

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA E DE ARTES
ENGENHARIA DE CONTROLE E AUTOMAÇÃO
Trabalho Final de Curso II

Estêvão Santos Cavalcante

**ANÁLISE PREDITIVA COM REDES NEURAI CONVOLUCIONAIS PARA O
GEOPROCESSAMENTO DE IMAGENS**

Trabalho Final de Curso II como parte dos requisitos para obtenção do título de bacharel em Engenharia de Controle e Automação apresentado à Pontifícia Universidade Católica de Goiás.

BANCA EXAMINADORA:

Prof. Dr. Marcos Antônio de Sousa – Orientador. POLI-PUC Goiás.
Prof. Dr. Antônio Marcos de Melo Medeiros – POLI-PUC Goiás.
Prof. Dr. Bruno Quirino de Oliveira – POLI-PUC Goiás.

Goiânia, 14 de junho de 2023.

Análise Preditiva com Redes Neurais Convolucionais para o Geoprocessamento de Imagens

ESTÊVÃO SANTOS CAVALCANTE, MARCOS A. SOUSA

Abstract— This course conclusion work presents the development of a Convolutional Neural Network (CNN) with the objective of executing image geoprocessing predictions, based on input data. The system allows the analysis of inputs and results in an output value characterized by the value of the prediction, making possible the predictability of future scenarios. A system was developed based on the developed techniques, obtained through research, to implement the prediction of image assertiveness by the applied training. The performance of the developed system was verified with values obtained through a hypothetical scenario. The results are presented and discussed.

Keywords – Convolutional neural network, artificial intelligence, prediction, images, geoprocessing.

Resumo – Este trabalho de conclusão de curso apresenta o desenvolvimento de uma Rede Neural Convolutiva (RNC) com o objetivo de executar processos de geoprocessamento, com destaque para a classificação de imagens de vegetação na produção agrícola. O sistema permite a análise de *inputs* e resulta em um valor de saída caracterizado pelo valor da predição, tornando possível a previsibilidade de cenários futuros. Foi desenvolvido um sistema baseado nas técnicas desenvolvidas, obtidas através de pesquisas, para implementar a previsão da assertividade na classificação de imagens de acordo com o treinamento aplicado. O desempenho do sistema desenvolvido é averiguado com valores obtidos por meio de um cenário hipotético. Os resultados são apresentados e discutidos.

Palavras-chave – Rede neural convolutiva, inteligência artificial, predição, imagens, geoprocessamento.

I. INTRODUÇÃO

As pragas em lavouras causam prejuízos econômicos na agricultura, reduzindo a produção e consequentemente os lucros. O manejo de pragas é essencial, para reduzir estes prejuízos, e consiste na identificação e posterior controle desse tipo de ameaça. O controle é fundamentalmente dependente da identificação, pois é a partir dela que o manejo é feito. A identificação é feita visualmente, baseando-se nas características da praga. Essas características são inerentes e diferem de espécie para espécie. Devido à dificuldade da identificação, esse processo é realizado principalmente por profissionais especializados na área, o que acarreta a concentração do conhecimento [1].

O sensoriamento remoto é uma solução muito interessante, pois possibilita a obtenção de informações sobre alvos na superfície terrestre, sem a necessidade de um contato direto. Geralmente esses sensores estão presentes em plataformas orbitais como satélites ou aviões.

Contraopondo-se às imagens de radar, resultado do retroespalhamento da radiação eletromagnética de comprimentos longos (1 mm a 1 m), estão as imagens ópticas, geradas a partir da reflexão da radiação eletromagnética no visível, infravermelho próximo e infravermelho de ondas curtas. Enquanto nas imagens de radar o que importa são as características físicas e macroscópicas da superfície (principalmente rugosidade, textura, estrutura e umidade), no sensoriamento óptico, o conjunto de respostas espectrais é resultado de interações microscópicas, determinado pela composição atômico-molecular dos materiais (ex. variação no teor de clorofila de uma folha, fazendo-a mais ou menos verde [1]).

Imagens de satélites são, em fato, um conjunto de dados em formato matricial, cujos vetores x , y (localização) e z (valores radiométricos) são passíveis das mais variadas transformações algébricas para fins de realce espectral e/ou espacial, com a geração ou não de novos vetores, com possibilidade de criação de novos conjuntos de dados e, consequentemente, novas análises estatísticas. No caso de estudos envolvendo a vegetação, duas transformações espectrais são particularmente importantes: os índices de vegetação, largamente utilizados como intermediários na obtenção de parâmetros biofísicos e no acompanhamento da dinâmica sazonal e fenológica; e os chamados modelos de mistura espectral que, ao decomporem o sinal do pixel em seus vários constituintes (solos, vegetação, água etc.), facilitam o mapeamento de classes e variações fitofisiológicas, bem como de importantes fatores abióticos, controlando estas distribuições (ex. delimitação de áreas sujeitas a inundação, transferência de sedimentos etc.) [2].

A lógica por trás dos índices de vegetação baseia-se no fato de que a energia refletida no vermelho e infravermelho próximo é diretamente relacionada à atividade fotossintética da vegetação, bem como na suposição de que a utilização de duas ou mais bandas espectrais pode, substancialmente, minimizar as principais fontes de ruídos que afetam a resposta da vegetação: (1) variações na irradiância solar; (2) efeitos atmosféricos; (3) contribuições da vegetação não-fotossinteticamente ativa; (4) contribuições do substrato (ex. solo); e (5) efeitos da composição e estrutura do dossel.

Um dos índices de vegetação mais utilizados tem sido o chamado índice de vegetação da diferença normalizada (NDVI). Sua simplicidade e sua relativa alta sensibilidade à densidade da cobertura vegetal tornaram possíveis comparações espaciais e temporais da atividade fotossintética terrestre, bem como o monitoramento sazonal, interanual e variações de longo prazo dos parâmetros estruturais, fenológicos e biofísicos da vegetação em escala global [2].

Nos últimos anos, técnicas de Inteligência Artificial (IA) vêm se destacando como ferramenta promissora na análise e classificação de imagens de geoprocessamento. A Inteligência Artificial consiste em uma vasta categoria de algoritmos e tecnologias utilizados para extrair, armazenar, analisar e transformar grandes volumes de dados, produzindo um ambiente de conhecimento, onde há produção sistemática de informação relevante, veloz e consistente, capaz de auxiliar as empresas a tomarem melhores decisões, baseado em fatos, com profundidade suficiente para descobrir as causas de uma tendência ou de um problema [3].

Dentre as várias técnicas de IA existe uma área de pesquisa chamada aprendizagem de máquina, com destaque para as Redes Neurais Artificiais (RNA), que visa fazer uma máquina (ou algoritmo) detectar e extrapolar novos padrões, com a capacidade de adaptação às novas circunstâncias. Esta área pode ser dividida em três ramos: aprendizagem supervisionada, não supervisionada e por reforço. O problema abordado na aprendizagem supervisionada é focado em aprender uma função a partir de exemplos em suas entradas e resultados. A aprendizagem não supervisionada visa aprender padrões em suas entradas, mas com nenhuma saída especificada. Na aprendizagem por reforço, um agente deve aprender a realizar alguma tarefa de acordo com a recompensa relacionada a uma entrada [4].

A Rede Neural Convolucional (RNC) é uma das ferramentas usadas na aprendizagem de máquina, com ênfase na análise de imagem. Além disso, o reconhecimento de objetos em imagens está se tornando cada vez mais fácil para os computadores, devido aos avanços em estudos de visão computacional que utilizam redes neurais de aprendizagem profunda. Essas redes tiveram grandes avanços a partir de 2012 e vêm sendo usadas em diversos problemas de classificações que envolvem imagens [5].

Uma RNC é composta por camadas que estão encadeadas e mapeiam os dados de entrada para fazer previsões de acordo com as classes definidas. Cada camada de entrada da rede contém neurônios que codificam os valores de entrada, ou seja, as saídas de algumas camadas se tornam entradas para as camadas seguintes.

As camadas possuem parâmetros a serem estimados que são chamados de pesos, os quais são usados para armazenar o conhecimento adquirido nas etapas de aprendizagem. Estes pesos são ajustados na medida que as camadas vão extraíndo *features* (atributos específicos de um objeto), com as informações de entrada. Assim, a rede aprende com os dados de entrada e consegue estimar uma saída. No contexto de classificação de imagens de produção agrícola, a rede pode estimar, por exemplo, se uma imagem é de uma folha de soja saudável ou não, a partir de *features* como: cor, formato e tamanho das folhas.

