

Universidade de Brasília – UnB
Faculdade UnB Gama – FGA
Engenharia de Software

Classificação de lavouras por aprendizagem profunda com dados de sensores remotos

Autor: Daniel Moura da Silva
Orientador: Prof. Dr. Nilton Correia da Silva

Brasília, DF
2018



Daniel Moura da Silva

Classificação de lavouras por aprendizagem profunda com dados de sensores remotos

Monografia submetida ao curso de graduação em Engenharia de Software da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia de Software.

Universidade de Brasília – UnB

Faculdade UnB Gama – FGA

Orientador: Prof. Dr. Nilton Correia da Silva

Brasília, DF

2018

Daniel Moura da Silva

Classificação de lavouras por aprendizagem profunda com dados de sensores remotos/ Daniel Moura da Silva. – Brasília, DF, 2018-
106 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Nilton Correia da Silva

Trabalho de Conclusão de Curso – Universidade de Brasília – UnB
Faculdade UnB Gama – FGA , 2018.

1. Classificação. 2. Lavouras. 3. Redes neurais. I. Prof. Dr. Nilton Correia da Silva. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Classificação de lavouras por aprendizagem profunda com dados de sensores remotos

CDU 02:141:005.6

Daniel Moura da Silva

Classificação de lavouras por aprendizagem profunda com dados de sensores remotos

Monografia submetida ao curso de graduação em Engenharia de Software da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia de Software.

Trabalho aprovado. Brasília, DF, 10 de dezembro de 2018 – Data da aprovação do trabalho:

Prof. Dr. Nilton Correia da Silva
Orientador

Prof. Dr. Fabricio Ataides Braz
Convidado 1

Profa. Ma. Natasha Sophie Pereira
Convidado 2

Brasília, DF
2018

Dedico este trabalho aos meus ensinadores, sendo eles acadêmicos ou os ensinadores do cotidiano. Por me fazerem crescer tanto intelectualmente, em determinação e em caráter.

Agradecimentos

Agradeço primeiramente a Deus, por ser essencial na minha vida. Por me guiar e me levar à lugares que nunca imaginei chegar.

Agradeço a minha família pelo suporte em todos os momentos da minha vida, sobretudo o período da minha graduação. À minha mãe Eliete de Freitas Moura da Silva, ao meu pai Antônio de Pádua Araújo da Silva, aos meus irmãos André Moura da Silva e Matheus Moura Guedes.

Agradeço ao meu orientador, Prof. Dr. Nilton Correia da Silva, por aceitar esse desafio comigo, pelas contribuições, ensinamentos que foram fundamentais para construção deste trabalho.

Muito obrigado.

*“Combati o bom combate,
acabei a carreira,
guardei a fé”
(Bíblia Sagrada, Timóteo 4:7)*

Resumo

A classificação em larga escala em grandes regiões de plantio é um desafio, uma vez que a classificação de lavouras sem ferramentas pode ser errada. Mesmo sendo de vital importância para políticas de planejamento de *commodities* para o governo, pouco é realmente investido por motivos de esforço gasto. Entretanto, nos últimos anos, começou-se a utilizar dados de sensoriamento remoto, cuja informação de assinaturas espectrais dos objetos se mostrou um importante identificador para tais classificações. Técnicas recentes de aprendizado profundo, demonstram ser importantes para classificações corretas e precisas de forma autônoma. Dentro do paradigma de aprendizagem profunda, as redes neurais artificiais, sobretudo as convolutivas tem demonstrado resultados promissores. O objetivo deste trabalho é elaborar um sistema onde a partir de dados fornecidos por sensoriamento remoto, ocorra a classificação automática de lavouras. Foi usada uma adaptação da Rede Neural Convolutacional VGGNet, sendo utilizados 3152 polígonos coletados pelos autores através de dados do satélite *Landsat-8*. Estes polígonos estão numa estrutura 15 *pixels* por 15 *pixels*, sendo 2.206 polígonos utilizados para treinamento da rede e 946 para teste. Os polígonos foram classificados em Algodão, Arroz, Cana-de-açúcar, Laranja, Milho, Soja Uva e uma categoria Outros (Solo exposto, área urbana, floresta, pasto, matagal e água). Foi alcançado um resultado de 97.57% de acurácia, 97.7% de precisão, 96.1% de *recall*, 96.8% de *F1 score*. Os mesmos polígonos de treino e de testes foram aplicados em outros 9 classificadores de *Machine Learning* (*Support Vector Machine - SVM*, *Random Forest*, Regressão Logística, *K Neighbors*, *Gradient Boosting*, Gaussiano, *Extra Trees*, Árvore de Decisão e *AdaBoost*). O resultado atingido pela Rede Neural Convolutacional criada neste trabalho se mostrou superior ao de outros métodos de classificação, como o classificador *Extra Tree* que atingiu 94.1% de *F1 score* e 95.84% de acurácia e o *Random Forest* que atingiu 91.9% de *F1 score* e 92.75% de acurácia. O sistema se mostrou bem sucedido e foi comprovado que Redes Neurais Convolutacionais conseguem ter uma boa classificação de dados de sensoriamento remoto com assinaturas espectrais para a classificação de lavouras.

Palavras-chaves: Redes neurais artificiais. aprendizado profundo. agricultura. classificação. assinatura espectral.

Abstract

The large-scale sorting in large planting areas is a challenge, since classification of crops without tools may be wrong. While it is of vital importance for government commodity planning policies, little is actually invested for reasons of expenditure effort. However, in the last few years, remote sensing data began to be used, whose information on spectral signatures of the objects proved to be an important identifier for such classifications. Recent deep learning techniques prove to be important for accurate and correct classifications in an autonomous way. Within the deep learning paradigm, the artificial neural networks, especially the convolutive ones, have shown promising results. The objective of this work is to elaborate a system where from the data provided by remote sensing, automatic classification of crops occurs. An adaptation of the VGGNet Convolutional Neural Network was used, with 3,152 polygons collected by the authors using Landsat-8 satellite data. These polygons are in a structure 15 pixels by 15 pixels, with 2,206 polygons used for network training and 946 for testing. The polygons were classified in Cotton, Rice, Sugarcane, Orange, Corn, Soybean Grape and an Other category (exposed soil, urban area, forest, pasture, scrub and water). A result of 97.57% accuracy, 97.7% accuracy, 96.1% recall, 96.8% F1 score was achieved. The same training and test polygons were applied to other 9 Machine Learning classifiers (SVM, Random Forest, Logistic Regression, K Neighbors, Gradient Boosting, Gaussian, Extra Trees, Decision Tree, and AdaBoost). The result achieved by the Convolutional Neural Network created in this work was superior to that of other methods of classification, such as the Extra Tree classifier that reached 94.1% of F1 score and 95.84% of accuracy and Random Forest that reached 91.9% of F1 score and 92.75 % accuracy. The system proved to be successful and it has been proven that Convolutional Neural Networks can have a good classification of remote sensing data with spectral signatures for the classification of crops.

Key-words: artificial neural network. deep learning. agriculture. classification. spectral signature.

Lista de ilustrações

Figura 1 – Representação do neurônio artificial inspirado pelo neurônio biológico.	29
Figura 2 – Exemplo de uma CNN	32
Figura 3 – Processo de sensoriamento remoto	33
Figura 4 – Interação Radiação/Objeto	34
Figura 5 – Comparação entre resoluções espaciais	35
Figura 6 – Valores contidos em bits para resolução radiométrica	36
Figura 7 – Diferença de resolução radiométrica	36
Figura 8 – Ilustração de satélite orbitando o mesmo ponto em tempos diferentes .	37
Figura 9 – Espectro Eletromagnético (A) e Resolução espectral (B)	37
Figura 10 – Espectros de algumas espécies agrícolas, obtidas no Colorado em 3 de setembro de 1993 usando o AVIRIS com 244 canais e pixels de 20x20m	38
Figura 11 – Estrutura do tecido celular das folhas de milho e folhas de soja	38
Figura 12 – Faixas de resolução espacial do Satélite Landsat-8	39
Figura 13 – Exemplo de matriz de confusão	40
Figura 14 – Fluxograma da metodologia utilizada	43
Figura 15 – Gráfico de Artigos por Base	50
Figura 16 – Gráfico de relação dos anos de publicação	50
Figura 17 – Gráfico de países com obras publicadas e selecionadas	51
Figura 18 – Polígonos sendo formados para rotulação de áreas urbanas	55
Figura 19 – <i>CDL</i> : Imagem da cidade de Franklin, Iowa em Janeiro de 2018	57
Figura 20 – Imagem do sensor <i>landsat-8</i> (Externa) com imagem obtida pelo <i>CDL</i> (Interna)	57
Figura 21 – Região da Califórnia que será usada para treino/validação	58
Figura 22 – Camadas do <i>CDL</i> e camadas do sensor do <i>Landsat-8</i> que será usado para o treino da CNN	60
Figura 23 – Exemplo de Saída do Sistema	60
Figura 24 – Exemplo de matriz de classificação	61
Figura 25 – Arquitetura da rede neural do projeto Lavrador	63
Figura 26 – Processo de predição de sistemas multiclasse - Sistema Lavrador	65
Figura 27 – Matriz de confusão do Experimento 1	66
Figura 28 – Métricas do Experimento 1	67
Figura 29 – Matriz de confusão do Experimento 2	68
Figura 30 – Métricas do Experimento 2	68
Figura 31 – Visualização dos polígonos selecionados no experimento 2	69
Figura 32 – Média das Assinaturas Espectrais dos Polígonos analisados no Experimento 3	70

Figura 33 – Exemplo de lavoura de Arroz	71
Figura 34 – Assinatura espectral dos polígonos da categoria Outros	71
Figura 35 – Assinatura espectral dos polígonos de Cana-de-açúcar	72
Figura 36 – Matriz de confusão do Experimento 3	72
Figura 37 – Métricas do Experimento 3	73
Figura 38 – Plantação de uva	74
Figura 39 – Layer de soja (em verde) e arroz (em azul) utilizado para a coleta de polígonos	74
Figura 40 – Matriz de confusão e dados das métricas do classificador SVC	75
Figura 41 – Matriz de confusão e dados das métricas do classificador Random Forest	76
Figura 42 – Matriz de confusão e dados das métricas do classificador Logistic	76
Figura 43 – Matriz de confusão e dados das métricas do classificador K Neighbors	77
Figura 44 – Matriz de confusão e dados das métricas do classificador Gradient Boosting	77
Figura 45 – Matriz de confusão e dados das métricas do classificador Gaussiano	78
Figura 46 – Matriz de confusão e dados das métricas do classificador Extra Trees	79
Figura 47 – Matriz de confusão e dados das métricas do classificador Decision Tree	79
Figura 48 – Matriz de confusão e dados das métricas do classificador AdaBoost	80
Figura 49 – Imagem multiespectral da região de plantio de cana-de-açúcar da Flórida	81
Figura 50 – <i>Layer</i> do <i>CropScape</i> da região de plantio de cana-de-açúcar da Flórida	81
Figura 51 – Cores utilizadas no sistema Lavrador para identificação dos polígonos	82
Figura 52 – Polígonos classificados pelo sistema Lavrador plotado em cima da API do <i>Google Maps</i> dentro do sistema Lavrador	82
Figura 53 – Polígonos classificados pelo sistema Lavrador plotado em cima da imagem de satélite na API do <i>Google Maps</i> dentro do sistema Lavrador	83
Figura 54 – Função do <i>Street View</i> do <i>Google Maps</i> dentro do sistema Lavrador	83
Figura 55 – Portal do <i>CropScape</i>	95
Figura 56 – <i>Layer</i> de soja obtido pelo <i>CropScape</i>	96
Figura 57 – Portal do <i>EarthExplorer</i>	97
Figura 58 – Portal do <i>EarthExplorer</i>	98
Figura 59 – Camada de rótulo do CDL com a imagem multiespectral coletada pelo <i>EarthExplorer</i> no programa ENVI	99
Figura 60 – Janela do ENVI para seleção da camada de rótulo do <i>CropScape</i>	100
Figura 61 – Janela para salvar o polígono	100
Figura 62 – Janela para salvar o polígono	101
Figura 63 – Resultado final do processo	101
Figura 64 – Polígonos coletados (quadrados amarelos)	101

Lista de tabelas

Tabela 1 – Quantidade de obras excluídas	48
Tabela 2 – Artigos selecionados	49
Tabela 3 – Comparativo dos algoritmos estudados em T3	51
Tabela 4 – Comparativo dos algoritmos estudados em T5	52
Tabela 5 – Lavouras e quantidade de amostras utilizadas no Experimento 1	66
Tabela 6 – Lavouras e quantidade de amostras utilizadas no Experimento 2	68
Tabela 7 – Lavouras e quantidade de amostras utilizadas no Experimento 3	70
Tabela 8 – Objetos classificados dentro da categoria Outros	70

Lista de abreviaturas e siglas

ANN	<i>Artificial Neural Network</i>
API	<i>Application Program Interface</i>
CDL	<i>Cropland Data Layer</i>
CNN	<i>Convolutional Neural Network</i>
ENVI	<i>Environment for Visualizing Images</i>
EUA	Estados Unidos da América
HLVQ	<i>Hybrid Learning Vector Quantization</i>
IFOV	<i>Instantaneous Field Of View</i>
KNN	<i>K-Nearest Neighbors Algorithm</i>
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
ML	<i>Machine Learning</i>
MV	<i>Máxima Verossimilhança</i>
OLI	<i>Operational Land Imager</i>
RF	<i>Random Forest</i>
ReLU	<i>Rectified Linear Unit</i>
SOFM	<i>Self-Organizing Maps</i>
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machine</i>
TIFF	<i>Tagged Image File Format</i>
TIRS	<i>Thermal Infrared Sensor</i>
USDA	<i>United States Department of Agriculture</i>
VGGNet	<i>United States Department of Agriculture</i>

Lista de símbolos

μ	Micrômetro
ϕ	Refletância
λ	Comprimento de onda
θ	Limiar de ativação
$^{\circ}k$	Kelvin
$^{\circ}c$	Graus Celsius

Sumário

1	INTRODUÇÃO	27
1.1	Contextualização	27
1.2	Objetivo	27
1.2.1	Geral	27
1.2.2	Específicos	28
1.3	Organização do Documento	28
2	REFERENCIAL TEÓRICO	29
2.1	Redes Neurais Artificiais	29
2.1.1	Perceptron multicamadas	30
2.1.2	Redes Neurais Convolucionais	31
2.2	Sensoriamento Remoto	32
2.2.1	Processamento de sinais	33
2.2.2	Resolução das imagens	35
2.2.3	Assinatura Espectral	38
2.2.4	Sensores de dados espectrais	39
2.3	Métricas de Performance	39
2.3.1	Matriz de Confusão	39
2.3.2	Acurácia	40
2.3.3	Precisão	40
2.3.4	<i>Recall</i>	41
2.3.5	<i>F1 Score</i>	41
3	METODOLOGIA	43
3.1	Detalhamento do plano metodológico	44
3.1.1	Fase de Planejamento da Pesquisa	44
3.1.2	Fase de Coleta de Dados	44
3.1.2.1	Pesquisa Bibliográfica	44
3.1.2.1.1	Revisão Sistemática de Literatura	44
3.1.2.2	Pesquisa de Dados	44
3.1.2.3	Cruzamento de Dados	45
3.1.2.4	Modelagem do problema por Aprendizado de Máquina	45
3.1.2.5	Elaboração do Sistema	45
3.2	Revisão Sistemática de Literatura	46
3.2.1	Planejamento	46
3.2.1.1	Objetivos	46

3.2.1.2	Planejamento da Pesquisa	46
3.2.1.3	Cr�terios de Sele�o	47
3.2.2	Execu�o	47
3.2.3	Resultados	50
3.2.3.1	Pesquisas Comparativas	51
3.2.3.2	Aprendizagem h�brida	52
3.2.3.3	Redes Neurais Convolucionais	52
3.2.4	Considera�es Finais da Revis�o Sistem�tica de Literatura	53
4	PROPOSTA DE SISTEMA DE CLASSIFICA�O DE LAVOURAS .	55
4.1	Extra�o de Dados	55
4.2	Cruzamento dos Dados	56
4.3	Delimita�o da �rea de estudo	57
4.4	Treinamento da Rede	59
4.5	Sa�da da Rede	60
4.6	An�lise dos Resultados	61
5	RESULTADOS	63
5.1	Arquitetura	63
5.2	Desenvolvimento	63
5.3	Experimentos	65
5.3.1	Experimento 1	66
5.3.2	Experimento 2	67
5.3.3	Experimento 3	69
5.3.3.1	Dados obtidos	72
5.3.4	Outros classificadores	75
5.3.4.1	Support Vector Machine - SVM	75
5.3.4.2	Random Forest	76
5.3.4.3	Regress�o Log�stica	76
5.3.4.4	K Neighbors	77
5.3.4.5	Gradient Boosting	77
5.3.4.6	Gaussiano	78
5.3.5	Extra Trees	78
5.3.5.1	�rvore de Decis�o	79
5.3.5.2	AdaBoost	80
5.4	Sistema Lavrador	80
6	CONSIDERA�ES FINAIS	85
6.1	Trabalhos Futuros	86

	REFERÊNCIAS	89
	APÊNDICES	93
	APÊNDICE A – TUTORIAL DE COLETA DE RÓTULOS	95
A.1	Descrição	95
A.2	Passos a serem seguidos	95
	APÊNDICE B – TUTORIAL DE COLETA DE IMAGENS LANDSAT-8	97
B.1	Descrição	97
B.2	Passos a serem seguidos	97
	APÊNDICE C – TUTORIAL DE RECORTE DE POLÍGONOS	99
C.1	Descrição	99
C.2	Passos a serem seguidos	99
	APÊNDICE D – CÓDIGO DA ARQUITETURA DA CNN	103
D.1	Descrição	103
D.2	Código	103
	APÊNDICE E – CÓDIGO DA RECORTE DOS POLÍGONOS	105
E.1	Descrição	105
E.2	Código	105

1 Introdução

1.1 Contextualização

O Brasil ocupa posição mundialmente privilegiada no setor agropecuário. É destaque mundial na produção agrícola da soja, milho, café, cana-de-açúcar, cacau, laranja, algodão, arroz, mandioca etc. Entretanto o país apresenta poucas ferramentas automatizadas para o auxílio da gestão do agronegócio, utilizando ferramentas manuais (MAPA, 2017).

