

UNIVERSIDADE FEDERAL DE PELOTAS
Faculdade de Agronomia Eliseu Maciel
Programa de Pós-Graduação em Ciência e Tecnologia de Sementes

Dissertação



**Métodos de identificação para separação de sementes de arroz quanto à
diferença de pigmentação, dimensões e fissuras por meio do
processamento de imagens**

Rita de Cassia Mota Monteiro

Pelotas, 2022

Rita de Cassia Mota Monteiro

**Métodos de identificação para separação de sementes de arroz quanto à
diferença de pigmentação, dimensões e fissuras por meio do
processamento de imagens**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência e Tecnologia de Sementes da Faculdade de Agronomia Eliseu Maciel da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Ciências (Ciência e Tecnologia de Sementes).

Orientador: Prof. Dr. Francisco Amaral Villela

Co-Orientadora: Profa. Dra. Gizele Ingrid Gadotti

Pelotas, 2022

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

M772m Monteiro, Rita de Cassia Mota

Métodos de identificação para separação de sementes de arroz quanto à diferença de pigmentação, dimensões e fissuras por meio do processamento de imagens / Rita de Cassia Mota Monteiro ; Francisco Amaral Villela, orientador ; Gizele Ingrid Gadotti, coorientadora. — Pelotas, 2022.

72 f.

Dissertação (Mestrado) — Programa de Pós-Graduação em Ciência e Tecnologia de Sementes, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, 2022.

1. *Oryza sativa* L. 2. RGB. 3. Aprendizado de máquina. 4. Imagens. I. Villela, Francisco Amaral, orient. II. Gadotti, Gizele Ingrid, coorient. III. Título.

CDD : 631.521

Rita de Cassia Mota Monteiro

Métodos de identificação para separação de sementes de arroz quanto à diferença de pigmentação, dimensões e fissuras por meio do processamento de imagens

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre em Ciência e Tecnologia de Sementes, Programa de Pós-Graduação em Ciência e Tecnologia de Sementes, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas.

Data da Defesa:

Banca examinadora:

**Prof. Dr. Francisco Amaral Villela
(Orientador)**

Doutor em Fitotecnia pela Universidade Estadual de São Paulo - USP

Profa. Dra. Gizele Ingrid Gadotti

Doutora em Ciência e Tecnologia de Sementes pela Universidade Federal de Pelotas - UFPel

Prof. Dr. Adamo de Souza Araújo

Doutor em Ciência e Tecnologia de Sementes pela Universidade Federal de Pelotas - UFPel

Prof. Dr. Marcelo Lemos Rossi

Doutor em Engenharia Elétrica pela Universidade Federal de Uberlândia

Agradecimentos

À minha mãe, a “pequena Eva” por todo o apoio, pela grande paciência, cuidado, preocupação e os sacrifícios, provavelmente, sem essa colaboração, essa “odisseia estudantil” novamente teria sido bem mais difícil.

Ao meu orientador professor Francisco Villela, meu orientador a quem agradeço pela acolhida, pela oportunidade compartilhar de seus ensinamentos e por toda sua disponibilidade.

À minha coorientadora professora Gizele obrigada pelas oportunidades, por apoiar minhas ideias e principalmente por sempre acreditar no meu potencial mesmo quando estou desacreditada.

Ao professor Marcelo Rossi pela ajuda e contribuição durante o desenvolvimento do trabalho.

À Universidade Federal de Pelotas que faz parte da minha vida desde que eu nasci.

Ao Programa de Pós-graduação em Ciência e Tecnologia de Sementes pela oportunidade e por todo o conhecimento adquirido.

Ao Laboratório de Agrotecnologia (Prédio 33) ao qual sempre farei parte e levarei comigo, e aos amigos que tive a oportunidade de fazer durante esse período.

Aos meus amigos, seria injusto citar nomes, pois posso esquecer alguém, gostaria de agradecer o apoio, o incentivo e torcida e por sempre comemorarem as minhas vitórias como se fossem as suas.

Aos meus pequenos Lorenzo e Vicente, Analu e Cecília, cada vez que vejo vocês é um incentivo para que me torne uma pessoa melhor e eu corra atrás dos meus objetivos.

Resumo

MONTEIRO, Rita de Cassia Mota. **Métodos de identificação para separação de sementes de arroz quanto à diferença de pigmentação, dimensões e fissuras por meio do processamento de imagens** . 2022. 71f. Dissertação (Mestrado em Ciências) – Programa de Pós-graduação em Ciência e Tecnologia de Sementes, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, Pelotas, 2021.

Para avaliação das fissuras foram utilizadas amostras de três lotes de sementes de arroz, um lote contendo semente úmida, não submetida à secagem (semente com casca) e dois lotes submetidos à secagem, um contendo semente com casca e outro contendo semente sem casca, cada amostra contendo 100 sementes. Foram captadas imagens em formatos de raio X e RGB, na sequência processadas no software ImageJ - FIJI e introduzidas no software de aprendizagem de máquina, onde foram pré-processados com a utilização dos filtros adequados e depois classificadas por meio dos classificadores J48 e LDA. As imagens de raio X utilizando equipamento diferenciado permitem identificar fissuras em sementes de arroz pela utilização de técnicas de processamento de imagens e do classificador LDA. Além disso, a captura de imagens por RGB constitui-se em alternativa viável. A utilização dos filtros de forma individual ou em combinação pode consistir numa adequada alternativa para a classificação de sementes de arroz. Para a separação de sementes de arroz vermelho e preto de sementes de arroz branco, a componente de cor mais adequada é a escala de vermelho. Por outro lado, para sementes de arroz preto e vermelho a resposta mais eficiente é obtida com a escala de azul. Para as diferenças de dimensões entre sementes é possível utilizar técnicas de processamento de imagens, sendo que as relações de comprimento e largura são as mais promissoras para alcançar maior eficiência do processo, com precisão de 72 e 73%, respectivamente.

Palavra-Chave: *Oryza sativa* L., RGB, Aprendizado de máquina, Imagens.

Abstract

MONTEIRO, Rita de Cassia Mota. **Identification methods for rice seed separation regarding the difference in pigmentation, dimensions and fissures through image processing.** 2022. 71f. Dissertação (Mestrado em Ciências) – Programa de Pós-graduação em Ciência e Tecnologia de Sementes, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, Pelotas, 2021.

For fissure evaluation, samples of three lots of rice seeds were used, a lot containing moist seed not subjected to drying (peeled seed) and two lots submitted to drying, a seed with peel and another containing seedless seed, each Sample containing 100 seeds. Images in X-ray and RGB formats were provided in the sequence processed in the ImageJ - FIJI software and introduced in the machine learning software, where they were pre-processed using the appropriate filters and then classified through the J48 and LDA classifiers. X-ray images using differentiated equipment allow identifying cracks in rice seeds by using image processing techniques and the LDA classifier. In addition, the capture of images by RGB is a viable alternative. The use of filters individually or in combination may consist of an adequate alternative for rice seed classification. For red and black rice seed separation of white rice seeds, the most suitable color component is the scale of red. On the other hand, the most efficient response is obtained with the blue scale for black and red rice seeds. It is possible to use image processing techniques for the differences in seeds, and the length and width ratios are the most promising to achieve greater process efficiency, accurately from 72 and 73%, respectively.

Keyword: Oryza sativa L., RGB, Machine Learning, Images.

Lista de Figuras

Figura 1	Diagrama do processamento de imagem em raio x e RGB para verificação de fissuras em sementes de arroz	22
Figura 2	Equipamento de Raio X e amostra de sementes em placa de vidro.....	23
Figura 3	Identificação de fissuras nas sementes em imagem RGB	24
Figura 4	Sequência do processo de obtenção das fissuras no arroz sem casca através de imagens de raio X	25
Figura 5	Fissuras visualizadas após processamento de imagem em sementes de arroz sem casca e secas capturas por raio X.	28
Figura 6	Fissuras visualizadas após processamento de imagem em sementes de arroz com casca e sem secagem capturas por Raio X, duas fissuras (a), uma fissura (b) e sem fissuras (c), respectivamente.....	29
Figura 7	Matriz de confusão para os algoritmos J48 e LDA para imagens obtidas por meio do raio X	32
Figura 8	Matriz de confusão para os algoritmos J48 e LDA para imagens obtidas por meio de RGB – Adjust e Binary.	34
Figura 9	Imagem representativa de sementes de arroz a) branco - b) preto - c) vermelho.....	40
Figura 10	Fluxograma de separação das sementes de arroz, captura e processamento das imagens e procedimento estatístico.....	42
Figura 11	Obtenção da medida de espessura da semente de arroz.....	43
Figura 13	Classificação das sementes de arroz quanto as suas dimensões.....	44
Figura 13	Média dos valores máximos e mínimos da componente cinza para cada pigmento de arroz em mm.....	47
Figura 14	Árvore de decisão J48 largura e espessura entre os pigmentos de sementes de arroz.	51
Figura 15	– Matriz de confusão para largura e espessura com os dados de treinamento.	54
Figura 16	Matriz de confusão para largura e comprimento com dados para treinamento	55
Figura 17	Matriz de confusão para largura e espessura com os dados para teste.	55
Figura 18	Matriz de confusão para largura e comprimento com os dados para teste.	56

Lista de Tabelas

Tabela 1	Número de imagens capturadas e sua classificação quanto a presença ou não de fissuras.....	26
Tabela 2	Filtros analisados	27
Tabela 3	Combinações entre filtros.....	27
Tabela 4	Número de sementes analisadas por amostra e porcentagem de fissuras (%) obtida através de diferentes filtros e tratamentos de sementes de arroz.....	29
Tabela 5	Medidas avaliadas através da matriz de confusão.....	45
Tabela 6	Comparação entre as médias (%) do total de pixels das sementes de arroz branco, vermelho e preto em função das escalas de cores em oito bits	46
Tabela 7	Médias das dimensões das sementes	49
Tabela 8	Acuracia e média dos atributos obtidos através dos classificadores em %.....	53

Sumário

1 Projeto de Pesquisa.....	12
1.1 Introdução.....	13
1.2 Objetivos e metas.....	14
1.2.1 Objetivo geral.....	14
1.2.1 Objetivos específicos.....	14
1.3 Material e Métodos.....	15
1.3.1 Obtenção das amostras.....	15
1.3.2 Obtenção dos resultados.....	16
1.4 Cronograma do Projeto.....	17
2. Artigo 1.....	18
2.1 INTRODUÇÃO.....	19
2.2 MATERIAL E MÉTODOS.....	21
2.2.1 Avaliação das fissuras.....	23
2.2.2 Captura da imagem em RGB.....	23
2.2.3 Captura da imagem de raio X.....	23
2.3 Processamento das imagens.....	24
2.3.1 Imagens em RGB.....	24
2.3.2 Imagens em raio X.....	25
2.3.3 Aprendizado de máquina.....	26
3. RESULTADOS E DISCUSSÃO.....	27
4. CONCLUSÃO.....	36
5. Artigo 2.....	37
5.1 Introdução.....	38
5.2 Material e métodos.....	40
5.2.1 Captura da imagem em RGB.....	40
5.2.2 Obtenção dos resultados.....	43

5.3 Resultados e discussão.....	46
5.4. Conclusões.....	57
6. Considerações finais.....	57
Referências.....	58
Apêndices.....	69
Apêndice A.....	70
Apêndice B.....	71
Apêndice C	72

1. Projeto de Pesquisa

PRPPG – Pró-Reitoria de Pesquisa e Pós-Graduação. Aprovado pelo COCEPE em 25/6/2021 nº. 4434, parte do projeto intitulado Aprendizado de Máquina e Inteligência Artificial no Controle de Qualidade de Sementes.

Métodos de identificação para separação de sementes de arroz quanto à diferença de pigmentação, dimensões e fissuras por meio do processamento de imagens

Equipe

Rita de Cassia Mota Monteiro

Francisco Amaral Villela

Gizele Ingrid Gadotti

1.1 Introdução

A espécie *Oryza sativa* L. tem cultivo caracterizado como gramínea anual, que possui a facilidade de se adaptar a ambientes aquáticos por possuir aerênquima, um tecido parenquimatoso formado por células infladas ou grandes espaços, no colmo e nas raízes das plantas, o que permite a passagem do ar para a rizosfera (SOSBAI, 2018). A pálea e lema são as partes que constituem a casca do arroz, normalmente retiradas no beneficiamento. Elas envolvem a cariopse, conhecida como fruto-semente, que reveste a semente ligada ao pericarpo que é uma membrana que circunda o fruto (GUIMARÃES, FAGERIA, BARBOSA, 2002; SWAROWSKY; ASSMANN, 2016).

A qualidade da semente é definida no campo de produção, entretanto o período de armazenamento é crucial na produção de sementes de alto vigor (PESKE; VILLELA e GADOTTI, 2019). Preservar a qualidade fisiológica das sementes contribui para o alto desempenho agrônômico.

O arroz vermelho e o arroz preto são caracterizados pela coloração do pericarpo. Possuem a capacidade de adequar-se ao campo dificultando sua identificação devido a alteração da sua cor e formato tornando-se semelhante às sementes de arroz branco cultivadas contribuindo para as perdas na lavoura (NOLDIN *et al.*, 2004, DRUM; SILVA, 2017).

A fissura origina-se quando a superfície se expande pela sorção da água do interior das sementes ou de ambos ocasionando assim uma ruptura superficial. A sua causa pode ser o processo de secagem artificial, onde a qualidade da semente pode ser reduzida se a mesma for exposta a condições adversas, tornando-as mais vulneráveis à quebra durante o processo de beneficiamento (OLIVEIRA; ROSA; CARVALHO, 2021).

A utilização de sementes de alta qualidade influencia no rendimento da colheita, aumentando a produtividade (TAVARES *et al.*, 2013; SILVA *et al.*, 2016; BAGATELI *et al.*, 2019). É possível contribuir para aumentar a qualidade das sementes, evitando a presença de sementes com fissuras e de outras espécies de arroz como vermelho ou preto.

A identificação e classificação das sementes é realizada de maneira visual necessitando de tempo hábil, treinamento específico e, muitas vezes, custos elevados (FRANÇA-SILVA *et al.*, 2020). A necessidade do setor sementeiro de

utilizar métodos mais precisos que permitam tomadas decisões de forma mais rápida, principalmente ao se trabalhar com grandes lotes, fazem com que a indústria invista em novas técnicas automatizadas e não destrutivas capazes de auxiliar no controle de qualidade das sementes durante o processo de pós-colheita (RAZAVI *et al.*, 2010; PATRÍCIO; RIEDER, 2018; NIXON; BURNS, 2018; FRIGAU *et al.*, 2019).

Em busca de novas técnicas surgem novas alternativas para a indústria como o teste de raio X, processamento de imagens (PDI) e aprendizado de máquinas (AP). Dessa forma, nos últimos anos, o interesse pelo uso de algoritmos com pré-processamentos apropriados visando tornar possível um sistema com características de qualidades específicas dos produtos vem tornando-se de grande importância e utilidade para as indústrias.

O presente trabalho tem como objetivo identificar as diferenças por meio do processamento de imagens e aprendizado de máquinas para separação de sementes de arroz quanto à pigmentação, dimensões e fissuras.

1.2 Objetivos e metas

1.2.1 Objetivo geral

Os objetivos deste trabalho serão avaliar a componente de cor que pode ser utilizada na separação de sementes de arroz vermelho e preto de lotes de sementes de arroz pelo uso de imagens RGB, verificando assim a viabilidade de seu emprego na seleção óptica mecanizada, como operação de beneficiamento e identificar a separação por meio de diferença de dimensões pelo emprego de técnicas de RGB e aprendizado de máquinas. Além disso, visa avaliar a identificação de fissuras em sementes de arroz em casca e descascadas pelo uso de técnicas de raio X e RGB. Em ambos os casos, após a identificação por meio de imagens, será utilizada a técnica de aprendizado de máquinas.

1.2.2 Objetivos específicos

I - Estabelecer diferentes componentes do sistema de cor vermelho, verde e azul para a separação de sementes de arroz vermelho e preto, a separação de sementes por meio de diferenças entre as dimensões.

II - Identificar fissuras em sementes de arroz com utilização do processamento de imagens e do aprendizado de máquinas;

III - Avaliar a eficiência das ferramentas desenvolvidas mediante uso de aprendizado de máquinas para a categorização de lotes de sementes;

IV - Operacionalizar processos com uso de técnicas de aprendizado de máquinas;

V - Verificar a viabilidade do processo durante a separação de sementes.

1.3 Material e Métodos

O presente trabalho será conduzido no Laboratório de Agrotecnologia, da Universidade Federal de Pelotas, Campus Capão do Leão, Pelotas-RS.

1.3.1 Obtenção das amostras

Para a execução das análises de danos em sementes serão utilizadas amostras representativas de lotes de sementes com diferentes tipos e níveis de danos, sendo as sementes separadas manualmente, obtendo-se os diferentes tratamentos. Essa separação será realizada pelo mesmo operador, empregando a mesma técnica, para minimizar a ocorrência de erros sistemáticos. Neste trabalho serão utilizadas sementes de arroz. As imagens serão digitalizadas empregando um escâner com um fundo de Etil Vinil Acetato (EVA) nas cores preta e azul, com dimensões de 22x30 cm, onde será delimitada uma área de 11x11cm devido ao tamanho das amostras, junto com uma grade quadriculada do mesmo material, cada quadriculado com dimensões de 2x2cm com o intuito de analisar as sementes de arroz de forma individualizada. Entre as possíveis técnicas de aquisição das imagens a escolha do escâner foi a mais indicada, pois além de evitar a presença de sombras que podem dificultar na hora do processamento, as imagens de várias sementes podem ser capturadas simultaneamente. As imagens serão capturadas em RGB (vermelho-verde-azul) e depois processadas. As imagens escaneadas serão processadas no software ImageJ - FIJI (Schindelin *et al.*, 2012), sendo esse um software livre, que terá a função de verificar qual das faixas de cores apresentará maior facilidade de separação das sementes, para futuro uso em equipamentos de seleção por cor em unidades de beneficiamento.

Para isso serão gerados histogramas e, por meio destes, verificadas as maiores diferenças de tonalidade e, portanto, identificadas as tonalidades mais eficientes para a separação das sementes. Nos casos de a cor não ter sido

suficiente para tal separação, será usado o Software ImageJ - FIJI e filtros para a separação.

1.3.2 Obtenção dos resultados

Na sequência serão realizadas as análises estatísticas descritivas exploratórias, visando à obtenção de maior quantidade possível de informações por meio dos dados. Os dados coletados serão submetidos à análise de variância ($p = 0,05$) e depois comparados pelo teste de Tukey em nível de probabilidade de 5%. Serão obtidos dados estatísticos que relacionados permitirão refletir às propriedades físicas da área de pixels das imagens, além dos gráficos de histograma de frequência, frequência acumulada e utilização das médias com intervalo de confiança.

Os resultados obtidos por meio das imagens serão classificados de acordo com separação e depois introduzidos em *softwares* de mineração de dados. No caso da separação por dimensões será utilizado o *Google Colaboratory* e para a separação das fissuras será utilizado o Weka (Eibe; Mark; Ian, 2016). Na sequência será realizado o pré-processamento, sendo os dados divididos em arquivo de treinamento e de teste. Os classificadores utilizados serão *Decision Tree* (J48) tem como objetivo a construção de um modelo do valor de um alvo variável pela tomada de decisão a partir dos dados e *Linear Discriminant* (LDA) que tem como finalidade reduzir a dimensionalidade das características espectrais (originalmente 256) no conjunto de dados maximizando a classificação. Para a classificação das fissuras além do J48 foi utilizado o *NaiveBayes*, onde é possível presumir a independência entre os atributos dos dados empregando probabilidade, com a finalidade de melhor apresentar o resultado esperado para sua avaliação para separação das sementes quanto às dimensões (LI *et al.*, 2018, THARWAT; GABER; IBRAHIM; HASSANIEN, 2017; HARRISON, 2019).