Nas seções seguintes serão detalhadas as etapas de construção do sistema de geoprocessamento de imagens. A seção II descreve as técnicas de inteligência artificial e os processos de aprendizagem de sistemas especialistas baseados em IA. A seção III destaca os principais elementos das Redes Neurais Convolucionais, bem como as suas aplicações, vantagens e desvantagens. O protótipo do sistema desenvolvido é detalhado na seção IV, com destaque para o processo de implementação computacional. Os resultados mais relevantes das simulações computacionais, juntamente com as suas discussões, podem ser conferidos na seção V. Por

fim, a seção VI descreve as conclusões gerais sobre o trabalho.

II. FUNDAMENTAÇÃO TEÓRICA

A Inteligência Artificial (IA) é um ramo de pesquisa da ciência da computação que busca, através de símbolos computacionais, construir mecanismos e/ou dispositivos que simulem a capacidade do ser humano de pensar, resolver problemas, ou seja, de ser inteligente.

Uma solução de IA envolve um agrupamento de várias tecnologias, como redes neurais artificiais, algoritmos, sistemas de aprendizado, entre outros que conseguem simular capacidades humanas ligadas à inteligência. Por exemplo, o raciocínio, a percepção de ambiente e a habilidade de análise para a tomada de decisão [6].

Há um potencial benéfico para organizações que adotaram essa tecnologia, independentemente da área em que se encontram. Isso porque ela vai além da automação mecânica, englobando processos cognitivos, que geram uma capacidade de aprendizado. Dessa forma, um sistema de Inteligência Artificial consegue realizar atividades não apenas repetitivas, numerosas e manuais, como também as que demandam análise e tomada de decisão.

As técnicas de Inteligência Artificial podem ser divididas em dois grandes grupos: Inteligência Artificial Clássica, que envolve basicamente os sistemas especialistas e sistemas baseados em raciocínio ou inferência lógica; e a Inteligência Computacional ou Aprendizagem de Máquina, que tem como base a concepção de que sistemas tecnológicos podem aprender usando dados, de modo a descobrir padrões, tomar decisões e se aperfeiçoar com pouca interferência humana. Dessa forma, pode melhorar a realização de uma atividade ao longo do tempo.

A. Técnicas de Análise de Imagem

As diversas técnicas de aplicação da Inteligência Artificial variam no funcionamento, na lógica aplicada e, principalmente, na saída que se espera dos algoritmos desenvolvidos. Neste contexto, a aprendizagem de máquina (*machine learning*) apresenta-se como um conjunto de técnicas de inteligência artificial que visam reconhecer padrões em base de dados. A aprendizagem de máquina agrega qualidade na geração de informação e conhecimento, auxiliando os gestores, e melhorando os processos de tomadas de decisão das empresas.

Entre as principais tarefas que se podem ser executadas com a aplicação de técnicas de aprendizagem de máquina se destacam: análise descritiva de dados, predição (classificação e estimação), análise de grupos, associação e detecção de anomalias [8]. Neste trabalho pretende-se abordar o estudo de problemas de predição, com destaque para o processo de classificação de imagens de geoprocessamento. Entre os principais métodos testados na aprendizagem de máquina deste trabalho, podem ser destacados: Regressão Logística, *Random Forest* e Redes Neurais Convolucionais.

Regressão Logística

Na regressão logística a variável dependente tem apenas duas categorias⁶. Em geral, a ocorrência do evento de interesse é codificada como “1” e a ausência como “0”. Lembrando que a codificação altera o sinal dos coeficientes e, portanto, sua interpretação substantiva. Para melhor

entender o funcionamento da regressão logística é necessário compreender a lógica da análise de regressão de forma geral. Vejamos a notação clássica do modelo linear [9]:

$$Y = \alpha + \beta * X + \varepsilon$$

Y representa a variável dependente, ou seja, aquilo que queremos entender/explicar/predizer. X representa a variável independente. O intercepto, (α), representa o valor de Y quando X assume valor zero. O coeficiente de regressão, (β), representa a variação observada em Y associada ao aumento de uma unidade em X. O termo estocástico, (ε), representa o erro do modelo. Tecnicamente, é possível estimar se existe relação linear entre uma variável dependente (Y) e diferentes variáveis independentes. Como a variável dependente no modelo logístico assume apenas dois valores (0 ou 1), a probabilidade predita pelo modelo também deve se limitar ao referido intervalo. Quando X (variável independente) assume valores mais baixos, a probabilidade se aproxima de zero. No outro oposto, na medida em que X aumenta, a probabilidade se aproxima de um. A Figura 1 descreve uma possível relação entre as variáveis X e Y.

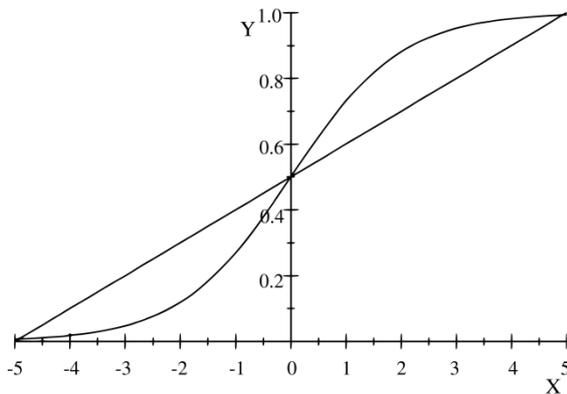


Figura 1. Reta de regressão linear versus curva logística [9].

Random Forest

A técnica *Random Forest* (RF) pode ser vista como um classificador formado por uma coleção de árvores de classificação, cada qual construída a partir de uma amostra, ou seja, estimativa da precisão de amostras estatísticas (medianas, variâncias, percentagens) pelo uso de subconjuntos de dados disponíveis, aleatória do conjunto de treinamento original. A classificação de um vetor de características x é feita por votação, submetendo-se o vetor às árvores da floresta e atribuindo-se a x , a classe mais votada [10].

Na construção das árvores em uma RF (Figura 2), atributos com maior relevância global tendem a ser escolhidos antes dos atributos com relevância local. Logo, tendem a aparecer nos nós mais próximos à raiz, sobre os quais incidem as maiores quantidades de exemplos [11]. As árvores são expandidas ao máximo, sem poda. Para a divisão de cada nó, um subconjunto de tamanho fixo dos atributos de entrada é selecionado aleatoriamente, escolhendo-se a divisão ótima dentro desse subconjunto.

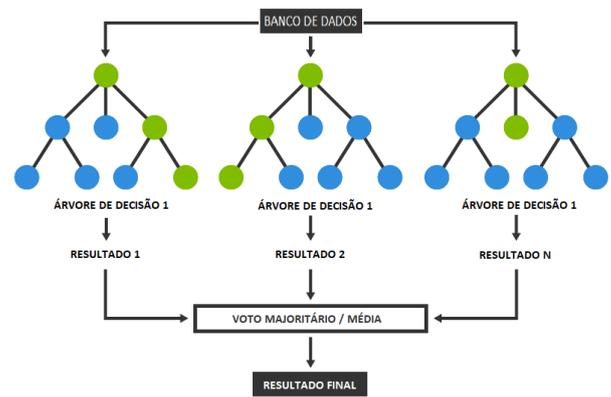


Figura 2. Exemplificação de uma Random Forest (adaptada de [11]).

Redes Neurais Convolucionais (RNC)

A RNC é provavelmente o modelo de *Deep Learning* mais conhecido e utilizado atualmente. O que caracteriza esse tipo de rede é ser composto basicamente de camadas convolucionais que processam as entradas considerando campos receptivos locais, as quais funcionam como extratores de características. Adicionalmente, incluem também operações conhecidas como *pooling*, responsáveis por reduzir a dimensionalidade espacial das representações [12].

Na camada convolucional, cada neurônio é um filtro aplicado a uma imagem de entrada. Um filtro é uma matriz de pesos que faz uma combinação linear dos pixels vizinhos e, por isso, considera-se que a convolução filtra as imagens levando em conta sua estrutura bidimensional. Cada representação gerada por um filtro da camada convolucional é conhecida como mapa de características. Estes são empilhados, formando um *tensor* com profundidade igual ao número de filtros, o qual será a entrada para a próxima camada da rede, como mostrados na figura 3.

