveitando algoritmos utilizados para identificar insetos e mitigar os riscos enfrentados pelos agricultores, contribuindo com a lucratividade desse grão importante para a economia nacional e internacional.

REFERÊNCIAS

- AGROCAMPO. **Percevejo-Marrom e seu manejo integrado**, 2018. Disponível em: <<https://www.revistaagrocampo.com.br/noticia/manejo/percevejo-marrom-e-o-manejo-integrado#>>. Acesso em: 2 novembro 2018.
- APPOLINÁRIO, F. **Dicionário de Metodologia Científica**. 2. ed. São Paulo: Atlas S.A, 2011.
- ARAÚJO, F. H. D. CARNEIRO, A. C., MEDEIROS, F. N. S., SILVA, R. R. V., USHIZIMA, D. M. **Redes Neurais Convolucionais com TensorFlow: Teoria e Prática**. Artigo em III Escola Regional de Informática do Piauí. Livro Anais - Artigos e Minicursos, Piauí: Eripi. 2017.
- ABMRA. -. ASSOCIAÇÃO BRASILEIRA DE MARKETING RURAL E AGRONEGÓCIO. **7ª edição da Pesquisa Hábitos do Produtor Rural**, 2017. Disponível em: <<http://www.abmra.org.br/2016>>. Acesso em: 10 novembro 2018.
- ASSOCIAÇÃO DE COMÉRCIO EXTERIOR DO BRASIL. **Revisão da balança comercial**, 2018. Disponível em <<http://www.aeb.org.br/noticias.asp?Id=4698>>. Acesso em: 07 outubro 2018.
- BARBEDO, J. A novel algorithm for semi-automatic segmentation of plant leaf disease symptoms using digital image processing, 2016. **Tropical Plant Pathology**. 41. 210-224. 10.1007/s40858-016-0090-8.
- BARBOSA, Fabio. **Inteligência artificial vence dermatologistas no diagnóstico de câncer de pele**, 2018. Disponível em: <<http://www.cofemac.com.br/noticia/6387/inteligencia-artificial-vence-dermatologistas-nodiagnostico-de-cancer-de-pele>>. Acesso em: Acesso em: 30 setembro 2018.
- BRAUN, A-T, COLANGELO, E., STECKEL, T. **Farming in the Era of Industrie 4.0. Procedia CIRP**, v. 72, 2018, p. 979-984, ISSN 2212-8271. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2212827118303342>>. Acesso em: 10 novembro 2018.
- BUNGE, M. A. **Epistemologia**. São Paulo: T. A. Queiróz/EDUSP, 1983.
- CARVALHO, de F. L. P. A. -. **Redes Neurais Artificiais**, 2009. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/>>. Acesso em: 05 outubro 2018.
- CASTRO, F. **Inteligência Artificial vence dermatologistas no diagnóstico de câncer de pele**, 2018. Disponível em <<https://saude.estadao.com.br/noticias/gera-l-inteligencia-artificial-vence-dermatologistas-nodiagnostico-de-cancer-de-pele,70002328295>>. Acesso em: 30 setembro 2018.
- CONFEDERAÇÃO DA AGRICULTURA E PECUÁRIA DO BRASIL. **Projeções do Agronegócio, Brasil 2017/18 a 2027/28**, 2018. Disponível em: <http://www.agricultura.gov.br/assuntos/politica-agricola/todaspublicacoes-de-politica-agricola/projecoes-doagronegocio/PROJECOES2018_FINALIZADA_web_05092018.pdf>. Acesso em: 24 outubro 2018.
- CONAB. -. Companhia Nacional De Abastecimento. **Perspectivas para a agropecuária**. v. 6. Brasília: CONAB, 2018.
- CONAB. -. Companhia Nacional De Abastecimento. **Acompanhamento da Safra Brasileira: grãos (2016/17)**. v. 4. p. 1-164. Brasília: CONAB, 2016.
- DATASCIENCE ACADEMY. **O que é o TensorFlow Machine Intelligence Platform?**, 2018. Disponível em: <<http://datascienceacademy.com.br/blog/o->



que-e-o-tensorflow-machine-intelligence-platform/>. Acesso em: 24 outubro 2018.

DBV ASSOCIAÇÃO ALEMÃ DE AGRICULTORES. **Agricultura 4.0 - Oportunidades e Desafios**, 2016. Disponível em: <<https://www.bauernverband.de/landwirtsch aft-40>>. Acesso em: 13 novembro 2018.

EMBRAPA -. Empresa Brasileira de Pesquisa Agropecuária. **Soja Louca II é reconhecida como doença da soja pelo Mapa**, 2015. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/5213621/sojalouca-ii-e-reconhecida-como-nova-doenca-da-soja-pelo-mapa>>. Acesso em: 24 outubro 2018.

EMBRAPA. -. Empresa Brasileira de Pesquisa Agropecuária, 2018 p. 1. Disponível em: <<https://www.embrapa.br/soja/cultivos/soja1>>. Acesso em: 07 outubro 2018.

EMBRAPA. -. Empresa Brasileira de Pesquisa Agropecuária. **Aplicativo auxilia na identificação de inimigos naturais de pragas agrícolas**, 2018. Disponível em: <<https://www.embrapa.br/agencia-de-noticiasembrapa/busca-de-noticias/-/noticia/31597890/aplicativo-auxilia-na-identificacao-de-inimigos-naturais-depragas-agricolas>> Acesso em: 02 novembro 2018.

EMBRAPA. -. Empresa Brasileira de Pesquisa Agropecuária. **Soja em números (safra 2017/2018)**, 2018. Disponível em <<https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>>. Acesso em: 07 outubro 2018.

