

APRENDIZADO DE MÁQUINAS PARA SEPARAÇÃO DE SEMENTES DE ARROZ ATRAVÉS DE SUAS DIMENSÕES

RITA DE CASSIA MOTA MONTEIRO¹; GIZELE INGRID GADOTTI²; FRANCISCO AMARAL VILLELA³

¹Universidade Federal de Pelotas – ritamonteiro@gmail.com

²Universidade Federal de Pelotas – gizele.gadotti@ufpel.edu.br

³Universidade Federal de Pelotas - francisco.villela@ufpel.edu.br

1. INTRODUÇÃO

O arroz (*Oryza sativa* L.) é um dos produtos mais consumidos no mundo e possui uma grande importância socioeconômica (CONAB, 2021). É fundamental assegurar uma alta qualidade fisiológica na produção das sementes de arroz, durante todo o processo, desde a colheita até o armazenamento (MENEZES; CÍCERO; VILLELA, 2005). A separação é um dos processos do beneficiamento de sementes que tem como finalidade separar por distinção de características físicas entre as sementes e as impurezas. Um dos métodos de separação é por meio de diferenças quanto às dimensões de largura, espessura e comprimento (CARVALHO E NAKAGAWA, 2012).

O processamento digital de imagens (PDI) é uma técnica que vem sendo utilizada em diversos estudos relacionados à área de pós-colheita. Trabalhando com grãos de arroz foi constatado que é possível identificar os defeitos presentes nos grãos mediante análise de imagens RGB (*Red, Green e Blue*) (MONTEIRO; GADOTTI; ARAÚJO, 2019).

O aprendizado de máquinas (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; SHARMA; SHARMA, 2018). A aplicação da técnica no setor agrícola poder vir a contribuir, favorecendo e aprimorando os recursos. Seu entendimento torna-se necessário para o desenvolvimento sustentável do setor (MORAES, 2020). O presente trabalho tem o objetivo de identificar a separação de sementes de arroz branco, vermelho e preto por meio de diferenças em dimensões com o auxílio de técnicas de RGB e aprendizado de máquinas.

2. METODOLOGIA

O presente trabalho foi conduzido na Universidade Federal de Pelotas, Campus Capão do Leão, Pelotas-RS, no Laboratório de Agrotecnologia. Foram selecionadas manualmente quatro amostras contendo 88 sementes cada uma, totalizando 352 grãos de arroz branco, vermelho e preto. Na sequência, as imagens foram dispostas em escâner e delimitadas com fundo de EVA (*Etil Vinil Acetato*) 22x30cm junto com uma grade quadriculada do mesmo material, tendo cada quadrícula as dimensões de 2x2cm, com o intuito de analisar as sementes de arroz de forma individualizada.

As imagens foram captadas uma por vez e na sequência introduzidas no *software* ImageJ. Após inserir as imagens, a primeira etapa foi utilizar a ferramenta de calibração do *software* para a determinação de uma medida real. Na sequência, as imagens foram transformadas de RGB para escala cinza (oito bits) e 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.

Os resultados obtidos por meio das imagens foram utilizados para a base de treinamento por aprendizado de máquina supervisionado de 88 linhas com 6 atributos, onde 31 ocorreu separação por comprimento (COMP), 41 por largura (LARG), 13 comprimento ou largura (COMP ou LARG) e 3 não (NÃO) foram separadas em ambas as dimensões.

Na sequência, os resultados foram inseridos no *software* de mineração de dados denominado Weka. Dos dados foram segregados um arquivo para treinamento com a finalidade de calibrar o software e um arquivo de teste. Na sucessão, os dados foram classificados empregando classificador *Decision Tree* (J48) e *MultiLayer Perceptron*, com a finalidade de melhor apresentar o resultado esperado para a avaliação dos resultados obtidos.

3. RESULTADOS E DISCUSSÃO

Os conjuntos de treinamento para J48 e *MultiLayer Perceptron* compreenderam 97,46% e 98,73%, respectivamente, tendo o segundo método apresentado desempenho superior. Os resultados obtidos após o treinamento foram 95,45% para o J48 e 96,60% para *MultiLayer Perceptron*, indicando a maior eficiência deste. A Figura 1 apresenta as características extraídas por meio do classificador J48, de acordo com separação das sementes, a partir de tomadas de decisões, formando assim uma árvore de classificação constituída por nós, ramos e folhas.

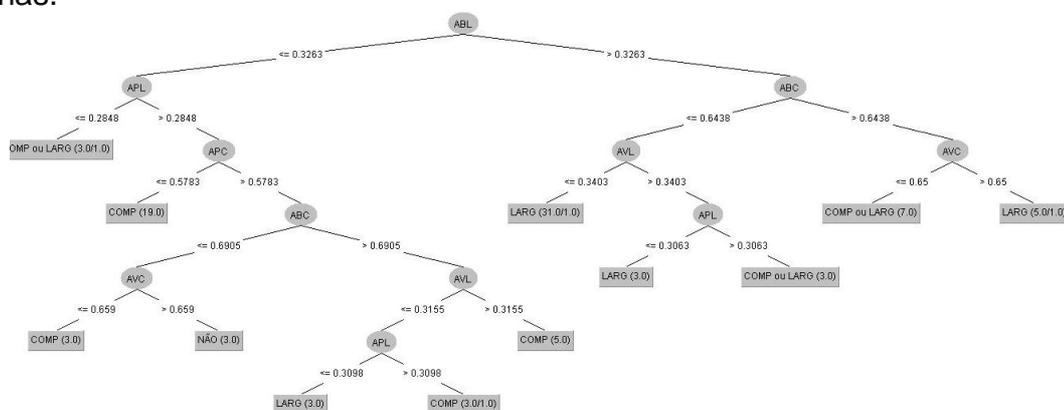


Figura 1 – Árvore de decisão para a classificação das sementes de arroz.

