

UNIVERSIDADE FEDERAL DO PAMPA

DOUGLAS MONTANHA GIORDANO

**DEMÉTER: UM SOFTWARE PARA DETECÇÃO DA PERDA DE GRÃOS DA
PANÍCULA DO ARROZ**

**Alegrete
2023**

DOUGLAS MONTANHA GIORDANO

**DEMÉTER: UM SOFTWARE PARA DETECÇÃO DA PERDA DE GRÃOS DA
PANÍCULA DO ARROZ**

Dissertação apresentado ao curso de Pós
Graduação em Engenharia de Software do
Campus Alegrete da Universidade Federal do
Pampa como requisito parcial para obtenção do
grau de Mestre em Engenharia de Software.

Orientador: Dr. João Pablo Silva da Silva

**Alegrete
2023**

Ficha catalográfica elaborada automaticamente com os dados fornecidos
pelo(a) autor(a) através do Módulo de Biblioteca do
Sistema GURI (Gestão Unificada de Recursos Institucionais) .

G497d Giordano, Douglas Montanha

Deméter: um software para detecção da perda de grãos da
panícula do arroz / Douglas Montanha Giordano.

61 p.

Dissertação(Mestrado)-- Universidade Federal do Pampa,
MESTRADO EM ENGENHARIA DE SOFTWARE, 2023.

"Orientação: João Pablo Silva Da Silva".

1. Engenharia de Software. 2. Processamento de Imagens. 3.
Aprendizado de Máquina. 4. Agricultura. 5. Arroz. I. Título.

DOUGLAS MONTANHA GIORDANO

DEMÉTER - UM SOFTWARE PARA DETECÇÃO DE PERDA DE GRÃOS DA PANÍCULA DO ARROZ

Dissertação apresentada ao Programa de Engenharia de Software, da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia de Software.

Dissertação defendida e aprovada em: 14/06/2023.

Banca examinadora:

Prof. Dr. João Pablo Silva da Silva
Orientador
Unipampa

Prof. Dra. Alice Fonseca Finger
Unipampa

Prof. Dr. Marcelo Serrano Zanetti
UFSM



Assinado eletronicamente por **JOAO PABLO SILVA DA SILVA, PROFESSOR DO MAGISTERIO SUPERIOR**, em 14/06/2023, às 11:12, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **ALICE FONSECA FINGER, PROFESSOR DO MAGISTERIO SUPERIOR**, em 14/06/2023, às 11:13, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **Marcelo Serrano Zanetti, Usuário Externo**, em 14/06/2023, às 13:09, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



A autenticidade deste documento pode ser conferida no site https://sei.unipampa.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1147670** e o código CRC **4F959D5D**.

Dedico esta dissertação aos meus pais Ana Cláudia e Rui e também a minha esposa Adriana, uma das mulheres mais fortes que já conheci. Ambos a fonte da minha alegria e força.

AGRADECIMENTO

A toda minha família pelo apoio durante o processo de desenvolvimento da dissertação e também demais atividades relacionadas com a pós. Minha mãe (Ana Cláudia Montanha Giordano), meu pai (Rui Souza Giordano) e a minha esposa (Adriana Souza de Quadros) foram os pilares do que eu sou e do que serei.

Ao prof. Dr. João Pablo Silva da Silva pelo apoio durante a pesquisa e principalmente por não desistir de mim durante alguns obstáculos durante o processo de escrita da dissertação e também desenvolvimento da pesquisa.

Ao meu ex colega de trabalho, amigo e também revisor da minha dissertação Miguel Ecar.

Aos meus amigos próximos, pelos momentos de alegria que permitiram recarregar as energias.

Aos professores que ajudaram a construir cada pedaço de conhecimento que carrego hoje e sempre.

“A vida só pode ser comprendida, olhando-se
para trás; mas só pode ser vivida, olhando-se
para frente.”

– Søren Kierkegaard

RESUMO

O arroz é um dos alimentos mais consumidos do mundo e a sua demanda é bastante alta. Durante a produção do arroz, os agricultores podem enfrentar diversos cenários que venham a comprometer sua produção, diminuindo a quantidade produzida durante uma determinada safra. Eventos climáticos, doenças, problemas no solo e pragas são alguns dos fatores que podem influenciar negativamente na produção do arroz. A detecção dessa perda e também sua contagem pode auxiliar o agricultor a buscar possíveis causas. A tecnologia pode ser um recurso importante, oferecendo suporte ao agricultor na detecção de possíveis problemas na lavoura. Esse estudo tem como objetivo apresentar a ferramenta Deméter. A ferramenta Deméter é um conjunto de microsserviços responsáveis pela detecção da perda de uma planta de arroz. Atualmente usamos algoritmos de aprendizado de máquina, especificamente SVM, *Decision Tree* e *Forest Random*, para classificar possíveis locais de perda na planta. O melhor resultado foi obtido com o algoritmo SVM. Novos estudos podem ser feitos para avaliar as entradas e os hyper parametros com outros algoritmos de aprendizado de máquina.

Palavras-chave: Engenharia de Software. Processamento de Imagens. Aprendizado de Máquina. Agricultura. Arroz.

ABSTRACT

Rice is one of the most consumed foods in the world and it requires a high demand. During rice production, farmers may face several scenarios that can compromise rice production, reducing the amount produced during a given harvest. Climatic events, diseases, soil problems, and pests are some of the factors that can influence in rice production. The detection of this loss and also counting it can help the farmer to look for possible causes. Technology can be an important resource and may help the farmer to detect these possible problems. Drones are great resources that can be used to identify places where rice grain is lost, which leads to reduced production. Therefore, a set of services, together with the drone, can help the farmer in detecting the loss. This study aims to present Demeter, which is a set of microservices responsible for detecting the loss of a rice plant. We are currently using machine learning algorithms, specifically SVM, Decision Tree, and Forest Random, to classify possible loss locations in the plant. The best result was obtained with the SVM algorithm. New studies can be done to evaluate inputs and hyperparameters with other machine learning algorithms.