O resultado será obtido por meio de médias das precisões que correspondem ao desempenho sobre o conjunto de dados fornecido. Essa técnica auxiliará a reduzir a probabilidade de que coincidências subavaliem ou sobreavaliem o desempenho para uma determinada configuração. Todos os resultados reportados neste trabalho utilizarão essa técnica.

1.4 Cronograma do Projeto

Atividades	Ano 2021			Ano 2022
	abr-jun	jul-set	out-dez	jan-fev
Revisão de literatura	X	X	X	X
Seleção dos lotes	X			
Aquisição das imagens (raio-x)	X	X		
Aquisição das imagens (escaneadas)	X	X		
Introdução das Imagens no software	X	X		
Análise estatística		X		
Classificação dos resultados		X	X	
Mineração dos dados		X	X	
Interpretação dos dados		X	X	X
Redação da dissertação		X	X	X
Elaboração dos artigos		X	X	X

2. Artigo 1

Revista: Engenharia Agrícola

MÉTODOS DE IDENTIFICAÇÃO DE FISSURAS EM SEMENTES DE ARROZ APÓS A SECAGEM ARTIFICIAL

RESUMO: A crescente busca por novas técnicas eficientes, com baixo custo tornam o processamento de imagens e a aprendizagem de máquina alternativas para o beneficiamento de sementes. O objetivo deste trabalho foi identificar fissuras em sementes de arroz em casca e descascadas com o uso de técnicas de raio X e RGB e aprendizado de máquina. Foram utilizadas amostras de três lotes de sementes de arroz, um lote contendo semente úmida, não submetida à secagem (semente com casca) e dois lotes submetidos à secagem, um contendo semente com casca e outro contendo semente sem casca, cada amostra apresentando 100 sementes. Foram captadas imagens em formatos de raio X e RGB, na sequência processadas no software ImageJ e introduzidas no software de aprendizagem de máquina onde foram pré-processados com a utilização dos filtros adequados e depois classificadas por meio dos classificadores J48 e LDA. As imagens de raio X utilizando equipamento diferenciado permitem identificar fissuras em sementes de arroz pela utilização de técnicas de processamento de imagens e do classificador LDA. Além disso, a captura de imagens por RGB constitui-se em alternativa viável. A utilização dos filtros de forma individual ou em combinação pode constituir-se numa adequada alternativa para a classificação de sementes de arroz.

PALAVRAS-CHAVE: Aprendizado de máquina, Imagens, RGB, Raio X

FISSURE IDENTIFICATION METHODS IN RICE SEEDS AFTER ARTIFICIAL DRYING

ABSTRACT: The growing search for new efficient, low-cost techniques make image processing and alternative machine learning for seed processing. The objective of this work was to identify fissures in bark and peeled rice seeds using X-ray and RGB techniques and machine learning. Samples of three lots of rice seeds, a lot was containing

moist seed, not subjected to drying (peeled seed) and two lots submitted to dry, one contained seed with peel and another containing seedless seed, each sample presenting 100 seeds. Images in X-ray and RGB formats were provided in the sequence processed in the ImageJ software and introduced in the machine learning software, where they have been pre-processed using the appropriate filters and then classified by the J48 and LDA classifiers. X-ray images using differentiated equipment allow identifying cracks in rice seeds by using image processing techniques and the LDA classifier. In addition, the capture of images by RGB is a viable alternative. The use of filters individually or in combination may constitute an adequate alternative for rice seed classification.

KEYWORDS: Machine Learning, Images, RGB, X-ray

2.1 INTRODUÇÃO

Há no Brasil uma cultura comercial que arroz de qualidade é o arroz longo, branco translúcido e sem impurezas. Para esse padrão ser obtido, as etapas de beneficiamento apresentaram evolução. Conta-se atualmente com máquinas modernas e eficientes para o alcance dessa qualidade (Monteiro et al., 2019).

O uso de processamento de imagens em sementes ainda é pouco utilizado, mesmo que a técnica já se encontre nas Regras para Análise de Sementes (Brasil, 2009).

Os primeiros trabalhos com raio X em sementes ocorreram em sementes de espécies florestais com Stark & Adams (1963) e Kamra (1976) e em tomate com Burg et al. (1994). Menezes et al. (2005) identificaram com eficiência fissuras em sementes de arroz por meio de raio X, no entanto, com o uso de um equipamento de acesso não muito fácil e de custo elevado.

O teste de raio X tem a finalidade de verificar possíveis avarias como a presença de anomalias internas e insetos, danos mecânicos internos e sementes vazias na morfologia

interna. Embora não seja considerado um teste de viabilidade, os resultados adquiridos são relevantes para a avaliação da viabilidade dos lotes de forma rápida e precisa. A técnica busca absorver por meio de ondas eletromagnéticas distintas camadas de tecidos das sementes de acordo com sua densidade, sendo indicada para sementes que apresentam tegumentos mais rígidos (Elias et al., 2012).

O uso em grande escala de um equipamento de raio X e seu custo inviabiliza a utilização desta técnica em escala comercial. Além disso, haveria a necessidade de treinamento especializado e o resíduo gerado é uma problemática ambiental.

O processamento de imagens em RGB (escala vermelha, verde e azul) é uma técnica simples de captura de imagem. Monteiro et al. (2019) trabalharam com defeitos em grãos arroz como: gessado, marinheiro, ardido e manchado e picado, tendo eficiência em RGB, embora não tenham trabalhado com fissuras. Em outras espécies, como soja, foi utilizado para a detecção de sementes esverdeadas e com dano por umidade (Monteiro et al., 2021).

O aprendizado de máquina (AP) também pode ser utilizado como ferramenta de uso em tarefas diárias. Seu princípio é composto por um campo da ciência da computação e um ramo central da inteligência artificial (IA) expressando seus resultados de forma estatística. O AP tem como característica o aprendizado automatizado, ou seja, sem a necessidade de orientações e regulações, facilitando a habilidade de aprendizado com os seus resultados e algoritmos antigos (Pooja et al., 2018). A aplicação da técnica no setor agrícola pode vir a contribuir, favorecendo e aprimorando recursos e equipamentos utilizados. Seu entendimento torna-se necessário para o desenvolvimento do setor pelo emprego de técnicas robustas, eficazes e viáveis (Talaviya et al., 2020).

Por se tratar de duas técnicas não destrutivas, a combinação do processamento de imagens com inteligência artificial tende a facilitar e contribuir de forma positiva para o setor sementeiro, porém ainda há a necessidade de mais estudos relacionados ao assunto

(Pinheiro et al., 2021). Dessa forma, nos últimos anos o interesse pelo uso de algoritmos com pré-processamentos apropriados visando tornar possível um sistema com características de qualidades específicas dos produtos vem tornando-se de grande importância e utilidade para as indústrias.

O presente trabalho tem como objetivo identificar fissuras em sementes de arroz em casca e descascadas com o uso de técnicas de raio X e RGB e aprendizado de máquina.

2.2 MATERIAL E MÉTODOS

O presente trabalho foi conduzido na Universidade Federal de Pelotas, Campus Capão do Leão, Pelotas-RS, no Laboratório de Agrotecnologia. Foram utilizadas amostras de três lotes de sementes de arroz, um lote contendo semente úmida, não submetida à secagem (semente com casca) e dois lotes submetidos à secagem, um contendo semente com casca e outro contendo semente sem casca, cada amostra apresentando 100 sementes.

Antes de iniciar a avaliação das fissuras, as três amostras passaram por técnicas de processamento de imagens de raio X e RGB. A Figura 1 ilustra a sequência utilizada no estudo, a partir da chegada das amostras de arroz, nas quais ambas as imagens passaram até a aquisição dos seus resultados.

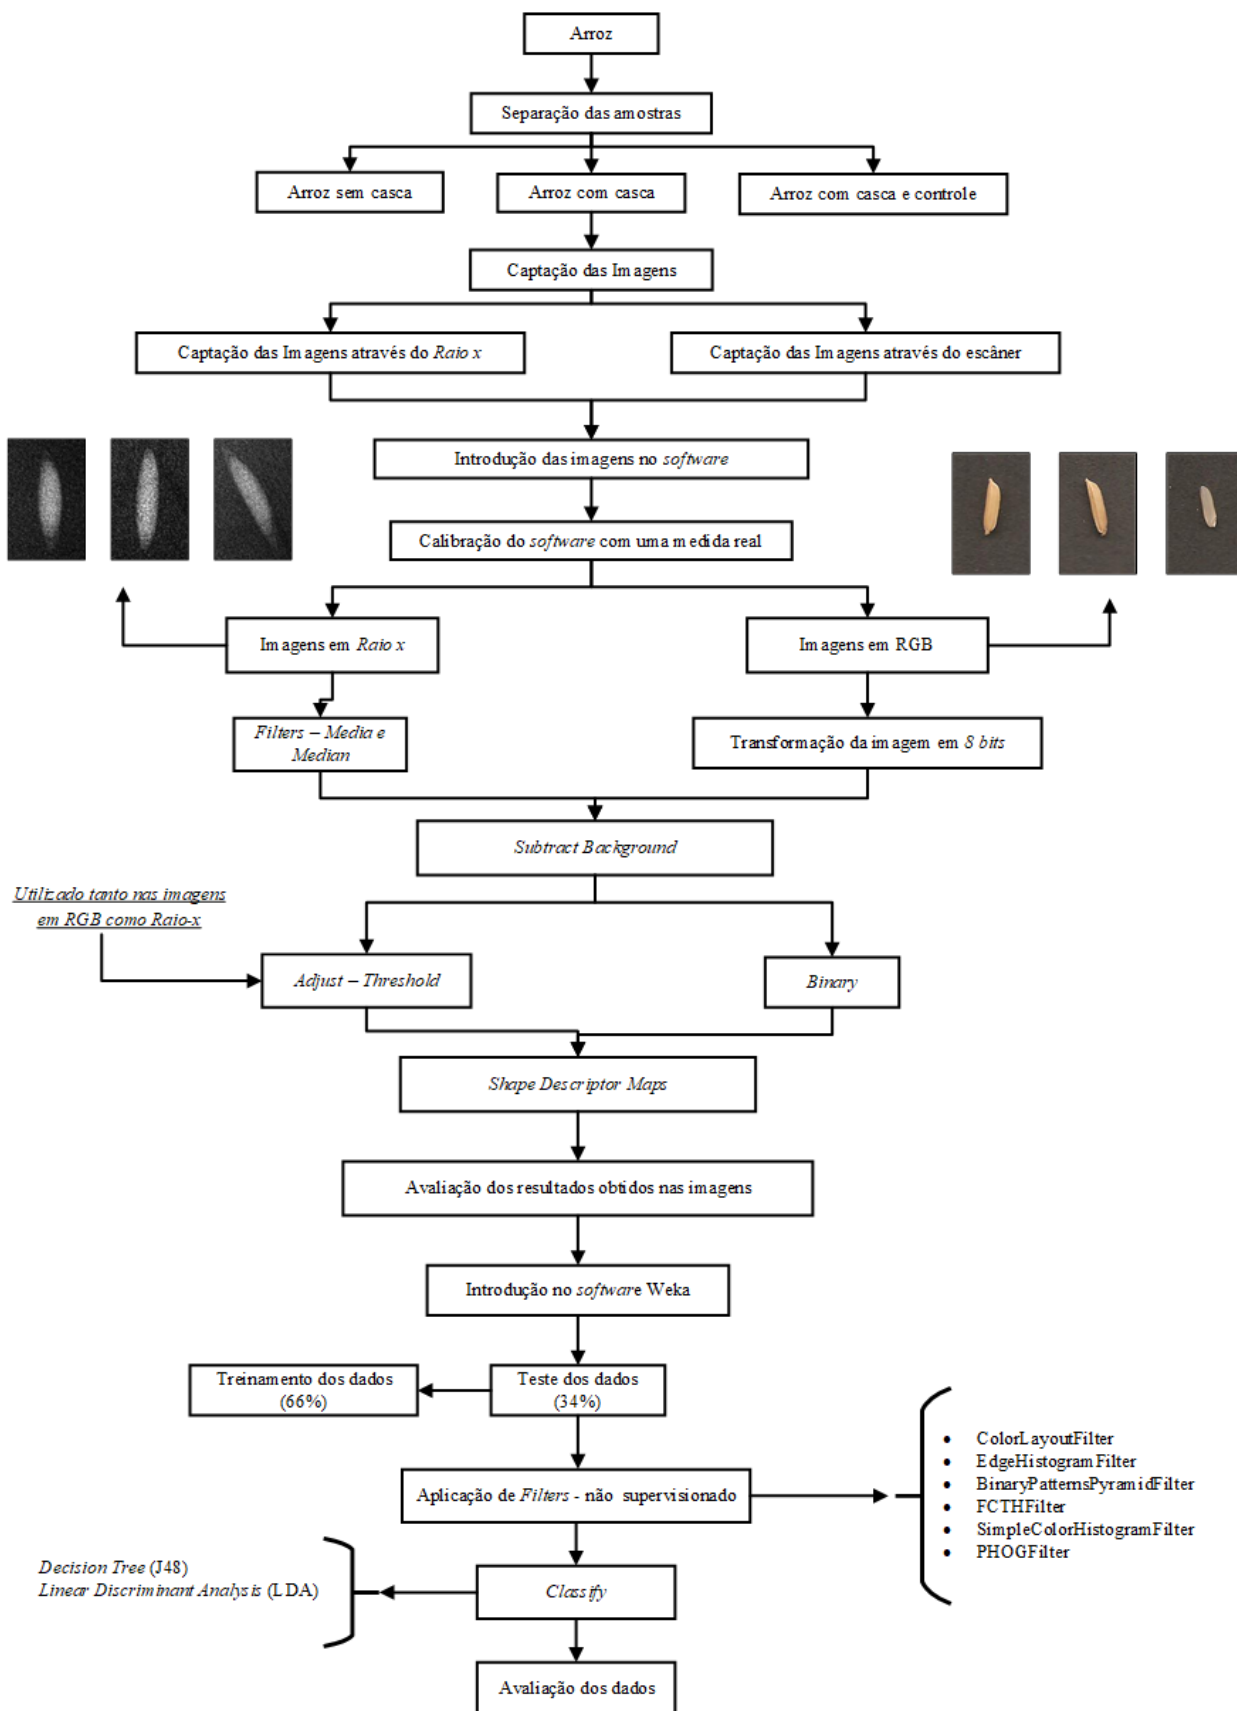


Figura 1. Diagrama do processamento de imagem em raio x e RGB para verificação de fissuras em sementes de arroz. Figure 1. Diagram of image processing in x-ray and RGB for verification of cracks in rice seeds.

2.2.1 Avaliação das fissuras

O índice de fissuras foi determinado segundo a metodologia proposta por Cnossen et al. (2003), em quadruplicada, avaliando-se 25 grãos inteiros, em cada repetição, para cada ensaio. Com auxílio de uma caixa de luz com paredes e fundo escuro, com tampa de vidro, verificou-se visualmente a existência de fissuras internas nos grãos, contabilizando-se o número total de grãos com fissuras e expressando-o em porcentagem.

2.2.2 Captura da imagem em RGB

As imagens em RGB foram captadas por meio de um escâner (modelo *HP Photosmart C3180 All-in-One Printer*), delimitado com fundo de EVA (*Etil Vinil Acetato*) na cor preta, com as dimensões de 22 x 30cm junto com uma grade quadriculada do mesmo material, cada quadrícula nas dimensões de 2 x 2cm com o intuito de analisar a semente de arroz de forma individual.

2.2.3 Captura da imagem de raio X

As imagens foram obtidas em equipamento de raio X odontológico Procion ion 70x coluna móvel, capaz de emitir radiação ionizante proveniente de um tubo eletrônico que contém anodo, catodo e filamento, o qual pode produzir e realizar a emissão de raios X com uma intensidade de 70 kVp e corrente elétrica do tubo de 8 mA. Amostras de 100 sementes foram distribuídas em placas de vidro com células individualizadas (Figura 2).



Figura 2. Equipamento de Raio X e amostra de sementes em placa de vidro. Figure 2. X-ray equipment and sample of seeds on glass plate.

Durante a exposição, a placa de vidro foi sobreposta ao sensor digital placa de fósforo (Acteon MicroImagem, 31x41mm) sobre a fonte de raios X. Testes preliminares realizados permitiram estabelecer o tempo de exposição de 45s a ser utilizado, conforme testes preliminares realizados que permitiram estabelecer o mesmo.

2.3 Processamento das imagens

2.3.1 Imagens em RGB

Na sequência, as imagens foram importadas para o software ImageJ, utilizado para processamento e extração de informações de imagens RGB. Com a finalidade de individualizar as sementes foi utilizada uma grade de medição EVA 2 × 2 cm. A leitura de pixels EVA não atrapalhou o processamento de imagens no software; as imagens foram tratadas com a ferramenta de limiar, eliminando suas variações. Por meio da visualização das imagens ampliadas, a classificação das sementes foi realizada por meio da análise do número de fissuras por semente: uma ou duas fissuras (Figura 3).




Figura 3. Identificação de fissuras nas sementes em imagem RGB. Figure 3. Identification of fissures in the seeds in RGB image.

Com o auxílio do *software* ImageJ- FIJI (Schindelin et al., 2012) e sua ferramenta de seleção de pixels, foram feitas múltiplas seleções nas imagens, estabelecendo a região correta do interesse (ROI) no centro de cada imagem. Para isso, os quadros de cada imagem foram recortados com retângulos de 2,25 x 4,10 cm com o intuito de duplicar a

imagem e aproximá-la para captura de detalhes. Esse processo foi feito para aumentar a eficiência na execução das etapas seguintes.

Para extrair as informações, foi necessário modificar a imagem RGB em oito bits, transformando-a em tons de cinza, contendo 256 tons possíveis, variando de zero (preto absoluto) a 255 (branco absoluto). A binarização da imagem foi necessária para que as sementes pudessem ser identificadas individualmente, representadas por um contorno e um número, auxiliando na obtenção de diversas características como área projetada no plano, perímetro e contagem de pixels em cada uma das regiões identificadas, conforme o interesse do trabalho. Após a transformação da imagem, foi realizada a etapa a segmentação através do comando de pré-processamento denominados *adjust threshold* com a finalidade de definir os valores de limite inferior e superior segmentando imagens em escala cinza em recursos de interesse e de fundo e *binary* com a função de converter uma imagem em preto e branco (Ferreira & Rasband, 2011). Nessa etapa, cada imagem foi dividida em duas ou mais classes de pixels (imagem binária). Com isso, as imagens foram analisadas pixel a pixel, obtendo-se assim o valor total de pixels em cada semente, separando o fundo, classificado como 255 (branco absoluto), do objeto de interesse. Na sequência foi utilizado o comando *Shape Descriptor Maps*, do plug-in *BioVoxxel*, que tem como finalidade contribuir para a identificação de características de acordo com suas propriedades de forma, de maneira visual sendo assim possível verificar as fissuras (Brocher, 2014).

2.3.2 Imagens em raio X

As imagens adquiridas por meio do equipamento de raio X foram digitalizadas e processadas conforme a Figura 4 no *software* ImageJ- FIJI.




Figura 4. Sequência do processo de obtenção das fissuras no arroz sem casca por meio de imagens de raio X. Figure 4. Sequence of the process of obtaining fissures in peellless rice through X-ray images.

