

# Análise e Classificação Automática de Nódulos em Raízes de Cultivares de Soja

Eber Fabiano Pacanhela<sup>1</sup>, Artur Berbel Lirio Rondina<sup>2</sup>,  
Marco Antonio Nogueira<sup>3</sup>, Mariangela Hungria<sup>3</sup>,  
Priscila Tiemi Maeda Saito<sup>4</sup>, Fabrício Martins Lopes<sup>1</sup>

<sup>1</sup>Departamento Acadêmico de Computação,  
Universidade Tecnológica Federal do Paraná (UTFPR) – Câmpus Cornélio Procópio,  
Avenida Alberto Carazzai, 1640, Cornélio Procópio, PR, CEP: 86.300-000, Brasil

<sup>2</sup>Departamento de Biologia,  
Centro Universitário das Faculdades Integradas de Ourinhos (Unifio),  
Rodovia BR-153, km 338, Ourinhos, SP, CEP: 19.909-100, Brasil

<sup>3</sup>Centro Nacional de Pesquisa de Soja,  
Empresa Brasileira de Pesquisa Agropecuária (Embrapa),  
Rodovia Carlos João Strass, Distrito de Warta, Londrina, PR, CEP: 86.001-970, Brasil

<sup>4</sup>Departamento de Computação,  
Universidade Federal de São Carlos (UFSCar),  
Rodovia Washington Luís, km 235, São Carlos, SP, CEP: 13.565-905, Brasil

eberfabiano@alunos.utfpr.edu.br

**Abstract.** Soybean is the most cultivated oilseed in the world, and requires high amounts of nitrogen to the plant's nutrition. The nutrient can be supplied by chemical fertilizers, harmful to the environment. However, the biological nitrogen fixation (BNF) process has been an effective option for increasing productivity and minimize environmental effects. BNF occurs through the association of diazotrophic bacteria in the root system of legumes and oilseeds, where root nodules are formed. This work proposes an analysis and automatic classification through image processing and computer vision of these root nodules to evaluate the efficacy of nodulation on soybean, considering the nodules amount.

**Resumo.** A soja é a oleaginosa mais cultivada no mundo e requer grandes quantidades de nitrogênio para a nutrição da planta. O nutriente pode ser fornecido por fertilizantes químicos, prejudiciais ao meio ambiente. No entanto, o processo de fixação biológica do nitrogênio (FBN) tem sido uma opção eficaz para aumentar a produtividade e minimizar os impactos ambientais. A FBN ocorre por meio da associação de bactérias diazotróficas no sistema radicular de leguminosas e oleaginosas, onde nódulos radiculares são formados. Este trabalho propõe-se uma análise e classificação automática, por meio do processamento de imagens e visão computacional, destes nódulos radiculares para avaliar a eficácia da nodulação em soja, considerando a quantidade de nódulos.

## 1. Introdução

A soja (*Glycine max* (L.) Merril) é uma oleaginosa com alto teor proteico em seus grãos, cerca de 38%. Devido ao fato dela se adaptar facilmente aos diversos tipos de clima,

possuir inúmeras variedades e alto valor econômico, esta leguminosa é a mais cultivada no mundo [Barreto 2004] [USDA 2022].

O cultivo da soja apresenta alta demanda de nitrogênio (N), devido ao alto teor proteico dos grãos desta oleaginosa [Gomes 2019]. O nutriente pode ser fornecido por fertilizantes químicos, prejudiciais ao meio ambiente [Gomes 2019]. Os grãos de soja possuem um teor médio de 6,5% de nitrogênio [Hungria et al. 2001], sendo necessário 80 kg de nitrogênio, considerando também as demais partes da planta, para produzir 1.000 kg de grãos de soja [Hungria and Mendes 2015].

O uso de biofertilizantes tem se demonstrado uma alternativa importante para reduzir os impactos ambientais causados pela utilização desnecessária ou incorreta de agroquímicos nitrogenados na produção de soja [Hungria et al. 2020]. Visto que, a fixação biológica do nitrogênio (FBN) na cultura da soja tem se destacado pela capacidade de aumentar a produtividade sem aumentar excessivamente os custos, além de possuir impacto ambiental mínimo [Hungria et al. 2001].