Keywords: Software Engineering. Image Processing. Machine Learning. Agriculture. Rice.

LISTA DE FIGURAS

Figura 1 – Processo representando as etapas da pesquisa.	29
Figura 2 – Etapas do reconhecimento de padrões em uma imagem. Fonte: Autor. . . .	33
Figura 3 – Quantidade de estudos após cada etapa de seleção dos estudos.	41
Figura 4 – Média da métrica <i>accuracy</i> por algoritmo representando cada um dos estudos selecionados.	42
Figura 5 – A ferramenta Deméter, representando as fronteiras do estudo.	46
Figura 6 – <i>Feature Model</i> da ferramenta Deméter.	47
Figura 7 – Arquitetura de microserviços do Deméter considerando as <i>features</i> de <i>Grain Detector</i> , <i>Classifier Trainer</i> e <i>Grain Loss Counter</i>	48
Figura 8 – Método de treinamento do classificador.	49
Figura 9 – Exemplo de panícula do arroz. Fonte: Autor.	50
Figura 10 – Imagem usada como entrada no microserviço para contagem de perda. . . .	54
Figura 11 – Imagem usada como entrada no microserviço para contagem de perda e armazenada após a detecção de bordas usando <i>Harris Corner Detection</i>	55
Figura 12 – Imagem usada como entrada no microserviço para contagem de armazenada e salva após o processo de identificação usando o classificador treinado	56

LISTA DE TABELAS

Tabela 1 – Critérios de Inclusão.	38
Tabela 2 – Critérios de Exclusão.	39
Tabela 3 – Score de qualidade.	39
Tabela 4 – Critérios de Qualidade.	39
Tabela 5 – Definição dos dados de extração.	40
Tabela 6 – Configuração do algoritmo e população utilizado para treinamento do classificador.	51
Tabela 7 – O melhor resultado de cada algoritmo usado na criação do classificador.	53

LISTA DE QUADROS

Figura 3.1 – Termos e seus respectivos sinônimos usados na construção da string de busca.	38
Figura 3.2 – String de buscas utilizada nas bases de dados e motores de busca.	38

LISTA DE ABREVIATURAS E SIGLAS

UNIPAMPA – Universidade Federal do Pampa

SVM – Support Vector Machine

HOG – Histogram of Oriented Gradients

MCC – Matthews Correlation Coefficient

IA – Inteligência Artificial

QR – Quick Response

FM – Feature Model

SUMÁRIO

1	INTRODUÇÃO	27
1.1	Motivação	27
1.2	Objetivo	28
1.3	Metodologia	28
1.4	Contribuições	29
1.5	Organização do Documento	29
2	REFERENCIAL TEÓRICO	31
2.1	Processamento de Imagens Digitais	31
2.2	Segmentação de Imagens	31
2.3	Reconhecimento de Padrões em Imagens	32
2.3.1	Extração de Características	33
2.3.2	Pré-processamento dos Dados	33
2.3.3	Treinamento do Classificador	34
2.3.3.1	Naive Bayes	34
2.3.3.2	Decision Tree	34
2.3.3.3	Support Vector Machine (SVM)	35
2.3.4	Avaliação do Classificador	35
2.4	Lições do Capítulo	36
3	TRABALHOS RELACIONADOS	37
3.1	Protocolo da Revisão	37
3.1.1	Questões de Pesquisa	37
3.1.2	Processo de Busca	37
3.1.3	Processo de Seleção	38
3.1.4	Extração e Análise de Dados	39
3.2	Execução da Revisão	40
3.2.1	Questão de Pesquisa Q1	40
3.2.2	Questão de Pesquisa Q2	41
3.3	Ameaças à Validade	42
3.4	Lições do Capítulo	43
4	DESENVOLVIMENTO	45
4.1	Visão Geral da Solução	45
4.2	Classificador: detecção da ausência do grão do arroz	48
4.2.1	Seleção dos Dados	49
4.2.2	Pré-Processamento da Imagem	49
4.2.3	Segmentação das Áreas de Interesse	50
4.2.4	Extração das Características	50
4.2.5	Treinamento do Classificador	51
4.3	Lições do Capítulo	51
5	RESULTADOS	53
5.1	Resultados do Classificador	53
5.2	Microserviço de reconhecimento da perda de grãos	54
5.3	Lições do Capítulo	56

6	CONSIDERAÇÕES FINAIS	57
6.1	Contribuições	57
6.2	Limites	57
	REFERÊNCIAS	59

1 INTRODUÇÃO

O cultivo de arroz faz parte da grande história da humanidade, sendo uma das principais fontes de alimento em muitos países. O aumento do consumo de arroz levou a indústria agrícola a procurar novos meios de aumentar a produção e atingir as expectativas de consumo. Os países com o objetivo de atingir as necessidades locais de consumo, acabaram importando arroz de outros países ou novas tecnologias que apoiassem o aumento de sua produção.

A tecnologia tem oferecido suporte ao processo de produção de arroz, e consequentemente aumentado a produção através da automação. Exemplos de uso da tecnologia na produção de arroz são: a criação de famílias híbridas de arroz alteradas geneticamente (LI; YUAN et al., 2000; YUAN; FU et al., 1995); maquinário usado na plantação, irrigação e colheita do arroz com um grande suporte computacional (LI et al., 2020; MASSERONI et al., 2017); uso de drones para detecção de doenças em lavouras (KITPO; INOUE, 2018; STAVRAKOUDIS et al., 2019); e o controle totalmente automatizado do maquinário através da agricultura de precisão (KUMAR; KARALIYA; CHAUDHARY, 2017). Contudo, apesar do aumento de produção usando tecnologias cada vez mais sofisticadas, muitos problemas ainda ocorrem na produção de arroz.