Na sequência, as imagens foram introduzidas no *software* ImageJ. A primeira etapa realizada foi a calibração do próprio para a determinação de uma medida real, após foi

delimitado com retângulo com as mesmas dimensões dos utilizados para o processamento de imagens de RGB, com o intuito de duplicar a imagem e aproximá-la para captura de detalhes.

No caso das imagens obtidas por meio do raio X, não foi necessário transformar a imagem em escala de cinza (8 bits) antes da correção de fundo. Foram utilizados os filtros de *Media* que suaviza a imagem atual substituindo cada pixel pela média da vizinhança e o *Median* com objetivo de suavizar a imagem atual, fazendo com que cada pixel fosse substituído pela média do pixels ao redor.

As próximas etapas foram semelhantes às verificadas nas imagens em RGB, ocorrendo os processos de subtração do fundo, com o uso do comando *threshold* para dividir a imagem em classes de *pixels* e depois a utilização do plug-in *BioVoxel*.

Na sequência do processamento de imagens em raio X e RGB, os dados foram analisados por meio do aprendizado de máquinas.

2.3.3 Aprendizado de máquina

Os resultados obtidos por meio das imagens foram utilizados para a base de treinamento por aprendizado de máquina supervisionado, composto por três tipos de sementes classificadas utilizando um atributo. A separação foi realizada de forma visual de acordo com a ocorrência de fissuras nas sementes, havendo a sua presença foi classificada como SIM e não ocorrendo foi classificada como NÃO (Tabela 1).

Sementes de Arroz	Classificação	
	Sim	Não
Sementes sem casca	52	11
Sementes com casca	46	19
Sementes com casca e controle	38	16

Tabela 1. Número de imagens capturadas e sua classificação quanto à presença ou não de fissuras. Table 1. Number of captured images and their classification as to the presence or not of fissure.

Na sequência, os resultados foram inseridos no *software* de mineração de dados denominado Weka (Eibe; Mark; Ian, 2016). Foi realizado um pré-processamento para os

dados de imagem com a finalidade de detectar a presença de alguma imagem que estivesse corrompida, vindo a prejudicar a classificação.

Após foi realizado o uso de filtros. Essa técnica não-supervisionada é realizada por meio de filtros indicados para imagens (Tabela 2) inclusos no pacote *imageFilters*, com o intuito de transformar os valores de intensidade de pixel para obter dados numéricos.

Filtros
ColorLayoutFilter
EdgeHistogramFilter
BinaryPatternsPyramidFilter
FCTHFilter
SimpleColorHistogramFilter
PHOGFilter

Tabela 2. Filtros analisados. Table 2. Analyzed filters.

Na primeira etapa do pré-processamento, os filtros foram avaliados de forma individual e de acordo com os resultados obtidos por meio dos atributos foram realizadas combinações (Tabela 3) entre os mesmos, para ambas as técnicas de processamento de imagens.

Combinações
EdgeHistogramFilter + BinaryPatternsPyramidFilter
EdgeHistogramFilter + FCTHFilter
EdgeHistogramFilter + PHOGFilter
BinaryPatternsPyramidFilde + FCTHFilter
BinaryPatternsPyramidFilde + PHOGFilter
FCTHFilter + PHOGFilter

Tabela 3. Combinações entre filtros. Table 3. Combinations between filters.

Na sucessão, os dados foram analisados empregando os classificadores *Decision Tree* (J48) e *Linear Discriminant Analysis* (LDA), com a finalidade de melhor apresentar o resultado esperado para a avaliação dos resultados obtidos.

3. RESULTADOS E DISCUSSÃO

Foram realizados pré-testes antes da definição da metodologia, um sendo o tempo de exposição para a captura da imagem em raio X.

Arruda et al., (2016) verificaram que análise de imagens radiográficas possibilitou a identificação de danos mecânicos, danos por percevejos e tecidos deteriorados em sementes de *Crotalaria juncea*, com efeitos negativos à germinação.

A identificação das fissuras neste trabalho observou que o processamento de imagem identificou prioritariamente uma, duas ou três fissuras conforme a Figura 5.

Na Figura 5 é possível identificar o processamento de imagem realizado a partir de uma imagem de raio X no qual no tratamento sem casca e seco 81% das imagens possuíam fissuras. A possibilidade de analisar fissuras sem a necessidade de realizar o descascamento faz com que a análise se torne menos morosa e com isso contribua com os laboratórios de qualidade de sementes e de grãos.




Figura 5. Fissuras visualizadas após processamento de imagem em sementes de arroz sem casca e secas capturadas por raio X. Figure 5. Fissures viewed after image processing in peeled rice seeds and dried captures by X-ray.

No tratamento de sementes de arroz com casca e secas, 71% possuem fissuras em imagens de raio X, sendo que 100% do total das fissuras é no endosperma, conforme a classificação de Silva et al. (2014).

No tratamento com casca e sem secagem, 70% das sementes têm fissuras em imagens de raio X. Já era esperado que a secagem causasse mais fissuras em sementes de arroz. Pois a transição vítrea, que pode ocorrer durante a secagem e/ou logo após, durante o período de resfriamento natural dos grãos (têmpera), está diretamente relacionado ao aumento de gradientes de umidade, temperatura e tensão dentro dos grãos, o que pode

causar fissuras (Mukhopadhyay & Siebenmorgen, 2018). Sendo que, novamente 100% das fissuras são no endosperma (Figura 6).

As fissuras do grão de arroz são fraturas ocorridas por estresse que se desenvolvem nas camadas interna ou externa do endosperma do grão, causadas por uma combinação de gradiente de umidade, estresse térmico e mecânico, que podem ocorrer em pré e pós-colheita, particularmente durante o processo de secagem (Tong et al., 2019).



Figura 6. Fissuras visualizadas após processamento de imagem em sementes de arroz com casca e sem secagem capturas por Raio X, duas fissuras (a), uma fissura (b) e sem fissuras (c), respectivamente. Figure 6. Fissures viewed after image processing in rice seeds with peel and without drying captures by X-ray, two fissures (a), one fissure(b) and no fissures (c) respectively.

Na Figura 6 nota-se que não há fissuras transversais, o que pode ser justificado pois houve somente duas operações unitárias: secagem e descascamento. Muito provavelmente, no processamento industrial de grãos de arroz no qual a operação de polimento haverá a possibilidade de fissuras transversais.

Ao analisar as diferentes técnicas, observa-se na Tabela 4 que ao utilizar o filtro *Binary* os resultados obtidos apresentam valores inferiores e os da técnica de raio X, esses com valores superiores em comparação aos demais, independente do filtro.

Sementes	Seca sem casca			Seca com casca			Controle		
	Raio X	Escaneadas		Raio X	Escaneadas		Raio X	Escaneadas	
		Adjust	Binary			Adjust		Binary	
Total	63	70	70	65	88	88	56	88	88
Fissuras	51	35	33	46	35	29	39	26	25
% fissuradas	81	50	47	71	40	33	70	30	28

Tabela 4. Número de sementes analisadas por amostra e porcentagem de fissuras (%) obtida através de diferentes filtros e tratamentos de sementes de arroz. Table 4. Number of seeds analyzed by sample and percentage of fissures (%) obtained through different filters and rice seeds treatments.

Ao analisar as duas técnicas são obtidos os resultados encontrados na Tabela 5, onde a técnica de raio X possui valores absolutos superiores à técnica RGB. Ainda que sementes controle e seca com casca possam possuir a mesma porcentagem de sementes fissuradas, isto seria considerado um equívoco de leitura devido a secagem.

Há uma tendência na técnica de sementes por RGB (escaneadas) que as sementes com casca e não secas (controle) apresentem menos fissuras que as demais. Isso demonstra a realidade do teste por que sementes que passaram por alguma operação unitária possuem maior probabilidade de cisalhamento e conseqüentemente fissuras (Tong et al., 2019).

Tong et al. (2019) discutem que o aquecimento volumétrico com secagem por micro-ondas minimiza a fissura do arroz, mantendo a qualidade do processamento, talvez por uma diferente aglomeração dos grânulos de amido, aumentando assim a resistência dos grãos. Portanto, a captura da imagem por raio X pode causar o mesmo efeito da secagem por microondas e com isso os dados se equiparem às sementes secas (Tabela 5).

Menezes et al. (2012) concluíram que as imagens radiográficas permitem a identificação de fissuras em sementes de arroz secas artificialmente e sua correlação com a porcentagem de plântulas normais e anormais no teste de germinação.

Outro pré-teste, já no pré-processamento das imagens, foi a escolha das combinações dos filtros, podendo-se notar que os filtros `ColorLayoutFilter` e `SimpleColorHistogramFilter` foram eliminados das combinações em razão das baixas respostas.

Tratando-se da utilização de aprendizado de máquina, a aplicação de um filtro significa para cada instância que seus atributos numéricos são adicionados aos dados. Esses atributos têm como finalidade auxiliar na precisão dos algoritmos de classificação de dados (Abidin, 2019).

Nesse caso, os filtros que apresentaram valores de atributos significativos foram os filtros de BinaryPatternsPyramidFilter e PHOGFilter (*Pyramid Histogram of Oriented Gradients*) com valores de 758 e 632, respectivamente que contribuem para a transformação de valores de pixels em valores numéricos. O filtro BinaryPatternsPyramidFilter tem como finalidade gerar histogramas locais onde os padrões de escala maior ocorrem nas regiões das imagens, sendo de bastante utilidade para imagens que apresentam texturas. Já o PHOGFilter consiste em um histograma de gradiente orientação de cada sub-região de imagem de cada nível de resolução (Abidin, 2019).

No caso de utilizar o filtro de forma individual, o mais indicado seria o BinaryPatternsPyramidFilter, porém a combinação dos dois filtros com funções diferentes fez aumentar o número de atributos, para cada instância, de forma que mais regiões fossem avaliadas ao utilizá-los.

Os resultados de fissuras obtidos por meio da aprendizagem de máquina para as imagens de raio X, utilizando os classificadores J48 e LDA, compreenderam 74,60% e 92,06%, respectivamente para sementes sem casca. Para as sementes com casca foram obtidos 83,08% e 90,77% e para as sementes com casca e controle 64,81% e 87,04%. Em todas as avaliações, o classificador LDA apresentou valores superiores, indicando maior eficiência. Os resultados obtidos na classificação realizada por meio das imagens de sementes sem casca em RGB com aplicação das técnicas de *Adjust e Binary* compreendidas, ou seja, a classificação correta empregando os classificadores J48 e LDA foi inferior aos encontrado para as imagens de raio X.

Para a avaliação do desempenho de cada um dos algoritmos de classificação, foram utilizadas as matrizes de confusão (Figura 7) nas imagens de raio X. É possível notar que com a execução dos classificadores J48 e LDA, o segundo apresenta valores superiores

de verdadeiro positivo para todas as classificações de sementes indicando que o modelo de classificação consegue identificar as sementes que realmente apresentam fissuras.

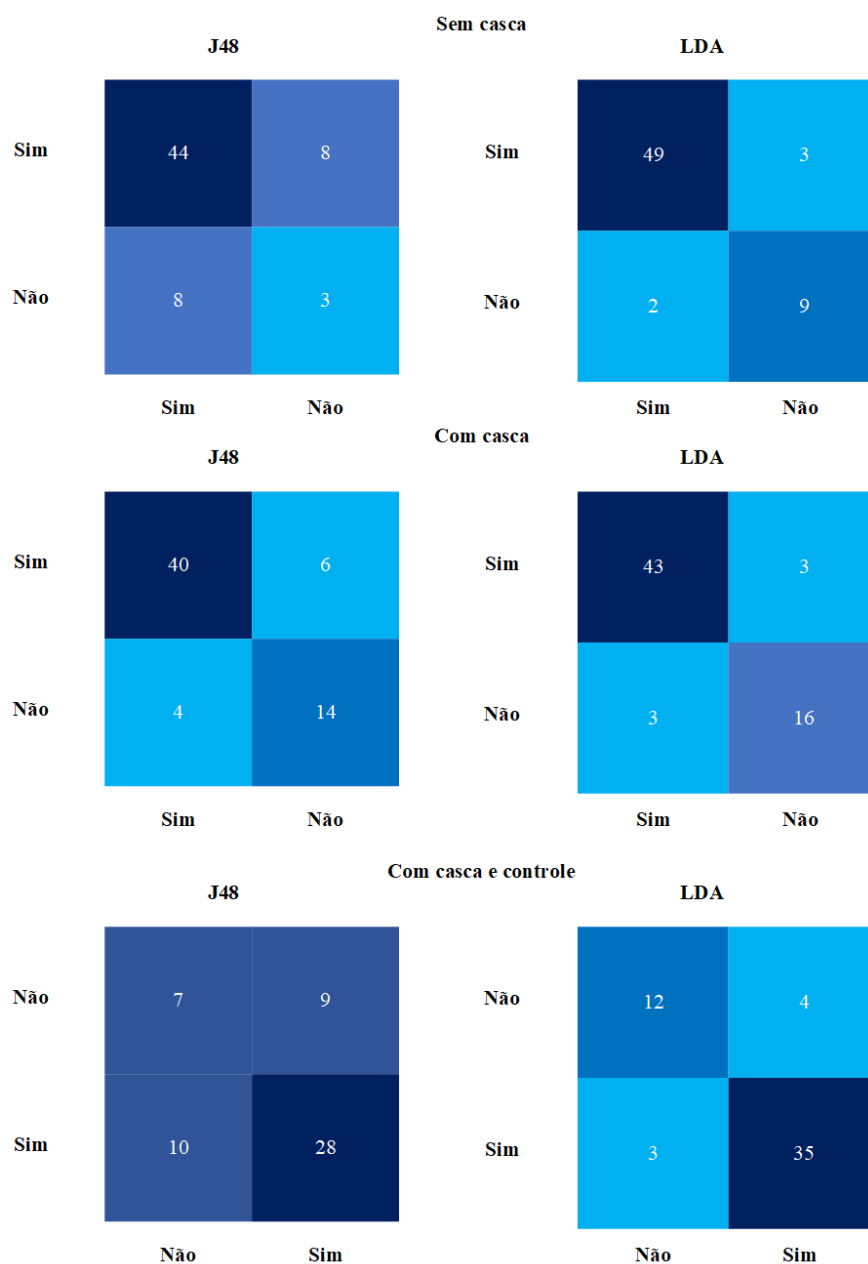


Figura 7. Matriz de confusão para os algoritmos J48 e LDA para imagens obtidas por meio do raio X.
Figure 7. Matrix of confusion for J48 and LDA algorithms for images obtained through X-ray.

Em geral, as sementes sem casca com a utilização do *Binary* apresentaram porcentagens de classificação correta inferiores aos resultados de *Adjust*. Em contrapartida, ao avaliar o desempenho dos algoritmos por meio das matrizes de confusão, é possível notar pelos resultados que a escala azul apresenta resultados

superiores em ambas as classificações, assim como para as sementes com cascas (Figura 8). No caso das sementes com casca e controle, ambas as classificações indicaram maior quantidade de fissuras na escala azul chamando a atenção para o classificador J48.

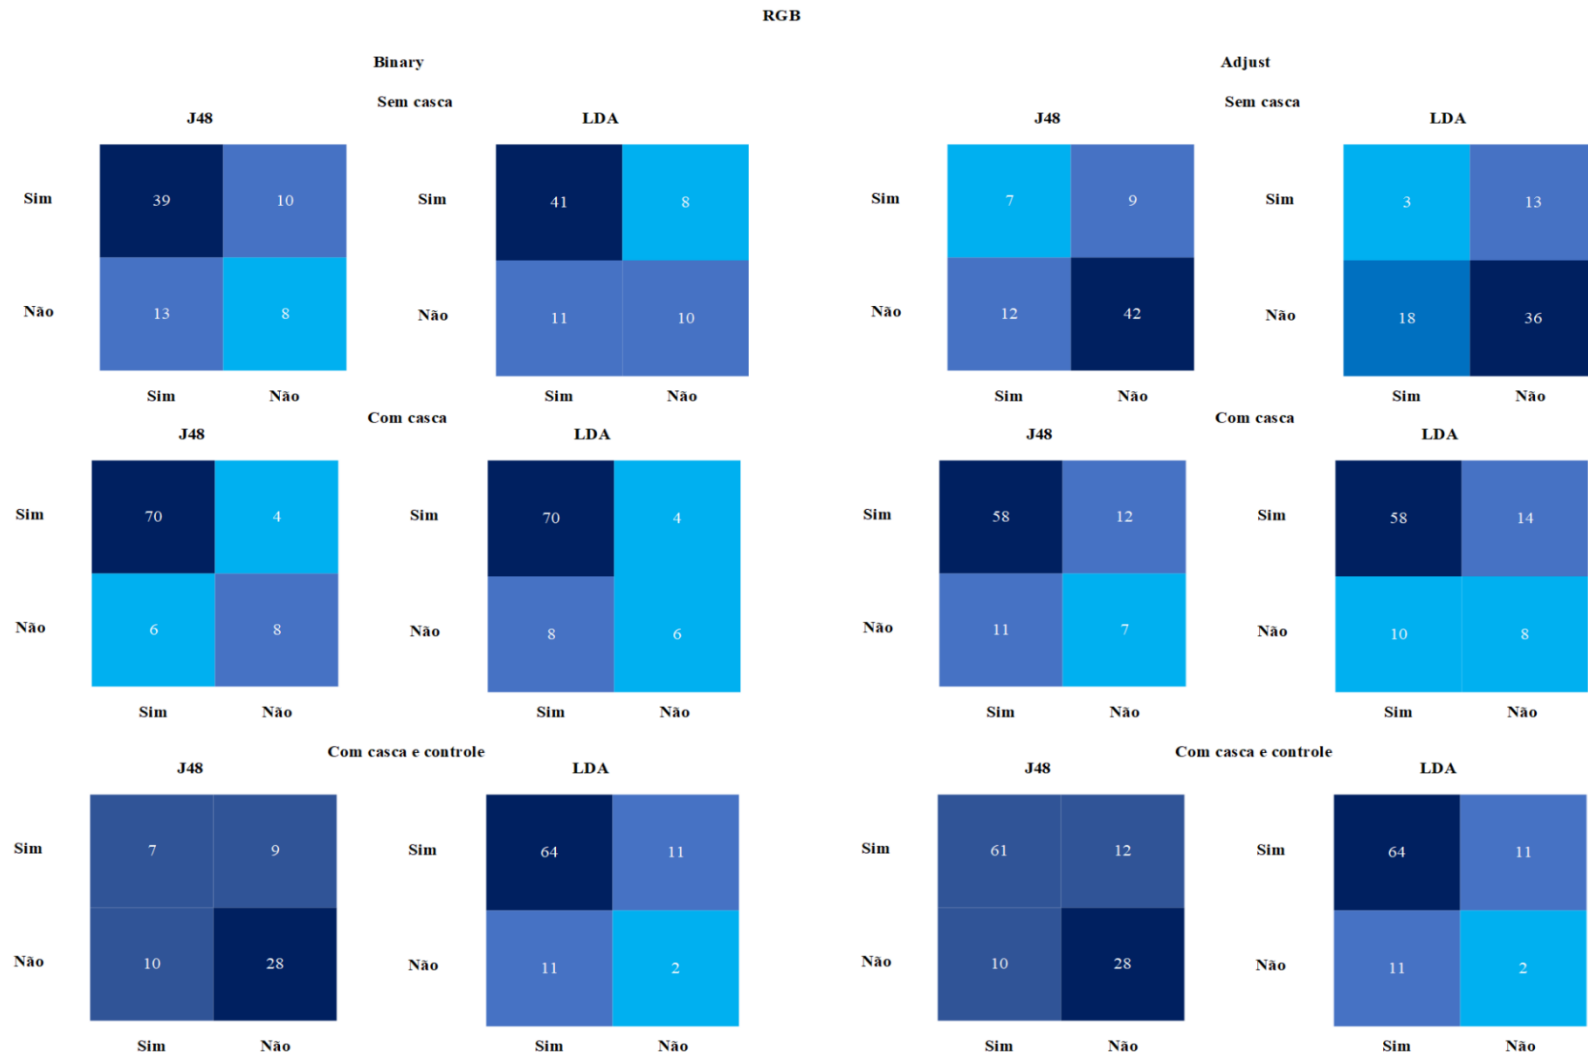


Figura 8 - Matriz de confusão para os algoritmos J48 e LDA para imagens obtidas por meio de RGB – Adjust e Binary. Figure 8 - Confusion matrix for the J48 and LDA algorithms for images obtained by RGB - Adjust and Binary

A escala azul indicou resultados superiores na classificação de todas as sementes avaliadas durante o trabalho, em ambos os classificadores utilizados. Essa mesma escala alcançou resultados satisfatórios no estudo de Monteiro et al. (2019) para avaliar a separação de defeitos de grãos de arroz por meio de imagens RGB, verificando a viabilidade dessa técnica para beneficiamento.