A FBN ocorre por meio da associação simbiótica de bactérias diazotróficas no sistema radicular de leguminosas e oleaginosas, formando nódulos radiculares. As bactérias se abrigam nestes nódulos e recebem da planta proteção e alimento e, em compensação, elas capturam e transformam o nitrogênio atmosférico ( $N_2$ ) em forma assimilável para a planta, fornecendo o nitrogênio necessário para o seu desenvolvimento [Nogueira et al. 2018]. No cultivo da soja, as bactérias capazes de nodular as raízes da planta pertencem ao gênero *Bradyrhizobium*, principalmente nas espécies *Bradyrhizobium japonicum* e *Bradyrhizobium elkanii*; geralmente, elas são denominadas pelos termos genéricos: rizóbio ou *bradyrhizobium diazoeficiens* [Hungria et al. 2001].

Segundo [Meshram et al. 2021], aprendizado de máquina, aprendizado profundo e visão computacional contribuem com a produtividade agrícola, melhorando a qualidade e aumentando a lucratividade dos agricultores. Sabe que o uso de diversas tecnologias é realidade em plantações, por exemplo, o uso de sensores de temperatura/umidade e captura de imagens aéreas por meio de drones. Essas informações obtidas e processadas por meio de tecnologia, podem auxiliar os produtores nas decisões e reduzir problemas relacionados à agricultura [Meshram et al. 2021].

Neste contexto, o objetivo deste trabalho consiste na análise e classificação automática dos nódulos radiculares da soja, por meio do processamento de imagens e visão computacional, para avaliar a eficácia da nodulação em soja, considerando a quantidade de nódulos.

A identificação de nódulos em raízes de soja tem sido alvo de poucos trabalhos na literatura. Recentemente, um pipeline foi desenvolvido para detectar automaticamente nódulos em imagens de raízes de soja através de aprendizado de máquina, fornecendo a quantidade de nódulos, tamanho dos nódulos e distribuições de nódulos ao longo da raiz principal [Jubery et al. 2021]. Para isto, foram adotadas 691 imagens e aprendizado profundo. Para detecção dos nódulos, foi utilizada a arquitetura Retina-Net [Lin et al. 2017] e para a detecção da raiz principal foi utilizada a arquitetura U-Net [Ronneberger et al. 2015], adotando 80% das amostras para o treinamento e 20% para teste. Além disso, foi adotado o aumento de dados com técnicas de transformações geométricas (flipping), zoom de 120%, translação nas direções horizontal e vertical em

5% e rotação das imagens até 15 graus [Shorten and Khoshgoftaar 2019].

Outro trabalho foi desenvolvido para caracterizar nódulo de raiz de soja exposta ao silício, através de aprendizado de máquina baseado em imagens [Chung et al. 2020]. Imagens 2D foram adotadas para a extração de características morfológicas das raízes, como área de superfície, comprimento e ângulo, bem como a quantidade e tamanho dos nódulos radiculares. A quantidade e o tamanho dos nódulos foram determinados pela detecção e segmentação baseada em aprendizado profundo. A arquitetura U-Net [Ronneberger et al. 2015] foi utilizada para a segmentação dos nódulos. Foram anotadas 35 imagens manualmente, através de polígonos desenhados no contorno de cada nódulo e realizado o treinamento da rede. Porém, mais dados de treinamento foram adicionados por meio de uma abordagem de anotação semiautomática, resultando em um total de 135 imagens para treinamento da rede profunda.

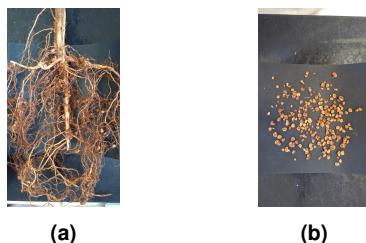
Recentemente, uma nova abordagem foi proposta por meio de métodos interativos e tradicionais de aprendizado de máquina para classificar sementes e mudas de soja de acordo com sua aparência e potencial fisiológico [Medeiros et al. 2020]. Foram selecionadas 700 sementes de soja da safra 2019/2020 e a partir das sementes as mudas foram produzidas. As características das sementes e das mudas foram baseadas em cor e intensidade de pixel e descritores de borda e textura. Os modelos de classificação selecionados pelos autores foram: Linear Discriminant Analysis (LDA), Random Forest (RF) e Support Vector Machine (SVM), onde utilizaram validação cruzada para avaliação dos modelos com 90% do conjunto de dados para treinamento e 10% para teste com iteração de 10 vezes.

