

INSTITUTO FEDERAL DE SANTA CATARINA

VINICIUS FIGUEIRÓ TONINI

**Desenvolvimento de um sistema de detecção de  
pragas em soja utilizando técnicas de  
aprendizado de máquina**

São José - SC

dezembro/2023

# **DESENVOLVIMENTO DE UM SISTEMA DE DETECÇÃO DE PRAGAS EM SOJA UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Proposta de Trabalho de Conclusão de Curso  
apresentada ao Curso de Engenharia de Te-  
lecomunicações do campus São José do Ins-  
tituto Federal de Santa Catarina.

Orientador: Prof. Mario de Noronha Neto,  
Dr.

São José - SC

dezembro/2023

# RESUMO

O agronegócio no Brasil é fundamental para o crescimento econômico e movimentação de trilhões de reais a cada ano. Esse crescimento, é protagonizado pela exportação da soja e pela implementação de soluções inovadoras que aumentam a produtividade e a eficiência no campo. O Brasil, é líder na exportação da soja e o mercado mundial apresenta uma crescente demanda por este grão. Diante disso, este trabalho tem o objetivo de implementar uma solução que permita ao agricultor controlar pragas na soja a partir do uso de Inteligência Artificial (IA). Para tanto, será desenvolvido um aplicativo móvel, que permita agricultores enviar imagens de sua plantação de soja para uma aplicação com um modelo previamente treinado por meio de algoritmos de aprendizado de máquina e uma ampla base de dados. A aplicação, deve identificar a praga presente na imagem enviada, em seguida, retornar o resultado de forma amigável ao agricultor em seu celular. A aplicação móvel, é uma abordagem que visa facilitar, tendo em vista que não exige ao agricultor possuir uma estrutura complexa, apenas com seu celular, é possível identificar problemas que poderiam tomar grandes proporções e prejudicar a colheita. Como resultados, é esperado que a precisão do modelo de IA e o aplicativo móvel auxiliem com a tomada de decisão do agricultor, minimize danos causados por pragas, favoreça o monitoramento da plantação e aumente a produção das lavouras de soja.

**Palavras-chave:** Inteligência Artificial. Agronegócio. Detecção de pragas. Soja.

# LISTA DE ILUSTRAÇÕES

Figura 1 – Rede Neural Simples e Rede Neural Profunda ( <i>Deep Learning</i> ) . . . . .	11
Figura 2 – Exemplo de <i>Convolutional Neural Network</i> (CNN) . . . . .	12
Figura 3 – Arquitetura da <i>Residual Neural Network</i> (ResNet) com 34 camadas . .	13
Figura 4 – Diferença entre os processos de aprendizado (a) aprendizado de máquina tradicional e (b) aprendizado de máquina por transferência . . .	14
Figura 5 – Algumas aplicações industriais de visão computacional . . . . .	15
Figura 6 – Construção do primeiro modelo com a biblioteca FastAI . . . . .	16
Figura 7 – Imagem fornecida ao modelo . . . . .	17
Figura 8 – Diagrama da arquitetura do projeto . . . . .	19

# LISTA DE TABELAS

Tabela 1 – Cronograma de atividades . . . . .	20
-----------------------------------------------	----

# LISTA DE CÓDIGOS

Código 2.1 – Código <i>Python</i> utilizado por Howard e Gugger (2020) para validar o modelo . . . . .	17
--------------------------------------------------------------------------------------------------------	----

# LISTA DE ABREVIATURAS E SIGLAS

**API** *Application Programming Interface.*

**CNN** *Convolutional Neural Network.*

**IA** inteligência artificial.

**ResNet** *Residual Neural Network.*

**RNAs** Redes Neurais Artificiais.

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>8</b>
<b>1.1</b>	<b>Objetivo geral</b>	<b>9</b>
<b>1.2</b>	<b>Objetivos específicos</b>	<b>9</b>
<b>1.3</b>	<b>Organização do texto</b>	<b>9</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>10</b>
<b>2.1</b>	<b>Inteligência Artificial</b>	<b>10</b>
2.1.1	Redes neurais profundas	10
2.1.2	Arquiteturas de redes neurais consolidadas	11
2.1.3	Aprendizado por transferência	14
2.1.4	Visão computacional	15
<b>2.2</b>	<b>Fast AI</b>	<b>16</b>
<b>2.3</b>	<b>Aplicação <i>mobile</i></b>	<b>17</b>
<b>3</b>	<b>PROPOSTA</b>	<b>19</b>
<b>3.1</b>	<b>Proposta de Arquitetura</b>	<b>19</b>
<b>3.2</b>	<b>Metodologia</b>	<b>20</b>
3.2.1	Cronograma de Atividades	20
<b>3.3</b>	<b>Resultados esperados</b>	<b>21</b>
	<b>REFERÊNCIAS</b>	<b>22</b>

# 1 INTRODUÇÃO

A agricultura brasileira é um setor econômico que contribui significativamente para o desenvolvimento do país. Segundo a [Embrapa \(2020\)](#), é um setor que contribui com 21% do PIB nacional, implicando em uma das maiores contribuições no país, por representar a soma de todas as riquezas produzidas. Atualmente, é responsável pela geração de um quinto de empregos e por 43,2% das exportações, além de ser um dos poucos segmentos da economia brasileira que manteve um crescimento positivo durante os últimos anos. Dessa forma, a [Embrapa \(2020\)](#), afirma, que modelos matemáticos projetam para 2030, produções de grãos superiores a 318 milhões de toneladas, representando um aumento de 68 milhões de toneladas a produção atual no Brasil, reforçando assim, a competitividade do Brasil neste segmento.

O crescimento econômico visto no agronegócio, é dado devido a ampla modernização do campo, que possibilita o aumento da eficiência dos processos na lavoura. Segundo [Aires \(2023\)](#), é por meio das inovações tecnológicas que é possível reduzir custos, aumentar a produtividade e garantir maior rentabilidade para o negócio rural. A utilização de tecnologias capazes de fornecer dados de clima, solo, entre outros, auxilia significativamente na tomada de decisão do agricultor e reduz desperdício. Portanto, com o emprego dos dispositivos de inteligência artificial para o monitoramento das plantas, a tendência é proporcionar uma visão mais clara da saúde da lavoura e conseqüentemente, aumentar a produtividade da plantação.