O planejamento de plantações, que é tipicamente representado usando mapas temáticos, é fundamental na aplicação do agronegócio computacional. Em alguns países, o mapeamento correto das áreas é também um requisito para incluir programas de financiamento para produtores por parte do governo. Embora muitas pesquisas de uso da terra sejam ainda feitas manualmente, o uso de imagens de sensoriamento pode fornecer uma fonte de informação para criar automaticamente mapas temáticos, e está se tornando comum nos últimos anos em diversos países do mundo (MAPA, 2017).

O sensoriamento remoto (SR) é identificado pela obtenção de dados de um objeto sem haver um contacto físico com o mesmo, e várias vezes à longas distâncias. Atualmente, após o lançamento de satélites que coletam tais dados disponibilizarem seus dados para pesquisas, estes se tornaram ferramentas eficazes para diversas aplicações, entre elas, a estimativa de biomassa e produtividade de culturas.

Diversos países já se atentaram à tecnologia da classificação de lavouras de forma automática. Com o decorrer deste avanço tecnológico, tal classificação tem também evoluído e conseguido melhores resultados. Este trabalho se propõe a fazer um estudo da classificação de lavouras de forma autônoma, utilizando um paradigma que tem se demonstrado promissor para processamento e classificação de imagens, as redes neurais artificiais.

1.2 Objetivo

1.2.1 Geral

- Desenvolver um sistema capaz de classificar lavouras a partir de dados de sensoriamento remoto com o auxílio de aprendizado de máquina.

1.2.2 Específicos

- Pesquisar quais satélites e bandas fornecem dados interessantes à resolução do problema.
- Conferir se a abordagem de redes neurais convolucionais consegue bons resultados na classificação de lavouras.
- Comparar os resultados obtidos com redes neurais convolucionais com outras redes conhecidas.
- Chegar a uma conclusão se algoritmos de *deep learning* são bons auxiliares na mensuração e classificação da produtividade de culturas.

1.3 Organização do Documento

Este trabalho está organizado em seis capítulos, incluindo este capítulo de introdução, que compreende a contextualização e os objetivos selecionados.

O Capítulo 2 – Abrange o referencial teórico em que se baseia essa pesquisa. Contém a Pesquisa Bibliográfica que dá a base necessária sobre Redes Neurais Artificiais, especificamente as Redes Neurais Convolucionais. Contém também o Referencial Teórico sobre Sensoriamento Remoto, e conceitos importantes para a execução deste trabalho. Possui um conteúdo sobre as Métricas de *performance* utilizadas neste trabalho. Além de um resumo sobre alguns dos trabalhos correlatos já realizados na área.

O Capítulo 3 – Detalha a metodologia utilizada para a elaboração deste trabalho, uma Revisão Sistemática de Literatura onde foi levantado o estado da arte.

O Capítulo 4 – Mostra a elaboração do sistema desenvolvido para a classificação de lavouras.

O Capítulo 5 – Mostra a arquitetura e desenvolvimento das principais partes da Rede Neural Convolucional (CNN - *Convolutional Neural Network*) construída. Detalha os resultados obtidos nos experimentos da classificação de lavouras com o sistema elaborado, assim como a comparação com outros algoritmos de *machine learning* e também relata o funcionamento das funcionalidades da CNN.

O Capítulo 6 – Contém as considerações finais e indicação de trabalhos futuros.


2 Referencial Teórico

2.1 Redes Neurais Artificiais

Redes neurais são conjuntos de neurônios ligados entre si, formando um sistema nervoso onde cada indivíduo é responsável pela transmissão de pedaços de informação e em conjunto processam dados completos. As redes neurais artificiais são representações do modelo biológico que possibilitam representar os neurônios como unidades mais simples de computação. Diante de tais dados, consegue-se deduzir que neurônio é uma unidade de processamento de dados que é primordial para a operação de uma rede neural. Identificam-se 3 elementos básicos do modelo neural (HAYKIN, 2003):

- Um **conjunto de sinapses ou elos de conexão**, cada um caracterizado por um peso ou força própria. As sinapses são regiões ativas eletroquimicamente entre as membranas celulares dos neurônios, onde a partir de uma excitação ocorre uma reação química, que transmite os sinais de uma célula a outra por intermédio de substâncias chamadas neurotransmissores. Ao contrário de uma sinapse do cérebro, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos, bem como positivos (HAYKIN, 2003).
- Um **somador**, que soma os sinais de entrada ponderados pelas respectivas sinapses dos neurônios (HAYKIN, 2003).
- Uma **função de ativação** para restringir a amplitude da saída de um neurônio. A função de ativação é também conhecida como restritiva, já que restringe o intervalo permissível de amplitude do sinal de saída a um valor finito (HAYKIN, 2003).

Figura 1 – Representação do neurônio artificial inspirado pelo neurônio biológico.



Fonte: (VINICIUS, 2017)

Normalmente a função de ativação costuma ser do tipo função degrau ou degrau bipolar. Sua representação matemática é:

$$y = g(u) \quad (2.1)$$

Onde:

$$\sum_{i=1}^n w_i \cdot X_i - \theta \quad (2.2)$$

Simbologia:

- X_i : Entradas
- W_i : Pesos Sinápticos
- θ : Limiar de Ativação
- y : Saída
- $g(\cdot)$: Função de Ativação - Degrau ou Degrau Bipolar

O funcionamento da rede se deve as entradas (X_i) que representam as informações do processo a ser mapeado, sendo que cada uma das entradas terá um peso sináptico ponderado (W_i) que representa a importância de cada entrada em relação ao valor de saída esperado (y). O limiar de ativação será subtraído do resultado da somatória (θ) e então repassado como argumento da função de ativação $g(\cdot)$, a qual conseguirá como resultado a saída esperada (HAYKIN, 2003).

2.1.1 Perceptron multicamadas

A perceptron multicamadas (*Multilayer Perceptron* - MLP) é uma rede neural que trabalha similarmente a um perceptron, mas com mais de uma camada de neurônios. Sua composição é formada por camadas de neurônios ligadas entre si por sinapses com pesos. Seu aprendizado é geralmente feito através do algoritmo de *Backpropagation* (retropropagação do erro) (MATSUGU et al., 2003).

Esta rede é composta de camadas de perceptrons alinhados em diferentes camadas, que podem variar a partir de três (MATSUGU et al., 2003):

- **Camada de entrada**, por onde os dados são incluídos na rede.
- **Camada intermediária de processamento**, normalmente chamada de hidden layer (camada oculta).
- **Camada dos neurônios de saída**, que apontam a resposta, comunicando ao mundo exterior.

Seu treinamento, que é supervisionado, utiliza duas fases (MATSUGU et al., 2003):

- **Fase de propagação do sinal funcional (*feedforward*):** Os dados aplicados aos neurônios de entrada, tem o efeito de propagação de camada a camada, sendo que os pesos continuam fixos. Um conjunto de dados de saída é produzido como resposta da rede.
- **Retropropagação do erro (*backpropagation*):** *Backpropagation* é um algoritmo de *machine learning* aplicado à rede *Multilayers Perceptron*, que possui como objetivo o reconhecimento de padrões baseados em correção de erros. Isso ocorre devido à retropropagação dos erros de saída de uma (*Artificial Neural Network* - ANN) através das camadas precedentes, para que dessa maneira sejam balanceados os pesos de entrada da rede.

Existem vários tipos de ANN e dentro destes vários, existe a Rede Neural Convolutiva ou Convolutiva, que é uma variação das MLP. As redes convolucionais também são inspiradas nos processos biológicos (MATSUGU et al., 2003).

2.1.2 Redes Neurais Convolucionais

Redes Neurais Convolucionais ou Redes Neurais Convolutivas (*Convolutional Neural Networks* - CNN) são um sub ramo das Redes Neurais Artificiais MLP, e têm inspiração de como a percepção visual ocorre biologicamente (NIELSEN, 2018).

A arquitetura das CNN pode ser referenciada através de um conjunto de outras camadas sequenciais, cada uma contendo um objetivo específico. A arquitetura de uma rede convolutiva se baseia basicamente em três tipos de camada (NIELSEN, 2018):

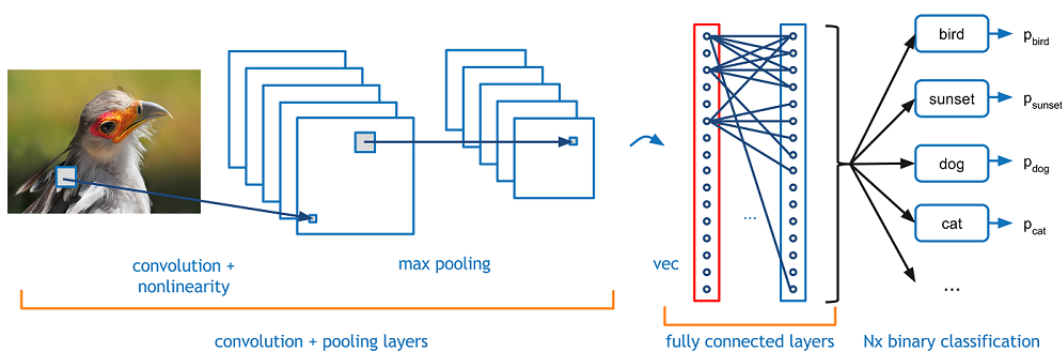
- ***Convolutional layers*:** A camada convolutiva possui neurônios correspondentes a intensidade de cada pixel da imagem analisada, sendo que um conjunto de pixels dessa imagem corresponde à um único neurônio da camada oculta (HAFEMANN; SABOURIN; OLIVEIRA, 2016).
 - **Campo receptivo local** é a maneira como é denominada a região onde cada conexão possui determinado peso e cada neurônio reconhece um viés global. Então, a região é percorrida por toda a imagem, sendo que cada deslocamento da imagem é representado por um novo neurônio da camada oculta (NIELSEN, 2018).
 - **Pesos Compartilhados** dentro da camada convolutiva são os mesmos para cada campo receptivo local. Ou seja, os neurônios da primeira camada oculta detectam um padrão que é o mesmo das outras regiões da imagem. Esta é uma

característica que torna a CNN adaptativa em relação a diferentes representações que um padrão possa ter (NIELSEN, 2018).

- **Filtros:** Esses filtros ficam responsáveis pela formação dos mapas de características. Na camada convolucional se aplicam os filtros realizando convolução ao decorrer da imagem. O processo se deve às diversas operações na mudança dos valores numéricos da matriz de filtro antes da operação de convolução. Isso significa que diferentes filtros detectam diferentes padrões (NIELSEN, 2018).
- **Pooling layers:** A camada de *pooling* é utilizada logo após a camada de convolução e sua função é reduzir as dimensões da imagem para achar padrões que possam ficar mais evidentes (NIELSEN, 2018). Um procedimento comum na camada de *pooling* é chamado de *max-pooling*, no qual em uma unidade de *pooling* exibe-se a ativação máxima na região de entrada (NIELSEN, 2018).
- **Fully-connected layers:** É uma camada que também está presente nas redes neurais artificiais em geral (não necessariamente convolucionais). Ela é responsável por conectar as camadas sem utilizar pesos compartilhados. (HAFEMANN; SABOURIN; OLIVEIRA, 2016) Cada neurônio da camada anterior está conectado a algum neurônio da camada a vir, e adiciona uma camada saída com o número de neurônios em relação ao número de classes presentes no estudo em questão. por isso o termo totalmente conectado. É uma forma barata de aprender combinações não-lineares desses recursos.

Um exemplo de CNN pode ser visto na Figura 2. Note como a junção das camadas citadas anteriormente servem para a classificação de um objeto em uma saída multiclasse.

Figura 2 – Exemplo de uma CNN




Fonte: (DESHPANDE, 2016)

2.2 Sensoriamento Remoto

Sensoriamento Remoto (SR) é a utilização de sensores que adquirem informações sobre objetos sem que haja contato direto entre eles. A partir do SR se obtém imagens

e dados da superfície terrestre através de captação e registro da energia refletida pela superfície, não havendo contato físico entre o sensor e a superfície estudada. O veículo mais utilizado é o satélite por conta de seu custo-benefício, podendo orbitar a terra ao decorrer de anos (CROSTA, 1999).

Figura 3 – Processo de sensoriamento remoto



Fonte: (BOSQUILLA, 2013)

O SR é um processo de algumas etapas, dividindo responsabilidades à alguns agentes. Seus elementos são (CROSTA, 1999):

- A - Fonte de iluminação
- B - Interação entre radiação e atmosfera terrestre
- C - Interação com alvo
- D - Recepção de energia refletida pelo sensor
- E - Transmissão, recepção e processamento de imagem
- F - Interpretação e análise
- G - Aplicação


A classificação das imagens de lavouras se encontra entre as etapas E e F, onde em E existe o tratamento dos dados recebidos e em F, após a passagem dos dados em algum algoritmo para o tratamento, é realizada a interpretação e análise dos dados (CROSTA, 1999).

2.2.1 Processamento de sinais

Toda matéria a uma temperatura superior à zero absoluto (0° K ou -273° C) emite radiação eletromagnética, como resultado de suas oscilações atômicas e moleculares. Sendo que essa radiação, pode ser refletida, absorvida ou transmitida. Quando ela é absorvida,

a energia é reemitida através de comprimentos de onda que são captados por sensores eletromagnéticos. A energia capturada demonstra o comportamento espectral do alvo e é denominada assinatura espectral, sendo utilizada, em SR, para distinguir diversos materiais entre si (FONTANA, 2011).

Figura 4 – Interação Radiação/Objeto



Fonte: (FONTANA, 2011)

$$\phi Ri_{\lambda} = \phi Rr_{\lambda} + \phi Ra_{\lambda} + \phi Rt_{\lambda} \quad (2.3)$$

Onde:

Ri = radiação incidente

Rr = radiação refletida

Ra = radiação absorvida

Rt - radiação transmitida

Na Figura 4, a energia eletromagnética que incide, interage com as células da planta, água, ar dos espaços entre as células, pigmentos dentro da folha, refletindo energia em diferentes faixas do espectro eletromagnético. Isso ocorre de forma similar para os diferentes tipos de objetos. O espectro eletromagnético capta energia nas seguintes frequências: (FONTANA, 2011).

- **Raios-GAMA:** são os raios mais penetrantes das emissões de substâncias radioativas. Não existe, em princípio, limite superior para a frequência das radiações gama.
- **Raios X:** Por se constituir de fótons de alta energia, os raios-X são altamente penetrantes, sendo uma poderosa ferramenta em pesquisas sobre a estrutura da matéria.
- **Ultravioletas:** Geralmente fotografias são mais sensíveis à radiação ultravioleta do que a luz visível. Tem um grande uso na detecção de minerais e poluição marinha.

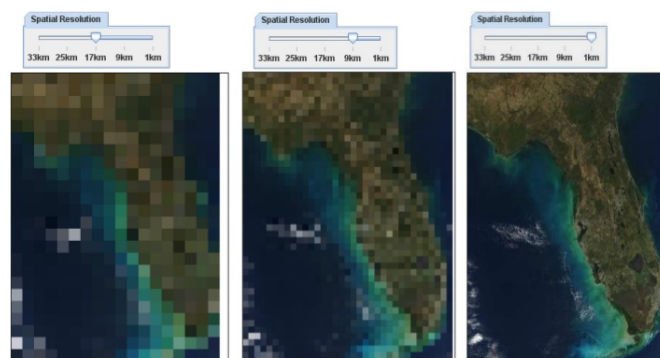
- **Visível:** Causa a sensação de visão ao olho humano. Possui pequena variação dos comprimentos de onda. Também é importante para o SR pois possui boa correlação com a experiência visual dos intérpretes.
- **Infravermelho:** Possui grande importância para o SR. Essa radiação é facilmente absorvida pela maioria das substâncias (causando o efeito de aquecimento).
- **Microondas:** Podem gerar feixes de radiação eletromagnética altamente concentrados, chamados radares. São pouco atenuadas pela atmosfera, permitindo o uso de sensores de microondas em qualquer condição climática.
- **Ondas de rádio:** Baixas frequências e grandes comprimentos de onda. São utilizadas para comunicação a longa distância.

2.2.2 Resolução das imagens

O termo resolução em sensoriamento remoto contém quatro diferentes (e independentes) parâmetros: resolução espacial, resolução espectral, resolução radiométrica e resolução temporal (CROSTA, 1999).

- **Resolução Espacial:** Refere-se à capacidade do sistema sensor em diferenciar e medir os alvos. Esta competência baseia-se na composição geométrica do detector na superfície terrestre, estabelecendo sua área do campo de visada do instrumento em uma certa altitude e em um determinado período (CROSTA, 1999). Como pode ser visto na Figura 5, quanto menor a área representada por *pixel*, mais detalhes o sensor conseguirá obter.

Figura 5 – Comparação entre resoluções espaciais

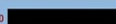

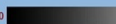


Fonte: (JENSEN, 2015)

O ângulo definido por esta composição é intitulado de campo de visada instantânea (*Instantaneous Field Of View*, IFOV). O IFOV define a área do terreno focalizada a uma determinada altitude através do instrumento sensor (CROSTA, 1999).

- **Resolução Radiométrica:** Refere-se à capacidade do sistema sensor em identificar as mudanças da radiância espectral captada. A radiância do pixel passa por uma codificação digital, adquirindo um valor numérico, que é representado em bits, denominado de Número Digital. Este valor é traduzido para uma intensidade visual, um nível de cinza, localizado num intervalo finito (0, K-1), onde K é o número de valores possíveis, denominados de níveis de quantização (SCHOWENGERDT, 2006).


Figura 6 – Valores contidos em bits para resolução radiométrica

Bits	Wertebereich	Grauwerte
1Bit	$2^1 = 2$ (0-1)	0  1
4Bit	$2^4 = 16$ (0-15)	0  15
8Bit	$2^8 = 256$ (0-255)	0  255

Fonte: (JENSEN, 2015)

O seu valor é sempre em potência de 2. Exemplificado na Figura 6, as diferenças são maiores nos níveis 2 e 16 do que nos níveis 256 e 2048, devido ao fato do olho humano não possuir sensibilidade às mudanças de intensidade acima de 30 níveis de cinza (CROSTA, 1999). Exemplo de mesma região com diferentes resoluções radiométricas pode ser encontrado na Figura 7.


Figura 7 – Diferença de resolução radiométrica



Fonte: (JENSEN, 2015)

- **Resolução Temporal:** A resolução temporal é importante em estudos relacionados a mudanças na superfície terrestre e seu monitoramento. Refere-se à frequência de transição do sensor num mesmo local, num determinado intervalo de tempo. Este ciclo está relacionado às características orbitais da plataforma que são sua altura, sua velocidade e inclinação, e ao ângulo total de abertura do sensor, como pode ser ilustrada na Figura 8 (NOVO, 2010).