Diferente dos trabalhos anteriores, este trabalho propõe uma abordagem com modelos tradicionais de aprendizado de máquina, tais como K-Nearest Neighbors (KNN), RF e SVM, para classificar nódulos em raízes de cultivares de soja, utilizando descritores tradicionais e arquiteturas profundas para extrair as características e avaliar sua contribuição na classificação das amostras.

## 2. Materiais e Métodos

### 2.1. Aquisição do Conjunto de Dados

As imagens de raízes de soja contendo nódulos foram obtidas no Laboratório de Biotecnologia do Solo da Embrapa Soja, Londrina - PR. O conjunto de dados contempla um total de 191 imagens, deste total, 162 imagens são amostras de raízes de soja contendo nódulos e 29 imagens são amostras de nódulos separados das raízes, conforme pode ser observado na Figura 1.



**Figura 1. Exemplo de imagens do conjunto de dados. (a) raiz de soja contendo nódulos; (b) nódulos separados das raízes.**

## 2.2. Pré-Processamento e Extração de Características

Foi adotada a padronização da orientação das imagens em modo retrato e com o caule da planta voltado para a parte superior da imagem antes de iniciar o processo de anotação, pois o conjunto de dados contém imagens com diferentes orientações.

Para anotação das regiões de interesse (nódulos, raízes e fundos) nas imagens adotou-se a ferramenta LabelMe [Wada 2022] utilizando a forma de anotação retângulo envolvente. Por padrão, foram anotados todos os nódulos, cinco amostras de raízes e cinco amostras de fundos existentes de cada uma das imagens. As regiões de interesse foram extraídas das imagens originais, resultando em um total de 11.414 amostras, deste total, 9.649 amostras são nódulos, 810 amostras são raízes e 955 amostras são fundos.

Após a segmentação das regiões de interesse, a técnica de *Data Augmentation* [Shorten and Khoshgoftaar 2019] foi adotada para tratar a desproporção entre a quantidade de amostras de cada uma das classes (nódulo, raiz e fundo) com o objetivo de aumentar a quantidade de amostras das classes raiz e fundo. A estratégia utilizada foi rotacionar as regiões de interesse em 15, 30, 45, 60, 75, 90, 105, 120, 135, 150 e 165 graus. Foi realizado também um recorte em cada região de interesse rotacionada para remover os *pixels* de intensidade zero das bordas. É importante ressaltar que nem todas as regiões de interesse foram rotacionadas, só foram rotacionadas regiões de interesse o suficiente para atingir a mesma quantidade da classe nódulo anotada inicialmente, ou seja, até atingir 9.649 amostras para as classes raiz e fundo.

Com o conjunto de dados balanceado, aplicou-se em cada uma das regiões de interesse 25 descritores de características [Bressan et al. 2018], os quais podem ser observados na Tabela 1.