1.1 Motivação

Um dos problemas mais comuns durante o processo de desenvolvimento do Arroz são os eventos climáticos em certas épocas do ano e em determinados países (WASSMANN et al., 2010; KIM; PANG, 2009). Contudo, eventos não esperados podem ocorrer durante a produção do arroz, a qual pode ser muito afetada pelas variações do tempo (LANSIGAN; SANTOS; COLADILLA, 2000). Além disso, é importante salientar que eventos climáticos, são eventos comuns e mesmo assim podem causar prejuízos à produção de arroz. A agricultura não sofre apenas por fatores climáticos, além disso existem outros fatores que podem comprometer a produção e ocasionar a perda de grãos.

Doenças, ação do vento, problemas na qualidade do solo são outros exemplos de fatores que podem afetar a quantidade produzida de arroz. Comumente os agricultores procuram meios de identificar a ocorrência de problemas em sua produção. A identificação de problemas precocemente pode diminuir o impacto na lavoura e possibilitar mais tempo para ações do agricultor, diminuindo a perda da produção (BAITE et al., 2020; FOMBA; SINGH, 1990).

A planta arroz é constituída de várias partes, que mudam no decorrer de seu crescimento como por exemplo em sua fase de embrião, fase vegetativa e fase de reprodução. A inflorescência do arroz é chamada de panícula devido ao seu formato cônico ou de pirâmide. Nas extremidades da panícula, encontramos os ramos ao qual encontramos os grãos do Arroz que posteriormente são descascados e usados na produção até o consumo do arroz (ITOH et al., 2005).

A automatização do processo de identificação de possíveis perdas de grãos na lavoura

pode auxiliar o agricultor. Por exemplo, um software pode realizar a captura e análise de imagens com o objetivo de identificar a perda em locais de difícil acesso para o agricultor. Além disso, um software também possibilitaria analisar muitas áreas, sem a necessidade de uma equipe especializada para identificar a perda.

Contudo, esse escopo é muito amplo, podendo envolver desde um software para a tomada de decisão de possíveis áreas que devem ser analisadas até o processo de identificação da ausência do grão na panícula do arroz. Logo, é importante priorizar e identificar o principal problema na automatização do processo. Considerando o principal objetivo encontrado no problema de automatização, este estudo levanta a seguinte questão de pesquisa:

- Como automatizar a detecção da perda do grão de arroz em lavouras de arroz?

1.2 Objetivo

O objetivo deste estudo é propor uma solução computacional baseada em processamento de imagens e inteligência artificial para a identificação da ausência do grão na panícula do arroz. Abaixo seguem os seguintes objetivos específicos:

- investigação do estado da arte das tecnologias de detecção de grãos;
- criação de classificadores para detectar a ausência do grão na panícula;
- desenvolvimento de um conjunto de microsserviços para segmentação e detecção da ausência do grão na panícula;
- avaliação do sistema através de experimentos e métricas de desempenho de classificação.


1.3 Metodologia

Seguindo a taxonomia de Prodanov Cleber Cristiano de Freitas (2013) nossa pesquisa pode ser classificada em três dimensões. Quanto à natureza da pesquisa, quanto aos objetivos e quanto aos procedimentos. A pesquisa tem natureza aplicada, ou seja, foca na aplicação do conhecimento gerado ou existente para a resolução de um problema prático.

Quanto aos objetivos, a pesquisa é classificada como exploratória. Tem o objetivo de desenvolver uma solução para detectar a perda do grão da panícula do arroz, ou seja o conhecimento existente na literatura e o estado da arte da mesma será usada como insumo na construção da solução. Quanto aos procedimentos, nossa pesquisa é classificada como pesquisa experimental, uma vez que iremos realizar uma avaliação na solução para verificar e determinar sua contribuição e expressividade.

A etapa de revisão bibliográfica será executada com base nos *guidelines* propostos por Kitchenham (2004). As etapas relacionadas a processamento e segmentação de imagens serão executadas usando a biblioteca Scikit Image. A biblioteca atualmente é muito usada pela comunidade Python e possui vários algoritmos para detectar áreas de interesse.

Figura 1 – Processo representando as etapas da pesquisa.



Fonte: Autor.

A ferramenta usada para preprocessar os dados de treinamento e treinar os classificadores é a biblioteca *Scikit-learn*. A biblioteca contém um conjunto de algoritmos prontos para a geração de classificadores e também avaliação dos mesmos. O algoritmo SVM, *Naive Bayes* e *Decision Tree* serão usados no treinamento dos classificadores. O algoritmo *Adaboost* será usado para balancear os exemplos de dados das imagens.

1.4 Contribuições

As contribuições do estudo não se limitam em apenas na automatização do processo de contagem da perda de arroz. Segue abaixo uma lista das potências contribuições do estudo:

- classificador para o reconhecimento da perda do grão de arroz;
- criação de uma base de dados de imagens da panícula do arroz que podem ser usados pela comunidade científica;

1.5 Organização do Documento

O restante deste documento está organizado da seguinte forma:

- no capítulo 2 são apresentados os insumos e informações básicas das técnicas, tecnologias e métodos utilizados na pesquisa;

- no capítulo 3 é reportado um mapeamento sistemático da área, focando na busca por estudos que usam reconhecimento de imagens para o reconhecimento de grãos em plantas de arroz;
- no capítulo 4 é relatado o desenvolvimento do classificador, apresentando o método utilizado e os resultados de desempenho;
- no capítulo 5 são relatados os resultados de desempenho do classificador e a apresentação do microserviço que utiliza o mesmo para a contagem de perda;
- no capítulo 6 são discutidos os próximos passos da pesquisa, limites, contribuições e ameaças a validade.