Os avanços tecnológicos e crescimento econômico, tem como destaque a soja. As exportações de soja, geram uma receita que supera os dez bilhões de dólares, representando cerca de 8% do total exportado pelo país. Sendo que cada um de quatro dólares exportados pelo agronegócio brasileiro provém da soja ([DALL'AGNOL et al., 2021](#)). No Brasil moderno, pode ser comparada ao fenômeno ocorrido com o ciclo da cana-de-açúcar, da borracha e do café, que, em distintos períodos dos séculos XVII a XX, comandaram o comércio exterior do país ([DALL'AGNOL et al., 2021](#)). De acordo com [Dall'Agnol et al. \(2021\)](#), no mercado mundial, há uma crescente demanda pela soja e o grande exportador deste grão é o Brasil, a tendência é que se mantenha na liderança da exportação mundial por muitos anos, se é que será superado algum dia, tendo em vista o potencial que o Brasil possui para se expandir.

No contexto do agronegócio brasileiro, este projeto visa introduzir inovações significativas para um setor de extrema importância. A presença de pragas durante todo o processo produtivo da soja, desde o plantio até a colheita, é uma das principais preocupações, uma vez que a soja é uma cultura de grande importância para a economia

(FERREIRA; CAMPO; GÓMEZ, 2014). Diante disso, objetiva-se desenvolver uma solução inovadora com *inteligência artificial (IA)*, dado que as pragas podem gerar grandes prejuízos para o produtor, como a diminuição da produtividade, da sanidade das lavouras e danos econômicos. O objetivo é desenvolver um sistema capaz de identificar pragas nas plantações por meio da análise de imagens, com visão computacional, oferecendo assim uma abordagem eficaz e proativa para resolver esse problema que os produtores enfrentam.

## 1.1 Objetivo geral

O objetivo geral deste trabalho é desenvolver um sistema de detecção de pragas em sojas utilizando uma abordagem centrada em dados e técnicas de aprendizado de máquina.

## 1.2 Objetivos específicos

Através do objetivo geral, foram definidos os seguintes objetivos específicos.

- Definir uma base de dados representativa para o trabalho.
- Realizar o pré-processamento das imagens para o treinamento de algoritmos de aprendizado de máquina.
- Gerar modelo de aprendizado de máquina utilizando a ferramenta FastAI.
- Desenvolver aplicação *mobile* para captura e inferência de imagens de plantaço de soja e visualização do resultado.
- Validar o protótipo por meio de testes.

## 1.3 Organização do texto

Este trabalho está organizado da seguinte forma: no *Capítulo 2* aborda a base teórica necessária para o entendimento e desenvolvimento deste trabalho. No *Capítulo 3* é apresentado a proposta para este projeto e o cronograma previsto para sua execução.

## 2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo são apresentadas as revisões bibliográficas dos principais conceitos que serão abordados, assim como estão relacionados ao tema e à proposta do projeto que será descrita no [Capítulo 3](#).

### 2.1 Inteligência Artificial

A [inteligência artificial \(IA\)](#) trata-se da capacidade de tornar os computadores capazes de realizar tarefas de pensamento que se assemelha a inteligência humana ([MILLINGTON, 2006](#)). A diferença, é que os computadores são um milhão de vezes mais rápidos que o cérebro humano, e executam tarefas com agilidade e eficiência que superam o ser humano ([MORETI et al., 2021](#)). Além disso, possui a capacidade de reconhecer e classificar padrões, raciocinar de forma lógica e aprender com a experiência ([HONAVAR, 2016](#)).

De acordo com [Norvig e Russell \(2013\)](#), IA não é um conceito novo, em meados de 1950 Alan Turing propôs o Teste de Turing. Este teste, avalia se uma máquina é inteligente conforme as suas respostas forem indistinguíveis das de um humano, diante disso, foi estabelecida as bases para o desenvolvimento de habilidades como processamento de linguagem natural, representação de conhecimento, raciocínio automatizado e aprendizado de máquina. A IA é um ramo da computação que já existe há algum tempo, mas ganhou força com a modernidade devido a outros meios que possibilitam seu desenvolvimento, como a computação em nuvem e *Big Data* ([MORETI et al., 2021](#)).

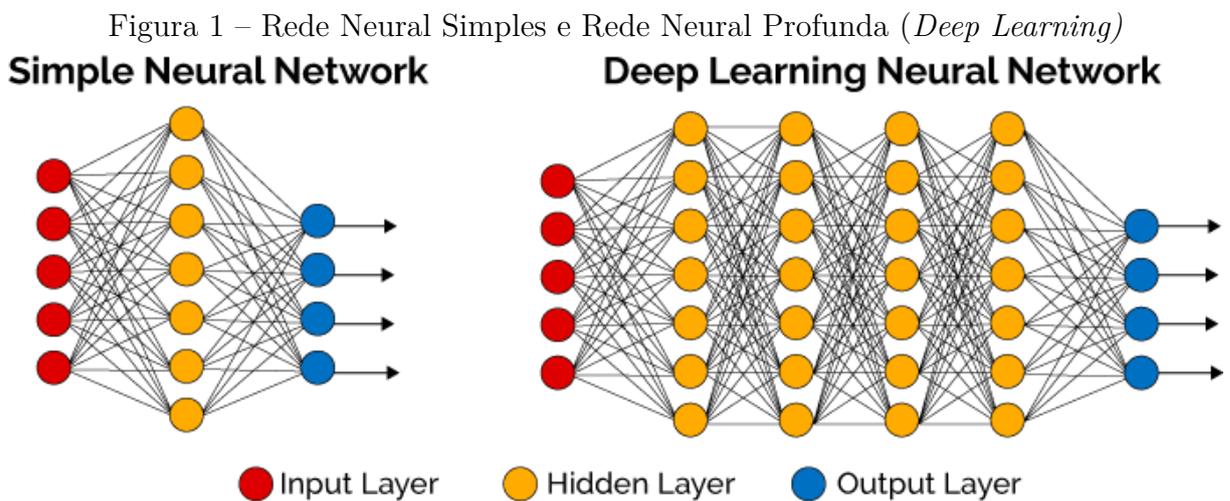
Atualmente, diversos ramos de estudo tem se voltado para IA e na agricultura não é diferente. Com a tecnologia no campo, a necessidade de obter respostas rápidas e precisas para situações com grandes volumes de dados onde a capacidade intelectual humana não consegue lidar, a IA está pronta para interpretar os dados ([PINHEIRO et al., 2021](#)). De acordo com [Pinheiro et al. \(2021\)](#), os algoritmos de aprendizagem de máquina mais utilizados no setor agrícola, são os de redes neurais e árvores de decisão, sendo que redes neurais chamam mais atenção dos pesquisadores, por simular conexões de um cérebro humano.