**Tabela 1. Descritores de imagens, tipos e quantidade de características.**

	Descriptor	Tipo	Características	Referência
Tradicionais	Momentos Invariante de Hu	Forma	7	[Hu 1962]
	First Order Measures (FOM) Gray	Textura	8	[Irons and Petersen 1981]
	Haralick	Textura	13	[Haralick et al. 1973]
	First Order Measures (FOM) Color	Textura	24	[Irons and Petersen 1981]
	Global Color Histogram (GCH)	Cor	30	[Stricker and Orenco 1995]
	Zernike	Forma	72	[Teague 1980]
	Local Binary Patterns (LBP)	Textura	352	[Ojala et al. 2000]
Arquiteturas Profundas	VGG16	Genérico	512	[Simonyan and Zisserman 2015]
	VGG19	Genérico	512	[Simonyan and Zisserman 2015]
	DenseNet121	Genérico	1.024	[Huang et al. 2017]
	MobileNet	Genérico	1.024	[Howard et al. 2017]
	NASNetMobile	Genérico	1.056	[Zoph et al. 2018]
	MobileNetV2	Genérico	1.280	[Sandler et al. 2018]
	InceptionResNetV2	Genérico	1.536	[Szegedy et al. 2017]
	DenseNet169	Genérico	1.664	[Huang et al. 2017]
	DenseNet201	Genérico	1.920	[Huang et al. 2017]
	InceptionV3	Genérico	2.048	[Szegedy et al. 2016]
	ResNet101	Genérico	2.048	[He et al. 2016a]
	ResNet101V2	Genérico	2.048	[He et al. 2016b]
	ResNet152	Genérico	2.048	[He et al. 2016a]
	ResNet152V2	Genérico	2.048	[He et al. 2016b]
	ResNet50	Genérico	2.048	[He et al. 2016a]
	ResNet50V2	Genérico	2.048	[He et al. 2016b]
	Xception	Genérico	2.048	[Chollet 2017]
	NASNetLarge	Genérico	4.032	[Zoph et al. 2018]

## 2.3. Classificação

Após a extração das características foi realizado o treinamento dos modelos de aprendizado de máquina. É necessário evidenciar que as características foram reescaladas no intervalo [0, 1] utilizando a técnica conhecida como MinMax [Witten et al. 2011], de forma a serem comparáveis entre si.

Foram selecionados três classificadores clássicos da literatura, sendo eles o KNN, RF e SVM, sendo que para este último, foram considerados Kernel Linear (KL) e Kernel Polinomial de Grau 2 (KPG2). É importante destacar que não foram modificados os hiperparâmetros dos modelos de classificação, exceto no SVM para criar uma variação do mesmo, pois este trabalho não tem como objetivo estabelecer os melhores parâmetros para estes classificadores neste conjunto de dados.

Utilizou-se também a técnica de validação cruzada [Refaeilzadeh et al. 2009] para avaliar os modelos, onde o conjunto de dados foi dividido em 10 subconjuntos, considerando 90% dos dados para treinamento e 10% dos dados para teste. Para cada modelo e descritor utilizou-se as mesmas amostras nas execuções da validação cruzada.

### 3. Resultados e Discussão

Com o objetivo de avaliar a abordagem proposta para o reconhecimento e classificação de nódulos presentes nas raízes de soja, foram considerados o conjunto de imagens (Seção 2.1) e as características extraídas (Seção 2.2) com aplicação dos modelos de classificação descritos na Seção 2.3.

A Tabela 2 apresenta a quantidade de características de cada descritor, bem como as acurárias médias obtidas em cada um dos modelos, considerado separadamente os descritores tradicionais e arquiteturas profundas. Os melhores resultados (i.e. classificadores) para cada extrator são destacados em negrito, os melhores resultados (i.e. extratores) para cada classificador são apresentados sublinhados e os melhores resultados (i.e. maiores acurárias médias) obtidos são apresentados com asterisco.

**Tabela 2. Média de acurárias  $\pm$  desvio padrão obtidos pelos classificadores KNN, RF, SVM (KL) e SVM (KPG2), utilizando as características obtidas pelos extratores tradicionais e arquiteturas profundas.**