2 REFERENCIAL TEÓRICO

Este capítulo tem como objetivo apresentar os pressupostos conceituais para o entendimento da metodologia usada para atingir o objetivo de pesquisa. A pesquisa envolve algoritmos de processamento de imagens e inteligência artificial. Logo, cada algoritmo está envolvido em uma etapa da metodologia de reconhecimento de uma imagem. A Seção 2.1 descreve a importância na melhoria de características da imagem para o seu reconhecimento e segmentação. A Seção 2.2 aborda a etapa de extração das áreas de interesse da imagem. A Seção 2.3 descreve as principais etapas no processo de classificação de uma imagem.

2.1 Processamento de Imagens Digitais

O processamento de imagens é uma etapa comumente encontrada em sistemas de processamento de imagens e também é considerada uma área de estudo. Alguns autores separam o processamento de imagens como uma grande área e outros como uma pequena etapa dentro da visão computacional, especificamente denominando a mesma como pré-processamento. Ambas afirmações podem ser consideradas corretas, visto que qualquer operação computacional em uma imagem digital pode ser considerada um processamento de imagem.

Atualmente, nota-se o uso de processamento de imagens em diversos dispositivos do dia a dia, como por exemplo a leitura de um simples Quick Response (QR) Code ou mesmo o lento surgimento de carros autônomos em países desenvolvidos. Todos os anos surgem novas pesquisas que envolvem a criação de novos algoritmos de processamento de imagens ou a sua aplicação.

Logo, muitas pesquisas ainda são recentes e abordam os mais diferentes temas como por exemplo a melhoria do processo de produção na agricultura (DESAI; KANPHADE, 2021; RAFI et al., 2021) e a ajuda na detecção de doenças na medicina (DOUGHERTY, 2009; BHATTACHARYA et al., 2021; DEVI; NAYYAR, 2021). A evolução da área é constante e o seu interesse aumenta cada vez mais.

2.2 Segmentação de Imagens

A segmentação de imagens tem como objetivo extrair da imagem as áreas de interesses (GONZALEZ; WOODS, 2000). A extração tem como objetivo isolar o que é realmente importante para a resolução do problema.

A medicina é uma área bastante beneficiada com o uso de algoritmos de segmentação. Muitas pesquisas aplicam ou propõem novos algoritmos para segmentação, com o interesse em facilitar a detecção de doenças em imagens médicas (MÜLLER; KRAMER, 2021).

Atualmente, existem muitos tipos de algoritmos usados para realizar a segmentação de uma imagem. Alguns algoritmos são baseados em cálculos matemáticos, utilizando implementações mais simples, como por exemplo: algoritmos de detecção de linha, bordas ou técnicas de

limiarização (GONZALEZ; WOODS, 2000). Outros algoritmos realizam a segmentação através de algoritmos de inteligência artificial (BADRINARAYANAN; KENDALL; CIPOLLA, 2017; MILLETARI; NAVAB; AHMADI, 2016), utilizando como insumo em seus algoritmos imagens pré-processadas.

O algoritmo *Harris Corner Detector* é um exemplo de segmentador muito usado na detecção de cantos (HARRIS; STEPHENS et al., 1988). O algoritmo foi criado em 1988 e tem como conceito a detecção do canto através da variação de intensidade, considerando todas direções.

2.3 Reconhecimento de Padrões em Imagens

O processo de reconhecimento de padrões é uma parte da análise de imagens e tem como objetivo identificar padrões em uma imagem (GONZALEZ; WOODS, 2000). A identificação de padrões é muito utilizada, visto que a imagem digital, e suas áreas de interesse segmentadas, são apenas pixels, sem uma identificação do que as mesmas representam no mundo real.

Os algoritmos de reconhecimento de padrões podem ser utilizados em aplicações simples como a identificação se uma figura geométrica é uma quadrado ou triângulo ou também em situações complexas como a identificação da espécie de uma planta.

As etapas do reconhecimento de padrões de uma imagem dependem do contexto do problema e a técnica utilizada para a resolução do mesmo. Este estudo foca no uso de algoritmos de inteligência artificial para a resolução de problemas. Especificamente, são utilizados algoritmos supervisionados para realizar o reconhecimento da área de interesse, após processamento da imagem e segmentação dos objetos de interesse.


As principais etapas para reconhecimento de uma imagem são demonstradas na Figura 2. A primeira etapa, denominada de extração de características, tem como objetivo definir quais características serão extraídas de um conjunto de imagens utilizado como entrada no algoritmo supervisionado.

A segunda etapa, denominada de pré-processamento dos dados (Seção 2.3.1), tem como objetivo realizar um tratamento nas características extraídas de cada imagem, removendo possíveis *outliers* dos dados. Além disso, nessa etapa é realizado o processo de normalização dos dados e separação dos dados de treinamento e teste (utilizado para avaliação do algoritmo).

A terceira etapa, denominada de treinamento do classificador (Seção 2.3.3), tem como objetivo criar classificadores para reconhecer o padrão na imagem e definir uma classificação para a mesma. Durante essa etapa são criados vários classificadores com o objetivo de escolher o melhor.

A última etapa, denominada avaliação do classificador (Seção 2.3.4), tem como objetivo avaliar os classificadores gerados. A avaliação é feita com base nos dados de testes e são aplicadas métricas de desempenho em cada um dos classificadores para selecionar o classificador com o melhor resultado.

Figura 2 – Etapas do reconhecimento de padrões em uma imagem. Fonte: Autor.



Fonte: Autor.

2.3.1 Extração de Características

A extração de características tem como objetivo reduzir a complexidade da imagem, através da extração de suas principais características. A extração de características faz parte do processo de redução de dimensionalidade. A redução tem como objetivo diminuir a complexidade dos dados utilizados para treinamento através do agrupamento de informações facilmente gerenciáveis (KUMAR; BHATIA, 2014).

A representação comumente são características da imagem, como por exemplo suas linhas, cores ou mesmo alguma outra representação mais complexa. Esses agrupamentos de informações são também conhecidos como *Feature Descriptor*. Um *Feature Descriptor* bastante usado na extração de características de imagens é o Histogram of Oriented Gradients (HOG). HOG é um algoritmo muito usado pois extrai as principais características de uma imagem. O algoritmo tem maior foco na estrutura e forma do objeto (DALAL; TRIGGS, 2005).