#### 2.1.1 Redes neurais profundas

O aprendizado profundo é uma subárea do aprendizado de máquina (*machine learning*). É uma rede neural com muitas camadas e parâmetros ([SHINDE; SHAH, 2018](#)). Segundo [Patterson e Gibson \(2017\)](#), com a melhoria de hardware, ou seja, um maior poder

de processamento, possibilitou os resultados espetaculares vistos recentemente, como os avanços das redes neurais profundas no inglês *Deep Neural Networks* sendo o acréscimo de novas camadas.

No geral, o aprendizado profundo usa uma cascata de unidades de processamento de várias camadas. As camadas iniciais, próximas à entrada de dados, aprendem recursos simples, enquanto as camadas mais distantes da entrada, aprendem recursos mais complexos, os quais são derivados de recursos das camadas iniciais. A arquitetura forma uma representação de recursos hierárquica e robusta, que possibilita analisar e extrair conhecimento útil de grandes quantidades de dados (SHINDE; SHAH, 2018).



Fonte: (ACADEMY, 2022b).

Na Figura 1, é apresentado a representação esquemática de duas arquiteturas de Redes Neurais Artificiais (RNAs): uma rede neural simples, à esquerda, e uma rede neural profunda, à direita. Os círculos vermelhos representam as entradas da rede, enquanto os azuis representam suas saídas. Em amarelo, a representação dos neurônios que compõem as camadas ocultas da rede.

### 2.1.2 Arquiteturas de redes neurais consolidadas

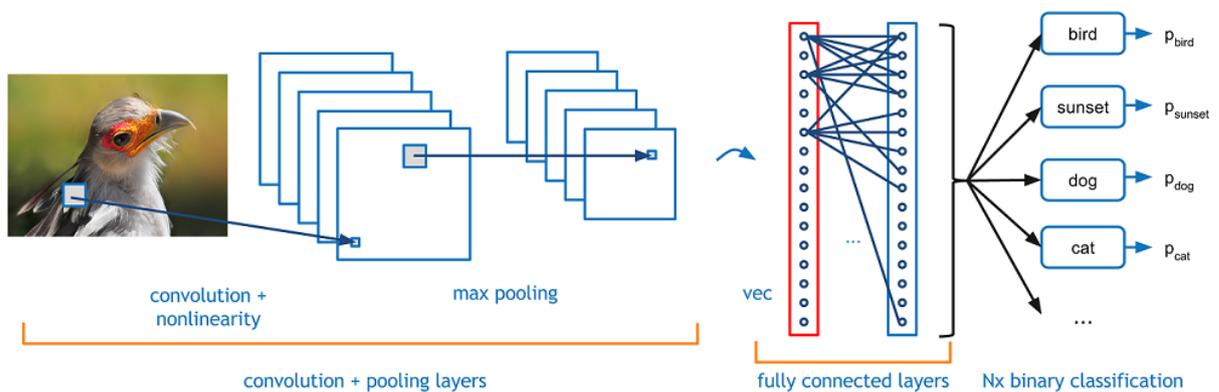
Esta seção apresenta algumas das arquiteturas consolidadas encontrada na literatura, com ênfase nas arquiteturas relevantes ao trabalho aqui realizado. Para obter uma apresentação mais completa, é possível acessar as páginas de *The Asimov Institute* ("The Neural Network Zoo") (LEIJNEN STEFAN, 2019) e *Data Science Academy* ("Deep Learning Book") (ACADEMY, 2022a), onde uma gama maior de arquiteturas de redes neurais são descritas. As arquiteturas julgadas relevantes para este trabalho são: *Convolutional Neural Network* (CNN) e *Residual Neural Network* (ResNet).

- **Rede Neural Convolutacional (CNN):** A arquitetura de rede neural CNN, apresenta um alto desempenho nas áreas de relacionadas à visão computacional tais

como reconhecimento de imagem e detecção de objetos (PANG et al., 2018). Sua organização é em camadas computacionais sucessivas, alternando entre convolução e *pooling* (subamostragem). Segundo Pang et al. (2018), em comparação com outros tipos de redes neurais profundas, as CNNs são treinadas com maior facilidade, dado que utiliza retro propagação, e possuem uma conectividade dispersa em cada camada convolucional. Em uma camada convolucional, filtros lineares são usados para convolução. Os principais parâmetros das CNNs são os pesos dos filtros. Para reduzir o número de parâmetros, é adotada uma estratégia de compartilhamento de parâmetros. Embora o compartilhamento de parâmetros reduza a capacidade das redes, melhora a sua capacidade de generalização.

Na Figura 2, apresenta um exemplo da arquitetura CNN, onde temos o processo de convolução e *max pooling* no qual a saída da camada é o valor máximo de um grupo de neurônios. O objetivo da convolução é agrupar as camadas e reduzir a imagem de entrada em um formato simples para as camadas conseguirem processar. Inicialmente as CNNs se concentram em recursos de baixo nível antes de passar para recursos ou características de alto nível à medida que se aprofundam. A soma ponderada dos bits da imagem serve como base para a camada de junção e assim ao final classifica a imagem (MURPHY, 2016).