A camada de *pooling* é utilizada para reduzir a dimensionalidade ao longo das camadas da rede, mas há estudos a favor de não utilizar *pooling* e sim aumentar o passo (*stride*) nas convoluções. A camada de *dropout* aleatoriamente desativa com probabilidade p a ativação de neurônios na fase de treinamento e durante o passo de propagação dos dados pela rede. Ao longo das iterações, isso dá um efeito que minimiza a variância e aumenta o viés das funções e, por isso, foi demonstrado que a saída tem relação como método de ensemble *bagging*.

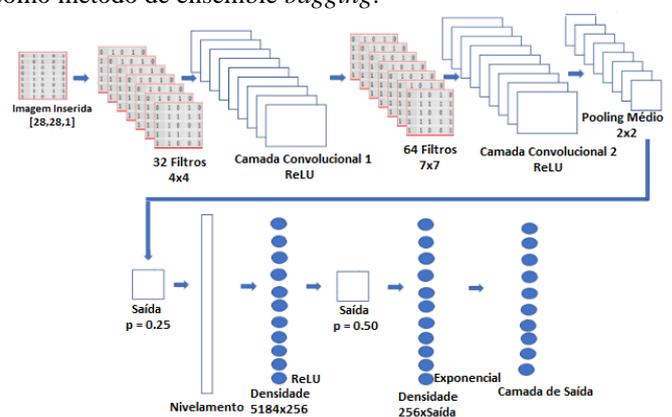


Figura 3. Exemplificação do tratamento de camadas de uma Rede Neural Convolucional (adaptada de [12]).

B. Trabalhos Relacionados

Alguns trabalhos relacionados com o presente artigo são: “Classificação de imagens de ideogramas Kuzushiji com Redes Neurais Convolucionais” [12], que tem como síntese a avaliação de algoritmos de aprendizado de máquina para a classificação de um conjunto de imagens de ideogramas japoneses, em estilo cursivo Kuzushiji.

Já o artigo “Resumo de Grandes Volumes de Dados com Filtro de Bloom: Uma Abordagem Eficiente para Aprendizado Profundo com Redes Neurais Convolucionais em Fluxos de Rede” [13], tem como objetivo a geração de resumos de dados bidimensionais a partir de fluxos em uma janela de uso da rede formando um mapa de bits.

E de grande valia, o trabalho “Rede Neural Convolutiva e LSTM para Biometria Baseada em EEG no Modo de Identificação” [15], que utiliza a RNC para a construção de um sistema biométrico.

III. REDE NEURAL CONVOLUCIONAL

O fator mais importante presente nas redes neurais artificiais/machine learning, é a habilidade de aprender e, dessa forma, melhorar gradativamente o seu desempenho, assim como ocorre com um bebê aprendendo suas funções motoras básicas por tentativa e erro, e visualizando os atos de seus responsáveis [7].

O que caracteriza a RNC é ser composta basicamente de camadas convolucionais que processam as entradas considerando campos receptivos locais, as quais funcionam como extratores de características. Incluem também operações conhecidas como *pooling*, responsáveis por reduzir a dimensionalidade espacial das representações [12].

A. Funcionamento de uma RNC

O funcionamento de uma RNC é determinado de forma simplificada na Figura 5:

- Uma rede neural convolutiva analisa conjuntos de dados em duas dimensões [16];
- Para cada conjunto de pixels da imagem, o neurônio multiplica o valor dos pixels pelo valor do peso correspondente e soma todos eles;
- A RNC gera grande custo computacional e ao algoritmo. Para tentar minimizar esse custo, emprega-se algumas camadas cujo objetivo é reduzir o tamanho da saída gerada por um neurônio.

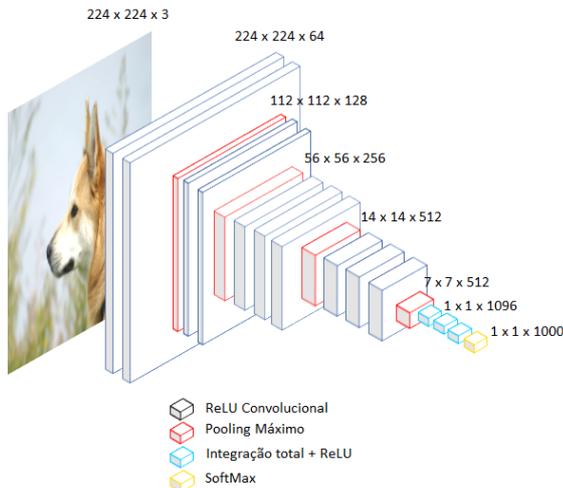


Figura 5. Modelo de uma RNC simplificada (adaptada de [16]).

Por meio do treinamento da RNC, melhora-se a acertabilidade no reconhecimento de imagens, além de utilizar melhor a capacidade operacional da CPU do usuário sem comprometer a aplicação.

B. Treinamento de uma RNC

O treinamento de uma RNC é uma tarefa deveras importante pois ao efetuar essa etapa, melhora-se o reconhecimento de imagem, quanto a precisão e a acurácia.

O treinamento da rede neural convolutiva é baseado na minimização da função de perda definida no modelo. O procedimento de treinamento para redes neurais convolucionais é semelhante ao das redes neurais artificiais convencionais com uso de retropropagação (*backward propagation*) [13]. A minimização da função de perda, representando o erro de classificação da rede, é realizada pelo método do gradiente descendente estocástico. Na primeira fase, as informações são propagadas através das camadas na direção de classificação da rede, calculando os valores da saída. Na segunda fase, o erro entre os valores esperados e os reais da saída é calculado. Retropropagando e minimizando esse erro, a matriz de peso é ajustada posteriormente e a rede é então ajustada com precisão [13].

No Aprendizado Supervisionado, é necessário um *dataset* de treino, no qual são conhecidos os valores corretos de saída para as entradas correspondentes. A partir dele, é treinado o algoritmo que aprende a prever resultados, com certo grau de acurácia, previamente desconhecidos [17].

No Aprendizado Não Supervisionado, o algoritmo procura separar os dados em grupos com características similares. Não há *dataset* para treino, ou seja, não há informação prévia sobre em qual grupo pertence uma determinada entrada.

Já o Aprendizado por Reforço se assemelha com o primeiro tipo de aprendizado no sentido de aprender com as experiências anteriores e com o segundo no sentido de aprender de uma forma não supervisionada.

Pode-se ver os tipos de aprendizado de maneira simplificada na Figura 6. E, o tipo de aprendizagem escolhido para a execução deste projeto foi o Aprendizado Supervisionado, pois já há a resposta prévia do que o programa tem que analisar, ou seja, já se sabe que as seis imagens usadas para teste são de folhas de soja saudáveis ou doentes.

Tipos de Machine Learning

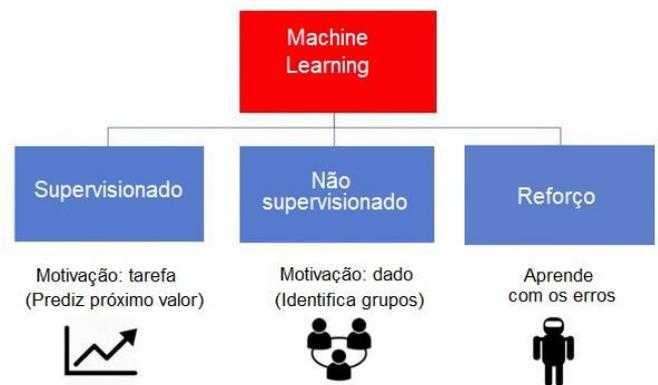


Figura 6. Diferença dos 3 tipos de aprendizado em RNC [17].

C. Aplicações de uma RNC

Imagens são, em fato, um conjunto de dados em formato matricial, cujos vetores x , y (localização) e z (valores radiométricos) são passíveis das mais variadas transformações algébricas para fins de realce espectral e/ou espacial (com a geração ou não de novos vetores, e novos conjuntos de dados) e análises estatísticas [2].

Logo, para uma aplicação como geoprocessamento remoto, a RNC treinada por Aprendizado Supervisionado torna-se bastante eficaz, afinal o geoprocessamento consiste no processamento de dados geoespaciais, produzindo informações a partir de dados de entrada.