2.3.2 Pré-processamento dos Dados

A etapa de pré processamento tem como objetivo preparar os dados para o processo de treinamento. A primeira etapa é a remoção dos *outliers*. Um *outlier* é uma observação, exemplo ou mesmo um dado fora do padrão, ou seja, muito distante das demais observações (HAWKINS, 1980).

Os *outliers* podem ser classificados considerando seu contexto de uso e o seu possível impacto no uso dos dados. *Outliers* de erro e *Fit Model* são exemplos de possíveis categorias que um determinado dado não esperado pode se encaixar (AGUINIS; GOTTFREDSON; JOO, 2013). O *outliers* de erro representa dados que foram capturados ou calculados de forma imprecisa, ou seja, um dado incorreto. Os *outliers* de *Model Fit* comumente representam *Outliers* que influenciam no ajuste de um determinado modelo em treinamento.

Este estudo foca no uso de métodos para detectar *outliers* de erro durante o pré-processamento dos dados. Os *outliers* serão detectados usando o método de GRUBBS (GRUBBS, 1969). A

detecção de GRUBBS é baseado na distância e pode ser classificado como uma técnica de construção múltipla (AGUINIS; GOTTFREDSON; JOO, 2013). O cálculo para detectar a mudança de comportamento consiste em:

$$T = ((mean - value))/SD \quad (2.1)$$

O calculo de GRUBBS é calculado com base no resultado da subtração entre a média (*mean*) do conjunto de dados e o valor (*value*) comparativo dividido pelo desvio padrão (*SD*).

A normalização é uma etapa usada com o objetivo de diminuir a complexidade dos dados através da diminuição ou aumento do intervalo (PATRO; SAHU, 2015). Logo, a normalização é uma etapa importante de pré-processamento dos dados antes do treinamento. Este estudo foca-se no uso da normalização L2. A normalização L2 é muito eficiente e simples de ser aplicada em um conjunto de dados (HADJIELEFThERIOU; KOUDAS; SRIVASTAVA, 2009).

2.3.3 Treinamento do Classificador

O treinamento de um classificador é baseado em um conjunto de algoritmos. O resultado desse treinamento é um modelo ajustado que possibilita a classificação de determinada informação considerando um contexto de aplicação. Um exemplo de um simples classificador é um modelo que possibilita classificar uma determinada figura geométrica em quadrado, círculo ou retângulo.

Atualmente existe um grande conjunto de algoritmos para criar classificadores. Este estudo concentra-se no emprego dos seguintes algoritmos: NAIVE BAYES, DECISION TREE e SVM.

2.3.3.1 Naive Bayes

O algoritmo Naive Bayes é um algoritmo de classificação probabilístico simples e eficiente que é amplamente utilizado em aprendizado de máquina e foi baseado no teorema de Bayes (RISH et al., 2001).

O Naive Bayes funciona criando um modelo probabilístico a partir dos dados de treinamento para cada classe. Esse modelo é usado para prever a classe de novos exemplos. O algoritmo assume que a probabilidade de um exemplo pertencer a uma classe é igual à probabilidade de cada um de seus atributos, dados os valores dos outros atributos e a classe.

Devido a sua simplicidade, o algoritmo Naive Bayes é usado em diferentes tipos de problemas de classificação .

2.3.3.2 Decision Tree

O algoritmo Decision Tree (ou árvore de decisão) é uma técnica de aprendizado de máquina supervisionado que é usada para resolver problemas de classificação e regressão (BREI-MAN, 2001). .

O algoritmo Decision Tree funciona criando uma árvore onde cada nó representa um atributo, cada ramificação representa uma decisão e cada folha representa uma classe ou um valor de regressão. O objetivo é dividir o conjunto de dados em subconjuntos cada vez menores, de forma que cada subconjunto seja cada vez mais homogêneo em termos da classe.

A construção da árvore começa selecionando o melhor atributo para dividir o conjunto de dados. Existem diferentes métricas para selecionar o melhor atributo, como a entropia ou ganho de informação. O processo de divisão é repetido recursivamente para cada subconjunto, até que não seja possível dividir mais ou até que se atinja um critério de parada pré-definido, como o tamanho mínimo da folha ou o número máximo de níveis.

2.3.3.3 SVM

Por fim, o SVM é um algoritmo binário utilizado para classificação, comumente apresentando bons resultados na aplicação para o reconhecimento de padrões em imagens (JOACHIMS, 1998). SVM também pode resolver problemas de multiclasse, porém o foco desse estudo é em seu comportamento na classificação binária.

O SVM funciona encontrando um hiperplano que melhor separa as classes no espaço de atributos. O hiperplano é escolhido de tal forma que a margem entre as duas classes é maximizada. A margem é a distância entre o hiperplano e os pontos de dados mais próximos de cada classe, também conhecidos como vetores de suporte.

2.3.4 Avaliação do Classificador

A avaliação de um classificador é realizada considerando seus dados de treinamento e teste. Os dados de treinamento são usados como entrada para treinar o algoritmo supervisionado e os dados de teste são usados para avaliar a efetividade do classificador. Os dados de testes são usados como entrada no classificador em treinamento e o resultado é capturado, criando uma métrica considerando o erro ou acerto daquele determinado exemplo de entrada.

A avaliação dos classificadores pode ser realizada usando um conjunto de métricas. Este estudo foca-se no uso da matriz de confusão e as métricas de *accuracy*, *recall*, *precision*, *F1-Score* e Matthews Correlation Coefficient (MCC).

Tomando como hipótese duas possíveis condições, uma positiva (P) e outra negativa (N). A matriz de confusão tem como resultado o número de verdadeiros positivos (VP), falsos positivos (FP), verdadeiros negativos (VN) e falsos negativos (FN).