Figura 2 – Exemplo de *Convolutional Neural Network* (CNN)

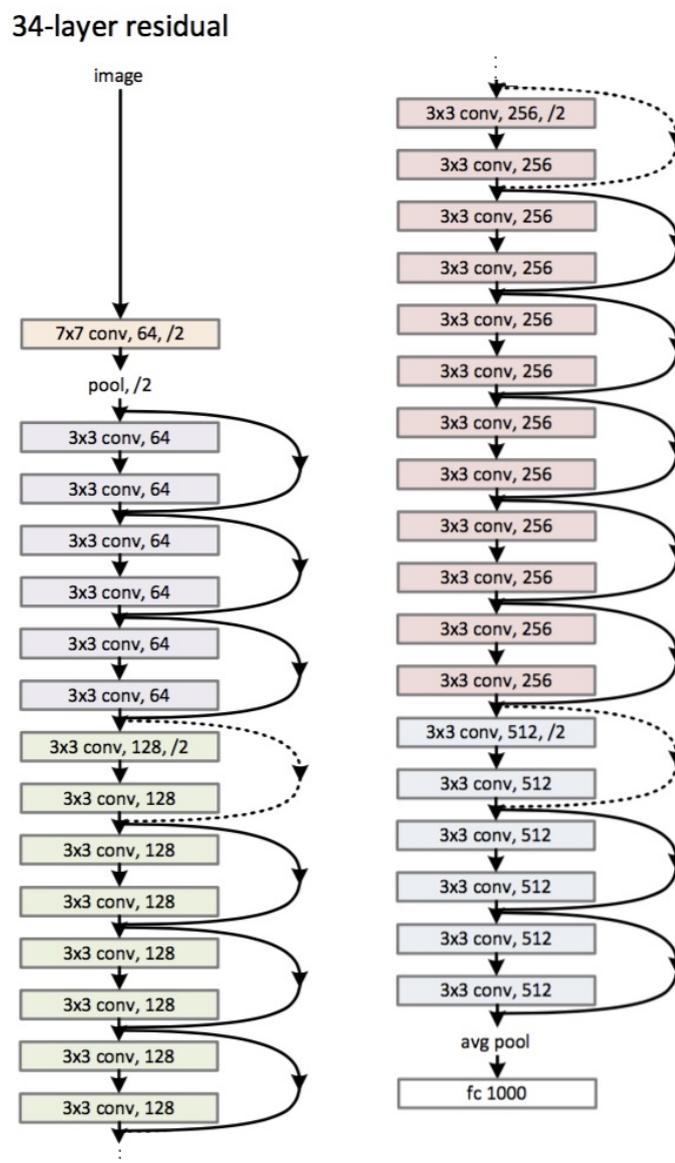


Fonte: (ACADEMY, 2022a).

- **Rede Neural Residual (ResNet):** A arquitetura de rede neural ResNet, é baseada na arquitetura CNN, projetada para tarefas de visão computacional como classificação de imagens e detecção de objetos. Essa arquitetura, foi introduzida por He et al. (2016), segundo Howard e Gugger (2020), é de longe o modelo de arquitetura mais usado atualmente na área de imagens. De acordo com He et al. (2016), os níveis de recursos podem ser enriquecidos pelo número de camadas empilhadas, basicamente, a arquitetura ResNet, são diversas camadas empilhadas, trazendo maior profundidade.

Na arquitetura ResNet, as camadas convolucionais são estendidas com conexões residuais (*skip connections*), que permitem o fluxo direto de dados pela rede. Isso ajuda a superar o problema do desvanecimento do gradiente (*vanishing gradient*), que ocorre quando o treinamento de uma rede é dificultado em redes muito profundas (HOWARD; GUGGER, 2020). Na Figura 3, é apresentada a arquitetura da Resnet com 34 camadas. Nota-se, os “saltos” de informações ilustrados pelas setas em curva na imagem. Para o desenvolvimento do modelo de IA, com a biblioteca FastAI, será adotado essa arquitetura.

Figura 3 – Arquitetura da *Residual Neural Network* (ResNet) com 34 camadas



Fonte: Adaptado de (HE et al., 2016).

### 2.1.3 Aprendizado por transferência

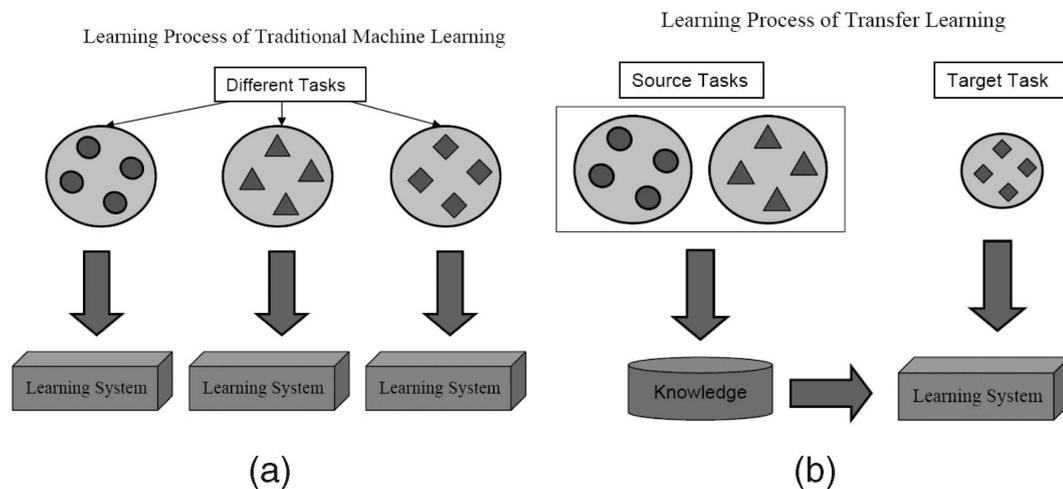
O aprendizado de máquina vem sendo aplicado com sucesso em diversas áreas e tem recebido atenção da indústria e na área acadêmica. O objetivo principal do aprendizado de máquina, é extrair e aprender estruturas de dados para estimar resultados futuros. As abordagens de aprendizado de máquina existentes, geralmente apresentam problemas com dados rotulado e não rotulados no mesmo espaço de recursos (NGUYEN et al., 2022).