O método de LDA pode ser utilizado para classificação de qualidade de sementes por meio de diferentes características obtidas por imagens (Silva *et al.*, 2021). Em seu estudo, Medeiros et al. (2020a) utilizaram técnicas de aprendizagem de máquina e imagens de raio X para avaliar a capacidade de germinação das sementes de *Jatropha curcas* e sua viabilidade pela combinação das técnicas. Os resultados indicaram que as imagens de raio X são capazes de fornecer informações necessárias para separar as sementes de forma individual, avaliando a qualidade das sementes, enquanto a aprendizagem de máquina é adequada para separar as sementes com alta precisão.

As imagens de raio X alcançaram valores de 96,1% para sementes sem casca, 93,5% para sementes com casca e 80% para sementes com casca e controle. Para distinguir uma amostra com diversidades de grãos de arroz, Nagoda & Ranathinga (2018), para imagens em RGB com a utilização do filtro Local Binary Pattern (LBP), encontraram para os grãos com casca 96,04% e 99,75% para o arroz sem casca. Em ambos os estudos, independente do formato das imagens, a utilização dos filtros apresentou resultados satisfatórios, tornando-se assim alternativa para auxiliar no processo de classificação.

Os resultados de precisão de 81%, 71% e 70% para sementes sem casca, com casca e controle com casca mostraram-se superiores ao trabalho de Shi *et al.* (2019) para imagens de sementes de arroz com casca em raio X onde indicou que a mesma capacidade do algoritmo de visualizar as fissuras com porcentagens variou entre 0-60%.

Estudos com sementes de outras espécies também apresentam resultados que contribuem para a utilização da técnica. Para avaliar sementes de soja de acordo com seu potencial e desempenho fisiológico, Medeiros et al., (2020b) utilizaram técnicas de análise de imagens de métodos interativos e tradicionais com aprendizagem de máquina. Os resultados indicaram que a combinação das técnicas é de alta precisão para a classificação, conseguindo identificar danos, classificar plântulas quanto ao vigor e avaliar a qualidade das sementes.

Este trabalho buscava identificar uma técnica fácil e de baixo custo para o levantamento de fissuras de sementes de arroz. Os resultados alcançados mostraram que a técnica de RGB constitui-se em alternativa viável devido ao baixo custo e reduzida complexidade em comparação ao raio X, conforme observado por Brunes et al. (2016) em trigo, Monteiro et al. (2019) e Brunes et al. (2019) em arroz e Monteiro et al. (2021) em soja.

4. CONCLUSÃO

As imagens de raio X utilizando equipamento diferenciado permitem identificar fissuras em sementes de arroz pela utilização de técnicas de processamento de imagens e do classificador LDA. Além disso, a captura de imagens por RGB constitui-se em alternativa viável.

A utilização dos filtros de forma individual ou em combinação pode constituir-se numa adequada alternativa para a classificação de sementes de arroz.

5. Artigo 2

MÉTODOS DE IDENTIFICAÇÃO POR MEIO DO PROCESSAMENTO DE IMAGENS PARA SEPARAÇÃO DE SEMENTES DE ARROZ QUANTO À DIFERENÇAS DE PIGMENTAÇÃO E DE DIMENSÕES

Resumo – A busca por padrões de qualidade em sementes de arroz faz com que ocorra a evolução das etapas do beneficiamento com a utilização de máquinas modernas e processos mais rápidos e precisos. O presente estudo tem o objetivo de avaliar a componente de cor que pode ser utilizada na separação de sementes de arroz vermelho e preto de lotes de sementes de arroz branco pelo uso de imagens RGB, verificando assim a viabilidade de seu emprego na seleção óptica mecanizada, como operação de beneficiamento e identificar a separação por meio de diferenças quanto às dimensões pelas técnicas de RGB e aprendizado de máquinas. Para a execução foram separadas de forma manual, amostras de sementes de arroz branco, vermelho e preto. Na sequência, ocorreu a captação das imagens por meio de um escâner, delimitado com EVA de cor azul escolhido por nenhuma das sementes apresentar tonalidades iguais ao fundo, com as dimensões de 22x30cm junto com uma grade quadriculada do mesmo material, cada quadrícula apresentando dimensões de 2x2cm com o intuito de analisar a semente de arroz de forma separada. As imagens foram introduzidas no *software* ImageJ, onde foram analisadas e os dados coletados foram submetidos à análise de variância ($p \leq 0,05$) e depois comparados usando o teste de Tukey com 5% de probabilidade e submetidos à regressão polinomial. Para a realização da avaliação das sementes em relação às diferentes dimensões, os resultados foram introduzidos no Python, manipulado por meio das bibliotecas específicas e classificados por meio dos classificadores J48 e *Naive Bayes*. Para a separação de sementes de arroz vermelho e preto de sementes de arroz branco, a componente de cor mais adequada é a escala de vermelho. Por outro lado, para sementes de arroz preto e vermelho a resposta mais eficiente é obtida com a escala de azul. Para as diferenças de dimensões entre sementes é possível utilizar técnicas de processamento de imagens, sendo que as relações de comprimento e largura são as mais promissoras para alcançar maior eficiência do processo, com precisão de 72 e 73%, respectivamente.

Palavra-Chave: *Oryza sativa* L., RGB, Aprendizado de máquina, Imagens.

IDENTIFICATION METHODS BY PROCESSING IMAGES FOR RICE SEED SEPARATION FOR PIGMENTATION AND DIMENSION

Abstract - The search for quality standards in rice seeds causes the evolution of the processing steps with the use of modern machines and faster and faster processes. The present study aims to evaluate the color component that can be used to separate red and black rice seeds from white rice seeds by using RGB images, thus verifying the feasibility of employment in the mechanized optical selection. As a beneficiation operation and identify separation through differences for dimensions by RGB techniques and machine learning. For execution were separated manually, white, red, and black rice seed samples and in the sequence, the capture of the images occurred through a scanner, delimited with blue-colored EVA chosen by any of the seeds present shades equal to the bottom, with the dimensions of 22x30cm along with a checkered grid of the same material, each compressing 2x2cm to analyze the rice seed separately. The images were introduced in the ImageJ software, where they were analyzed, and the data collected were submitted to analysis of variance ($p \leq 0.05$) and then compared using the Tukey test with 5% probability and submitted to the polynomial regression. In order to carry out the seed assessment concerning the different dimensions, the results were introduced in Python, manipulated by the specific libraries, and classified through the J48 and Naive Bayes classifiers. For red and black rice seed separation of white rice seeds, the most suitable color component is the scale of red. On the other hand, for black and red rice seeds, the most efficient response is obtained with the scale of blue. Therefore, it is possible to use image processing techniques for the differences in seeds, and the length and width ratios are the most promising to achieve greater process efficiency, accurately from 72 and 73%, respectively.

Keywords: *Oryza sativa* L., RGB, Machine Learning, Images.

5.1 Introdução

Além de apresentar grande importância socioeconômica, o arroz (*Oryza sativa* L) é um dos produtos mais consumidos no mundo. Ao que tudo indica, a safra 2021/2022 não será favorecida pelas condições climáticas e que ocorrerão reduções de 2,4% e 10,1%, tanto na área cultivada como na produção, respectivamente em comparação com os resultados obtidos na safra anterior (CONAB, 2022).

A espécie de *Oryza sativa* L apresentam cultivares especiais diferenciadas pela sua pigmentação. O arroz preto possui casca de coloração palha e um pericarpo de cor preta. Já o arroz vermelho possui um pericarpo de coloração avermelhada e a capacidade de adaptação ao sistema de produção

competindo por recursos essenciais para o desenvolvimento da produção (DRUM; SILVA, 2017; GOUVÊA *et al.*, 2017).

Entre os processos do beneficiamento está a separação das sementes. Esse processo tem como finalidade distinguir as sementes das impurezas por meio de características físicas. Um dos princípios de separação é por meio de diferenças quanto às dimensões de largura, espessura e comprimento (CARVALHO e NAKAGAWA, 2012).

Durante a produção de sementes de arroz é fundamental que a alta qualidade fisiológica das mesmas seja mantida desde o período da colheita até o armazenamento (MENEZES; CÍCERO; VILLELA, 2005).

Levar em consideração que as sementes pigmentadas possuem semelhanças quanto as suas dimensões em relação ao sementes de arroz branco faz com que a seleção eletrônica por cor através da componente de cor adequada surja como uma opção para a sua retirada (MONTEIRO *et al.*, 2020).

Diversos estudos na área de pós-colheita estão utilizando a técnica de processamento digital de imagens (PDI). Em seu estudo Monteiro *et al.*, 2021, indicou de acordo com a variação entre as escalas, a vermelha foi a mais adequada para a remoção de sementes esverdeadas de soja. Já no estudo de Monteiro; Gadotti; Araújo, 2019, também utilizando análise de imagens, foi possível identificar a escala de cor mais adequada para a separação dos defeitos presentes nos grãos. Em sementes de coentro por meio de parâmetros de separação baseados pela diferença de coloração foi possível uma melhor solução (MOREIRA *et al.*, 2022). Os três estudos indicaram a possibilidade de utilização de novas técnicas de separação nas indústrias.

Entre as características do aprendizado de máquinas (AP) está a capacidade de aprendizado automatizado, o que auxilia no aprendizado pois não há necessidade de serem realizadas regulagens ou orientações. A utilização da técnica no setor sementeiro auxilia em tomadas de decisões de forma mais rápida favorecendo e aprimorando novas técnicas. Para que ocorra esse desenvolvimento é necessário o seu entendimento (POOJA; SHARMA; SHARMA, 2018; MORAES, 2020, MONTEIRO; GADOTTI; VILLELA, 2021).

O presente trabalho tem o objetivo de avaliar a componente de cor que pode ser utilizada na separação de sementes de arroz vermelho e preto de lotes de sementes de arroz pelo uso de imagens RGB, verificando assim a viabilidade de seu emprego na seleção óptica mecanizada, como operação de beneficiamento e identificar a separação das mesmas por meio de diferença de suas dimensões por meio de técnicas de RGB e aprendizado de máquinas.

5.2 Material e métodos

O presente trabalho foi conduzido na Universidade Federal de Pelotas, Campus Capão do Leão, Pelotas-RS, no Laboratório de Agrotecnologia, sendo a captura de imagens realizada no período de maio a setembro de 2020.

5.2.1 Captura da imagem em RGB

Foram selecionadas quatro amostras contendo 88 sementes cada uma, totalizando 352 sementes de arroz branco, vermelho e preto (Figura 9). As amostras foram resultantes da porção sementes puras, previamente descascadas, conforme as Regras para Análise de Sementes (Brasil, 2009).

As amostras foram separadas de forma manual, pelo mesmo operador para minimizar erros. Na sequência, as imagens foram dispostas no escâner e delimitadas com fundo de EVA (*Etil Vinil Acetato*) 22x30cm junto com uma grade quadriculada do mesmo material, cada quadriculado com dimensões de 2x2cm com o intuito de analisar as sementes de arroz de forma individualizada.




Figura 9 – Imagem representativa de sementes de arroz a) branco - b) preto - c) vermelho.

As imagens foram captadas uma por vez por meio de um escâner (modelo *HP Photosmart C3180 All-in-One Printer*) e na sequência introduzidas no *software* ImageJ- FIJI (SCHINDELIN *et al.*, 2012). Após inseridas, a primeira etapa foi realizar a calibração do *software* para a obtenção de uma medida real. Na sequência, as imagens foram duplicadas, onde ocorreu a transformação de uma delas de RGB para escala cinza (oito bits) por meio do comando *Type* e a outra foi dividida em componentes de imagem (vermelho, verde e azul), mediante *Split Channels* (Figura 10).

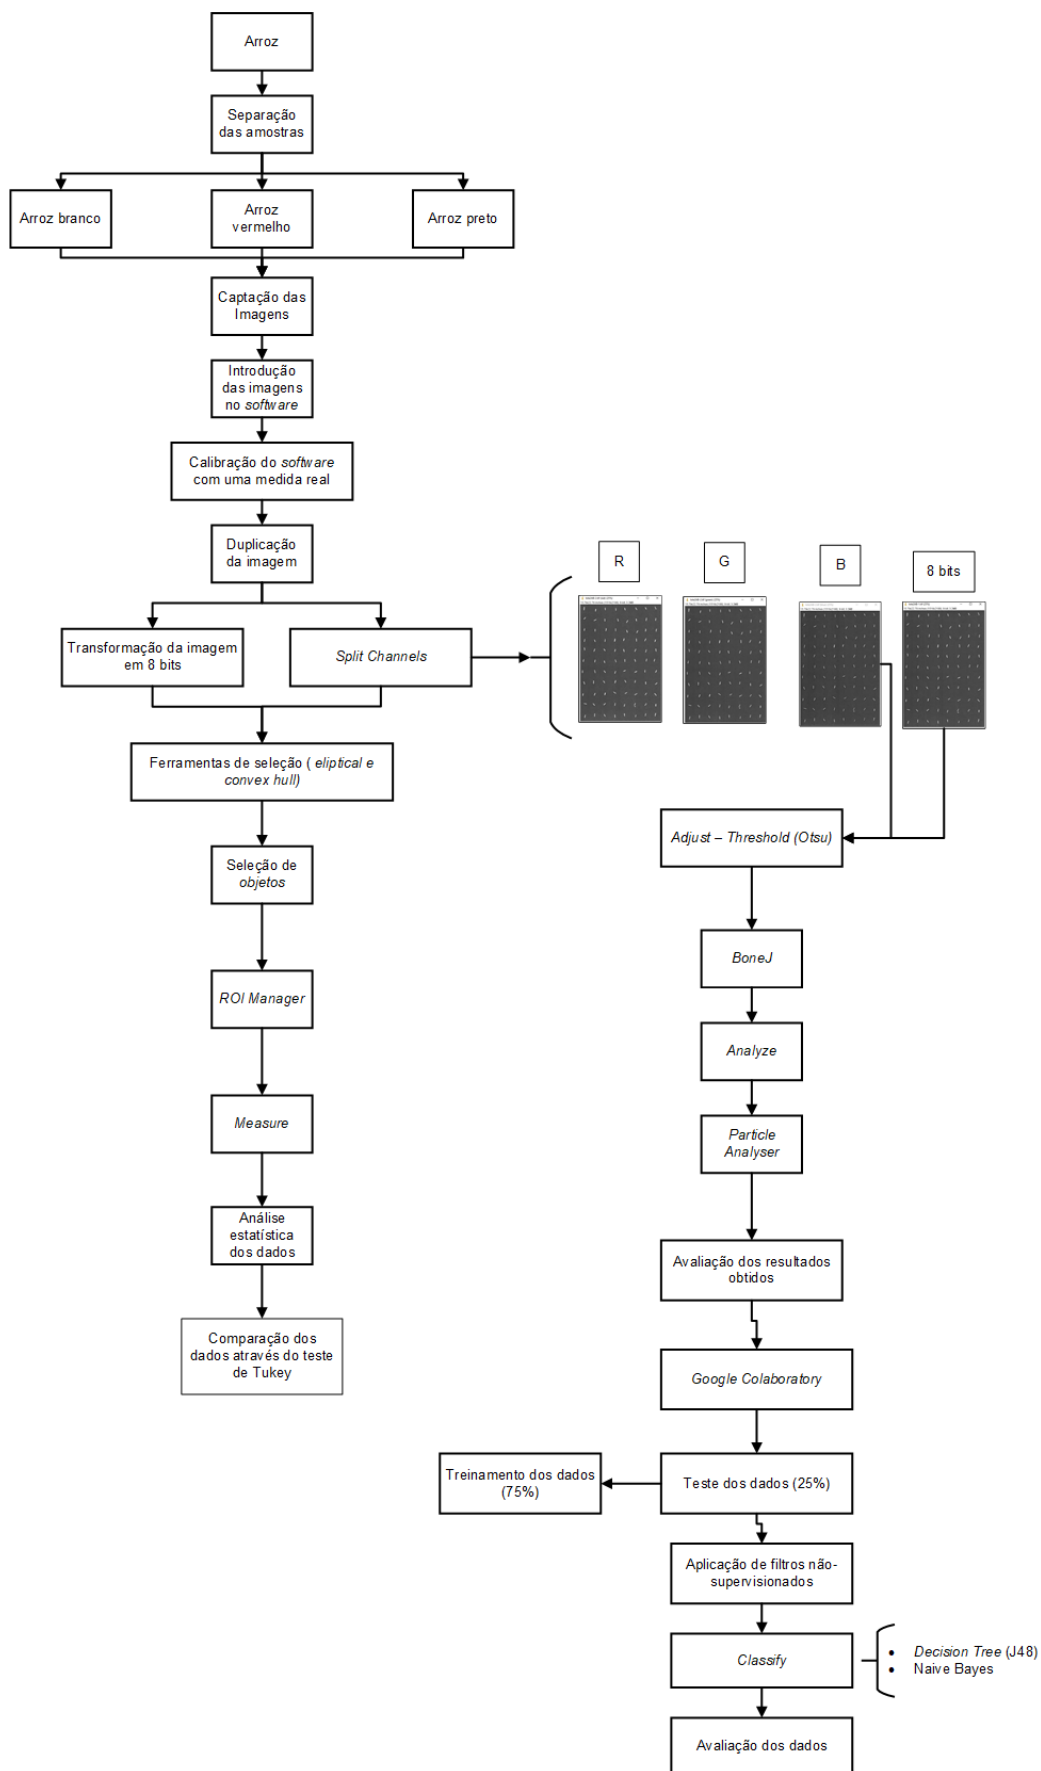


Figura 10 – Fluxograma de separação das sementes de arroz, captura e processamento das imagens e procedimento estatístico.

Após a duplicação das imagens, foi realizada a seleção de forma individual das sementes de arroz com o auxílio das ferramentas *elliptical* e *convex hull*. Recorrendo à ferramenta de seleção de *pixels*, foram realizadas múltiplas seleções estabelecendo as regiões de interesse (ROI) para cada uma das sementes em cada uma das imagens transformadas. Com o auxílio da ferramenta *Measure*, foram determinadas as medidas de cada região de interesse, a contagem de pixel total (média), máximo e mínimo, para cada tipo de semente de arroz vermelho e arroz preto analisado, por meio de faixas de cores (escala de cinza, vermelho, verde e azul).