	Descriptor	Características	KNN	RF	SVM (KL)	SVM (KPG2)
Tradicionais	Momentos Invariante de Hu	7	0,672 $\pm$ 0,009	<b>0,785 <math>\pm</math> 0,009</b>	0,457 $\pm$ 0,012	0,579 $\pm$ 0,012
	FOM (Gray)	8	0,920 $\pm$ 0,003	<b>0,969 <math>\pm</math> 0,003</b>	0,889 $\pm$ 0,005	0,912 $\pm$ 0,006
	Haralick	13	0,976 $\pm$ 0,002	<b>0,982 <math>\pm</math> 0,002</b>	0,954 $\pm$ 0,003	0,963 $\pm$ 0,003
	FOM (Color)	24	0,977 $\pm$ 0,003	<b>0,986 <math>\pm</math> 0,002*</b>	0,967 $\pm$ 0,003	0,972 $\pm$ 0,003
	GCH	30	0,976 $\pm$ 0,001	<b>0,989 <math>\pm</math> 0,002*</b>	0,868 $\pm$ 0,006	0,866 $\pm$ 0,007
	Zernike	72	0,506 $\pm$ 0,010	<b>0,640 <math>\pm</math> 0,007</b>	0,609 $\pm$ 0,005	0,615 $\pm$ 0,005
	LBP	352	0,826 $\pm$ 0,008	<b>0,879 <math>\pm</math> 0,007</b>	0,854 $\pm$ 0,007	0,779 $\pm$ 0,006
Arquiteturas Profundas	VGG16	512	0,989 $\pm$ 0,002	<u>0,991 <math>\pm</math> 0,002</u>	<b>0,997 <math>\pm</math> 0,001*</b>	<b>0,996 <math>\pm</math> 0,001</b>
	VGG19	512	0,990 $\pm$ 0,002	<u>0,992 <math>\pm</math> 0,001</u>	<b>0,996 <math>\pm</math> 0,001</b>	<b>0,996 <math>\pm</math> 0,001</b>
	DenseNet121	1.024	<b>0,993 <math>\pm</math> 0,002</b>	0,987 $\pm$ 0,002	<b>0,996 <math>\pm</math> 0,001</b>	<b>0,995 <math>\pm</math> 0,002</b>
	MobileNet	1.024	<u>0,994 <math>\pm</math> 0,001</u>	0,988 $\pm$ 0,001	<b>0,993 <math>\pm</math> 0,002</b>	<b>0,996 <math>\pm</math> 0,001</b>
	NASNetMobile	1.056	0,877 $\pm$ 0,006	0,893 $\pm$ 0,006	<b>0,910 <math>\pm</math> 0,006</b>	<b>0,903 <math>\pm</math> 0,007</b>
	MobileNetV2	1.280	0,988 $\pm$ 0,002	0,982 $\pm$ 0,002	<b>0,990 <math>\pm</math> 0,001</b>	<b>0,992 <math>\pm</math> 0,001</b>
	InceptionResNetV2	1.536	0,874 $\pm$ 0,006	<b>0,890 <math>\pm</math> 0,006</b>	0,874 $\pm$ 0,004	0,801 $\pm$ 0,009
	DenseNet169	1.664	0,992 $\pm$ 0,002	0,987 $\pm$ 0,002	<b>0,997 <math>\pm</math> 0,001*</b>	<b>0,996 <math>\pm</math> 0,001</b>
	DenseNet201	1.920	<b>0,994 <math>\pm</math> 0,002</b>	0,988 $\pm$ 0,001	<b>0,997 <math>\pm</math> 0,001*</b>	<b>0,997 <math>\pm</math> 0,001*</b>
	InceptionV3	2.048	0,920 $\pm$ 0,004	0,926 $\pm$ 0,006	<b>0,955 <math>\pm</math> 0,003</b>	0,946 $\pm$ 0,005
	ResNet101	2.048	0,995 $\pm$ 0,001	0,994 $\pm$ 0,001	<b>0,998 <math>\pm</math> 0,001*</b>	<b>0,998 <math>\pm</math> 0,001*</b>
	ResNet101V2	2.048	0,930 $\pm$ 0,004	0,927 $\pm$ 0,006	<b>0,965 <math>\pm</math> 0,003</b>	0,935 $\pm$ 0,004
	ResNet152	2.048	0,995 $\pm$ 0,001	0,993 $\pm$ 0,002	<b>0,998 <math>\pm</math> 0,001*</b>	<b>0,998 <math>\pm</math> 0,001*</b>
	ResNet152V2	2.048	0,952 $\pm$ 0,004	0,952 $\pm$ 0,005	<b>0,983 <math>\pm</math> 0,002</b>	0,957 $\pm$ 0,004
	ResNet50	2.048	0,996 $\pm$ 0,001	0,994 $\pm$ 0,001	<b>0,999 <math>\pm</math> 0,001*</b>	<b>0,999 <math>\pm</math> 0,001*</b>
	ResNet50V2	2.048	0,950 $\pm$ 0,003	0,939 $\pm$ 0,005	<b>0,976 <math>\pm</math> 0,002</b>	0,956 $\pm$ 0,001
	Xception	2.048	0,961 $\pm$ 0,005	0,958 $\pm$ 0,002	<b>0,979 <math>\pm</math> 0,002</b>	<b>0,978 <math>\pm</math> 0,002</b>
	NASNetLarge	4.032	0,898 $\pm$ 0,004	0,899 $\pm$ 0,004	<b>0,944 <math>\pm</math> 0,003</b>	0,925 $\pm$ 0,003