A *accuracy* é calculada com base na soma dos positivos e negativos verdadeiros divididos pela soma das duas condições como apresentado na equação 2.2.

$$(TP + TN)/(P + N) \quad (2.2)$$

O *recall* é calculado com base na divisão dos positivos verdadeiros com a soma dos falsos negativos e os positivos verdadeiros como apresentado na equação 2.3.

$$TP/(FN + TP) \quad (2.3)$$

A *precision* é calculada com base na divisão dos positivos verdadeiros com a soma dos falsos positivos e positivos verdadeiros como apresentado na equação 2.4.

$$TP/(FP + TP) \quad (2.4)$$

A métrica F1-Score é criada com base no *recall* e *precision*, sendo uma ótima métrica de desempenho para classificadores binários. A equação 2.5 demonstra estrutura a F1-Score.

$$F1 - Score = \frac{2 \times (Recall \times Precision)}{Recall + Precision} \quad (2.5)$$

O MCC é uma medida de qualidade para classificadores binários (SVM). O resultado igual a +1 representa uma predição sem erros, 0 é considerada uma predição randômica e -1 indica erros em toda predição. A equação 2.6 demonstra a expressão usada para encontrar o valor da métrica MCC.

$$MCC = \frac{TP \times TN - FP \times FN}{(TP + FP)(TP + FN)(TN + FP)(TN + FN))} \quad (2.6)$$

2.4 Lições do Capítulo

O processo de construção de um software para reconhecimento de imagens engloba muitas etapas, contudo cada qual com sua importância. A captura, pré processamento, segmentação e treinamento do classificador demonstra a complexidade do processo e as decisões que devem ser tomadas durante o desenvolvimento.

A escolha dos algoritmos adequados ao contexto, e uma boa base de exemplos para realizar o treinamento são peças fundamentais de um classificador com um desempenho ótimo. O uso de algoritmos existentes, com aplicações já testadas na indústria e academia pode acelerar o processo de desenvolvimento. Contudo, sempre é interessante a diversidade de possíveis classificadores treinados, possibilitando a escolha do que possuir o melhor resultado. Principalmente em contextos de reconhecimento não conhecidos.

O próximo capítulo apresenta um conjunto de pesquisas que fazem o uso de todo o processo descrito nesse capítulo. Este conjunto foi buscado através de uma revisão sistemática. Esses estudos demonstram o grande avanço da tecnologia durante o processo de produção de arroz.

3 TRABALHOS RELACIONADOS

Este capítulo tem como objetivo apresentar a metodologia utilizada na busca dos trabalhos relacionados e seus resultados. A pesquisa dos estudos foi norteadada através da definição e execução de uma revisão sistemática. A revisão tem como objetivo descobrir o estado da arte das tecnologias de processamento de imagens utilizadas em soluções de detecção de grãos em lavouras de arroz. A revisão sistemática descrita nas próximas seções é baseada nos *guidelines* propostos por (KITCHENHAM, 2004). A Seção 3.1 apresenta o protocolo que guia toda a busca por trabalhos relacionados. A Seção 3.2 apresenta o processo de execução do protocolo e seus respectivos resultados. A Seção 3.3 demonstra as possíveis ameaças a validade da revisão sistemática executada. Por fim, a Seção 3.4 lista e contextualiza os principais pontos discutidos no capítulo.

3.1 Protocolo da Revisão

O objetivo da revisão sistemática é analisar os estudos de processamento de imagens com o objetivo de encontrar soluções de detecção de grãos em lavouras de arroz. Portanto, nossa meta está estruturada da seguinte forma:

Analisar	estudos de processamento de imagens
no intuito de	descobrir o estado da arte
no que tange a	detecção de grãos em lavouras de arroz
na perspectiva de	pesquisadores
no contexto do	publicações científicas.

3.1.1 Questões de Pesquisa

As questões de pesquisa foram definidas baseadas na técnica *Population, Intervention, Comparison, Outcomes* (PICO) (SANTOS; PIMENTA; NOBRE, 2007).

- **Q1.** Quais são as diferenças de desempenho da aplicação de algoritmos de aprendizado de máquina em relação aos algoritmos baseados em formato, características ou histogramas na segmentação de áreas de interesse de imagens contendo grãos?
- **Q2.** Quais são as diferenças de desempenho da aplicação de algoritmos de aprendizado de máquina em relação aos algoritmos baseados em formato, características ou histogramas no reconhecimento de grãos?

3.1.2 Processo de Busca

O processo de busca se baseia nos termos da área de interesse da pesquisa, a meta da revisão e as questões de pesquisa. Considerando esses contextos, definimos os seguintes termos relacionados a revisão no Quadro 3.1

Quadro 3.1 – Termos e seus respectivos sinônimos usados na construção da string de busca.

Termo	Sinônimo
image processing	computer vision
agriculture	farming, tillage
seed	grain
recognize	identify, detect
rice	-

Fonte: Autor.

Usando como base os termos e seus respectivos sinônimos foi criado a seguinte *string* de busca demonstrada no Quadro 3.2.

Quadro 3.2 – String de buscas utilizada nas bases de dados e motores de busca.

String de Busca
(“image processing” OR “computer vision”) AND (agriculture OR farming OR tillage) AND (seed OR grain) AND (recognition OR identification OR detection OR recognize OR detect) AND rice)

Fonte: Autor.

As strings de busca foram utilizadas nos respectivos métodos de busca e bases de dados: Scopus, Engineering Village, Science Direct, ACM, IEEE e Springer Link.

3.1.3 Processo de Seleção

O processo de seleção envolve a aplicação de alguns critérios objetivando a decisão de incluir o estudo ou não na revisão sistemática. Os critérios de inclusão, exclusão e qualidade são descritos a seguir.

A Tabela 1 descreve o critério de inclusão, o qual refere-se ao que deve ser considerado para incluir o estudo na seleção.