Algumas vantagens que podem ser destacadas a favor das Redes Neurais Convolucionais, na predição e classificação de imagens de vegetação agrícola, são [16]:

- Capacidade de atingir alto desempenho em tarefas visuais complexas;
- Capacidade de aprender automaticamente um grande número de filtros;
- Muito flexível, permitindo a solução de problemas de diferentes segmentos;
- Reconhecimento de imagens com altíssimas taxas de acerto;
- Possui sucesso em experimentos envolvendo processamento de vídeo, voz e linguagem natural.

Por outro lado, a utilização de Redes Neurais Convolucionais ainda possui alguns desafios relevantes. Algumas características da RNC frente a outras técnicas de predição e classificação de imagens que podem ser observadas como desvantagens [16]:

- Requer uma quantidade consideravelmente alta de dados;
- Demanda alto poder computacional (dependendo da aplicação);
- O ajuste de parâmetros de uma RNC pode ser extremamente difícil para determinada aplicação.

IV. MATERIAIS E MÉTODOS

O projeto dividiu-se em três etapas: Estudo sobre técnicas de IA, ou seja, quais metodologias e parâmetros a serem utilizados para o treinamento da RNC; seguido de um treinamento no Orange [14], conforme a Figura 7, para definir qual técnica de análise de imagens seguir; e, por último, desenvolver um programa de reconhecimento de imagens na linguagem Python [18].

Dentre diversas linguagens de programação voltadas para o desenvolvimento de uma IA, foi escolhido o Python pelas seguintes características [18]:

- Fácil entendimento para um programador iniciante ou experiente com outras linguagens;
- Hospeda milhares de bibliotecas de terceiros;
- Possui comunidade que organiza conferências e encontros, colabora em código e muito mais;
- É desenvolvido sob uma licença de código aberto, tornando-o livremente utilizável e distribuível, mesmo para uso comercial.

A rede neural convolucional é desenvolvida para auxiliar no processo de tomada de decisão em cenário de controle de pragas em plantação de soja. A partir da análise das imagens coletadas e comparadas com a *database*, o sistema deve ser capaz de dizer se uma imagem de um quadrante coletado da plantação está com suas folhas saudáveis ou com doença

(diabrotica speciosa, por exemplo) [19], marcas de furos deixadas por insetos nas folhas.

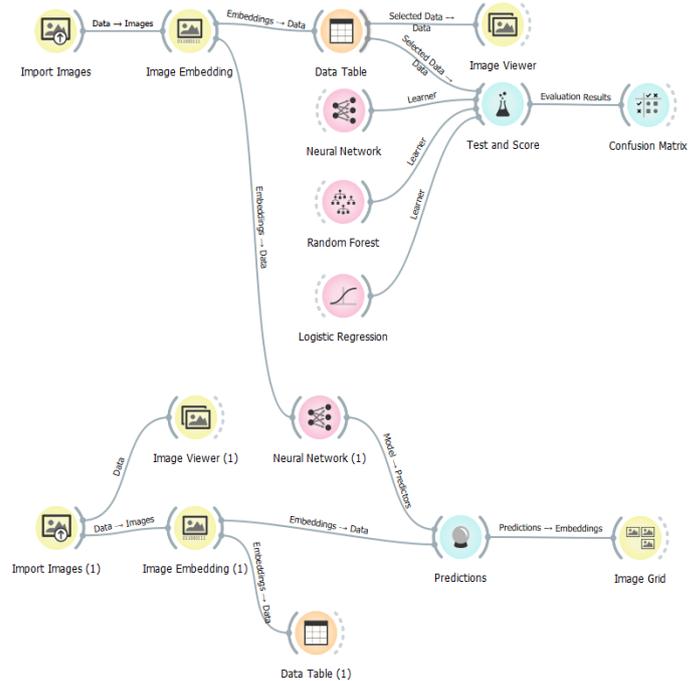


Figura 7 – Escolha do método RNC feita no Orange [19], autoria própria.

A. Base de Dados

Conforme explicitado anteriormente, a RNC serve como uma grande ferramenta na solução de problemas. Porém, o seu desenvolvimento é, de certa forma, simples de programar, porém trabalhoso para descobrir seus parâmetros e treinar.

Quanto a base de dados, foram utilizadas 3102 fotos de folhas de soja de diferentes perspectivas ao todo. Sendo que deste total, 2000 delas possuem a doença confirmadas, 800 são saudáveis, também confirmadas pelo fornecedor da *database* [19], amostragem delas na Figura 8.

Quanto as imagens de teste, 96 delas eram de folhas de soja potencialmente saudáveis, e as outras 206 eram de folhas de soja potencialmente doentes.

Etapa de Inicialização

A estrutura da RNC a ser desenvolvida depende da complexidade do problema. Existem certos parâmetros e bibliotecas a serem utilizadas no Python para resolução de alguma aplicação específica.

Neste projeto, as principais bibliotecas utilizadas para realização do treinamento da RNC são: Keras [20], juntamente com o Tensorflow [21], para criação e treinamento de redes neurais, com o intuito de detectar e decifrar padrões e correlações, análogo à forma como humanos aprendem e raciocinam; Numpy [22], que suporta o processamento de grandes, multidimensionais arranjos e matrizes, juntamente com uma grande coleção de funções matemáticas de alto nível para operar sobre estas matrizes; e por fim a biblioteca Matplotlib [23], que serve para criação de gráficos e visualizações de dados em geral.

É de interesse, também, estabelecer a taxa de aprendizado (valor aplicado sobre o erro para determinar a variação da diminuição) e um número máximo de *Epoch* (um ciclo completo de treinamento).



Folhas de soja saudáveis



Folhas de soja com *diabrotica speciosa*

Figura 8 – Amostragem das imagens utilizadas do banco de dados [19].

Padronização dos Dados

Ao efetuar o treinamento da RNC, é necessário que seja feita a escolha do método de aprendizagem, como citado na seção B, e após isso determinar os melhores parâmetros para a execução da aplicação.

Para que o modelo não alcance um *overfitting*, ou seja, quando um modelo estatístico se ajusta muito bem ao conjunto de dados anteriormente observado, mas se mostra ineficaz para prever novos resultados, é coerente a procura por pelo menos dois dos principais critérios de parada do processo de treinamento: número máximo de iterações (*epoch*) e erro mínimo alcançado. Para a minimização do erro e *overfitting*, uma alternativa é adquirir mais dados com o intuito de equilibrar a quantidade de parâmetros *versus* a quantidade de instâncias de treinamento. Ou, simplesmente, deve-se escolher uma máquina mais simples, que tenha menos parâmetros, afinal das 3102 imagens utilizadas, apenas 302 delas estão sendo utilizadas para teste.

V. CENÁRIO DE APLICAÇÃO

O uso do geoprocessamento de imagens com RNC para a determinação do estado de saúde de uma plantação de soja pode ser muito útil quando empregado a um sistema de sensoriamento remoto, ou seja, com a integração de um drone, uma câmera de altas resoluções que consiga captar diferentes espectros de luz, como a hiperespectral, o dono do

terreno terá dimensão do que há de errado com sua plantação, e logo poderá tomar medidas contra o problema identificado.

A Figura 9 descreve um possível fluxograma do processo de tomada de decisão no controle da doença após as análises das imagens. O processo de tomada de decisão pode ser realimentado com informações que podem ser coletadas com mais imagens obtidas a partir do sensoriamento remoto. Logo, quanto mais levantamentos forem feitos na plantação de soja, mais imagens diferentes irão para o banco de dados, assim a RNC será alimentada constantemente e terá uma taxa de assertividade ainda melhor nas próximas análises de estado da plantação. Sem contar que o dono do terreno poderá ter uma ideia constante de quão saudável e rentável está sua plantação, e se não estiver, saberá a possível causa do problema. Afinal, expandindo a base de dados com mais imagens de outros tipos de doença além da *diabrotica speciosa*, o cliente poderá ter uma noção mais abrangente do que aflige sua plantação e como proceder quanto a esse problema.

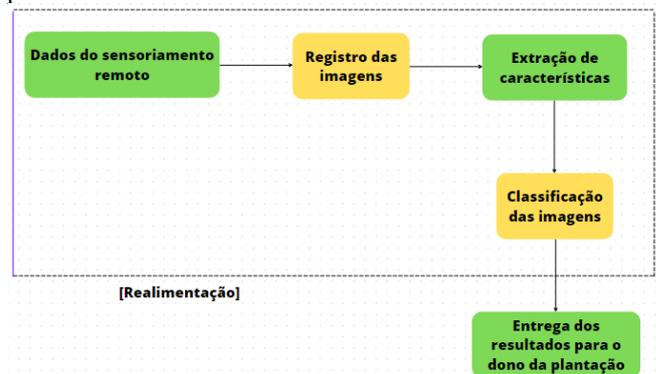


Figura 9 – Fluxograma do processo de geoprocessamento de imagens, autoria própria.