EUROPEAN COMMISSION. Industry 4.0 in agriculture: Focus on IoT aspects. 2017

GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. 6. ed. São Paulo: Atlas S.A, 2008.

GOOGLE. **Get Started with TensorFlow**. Disponível em: <<https://www.tensorflow.org/tutorials/>>. Acesso em: 30 setembro 2018.

GOVERNO DO BRASIL. **Soja lidera exportações do agronegócio em maio**, 2017. Disponível em: <<http://www.brasil.gov.br/economia-e-emprego/2017/06/soja-lidera-exportacoes-do-agronegocio-em-maio>>. Acesso em: 24 outubro 2018.

IBGE. -. Instituto Brasileiro De Geografia E Estatística. **Censo Agropecuário: Resultados preliminares**. v. 7. Rio de Janeiro: IBGE, 2017.

IBGE. -. Instituto Brasileiro De Geografia E Estatística. **Indicadores Agropecuários**. v. 3. Rio de Janeiro: IBGE, 2004.

KDNUGGETS. **Top Data Science and Machine Learning Methods Used in 2017**, 2017.

<<https://www.kdnuggets.com/2017/12/top-data-science-machine-learning-methods.html>>. Acesso em: 15 outubro 2018.

KERAS. **Keras: A biblioteca do Python Deep Learning**, 2018. Disponível em: <<https://keras.io/>>. Acesso em: 30 setembro 2018.

MARCONI, M. A., LAKATOS, E. M. **Fundamentos de Metodologia Científica**. (7a ed.). São Paulo: Atlas, 2010.

MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; MOURA, M. F. Os novos desafios e oportunidades das tecnologias da informação e da comunicação na agricultura (AgroTIC). In: MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; LUCHIARI JUNIOR, A.; ROMANI, L. A. S. (Ed.). **Tecnologias da informação e comunicação e suas relações com a agricultura**.

Brasília, DF: Embrapa, 2014. Cap. 1. p. 23-38

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. **Estimativa para safra 2017/2018 é de até 227,5 milhões de toneladas**, 2017. Disponível em:



<<http://www.agricultura.gov.br/noticias/estimativapara-safra-2017-2018-e-de-ate-227-5-milhoes-de-toneladas>>. Acesso em: 31 outubro 2018.

MOTTA, da G. Fernando et al. **Perspectivas para a agropecuária**. v. 3. Brasília: CONAB, 2015.

PARRONCHI, P. **Os Pioneiros do desenvolvimento e a Nova Agricultura 4.0: desenvolvimento econômico a partir do campo? In: Crise, austeridade e luta de classes: o Brasil num beco sem saída**, 2018. Disponível em <<https://sep.org.br/anais/>>. Acesso em: 13 novembro. 2018.

PILLON, C. N. **Dos Pós de Rocha aos Remineralizadores: Passado, Presente e Desafios**. Artigo em Anais de Congresso, Rio Grande do Sul: Embrapa. 2016.

PORTAL SYNGENTA. **Percevejo-marrom: Um perigo real para os grãos de soja**, 2017. Disponível em: <<https://www.portalsyngenta.com.br/direto-do-campo/percevejo-marrom-um-perigo-real-para-os-graos-desoja>>. Acesso em: 02 novembro 2018.

POPOV, Daniel. **Piores pragas da soja**. Disponível em: <<http://www.projetosojabrasil.com.br/saiba-quais-as-10-piores-pragas-da-soja/>>. Acesso em: 17 outubro 2018.

RAUPP, F. M.; BEUREN. **Metodologia da pesquisa aplicável às ciências sociais**. ed. 3. São Paulo: Atlas, 2012.

SANTOS, T. T. -. **Deteção Automática de Bagas de Café em Imagens de Campo**, 2015. Disponível em <<https://www.alice.cnptia.embrapa.br/bitstream/doc/1027251/1/22thiagoteixeirasantos162.pdf>>. Acesso em: 05 outubro 2018.

SEVERINO, A. J. **Metodologia do Trabalho Científico**. 23. ed. São Paulo: Cortez, 2007.

SUTTON, R. S, BARTO A. G. **Reinforcement Learning: An**

introdutivo. ed. 2. Londres: The MIT Press Cambridge, 2017.

TORDIN, Cristina. **Projeto realiza o diagnóstico de doenças em plantas com o uso de imagens digitais**, 2016. Disponível em:

<<https://www.grupocultivar.com.br/noticias/projeto-realiza-o-diagnostico-de-doencas-em-plantas-com-uso-de-imagens-digitais>>. Acesso em: 10 novembro 2018.

TUYTELAARS, T, MIKOLAJCZYK, K. **Local Invariant Feature Detectors: A Survey**. v. 3. Boston: Now The essence of knowledge, 2007.

UNIVERSIDADE STANFORD. **Deep learning algorithm does as well as dermatologists in identifying skin cancer**, 2017. Disponível em: <<https://news.stanford.edu/2017/01/25/artificial-intelligence-used-identify-skincancer/>>. Acesso em: 15 outubro 2018.

VDMA-VERLAG. **Industrie 4.0 konkret - Lösungen für die industrielle Praxis**, 2018. Disponível em:

<<https://www.vdmaverlag.com/home/artikel/industrie40%20konkret.html#modal-cookiewarning>>. Acesso em: 02 novembro 2018.

WILLEMS, K. **Keras Tutorial: Deep Learning in Python**, 2017. Disponível em:

<<https://www.datacamp.com/community/tutorials/deep-learning-python>>. Acesso em: 30 setembro 2018.

ZIKMUND, W.G., BABIN, B.J., CARR, J.C., GRIFFIN, M.: **Business Research Methods**, 8 ed. SouthWestern College Pub: 2009.