As técnicas convencionais de aprendizado de máquina, apresenta um desempenho de previsão e classificação pouco eficaz, devido à falta de dados de treinamento, pois em alguns casos recolher os dados é muito complexo ou mesmo impossível (NGUYEN et al., 2022).

Uma solução para resolver esses problemas, é o aprendizado por transferência. Diferente do aprendizado de máquina tradicional, o principal fundamento do aprendizado por transferência, é a transferência de conhecimento de uma tarefa fonte para uma tarefa alvo relacionada para melhorar o aprendizado (NGUYEN et al., 2022). A motivação do aprendizado por transferência possibilita resolver novos problemas mais rapidamente e com mais eficiência usando o que já sabemos. Por exemplo, aqueles que aprenderam a tocar violino podem aprender a tocar violão mais rápido do que indivíduos que não têm experiência anterior com instrumentos musicais (NGUYEN et al., 2022) (WANGENHEIM, 2018).

Na Figura 4, pode-se observar a diferença entre os processos de aprendizagem de máquina tradicional e aprendizagem por transferência, onde no processo de aprendizado por transferência utilizam-se modelos previamente treinados no aprendizado de novas tarefas.

Figura 4 – Diferença entre os processos de aprendizado (a) aprendizado de máquina tradicional e (b) aprendizado de máquina por transferência



Fonte: (PAN; YANG, 2010).

## 2.1.4 Visão computacional

A visão computacional é o processo de replicação da visão humana, usando software e hardware (MARENGONI; STRINGHINI, 2009). No processo de visão computacional, é frequente a necessidade de etapas de pré-processamento. As imagens de onde queremos obter alguma informação, necessitam ser convertidas para um determinado formato ou tamanho, além de passarem por uma etapa de filtragem para remover ruídos vindos do processo de aquisição da imagem. As fontes dos ruídos são diversas, como o tipo de sensor, a iluminação do ambiente e as condições climáticas no momento da captura da imagem (MARENGONI; STRINGHINI, 2009).

Na Figura 5, são apresentados alguns exemplos da utilização da visão computacional em nossa vida cotidiana, como carros *self-driving* (veículos autônomos) e robôs de fábrica, entretanto, é utilizada também para identificar doenças médicas em raio-x, leitura de sinais de trânsito e reconhecendo pedestres (SZELISKI, 2022).

Figura 5 – Algumas aplicações industriais de visão computacional



(a) *Self-driving car*

(b) *Warehouse picking*

Fonte: (SZELISKI, 2022).

Há poucos anos, a criação e operação de redes neurais artificiais era impraticável devido ao alto nível de computação exigido. Os avanços no processamento paralelo, *Big Data* e utilização de *CNN* tem aumentado a taxa de precisão em atividades de visão computacional e com isso vem surgindo sistemas com nível de reconhecimento e classificação de imagens semelhante ao realizado por humanos. (ACADEMY, 2022c).

Ainda há muito o que fazer até que os algoritmos processem a visão da mesma forma como fazemos, mas considerando a rapidez com que as soluções de problemas de visão computacional progridem, é possível dizer que este é um dos campos mais promissores da IA (ACADEMY, 2022c).

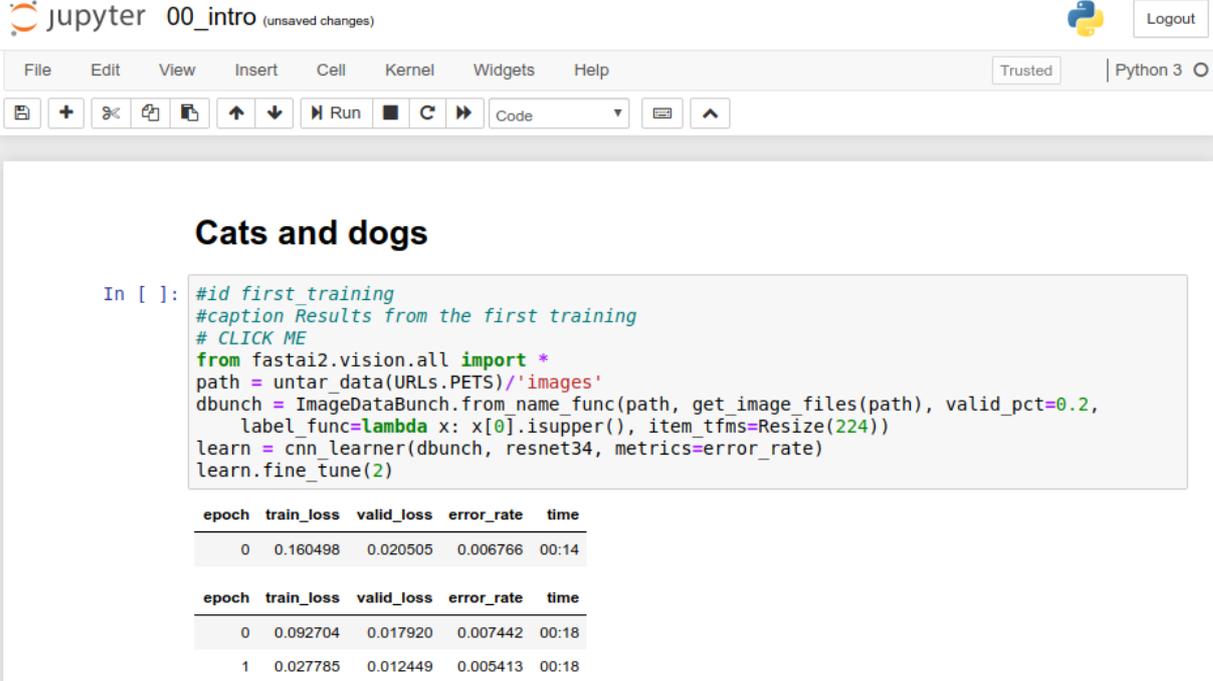
## 2.2 Fast AI

A fastAI é uma biblioteca de aprendizagem profundo de código aberto que simplifica a construção de modelos de IA, além disso, disponibiliza técnicas de processamento de linguagem natural, visão computacional, aprendizado por reforço e muito mais. É uma biblioteca com uma arquitetura em camadas, "que expressa padrões subjacentes comuns de muitas técnicas de aprendizagem profunda e processamento de dados em termos de abstrações dissociadas"(HOWARD; GUGGER, 2020).