Tabela 1 – Critérios de Inclusão.

Identificador	Descrição
IC-001	Estudo primários que aplicam técnicas de processamento de imagens no reconhecimento de sementes

Fonte: Autor.

A Tabela 2 descreve os critérios de exclusão, os quais referem-se ao que deve ser considerado para excluir o estudo na seleção. Caso um estudo seja definido para qualquer um dos critérios de exclusão, o mesmo é desclassificado da seleção.

Os critérios de qualidade são baseados em um Score. Caso o estudo tenha um peso maior que o mínimo definido, o mesmo é selecionado. A Tabela 3 demonstra o score definido

Tabela 2 – Critérios de Exclusão.

Identificador	Descrição
EC-001	Estudos duplicados
EC-002	Estudos abaixo de 6 páginas
EC-003	Estudos secundários ou terciários
EC-004	Estudos não escritos em inglês

Fonte: Autor.

através de intervalos e suas respectivas descrições. A Tabela 4 define dois critérios de qualidade, usando como base o score de qualidade citado anteriormente.

Tabela 3 – Score de qualidade.

Início	Fim	Descrição
0	0	Qualidade Baixa
0,1	0,33	Qualidade Média
0,34	0,66	Qualidade Boa
0,67	1	Qualidade Excelente

Fonte: Autor.

Tabela 4 – Critérios de Qualidade.

ID	Descrição	Regras do Score		Peso	Min.
		Regra Score	Descrição		
QQ-01	O estudo apresenta métricas de performance da solução?	0 - Qualidade Baixa	O estudo não avalia a performance	0,50	0,6
		0,50 - Qualidade Boa	O estudo realiza uma avaliação ad hoc da solução.		
		1 - Qualidade Excelente	O estudo avalia sistematicamente a solução.		
QQ-02	O algoritmo de reconhecimento de grãos é comparado a soluções e medidas existentes?	0 - Qualidade Baixa	O algoritmo não é comparado a nenhum outro.	0,50	
		0,50 - Qualidade Boa	O algoritmo é comparado apenas com uma solução existente.		
		1 - Qualidade Excelente	O algoritmo é comparado com uma ou mais soluções.		

Fonte: Autor

3.1.4 Extração e Análise de Dados

Após o processo de filtragem (critérios de inclusão, exclusão e qualidade) os estudos selecionados passaram por um processo de extração. O processo de extração tem como objetivo encontrar insumos para responder cada uma das questões de pesquisas demonstradas na revisão sistemática. A Tabela 5 demonstra as informações que foram extraídas durante o processo de extração.

Tabela 5 – Definição dos dados de extração.

Identificador	Descrição	Tipo	Questão
DE-001	Título	Texto	
DE-002	Autor	Texto	
DE-003	Ano	Texto	
DE-004	Resumo	Texto	
DE-005	Sentença que indica o tipo de grão/semente reconhecido.	Texto	Q2
DE-006	Parágrafo que indique a metodologia de reconhecimento.	Texto	Q1, Q2
DE-007	Sentença que tem o Nome do hardwares usados no reconhecimento.	Texto	Q2
DE-008	Sentença que indica o ambiente de entrada dos dados.	Texto	Q2
DE-009	Sentença que indique as técnicas de segmentação.	Texto	Q1
DE-010	Sentença com a informação da área de interesse a ser segmentada	Texto	Q1
DE-011	Parágrafo ou tabelas contendo as métricas de performance do algoritmo de segmentação	Tabelas ou Parágrafos	Q1
DE-012	Parágrafo ou tabelas contendo as métricas de performance do algoritmo de reconhecimento	Tabelas ou Parágrafos	Q2

Fonte: Autor.

3.2 Execução da Revisão

Ao executar a busca em cada uma das bases de artigos científicos e motores de busca foram localizados o total de 1051 estudos, 152 artigos duplicados, 35 foram aceitos e incluídos e 864 artigos foram rejeitados.


Os dados foram extraídos através da leitura de cada um dos estudos. Durante a leitura os dados foram armazenados em uma planilha que contém as informações necessárias para responder cada uma das questões de pesquisas descritas no protocolo da revisão sistemática.

3.2.1 Questão de Pesquisa Q1

A maioria dos estudos selecionados focam na classificação e reconhecimento do arroz. O uso de técnicas de segmentação é pouco explorado, pois os estudos focam em um ambiente controlando e com os grãos separados ou próximos, possibilitando a segmentação dos grãos com técnicas básicas.

Encontramos apenas três algoritmos usados como ferramenta para segmentar as áreas de interesse. Enclosing Region-of-Interest Rectangle, Distance Transform e Watershed Transform. Os algoritmos foram usados com o objetivo de segmentar e separar os grãos de arroz

Figura 3 – Quantidade de estudos após cada etapa de seleção dos estudos.



Fonte: Autor.

existentes em uma imagem. Por exemplo, segmentação de Watershed pode ajudar a separar grãos próximos através de técnicas de erosão da morfologia matemática.

Os estudos focaram totalmente em demonstrar seu método de reconhecimento, muitas vezes apenas referenciando técnicas já existentes de segmentação usadas apenas para atingir seu objetivo de buscar as áreas de interesse (grãos de arroz). Um exemplo é o artigo (GAO et al., 2011) focado no uso do Fourier descriptor para representar a imagem e BP neural network para treinar uma rede neural.

Portanto, apenas existem indícios, nos estudos encontrados, de técnicas que não são baseadas em aprendizado de máquina para a segmentação do arroz de imagens. Seguindo essa informação, é impossível realizar uma comparação de desempenho entre as técnicas de segmentação baseadas em aprendizado de máquina ou não. Uma revisão sistemática apenas considerando técnicas de segmentação pode possibilitar uma análise comparativa entre os métodos existentes e aplicados na literatura.