As medidas de comprimento e largura também foram obtidas empregando a ferramenta *measure*. Para extrair as informações relacionadas à espessura foi preciso realizar a avaliação de qual o canal (RGB ou 8 bits) era o mais indicado para realizar a segmentação da imagem. No caso das sementes de arroz branco, foi utilizado o canal de 8 bits e para as demais sementes (preto e vermelho) foi utilizado o canal *blue* (azul).

Na sequência foi realizada a segmentação das sementes por meio da ferramenta *adjust threshold – otsu* com a finalidade de dividir a imagem em múltiplas regiões ou objetos. Pós segmentação foi utilizado o comando *particle analyser* do plug-in *BoneJ* (Doube, 2010), com a finalidade de adquirir as medidas de espessura das sementes (Figura 11).




Figura 11 – Obtenção da medida de espessura da semente de arroz.

5.2.2 Obtenção dos resultados

Para os resultados de média, máximo e mínimo foram utilizados para a realização da estatística dos dados, empregando delineamento inteiramente ao

acaso. Os dados coletados foram submetidos à análise de variância ($p \leq 0,05$) e havendo significância foram comparados pelo teste de Tukey em nível de 5% de probabilidade e submetidos à regressão polinomial.

Os valores de comprimento, largura e espessura obtidos a partir das imagens foram expressos em milímetros (mm) e os utilizados para a base de treinamento por aprendizado de máquinas supervisionado. Essa base foi composta por 88 linhas e 9 atributos. A classificação foi realizada de duas maneiras, a primeira largura e espessura (LARG-ESP) e a segunda utilizando a dimensão que teve maior quantidade de classificação na segunda e comparando-a com o comprimento (LARG-COMP). A Figura 12 apresenta a quantidade de resultados encontrados em cada uma das classificações.

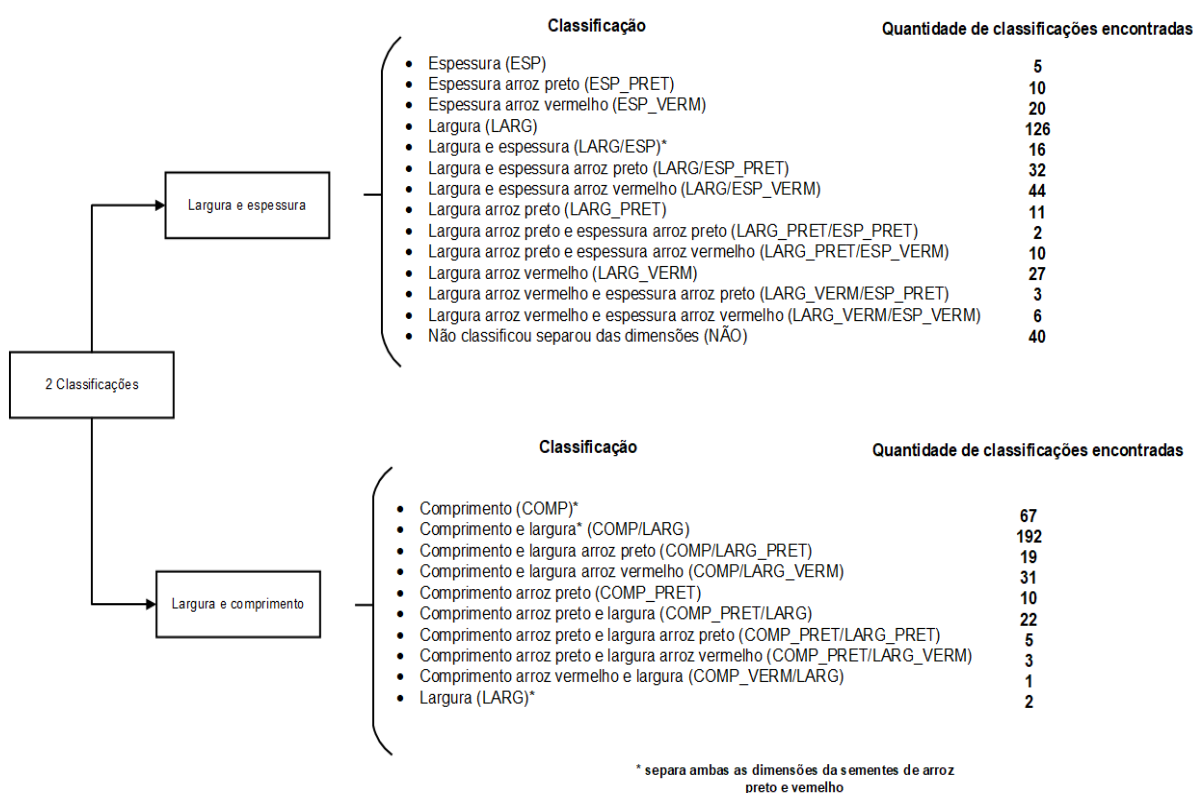


Figura 12 – Classificação das sementes de arroz quanto às suas dimensões.

Na sequência, os resultados foram inseridos no *Google Colaboratory*, uma ferramenta que vem sendo bastante utilizada em técnicas de aprendizado de máquinas e inteligência artificial com a finalidade de escrever e executar códigos em Python. Foram utilizadas para a categorização da aprendizagem de

máquinas as bibliotecas de *Numpy*, *Scipy*, *Scikit-Learn*, *Keras*, *Pandas* e *Matplotlib*.

Os dados foram segregados em dois conjuntos um de teste (30%) e outro de treinamento (70%) e depois avaliados empregando os classificadores *Decision Tree* (J48), um método de classificação não supervisionado que tem como objetivo a construção de um modelo do valor de um alvo variável pela tomada de decisão a partir dos dados e *Naive Bayes*, onde é possível presumir a independência entre os atributos dos dados empregando probabilidade, com a finalidade de melhor apresentar o resultado esperado para sua avaliação (HARRISON, 2019).

Os resultados obtidos foram avaliados pela matriz de confusão e assim foi medida a eficácia do classificador, fornecendo o número de previsões precisas e incertas com base em valores verdadeiros conhecidos (Tabela 5).

Tabela 5 – Medidas avaliadas por meio da matriz de confusão.

Medidas	Fórmulas	Conceito
<i>Accuracy</i>	$\frac{tp + tn}{tp + fp + tn + fn}$	Relaciona-se com o número de vezes que o modelo previu o valor correto.
<i>Precision</i>	$\frac{tp}{tp + fp}$	Tem como finalidade informar com que frequência o modelo prevê a quantidade de verdadeiro positivo. Menor precisão significa maior número de falsos positivos.
<i>Recall</i>	$\frac{tp}{tp + fn}$	Contabiliza informações relacionadas aos falsos negativos, quanto mais baixo o valor de <i>recall</i> significa que o modelo contém uma quantidade elevada de falsos negativos, ou seja, não conseguiu identificar corretamente uma grande proporção.
<i>F1- Score</i>	$2 * \frac{Precision * Recall}{Precision + Recall}$	Expressa a média entre a precisão e o <i>recall</i> . Os pesos podem ser aplicados se uma métrica for mais importante que a outra. Uma pontuação alta F1 indica um baixo número de falsos positivos e falsos negativos, que infere que o modelo detecta com precisão ameaças e não são influenciadas por incertezas.

*tp: verdadeiro positivo, tn: verdadeiro negativo, fp: falso positivo e fn: falso negativo. Fonte: Harrison (2019); Koklu e Ozkan (2020); Kumar *et al.* (2021).

5.3 Resultados e discussão

O processamento digital de imagens permitiu contabilizar, neste caso, a escala de cores. Ao ser comparado em oito bits, as médias dos componentes em escalas de cores em *pixels* de sementes de arroz branco, vermelho e preto encontram-se na Tabela 6. Nota-se que é possível ocorrer a separação em todas as escalas.

Tabela 6 – Comparação entre as médias (%) do total de pixels das sementes de arroz branco, vermelho e preto em função das escalas de cores em oito bits.

Escala	Arroz branco	Arroz vermelho	Arroz preto	(AB-AV ^{**})	(AV – AP ^{***})
			(%)		
Cinza	67,6 a B	38,0 b B	22,6 c B	29,6	15,4
Vermelha	72,6 a A	52,6 b A	24,7 c A	20,0	27,9
Verde	65,8 a C	37,1 b B	21,4 c C	28,7	15,4
Azul	62,1 a D	29,2 b C	23,0 c B	39,2	6,2

*Médias seguidas de letras minúsculas diferentes na linha diferem entre si pelo teste de Tukey em nível de probabilidade de 5%. Médias seguidas de letras maiúsculas diferentes na coluna diferem entre si pelo teste de Tukey em nível de probabilidade de 5%. ** Arroz branco separa arroz vermelho através da sua diferença de porcentagens. ***Arroz vermelho separa arroz preto através da sua diferença de porcentagem **** Arroz branco separa arroz preto.

Conforme Tabela 6, é possível perceber que as quatro escalas de pigmentação permitem a separação entre arroz de diferentes cores. Os resultados encontrados para as médias corroboram com os encontrados no estudo para separação de defeitos do grão de arroz por Monteiro, Gadotti e Araújo (2019), onde a escala cinza, muito utilizada pelas indústrias, também apresentou valores intermediários e a escala vermelha apresentou os valores mais altos de *pixels* assim como no presente estudo. É de conhecimento que os equipamentos mais modernos trabalham com infravermelho (RGB+NIR) (Machvision, 2022), no entanto uma câmara com esse filtro eleva o custo do equipamento.

Na escala verde e azul, a separação mais eficiente seria entre o arroz branco e vermelho (AB_AV) através da diferença das porcentagens das medidas. Sendo que a escala azul seria considerada a melhor entre as duas pelo seu resultado. Assim como no trabalho de Moreira *et al.* (2022) que para separar as sementes de coentro por meio da diferença de cor, a escala mais indicada também foi a azul.

Em relação às dimensões máximas e mínimas, a Figura 13 apresenta os resultados de valores mínimos e máximos de cinza dentro da seleção. Em relação aos valores mínimos, a escala vermelha destaca-se apresentando os maiores valores em todas as seleções, assim como nos valores máximos.

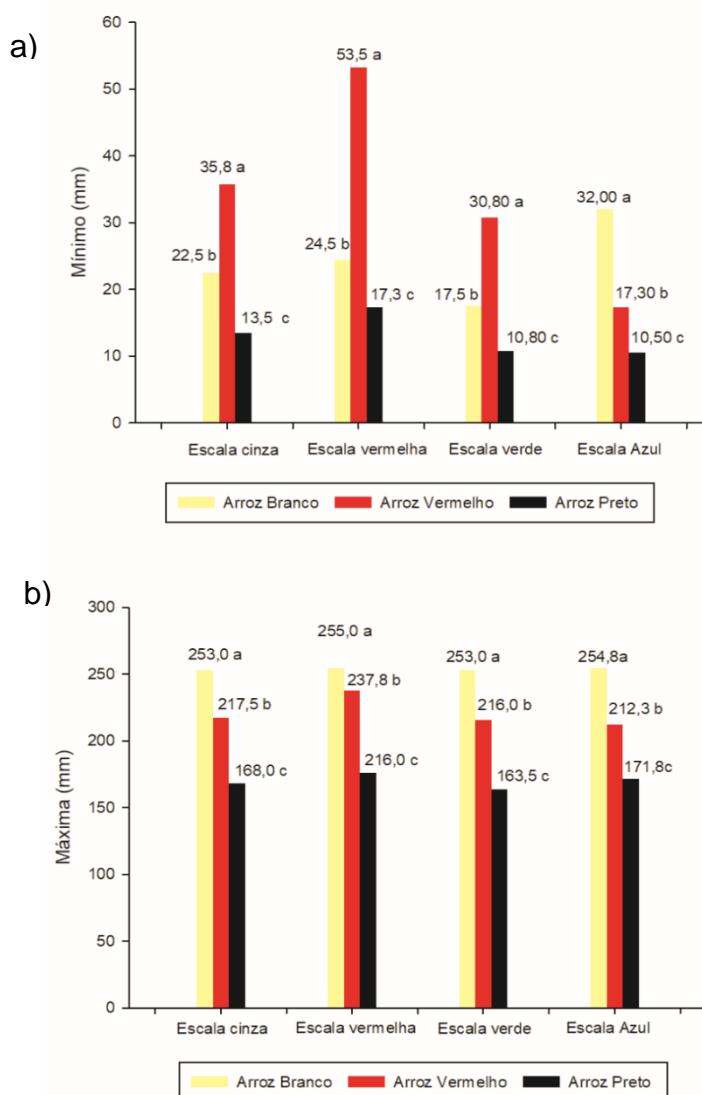


Figura 13 - Média dos valores mínimos (a) e máximos (b) da componente cinza para cada pigmento de arroz, em mm.

Em relação ao tamanho das sementes, o arroz branco apresenta os menores valores de mínimo nas dimensões, o arroz preto os valores intermediários e o arroz vermelho os maiores. Para os valores de máxima, o arroz branco apresenta os maiores valores, seguido pelo arroz vermelho com valores intermediários e o arroz preto com os menores valores entre as escalas de cores. Verifica-se, portanto, que o arroz branco possui a maior amplitude com os valores mínimos e máximos, o que faz sua separação com as demais cores

complexa ao se considerar somente o tamanho. Tratando-se de uma separação de sementes por tamanho, a utilização dos valores máximos em todas as escalas seria a mais adequada.

Comparando o PDI em outras espécies, esse foi utilizado em grãos de soja para determinar suas propriedades físicas comparando-as com métodos de medições tradicionais. Ao final do estudo chegou-se ao resultado de que as medidas obtidas por meio das imagens e das análises estatísticas tornaram o método viável (GUEDES et al., 2011).

Ao analisá-los, nota-se que todas as sementes apresentaram dimensões semelhantes. Conforme USDA (1994) e FAO (1995), um grão de arroz longo fino tem comprimento de 3,0mm ou mais, um médio de 2,0 a 2,9mm e curto de 1,9mm ou menos.

De acordo com Azapoglu *et al.* (2022), ao avaliarem sementes de arroz, por meio das dimensões de largura, relação de largura de comprimento, comprimento e espessura, verificaram que os valores de média de comprimento foram de 9,7 mm, podendo variar entre 8,2 e 11 mm. Para a largura, a média foi de 2,5 mm, variando entre 2,3 a 2,7 mm, a relação de largura de comprimento obteve intervalo mais significativo entre 3,0 a 4,5mm e média de 3,74mm e a espessura entre 1,7 e 2,11 mm, com a média o mesmo valor de 2,11mm. Os resultados da Tabela 7 estão de acordo com as obtidas pelo processamento de imagens, partindo do princípio de que variedades diferentes, no caso de pigmentos, possuem dimensões diferentes.

Tabela 7 – Médias das dimensões das sementes de arroz branco, vermelho e preto.

Dimensão (mm)	Arroz Branco	Arroz Vermelho	Arroz Preto
Comprimento	7,08 a A	6,18 a B	5,34 a C
Largura	4,29 b A	2,93 b B	2,91 b B
Espessura	1,84 c C	2,01 c B	2,15 c A

*Médias seguidas de letras diferentes, minúsculas na linha e maiúsculas na coluna, diferem entre si pelo teste de Tukey em nível de probabilidade de 5%.

Nota-se que as sementes de arroz branco podem ser separadas das sementes dos demais de acordo com o comprimento e a largura. Em relação à largura e espessura do arroz vermelho e preto, os valores muito próximos podem dificultar o processo de separação das sementes. Esta ocorrência pode ser explicada pelas semelhanças visuais, ocasionadas pelo uso de uma estreita

base genética durante o processo de melhoramento (MENEZES; ROMERO, 1996).

Li *et al.* (2018) discutem que ainda há dúvidas em relação ao processo envolvido na determinação do tamanho da semente de arroz, mas que a divisão e expansão celular na palea e na lema, que define a capacidade de armazenamento da semente e limita o enchimento da semente. Estudos recentes identificaram vários loci de características quantitativas e uma série de genes como reguladores chave do tamanho da semente. Entende-se então que isso é uma característica determinada geneticamente em cada espécie.

No trabalho com sementes de trigo, Khatri, Agrawal e Chatterjee (2020) concluíram que apesar da aprendizagem de máquinas ser uma técnica que vem contribuindo e sendo bastante utilizada para a classificação de grãos e sementes, ainda existem alguns desafios principalmente relacionados à análise de sementes em geral por apresentarem características semelhantes e diferentes categorias.

A Figura 14 apresenta as características extraídas por meio do classificador J48 em relação à diferenciação de largura e espessura de acordo com separação das sementes, e a partir de tomadas de decisões, formando assim uma árvore de classificação constituída por nós, ramos e folhas. Para a construção da árvore foi utilizado o conceito do atributo Gini, responsável por medir a impureza dos nós variando de 0 a 1. Se o nó é igual a 0, é detectada a pureza das classes e se o valor é igual a 1 indica que há distribuição de elementos em várias classes (GÉRON, 2019). Nesse caso, a classificação das sementes pode ser realizada de acordo com as diferenças de largura e espessura, resultando em classes puras e com classificação podendo ser explicada por meio das dimensões encontradas durante o processamento.

É possível visualizar ainda na Figura 14 (APÊNDICE A) que a medida de espessura, independente do pigmento, é o parâmetro que mais permite ranquear as sementes. No entanto, esse classificador possui uma precisão de 100% e com isso nota-se que o mesmo não diferencia as classes, visto que historicamente a largura é a técnica de separação mais usada. Peske, Baudet e Panozzo (2019) comentam que para a separação de arroz vermelho de branco

deve-se utilizar uma peneira corrugada de perfuração 3,0 mm na 3ª posição da máquina de ar e peneiras, pois o arroz vermelho possui largura superior a essa medida. No entanto, o rendimento da máquina pode reduzir em até 40% com essa técnica. Contudo para as variedades atuais, a dimensão de espessura torna-se mais adequada para a separação utilizando peneiras de furo oblongo como nova alternativa.