Figura 8 – Ilustração de satélite orbitando o mesmo ponto em tempos diferentes

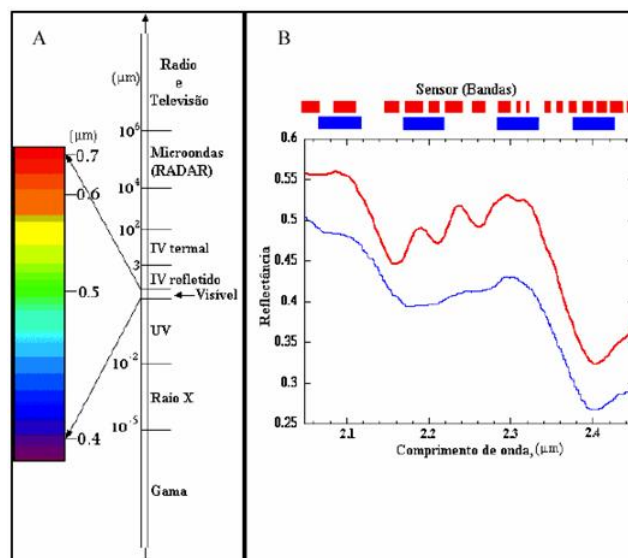


Fonte: (JENSEN, 2015)

- **Resolução Espectral:** Resolução espectral é "uma medida da largura das faixas espectrais e da sensibilidade do sistema sensor em distinguir entre dois níveis de intensidade do sinal de retorno"(NOVO, 2010).

Dois aspectos são importantes para a compreensão de resolução espectral: o comprimento de onda detectado pelo sensor e a quantidade de faixas espectrais que ele pode captar. A Figura 9.A evidencia as diferentes regiões do espectro eletromagnético aplicadas em sensoriamento remoto. A Figura 9.B mostra o comprimento de onda detectado através das bandas de dois sistemas sensores (vermelho e azul). O primeiro sistema, vermelho, tem um amplo número de bandas espectrais e uma grande sensibilidade espectral. O sistema azul, possui poucas bandas e uma menor sensibilidade espectral. Percebe-se que o sistema vermelho consegue identificar melhor as características da resolução espectral de um dado objeto (NOVO, 2010).

Figura 9 – Espectro Eletromagnético (A) e Resolução espectral (B)

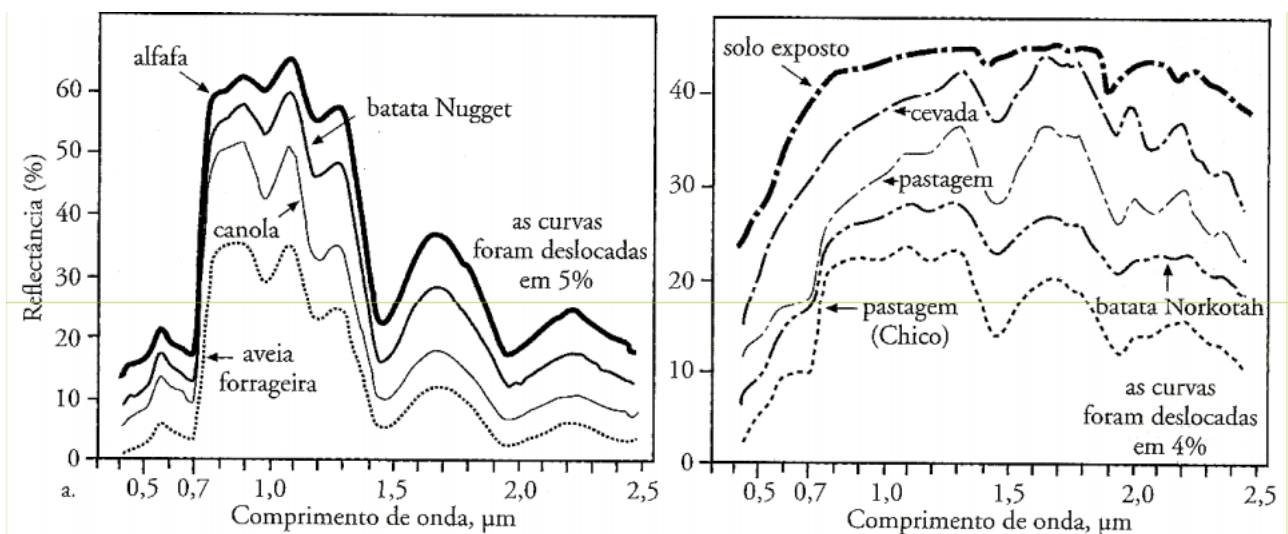


Fonte: (JENSEN, 2015)

2.2.3 Assinatura Espectral

Diferentes tipos de superfície, como a água, o solo descoberto ou a vegetação, refletem a radiação de forma distinta em diversos canais. A radiação refletida em função do comprimento de onda é denominada assinatura espectral da superfície (FONTANA, 2011).


Figura 10 – Espectros de algumas espécies agrícolas, obtidas no Colorado em 3 de setembro de 1993 usando o AVIRIS com 244 canais e pixels de 20x20m



Fonte: (FONTANA, 2011)

Percebe-se pelas Figuras 10 e 11 que o modo como a radiação interage com a estrutura do tecido celular das folhas das árvores, por possuírem estruturas distintas, refletem de volta radiações distintas, criando assim, cada objeto uma assinatura espectral também distinta.

Figura 11 – Estrutura do tecido celular das folhas de milho e folhas de soja



Fonte: (FONTANA, 2011)

2.2.4 Sensores de dados espectrais

Como visto na Figura 9, a quantidade de bandas espectrais de um sensor, está diretamente relacionada ao quão bem um sensor conseguirá identificar as nuances da assinatura espectral de cada objeto. Existem diversos satélites que oferecem dados abertos aos dados captados por eles, assim como às características de suas bandas quanto as suas resoluções.

Na Figura 12 seguem as especificações do satélite *Landsat-8* da série *Landsat*, assim como suas bandas e os comprimentos de onda captados por cada banda, e suas resoluções espaciais.

Figura 12 – Faixas de resolução espacial do Satélite Landsat-8

Landsat 8	Bands	Wavelength (micrometers)	Resolution (meters)
Operational Land Imager (OLI) and Thermal Infrared Sensor (TIRS)	Band 1 - Ultra Blue (coastal/aerosol)	0.435 - 0.451	30
	Band 2 - Blue	0.452 - 0.512	30
	Band 3 - Green	0.533 - 0.590	30
	Band 4 - Red	0.636 - 0.673	30
	Band 5 - Near Infrared (NIR)	0.851 - 0.879	30
	Band 6 - Shortwave Infrared (SWIR) 1	1.566 - 1.651	30
	Band 7 - Shortwave Infrared (SWIR) 2	2.107 - 2.294	30
	Band 8 - Panchromatic	0.503 - 0.676	15
	Band 9 - Cirrus	1.363 - 1.384	30
	Band 10 - Thermal Infrared (TIRS) 1	10.60 - 11.19	100 * (30)
	Band 11 - Thermal Infrared (TIRS) 2	11.50 - 12.51	100 * (30)

* TIRS bands are acquired at 100 meter resolution, but are resampled to 30 meter in delivered data product.

Fonte: (SMITH, 2017)

De acordo com Smith (2017), as combinações de bandas favorecem o estudo de determinadas áreas. Para estudos sobre agricultura são indicadas as bandas 6, 5 e 2. Para estudos de análise de vegetação, as bandas 6, 5 e 4.

2.3 Métricas de Performance

Diferentes métricas de desempenho são usadas para avaliar diferentes algoritmos de aprendizado de máquina. A escolha das métricas influencia em como o desempenho dos algoritmos de aprendizado de máquina é medido e comparado, sendo muito importantes para chegar a uma conclusão sobre a performance do seu modelo (POWERS, 2007). As métricas abordadas neste trabalho estão concentradas para auxiliar problemas de classificação.

2.3.1 Matriz de Confusão

A matriz de confusão é uma métrica eficiente para descobrir a exatidão e precisão do modelo. É usada para problemas de classificação, onde a saída pode ser de dois ou mais tipos de classes, como pode ser visto na Figura 13. A matriz de confusão em si não

é uma medida de desempenho, mas quase todas as métricas de desempenho são baseadas na matriz de confusão e nos dados fornecidos por ela (POWERS, 2007).

Figura 13 – Exemplo de matriz de confusão

		Valor Verdadeiro (confirmado por análise)	
		positivos	negativos
Valor Previsto (predito pelo teste)	positivos	VP Verdadeiro Positivo	FP Falso Positivo
	negativos	FN Falso Negativo	VN Verdadeiro Negativo

Fonte: (POWERS, 2007)

- **Verdadeiros Positivos (VP):** Verdadeiros positivos são os casos em que a classe real do ponto de dados era 1 (verdadeiro) e o previsto também é 1 (verdadeiro) (POWERS, 2007).
- **Verdadeiros Negativos (VN):** Verdadeiros negativos são os casos em que a classe real do ponto de dados era 0 (Falso) e o previsto também é 0 (Falso) (POWERS, 2007).
- **Falsos Positivos (FP):** Falso positivos são os casos em que a classe real do ponto de dados era 0 (Falso) e o previsto é 1 (Verdadeiro). Falso é porque o modelo previu incorretamente e positivo porque a classe prevista era positiva (1) (POWERS, 2007).
- **Falsos Negativos (FN):** Falso negativos são os casos em que a classe real do ponto de dados era 1 (Verdadeiro) e o previsto é 0 (Falso). Falso é porque o modelo previu incorretamente e negativo porque a classe prevista era negativa (0) (POWERS, 2007).

2.3.2 Acurácia

Uma métrica muito utilizada para medir performance em modelos de classificação envolvendo *machine learning* é a acurácia ou precisão geral do modelo, que mede o número de acertos divididos pelo número total de testes. Ela serve para responder o seguinte questionamento: No geral, o quão frequente o classificador está correto? (POWERS, 2007)

$$Acurácia = \frac{Verdadeiros\ Positivos(VP) + Verdadeiros\ Negativos(VN)}{Total} \quad (2.4)$$

2.3.3 Precisão

A precisão é uma medida que nos diz qual a proporção das amostras classificadas como verdadeiras, quantas destas realmente eram verdadeiras. Ela serve para responder

o seguinte questionamento: daqueles que classifiquei como corretos, quantos efetivamente eram? A precisão é uma boa medida quando as classes da variável de destino nos dados são equilibradas, e ela não é recomendada como medida quando as classes da variável destino nos dados são a maioria de uma classe. (POWERS, 2007)

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos}(VP)}{\text{Verdadeiros Positivos}(VP) + \text{Falsos Positivos}(FP)} \quad (2.5)$$

2.3.4 Recall

O *recall* é a frequência em que o classificador encontra os exemplos de uma classe, ou seja, “quando é da classe X, o quão frequente realmente é classificado como X?”. O *recall* nos dá informações sobre o desempenho de um classificador em relação a falsos negativos (quantos faltaram), enquanto a precisão nos dá informações sobre o seu desempenho em relação aos falsos positivos (quantos capturamos). (POWERS, 2007)

$$\text{Recall} = \frac{\text{Verdadeiros Positivos}(VP)}{\text{Verdadeiros Positivos}(VP) + \text{Falsos Negativos}(FN)} \quad (2.6)$$

2.3.5 F1 Score

Essa métrica combina precisão e *recall* de modo a trazer uma única métrica que indique a qualidade geral do modelo classificador e é indicada para amostras com conjuntos de dados que possuem classes desproporcionais (POWERS, 2007). O *F1 Score* pode ser traduzido na equação 7:

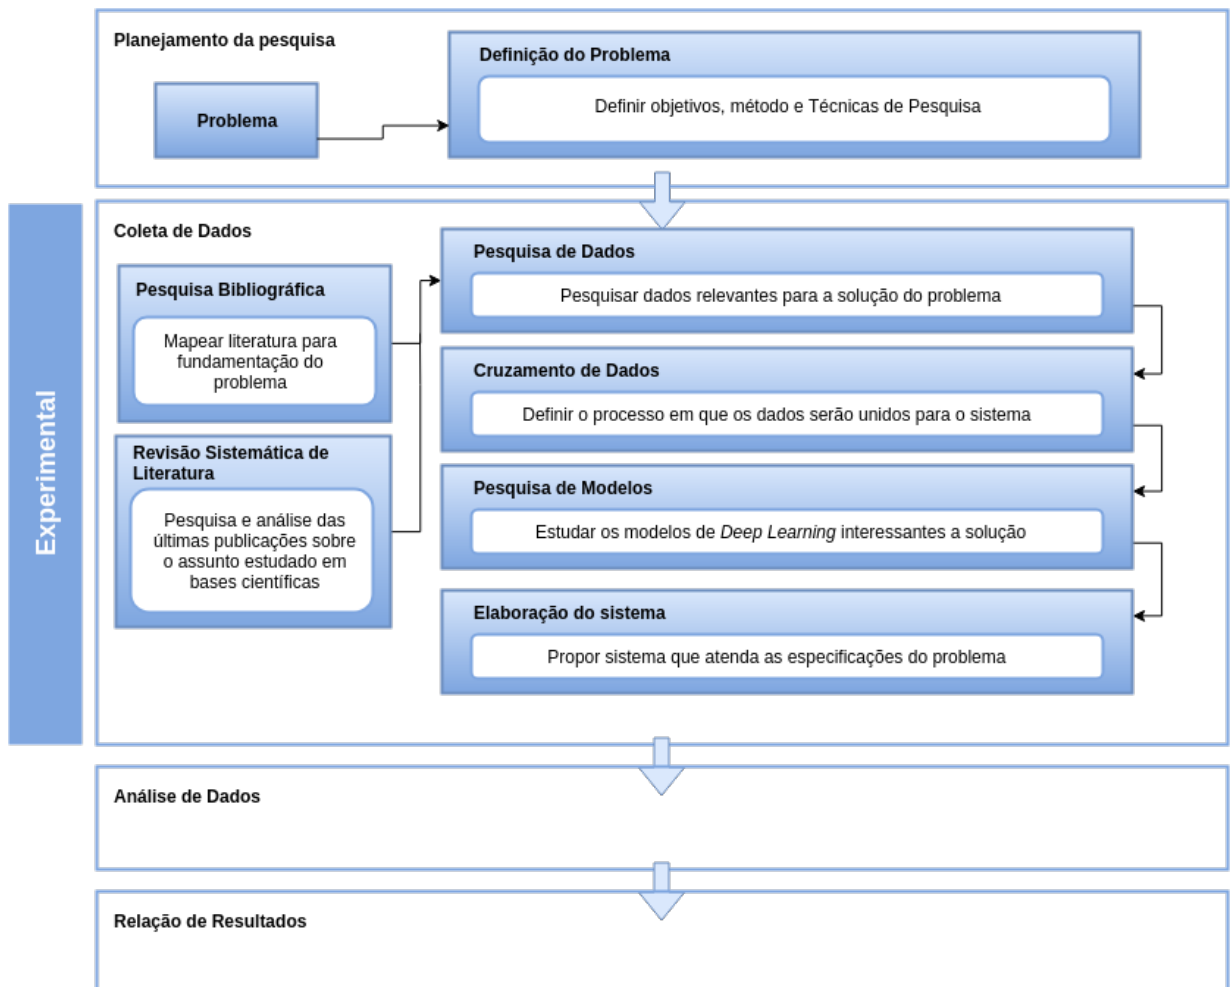
$$F1 = \frac{2 * \text{precisão} * \text{recall}}{\text{precisão} + \text{recall}} \quad (2.7)$$

3 Metodologia

Para o alcance do objetivo da pesquisa proposta, a metodologia de pesquisa foi classificada e definida, e foi adotado um plano metodológico.

Para a coleta de dados foram empregadas as técnicas de pesquisa bibliográfica contendo uma revisão sistemática de literatura, que permitiu a pesquisa sistematicamente entre publicações mais relevantes vinculadas com a problemática estudada. O plano metodológico compreendeu 04 fases básicas: planejamento da pesquisa; coleta de dados; análise dos dados; e relato dos resultados, apresentado na figura 14.

Figura 14 – Fluxograma da metodologia utilizada



Fonte: Os autores.

3.1 Detalhamento do plano metodológico

3.1.1 Fase de Planejamento da Pesquisa

A fase de Planejamento da Pesquisa foi fundamental para o entendimento do problema, assim como para o primeiro *brainstorm* de ideias para a resolução do problema proposto. Foram realizadas pesquisas sobre os principais problemas vinculados à uma classificação ruim de lavouras e como seriam as principais maneiras de melhorar tal processo.

3.1.2 Fase de Coleta de Dados

3.1.2.1 Pesquisa Bibliográfica

A partir de pesquisas em bases de dados científicas foram levantadas informações sobre o *background* teórico que sustenta o estudo. Nos Capítulos 1 e 2 são apresentados um levantamento sobre processamento de imagens de sensoriamento remoto, e as problemáticas envolvendo a classificação de lavouras.

3.1.2.1.1 Revisão Sistemática de Literatura

A revisão sistemática é um método de revisão de literatura que tem como objetivo compreender e analisar estudos significativos a respeito de um determinado tema. Tendo em vista a aplicação de revisão, se propõe um processo que retrata os passos essenciais para a realização da revisão sistemática. A condução desse modelo provê um resumo sucinto sobre o tópico em questão e envolve atividades que podem ser categorizadas em três fases – planejamento, condução e relato (SAMPAIO, 2007).

Sua natureza sistêmica permite sua posterior execução, garantindo os mesmos resultados caso seja executada da mesma maneira proposta pelo pesquisador (SAMPAIO, 2007). Ela é importante pois traz publicações anteriores a data do início desta pesquisa, permitindo saber quais foram as principais contribuições científicas na área de classificação de lavouras utilizando dados de sensores remotos com o auxílio de redes neurais artificiais. Com as informações levantadas nesta pesquisa secundária, é possível ter uma base científica para saber quais tecnologias obtiveram sucesso para o objetivo desta pesquisa.

3.1.2.2 Pesquisa de Dados

Nesta etapa, foi conduzida uma pesquisa para saber qual a periodicidade de cada satélite e quais bandas fornecem mais informações, quais sensores obtém os melhores resultados e estudo dos dados utilizados para classificação. Pesquisou-se também aonde encontrar dados disponíveis de colheitas já plantadas, assim como seu período, e localização em coordenadas.