Os descritores profundos VGG16, DenseNet169, DenseNet201, ResNet101, ResNet152 e ResNet50 em conjunto com o classificador SVM apresentaram melhores resultados em comparação com os descritores tradicionais FOM (Color) e GCH em conjunto com o classificador RF. No entanto, é importante destacar que quanto maior a quantidade de características para cada instância, mais lento se torna o treinamento do modelo [Géron 2019]. De modo geral, as combinações de descritores e classificadores apresentaram resultados promissores para a classificação de nódulos em raízes de cultivares de soja.

Na Tabela 3 são apresentadas as demais métricas (sensibilidade, especificidade e precisão) de avaliação dos modelos e extratores que apresentaram resultados (i.e. maiores acurárias médias) destacados na Tabela 2.

**Tabela 3. Métricas (sensibilidade, especificidade e precisão)  $\pm$  desvio padrão obtidos pelos classificadores e extratores tradicionais e arquiteturas profundas dos melhores resultados (i.e. maiores acurárias médias) apresentados na Tabela 2.**

Descriptor	RF			SVM (KL)			SVM (KPG2)		
	Sensibilidade	Especificidade	Precisão	Sensibilidade	Especificidade	Precisão	Sensibilidade	Especificidade	Precisão
FOM (Color)	0,986 $\pm$ 0,002	0,993 $\pm$ 0,001	0,986 $\pm$ 0,002	0,967 $\pm$ 0,003	0,983 $\pm$ 0,001	0,967 $\pm$ 0,003	0,972 $\pm$ 0,003	0,986 $\pm$ 0,001	0,972 $\pm$ 0,003
GCH	0,989 $\pm$ 0,002	0,995 $\pm$ 0,001	0,989 $\pm$ 0,002	0,868 $\pm$ 0,006	0,934 $\pm$ 0,003	0,868 $\pm$ 0,006	0,866 $\pm$ 0,007	0,933 $\pm$ 0,003	0,866 $\pm$ 0,007
VGG16	0,991 $\pm$ 0,002	0,995 $\pm$ 0,001	0,991 $\pm$ 0,002	0,997 $\pm$ 0,001	0,998 $\pm$ 0,000	0,997 $\pm$ 0,001	0,996 $\pm$ 0,001	0,998 $\pm$ 0,000	0,996 $\pm$ 0,001
DenseNet169	0,987 $\pm$ 0,002	0,993 $\pm$ 0,001	0,987 $\pm$ 0,002	0,997 $\pm$ 0,001	0,998 $\pm$ 0,000	0,997 $\pm$ 0,001	0,996 $\pm$ 0,001	0,998 $\pm$ 0,001	0,996 $\pm$ 0,001
DenseNet201	0,988 $\pm$ 0,001	0,994 $\pm$ 0,001	0,988 $\pm$ 0,001	0,997 $\pm$ 0,001	0,999 $\pm$ 0,001	0,997 $\pm$ 0,001	0,997 $\pm$ 0,001	0,998 $\pm$ 0,000	0,997 $\pm$ 0,001
ResNet101	0,994 $\pm$ 0,001	0,997 $\pm$ 0,001	0,994 $\pm$ 0,001	0,998 $\pm$ 0,001	0,999 $\pm$ 0,001	0,998 $\pm$ 0,001	0,998 $\pm$ 0,001	0,999 $\pm$ 0,000	0,998 $\pm$ 0,001
ResNet152	0,993 $\pm$ 0,002	0,997 $\pm$ 0,001	0,993 $\pm$ 0,002	0,998 $\pm$ 0,001	0,999 $\pm$ 0,000	0,998 $\pm$ 0,001	0,998 $\pm$ 0,001	0,999 $\pm$ 0,000	0,998 $\pm$ 0,001
ResNet50	0,994 $\pm$ 0,001	0,997 $\pm$ 0,001	0,994 $\pm$ 0,001	0,999 $\pm$ 0,001	0,999 $\pm$ 0,000	0,999 $\pm$ 0,001	0,999 $\pm$ 0,001	0,999 $\pm$ 0,000	0,999 $\pm$ 0,001