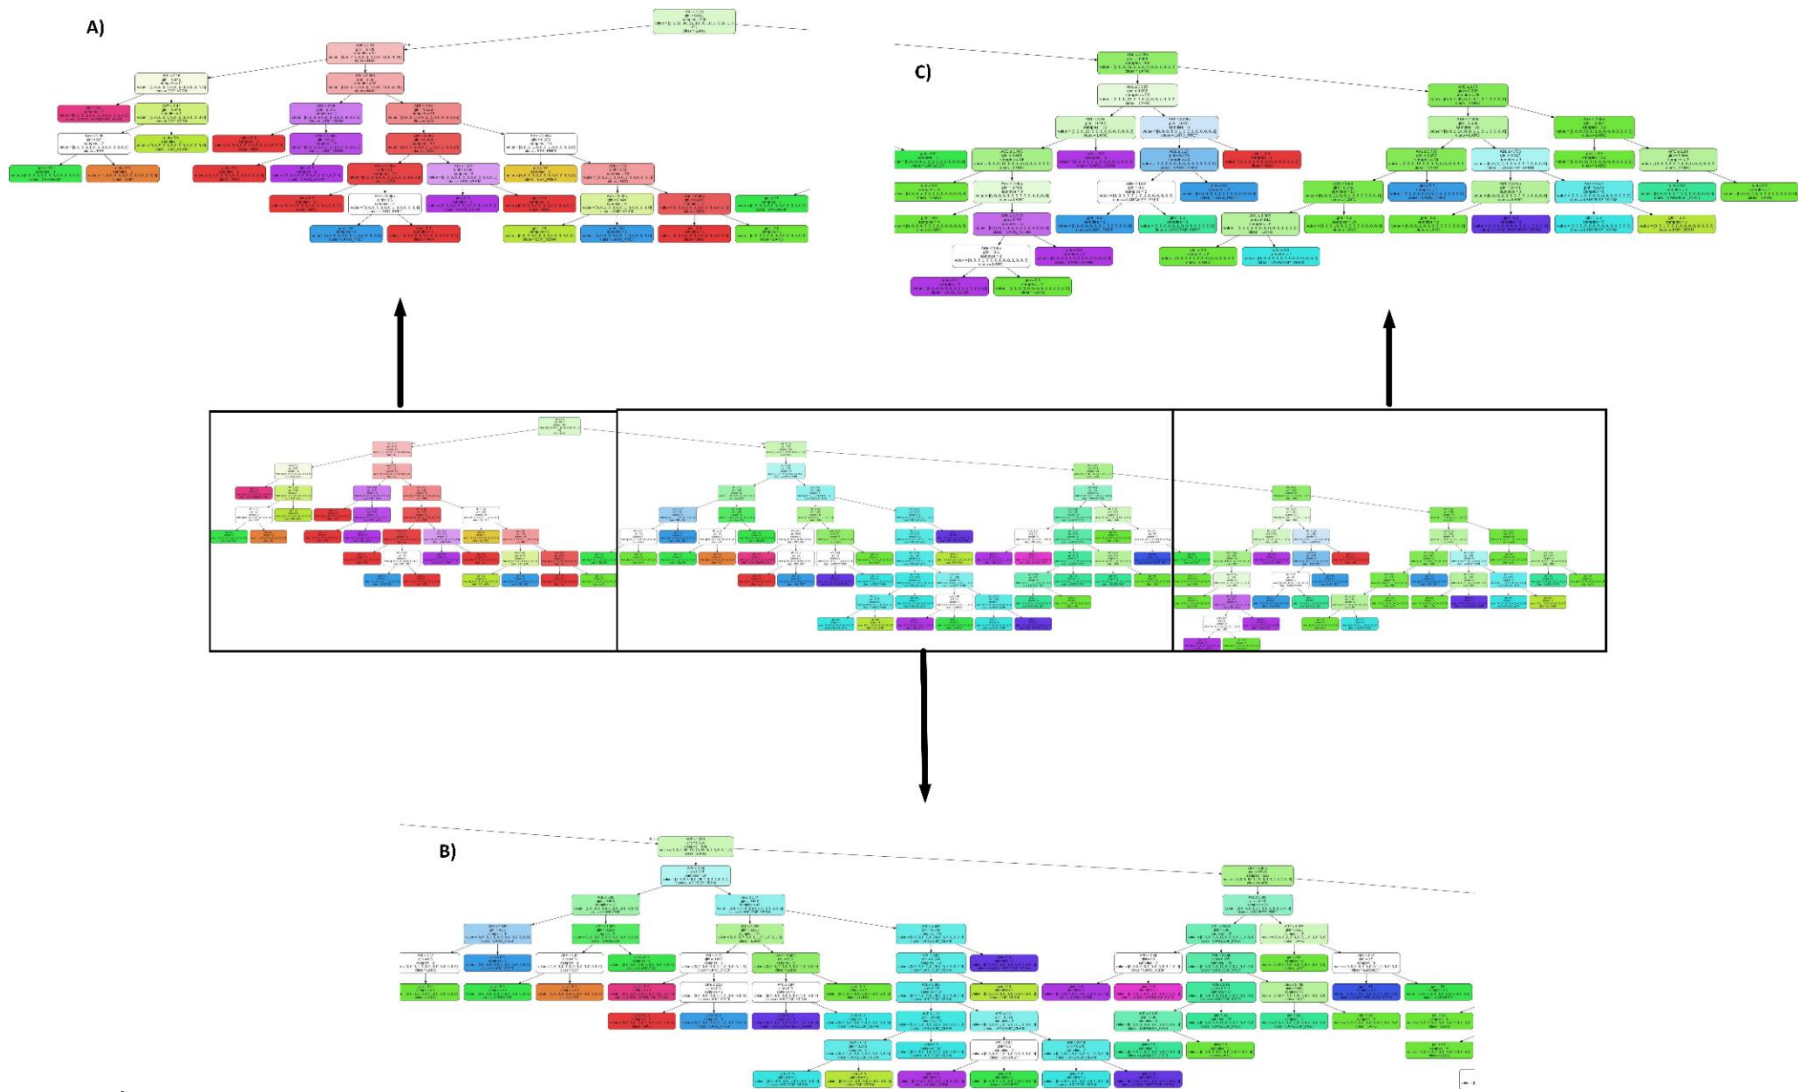


Figura 14 – Árvore de decisão J48 largura e espessura entre os pigmentos de sementes de arroz.

Nesse caso, as sementes poderiam ser separadas utilizando as diferenças quanto ao comprimento, largura e comprimento ou largura. A última classificação pode ser explicada por meio das dimensões encontradas durante o processamento. As sementes poderiam ser separadas tanto pela diferença de comprimento, como por diferença de largura. Esse processo vai depender do método de separação a ser utilizado pela indústria. No beneficiamento das sementes, a máquina utilizada para fazer a separação de sementes de arroz, principalmente o vermelho é denominada *separador de cilindro* ou *trieur*. Para a separação quanto às diferenças em largura e espessura é utilizada a máquina de ar e peneiras, empregando peneiras de perfuração redonda para a separação por largura e peneiras de furo oblongo para a separação por espessura (PESKE *et al.*, 2019).

A matriz de confusão avalia os atributos de *accuracy*, *precision*, *recall* e *f1-score*. Os resultados obtidos por meio da aprendizagem de máquinas indicam que para a *accuracy*, o conjunto de treinamento para cada modelo compreendeu 82% e 61% para LARG-COM e LARG-ESP, respectivamente para *Naive Bayes*. Na classificação por meio do J48, todas as avaliações obtiveram o resultado de 100%. Essa *accuracy* pode não ser a mais adequada para trabalhar com separação, pois ela tende a induzir que o modelo consiga distinguir apenas uma classe entre todas as classificadas.

No trabalho de Khatri, Agrawal e Chatterjee (2020) foram avaliadas, de forma independente, os parâmetros perímetro, compactividade, comprimento, largura, coeficiente de assimetria e o comprimento e os valores encontrados nos classificadores de *Naive Bayes* e J48 foram de 94% e 92%.

Com a finalidade de avaliar recursos geométricos de sementes de três variedades de maçãs, por meio de imagens digitais utilizando entre os modelos de classificação *Naive Bayes* e J48, Koklu; Ozkan (2020) calcularam os atributos de dimensões lineares e foram utilizadas análises discriminantes de 'Gala' com 'Inigared', 'Gala' com 'Jonagold', 'Indad' com 'Jonagold' e 'Gala' com 'Initared' com 'Jonagold' com resultado de maior precisão de 93% com a utilização do classificador J48, viabilizando a possibilidade de determinar recursos ligados às sementes de forma rápida, econômica e não destrutiva.

A Tabela 8 apresenta os resultados de *macro avg* obtidos após o treinamento pela média aritmética de todas as pontuações de *F1 score* por classe. Essa pontuação geralmente é utilizada no caso em que todas as classes precisam ser tratadas igualmente, para avaliar o desempenho geral do classificador em relação aos rótulos de classe. Observa-se que em ambos os classificadores a *precision* de sementes não separadas para a classe de LAR-ESP foi semelhante, assim como na classe de LARG-COMP. Mesmo com o primeiro modelo J48 de classificador apresentando valores superiores de observações, na comparação com os demais parâmetros, valores inferiores são encontrados. Esse resultado corrobora com o citado anteriormente que a largura era uma diferença utilizada na separação nos processos de beneficiamento e que agora sua eficiência é baixa devido à semelhança de largura existente entre as sementes de arroz de diferentes pigmentos.

Tabela 8. Acurácia e média dos atributos obtidos por meio dos classificadores, em %.

Classificadores	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	Classe
J48	33	20	19	19	LARG-ESP
	72	18	20	17	LARG-COMP
<i>Naive Bayes</i>	43	21	21	21	LARG-ESP
	73	39	30	31	LARG-COMP

Koklu e Ozkan (2020) citam que duas condições relevantes, a primeira refere-se ao fato de os modelos realizarem a classificação de modo adequado apresentando valores significativos ou seja o valor de *f1-score* também é alto em toda classificação e a segunda refere-se ao valor de precisão ser realmente positivo em todos os classificadores utilizados, visto que os mesmos determinam a proporção do número de classificados positivos para todos os aspectos positivos proporcionais à precisão.

Na Figura 15 encontra-se a matriz de confusão das classificações das sementes em relação à largura e à espessura dos dados de treinamento e largura e comprimento para ambos os classificadores. O classificador *Naive Bayes* ao ser utilizado na classificação da largura e espessura verifica-se que apenas a classe de LARG_PRET/ESP_PRET teve seu resultado classificado corretamente. As classes de ESP, ESP_PRET e ESP_VERM contém em suas classes 4, 8 e 7 avaliações, respectivamente, sendo que dessas 2, 4 e 1 são consideradas como verdadeiro

positivo e o restante é considerada falso negativo. As demais classes registraram avaliações de falso positivo e falso negativo durante a separação.

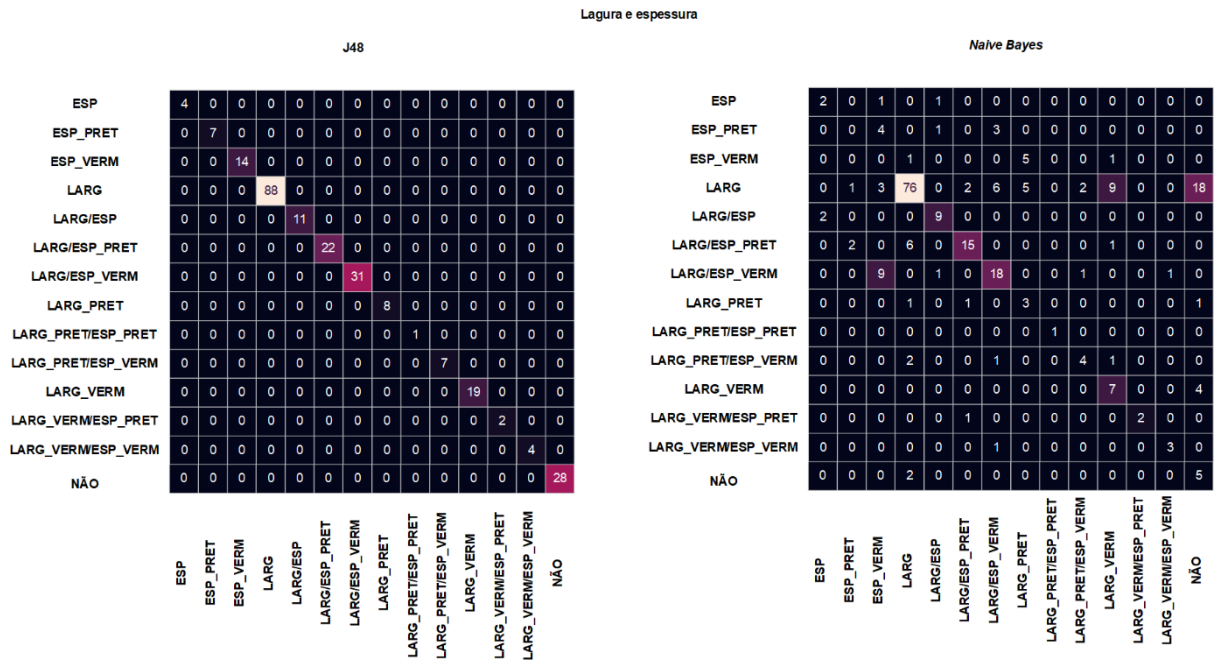


Figura 15 – Matriz de confusão para largura e espessura com os dados de treinamento.

Ao se tratar das avaliações de largura e comprimento (Figura 16), a classe de comprimento (COMP) identificou corretamente 42 avaliações e 23 avaliações consideradas falso positivo e distribuídas em seis classes diferentes. A classe de comprimento e largura totalizou 141 avaliações, sendo que dessas 127 foram classificadas como verdadeiro positivo, sendo a classe com maior quantidade de separação. As classes de COMP_LARG, COMP_PRET/LARG_VERM, COMP_VERM/LARG e LARG obtiveram os acertos de acordo com o seu classificador.

Largura e comprimento

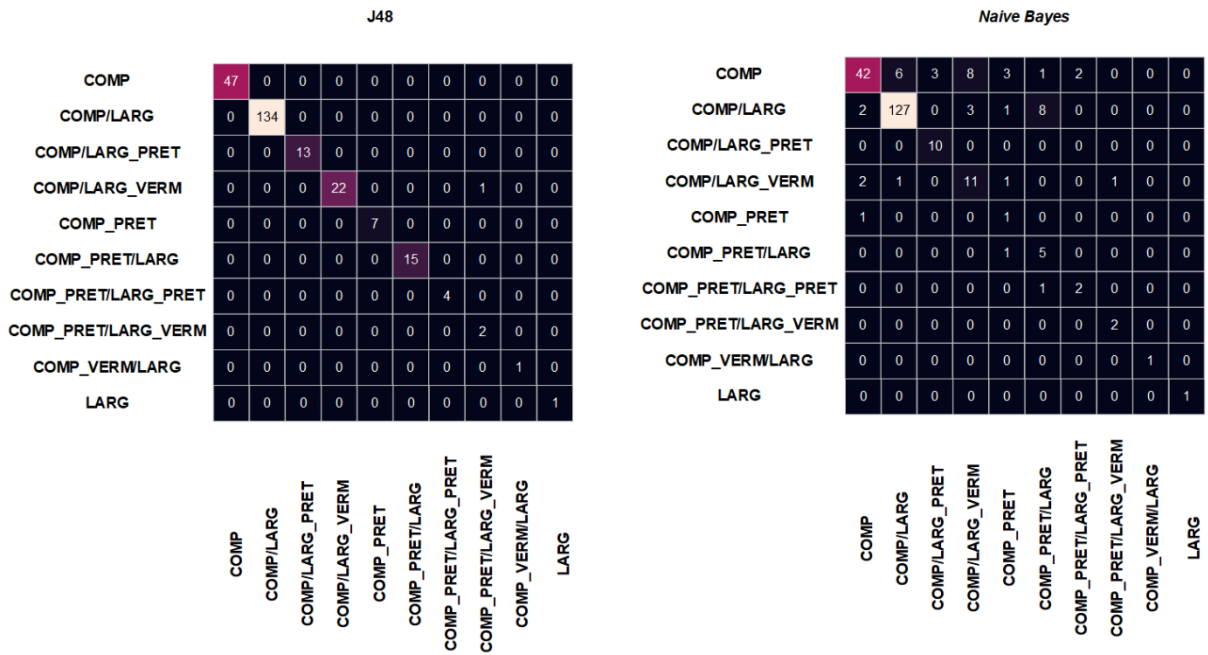


Figura 16 – Matriz de confusão para largura e comprimento com dados para treinamento.

A Figura 17 mostra os resultados para a matriz de confusão a partir dos dados de teste. Ao separar o LARG-ESP por meio do *Naive Bayes* é possível notar na distribuição das classes que nenhum dos valores corresponde ao valor real, ou seja, nenhum verdadeiro positivo. LARG identificou o total de 52 avaliações, sendo que destas 22 são consideradas falsos positivos.

Largura e espessura

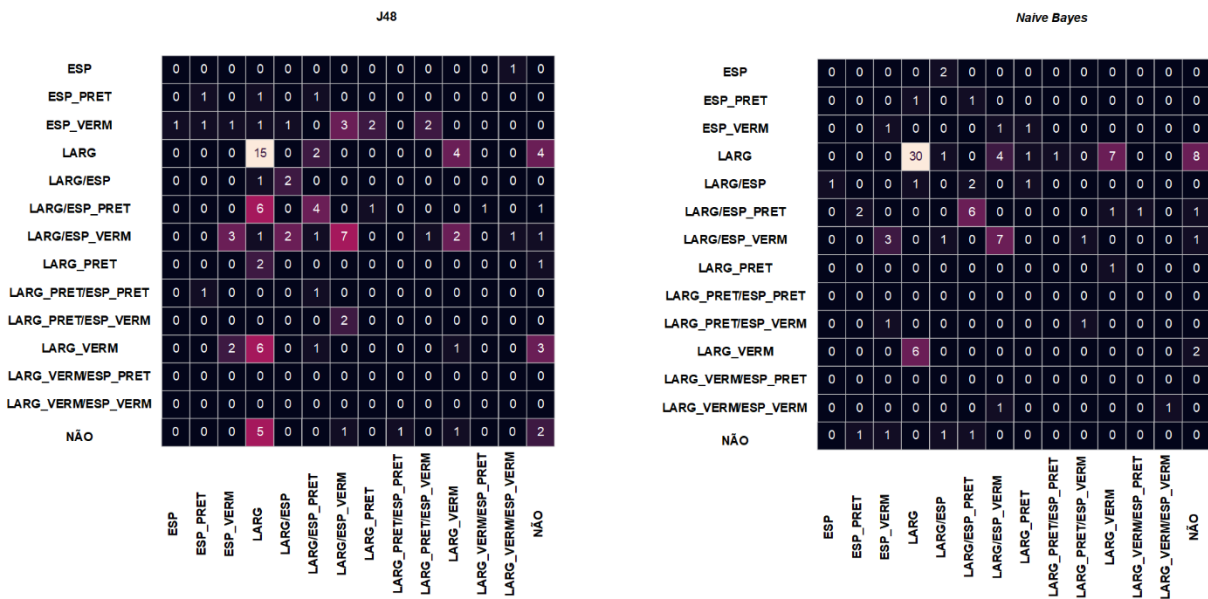


Figura 17 - Matriz de confusão para largura e espessura com os dados para teste.

Ao analisar as matrizes classificação de COMP/LARG é possível verificar que sua estrutura é semelhante. A classe de COMP/LARG de ambas apresentam resultados e distribuição dos valores de falso positivo e negativo semelhantes e a maior avaliação de verdadeiros positivos (Figura 18).

Largura e comprimento

	J48									Naive Bayes								
COMP	19	1	0	1	2	0	0	0	0	17	3	3	5	3	0	0	0	0
COMP/LARG	1	49	0	1	0	6	0	0	1	0	53	0	1	0	5	0	0	1
COMP/LARG_PRET	0	1	5	0	0	0	0	0	0	0	0	2	0	0	0	1	0	0
COMP/LARG_VERM	0	0	0	4	0	0	0	0	0	2	1	0	3	0	0	0	1	0
COMP_PRET	0	2	1	0	0	0	0	1	0	1	0	1	0	0	0	0	0	0
COMP_PRET/LARG	0	4	0	0	1	1	1	0	0	0	0	0	0	0	2	0	0	0
COMP_PRET/LARG_PRET	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
COMP_PRET/LARG_VERM	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0
COMP_VERMLARG	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	COMP	COMP/LARG	COMP/LARG_PRET	COMP/LARG_VERM	COMP_PRET	COMP_PRET/LARG	COMP_PRET/LARG_PRET	COMP_PRET/LARG_VERM	COMP_VERMLARG	COMP	COMP/LARG	COMP/LARG_PRET	COMP/LARG_VERM	COMP_PRET	COMP_PRET/LARG	COMP_PRET/LARG_PRET	COMP_PRET/LARG_VERM	LARG

Figura 18- Matriz de confusão para largura e comprimento com os dados para teste.