Finalmente, concluiu-se a classificação das sementes 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. Essa vai depender do método de classificação 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 à diferença em largura são utilizadas as máquinas de ar e peneiras, empregando peneiras de perfuração redonda (PESKE et al., 2019). Para a avaliação do desempenho de cada um dos algoritmos de classificação foram utilizadas as matrizes de confusão (Tabela 1). É

possível notar que com a execução dos classificadores J48 e *MultiLayer Perception* não houve diferenças notórias nos resultados encontrados.

TABELA 1 - Matrizes de confusão obtidas por meio do J48 e *MultiLayer Perception*.

J48					<i>MultiLayer Perception</i>				
a	b	c	d	< classificação por	a	b	c	d	< classificação por
29	01	01	00	a = COMP	30	01	00	00	a = COMP
01	40	00	00	b = LARG	02	39	00	00	b = LARG
00	01	12	00	c = COMP ou LARG	00	00	13	00	c = COMP ou LARG
00	00	00	03	d = NÃO	00	00	00	03	d = NÃO

Na Tabela 2 é possível verificar que a maiores quantidades de TP Rate (falso positivo) e FP Rate (falso negativo) ocorreram na classe relacionada à largura (LARG) no algoritmo J48.

TABELA 2 - Resultados dos algoritmos J48 e *MultiLayer Perception*

Classificadores	Acurácia				
	Razão TP	Razão FP	Recolha	Precisão	Classe
J48	0,935	0,018	0,935	0,967	COMP
	0,976	0,043	0,976	0,952	LARG
	0,923	0,013	0,923	0,923	COMP ou LARG
	1,000	0,000	1,000	1,000	NÃO
<i>MultiLayer Perception (MLP)</i>	0,986	0,035	0,968	0,938	COMP
	0,951	0,021	0,951	0,975	LARG
	1,000	0,000	1,000	1,000	COMP ou LARG
	1,000	0,000	1,000	1,000	NÃO

Ainda com os dados gerados pelo treinamento o algoritmo J48 resultou em 93,5% de recolha e 96,7 % de precisão em relação ao conjunto de dados de teste real para a classe de comprimento (COMP). Em relação a largura (LARG), os resultados para recolha e precisão média foram de 97,6% e 95,2%, respectivamente.

No caso do algoritmo *MultiLayer Perception (MLP)* os resultados encontrados para o COMP foram superiores aos do algoritmo, resultando em 96,8% para recolha e 93,8% de precisão média. A largura (LARG) apresentou os resultados de recolha inferiores dentre os parâmetros avaliados. Para a classificação de sementes, TEKALINGTUJI et al (2017) testaram diversos classificadores com a finalidade de separar as sementes por meio de suas formas, tamanhos e tipo varietal, entre eles o que mais destacou-se foi o MLP, expressando o maior valor de precisão 97,6%.

Assim como nos resultados apresentados por esse estudo, em trabalho de ROPELEWESKA e RUTKOWSKI (2021) avaliaram as dimensões lineares e fatores de forma de sementes de diferentes cultivares de maçã por meio do processamento de imagens. Os resultados indicaram 93% de precisão para análises com base em suas dimensões, 90% para modelos construídos com base nos fatores de forma e 91% com base na combinação entre ambos, significando que pode ocorrer a distinção de dimensões entre as sementes e a eficácia do método.

4. CONCLUSÕES

De acordo com os resultados encontrados, verifica-se que é possível separar as sementes de arroz de acordo com as suas dimensões, com grande acurácia e precisão, por meio da inteligência artificial. Entre as classificações utilizadas, destacou-se a *MultiLayer Perception* apresentando menores taxas de erro em relação ao J48. Conforme os resultados e por se tratar de um método não destrutivo, sua utilização pode ser indicada como método de separação para sementes de cultivares diferentes.

5. REFERÊNCIAS BIBLIOGRÁFICAS

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

CONAB. **Acompanhamento da safra brasileira de grãos**. Acessado em 19 jul. 2021. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>.

MENEZES, N. L. de; CÍCERO, S. M.; VILLELA, F. A. Identificação de fissuras em sementes de arroz após a secagem artificial, por meio de raios-X. **Ciência Rural**, [S.L.], v. 35, n. 5, p. 1194-1196, 2005.

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.

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

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.

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.

ROPELEWSKA, E.; RUTKOWSKI, Krzysztof P. Cultivar discrimination of stored apple seeds based on geometric features determined using image analysis. **Journal Of Stored Products Research**, [S.L.], v. 92, p. 101804, 2021.

TEKALINGNTUJI, G., DILEEP, K. G., ELIFENESH, Y. D., MESERET, G. B. Predictive Model to Predict Seed Classes using Machine Learning. **International Journal of Engineering Research & Technology (IJERT)**, vol. 6, no. 08, pp. 334-344, 2017.