O seu objetivo é a facilidade de uso, flexibilidade e produtividade, por ser altamente configurável. Sua estrutura se baseia em uma hierarquia de APIs de nível inferior que fornecem blocos de construção que podem ser combinados. Dessa forma, um usuário pode reescrever parte da API de alto nível, caso queira, ou adicionar um comportamento específico para atender às suas necessidades (HOWARD; GUGGER, 2020).

A Figura 6, apresenta um exemplo simples de código para a criação de um modelo treinado para identificar se a imagem analisada é um gato ou cachorro. Já o Código 2.1 é utilizado por Howard e Gugger (2020), o qual mostra o processo de inferência do modelo e a probabilidade de a imagem da Figura 7 ter sido classificada corretamente como um gato.

Figura 6 – Construção do primeiro modelo com a biblioteca FastAI



The screenshot shows a Jupyter Notebook titled '00\_intro' with the following code in a cell:

```
In [ ]: #id first training
#caption Results from the first training
# CLICK ME
from fastai2.vision.all import *
path = untar_data(URLs.PETS) / 'images'
dbunch = ImageDataBunch.from_name_func(path, get_image_files(path), valid_pct=0.2,
    label_func=lambda x: x[0].isupper(), item_tfms=Resize(224))
learn = cnn_learner(dbunch, resnet34, metrics=error_rate)
learn.fine_tune(2)
```

Below the code, there are two tables showing training progress metrics:

epoch	train_loss	valid_loss	error_rate	time
0	0.160498	0.020505	0.006766	00:14

epoch	train_loss	valid_loss	error_rate	time
0	0.092704	0.017920	0.007442	00:18
1	0.027785	0.012449	0.005413	00:18

Fonte: (HOWARD; GUGGER, 2020).

Figura 7 – Imagem fornecida ao modelo



Fonte: (HOWARD; GUGGER, 2020).

Código 2.1 – Código *Python* utilizado por Howard e Gugger (2020) para validar o modelo

```
1 img = PILImage.create('images/chapter1_cat_example.jpg')
2 img.to_thumb(192)
3
4 img = PILImage.create(uploader.data[0])
5 is_cat,_,probs = learn.predict(img)
6 print(f"Is this a cat?: {is_cat}.")
7 print(f"Probability it's a cat: {probs[1].item():.6f}")
8 Is this a cat?: True.
9 Probability it's a cat: 0.999986
```

## 2.3 Aplicação *mobile*

Atualmente, o Android da Google e o iOS da Apple são os sistemas operacionais mais populares para aparelhos móveis (HARAKAWA; PEREIRA, 2021). O desenvolvimento de um aplicativo, depende de diversos requisitos que irão apontar para tecnologias que garantem um melhor resultado.

O cenário do aplicativo móvel para este trabalho, depende da comunicação com uma *Application Programming Interface* (API) para apresentar os resultados retornados de forma amigável na tela do dispositivo. Para o desenvolvimento deste aplicativo, será utilizado a linguagem de programação *JavaScript*, uma vez que um dos maiores sites de perguntas e respostas sobre programação, o Stack Overflow, coloca o *JavaScript* como a linguagem mais utilizada pelos programadores no desenvolvimento *frontend* e *backend*, com 63.61% dos votos em 87.585 respostas (OVERFLOW, 2023).

No desenvolvimento *mobile*, existem diversos *frameworks*, porém para utilizar a linguagem *JavaScript*, deve ser utilizado o *framework React Native*, dado que este *framework* viabiliza a criação de aplicações *mobile* nativas para as plataformas iOS e Android e é amplamente adotado por grandes empresas como o *Facebook* (EISENMAN, 2017).

Conforme mencionado, o *React Native* é um *framework JavaScript* usado para criar aplicativos móveis nativos para os sistemas operacionais iOS e Android. É baseado no React, um *framework JavaScript* desenvolvido pelo *Facebook* para criar aplicações *Web* (EISENMAN, 2017). Antes do surgimento do React Native, desenvolver aplicações nativas para Android e iOS era mais complexo e mais caro. Era necessário que o desenvolvedor, dominasse duas plataformas e linguagens diferentes, como *Java/Kotlin* para Android e *ObjectiveC/Swift* para iOS. Como as empresas precisavam contratar desenvolvedores para cada sistema operacional, o projeto ficava mais caro e demorado.(ESCUDELARIO; PINHO, 2020). O React Native, é uma boa opção, por facilitar o desenvolvimento simultâneo para Android e iOS e fornece interfaces em *JavaScript* que permitem que os aplicativos construídos com essa tecnologia acessem recursos nativos dos dispositivos, como a câmera ou a localização do usuário (EISENMAN, 2017).