O sistema de predição desenvolvido neste trabalho pode ser inserido neste cenário como ferramenta de apoio no processo de tomada de decisão em conjunto com o sensoriamento remoto. A proposta é avaliar o desempenho e a validade do sistema de predição em estimar as necessidades de uma plantação de soja caso ela esteja com alguma doença de difícil identificação a “olho nu” ou em uma área muito pequena, mas que possa se alastrar para setores maiores.

O sistema de geoprocessamento deve ser tão preciso quanto possível no processo de recomendação de tratativas da plantação de soja para o cliente. Para conferir essa validade do sistema, é necessário que sejam utilizadas as mesmas informações disponíveis durante todo o processo de tomada de decisão. Os relatórios gerenciais com a descrição das decisões adotadas também são fundamentais. Portanto, o sistema de predição deve ser submetido a um processo de treinamento supervisionado com registros históricos. A Figura 10 apresenta o processo de treinamento supervisionado para o sistema de predição proposto neste trabalho, com aplicação na determinação do estado de saúde de uma plantação de soja.

Após a aquisição das imagens ter sido realizada, algumas imagens podem apresentar imperfeições, e então o pré-processamento é utilizado a fim de solucionar ou amenizar problemas de ruído, contraste ou brilho inadequado, entre outras. O ruído não é apenas uma interferência no sinal de captura da imagem, pode ser também interferências que prejudicam a interpretação ou o reconhecimento de objetos na imagem [1].

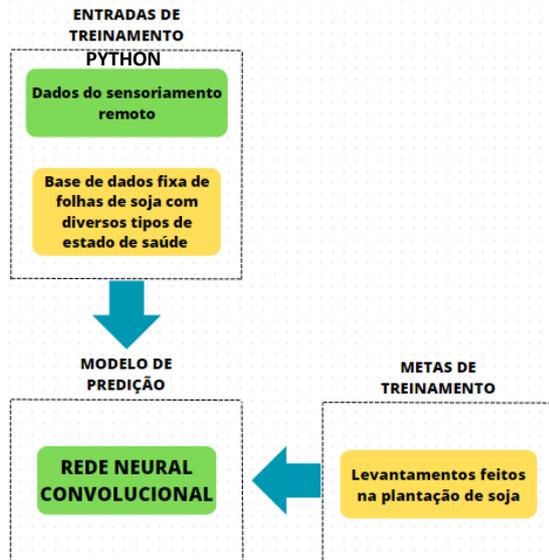


Figura 10 – Treinamento do sistema de predição para a determinação do estado de saúde de uma plantação de soja, autoria própria.

A extração de características transcreve a informação da imagem em pontos de interesse buscando localizar características que sejam relevantes para a tarefa de classificação. A extração de características e classificação de imagem tem sido dois problemas importantes no domínio computacional de visão de máquina e robótica, e suas aplicações continuam a crescer em vários outros campos. Uma técnica de extração de características deve ser robusta para transformações de imagem, como rotação, escala, iluminação, ruído e afim. Além disso, as características extraídas devem ser altamente distintas, de modo que sejam categorizadas com alta probabilidade [1].

As redes neurais convolucionais fazem a análise de campos receptivos locais (*local receptive fields*). Os neurônios da mesma camada são agrupados em mapas. Um mapa é produzido pelo agrupamento das saídas de neurônios que juntos cobrem uma parte da imagem que tenha sido processado com um filtro em comum. Durante o processo de treinamento, é realizado um compartilhamento dos pesos para que um conjunto de neurônios de um determinado mapa aplique o mesmo filtro em diferentes posições da imagem. Tal compartilhamento reduz significativamente o número de parâmetros a serem aprendidos e o tempo de treinamento da rede, consequentemente [1].

O processo de aprendizagem inicia-se ao dividir a imagem em recortes sobrepostos e então alimenta-se a rede ao invés de passar a imagem inteira como uma grade de números. A ideia é que o objeto é o mesmo não importa onde ele apareça em uma imagem, como mostrado na Figura 11.



Figura 11 - Recortes sobrepostos de uma imagem (adaptada de [1]).

VI. RESULTADOS E DISCUSSÕES

Nesta seção são descritos alguns resultados preliminares para as técnicas de configuração, treinamento e aplicação da Rede Neural Convolutiva no processo de geoprocessamento de imagens. Nas camadas de convolução das RNCs é preciso apenas definir a arquitetura dos filtros: quantidade e tamanho, passo, dos filtros por camada. O processo de aprendizado da rede altera os pesos ao longo do treinamento, até encontrar os melhores valores dos filtros para o conjunto de dados utilizado, tornando assim desnecessária a indicação de qual filtro deve ser utilizado.

Devido à complexidade das operações de convolução e a intricada interconexão dos neurônios, as redes convolucionais tendem a apresentar alto custo computacional e baixa velocidade de treinamento. A fim de otimizar a operação dessas redes, as operações de convolução são, comumente, executadas em hardware especializado como em unidades de processamento gráfico (GPU). Neste trabalho, foi utilizada como GPU, uma AMD Radeon Vega 8 Graphics.

Neste trabalho, a Rede Neural Convolutiva foi a técnica de Inteligência Artificial adotada para realizar o treinamento da análise das imagens geoprocessadas, folhas de soja saudáveis ou com doença (*diabrotica speciosa*), marcas de furos deixadas por insetos nas folhas.

A RNC foi escolhida perante as alternativas, Random Forest e Regressão Linear, pois teve uma taxa de precisão e acurácia melhor que as outras, de 98,2% no aplicativo Orange [14], conforme pode ser observado na Figura 12. Que mostra, respectivamente, o tipo de modelo avaliado; de 0, mínimo e 1, máximo, a acurácia, precisão do subconjunto, média harmônica de precisão, precisão total e a capacidade do classificador de encontrar todas as amostras positivas.

Model	AUC	CA	F1	Precision	Recall
Random Forest	0.942	0.868	0.866	0.866	0.868
Neural Network	0.982	0.940	0.940	0.941	0.940
Logistic Regression	0.979	0.935	0.935	0.936	0.935

Figura 12 – Imagem treinamento realizado no Orange, autoria própria.

Nesse projeto, utilizou-se o executável *open-source* Orange [14], que possui diversas bibliotecas integradas voltadas para Ciência de Dados, com finalidade de demonstrar a aplicação de maneira mais visual.

A biblioteca principal que foi utilizada no Python é a API Keras. É simples, de fácil uso, e fornece resultados consistentes, além de possuir vastas documentações e tutoriais [20].

O modelo genérico de utilização e aplicação da RNC está exemplificado no fluxograma da Figura 8. Por ser genérico, é entendível que são necessárias correções e adaptações na RNC para a aplicação do modelo abordado.

Keras tem como vantagem tirar o máximo proveito dos recursos de escalabilidade, podendo ser executada em TPU (*Tensor processing unit*) ou em GPU (*Graphics Processing Unit*), além de permitir salvar o modelo treinado e ser executada por exemplo, em dispositivos móveis [20].

Para facilitar melhor compreensão da máquina, todas as imagens foram reescaladas para 1/255, a taxa de aprendizado foi de 0.01, foram empregadas 33% das 3102 imagens de treino, variação do número de *epochs* e quantidade de passos

por *epoch*, e *batch size* de 8 passos, que é um número de amostras processadas antes que o modelo seja atualizado, conforme mostrado na Figura 13.

Na imagem pode-se notar alguns parâmetros relevantes para a observação do funcionamento da Rede Neural Convolutiva, que incluem o processo de *padding*, que consiste na adição de pixels ao redor da imagem antes da operação de convolução, visando manter a dimensionalidade da imagem resultante durante a operação. Outro parâmetro importante é o *pooling*, que tem como função diminuir a variância do modelo em relação a pequenas alterações, além de reduzir a quantidade de parâmetros treináveis pela rede.