## 4. Conclusões e Trabalhos Futuros

Este trabalho apresentou uma abordagem com modelos tradicionais de aprendizado de máquina (KNN, RF e SVM) para classificação de nódulos radiculares em raízes de soja, por meio de características extraídas utilizando descritores tradicionais e arquiteturas profundas.

O objetivo deste trabalho foi avaliar as características e algoritmos/arquiteturas de classificadores aplicados na classificação dos nódulos, de forma a apontar quais os mais assertivos/adequados. Neste contexto, os resultados experimentais indicam que tanto o classificador SVM em conjunto com os descritores profundos VGG16, DenseNet169, DenseNet201, ResNet101, ResNet152 e ResNet50 quanto o classificador RF em conjunto com os descritores tradicionais FOM (Color) e GCH são adequados para a classificação de nódulos radiculares em cultivares de soja.

Para trabalhos futuros, almeja-se realizar experimentos com a alteração dos hiperparâmetros dos modelos visando obter melhores resultados na classificação. E, se possível executar e comparar os modelos propostos por [Jubery et al. 2021], [Chung et al. 2020] e [Medeiros et al. 2020] utilizando o conjunto de dados proposto neste trabalho.

## Agradecimentos

Este trabalho foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Fundação Araucária (Grant number 035/2019, 138/2021 e NAPI - Bioinformática), INCT - Microrganismos Promotores do Crescimento Vegetal para a Sustentabilidade Agrícola e Responsabilidade Ambiental (CNPq 465133 / 2014-4, Fundação Araucária-STI, CAPES) e UTFPR.

## Referências

- Barreto, C. (2004). Os impactos socioambientais da soja no Brasil. In *II Encontro da Associação Nacional de Pós Graduação e Pesquisa em Ambiente e Sociedade*, Indaiatuba. II.
- Bressan, R. S., Alves, D. H. A., Valerio, L. M., Bugatti, P. H., and Saito, P. T. M. (2018). Doctor: The role of deep features in content-based mammographic image retrieval. In *2018 IEEE 31st Intl Symposium on Computer-Based Medical Systems*, pages 158–163.

- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *2017 IEEE Conf. on Computer Vision and Pattern Recognition*, pages 1800–1807.
- Chung, Y. S., Lee, U., Heo, S., Silva, R. R., Na, C.-I., and Kim, Y. (2020). Image-based machine learning characterizes root nodule in soybean exposed to silicon. *Frontiers in Plant Science*, 11.
- Gomes, M. S. (2019). Fertilização Nitrogenada: produção, produtividade e trocas gasosas da soja cultivada em latossolo amarelo em casa de vegetação. Mestrado em agronomia, Universidade Federal Rural da Amazônia.
- Géron, A. (2019). *Mãos à Obra Aprendizado de Máquina com Scikit-Learn TensorFlow: Conceitos, Ferramentas e Técnicas Para a Construção de Sistemas Inteligentes*. Alta Books, Rio de Janeiro.
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, (6):610–621.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016a). Deep residual learning for image recognition. *2016 IEEE Conf. on Computer Vision and Pattern Recognition*, pages 770–778.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016b). Identity mappings in deep residual networks. *ArXiv*, abs/1603.05027.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *ArXiv*, abs/1704.04861.
- Hu, M.-K. (1962). Visual pattern recognition by moment invariants. *IRE Transactions on Information Theory*, 8(2):179–187.
- Huang, G., Liu, Z., and Weinberger, K. Q. (2017). Densely connected convolutional networks. *2017 IEEE Conf. on Computer Vision and Pattern Recognition*, pages 2261–2269.
- Hungria, M., Campo, R. J., and Mendes, I. C. (2001). Fixação Biológica do Nitrogênio na Cultura da Soja. Technical Report 13, Embrapa Soja, Londrina.
- Hungria, M. and Mendes, I. C. (2015). *Nitrogen Fixation with Soybean: The Perfect Symbiosis?*, chapter 99, pages 1009–1024. John Wiley Sons, Ltd.
- Hungria, M., Moretti, L. G., Crusciol, C. A. C., Kuramae, E. E., Bossolani, J. W., Moreira, A., Costa, N. R., Alves, C. J., Pascoaloto, I. M., and Rondina, A. B. L. (2020). Effects of growth-promoting bacteria on soybean root activity, plant development, and yield. *Agronomy Journal*, 112(1):418–428.
- Irons, J. R. and Petersen, G. W. (1981). Texture transforms of remote sensing data. *Remote Sensing of Environment*, 11:359–370.
- Jubery, T. Z., Carley, C. N., Singh, A., Sarkar, S., Ganapathysubramanian, B., and Singh, A. K. (2021). Using machine learning to develop a fully automated soybean nodule acquisition pipeline (snap). *Plant Phenomics*, 2021.
- Lin, T.-Y., Goyal, P., Girshick, R. B., He, K., and Dollár, P. (2017). Focal loss for dense object detection. *2017 IEEE Intl Conf. on Computer Vision*, pages 2999–3007.

- Medeiros, A. D. d., Capobiango, N. P., Silva, J. M. d., Silva, L. J. d., Silva, C. B. d., and Santos Dias, D. C. F. d. (2020). Interactive machine learning for soybean seed and seedling quality classification. *Scientific Reports*, 10.
- Meshram, V., Patil, K., Meshram, V., Hanchate, D., and Ramkuteke, S. (2021). Machine learning in agriculture domain: A state-of-art survey. *AI in the Life Sciences*, 1:100010.
- Nogueira, M. A., Prando, A. M., de Oliveira, A. B., de Lima, D., Conte, O., Harger, N., de Oliveira, F. T., and Hungria, M. (2018). Ações de transferência de tecnologia em inoculação/coinoculação com bradyrhizobium e azospirillum na cultura da soja na safra 2017/18 no estado do paraná. Technical Report 143, Embrapa Soja, Londrina.
- Ojala, T., Pietikäinen, M., and Mäenpää, T. (2000). Gray scale and rotation invariant texture classification with local binary patterns. In *Computer Vision*, pages 404–420, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Refaeilzadeh, P., Tang, L., and Liu, H. (2009). *Cross-Validation*, pages 532–538. Springer US, Boston, MA.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *MICCAI*.
- Sandler, M., Howard, A. G., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). MobileNetv2: Inverted residuals and linear bottlenecks. *2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*, pages 4510–4520.
- Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, pages 2196–1115.
- Simonyan, K. and Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556.
- Stricker, M. A. and Orengo, M. (1995). Similarity of color images. In Niblack, W. and Jain, R. C., editors, *Storage and Retrieval for Image and Video Databases III*, volume 2420, pages 381 – 392. Intl Society for Optics and Photonics, SPIE.
- Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In *AAAI*.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. *2016 IEEE Conf. on Computer Vision and Pattern Recognition*, pages 2818–2826.
- Teague, M. R. (1980). Image analysis via the general theory of moments\*. *J. Opt. Soc. Am.*, 70(8):920–930.
- USDA (2022). United States Departamento of Agriculture: PSD Reports.
- Wada, K. (2022). Labelme. disponível em: <https://github.com/wkentaro/labelme>.
- Witten, I. H., Frank, E., and Hall, M. A. (2011). *Data mining: practical machine learning tools and techniques*. Morgan Kaufmann, Burlington, 3 edition.
- Zoph, B., Vasudevan, V., Shlens, J., and Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. *2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition*, pages 8697–8710.