# 3 PROPOSTA

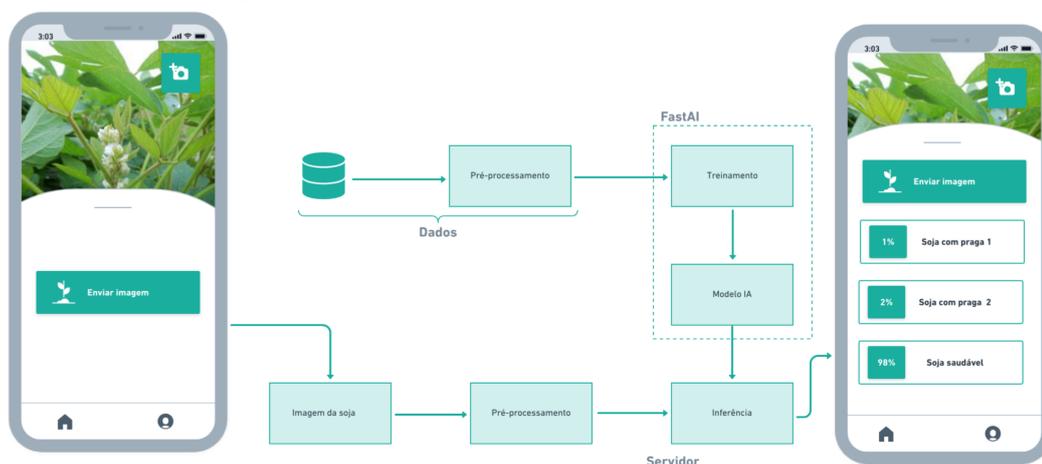
A proposta deste projeto de Trabalho de Conclusão de Curso (TCC) consiste no desenvolvimento de uma *Application Programming Interface* (API) que disponibiliza um *endpoint* com o modelo de aprendizado de máquina e um aplicativo móvel para o envio de imagens e visualização do resultado. A arquitetura adotada para a IA é uma rede neural profunda, que será previamente treinada por meio de uma ampla base dados com imagens de sojas saudáveis e com diferentes pragas utilizando a biblioteca FastAI e linguagem de programação *Python*. Esta aplicação visa a detecção de pragas em plantações de soja a partir de imagens fornecidas pelo aplicativo móvel, devolvendo o resultado da inferência ao usuário.

## 3.1 Proposta de Arquitetura

A arquitetura do projeto, é apresentada na *Figura 8*, que consiste em:

- Realizar o pré-processamento das imagens de soja por meio de bases de dados com imagens adequadas.
- Treinar e gerar o modelo no âmbito da soja com a utilização da biblioteca FastAi.
- Enviar imagens por meio de um aplicativo móvel para o *endpoint* da API no qual o modelo treinado está disponível.
- Apresentar o resultado da inferência retornado pela API ao usuário no aplicativo.

Figura 8 – Diagrama da arquitetura do projeto



Fonte: Elaborada pelo autor.

## 3.2 Metodologia

Este trabalho foi dividido em quatro etapas, sendo a primeira encontrar uma base de dados representativa para o trabalho e realizar o pré-processamento dos dados. A segunda etapa, é realizar o treinamento e criação do modelo, além dos testes de desempenho. Na terceira etapa, será desenvolvido a aplicação servidora e o aplicativo móvel. Por fim, a quarta etapa será feito a integração das aplicações.

A definição da base dados, consiste em encontrar imagens de soja com diferentes pragas e também de sojas saudáveis, para gerar um modelo com uma boa assertividade.

Após definir a base dados, será realizado o treinamento e geração do modelo no âmbito da soja, este processo, será feito com o uso da biblioteca FastAi e linguagem de programação *Python*, dado que facilita a geração do modelo com redes neurais profundas.

Com o modelo finalizado e testado, será implementado uma [API](#) para disponibilizar o *endpoint* que utiliza o modelo previamente treinado, sendo responsável por receber as imagens e identificar as pragas. Em seguida, será desenvolvido o aplicativo móvel, tendo como responsabilidade o envio de imagens para API e apresentar o resultado retornado.

Após validar a API e o aplicativo móvel, será realizado a integração. Em que, a API irá receber a imagem e devolver o resultado ao usuário.

### 3.2.1 Cronograma de Atividades

Para conclusão de todas as etapas elencadas, está organizado o seguinte cronograma:

Tabela 1 – Cronograma de atividades

Etapas	Mês					
	Fev	Mar	Abr	Mai	Jun	Jul
Definição das bases de dados do projeto	✓	✓				
Implementação do modelo de IA		✓	✓			
Implementação da API e aplicativo móvel			✓	✓	✓	
Integração das aplicações				✓	✓	
Elaboração do documento final			✓	✓	✓	✓

Fonte: Elaborada pelo autor.

### 3.3 Resultados esperados

Ao final deste trabalho, espera-se que a implementação do modelo para detecção de pragas, possua uma boa assertividade e o aplicativo móvel esteja funcional. Além disso, o aplicativo de celular, deve se comunicar com a [API](#) para o envio das imagens, portanto, é esperado que a integração entre as aplicações esteja adequado. A assertividade do modelo, depende de uma base de dados representativa, diante disso, espera-se que seja possível encontrar bases de dados adequadas para o projeto.