3.1.2.3 Cruzamento de Dados

Geralmente, um único tipo de dado não é suficiente para atingir o entendimento do problema que o pesquisador está tentando solucionar. Nesta fase da pesquisa, se estuda as principais formas para que haja o cruzamento dos dados pertinentes à resolução do problema. Para cruzar os dados, necessita-se de organização criteriosa e muito bem consolidada. É necessário entender quais critérios analisar e padronizá-los para a entrada em um sistema. A definição desses critérios é feita com base em informações que já foram coletadas. (NASCIMENTO, 2017)

Foram buscadas ferramentas que auxiliem de forma otimizada o cruzamento dos dados e que também entreguem esses dados cruzados de uma forma também otimizada para o modelo a ser adotado na resolução do problema.

3.1.2.4 Modelagem do problema por Aprendizado de Máquina

O processo de treinamento de um modelo de *Machine Learning* - ML envolve o fornecimento de modelo um modelo ou um algoritmo de aprendizagem, com os dados de treinamento que serão absorvidos para a calibração dos pesos do sistema. Esses, os dados obtidos pela etapa anterior.

Os dados de treinamento precisam conter as informações e rótulos corretos. Buscou-se trazer esses dados corretos na etapa de cruzamento dos dados.

3.1.2.5 Elaboração do Sistema

O último passo antes da execução do sistema, é o passo de planejamento. Nesta etapa foram levados em consideração todos os passos anteriores assim como o objetivo da pesquisa para decidir como o sistema de fato classificaria as lavouras automaticamente. Aqui serão levantados quais dados o sistema deverá receber, e quais dados ele mostrará após o processamento dos dados recebidos.

O sistema deverá ser escrito em *python*, vide a grande quantidade de estudos e bibliotecas no paradigma de ML para esta linguagem. A API para construção das camadas da CNN será a *Keras*, por ser uma API de alto nível em ANN, escrita em *python*, que corre em cima do *Framework* de código aberto *Tensorflow*, que é voltado para ML.

Para o manuseio das imagens multiespectrais e *layers* de rótulo de lavouras, será utilizada a versão 5.0.1 do *Environment for Visualizing Images* - ENVI.

3.2 Revisão Sistemática de Literatura

3.2.1 Planejamento

3.2.1.1 Objetivos

O objetivo deste trabalho de revisão sistemática foi analisar informações sobre as pesquisas relacionadas à classificação de lavouras com auxílio de dados de sensoriamento remoto utilizando algoritmos de redes neurais.

Foram formuladas três questões de pesquisas, que nortearam a revisão:

Perguntas:

- Q1. Redes neurais podem ser uma ferramenta eficaz?
- Q2. Quais dados foram usados para a classificação?
- Q3. Quais as acurácias gerais das abordagens adotadas?

De acordo com as respostas, foi possível estabelecer quais artigos tratam sobre a classificação de lavouras com sensoriamento remoto por redes neurais artificiais.

3.2.1.2 Planejamento da Pesquisa

As palavras-chave identificadas foram:

- PI1. Artificial neural network
- PI2. Processing
- PI3. Agriculture
- PI4. Classification
- PI5. Spectral

As fontes de dados utilizadas na condução da revisão sistemática foram as seguintes bases eletrônicas científicas:

- BD1. IEEEExplore;
- BD2. Scopus;

A string de busca que foi utilizada nas bases de dados para a obtenção dos resultados está representada a seguir :

String na base IEEE Xplore:

- SB1: (((((artificial neural network) AND processing) AND agricult*) AND classif*) AND spectral)

String na base Scopus:

- SB2.(“artificial neural network” AND processing AND agricult* AND classif* AND spectral)

3.2.1.3 Critérios de Seleção

Para selecionar os artigos que seriam utilizados neste trabalho, foram avaliados conforme os critérios de inclusão definidos:

- CI1. A publicação deve estar escrita em inglês ou português;
- CI2. A publicação deve estar acessível ao pesquisador para realização de download;
- CI3. A publicação deve apresentar estudos relevantes ao tema proposto nesta revisão sistemática no título ou no resumo.
 - CI3.1. A publicação deve tratar a área de aprendizado de máquina.
 - CI3.2. A publicação deve tratar de agricultura.

Os critérios de exclusão definidos foram:

- CE1. A publicação que não entra nos critérios de inclusão.
- CE2. A publicação que constar nota de retração.
- CE3. A publicação que se encontrar duplicada na outra base de dados pesquisada.
- CE4. A publicação trata de problema que não a classificação de lavouras.
- CE5. A publicação trata de problema que são resolvidos com auxílio de imagens de sensoriamento remoto.

3.2.2 Execução

Sobre os resultados obtidos através das strings, foram encontrados um total de 34 artigos, sendo 17 obtidos através da *string* de busca SB1 e 17 pela *string* de busca SB2.

Foram eliminadas 28 publicações de acordo com os critérios estabelecidos pelas restrições, como encontra-se na Tabela 1:

Tabela 1 – Quantidade de obras excluídas

Motivo da exclusão	Quantidade de obras excluídas
CE1	9
CE2	0
CE3	3
CE4	10
CE5	5
Total	28


O quadro 2 aponta as obras utilizadas, de acordo com as questões de pesquisa. A primeira coluna contendo a classificação por grupo dos artigos, a segunda contém a numeração dos trabalhos, a terceira contém os títulos dos trabalhos lidos por completo, a quarta contém o nome dos autores e a quinta contém o ano de publicação.

Tabela 2 – Artigos selecionados

<i>Classificação</i>	<i>ID</i>	<i>Título</i>	<i>Autores</i>	<i>Ano</i>
Redes Neural Convolutacional	T1	Learning Deep Features on Multiple Scales for Coffee Crop Recognition	Rafael Baeta, Keiller Nogueira, David Menotti, Jefersson A. dos Santos	2017
	T2	Peanut planting area change monitoring from remote sensing images based on deep learning	Zhuang Zhou, Shengyang Li	2017
Comparativos	T3	A comparison of machine learning algorithms for mapping of complex surface-mined and agricultural landscapes using ZiYuan-3 stereo satellite imagery	Xianju Li, Weitao Chen, Xinwen Cheng, Lizhe Wang	2016
	T4	SNNS application for crop classification using HyMap data	Dawid Olesiuk, Martin Bachmann, Martin Habermeyer, Wike Heldens, Bogdan Zagajewski	2012
	T5	Multitemporal classification of natural vegetation cover in Brazilian Cerrado	Gustavo Bayma Siqueira Silva, Marcio Pupin Mello, Yosio Edemir Shimabukuro, Bernardo Friedrich Theodor Rudorff, Daniel de Castro Victoria	2011
<i>Aprendizagem híbrida</i>	T6	Classification of Remote Sensing Agricultural Image by Using Artificial Neural Network	Haihui Wang, Junhua Zhang, Kai Xiang, Yang Liu	2009

3.2.3 Resultados

Figura 15 – Gráfico de Artigos por Base




Fonte: Os próprios autores.

A Figura 15 aponta a proporção de artigos escolhidos por base de dados. Percebe-se que a base IEEExplore possui mais artigos escolhidos (66,7%) em relação à base de dados da *Scopus* (33,3%). Isso se deve principalmente pela base IEEExplore ter sido consultada antes da base *Scopus*, e como o critério de exclusão CE3 definia que não seriam incorporados novamente artigos selecionados em bases anteriormente pesquisadas, alguns artigos da base *Scopus* foram eliminados.

Um outro fator importante para a prevalência de artigos da base IEEExplore em comparação aos artigos da base *Scopus*, foi que vários dos artigos desta base estavam no idioma mandarim, pois eram artigos chineses que continham títulos e *abstracts* em inglês, e com o restante da pesquisa não-inglês. Estes artigos foram eliminados por causa do critério de exclusão CE1, pois não se enquadraram no CI1.

Figura 16 – Gráfico de relação dos anos de publicação



Fonte: Os próprios autores.

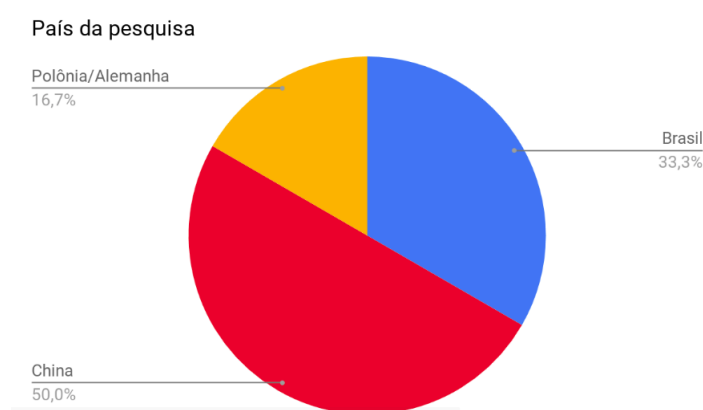
Como pode ser observado na Figura 16, os anos das publicações selecionadas por

esta pesquisa, vem da data de 2009 a 2017. Isso se deve ao fato de a tecnologia estar sendo utilizada mais fortemente durante esses anos. Os anos de 2016 e 2017, somados, equivalem há 50% dos artigos selecionados para esse trabalho.

O ano de 2017 contém 33% dos artigos escolhidos, que tratam sobre uma nova abordagem que tem sido muito utilizada na classificação de imagens por processamento, e será abordada mais a fundo posteriormente.

Na Figura 17, percebe-se que as autorias dos artigos selecionadas nesta revisão sistemática se concentram em 3 países/regiões. A China possui 50% das publicações selecionadas, demonstrando ser um grande nome na pesquisa de redes neurais para classificação de lavouras. O Brasil vem logo em seguida com 33,3% das publicações e um trabalho sendo realizado em colaboração entre a Polônia e Alemanha, totalizando 16,7% das publicações.

Figura 17 – Gráfico de países com obras publicadas e selecionadas



Fonte: Os próprios autores.

Isso se deve aos países China e Brasil serem grandes exportadores de grãos a nível mundial, e vêem a tecnologia das redes neurais como uma ferramenta eficaz para para a classificação de lavouras.

3.2.3.1 Pesquisas Comparativas

Em T3, o artigo faz uma comparação entre *Artificial Neural Networks* (ANNs), *Random Forest* (RF) e *Support Vector Machine* (SVM), seus resultados são os seguintes (LI et al., 2016).

Tabela 3 – Comparativo dos algoritmos estudados em T3

Algoritmo	ANN	ML	SVM
Acurácia	87,14%	87,14%	71,88%

Em T4, Artigo polonês/alemão de 2010, classificou objetos interessantes abundantes na região de estudo como milho e cevada. Concluiu que a melhor precisão foi obtida

usando as bandas de 10 MNF com o tamanho de sub-padrão de 3 x 3 pixels. A classificação, baseada nos índices de vegetação hiperespectral, alcançou uma precisão geral de 70.8-84.7% (OLESIUK et al., 2010).

T5 é um artigo brasileiro de 2011 que usou dados do satélite Moderate-Resolution Imaging Spectroradiometer, MODIS. Três classificadores foram testados: (i) MV - Máxima Verossimilhança; (ii) SVM - *Support Vector Machine*; e (iii) ANN. Concluiu que o classificador ANN apresentou maior coeficiente de *kappa* (0,58) e acurácia geral de 87,14%. Separou Bosque do Cerrado (CW); Cerrado arborizado (WC); Arbusto Cerrado (SC); e Cerrado pastagem (CG) (SILVA et al., 2011).

Tabela 4 – Comparativo dos algoritmos estudados em T5

Algoritmo	ANN	MV	SVM
Acurácia	87,14%	83,79%	71,88%

3.2.3.2 Aprendizagem híbrida

T6 é um artigo chinês de 2009 cujo principal resultado obtido é que a rede neural considerada nele fornece um efeito satisfatório para a classificação de imagens multiespectrais agrícolas, e isso significa que esta arquitetura de rede neural pode ser considerada uma boa alternativa ao método Bayesiano clássico, especialmente no processamento de dados hiperespectrais em que várias centenas de bandas espectrais devem ser consideradas em conjunto. As redes Kohonen (SOFM e HLVQ) foram melhores que as gaussianas. Não separa as lavouras em si, mas sim a água, a área úmida e as classes “agrícolas” e contém como melhor resultado HLVQ (WANG et al., 2009).

3.2.3.3 Redes Neurais Convolucionais

T1 é um artigo brasileiro recente (outubro de 2017) que utiliza a classificação de safra de café por sensoriamento remoto. Tem um *dataset* que contém imagens de sensoriamento do *Landsat*. Um fator que julgam ser impactante para a diminuição da porcentagem de acurácia foi medir reflectância de safras de café por causa do solo heterogêneo e espaçado. Propõem uma abordagem com outro tipo de safra, e levantam a hipótese de que seria mais bem sucedida. Propõe como trabalho futuro aplicar a abordagem proposta em outras aplicações. Também propõe analisar janelas de contexto maiores; investigar mais estratégias de fusão multi-escala; desenvolver uma estratégia para executar o ajuste fino; e para resolver o problema de formação de conjuntos de dados desequilibrados, atingindo 88,8% de acurácia (BAETA et al., 2017).

Em T2, com uma técnica de treino utilizando polígonos de imagens como dados de entrada para uma rede neural convolucional, atingiram uma acurácia geral de 96.42%. Esta

acurácia é a maior de todas as pesquisas encontradas nesta revisão. Utilizam a classificação de culturas de amendoim, com uma técnica binária com saídas como amendoim e não amendoim. Encorajam estudos sobre classificação multiclasse, como a classificação de mais de um tipo de cultura (ZHOU; LI, 2017).

3.2.4 Considerações Finais da Revisão Sistemática de Literatura

As publicações demonstram que nos últimos anos as redes neurais artificiais tem ganhado mais aplicabilidade e tem avançado no quadro de classificação de lavouras com a utilização de dados de sensoriamento remoto.

Percebe-se que os resultados com maior porcentagem de acurácia, são de estudos mais recentes(2017) com a utilização de redes neurais convolucionais, que é uma técnica criada recentemente.

Como trabalhos futuros, propõe-se aqui a criação de um sistema em que utiliza a recente tecnologia de classificação, que é uma subárea das redes neurais artificiais, que são as redes neurais convolucionais.

4 Proposta de Sistema de Classificação de Lavouras


4.1 Extração de Dados

Uma das coisas mais importantes para o paradigma de aprendizado de máquinas profundas é o poder de processamento de dados (FANG et al., 2009). Johnson e Iizuka (2016) demonstram uma abordagem em que juntam dados de mapas rotulados fornecidos por alguma plataforma de dados geospaciais com imagens de sensoriamento remoto, sobretudo o satélite *Landsat*, pode ser uma boa abordagem para classificação de solo. Em seu estudo, eles combinaram um conjunto de dados que foi derivado de dados geospaciais de duas fontes:

1. Imagens de satélite da série temporal *Landsat* dos anos 2014-2015.
2. Polígonos georreferenciados de *crowdsourcing* com rótulos de cobertura de terra obtidos do *OpenStreetMap*.

Os polígonos de *crowdsourcing* cobrem apenas uma pequena parte da área da imagem e são usados para extrair dados de treinamento da imagem para classificar o restante da imagem.

Figura 18 – Polígonos sendo formados para rotulação de áreas urbanas



Fonte: (JOHNSON; IIZUKA, 2016)

Uma vez provado que é possível a rotulação de áreas com auxílio de uma ferramenta, foi necessário algum dado que tivesse layers do objeto a ser estudado, as lavouras,

da mesma maneira que Johnson e Iikuza (2016) encontraram dados que rotulavam áreas rurais e áreas urbanas. Após pesquisas por alguma plataforma que tivesse dados abertos sobre lavouras classificadas em alguma região e em determinado período, foi encontrado o *Cropland Data Layer*, que fornecerá os dados rotulados de lavouras para os valores encontrados das imagens de sensoriamento fornecidos pelos satélites.

O *Cropland Data Layer (CDL)* foi criada pelo USDA (*United States Department of Agriculture*), Serviço Nacional de Estatísticas Agrícolas, pela Divisão de Pesquisa e Desenvolvimento, Seção de Informações Geoespaciais, Seção de Pesquisa de Análise Espacial. Os dados mais atuais estão disponíveis gratuitamente para download junto com metadados extensivos. O objetivo do CDL é usar imagens de satélite para fornecer estimativas de área cultivada ao Conselho de Estatística Agrícola para as principais commodities e para produzir produtos de saída georreferenciados categorizados, específicos para culturas.

As *layers* que contém os dados sobre refletância serão obtidas pelas imagens de sensoriamento remoto do satélite *Landsat-8*, as bandas de resolução de 30x30m, mesmo sabendo que as principais para classificação de lavouras são as 4, 5 e 6. Isso se deve à testes, para averiguar o impacto de outras bandas que não sejam só essas para a identificação da assinatura espectral de diversas culturas (SMITH, 2017).

O motivo da escolha do *Landsat-8* é o fácil acesso aos dados nas plataformas como o *Earth Explorer* e pelo tamanho de suas imagens abrangerem dentro de uma única folha a região a ser estudada que será detalhada nos próximos tópicos. Não se descarta a possibilidade de utilizar dados de outros satélites e suas bandas caso demonstrem ser impactantes para o êxito da classificação das lavouras.

4.2 Cruzamento dos Dados

Apenas os dados advindos do sensoriamento remoto, fornecido pelo *Landsat-8* por si só não são suficientes para a classificação, pois não garantem com muita precisão quais colheitas estão sendo mostradas. Também só os dados da camada rotulada fornecida pelo CDL não é suficiente para a classificação, pois ela não contém as frequências captadas pelos sensores que contém as assinaturas espectrais das lavouras, garantindo a identidade única das lavouras.

É necessário então o cruzamento de tais dados, onde a mesma área delimitada representada pela imagem do CDL, esteja contemplada nos dados das diferentes imagens de frequência dados pelos sensor do *Landsat-8*.


Para isso, utilizou-se a ferramenta *ENVI*, que em sua versão *5.0.3*, que permite que a partir de uma imagem com coordenadas geográficas, no caso, a imagem com extensão TIFF baixada pelo CDL, junte com os dados de diversos sensores da mesma área de

localização geográfica.

O *download* dos dados serão obtidos através do *site Earth Explorer*, por permitir o *download* de diversas imagens, de diversos satélites em períodos diferentes de forma gratuita. Tais dados podem ser acessados pelo próprio *site*. Ele fornece dados através de filtros de buscas como tempo da captação das imagens, cobertura de nuvens, entre outros.


Toda a parte de cruzamento de dados e recorte dos polígonos em multicamadas foi realizada com auxílio do *ENVI*.