Ademais, a técnica de *dropout* também pode ser aplicada para evitar que certas partes da rede neural sejam excessivamente sensíveis a pequenas mudanças, limitando sua responsabilidade e aumentando sua eficiência. A técnica de *flatten* também é relevante, pois ela transforma a matriz da imagem em um *array*, o que permite o processamento em camadas densas da RNC. Por fim, a camada *dense* é capaz de identificar padrões em um conjunto de dados, classificando-os em categorias ou realizando a regressão de valores.

Todos esses parâmetros podem ser utilizados em conjunto para melhorar a performance da RNC na classificação de imagens [20]. O *padding*, por exemplo, pode ser utilizado para manter a dimensionalidade da imagem ao longo do processo de convolução, enquanto o *pooling* pode ser aplicado para diminuir a variância do modelo. O *dropout*, por sua vez, pode ser utilizado para evitar que partes específicas da rede neural fiquem excessivamente sensíveis a mudanças, e a camada *dense* é capaz de realizar a classificação dos dados. Combinar essas técnicas pode resultar em uma RNC mais robusta e precisa.

```

Model: "sequential_39"
-----
Layer (type)                Output Shape                Param #
-----
conv2d_160 (Conv2D)         (None, 178, 178, 16)       448
max_pooling2d_160 (MaxPooli (None, 89, 89, 16)         0
ng2D)
conv2d_161 (Conv2D)         (None, 87, 87, 32)         4640
max_pooling2d_161 (MaxPooli (None, 43, 43, 32)         0
ng2D)
conv2d_162 (Conv2D)         (None, 41, 41, 64)         18496
max_pooling2d_162 (MaxPooli (None, 20, 20, 64)         0
ng2D)
conv2d_163 (Conv2D)         (None, 18, 18, 128)        73856
max_pooling2d_163 (MaxPooli (None, 9, 9, 128)         0
ng2D)
flatten_40 (Flatten)        (None, 10368)              0
dense_199 (Dense)           (None, 550)                5702950
dropout_160 (Dropout)       (None, 550)                0
dense_200 (Dense)           (None, 400)                220400
dropout_161 (Dropout)       (None, 400)                0
dense_201 (Dense)           (None, 300)                120300
dropout_162 (Dropout)       (None, 300)                0
dense_202 (Dense)           (None, 200)                60200
dropout_163 (Dropout)       (None, 200)                0
dense_203 (Dense)           (None, 2)                  402
-----
Total params: 6,281,692
Trainable params: 6,281,692
Non-trainable params: 0

```

Figura 13 – Imagem com os parâmetros utilizados na construção da RNC, autoria própria.

Procedimentos de utilização da RNC

Depois de inseridas todas as imagens de teste e treino, e definido os parâmetros da maneira mais assertiva possível, pode-se treinar o modelo a vontade, com o intuito também de sempre melhorar sua taxa de acurácia.

Após o término de diversos treinos, o modelo fica disponível para ser utilizado na predição de detecção de doenças em plantações de soja, ou para aplicações similares que envolvam classificação de imagens.

Treinamento e validação do sistema de predição:

Com os parâmetros devidamente definidos, conforme mostrados na Figura 13, pode-se prosseguir com o treino das imagens. O que resta para o melhor resultado de análise de imagens neste projeto é definir o número de *epochs*, tamanho do *batch*, quantidade de passos por *epochs*, taxa de aprendizado e quanto utilizar das imagens do banco de dados para o treino.

A nível de demonstração, neste trabalho o conjunto de dados de treinamento é composto por testes de tentativa e erro quanto a esses últimos parâmetros utilizados.

Além disso também é importante destacar o tipo de otimizador de parâmetros utilizado neste projeto, que neste caso foi o Adam.

A estimativa de momento adaptativo (Adam) é um método que calcula as taxas de aprendizado adaptativo para cada parâmetro. Além de armazenar uma média de decaimento exponencial de gradientes quadrados anteriores, Adam também mantém uma média de decaimento exponencial de gradientes anteriores, semelhante ao momento. Enquanto o momento pode ser visto como uma bola descendo um declive, Adam se comporta como uma bola pesada com atrito, que assim prefere mínimos planos na superfície de erro [24].

Com a RNC ajustada efetuaram-se mais treinamentos. Dessa vez, variando os valores de *epoch*. O objetivo foi identificar a melhor configuração da RNC para o processo de predição, conforme mostrado na Tabela 01, após o seu treinamento com a base dados das folhas de soja saudáveis e doentes.

Escolha no número de *epochs* baseados na média de desempenhos

Número de <i>epochs</i>	Acurácia (Treino)	Perda (Treino)	Acurácia (Validação)	Perda (Validação)
100	0,9077	0,4377	0,6997	1,834
150	0,9219	0,421	0,7203	1,7921
200	0,9361	0,4043	0,7409	1,7502
250	0,9503	0,3876	0,7615	1,7083
300	0,9645	0,3709	0,7821	1,6664
350	0,9687	0,3642	0,7827	1,6658

Tabela 01 – Treinamento da RNC x Número de *epoch*, autoria própria.

Como pode-se perceber, após o treinamento da RNC com número de *epochs* entre 100 e 300, com variação de 50, a melhor média para acurácia alcançada foi aquele com 350 *epochs*, no entanto foi não diferiu o suficiente da média de 300 *epochs*, logo o poder computacional exigido para treinar 50 *epochs* a mais não é tão compensativo.

O Gráfico 1 descreve a evolução do processo de treinamento e validação da RNC com 300 *epochs*. A Perda diminui mais que em 250 *epochs* até que os valores de Treino e Validação sejam mais parecidos em 300 *epochs*. Vale observar que o ajuste dos parâmetros da RNC durante esta etapa de treinamento e validação é um processo empírico. Outros resultados podem ser alcançados com diferentes métodos de análise para sair dos *overfitting* obtidos.

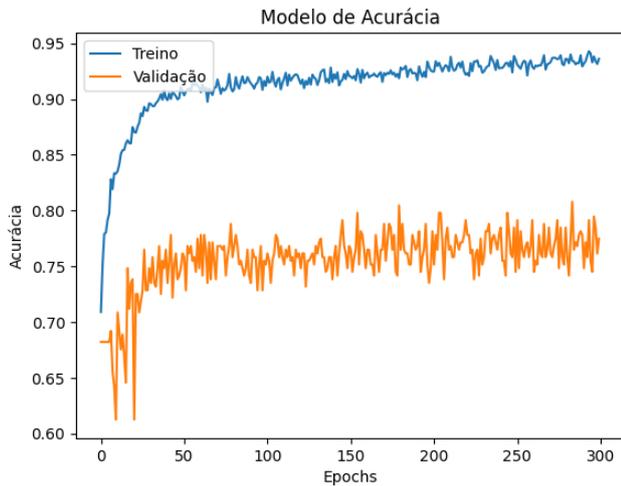


Gráfico 1 – Comparativo de valores verdadeiros em relação a predição, autoria própria.

Teste do sistema de predição:

A RNC configurada e treinada pode, então, ser utilizada na predição para auxiliar no processo de tomada de decisão do que há de possivelmente errado com a plantação, e logo poderá tomar medidas contra o problema identificado. O cenário de aplicação contempla uma base de dados com registros de 3102 imagens. A RNC recebe os dados das três variáveis de entrada, imagens do banco de dados de folhas saudáveis, imagens do banco de dados de folhas apresentando *diabrotica speciosa*, e por último as imagens a ser analisadas, provenientes do sensoriamento remoto.

A Figura 15 apresenta os resultados da predição da RNC para entrada de seis imagens obtidas por sensoriamento remoto a serem analisadas. Neste projeto, no entanto, foram separadas 6 imagens aleatórias do banco de dados, que não foram utilizadas, para simular esta entrada.

É possível perceber pelos resultados da Figura 15 que a RNC conseguiu, neste caso, classificar as imagens do sensoriamento remoto com 100% de acurácia quanto as classificações exigidas pelo projeto. Sendo que, as imagens de saída classificadas como “Diabrotica” são realmente “Doentes”, conforme os dados de entrada. Além disso, as imagens de saída classificadas como “Healthy” são realmente “Saudáveis”, conforme os dados de entrada.

No entanto, nota-se que algumas imagens ficam mais próximas da linha de tendência da classificação oposta do que outras. Este acontecimento pode ser explicado pelo seguinte motivo: os erros cometidos geralmente estão associados a probabilidades de classificação mais dispersas, isso indica uma incerteza do modelo frente às imagens mal classificadas [21].