Assim, é possível concluir que ainda a largura é a melhor medida de separação, mas, no entanto, as relações de comprimento e largura são as mais interessantes para obter maior eficiência do processo, com precisão de 72 e 73%.

A análise de imagens é considerada uma técnica econômica, baseada em modelos de textura, características geométricas, formas e descritores, sendo úteis para a separação de sementes e grãos podendo ser utilizada em diversas aplicações industriais. Uma alternativa a ser levada em consideração é a combinação das propriedades de textura e geometria ocasionando resultados mais precisos (ROPELEWSKA E RUTKOWSKI, 2021).

A busca por resultados mais rápidos, precisos e viáveis contribui para o crescimento da utilização da técnica em sementes de diversas espécies e variedades e diferentes utilidades podendo ser adaptadas em equipamentos já existentes.

5.4. Conclusões

Para a separação de sementes de arroz vermelho e preto de sementes de arroz branco, a componente de cor mais adequada é a escala de vermelho. Por outro lado, para sementes de arroz preto e vermelho a resposta mais eficiente é obtida com a escala de azul.

Para as diferenças de dimensões entre sementes é possível utilizar técnicas de processamento de imagens, sendo que as relações de comprimento e largura são as mais promissoras para alcançar maior eficiência do processo, com precisão de 72 e 73%, respectivamente.

6. Considerações finais

Sugere-se para pesquisas futuras:

1. Aplicar o processamento de imagens e o aprendizado de máquinas em sementes de outras espécies;
2. Explorar a questão dos filtros, pois pode construir-se em técnica promissora, capaz de viabilizar o estudo.
3. Analisar a influência da composição química das sementes, bem como realizar análise enzimática na busca de elucidar as possíveis respostas obtidas no processamento de imagens.

Referências

ABIDIN, D. Effects of image filters on various image datasets. In: **Proceedings of the 2019 5th International Conference on Computer and Technology Applications**, p.1–5. 2019. DOI:[10.1145/3323933.3324056](https://doi.org/10.1145/3323933.3324056). Disponível em: https://www.semanticscholar.org/paper/Effects-of-Image-Filters-on-Variou-Image-Datasets_Abidin/f810b292d7be17095a990b41a76194c6a7fd0f6c. Acesso em: 25 jul. 2021.

ARRUDA, N.; CICERO, S. M.; GOMES-JUNIOR, F. G. Radiographic analysis to assess the seed structure of *Crotalaria juncea* L. **Journal Of Seed Science**, v. 38, n. 2, p. 161-168, 2016. DOI: <https://doi.org/10.1590/2317-1545v38n2155116>. Disponível em: <https://www.scielo.br/j/jss/a/CtqN4pxTVhc98NShRXBphPN/?lang=en>. Acesso em 25 jul. 2021.

AZAPOGLU, O.; SRIVASTAVA, V.; SHA, X.; SHAKIBA, E. Evaluation of seed characteristics of selected rice lines in arkansas. **Euphytica**, [S.L.], v. 218, n. 1, p. 1-11, 2021. DOI: <http://dx.doi.org/10.1007/s10681-021-02950-5>. Disponível em: <https://link.springer.com/article/10.1007/s10681-021-02950-5#citeas>. Acesso em: 28 fev. 2022.

BAGATELI, J. R.; DÖRR, C. S.; SCHUCH, L. O. B.; MENEGHELLO, G. E. Productive performance of soybean plants originated from seed lots with increasing vigor levels. **Journal Of Seed Science**, [S.L.], v. 41, n. 2, p. 151-159, 2019. DOI: <http://dx.doi.org/10.1590/2317-1545v41n2199320>. Disponível em: <https://www.scielo.br/j/jss/a/G9f467vnfW7cL4NzMsQPkZS/?lang=en#:~:text=Productive%20performance%20of%20soybean%20plants%20augments%20as%20the%20vigor%20of,by%2028.0%20kg%20per%20hectare>. Acesso em: 10 mar. 2022.

BRASIL. Ministério de Agricultura, Pecuária e Abastecimento. **Regras para Análise de Sementes**. MAPA/DAS/ACS: Brasília. 2009. 395p.

BROCHER, J. **BioVoxel Toolbox**. 2014. Disponível em: http://fiji.sc/BioVoxel_Toolbox. Acesso em: 04 mai 2022.

BRUNES, A. P.; ARAÚJO, Á. S.; DIAS, L. W.; VILLELA, F. A.; AUMONDE, T. Z. Seedling length in wheat determined by image processing using mathematical tools. **Revista Ciência Agronômica**, v. 47, n. 2, p. 374-379, 2016. DOI: <http://dx.doi.org/10.5935/1806-6690.20160044>. Disponível em: <http://www.ccarevista.ufc.br/seer/index.php/ccarevista/article/view/3954>. Acesso: 26 jul. 2021.

BRUNES, A. P.; ARAÚJO, Á. S.; DIAS, L. W.; ANTONIOLLI, J.; GADOTTI, G. I.; VILLELA, F. A. Rice seeds vigor through image processing of seedlings. **Ciência Rural**, v. 49, n. 8, p. 1-6, 2019. DOI: <http://dx.doi.org/10.1590/0103-8478cr20180107>. Disponível em: <https://www.scielo.br/j/cr/a/LHFDXzVGPTpqrVMgJfrR4PH/?format=pdf&lang=en>. Acesso em: 26 jul. 2021.

BURG, W.J. Van Der; AARTSE, J.W.; VAN ZWOL, R.A; JALINK, H.; BINO, R.J.. Predicting Tomato Seedling Morphology by X-ray Analysis of Seeds. **Journal Of The American Society For Horticultural Science**, v. 119, n. 2, p. 258-263, 1994. DOI: <http://dx.doi.org/10.21273/jashs.119.2.258>. Disponível em: <https://journals.ashs.org/jashs/view/journals/jashs/119/2/article-p258.xml>. Acesso em: 26 jul. 2021.

CARVALHO, N. M.; NAKAGAWA, J. **Sementes: ciência, tecnologia e produção**. 5. ed. Jaboticabal: FUNEP, 2012. 590 p.

CNOSSEN, A.G.; JIMÉNEZ, M.J.; SIEBENMORGEN, T.J.. Rice fissuring response to high drying and tempering temperatures. **Journal Of Food Engineering**, [S.L.], v. 59, n. 1, p. 61-69, ago. 2003. Elsevier BV. DOI: [http://dx.doi.org/10.1016/s0260-8774\(02\)00431-4](http://dx.doi.org/10.1016/s0260-8774(02)00431-4). Disponível em: <https://agcomm.uark.edu/uarpp/Cnossen%20et%20al%202003%20J%20Food%20Engineering.pdf>. Acesso: 26 jul. 2021.

CONAB, Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira – Grãos safra 2021/2022**. Disponível em:

<https://www.conab.gov.br/component/k2/item/download/32478_92eba4272b36b69bebc2063e5b766bf7>. Acesso em: 01 mar. 2022.

ELIAS, S, COPELAND, LO, MCDONALD, MB, BAALBAKI, R. **Seed testing: Principles and practices. Seed Testing: Principles and Practices.** Michigan State University Press. 354 p. 2012.

DOUBE, M.; KŁOSOWSKI, M. M.; ARGANDA-CARRERAS, I.; CORDELIÈRES, F. P.; DOUGHERTY, R. P.; JACKSON, J. S.; SCHMID, B.; HUTCHINSON, J. R.; SHEFELBINE, S. J.; Bone, J: free and extensible bone image analysis in imagej. **Bone**, v. 47, n. 6, p. 1076-1079, 2010. DOI: <http://dx.doi.org/10.1016/j.bone.2010.08.023>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/20817052/>. Acesso em: 01 fev. 2022

DRUM, M. A.; SILVA, G., B. P. Arroz: vermelho daninho. **Cultivar: Grandes Culturas**, Pelotas, v. 218, n.7, p. 22-24, 2017. Disponível em: <https://www.grupocultivar.com.br/revistas/525>. Acesso em: 01 mar. 2022.

EIBE F.; MARK A. H.; IAN H. W. **The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques"**, Morgan Kaufmann, Fourth Edition, 2016.

FAO - Food and Agriculture Organization of the United Nations. **Codex standard for rice.** Disponível em: <http://www.fao.org/input/download/standards/61/CXS_198e.pdf>. Acesso em: 20 jan. 2022.

FERREIRA T.; RASBAND W. **The ImageJ User Guide — IJ 1.45.** 2011. Disponível em: imagej.nih.gov/ij/docs/guide/. Acesso em 04 mar. 2022.

FRANÇA-SILVA, F; REGO, C. H. Q.; GOMES-JUNIOR, F. G.; MORAES, M. H. D. de; MEDEIROS, A. D. de; SILVA, C. B. da. Detection of *Drechslera avenae* (Eidam) Sharif [*Helminthosporium avenae* (Eidam)] in Black Oat Seeds (*Avena strigosa* Schreb) Using Multispectral Imaging. **Sensors**, [S.L.], v. 20, n. 12, p. 3343, 12 jun. 2020. MDPI AG. <http://dx.doi.org/10.3390/s20123343>. Acesso em: 7 mar. 2021.

FRIGAU, L.; ANTOCH, J.; BACCHETTA, G.; SARIGU, M.; UCCHESU, M.; ALVES, C. Z.; MOLA, F. A statistical approach to the morphological classification of *Prunus* sp.

seeds. **Plant Biosystems - An International Journal Dealing With All Aspects Of Plant Biology**, [S.L.], v. 154, n. 6, p. 877-886, 2019. DOI: <http://dx.doi.org/10.1080/11263504.2019.1701126>. Disponível: <https://www.tandfonline.com/doi/full/10.1080/11263504.2019.1701126>. Acesso em: 26 ago. 2021.

GÉRON, A. **Mãos à obra aprendizado de máquina com Scikit-Learn & TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes**. Alta Books, 2019. 576 p.

GOUVÊA, A. C. M. S.; SANTIAGO, M. C. P. A.; JESUS, M. S. C.; PACHECO, S.; NASCIMENTO, L. S. M.; BORGUINI, R. G.; GODOY, R. L. O. Arroz preto (*Oryza sativa* L.) uma excelente fonte de anotocianinas. **Semioses**, v. 11, n. 3, p. 55-59, 2017. DOI: <http://dx.doi.org/10.15202/1981996x.2017v11n3p5>. Disponível: [https://www.semanticscholar.org/paper/ARROZ-PRETO-\(Oryza-sativa-L.\)-UMA-EXCELENTE-FONTE-Gouvea-Santiago/a0e518f2ad6a9f21babfb53987fc10da11023390](https://www.semanticscholar.org/paper/ARROZ-PRETO-(Oryza-sativa-L.)-UMA-EXCELENTE-FONTE-Gouvea-Santiago/a0e518f2ad6a9f21babfb53987fc10da11023390). Acesso em: 26 ago. 2021.

GUEDES, M. A.; MATA, M. E. R. M. C. M.; DUARTE, M. M. D.; FARIAS, P. A. F. A. Caracterização física de grãos de soja utilizando-se processamento de imagens. **Revista Brasileira de Produtos Agroindustriais**, v. 13, n. 3, p. 279-294, 2011. **Revista Brasileira de Productos Agroindustriais**. DOI: <http://dx.doi.org/10.15871/1517-8595/rbpa.v13n3p279-294>. Disponível em: <http://www.bibliotekevirtual.org/index.php/2013-02-07-03-02-35/2013-02-07-03-03-11/1421-rbpa/v13n03/15327-caracterizacao-fisica-de-graos-de-soja-utilizando-se-processamento-digital-de-imagens.html>. Acesso em: 26 ago. 2021.

GUIMARÃES, C. M.; FAGERIA, N. K.; BARBOSA FILHO, M. P. Como a planta de arroz se desenvolve. **Potafos**, v.13, n. 99, p. 1-12, 2002. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/749053/como-a-planta-de-arroz-se-desenvolve>. Disponível em: 10 mar. 2022.

HARISSON, M. **Machine Learning – Guia de referência rápida: trabalhando com dados estruturados em Python**. Novatec Editora, 2019. ISBN 8575228188, 9788575228180. p. 272.

KHATRI, A.; AGRAWAL, S.; CHATTERJEE, J. M. Wheat seed classification: utilizing ensemble machine learning approach. **Scientific Programming**, v.2, p. 1-9, 2022.

DOI: <http://dx.doi.org/10.1155/2022/2626868>. Disponível em:

<https://www.hindawi.com/journals/sp/2022/2626868/>. Acesso em: 25 fev. 2021.

KAMRA, S. **Use of X-ray radiography for studying seed quality in tropical forestry**. Studia Forestalia Suecica. Uppsala, Sweden. Royal College of Forestry, 1976. n. 131. 34p. Disponível:

<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.384.620&rep=rep1&type=pdf>. Acesso: 25 fev. 2021.

KOKLU, M.; OZKAN, I. A. Multiclass classification of dry beans using computer vision and machine learning techniques. **Computers And Electronics In Agriculture**, v. 174, p. 105507, 2020. DOI: <http://dx.doi.org/10.1016/j.compag.2020.105507>.

Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0168169919311573?via%3Dihub>. Acesso em: 25 fev. 2021.

KUMAR, R.; BALOCH, G.; BASEER, A.; BHATTI, J. Fungal blast disease detection in rice seed using machine learning. **International Journal Of Advanced Computer Science And Applications**, v. 12, n. 2, p. 248-258, 2021. DOI:

<http://dx.doi.org/10.14569/ijacsa.2021.0120232>. Disponível em:

<https://thesai.org/Publications/ViewPaper?Volume=12&Issue=2&Code=IJACSA&SerialNo=32>. Acesso em: 25 fev. 2021.

LI, N.; XU, R.; DUAN, P.; LI, Y. Control of grain size in rice. **Plant Reproduction**, v. 31, n. 3, p. 237-251, 2018. Springer Science and Business Media LLC. DOI:

<http://dx.doi.org/10.1007/s00497-018-0333-6>. Disponível em:

<https://link.springer.com/article/10.1007/s00497-018-0333-6>. Acesso em: 26 ago. 2021.

LI, W., FENG, F., LI, H., & DU, Q. (2018). Discriminant Analysis-Based Dimension Reduction for Hyperspectral Image Classification: A Survey of the Most Recent Advances and an Experimental Comparison of Different Techniques. **IEEE Geoscience and Remote Sensing Magazine**. n. 6, p. 15-34. DOI:

[10.1109/MGRS.2018.2793873](https://doi.org/10.1109/MGRS.2018.2793873). Disponível em:

<https://www.semanticscholar.org/paper/Discriminant-Analysis-Based-Dimension-Reduction-for-Li-Feng/b38e450dd5b5d61d613790abb7a4fe0e67f75505>. Acesso em: 04 mai. 2022.

MACHVISION. **Análise da qualidade de amostras de arroz**. Disponível em: <https://machvision.com.ar/pt/mv-control-3/>. Acesso em: 8 mar. 2022.

MEDEIROS, A. D.; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L.; DIAS, D. C. F. S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. **Industrial Crops And Products**, v. 146, p. 112-162, 2020. DOI: <http://dx.doi.org/10.1016/j.indcrop.2020.112162>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0926669020300789?via%3Dihub>. Acesso em: 26 ago. 2021.

MEDEIROS, A. D., CAPOBIANGO, N. P., DA SILVA, J. M., DA SILVA, L. J., DA SILVA, C. B., DOS SANTOS DIAS, D. C. F. Interactive machine learning for soybean seed and seedling quality classification. **Scientific Reports**, v.10, n.1, p. 10:11267, 2020 DOI: <http://dx.doi.org/10.1038/s41598-020-68273-y>. Disponível: <https://www.nature.com/articles/s41598-020-68273-y>. Acesso em: 26 ago. 2021.

MENEZES, N. L.; ROMERO, C. M. Determinação varietal em arroz. Pesquisa Agropecuária Brasileira, Brasília, v. 31, n. 2, p. 139-146, 1996. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/AI-SEDE/19266/1/pab96_08_fev.pdf. Acesso em: 26 ago. 2021.

MENEZES, N. L.; CÍCERO, S. M.; VILLELA, F. A. Identificação de fissuras em sementes de arroz após a secagem artificial, por meio de raios-X. **Ciência Rural**, v. 35, n. 5, p. 1194-1196, 2005. DOI: <http://dx.doi.org/10.1590/s0103-84782005000500033>. Disponível em: <https://www.scielo.br/j/cr/a/XQGJ9Kzwzt4kYW5k3Xk4wNL/?lang=pt>; Acesso em: 11 fev 2021.

MENEZES, N. L.; CICERO, S. M.; VILLELA, F. A.; BORTOLOTTI, R. P. Using X rays to evaluate fissures in rice seeds dried artificially. **Revista Brasileira de Sementes**, v.

34, n. 1, p. 70-77, 2012. DOI: <http://dx.doi.org/10.1590/s0101-31222012000100009>.

Disponível

em:

<https://www.scielo.br/j/rbs/a/43PrX6s4GzVwKWmHhN4RxQh/?lang=en>. Acesso em:

26 ago. 2021.

MORAES, N. A. B. **Predição de ranqueamento de lotes de sementes de milho por inteligência artificial**. 2020. 30 f. Dissertação (Mestrado em Ciência e Tecnologia de Sementes) – Faculdade de Agronomia, Universidade Federal de Pelotas, Pelotas, 2020.

MOREIRA, I. B.; MONTEIRO, R. C. M.; SILVA, R. N. O.; HORNKE, N. F.; ARAÚJO, Á. S.; GADOTTI, G. I. Separation of coriander seeds by Red, Green and Blue image processing. **Ciência Rural**, v. 52, n. 9, p. 1-7, 2022. DOI:

<http://dx.doi.org/10.1590/0103-8478cr20210384>.

Disponível

em:

<https://www.scielo.br/j/cr/a/dbQfzbnV8T3mPZSY9SwV7q/?lang=en>. Acesso em: 9

mar. 2022.

MONTEIRO, R. C. M.; GADOTTI, G. I.; ARAÚJO, Á. S. Processamento de imagens para identificação de defeitos no arroz. In: ZUFFO, A. M. (Org.). **A produção do conhecimento nas Ciências Agrárias e Ambientais**. 4. ed. Ponta Grossa: Atena, 2019. p. 298-306.

MONTEIRO, R. C. M.; GADOTTI, G. I.; ARAÚJO, Á. S.; PEDÓ, T.; VILLELA, F. A. Processamento Digital de Imagens na Separação de Sementes de Arroz Quanto à Diferença De Pigmentação. In: Encontro de Pós-Graduação, XXII., 2020, Pelotas. **Anais**. Pelotas: Ed. e Gráfica Universitária, 2020. p. 1-4. Disponível em: https://cti.ufpel.edu.br/siepe/arquivos/2020/CA_02835.pdf. Acesso em: 10 mar. 2022.

MONTEIRO, R. C. M.; GADOTTI, G. I.; MALDANER, V.; CURI, A. B. J.; BÁRBARA NETO, M. Image processing to identify damage to soybean seeds. **Ciência Rural**, v. 51, n. 2, p. 1-8, 2021. <http://dx.doi.org/10.1590/0103-8478cr20200107>. Disponível em; <https://www.scielo.br/j/cr/a/rWzgXD3LL94SqYRZGPyYkqG/?lang=en>. Acesso em: 24 jul. 2021.

MONTEIRO, R. C. M.; GADOTTI, G. I.; VILLELA, F. A.. Aprendizado de Máquinas para Separação de Sementes de Arroz Através de suas Dimensões. In: Encontro de Pós-Graduação, XXIII, 2021, Pelotas. **Anais**. Pelotas: Ufpel, 2021. p. 1-4. Disponível em: https://cti.ufpel.edu.br/siepe/arquivos/2021/CA_03153.pdf. Acesso em: 10 mar. 2022.