Figura 19 – *CDL*: Imagem da cidade de Franklin, Iowa em Janeiro de 2018



Fonte: Os próprios autores.

Figura 20 – Imagem do sensor *landsat-8* (Externa) com imagem obtida pelo CDL (Interna)



Fonte: Os próprios autores.

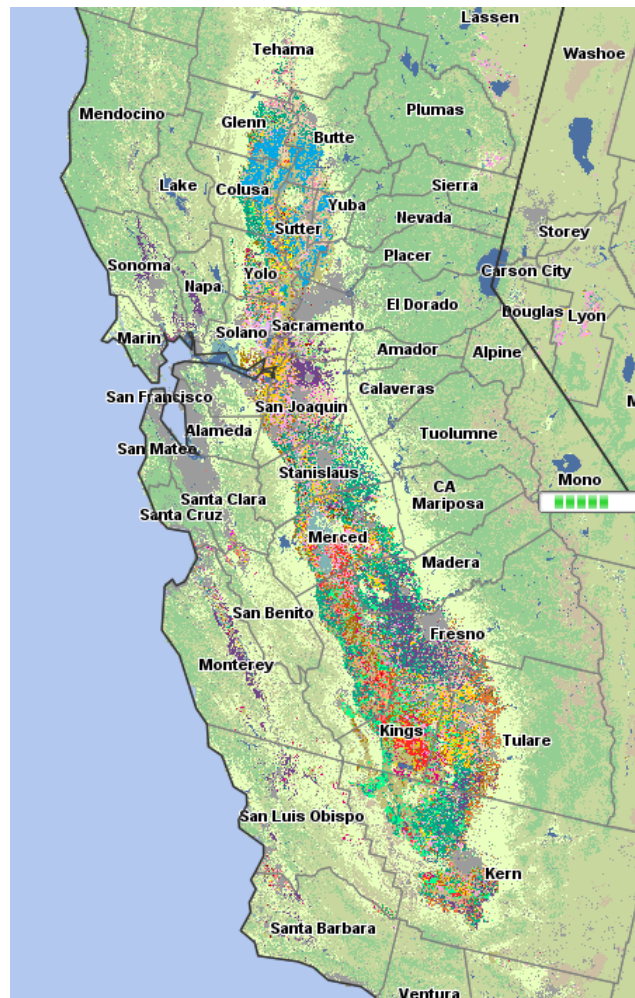
4.3 Delimitação da área de estudo

A área delimitada para a aplicação do estudo foi os Estados Unidos da América continental, uma vez que é a região contemplada pelo sistema do CDL pois é ela que fornece as lavouras rotuladas, com região e tempo especificados.

Dentro dos EUA continental, as regiões escolhidas para o treinamento da CNN foram os estados da Califórnia, Flórida, Louisiana e Illinois. As regiões foram escolhidas

por suas características climáticas favorecerem as lavouras estudadas neste estudo. A região da Califórnia se difere pela considerável variedade de lavouras, abrangendo colheitas que também são encontradas em outras regiões do país, como o milho e a soja, encontradas principalmente na região chamada *Grain Belt* (cinturão dos grãos) que se encontra na região centro-oeste do país, motivo da escolha do estado Illinois. A região da Flórida foi escolhida por ser a única região do país a plantar a lavoura de Cana-de-açúcar e por possuir uma enorme extensão de lavoura de Laranja. A região de Louisiana foi escolhida por possuir bastantes regiões de Algodão, Arroz e Soja.

Figura 21 – Região da Califórnia que será usada para treino/validação



Fonte: Os próprios autores.

Mesmo a área de estudo sendo essa região delimitada do interior da Califórnia, caso haja a necessidade do reforço de treino da rede com novas entradas, poderão ser coletados dados de outras regiões do país, desde que mapeados pelo CDL com data e localização precisas.

As lavouras escolhidas como objeto de estudo inicialmente são:

- Milho

- Soja
- Laranja
- Cana-de-açúcar


O motivo dessas escolhas se deu pela grande quantidade de tais amostras na região escolhida. Posteriormente, com o sucesso dos experimentos realizados ao longo da pesquisa, foram incluídas novas lavouras:

- Algodão
- Arroz
- Uva
- Outros
 - Água
 - Área urbana
 - Floresta
 - Gramado
 - Matagal
 - Solo exposto

4.4 Treinamento da Rede

O treinamento da rede se dará com os polígonos de multicamadas espectrais. A primeira com os rótulos do CDL e as demais camadas com as imagens espectrais captados pelos sensores. Da mesma maneira que Johnson e Iizuka (2016) utilizaram em seu estudo para classificar zonas agrícolas e zonas de de plantio, os polígonos serão a entrada da rede.

Figura 22 – Camadas do CDL e camadas do sensor do *Landsat-8* que será usado para o treino da CNN



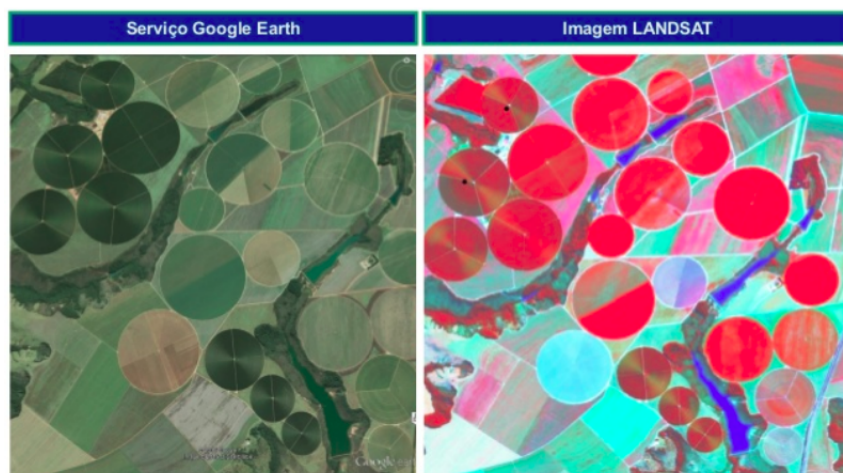
Fonte: Os próprios autores.

4.5 Saída da Rede

Como resposta da rede, o usuário ao entrar com os dados multicamadas na CNN, a rede deverá mostrar a predição da classificação por ela aprendida. Terá como saída n neurônios, de acordo com a quantidade de classes treinadas para a rede do tipo *fuzzy*, tendo no intervalo de 0-1 a precisão da lavoura ser daquela classe e a classificação final de tal polígono.

A API do *Google Maps* foi escolhida por ser de fácil integração com a linguagem e *frameworks* escolhidos e por possuir funcionalidades interessantes à visualização das regiões estudadas, como pode ser vista na Figura 23.

Figura 23 – Exemplo de Saída do Sistema



Fonte: Os próprios autores.

4.6 Análise dos Resultados

Para saber o comportamento das saídas da rede, ou seja, se suas predições são de fato corretas, será adotada a matriz de confusão ilustrada na Figura 24 para entender quais os pontos de acerto e de falhas da rede. Por exemplo, se a rede tem aprendido pouco uma das classes, tendo menor valor na diagonal principal daquela classe, um dos primeiros passos a ser tomado pode ser a coleta de mais amostras daquela classe para posterior treino da rede.

O eixo vertical, representa o que a classe realmente é, e em seu eixo horizontal o que o modelo da CNN, depois de treinado e testado, prediz que aquele objeto é. Quanto mais concentrado os valores em sua diagonal principal, maior o acerto e êxito da rede neural. A partir de então, pode-se perceber e estudar os *deficits* de aprendizado da rede e trabalhar possíveis melhorias.

Para melhorar a visualização dos erros de forma prática, se adotou cores em gradiente demonstrando a intensidade das células de acordo com o valor máximo no arranjo definido.

Figura 24 – Exemplo de matriz de classificação



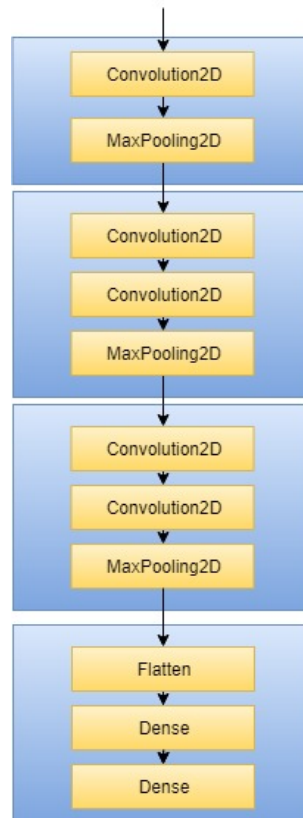
Fonte: Os próprios autores.

As principais métricas de performance serão obtidas e analisadas neste trabalho, como acurácia, precisão e *recall*, entretanto será dado maior peso para a métrica *F1 Score*, por ser um indicador melhor sobre a classificação envolvendo dados desbalanceados.

5 Resultados

5.1 Arquitetura

Figura 25 – Arquitetura da rede neural do projeto Lavrador



Fonte: Os próprios autores.

Como pode ser observado na Figura 25, a arquitetura da CNN é uma adaptação da *VGGNet*. Conterá 4 camadas conectadas que passará desde o começo, com a camada de alimentação da rede, até a camada de saída, onde haverá a predição da lavoura.

5.2 Desenvolvimento

Como pode ser visto no Apêndice D, o método de construção requer quatro parâmetros:

- *width* : a dimensão da largura da imagem.
- *height* : a dimensão da altura da imagem.

- *depth* : a profundidade da imagem - também conhecida como o número de canais, no caso 7, que é a quantidade de bandas das imagens multiespectrais.
- *classes* : o número de classes em nosso conjunto de dados (que afetará a última camada do nosso modelo).

```

model.add(Conv2D(32, (3, 3), padding="same", input_shape=inputShape))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(MaxPooling2D(pool_size=(3, 3)))
model.add(Dropout(0.25))

```

Entre as linhas 27 à 33, o bloco de código abaixo, começamos a construir a primeira camada do modelo, que indica o primeiro bloco da Figura 25. A camada de convolução tem 32 filtros com uma janela convolucional de 3x3. Está sendo utilizada a função de ativação RELU seguida de uma normalização de *batch*. Utilizou-se o *dropout*, que realiza desconexões aleatórias durante os lotes de treinamento, diminuindo a redundância no modelo. Nenhum nó único na camada é responsável por prever determinada classe, objeto, borda ou canto.

```

model.add(Conv2D(64, (3, 3), padding="same"))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(Conv2D(64, (3, 3), padding="same"))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))

```

A junção das camadas de convolução e de ativação, antes de reduzir as dimensões espaciais do volume, melhora o aprendizado dos conjuntos. Nesta segunda camada, aumenta-se o tamanho do filtro de 32 para 64. Quanto mais é aprofundado na rede, menores devem ser as dimensões espaciais do volume e mais filtros aprendidos. O tamanho de *pool* de 3 x 3 para 2 x 2 garante que não sejam reduzidas as dimensões rapidamente. Logo em seguida há uma etapa de *dropout*.

```

model.add(Conv2D(128, (3, 3), padding="same"))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(Conv2D(128, (3, 3), padding="same"))

```

```
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))
```

Nesta terceira camada foram aumentados os números de filtros para 128 e o *dropout* de 25% das conexões para reduzir o *overfitting*.

```
model.add(Flatten())
model.add(Dense(1024))
model.add(Activation("relu"))
model.add(BatchNormalization())
model.add(Dropout(0.5))

model.add(Dense(classes))
model.add(Activation("softmax"))
```

```
return model
```

A *fully connected layer* foi conectada à camada densa com ativação *ReLU* e normalização de *batch*. A última camada de ativação é a *Softmax*, que trará as probabilidades previstas para cada rótulo de classe como visto na Figura 26.

Figura 26 – Processo de predição de sistemas multiclasse - Sistema Lavrador

```
File: sugarcane40.tif
orange: 43.82%
soybean: 0.06%
sugarcane: 56.12%

Classified:
sugarcane: 56.12%
```

Fonte: Os próprios autores.

5.3 Experimentos

Afim de examinar com maior detalhe a performance do classificador, alguns experimentos foram definidos. Os experimentos irão avaliar o impacto de diferentes atributos do modelo o que possibilitará um maior entendimento do problema e possivelmente a determinação de melhores parâmetros. Será dado um peso maior ao parâmetro de F1 score pois os dados estão desbalanceados e tanto a precisão e *recall* ajudam a entender melhor o funcionamento da rede.

5.3.1 Experimento 1

Neste primeiro experimento, foi testado o escopo inicial do projeto. Foram 4 lavouras classificadas:

- Cana-de-açúcar
- Laranja
- Milho
- Soja

Foram coletados 148 polígonos na plataforma ENVI, utilizando a metodologia do Apêndice C. Como a entrada de uma rede neural tem parâmetros fixos, foi estabelecida como entrada polígonos de 55x55 pixels. Como foi explicado anteriormente, de acordo com resolução espacial do landsat, cada pixel representa uma área de 30x30m. Cada polígono então representa uma área de 1650x1650m, ou seja, 1.65 km².

Tabela 5 – Lavouras e quantidade de amostras utilizadas no Experimento 1

Lavoura	Quantidade de amostras
Cana-de-açúcar	40
Laranja	48
Milho	21
Soja	40
Total	148

As amostras foram treinadas na rede do anexo X. Foi utilizada uma proporção de 70% das amostras para treino e 30% das amostras para teste. A matriz de confusão, assim como as métricas analisadas são encontradas abaixo:



Figura 27 – Matriz de confusão do Experimento 1

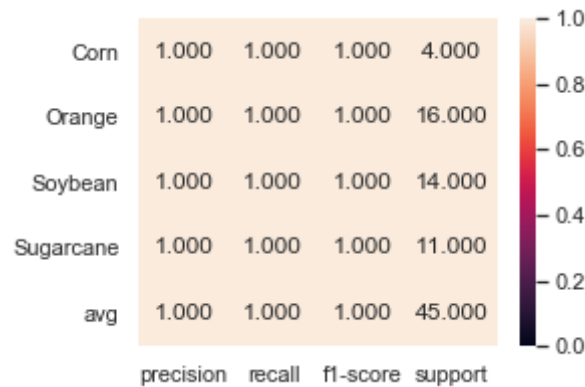


Figura 28 – Métricas do Experimento 1

De acordo com as métricas analisadas, o modelo atingiu o resultado perfeito de acertar corretamente todas as lavouras, sem errar em nenhuma classe, levando as métricas de acurácia, precisão, recall e F1 score a atingirem 100%. A rede de saiu bem mesmo com a baixa quantidade de amostras, um dos motivos de ter sido adotada a rede VGGNet, e demonstrou ser boa em classificação de amostras multivaloradas, ou seja, mais de 2 classes. Foi decidida a realização de um novo experimento contendo mais 3 lavouras, para conhecer o comportamento da rede na classificação de 7 lavouras diferentes.

5.3.2 Experimento 2

Neste segundo experimento, foram aproveitadas as amostras do experimento anterior e polígonos de outras lavouras diferentes do escopo do experimento anterior. Foram 3 novas lavouras classificadas:

- Algodão
- Arroz
- Uva


Foram coletados 191 polígonos na plataforma ENVI, utilizando a metodologia do Apêndice X. Continuou-se a usar polígonos 55x55 pixels.

Tabela 6 – Lavouras e quantidade de amostras utilizadas no Experimento 2

Lavoura	Quantidade de amostras
Algodão	18
Arroz	8
Cana-de-açúcar	40
Laranja	48
Milho	21
Soja	40
Uva	16
Total	191

Optou-se por continuar com a mesma proporção treino/teste. A matriz de confusão, assim como as métricas analisadas são encontradas abaixo:


Figura 29 – Matriz de confusão do Experimento 2



Fonte: Os próprios autores.

De acordo com as métricas analisadas, o modelo atingiu o resultado perfeito de acertar corretamente todas as lavouras, sem errar em nenhuma classe, como visto na Figura 29, levando as métricas de acurácia, precisão, *recall* e *F1* score a atingirem 100%, como visto na Figura 30. Mesmo com uma quantidade menor de amostras das novas lavouras, continuou-se tendo bons resultados.

Figura 30 – Métricas do Experimento 2



Fonte: Os próprios autores.

Entretanto, neste tipo de abordagem, não importa qual seja a assinatura espectral predominante no polígono, por exemplo, uma cidade. A cidade será classificada dentre as classes treinadas na rede, mesmo não contendo uma classe própria para a cidade.


Foi decidida a realização de um novo experimento contendo mais uma classe, uma nova categoria para classificar o que não são estas lavouras chamada de “Outros”. Os objetos contidos dentro da categoria “Outros” foi escolhida por serem objetos que poderiam confundir. A categoria “Outros” contém os seguintes objetos:

- Água
- Área urbana
- Floresta
- Gramado
- Matagal
- Solo exposto

5.3.3 Experimento 3

Neste experimento final, foram aproveitadas as amostras do experimento anterior adicionados os polígonos da classe “Outros”. Neste experimento foi decidido diminuir a dimensão de cada polígono que anteriormente eram de 55×55 *pixels* e agora passam a ser de 15×15 *pixels*. Esta decisão foi tomada depois de se observar como os polígonos eram mostrados visualmente após a classificação no sistema Lavrador.

Figura 31 – Visualização dos polígonos selecionados no experimento 2



Fonte: Os próprios autores.

Foram coletados 3.152 polígonos na plataforma ENVI, utilizando a metodologia do Apêndice C e também um código onde se cortava os polígonos utilizados nos outros experimentos. Tal código se encontra no Apêndice D.