Com o objetivo de melhorar o processo de tomada de decisão do sistema proposto, foi realizado um ajuste nos neurônios utilizados no RNC, neste caso reescalar todas as imagens, de treino e teste, para as mesmas dimensões foram de boa valia, pois a quantidade de pixels utilizados por imagens torna-se mais padrão, logo mais fica mais fácil o comparativo entre as imagens.

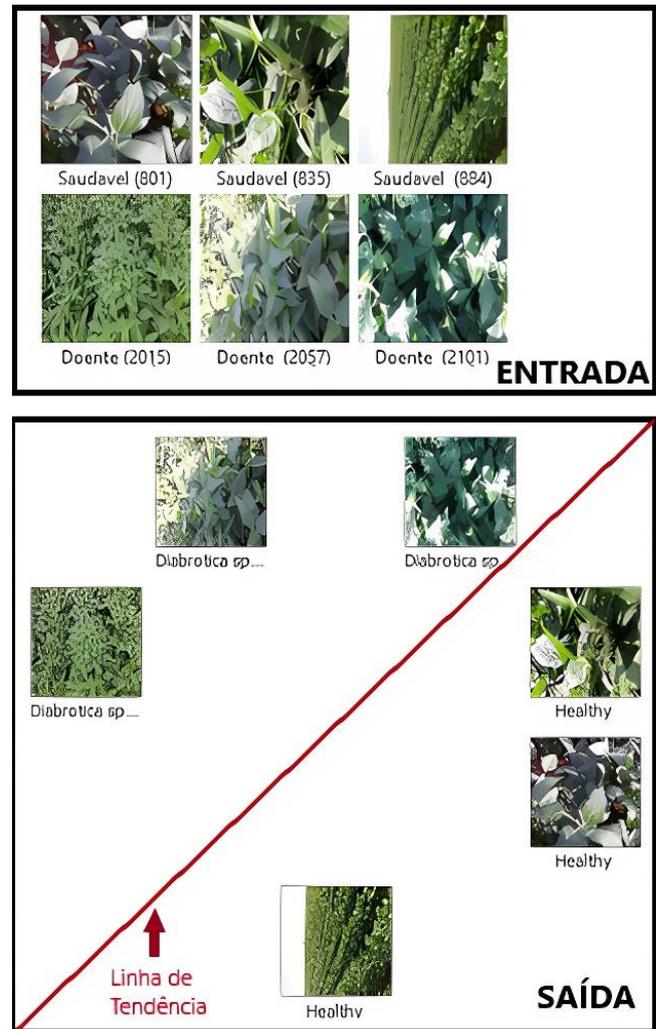


Figura 15 – Resultado do treinamento da RNC, autoria própria.

Otimizações futuras:

Este projeto contará com uma melhoria significativa no intuito de facilitar o manuseio do sistema de tomada de decisão proposto neste trabalho. Está sendo desenvolvido um *software* de interface gráfica, um site adaptando o treino do RNC em Python, agora para Flask, funcionalidade específica para construção de sites em Python. Dessa maneira o processo de utilização da IA fica bem mais intuitivo pelo usuário do sistema, como pode ser vista na Figura 16.

O site tem como ideia a inserção das imagens captadas pelo sensoriamento remoto, estas serão analisadas pelo RNC e devolvidas para o usuário com as classificações adequadas. Ou seja, o usuário terá noção se a sua plantação de soja está saudável ou se possui a doença *diabrotica speciosa*, podendo aplicar correção no problema, se for o caso.

Além disso, pretende-se ampliar a análise das imagens para mais tipos de doenças que afligem as plantações de soja. Logo, realizar mais captações de imagens por sensoriamento remoto poderá ser muito bom para ampliar e diversificar o banco de dados da aplicação.

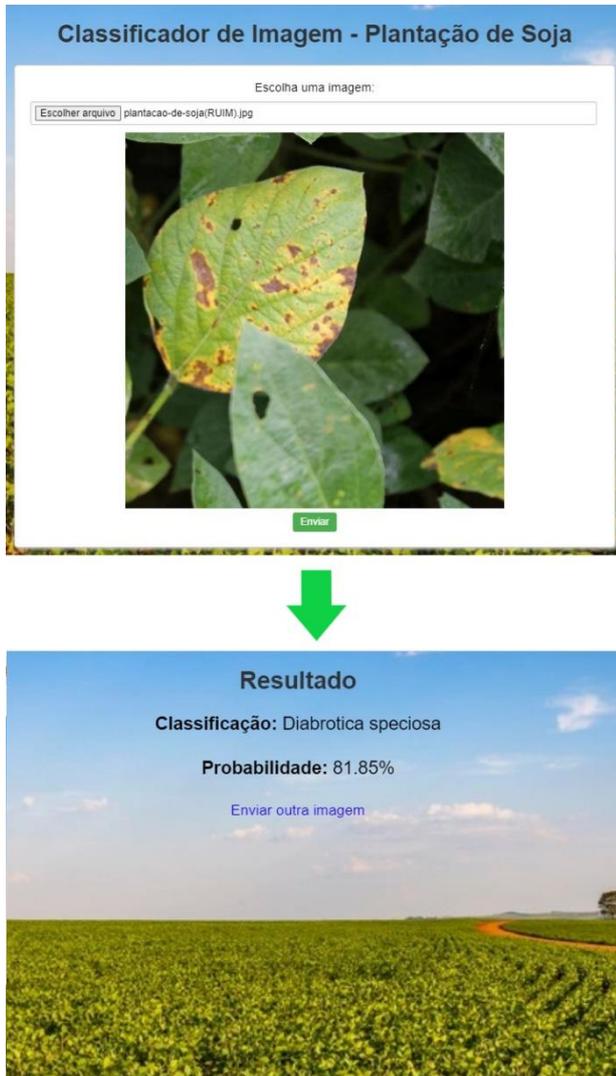


Figura 16 – Site projetado para o usuário, autoria própria.

VII. CONCLUSÃO

Com o avanço tecnológico atual, o volume de produção de dados aumenta constantemente, tornando difícil a extração de informações relevantes. Nesse âmbito, a IA entra como uma alternativa para resolver esse problema, automatizando os processos de aplicação e tomada de decisões e controle.

A relevância da RNC nesse quesito é de suma importância, pois pode ser utilizada na previsão de futuros cenários de calamidades nas plantações de soja. Dessa forma, este trabalho apresenta um estudo da aplicação destas técnicas no processo de apoio à decisão para melhoria do controle da plantação de soja.

Inicialmente foi realizada uma pesquisa referente a técnicas utilizadas na RNC para decidir qual aproximação seria feita em relação ao problema de previsão. Durante o estudo, chegou-se na definição de utilizar o treinamento pelo Aprendizado Supervisionado, pois já há a reposta prévia do que o programa tem que analisar, ou seja, já se sabe que as 6 imagens usadas para teste são de folhas de soja saudáveis ou doentes. Ainda assim, utilizar o Aprendizado por Reforço no futuro seria mais ideal, afinal existe o banco de dados alocado para treino da RNC, mas não há classificação prévia das novas imagens captadas por sensoriamento remoto.

Como plataforma de desenvolvimento, foi utilizada a linguagem de programação Python e o executável Orange

para testes prévios, ainda no Aprendizado Supervisionado. Os fatores determinantes para sua escolha foram: Python se tornou uma das linguagens mais utilizadas na comunidade de desenvolvedores de softwares, facilidade de aprendizado e variedade de bibliotecas voltadas para análise de dados e inteligência artificial. E, o Orange possui visualizações interativas que permitem a análise exploratória de dados. Pode-se selecionar subconjuntos de dados interessantes diretamente de plotagens, gráficos e tabelas de dados e explorá-los em *widets* [14].

Os resultados obtidos com o modelo foram promissores, considerando a dificuldade em efetuar uma operação de IA que necessita de GPU, da NVIDIA de preferência, usando uma AMD no lugar. Ainda assim, no cenário estudado, a IA desenvolvida consegue classificar as imagens das folhas de soja com alta precisão e assertividade.

Como um possível método aditivo, pretende-se utilizar uma máquina com de maior poder computacional e placa de vídeo da marca NVIDIA, com o objetivo de melhorar a IA, e gastando menos tempo. Afinal, para usar os *frameworks* com GPUs para treinamento de redes neurais convolucionais e processos de inferência, a NVIDIA fornece cuDNN e TensorRT™, respectivamente, que oferecem implementações altamente ajustadas para rotinas padrão, como convolução, *pooling*, normalização e camadas de ativação. Além de conseguir acelerar as estruturas de *deep learning* mais usadas, como o TensorFlow, que é bastante utilizado neste projeto [25].