MUKHOPADHYAY, S.; SIEBENMORGEN, T. J. Glass transition effects on milling yields in a cross-flow drying column. **Drying Technology**, v. 36, n. 6, p. 723-735, 2017. DOI: <http://dx.doi.org/10.1080/07373937.2017.1351453>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/07373937.2017.1351453>. Acesso em: 28 jul 2021.

NAGODA, N.; RANATHUNGA, L. Rice sample segmentation and classification using image processing and support vector machine. **2018 IEEE 13Th International Conference On Industrial And Information Systems (Iciis)**, [S.L.], p. 179-184, 2018. IEEE. <http://dx.doi.org/10.1109/iciinfos.2018.8721312>. Disponível em: <https://ieeexplore.ieee.org/document/8721312>. Acesso em: 1 ago 2021.

NIXON, G.; BURMS, M. Final report: Application of multispectral imaging (MSI) to food and feed sampling and analysis. Disponível em: <https://www.food.gov.uk/sites/default/files/media/document/fs301017finrep.pdf>. Acesso em: 30 jul. 2021.

NOLDIN, J.A.; YOKOYAMA, S.; STUKER, H.; RAMPELOTTI, F.T.; GONÇALVES, M.I.F.; EBERHARDT, D.s.; ABREU, A.; ANTUNES, P.; VIEIRA, J.. Desempenho de populações híbridas F2 de arroz-vermelho (*Oryza sativa*) com arroz transgênico (*O. sativa*) resistente ao herbicida amonio-glufosinate. **Planta Daninha**, v. 22, n. 3, p. 381-395, 2004. DOI: <http://dx.doi.org/10.1590/s0100-83582004000300008>. Disponível em: <https://www.scielo.br/j/pd/a/yKLHJRvsnj4SkSjwxNNgb8K/?lang=pt>. Acesso em: 02. Mar. 2022.

OLIVEIRA, J. A.; ROSA, S. D. V. F.; CARVALHO, E. R. Secagem de Sementes. In: OLIVEIRA, J. A. **Processamento pós-colheita de sementes**: abordagem agrônômica visando aprimorar a qualidade. Lavras, UFLA, 2021. p. 69-93. ISBN 978-65-86561-08-1.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: a systematic review. **Computers And Electronics In Agriculture**, v. 153, p. 69-81, 2018. Elsevier BV. DOI: <http://dx.doi.org/10.1016/j.compag.2018.08.001>. Disponível:

<https://www.sciencedirect.com/science/article/pii/S0168169918305829>. Acesso em: 26 ago. 2021.

PESKE, S. T.; BAUDET, L. M.; PANOZZO, L. E. Beneficiamento de sementes. In.: PESKE, S. T.; VILLELA, F. A.; MENEGHELLO, G. E. **Sementes: Fundamentos Científicos e Tecnológicos**, 3º ed., Pelotas: Ed. Universitária, UFPel, 2019, p. 457.

PESKE, S. T., VILLELA, F. A., GADOTTI, G. I. Secagem de sementes. In: Peske, S. T., Villela, F. A.; Meneghello, G.E. **Sementes: fundamentos científicos e tecnológicos**. 3ª ed. Ed. Universitária UFPel, 2019. Pelotas. p 355 - 405. 2019.

PINHEIRO, R. M.; GADOTTI, G. I.; MONTEIRO, R. C. M.; BERNARDY, R. Inteligência artificial na agricultura com aplicabilidade no setor sementeiro. **Diversitas Journal**, v. 6, n. 3, p. 2984-2995, 2021. DOI http://dx.doi.org/10.48017/diversitas_journal-v6i3-1857. Disponível em:

https://diversitasjournal.com.br/diversitas_journal/article/view/1857. Acesso em: 30 jul. 2021

POOJA, I, SHARMA, A.; SHARMA, A. Machine learning: a review of techniques of machine learning. JASC: Journal of Applied Science and Computations, v. 5, i. 7, 2018. p. 538-541. ISSN NO: 1076-5131. Disponível em:

https://www.researchgate.net/profile/Ankush-Sharma-7/publication/329609597_Machine_Learning_A_Review_of_Techniques_of_Machine_Learning/links/5c11f2764585157ac1be30f6/Machine-Learning-A-Review-of-Techniques-of-Machine-Learning.pdf. Acesso em: 27 jul. 2021.

RAZAVI, S. M.A.; BOSTAN, A.; RAHBARI, R.. Computer Image Analysis and Physico-Mechanical Properties of Wild Sage Seed (*Salvia macrosiphon*). **International Journal Of Food Properties**, v. 13, n. 2, p. 308-316,2010. DOI: <http://dx.doi.org/10.1080/10942910802398453>. Disponível:

<https://www.tandfonline.com/doi/full/10.1080/10942910802398453>. Acesso em: 26 ago. 2021.

ROPELEWSKA, E.; RUTKOWSKI, K. P.. Cultivar discrimination of stored apple seeds based on geometric features determined using image analysis. **Journal Of Stored Products Research**, v. 92, p. 101804, 2021. DOI: <http://dx.doi.org/10.1016/j.jspr.2021.101804>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0022474X21000436>. Acesso em: 28 fev. 2022

SCHINDELIN, J.; ARGANDA-CARRERAS, I.; FRISE, E.; KAYNIG, V.; LONGAIR, M.; PIETZSCH, T.; PREIBISCH, S.; RUEDEN, C.; SAALFELD, S.; SCHMID, B. Fiji: an open-source platform for biological-image analysis. **Nature Methods**, v. 9, n. 7, p. 676-682, 2012. DOI: <https://doi.org/10.1038/nmeth.2019>. Disponível em: <https://www.nature.com/articles/nmeth.2019>. Acesso em: 25. jun. 2021.

SILVA, C. B.; BIANCHINI, V. J. M.; MEDEIROS, A. D.; MORAES, M. H. D.; MARASSI, A. G.; TANNÕS, A. A novel approach for *Jatropha curcas* seed health analysis based on multispectral and resonance imaging techniques. **Industrial Crops And Products**, v. 161, p. 113186, 2021. DOI: <http://dx.doi.org/10.1016/j.indcrop.2020.113186>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0926669020311031>. Acesso em: 10 mar. 2022.

SILVA, T. A.; SILVA, P. B.; SILVA, E. A. A.; NAKAGAWA, J.; CAVARIANI, C. Condicionamento fisiológico de sementes de soja, componentes de produção e produtividade. **Ciência Rural**, v. 46, n. 2, p. 227-232, 2016. DOI: <http://dx.doi.org/10.1590/0103-8478cr20141736>. Disponível em: <https://www.scielo.br/j/cr/a/Xp7JrgCmKkZPcHtqqTmZrBC/?lang=pt>. Acesso em: 29 jul. 2021.

SILVA, V. N.; ARRUDA, N.; CICERO, S. M.; MAUS, C. A.; GIACOMELI, R. Morfologia interna e germinação de sementes de arroz de terras baixas produzidas em diferentes regimes hídricos. **Irriga**, v. 19, n. 3, p. 453, 2014. DOI: <http://dx.doi.org/10.15809/irriga.2014v19n3p453>. Disponível em:

<https://energia.fca.unesp.br/index.php/irriga/article/view/910>. Acesso em: 01 ago 2021.

SHI, H.; SIEBENMORGEN, T. J.; LUO, H.; ODEK, Z. Fissure detection and measurement in rough rice using X-Ray imaging. **Transactions Of The Asabe**, v. 62, n. 4, p. 859-866, 2019. DOI: <http://dx.doi.org/10.13031/trans.13043>. Disponível em: https://www.gycc.com/trends/rice_straw/publication/?pn=480. Acesso em: 29 jul. 2021.

SOSBAI - SOCIEDADE SUL-BRASILEIRA DE ARROZ IRRIGADO. **Recomendações técnicas da pesquisa para o sul do Brasil**. Pelotas: SOSBAI, 2018. 164 p. Disponível em: https://www.sosbai.com.br/uploads/documentos/recomendacoes-tecnicas-da-pesquisa-para-o-sul-do-brasil_906.pdf. Acesso em: 10 mar. 2022

STARK, R.; ADAMS, R. X-ray inspection technique aids forest tree seed production. *California Agriculture*, v.17, n. 7. p.6-7, 1963 Disponível em: <https://calag.ucanr.edu/Archive/?article=ca.v017n07p6>. Acesso em: 29 jul. 2021

SWAROWSKY, M. L.; ASSMANN, E. J. A importância da lema e da pálea na manutenção da qualidade fisiológica em sementes de arroz. **Cultivando O Saber**, Cascavel, v. 9, n. , p. 100-107, 2016. ISSN 2175-2214. Disponível em: <http://177.53.200.37/index.php/cultivando/issue/view/48>. Acesso em: 11 mar. 2022.

TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; SHAH, M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. **Artificial Intelligence In Agriculture**, v. 4, p. 58-73, 2020. DOI: <http://dx.doi.org/10.1016/j.aiia.2020.04.002>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S258972172030012X>. Acesso em: 29 jul. 2021.

THARWAT, Alaa; GABER, Tarek; IBRAHIM, Abdelhameed; HASSANIEN, Aboul Ella. Linear discriminant analysis: a detailed tutorial. **Ai Communications**, [S.L.], v. 30, n. 2, p. 169-190, 2017. IOS Press. DOI: <http://dx.doi.org/10.3233/aic-170729>. Disponível em: http://usir.salford.ac.uk/id/eprint/52074/1/AI_Com_LDA_Tarek.pdf. Acesso em 04 mai 2022.

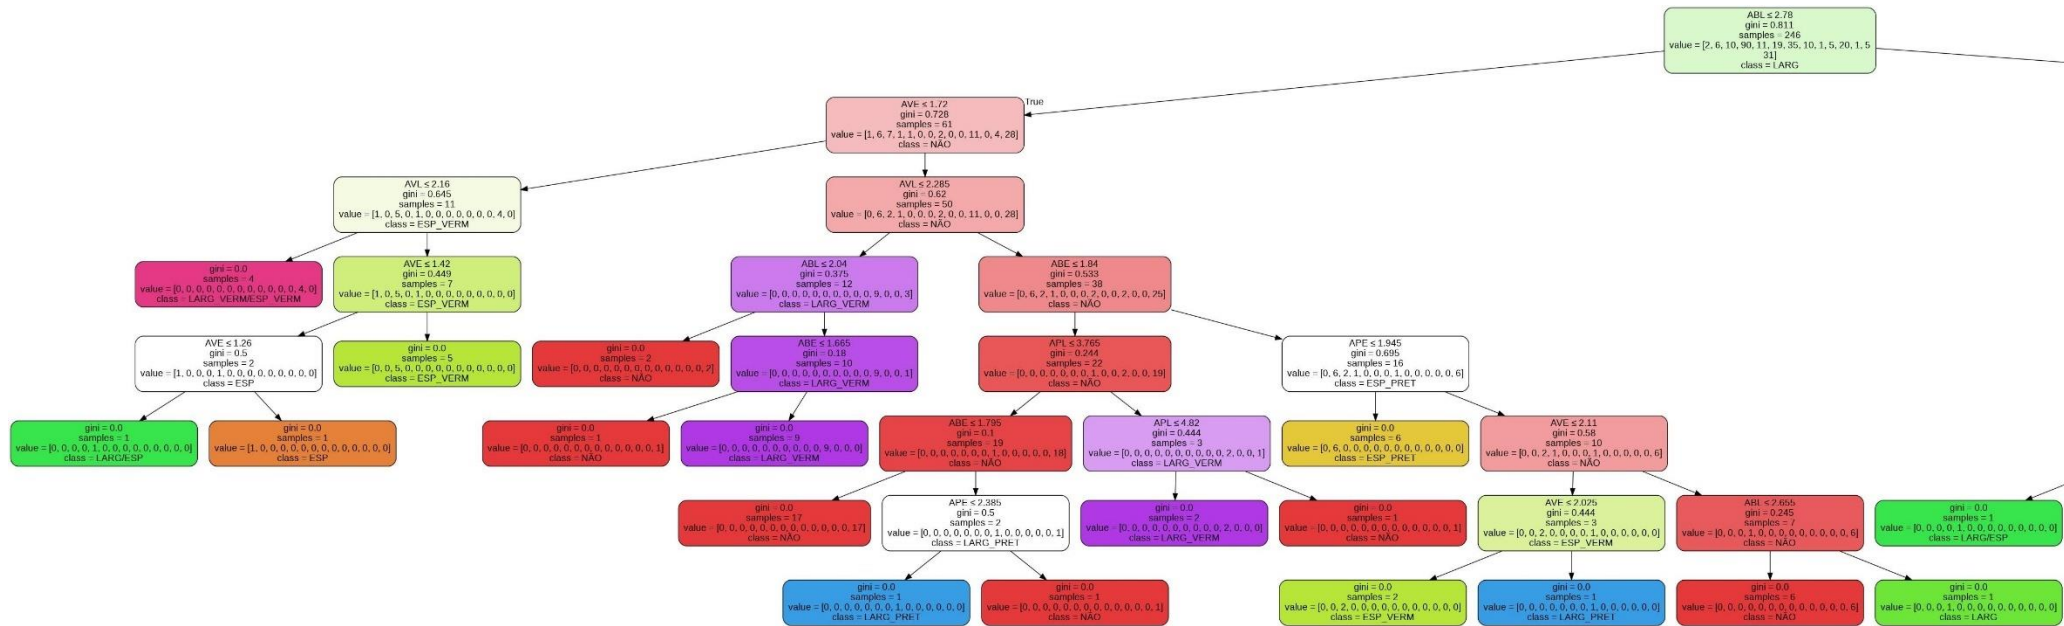
TAVARES, L.C.; RUFINO, C. A.; BRUNES, A.P.; TUNES, L.M.; BARROS, A.C.S.; PESKE, S.T. Desempenho de sementes de soja sob deficiência hídrica: rendimento e qualidade fisiológica da geração F1. **Ciência Rural**, Santa Maria v.43, n.8, p.1357-1363, 2013. DOI: <https://doi.org/10.1590/S0103-84782013000800003>. Disponível em: <https://www.scielo.br/j/cr/a/Gv6Zdb6hxH4YRsRm8kmFGdf/?lang=pt>. Acesso em: 10 mar. 2022.

TONG, C.; GAO, H.; LUO, S.; LIU, L.; BAO, J. Impact of postharvest operations on rice grain quality: a review. **Comprehensive Reviews In Food Science And Food Safety**, [S.L.], v. 18, n. 3, p. 626-640, 2019. Wiley. DOI: <http://dx.doi.org/10.1111/1541-4337.12439>. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1111/1541-4337.12439>. Acesso: 10 ago. 2021.

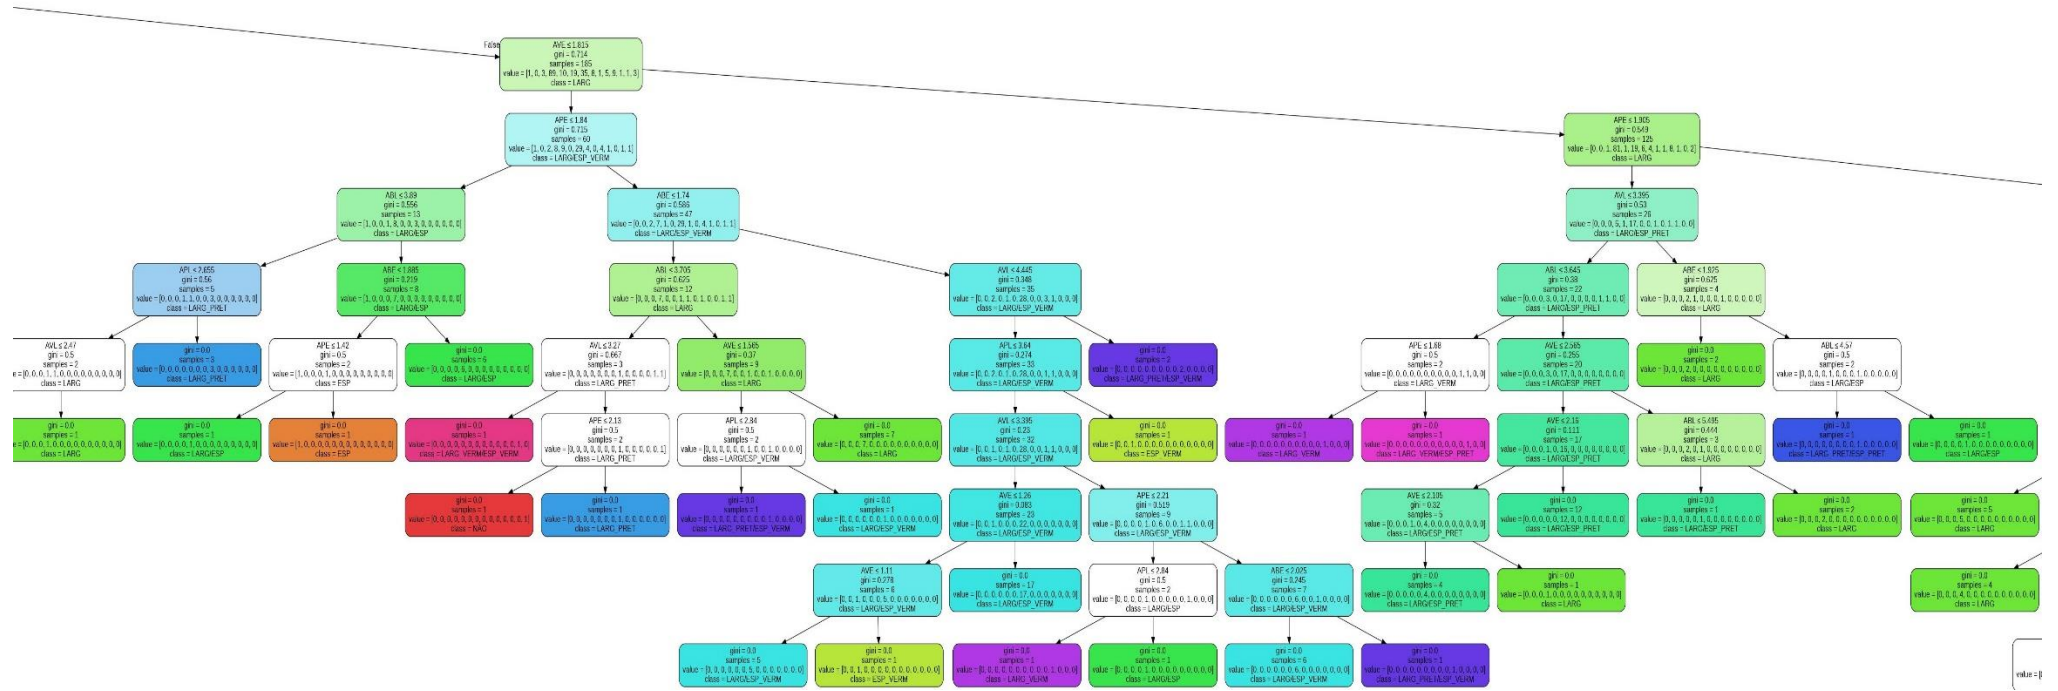
USDA. (1994). **Inspection of milled rice. Rice inspection handbook. USDA grain inspection, packers and stockyards administration Federal Grain Inspection Service.** Disponível em: <https://www.ams.usda.gov/sites/default/files/media/RiceHB.pdf>. Acesso em: 26 fev. 2022.

Apêndices

Apêndice A



Apêndice B



Apêndice C