Tabela 7 – Lavouras e quantidade de amostras utilizadas no Experimento 3

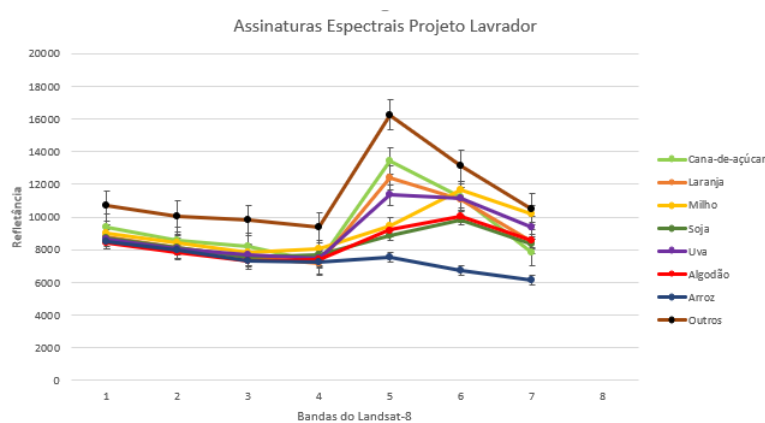
Lavoura	Quantidade de amostras
Algodão	161
Arroz	129
Cana-de-açúcar	242
Laranja	251
Milho	189
Outros	1664
Soja	247
Uva	269
Total	3152

Tabela 8 – Objetos classificados dentro da categoria Outros

Lavoura	Quantidade de amostras
Água	144
Área urbana	1002
Floresta	50
Gramado	43
Matagal	200
Solo exposto	225
Total	1664

Como pode ser observado na Figura 32, as assinaturas espectrais dos polígonos utilizados nestes experimentos possuem distinção, pois interagem com a luz solar de maneiras distintas. Percebe-se que as lavouras propostas a serem classificadas neste trabalho se assemelham, pois todas são vegetais, e possuem assinatura espectral semelhantes (FONTANA, 2011).

Figura 32 – Média das Assinaturas Espectrais dos Polígonos analisados no Experimento 3



Fonte: Os próprios autores.

As bandas 4, 5 e 6 são bandas que permitem melhor análise vegetativa e de fato, das bandas 4 à 7, demonstram uma grande variação dos valores espectrais. (SMITH, 2017). Um fato interessante é assinatura espectral das lavouras de arroz, que muito se assemelham à assinatura espectral da água, uma vez que as lavouras de arroz são lavouras alagadas, como exemplificado na Figura 33.

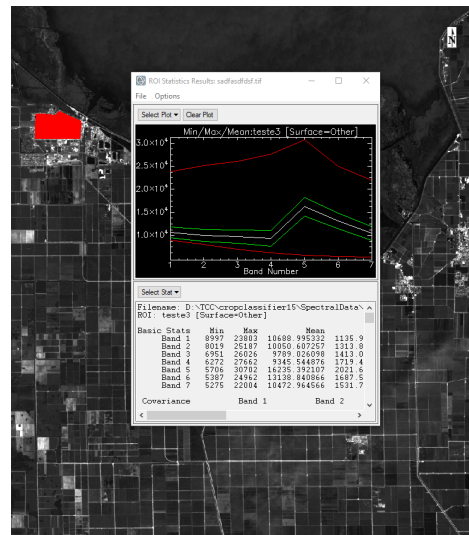
Figura 33 – Exemplo de lavoura de Arroz



Fonte: (MOHANTY, 2015)

A assinatura espectral da categoria Outros possui a maior margem de erro, uma vez que diversas categorias foram classificadas como uma só. Sua assinatura espectral pode ser melhor compreendida na Figura 34.

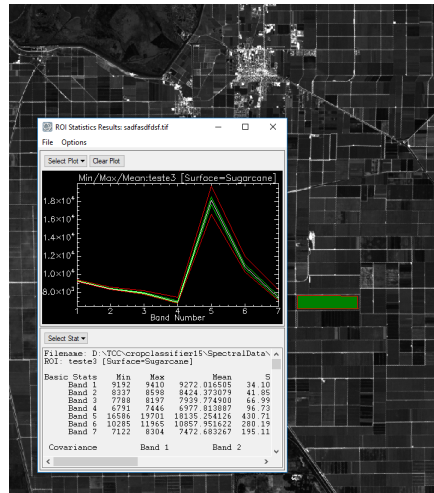
Figura 34 – Assinatura espectral dos polígonos da categoria Outros



Fonte: Os próprios autores.

Os polígonos das lavouras por sua vez possuem menor margem de erro, uma vez que existe mais homogeneidade das assinaturas espectrais dos pixels, como pode ser exemplificado na Figura 35.

Figura 35 – Assinatura espectral dos polígonos de Cana-de-açúcar

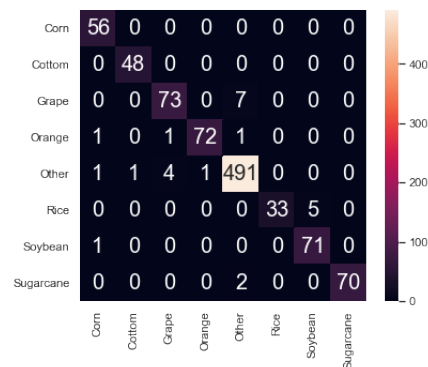


Fonte: Os próprios autores.

5.3.3.1 Dados obtidos

Foram utilizados os mesmos 939 polígonos para os testes do Experimento 3, em todos os modelos, e 2.213 polígonos para treino. Mantendo uma proporção de aproximadamente 30% para testes e 70% para treino.

Figura 36 – Matriz de confusão do Experimento 3



Fonte: Os próprios autores.

A Figura 36 concentra a maior parte de seus valores na diagonal principal, o que indica que a relação predição x realidade, ou seja, o que a rede prediz e o que de fato a classe de cada polígono é, tem bons resultados. Apenas a matriz de confusão não é suficiente para uma análise quantitativa, entretando, os dados obtidos por ela nos ajudam a conseguir as métricas abordadas na Figura 37

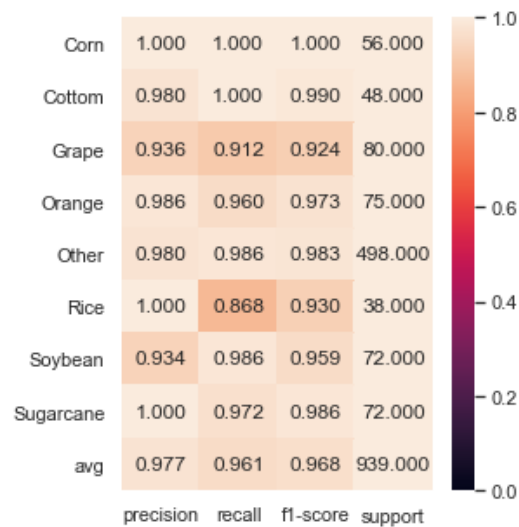


Figura 37 – Métricas do Experimento 3

Fonte: Os próprios autores.

Os dados apontam que a média da precisão é 97.7%, a média de *recall* é 96.1% e *F1-Score* é 96.8% e 97.57% de acurácia. Esses resultados são superiores à artigos similares ao deste trabalho como os de BAETA et al.(2017) que alcançaram 88.8% de acurácia, e também a pesquisa de ZHOU (2017) que atingiu 96.42% de acurácia.

Pela natureza dos dados deste trabalho serem desbalanceados, ou seja, existe uma grande desproporcionalidade no número de polígonos por classe, optou-se por usar a métrica *F1-Score* como uma boa representante da *performance* dos sistemas, sendo que a comparação com os 2 artigos citados posteriormente, por fornecerem a acurácia, não podem ser justamente comparados (POWERS, 2007).

Percebe-se que a rede tem uma maior facilidade de acertar a classe Milho. Todas as métricas estão no seu valor máximo, ou seja, todas as vezes que um polígono de milho foi classificado, realmente era um polígono de milho, sendo este resultado perfeito para a amostra do experimento.

Sobre o Algodão, o *recall* é 100.0%, isso conseguimos ver graficamente na matriz de confusão, uma vez que na horizontal do algodão, não houveram falsos positivos, ou seja, sempre que era algodão o sistema acertou. Entretanto, em sua vertical aponta um verdadeiro negativo, ou seja, quando era um polígono da classe Outro, ele apontou como algodão, abaixando sua taxa de precisão.

Os polígonos das Uvas tiveram o pior *F1-Score*, devido ao elevado número de falsos negativos e verdadeiros negativos em relação às demais classes. Nota-se que o maior problema do sistema é confundir os polígonos de uvas com a categoria Outros (7 casos), assim como o os polígonos da categoria de Outros serem confundidos com a categoria da uva (4 casos). Analisando o relevo de plantação de uvas assim como alguns casos da

categoria de Outros, uma vez que vários tipos de objetos foram classificados como Outros, pode-se tentar entender o motivo de confusão da rede.



Figura 38 – Plantação de uva

Fonte: (SWINDELL, 2016)


Como mostrado na Figura 38, existe certo distanciamento de uma parreira à outra onde pode haver grama ou solo exposto, categorias com assinaturas espectrais classificadas na categoria Outros. Esses espaçamentos podem estar confundindo a rede, uma que a assinatura espectral dos polígonos não é tão homogênea como o de outras culturas. Estudos sobre ruídos causados pela heterogeneidade do solo são fortemente indicados pelos autores deste trabalho.

A classe de Laranja obteve bons resultados neste modelo. Obteve 3 falsos positivos e 1 verdadeiro negativo o que fez a precisão ser maior do que o *recall*. Entretanto o modelo de *Machine Learning ExtraTrees* obteve melhores resultados, como será discutido no tópico 5.3.5.

A classe Outros obteve bons indicadores, com média da precisão é 98.%, a média de *recall* é 98.6% e *F1-Score* é 98.3%.

A classe Arroz obteve o pior *recall*, ou seja, houveram demasiados polígonos classificados como outra classe. No caso a classe onde houve essa dúvida é a de Soja. Um dos fatores que levam a entender essa confusão é a proximidade onde esses polígonos foram coletados. Como mostrado na Figura 39, as regiões de plantio de arroz são muito mescladas as de soja.

Figura 39 – Layer de soja (em verde) e arroz (em azul) utilizado para a coleta de polígonos



Fonte: Os próprios autores.

O oposto, soja se confundir com arroz, não acontece neste modelo devido aos polígonos de soja terem sido coletados em uma região com mais homogeneidade de soja.

Não se descarta a hipótese destes polígonos julgados como soja, serem de fato polígonos de soja, devido a algum erro de mapeamento ou coleta de polígonos. Soja no geral tiveram boas métricas em relação aos outros classificadores.


A classe Cana-de-açúcar obteve excelente precisão, entretanto como tiveram polígonos classificados como Outros (2 casos), abaixou seu recall. Entretanto seu *F1-Score* é um dos mais altos entre os outros classificadores.

5.3.4 Outros classificadores

Afim de averiguar se a CNN proposta pelo projeto Lavrador contém, de fato, boa *performance*, foram testados os mesmos polígonos de treino e teste para comparar com diversos outros classificadores.

5.3.4.1 Support Vector Machine - SVM

Figura 40 – Matriz de confusão e dados das métricas do classificador SVC



Fonte: Os próprios autores.


Visualmente nota-se na parte esquerda da Figura 40 o baixo desempenho do classificador SVM em trabalhar com dados de natureza espectrais. Como a maior parte de seus valores fora da diagonal principal, percebe-se a tendência do classificador em classificar os polígonos em Outros.

Suas métricas reforçam essa hipótese, como mostrado na parte direita da Figura 40. Ele têm acurácia média de 53.78% uma métrica não muito confiável com dados desbalanceados, e esse exemplo ilustra bem o porquê. Apesar de ter 100% de precisão na classe milho e 100% de recall. A média de suas métricas são muito baixas, o que demonstra a importância de métricas para dados desbalanceados.

5.3.4.2 Random Forest

Na parte esquerda da Figura 41 demonstra também uma boa *performance*. Seus maiores problemas são com a classes Uva, Arroz e Outros, que tiveram um número considerável de falsos positivos e falsos negativos.

Figura 41 – Matriz de confusão e dados das métricas do classificador Random Forest



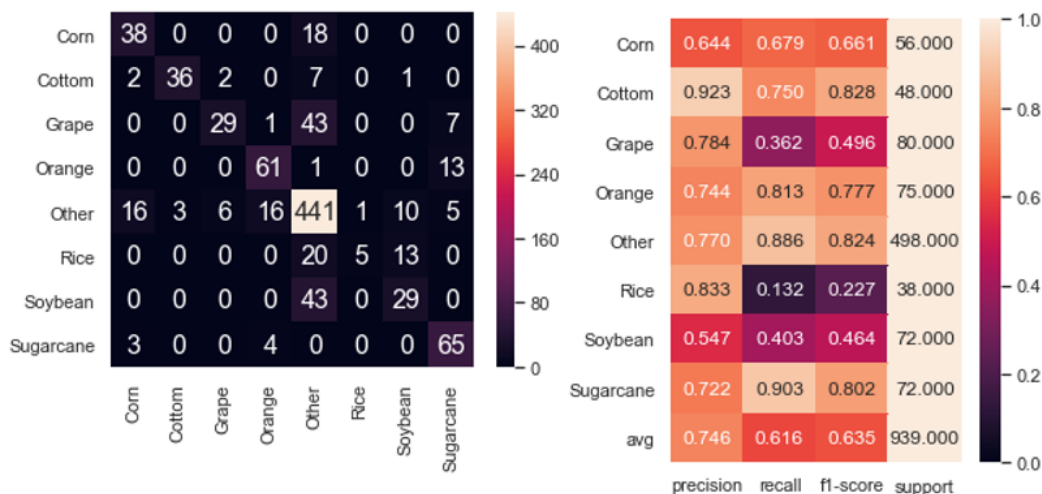
Fonte: Os próprios autores.

As métricas, que podem ser vistas na parte direita da Figura 41, demonstrou dados que comprovam os *deficits* na classe Uva e Arroz.

5.3.4.3 Regressão Logística

A parte esquerda da Figura 42 demonstra valores menos concentradas na diagonal principal, sendo inferior ao da CNN estudada neste trabalho. Em todas as classes possuem elevado número de falsos positivos e falsos negativos.

Figura 42 – Matriz de confusão e dados das métricas do classificador Logistic

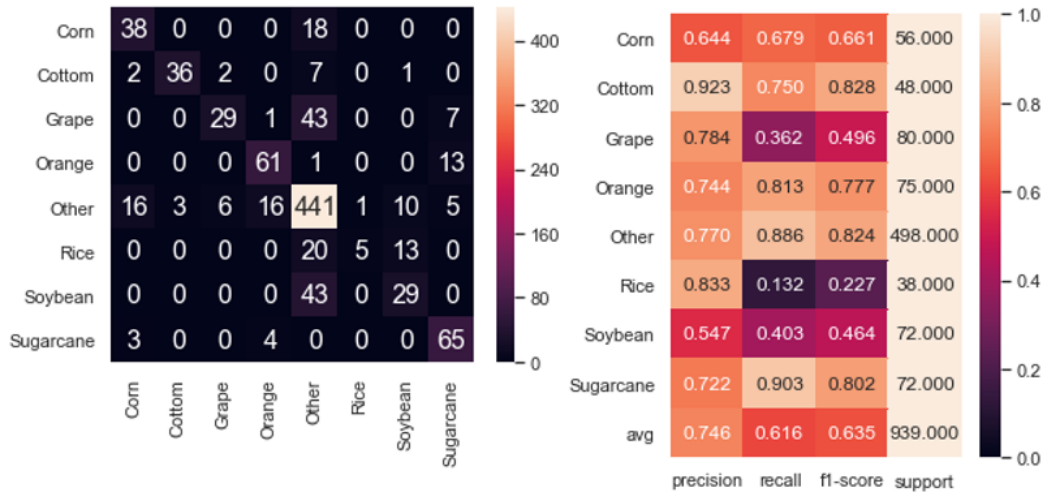


Fonte: Os próprios autores.

A parte direita da Figura 42 demonstra valores baixos de *recall* e conseqüentemente de *F1-Score*. As classes com maior problema predição são Uva, Arroz e Soja, os valores com maior falsos negativos de como visto na matriz de confusão.

5.3.4.4 K Neighbors

Figura 43 – Matriz de confusão e dados das métricas do classificador K Neighbors

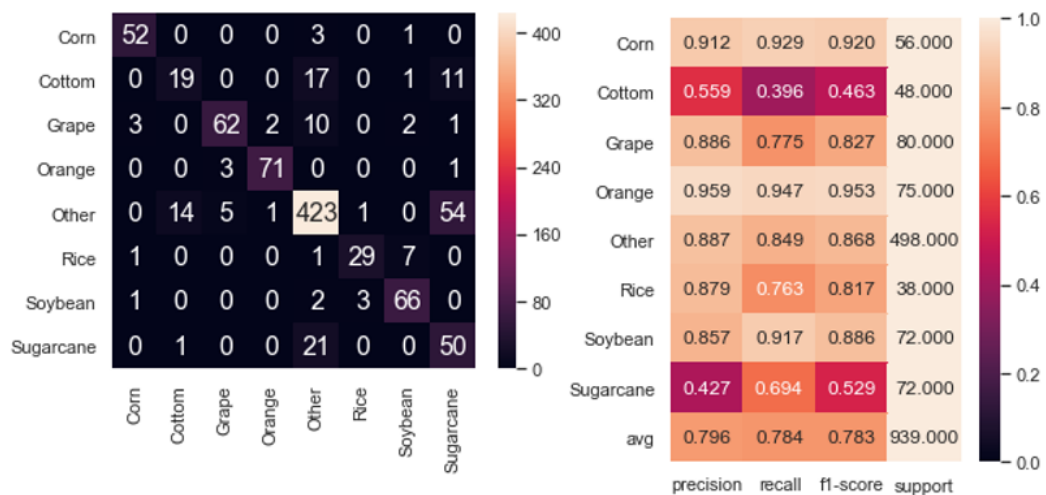


Fonte: Os próprios autores.

Como pode ser visto na Figura 43, os valores estão mais concentrados na diagonal principal, o que é um bom indicativo. Entretanto as classes Uva e Arroz possuem, proporcionalmente, muitos falsos positivos.

5.3.4.5 Gradient Boosting

Figura 44 – Matriz de confusão e dados das métricas do classificador Gradient Boosting



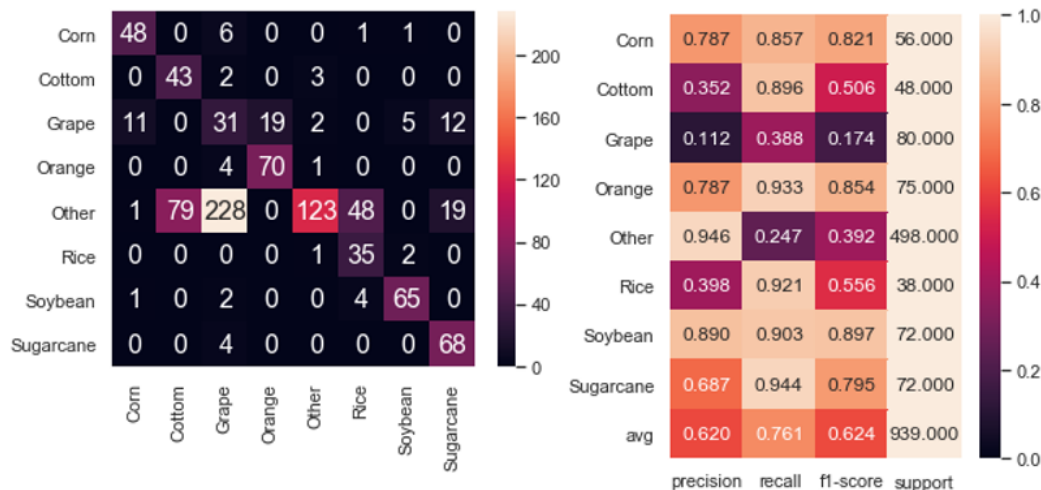
Fonte: Os próprios autores.