Para trabalhos futuros, vislumbra-se a implementação completa da Interface de Usuário e avaliar o desempenho do sistema de previsão desenvolvido em diversos cenários:

- Estudo de campo, com coleta de dados reais, acrescida de uma base de dados robusta obtidas a partir dos sensoriamentos remotos realizados;
- Aplicação em diferentes plantações, com diferentes tipos de estado das plantas, doenças ou outros agravos;
- Previsão de problemas futuros em determinada plantação analisada a partir dos dados passados coletados da mesma, assim o usuário não só poderia aplicar medidas corretivas na plantação, como também preventivas.

VIII. REFERÊNCIAS

- [1] VAZ, Maria Salete Marcon Gomes; BRITTO JUNIOR, Alceu de Souza; JORIS, Hélio Antônio Wood. MÉTODO DE CLASSIFICAÇÃO DE PRAGAS POR MEIO DE REDE NEURAL CONVOLUCIONAL PROFUNDA. Programa de Pós-Graduação Computação Aplicada, Brasil, 19 nov. 2018. Universidade Estadual de Ponta Grossa, p. 7-8. Disponível em: <http://tede2.uepg.br/jspui/handle/prefix/2747>. Acesso em: 30 out. 2022.
- [2] FERREIRA, Laerte Guimarães; FERREIRA, Nilson Clementino; FERREIRA, Manuel Eduardo. Sensoriamento remoto da vegetação: evolução e estado-da-arte. Acta Scientiarum. Biological Sciences, v. 30, n. 4, p. 379-390, 2008.
- [3] K. Faceli, A.C. Lorena, J. Gama, A.C.P.L.F Carvalho. Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina. LTC, 2011.
- [4] S. RUSSELL and P. NORVIG, Artificial Intelligence: A Modern Approach, 4th ed. Upper Saddle River, NJ, USA: Prentice Hall, 2009.
- [5] SILVA, Rodrigo Emerson Valentim da. Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens. 2018.
- [6] EQUIPE TOTVS. Inteligência Artificial: o guia completo sobre o assunto! Brasil, 9 ago. 2022. Disponível em: <https://www.totvs.com/blog/inovacoes/o-que-e-inteligencia-artificial/>. Acesso em: 30 out. 2022.

- [7] MARTINS, Fabiana. Os três tipos de aprendizado no machine learning, um ramo da inteligência artificial. Brasil: Certaja Inovação, 1 nov. 2019. Disponível em: <http://certaja.com.br/inovacao/os-tres-tipos-de-aprendizado-no-machine-learning-um-ramo-da-inteligencia-artificial/>. Acesso em: 13 nov. 2022.
- [8] De Castro, L.N; Ferrari, D.G. Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações. São Paulo. Saraiva, 2016.
- [9] Fernandes, Antônio Alves Tôres et al. Read this paper if you want to learn logistic regression. Revista de Sociologia e Política [online]. 2020, v. 28, n. 74 [Acessado 13 novembro 2022], 006. Disponível em: <https://doi.org/10.1590/1678-987320287406en>.
- [10] BASTOS, Denise; NASCIMENTO, Patricia; LAURETTO, Marcelo. Proposta e Análise de Desempenho de Dois Métodos de Seleção de Características para Random Forests. In: SIMPÓSIO BRASILEIRO DE SISTEMAS DE INFORMAÇÃO (SBSI), 9., 2013, João Pessoa. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2013. p. 49-60. DOI: <https://doi.org/10.5753/sbsi.2013.5675>.
- [11] O QUE é uma floresta aleatória?. USA: TIBCO, 2020. Disponível em: <https://www.tibco.com/pt-br/reference-center/what-is-a-random-forest>. Acesso em: 13 nov. 2022.
- [12] MARTINS, Lucimara; MURAMATSU JÚNIOR, Mario; SERAPIÃO, Adriane. Classificação de imagens de ideogramas Kuzushiji com Redes Neurais Convolucionais. In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL (ENIAC), 16., 2019, Salvador. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2019. p. 309-320. ISSN 2763-9061. DOI: <https://doi.org/10.5753/eniac.2019.9293>.
- [13] LOPEZ, Martin Andreoni; MATTOS, Diogo M. F. Resumo de Grandes Volumes de Dados com Filtro de Bloom: Uma Abordagem Eficiente para Aprendizado Profundo com Redes Neurais Convolucionais em Fluxos de Rede. In: SIMPÓSIO BRASILEIRO DE REDES DE COMPUTADORES E SISTEMAS DISTRIBUÍDOS (SBRC), 39., 2021, Uberlândia. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2021. p. 532-545. ISSN 2177-9384. DOI: <https://doi.org/10.5753/sbrc.2021.16745>.
- [14] University of Ljubljana. Orange Data Mining (.exe). Disponível em: <https://orangedatamining.com/>.
- [15] FREITAS, Carlos; SILVA, Pedro; MOREIRA, Gladston; LUZ, Eduardo. Rede Neural Convolucional e LSTM para Biometria Baseada em EEG no Modo de Identificação. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS), 22., 2022, Teresina. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2022. p. 256-267. ISSN 2763-8952. DOI: <https://doi.org/10.5753/sbcas.2022.222647>.
- [16] GUIMARÃES, Fábio. Rede neural Convolucional (CNN) – O que é e como funciona. Brasil: Mundo Projetado, 14 set. 2021. Disponível em: <https://mundoprojetado.com.br/rede-neural-convolucional/>. Acesso em: 14 nov. 2022.
- [17] NEVES, Enzo Cardeal. Aprendizado por Reforço #1— Introdução. Brasil: Turing Talks, 23 fev. 2020. Disponível em: <https://medium.com/turing-talks/aprendizado-por-reforco-C3%A7o-1-introdu%C3%A7%C3%A3o-7382ebb641ab>. Acesso em: 14 nov. 2022.
- [18] PYTHON SOFTWARE FOUNDATION. Python Language Site: Documentation, 2020. Página de documentação. Disponível em: <https://www.python.org/doc/>. Acesso em: 14 de nov. de 2022.
- [19] Mignoni, Maria Eloisa (2021), “Images of Soybean Leaves”, Mendeley Data, V1, doi: 10.17632/bycbh73438.1
- [20] KERAS. Keras: The Python deep learning API. Disponível em: <https://keras.io/>. Acesso em: 14 nov. 2022
- [21] TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Disponível em: <https://tensorflow.org>. Acesso em: 14 nov. 2022
- [22] Numpy: the fundamental package for scientific computing with Python, 2005. Disponível em: <https://numpy.org>. Acesso em: 14 nov. 2022.
- [23] Matplotlib: Visualization with Python, 2012. Disponível em: <https://matplotlib.org>. Acesso em: 14 nov. 2022.
- [24] ZHANG, Jeremy. Optimisation Algorithm — Adaptive Moment Estimation (Adam): Implementation of Adam. USA: Medium, 21 jan. 2020. Disponível em: <https://towardsdatascience.com/optimisation-algorithm-adaptive-moment-estimation-adam-92144d75e232>. Acesso em: 20 nov. 2022.
- [25] NVIDIA: Visão computacional, 2022. Disponível em: <https://www.nvidia.com/pt-br/glossary/data-science/computer-vision/>. Acesso em: 22 nov. 2022.



PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
GABINETE DO REITOR

Av. Universitária, 1069 • Setor Universitário
Caixa Postal 85 • CEP 74605-010
Goiânia • Goiás • Brasil
Fone: (62) 3946.1000
www.pucgoias.edu.br • reitoria@pucgoias.edu.br

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O(A) estudante ESTEVÃO SANTOS CAVALCANTE do Curso de ENGENHARIA DE CONTROLE E AUTOMACÃO, matrícula 2018.1.0118.0046-3, telefone: (62)99145-6153 e-mail estevaos.108@gmail.com, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado ANÁLISE PREDITIVA COM REDES NEURAIS CONVOLUCIONAIS PARA O GEOPROCESSAMENTO DE IMAGENS, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 06 de março de 2023.

Assinatura do autor: _____

Estevão S. Cavalcante

Nome completo do autor: Estevão Santos Cavalcante

Assinatura do professor-orientador: _____

Marcos A. de Sousa

Nome completo do professor-orientador: Marcos Antônio de Sousa