# REFERÊNCIAS

- ACADEMY, D. S. *Capítulo 10 - As 10 Principais Arquiteturas de Redes Neurais*. [s.n.], 2022. Disponível em: <https://www.deeplearningbook.com.br/as-10-principais-arquiteturas-de-redes-neurais/>. 11, 12
- ACADEMY, D. S. *Capítulo 3 - O Que São Redes Neurais Artificiais Profundas ou Deep Learning?* [s.n.], 2022. Disponível em: <https://www.deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/>. 11
- ACADEMY, D. S. *O Que é Visão Computacional?* 2022. Disponível em: [https://blog.dsacademy.com.br/o-que-e-visao\\_computacional/](https://blog.dsacademy.com.br/o-que-e-visao_computacional/). 15
- AIRES, R. *Tecnologia no agronegócio: importância e principais tendências*. 2023. Disponível em: <https://www.agriq.com.br/tecnologia-no-agronegocio/>. 8
- DALL'AGNOL, A. et al. *Importância socioeconômica da soja - Portal Embrapa*. 2021. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/soja/pre-producao/socioeconomia/importancia-socioeconomica-da-soja>. 8
- EISENMAN, B. *Learning React Native: Building Native Mobile Apps with JavaScript*. [S.l.]: O'Reilly Media, 2017. ISBN 978-1-4919-8909-8. 17, 18
- EMBRAPA. *VII Plano Diretor da Embrapa 2020-2030*. 2020. Disponível em: <https://www.embrapa.br/vii-plano-diretor>. 8
- ESCUDELARIO, B.; PINHO, D. *React Native: Desenvolvimento de aplicativos mobile com React*. [S.l.]: Casa do Código, 2020. ISBN 9786586110067. 18
- FERREIRA, B. S. C.; CAMPO, C. B. H.; GÓMEZ, D. R. S. Inimigos naturais de *Helicoverpa armigera* em soja. 2014. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/107296/1/Inimigos-naturais-de-Helicoverpa-armigera-em-soja.pdf>. 9
- HARAKAWA, F. S.; PEREIRA, A. S. Desenvolvimento e Implementação do Aplicativo Mobile Blog de Todas. 2021. Disponível em: [https://repositorio.ufsm.br/bitstream/handle/1/25618/Harakawa\\_Felipe\\_Seidi\\_2021\\_TCC.pdf?sequence=1&isAllowed=y](https://repositorio.ufsm.br/bitstream/handle/1/25618/Harakawa_Felipe_Seidi_2021_TCC.pdf?sequence=1&isAllowed=y). 17
- HE, K. et al. Deep residual learning for image recognition. 2016. Disponível em: <https://ieeexplore-ieee-org.ez130.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=7780459>. 12, 13
- HONAVAR, V. Artificial Intelligence: An Overview. 2016. Disponível em: <https://faculty.ist.psu.edu/vhonavar/Courses/ai/handout1.pdf>. 10
- HOWARD, J.; GUGGER, S. *Deep Learning for Coders with fastai and PyTorch*. [S.l.]: O'Reilly Media, 2020. ISBN 978-1-4920-4549-6. 5, 12, 13, 16, 17
- LEIJNEN STEFAN, F. v. V. *The Neural Network Zoo*. [s.n.], 2019. Disponível em: <https://www.asimovinstitute.org/neural-network-zoo/>. 11

- MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à Visão Computacional usando OpenCV. *Revista de Informática Teórica e Aplicada*, v. 16, n. 1, p. 125–160, 2009. ISSN 2175-2745. Number: 1. Disponível em: [https://seer.ufrgs.br/index.php/rita/article/view/rita\\_v16\\_n1\\_p125](https://seer.ufrgs.br/index.php/rita/article/view/rita_v16_n1_p125). 15
- MILLINGTON, I. *Artificial Intelligence for Games*. [S.l.]: Taylor & Francis, 2006. (Morgan Kaufmann series in interactive 3D technology). ISBN 978-0-12-497782-2. 10
- MORETI, M. P. et al. Inteligência Artificial no Agronegócio e os Desafios para a Proteção da Propriedade Intelectual. *Cadernos de Prospecção*, v. 14, n. 1, p. 60–60, jan. 2021. ISSN 2317-0026. Number: 1. Disponível em: <https://periodicos.ufba.br/index.php/nit/article/view/33098>. 10
- MURPHY, J. M. J. An Overview of Convolutional Neural Network Architectures for Deep Learning. 2016. Disponível em: [https://www.microway.com/download/whitepaper/An\\_Overview\\_of\\_Convolutional\\_Neural\\_Network\\_Architectures\\_for\\_Deep\\_Learning\\_fall2016.pdf](https://www.microway.com/download/whitepaper/An_Overview_of_Convolutional_Neural_Network_Architectures_for_Deep_Learning_fall2016.pdf). 12
- NGUYEN, C. T. et al. Transfer Learning for Wireless Networks: A Comprehensive Survey. *Proceedings of the IEEE*, v. 110, n. 8, p. 1073–1115, ago. 2022. ISSN 0018-9219, 1558-2256. Disponível em: <https://ieeexplore.ieee.org/document/9789336/>. 14
- NORVIG, P.; RUSSELL, S. *Inteligência Artificial*. 3. ed. ELSEVIER EDITORA, 2013. ISBN 978-85-352-3701-6. Disponível em: <https://www.cin.ufpe.br/~gtsa/Periodo/PDF/4P/SI.pdf>. 10
- OVERFLOW, S. *Most popular technologies*. 2023. Disponível em: <https://survey.stackoverflow.co/2023/#most-popular-technologies-language>. 17
- PAN, S. J.; YANG, Q. A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, v. 22, n. 10, p. 1345–1359, out. 2010. ISSN 1041-4347. Disponível em: <http://ieeexplore.ieee.org/document/5288526/>. 14
- PANG, Y. et al. Convolution in Convolution for Network in Network. *IEEE Transactions on Neural Networks and Learning Systems*, v. 29, n. 5, p. 1587–1597, maio 2018. ISSN 2162-237X, 2162-2388. Disponível em: <https://ieeexplore.ieee.org/document/7879808/>. 12
- PATTERSON, J.; GIBSON, A. *Deep Learning: A Practitioner's Approach*. [S.l.]: O'Reilly, 2017. ISBN 978-1-4919-1425-0. 10
- PINHEIRO, R. de M. et al. Inteligência artificial na agricultura com aplicabilidade no setor sementeiro | Diversitas Journal. ago. 2021. Disponível em: [https://diversitasjournal.com.br/diversitas\\_journal/article/view/1857](https://diversitasjournal.com.br/diversitas_journal/article/view/1857). 10
- SHINDE, P. P.; SHAH, S. A Review of Machine Learning and Deep Learning Applications. IEEE, Pune, India, p. 1–6, ago. 2018. Disponível em: <https://ieeexplore.ieee.org/document/8697857/>. 10, 11
- SZELISKI, R. *Computer Vision: Algorithms and Applications*. [S.l.]: Springer International Publishing, 2022. (Texts in Computer Science). ISBN 978-3-030-34372-9. 15

WANGENHEIM, A. von. *Deep Learning::Aprendizado por Transferência e Ajuste Fino*. 2018. Disponível em: <https://lapix.ufsc.br/ensino/visao/visao-computacionaldeep-learning/deep-learningaprendizado-por-transferencia-e-ajuste-fino/>. 14