A parte esquerda da Figura 44 possui dados mais concentrados na diagonal principal. O classificador *Gradient Boosting* classificou algumas classes como Algodão e Cana-de-açúcar com elevado número de falso positivos e falsos negativos, o que diminuiu as métricas de precisão, *recall* e *F1-Score*, como visto na parte esquerda da Figura 44

5.3.4.6 Gaussiano

Esse classificador possuiu o pior desempenho com a classe Outros, confundindo-a bastante com a classe Uva, Algodão, Arroz e Cana-de-açúcar, como demonstrado na parte esquerda da Figura 45.

Figura 45 – Matriz de confusão e dados das métricas do classificador Gaussiano



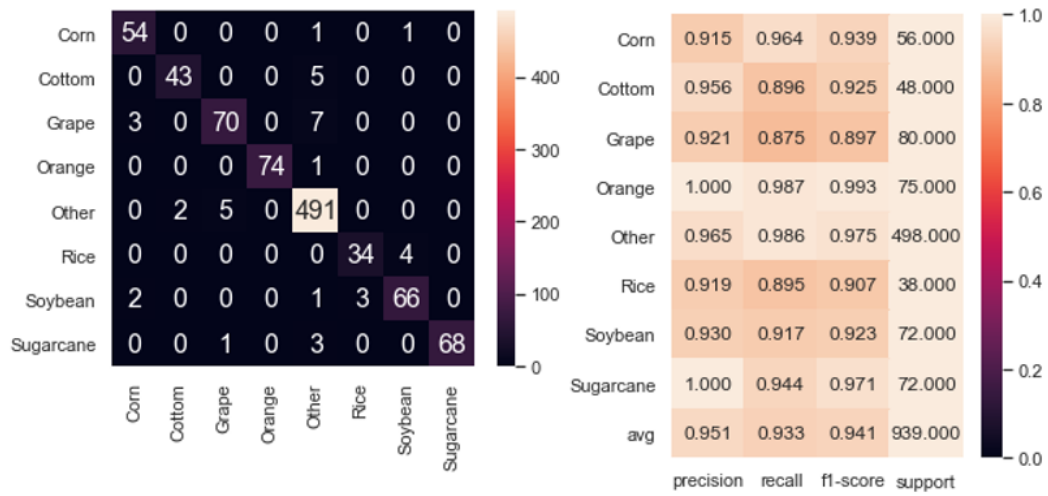
Fonte: Os próprios autores.

Na parte direita da Figura 45 teve um elevado número de falsos negativos na classe Outros, o que pode ser comprovado na métrica *recall*. O *recall* da classe uva também foi baixo, assim como sua taxa de precisão. A taxa de precisão das classes Algodão, Uva, Arroz e Cana-de-açúcar obtiveram baixas taxas de precisão e consequentemente, de *F1-Score*.

5.3.5 Extra Trees

A matriz de confusão do classificador *Extra Trees*, baseado em *Ensemble*, possuiu os melhores resultados, logo após a CNN, como pode ser visto na parte esquerda da Figura 46. As classes de Uva e Arroz tiveram proporcionalmente um número maior de falsos negativos, mas no geral, a matriz contém os dados concentrados na diagonal principal.

Figura 46 – Matriz de confusão e dados das métricas do classificador Extra Trees




Fonte: Os próprios autores.

Como citado anteriormente, obtive métricas superiores ao do lavrador, provando que classificadores, mesmo os que não utilizam *Deep Learning*, conseguem bons resultados na classificação de polígonos. Obteve as melhores métricas para classificação de Laranja e obtive boas métricas no geral.

5.3.5.1 Árvore de Decisão

Figura 47 – Matriz de confusão e dados das métricas do classificador Decision Tree

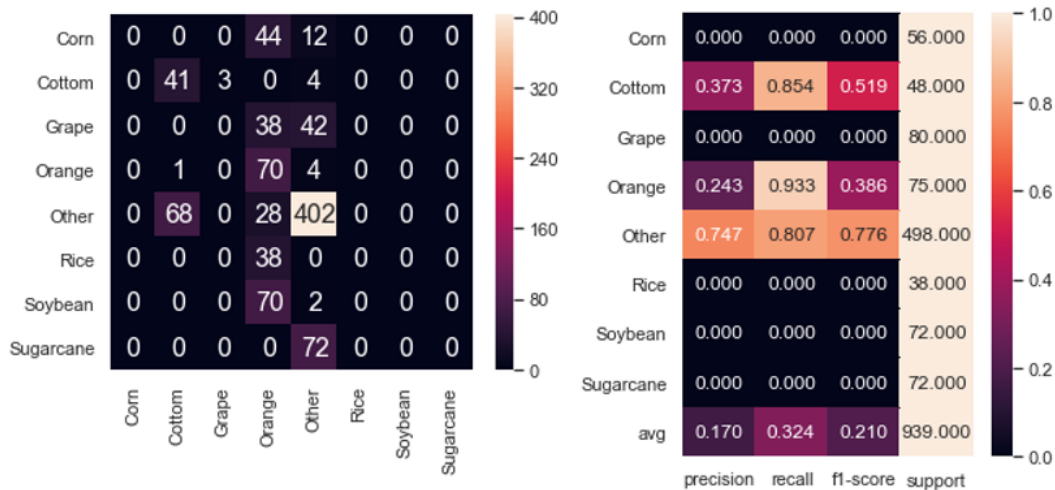


Fonte: Os próprios autores.

Como demonstrado na figura 47, este classificador possui dados concentrados na diagonal principal, o que indica uma boa *performance*. Entretanto as métricas das classes Algodão e Uva indicam a presença de falsos positivos e falsos negativos, que pode ser notado em sua matriz de confusão.

5.3.5.2 AdaBoost

Figura 48 – Matriz de confusão e dados das métricas do classificador AdaBoost



Fonte: Os próprios autores.

Como pode ser visto na Figura 48, possuem muitos dados concentrados no eixo vertical da classe Laranja, diminuindo as métricas das outras classes e aumentando o *recall* da classe Laranja. A classe Outros possui boas métricas, mesmo com os falsos negativos na classe Algodão e Laranja.

5.4 Sistema Lavrador

O sistema Lavrador consiste no código refatorado do Experimento 3, sendo que o passo-a-passo para sua correta utilização será explicado nesta sessão.

A entrada do sistema Lavrador consiste em polígonos de imagem multiespectral com as 7 bandas do *Landsat-8* de tamanho 15×15 *pixels*. O sistema, caso tenha o polígono da dimensão correta, classifica o polígono com uma das classes aprendidas pela CNN. Em casos de polígonos menores que as dimensões 15×15 *pixels*, o classificador não realiza a classificação.

Caso a imagem tenha dimensões maiores que 15×15 *pixels*, será feito recortes da imagem em polígonos de dimensão 15×15 *pixels*. A Figura 49 representa um pedaço de imagem baixada do *Landsat-8* contendo a região da Flórida, mais especificamente uma divisão de um lago, com uma cidade rodeados de plantação de Cana-de-açúcar.


Figura 49 – Imagem multiespectral da região de plantio de cana-de-açúcar da Flórida



Fonte: Os próprios autores.

A Figura 50 comprova esses dados. Uma *layer* com os rótulos dela representam esta região da Califórnia. A parte central em azul é o lago, a parte em rosa é a colheita de Cana-de-açúcar, a parte em verde-claro é uma área de vegetação que pode ser traduzida como "herbáceas de zonas úmidas" e a parte em marrom cinzento são áreas urbanas.

Figura 50 – *Layer* do *CropScape* da região de plantio de cana-de-açúcar da Flórida



Fonte: Os próprios autores.

A Figura 52 representa a parte visual da imagem predita pelo sistema Lavrador. Cada polígono foi classificado separadamente e plotado em uma API visual do *Google Maps*. Cada classe tem uma cor específica como visto na Figura 51. A opacidade dos polígonos é definido pela porcentagem da predição. Caso o polígono tenha sido classificado em uma classe com 90%, a opacidade de seu polígono será de 0.9, ou seja, quanto mais sólido a opacidade do polígono, mais certeza o sistema tem daquela classificação.


Figura 51 – Cores utilizadas no sistema Lavrador para identificação dos polígonos



Fonte: Os próprios autores.

A Figura 52 demonstra saber delimitar bem o que é a classe Outros e Cana-de-açúcar. Perceba que a parte de "herbáceas de zonas úmidas", como não foi aprendida pela rede (que contém na classe Outros as categorias: Água, Área urbana, Floresta, Gramado, Matagal, Solo exposto, mas não herbáceas de zonas úmidas) teve um desempenho ruim, classificando diversos como cana-de-açúcar por causa das assinaturas espectrais de cana-de-açúcar contida no meio dessa vegetação, como pode ser visto na Figura 50. Mesmo pequenas porções de um padrão aprendido pela CNN será acusado na classificação, e como a rede tem certeza que é um padrão de assinatura espectral de cana-de-açúcar, ela classifica o polígono inteiro como cana-de-açúcar e com alta acurácia.


Figura 52 – Polígonos classificados pelo sistema Lavrador plotado em cima da API do *Google Maps* dentro do sistema Lavrador



Fonte: Os próprios autores.

Na Figura 53 pode-se ver a mesma classificação em cima de imagens de satélite coletados pelo próprio *Google Maps*. Percebe-se com mais riqueza de detalhes informações sobre as colheitas de cana-de-açúcar neste modo.


Figura 53 – Polígonos classificados pelo sistema Lavrador plotado em cima da imagem de satélite na API do *Google Maps* dentro do sistema Lavrador



Fonte: Os próprios autores.

A funcionalidade de *Street View* permite ainda que estradas próximas às plantações sejam visualizadas de perto. A imagem desta região classificada foi baixada sendo coletada na data de 19/02/2017. Nesta região específica em 2 períodos distintos foram fotografadas as estradas desta região: em Fevereiro de 2008 e Maio de 2011. Mesmo com períodos tão diferentes, nota-se que a região nos 2 períodos possuía extensas plantações de Cana-de-açúcar como visto ao fundo a Figura 54 e também que as "herbáceas de zonas úmidas" são encontradas na região, sendo encontradas na região mais próxima das fotos registradas em períodos diferentes.

Figura 54 – Função do *Street View* do *Google Maps* dentro do sistema Lavrador



Fonte: Os próprios autores.

6 Considerações Finais

Neste trabalho foi apresentado um estudo em torno da classificação de lavouras via Redes Neurais Convolucionais, usando polígonos de caráter multiespectral fornecidos com dados do satélite Landsat-8. A compreensão de Redes Neurais Artificiais, sobretudo as convolucionais, e o funcionamento das imagens multiespectrais são necessários para a inserção de um programador no desenvolvimento de um sistema classificador como o proposto no trabalho aqui desenvolvido. Saber sobre a diferença entre as resoluções das imagens (radiométrica, espacial, temporal e espectral) e o conhecimento sobre o funcionamento das convoluções em redes neurais convolucionais foram indispensáveis e fundamentais para a conclusão desta pesquisa.

Os resultados obtidos foram de que as redes neurais convolucionais se mostraram um classificador com alta acurácia em relação aos demais classificadores de machine learning. Outros classificadores se mostraram promissores e exigem menor domínio sobre os parâmetros de seu algoritmo se aproximando bastante aos resultados obtidos com a rede neural convolucional. As Redes Neurais Convolucionais atingiram 97.57% de acurácia e 97.0% de F1 score e outros classificadores classificaram a mesma amostra de treino e teste com 94.1% de F1 score no algoritmo Extra Tree e 91.9% de F1 score no algoritmo Random Forest.

As bandas espectrais fornecidas através do satélite Landsat-8 foram dados importantes para a classificação das lavouras. Dentre as bandas utilizadas para o treino da rede, as 7 de mesma resolução espacial de 30 metros, todas demonstraram ser importantes para a classificação das lavouras, mesmo em bandas cujas as assinaturas espectrais fossem semelhantes na captação daquela determinada banda.

Nota-se a importância deste trabalho uma vez que existem diversos classificadores de dados multiespectrais, mas que entretanto não se aprofundam na classificação e diferenciação das lavouras entre si. Diversos trabalhos apresentação classificadores que rotulam vegetação em uma única categoria, ainda mais raros são trabalhos que se propõem a classificar lavouras, mas apenas 1 tipo de lavoura. O projeto Lavrador obteve êxito ao classificar 7 tipos de lavouras diferentes e ainda classificar o que não é nenhuma das lavouras aprendidas na categoria “Outros”. Sua estrutura atualmente permite ainda o aprendizado de outras lavouras, podendo posteriormente ultrapassar os 7 tipos de lavouras aprendidos até o momento.

6.1 Trabalhos Futuros

- Uma das motivações para o estudo desta área é ajudar o Brasil em seu estudo e planejamento agropecuário. A falta de dados de lavouras rotuladas para o treino de polígonos impossibilitou o estudo aplicado em cenário brasileiro neste trabalho. Um estudo sobre a predição do que foi aprendido pelo sistema Lavrador em contexto nacional ou em outros países que não os EUA é encorajado pelos autores.
- Aumentar a quantidade de classes aprendidas pelo Lavrador é uma das possibilidades que a arquitetura da rede permite. Atualmente ela conta com 7 lavouras aprendidas (Algodão, Arroz, Cana-de-açúcar, Laranja, Milho, Soja e Uva) e a categoria Outros (Solo exposto, área urbana, floresta, pasto, matagal e água). O sistema manteve o bom desempenho com o aumento gradual dos novos grupos de polígonos aprendidos e a ampliação de sua área de classificação é perfeitamente viável e encorajada. Tutoriais para a alimentação da rede podem ser encontradas nos Apêndices [A](#), [B](#) e [C](#).
- A conversão de polígonos de 55x55 *pixels* para 15x15 *pixels* foram importantes para melhor precisão da classificação do sistema Lavrador, vide Figura [31](#) e Figura [52](#). Entretanto não se exclui a possibilidade de um novo treino a partir de polígonos menores, como 5x5 *pixels* ou 7x7 *pixels* por exemplo. Tal esforço aumentaria a precisão por se tratar de áreas menores de mapeamento.
- Os 3.152 polígonos coletados pelos autores foram um número considerável em questão de esforço, entretanto, continua sendo um número muito pequeno quando se trata de classificação de imagens. Poucas imagens causam má generalização da rede em objetos não muito similares aos treinados. Existem diversas variações das colheitas aqui estudadas que podem não ser corretamente classificadas pela falta de variedade dos polígonos. A coleta de novos polígonos das classes já aprendidas, em diferentes épocas, regiões e lavouras, seria de grande contribuição para novos estudos dentro da área, vide que nenhum repositório foi encontrado para o estudo deste trabalho.
- O sistema realizado não foi hospedado em nenhum domínio, uma vez que o tratamento de imagens, sobretudo as multiespectrais, são demasiadas grandes para ser tais operações. Uma opção de trabalho futuro é a criação de um *plugin* onde dentro de algum programa já preparado pra o manuseio de tais dados, possa ser aplicado o resultado do sistema Lavrador. Ferramentas como o *QuantumGIS* permitem a criação de *frameworks* livres, podendo ser então o desenvolvimento de tal *framework*, alvo de um novo estudo.

- Uma das grandes limitações do Lavrador é a falta de redimensionamento dos polígonos. Bibliotecas famosas atuais se demonstraram problemáticas ao manter a integridade dos dados ao redimensionar imagens multibandas, como é o caso das imagens de resolução 30x30m do *Landsat-8*. Como o alvo deste trabalho era a classificação de imagens multiespectrais, o que permitia polígonos de dimensões fixas, pouco foi aprofundado sobre a problemática de se redimensionar estes polígonos para a camada de entrada da rede. Um estudo sobre redimensionamento de polígonos de extensão GeoTIFF para utilização em redes neurais convolucionais pode ser alvo de um novo estudo.

Referências

- BAETA, R. et al. Learning deep features on multiple scales for coffee crop recognition. In: . IEEE, 2017. p. 262–268. ISBN 978-1-5386-2219-3. Disponível em: <<http://ieeexplore.ieee.org/document/8097321/>>. Citado na página 52.
- BOSQUILLA, P. D. R. W. D. *Comportamento Espectral de Alvos Vegetação*. 1a edição. ed. [S.l.]: UTFPR, 2013. Citado na página 33.
- CROSTA, A. *Processamento digital de imagens de sensoriamento remoto*. UNICAMP/Instituto de Geociências, 1999. ISBN 9788585369026. Disponível em: <<https://books.google.com.br/books?id=XBNQAAAACAAJ>>. Citado 3 vezes nas páginas 33, 35 e 36.
- DESHPANDE, A. *A Beginner's Guide To Understanding Convolutional Neural Networks*. 2016. Disponível em: <<https://adeshpande3.github.io/A-Beginner's-Guide-To-Understanding-Convolutional-Neural-Networks/>>. Citado na página 32.
- FANG, L. et al. A per-pixel stratified classification methodology for land cover mapping based on medium-resolution satellite imagery. In: . IEEE, 2009. p. 1–5. ISBN 978-1-4244-4129-7. Disponível em: <<http://ieeexplore.ieee.org/document/5300978/>>. Citado na página 55.
- FONTANA, D. C. *Comportamento espectral da vegetação*. 1. ed. [S.l.]: UFRGS, 2011. Citado 3 vezes nas páginas 34, 38 e 70.
- HAFEMANN, L. G.; SABOURIN, R.; OLIVEIRA, L. S. Writer-independent feature learning for offline signature verification using deep convolutional neural networks. *CoRR*, abs/1604.00974, 2016. Disponível em: <<http://arxiv.org/abs/1604.00974>>. Citado 2 vezes nas páginas 31 e 32.
- HAYKIN, S. Redes neurais princípios e prática. In: *Bookman*. [S.l.: s.n.], 2003. Citado 2 vezes nas páginas 29 e 30.
- JENSEN, J. R. *Introductory Digital Image Processing: A Remote Sensing Perspective*. 4th. ed. Upper Saddle River, NJ, USA: Prentice Hall Press, 2015. ISBN 013405816X, 9780134058160. Citado 3 vezes nas páginas 35, 36 e 37.
- JOHNSON, B. A.; IIZUKA, K. Integrating OpenStreetMap crowdsourced data and landsat time-series imagery for rapid land use/land cover (LULC) mapping: Case study of the laguna de bay area of the philippines. v. 67, p. 140–149, 2016. ISSN 01436228. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0143622815300321>>. Citado na página 55.
- LI, X. et al. A comparison of machine learning algorithms for mapping of complex surface-mined and agricultural landscapes using ZiYuan-3 stereo satellite imagery. v. 8, n. 6, p. 514, 2016. ISSN 2072-4292. Disponível em: <<http://www.mdpi.com/2072-4292/8/6/514>>. Citado na página 51.

MAPA, PROJEÇÕES DO AGRONEGÓCIO BRASIL 2016/17 A 2026/27, PROJEÇÕES DE LONGO PRAZO. *PROJEÇÕES DO AGRONEGÓCIO Brasil 2016/17 a 2026/27, Projeções de Longo Prazo*. Brasília, DF, 2017. Citado na página 27.

MATSUGU, M. et al. Subject independent facial expression recognition with robust face detection using a convolutional neural network. v. 16, n. 5, p. 555–559, 2003. ISSN 08936080. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0893608003001151>>. Citado 2 vezes nas páginas 30 e 31.

MOHANTY, S. *Typhoon impact on the global rice market*. 2015. Disponível em: <<http://irri.org/blogs/sam-s-rice-price-and-market-blog/typhoon-impact-on-the-global-rice-market>>. Citado na página 71.

NASCIMENTO, R. *Big Data e Machine Learning: saiba como usar essas tecnologias no varejo*. 2017. Disponível em: <<https://br.udacity.com/blog/post/big-data-machine-learning-varejo>>. Citado na página 45.

NIELSEN, M. A. misc, *Neural Networks and Deep Learning*. Determination Press, 2018. Disponível em: <<http://neuralnetworksanddeeplearning.com/>>. Citado 2 vezes nas páginas 31 e 32.

NOVO, E. de M. *Sensoriamento remoto: princípios e aplicações*. Blucher, 2010. ISBN 9788521205401. Disponível em: <<https://books.google.com.br/books?id=M6kOuQAACAAJ>>. Citado 2 vezes nas páginas 36 e 37.

OLESIUK, D. et al. SNNS application for crop classification using HyMap data. In: . IEEE, 2010. p. 1–4. ISBN 978-1-4244-8906-0. Disponível em: <<http://ieeexplore.ieee.org/document/5594848/>>. Citado na página 52.

POWERS, D. Evaluation: From precision, recall and fmeasure to roc, informedness, markedness and correlation. In: . [S.l.: s.n.], 2007. v. 2, p. 37–63. Citado 4 vezes nas páginas 39, 40, 41 e 73.

SAMPAIO, R. Estudos de revisão sistemática: Um guia para síntese criteriosa da evidência científica. *Revista Brasileira De Fisioterapia - REV BRAS FISIOTER*, v. 11, 02 2007. Citado na página 44.

SCHOWENGERDT, R. A. *Remote Sensing, Third Edition: Models and Methods for Image Processing*. Orlando, FL, USA: Academic Press, Inc., 2006. ISBN 0123694078. Citado na página 36.

SILVA, G. B. S. et al. Multitemporal classification of natural vegetation cover in brazilian cerrado. In: . IEEE, 2011. p. 117–120. ISBN 978-1-4577-1202-9. Disponível em: <<http://ieeexplore.ieee.org/document/6005062/>>. Citado na página 52.

SMITH, P. *What are the band designations for the Landsat satellites?* 2017. Disponível em: <<https://landsat.usgs.gov/what-are-band-designations-landsat-satellites>>. Citado 3 vezes nas páginas 39, 56 e 71.

SWINDELL, B. *Lake County wine industry is ready for takeoff*. 2016. Disponível em: <<https://www.pressdemocrat.com/business/5595850-181/lake-county-wine-industry-is>>. Citado na página 74.

- VINICIUS, A. *Redes Neurais Artificiais*. Medium, 2017. Disponível em: <<https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39>>. Citado na página 29.
- WANG, H. et al. Classification of remote sensing agricultural image by using artificial neural network. In: . IEEE, 2009. p. 1–4. ISBN 978-1-4244-3893-8. Disponível em: <<http://ieeexplore.ieee.org/document/5072778/>>. Citado na página 52.
- ZHOU, Z.; LI, S. Peanut planting area change monitoring from remote sensing images based on deep learning. In: . IEEE, 2017. p. 1358–1362. ISBN 978-1-5386-1107-4. Disponível em: <<http://ieeexplore.ieee.org/document/8248497/>>. Citado na página 53.

Apêndices

APÊNDICE A – Tutorial de Coleta de Rótulos

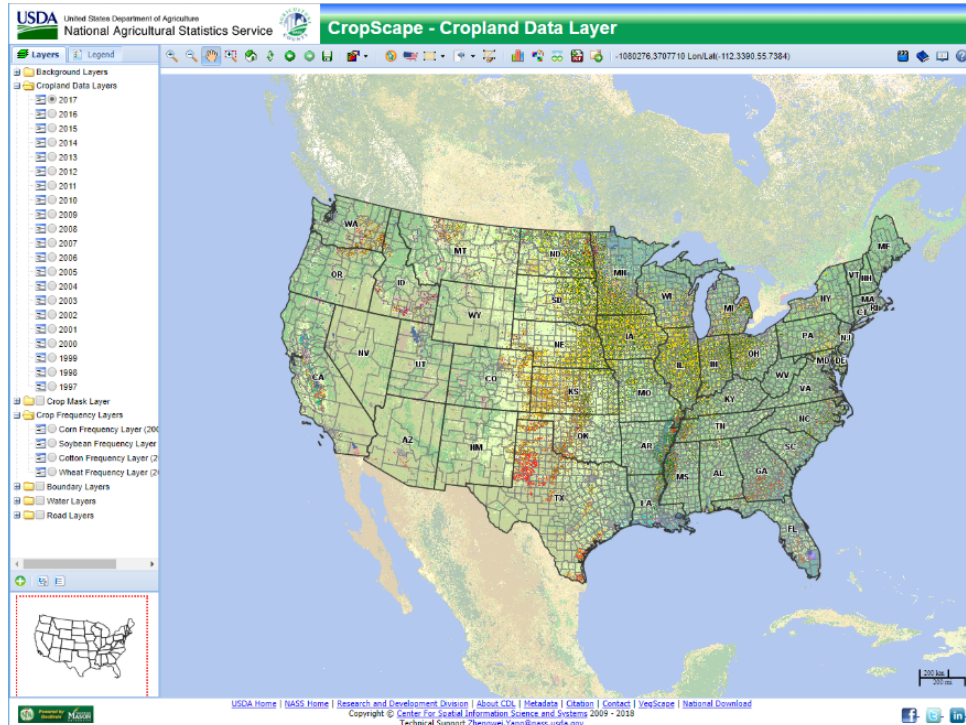
A.1 Descrição

Este tutorial tem o intuito de ajudar a coletar o *raster* com o rótulo de determinada plantação. No exemplo a seguir, um *raster* com rótulo de soja será coletado na região das cidades do Rio Mississippi.

A.2 Passos a serem seguidos

1. Acesse o portal do *CropScape*.
2. Selecione uma área com coordenadas.

Figura 55 – Portal do CropScape




Fonte: Os próprios autores.

3. Selecione a área com uma opção livre "*Define Area of Interest*" e selecione uma área de interesse.
4. Clique na opção "*Area of Interest Statistics*".

5. Selecione todas as plantações de interesse que serão colocadas na layer com os rótulos
6. Clique na opção "*Export the selected crop(s) for mapping*".
7. O resultado final deverá ser um layer no formato *TIF file* contendo o rótulo da colheita definida.

Figura 56 – *Layer* de soja obtido pelo *CropScape*



Fonte: Os próprios autores.

APÊNDICE B – Tutorial de Coleta de imagens *Landsat-8*

B.1 Descrição

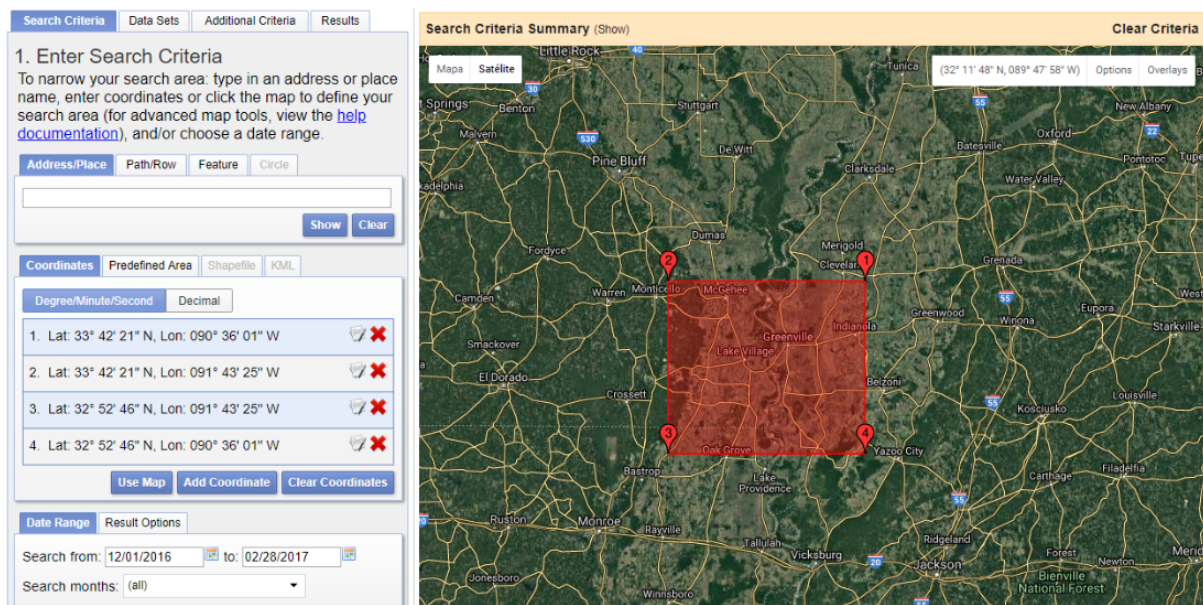
Este tutorial tem o intuito de ensinar como coletar os dados para a alimentação da rede. São dados públicos obtidos do satélite *Landsat-8*. O portal escolhido foi o *EarthExplorer* (<https://earthexplorer.usgs.gov/>).

É necessário cadastro prévio no portal.

B.2 Passos a serem seguidos

1. Acesse o portal do *EarthExplorer*.
2. Selecione uma área com coordenadas.

Figura 57 – Portal do *EarthExplorer*




Fonte: Os próprios autores.

3. Selecione na aba *Data Sets* a opção do *Landsat*.
4. Selecione qual coleção do *Landsat* (nível 1 ou nível 2).
5. Selecione o satélite *Landsat*.

6. Selecione opções adicionais, como a cobertura de nuvens.
7. Selecione uma cena que faça uma boa cobertura da área selecionada.
8. Uma prévia pode ser vista na opção *Show Footprint*.

Figura 58 – Portal do *EarthExplorer*



Fonte: Os próprios autores.

9. Selecione a opção de *Download*.
10. Selecione a opção que contém a imagem espectral (*Level-1 GeoTIFF Data Product*).
11. Caso ocorra tudo normalmente, será disponibilizado os dados zipados para serem baixados.

APÊNDICE C – Tutorial de recorte de polígonos


C.1 Descrição

O intuito deste tutorial é recortar em polígonos os das imagens do *Landsat-8* para servirem de entrada para o alimentar a CNN e os demais modelos de classificação.

C.2 Passos a serem seguidos

1. Acesse o programa ENVI.
2. Importe a camada de rótulo do CDL.
3. Importe a imagem do *Landsat-8*.

Figura 59 – Camada de rótulo do CDL com a imagem multiespectral coletada pelo *EarthExplorer* no programa ENVI

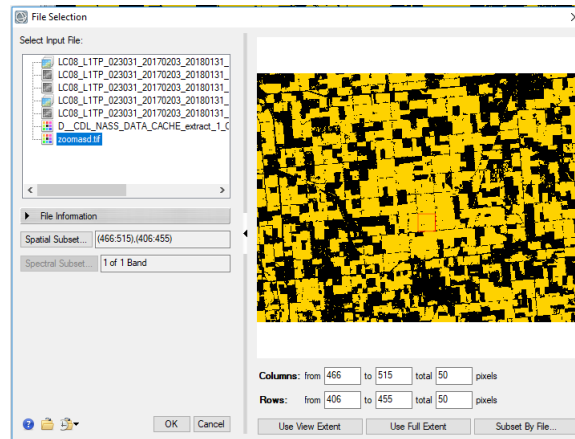


Fonte: Os próprios autores.

4. Clique em *File* »> *Save As*.
5. Selecione a *layer* que contém os dados com o rótulo da lavoura selecionada na janela "*Select Input File*".

6. Selecione o polígono desejado de acordo com a *layer* rotulada, em cima de uma região que contenha a lavoura. As dimensões podem ser ajustadas como na figura 60.

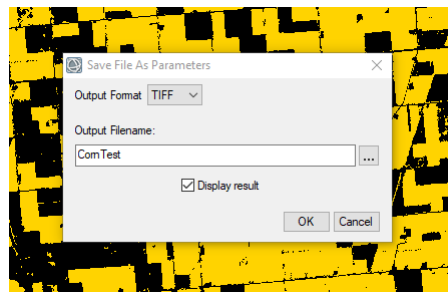
Figura 60 – Janela do ENVI para seleção da camada de rótulo do *CropScape*



Fonte: Os próprios autores.

7. Salve o polígono no formato TIFF.

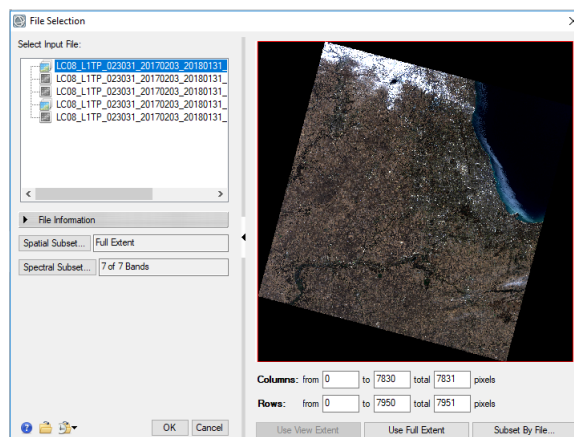
Figura 61 – Janela para salvar o polígono



Fonte: Os próprios autores.

8. Clique novamente em *File* » *Save As*.
9. Selecione a *layer* que contém os dados multiespectrais na janela "*Select Input File*", clique no botão "*Subset By File...*".


Figura 62 – Janela para salvar o polígono



Fonte: Os próprios autores.

10. Selecione o polígono coletado no passo 7 e clique em "OK".
11. Salve o novo polígono

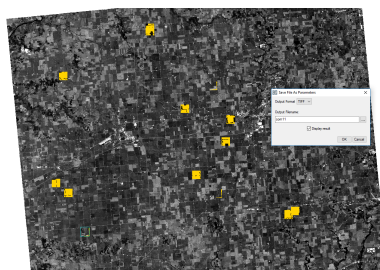
Figura 63 – Resultado final do processo



Fonte: Os próprios autores.

12. Repita os passos para todos os polígonos desejados.

Figura 64 – Polígonos coletados (quadrados amarelos)



Fonte: Os próprios autores.

APÊNDICE D – Código da Arquitetura da CNN

D.1 Descrição

Este código demonstra a implementação do modelo de CNN desenvolvido na Figura 25.

D.2 Código

```
from keras.models import Sequential
from keras.layers.normalization import BatchNormalization
from keras.layers.convolutional import Conv2D
from keras.layers.convolutional import MaxPooling2D
from keras.layers.core import Activation
from keras.layers.core import Flatten
from keras.layers.core import Dropout
from keras.layers.core import Dense
from keras import backend as K

class AddaptedVGGNet:
    @staticmethod
    def build(width, height, depth, classes):

        model = Sequential()
        inputShape = (height, width, depth)
        chanDim = -1

        if K.image_data_format() == "channels_first":
            inputShape = (depth, height, width)
            chanDim = 1

        model.add(Conv2D(32, (3, 3), padding="same",
            input_shape=inputShape))
        model.add(Activation("relu"))
        model.add(BatchNormalization(axis=chanDim))
```

```
model.add(MaxPooling2D(pool_size=(3, 3)))
model.add(Dropout(0.25))

model.add(Conv2D(64, (3, 3), padding="same"))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(Conv2D(64, (3, 3), padding="same"))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))

model.add(Conv2D(128, (3, 3), padding="same"))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(Conv2D(128, (3, 3), padding="same"))
model.add(Activation("relu"))
model.add(BatchNormalization(axis=chanDim))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))

model.add(Flatten())
model.add(Dense(1024))
model.add(Activation("relu"))
model.add(BatchNormalization())
model.add(Dropout(0.5))

model.add(Dense(classes))
model.add(Activation("softmax"))

return model
```

APÊNDICE E – Código da recorte dos polígonos

E.1 Descrição

Este código recorta polígonos multiespectrais no formato *GeoTIFF* em polígonos menores de tamanho customizado, definido pela variável *"tilesize"*.

E.2 Código

```
import os, sys
from osgeo import gdal

count = 0
Path = "./ClippedImages/" #Define where your new polygons will be saved
label = "sugar"

filepath = "./sugarcane2.tif" #Define which image to clip
dset = gdal.Open(filepath)

width = dset.RasterXSize
height = dset.RasterYSize

print (width, 'x', height)

tilesize = 15 #define the size of your polygon

for i in range(0, width, tilesize):
    for j in range(0, height, tilesize):
        w = min(i+tilesize, width) - i
        h = min(j+tilesize, height) - j
        if((j + tilesize) <= width and (i+tilesize) <= height):
            gdaltranString = "gdal_translate -of GTIFF -srcwin " +
                str(i)+", "+str(j)+", "+str(w)+", " \
                +str(h)+" " + filepath + " " + Path + label
                + "_"+str(i)+"_"+str(j)+"_"+str(count)+".tif"
```

```
count+=1  
os.system(gdaltranString)
```