3.2.2 Questão de Pesquisa Q2


Buscamos um conjunto de soluções que realizam o reconhecimento de grãos de arroz, algum optaram pelo uso de algoritmos de aprendizado de máquina supervisionados, enquanto outros focaram no uso de técnicas matemáticas que não envolviam a exemplificação como referência para uma possível classificação.

O total de estudos que usam algoritmos de machine learning chega a 96,8%. Podemos notar que a quantidade de artigos que utilizam algoritmos de aprendizado de máquina é maior, demonstrando uma predominância sobre o total de estudos selecionados.

A Figura 4 demonstra a média da métrica de desempenho *accuracy* para cada um dos algoritmos usados nos estudos. É importante salientar que a métrica *accuracy* é apenas uma das métricas existentes para calcular o desempenho de um classificador, contudo foi a única métrica encontrada em todos os artigos, o que possibilitou a comparação entre os mesmos.

Além disso, podemos notar que o desempenho entre os algoritmos ficou bastante próximo, e podem ser alterados com base em vários fatores: escolha dos parâmetros do algoritmo, entrada de dados selecionada para treinamento, balanceamento dos exemplos etc. Logo, não é possível definir qual abordagem pode oferecer o melhor desempenho, pois o resultado depende muito das variáveis envolvidas no treinamento e não apenas na seleção do algoritmo.

Figura 4 – Média da métrica *accuracy* por algoritmo representando cada um dos estudos selecionados.



Fonte: Autor.

3.3 Ameaças à Validade

O resultado de uma revisão sistemática da literatura é produto do planejamento, execução e interpretação dos resultados. Logo, é importante atentar-se a possíveis pontos que podem afe-

tar a validade do estudo.

A principal ameaça a validade da revisão sistemática é a deficiência e padronização das métricas de desempenho dos classificadores nos estudos selecionados. A inserção de métricas de qualidade mais rigorosa e objetiva pode mitigar o problema. Contudo, métricas de qualidade rigorosas podem levar a exclusão de artigos importantes da área e que ofereçam valor para a resposta de alguma das questões de pesquisa apresentadas nesse estudo.

Outra ameaça considerável do estudo é a ausência de métricas de desempenho para a segmentação das áreas de interesse da imagem. Comumente os artigos referenciavam os métodos, contudo não apresentavam nenhuma métrica de desempenho para o segmentador. A ausência da métrica impossibilitou comparações de desempenho entre os estudos. Além disso, uma busca focada apenas em métodos de segmentação de áreas de interesse do arroz poderia possibilitar uma análise mais assertiva do estado atual da área.

3.4 Lições do Capítulo

Este capítulo teve como objetivo apresentar uma revisão sistemática da literatura com o objetivo de buscar soluções tecnológicas de processamento de imagens utilizadas para a detecção de grãos de arroz.

Através do processo de criação e execução do protocolo, foi possível reconhecer métodos e tecnologias utilizadas para a classificação, detecção e reconhecimento de grãos de arroz.

A maioria dos estudos focam no uso de algoritmos de aprendizado de máquina para as soluções de processamento de imagens aplicadas no arroz. Classificar qual o tipo de arroz está em um local, detectar possíveis quebras no arroz, segmentar diferentes espécies de arroz, detectar o formato são exemplos de soluções envolvidas no processo de reconhecimento do arroz.

Todos os estudos optaram pelo treinamento do método e geração de métricas em um ambiente totalmente controlado. Além disso, demonstraram o uso de técnicas de segmentação existentes, aos quais foram usadas apenas como um meio para a etapa de reconhecimento do arroz.

Logo, considerando esses resultados, pode-se notar o uso de aprendizado de máquina como um meio seguro para o reconhecimento do arroz. Além disso, este estudo seguirá em uma mão inversa aos trabalhos relacionados, usando uma população de dados de um ambiente não controlado para o treinamento do classificador apresentado no capítulo seguinte.

4 DESENVOLVIMENTO

Este capítulo tem como objetivo demonstrar a visão geral da solução e o processo de desenvolvimento de um classificador para detectar a ausência de grãos na panícula da planta de arroz. A seção 4.1 apresenta a visão geral da solução, retomando o problema e descrevendo a solução proposta, segregando os escopos abordados nessa pesquisa. A seção 4.2 descreve o processo de desenvolvimento do classificador, parte importante na proposta da ferramenta Deméter.

4.1 Visão Geral da Solução

A perda do grão durante o processo de crescimento do arroz pode ocorrer por vários motivos como por exemplo eventos climáticos, doenças e decaimento da planta em decorrência do vento. A perda pode gerar prejuízos para o agricultor e a busca manual de pontos de perda pode custar tempo e dinheiro. A detecção da perda usando recursos tecnológicos visa diminuir o custo do agricultor na busca de problemas em sua lavoura. Portanto, a detecção automatizada de possíveis pontos de perda é uma ferramenta importante para auxiliar os agricultores em buscar e mitigar possíveis problemas que possam diminuir a produção de arroz.

DEMÉTER é um conjunto de soluções que visa auxiliar a detecção e gerenciamento da perda de grãos de arroz durante o processo de produção. O uso de inteligência artificial (IA), engenharia de software e processamento de imagens são os pilares da criação do Deméter. A ferramenta está sendo desenvolvida para oferecer um conjunto de serviços que podem ser usados desde a captura de amostras com drone até o reconhecimento das áreas de perda da lavoura.


A Figura 5 apresenta uma visão geral da solução, englobando a fronteira da solução da ferramenta Deméter e a fronteira em específico do reconhecimento da perda. A terceira fronteira, dos quais são apresentados o classificador e a base de conhecimento, representa a fronteira abordada por esse documento.

A fronteira Deméter apresenta tudo relacionado ao Deméter, começando no momento da entrada das imagens da planta de arroz, capturada da lavoura. A interface recebe essas imagens através do protocolo (http), realizando uma interface com o ambiente externo e os serviços oferecidos pela plataforma Deméter.

Dentro da fronteira Deméter, as imagens são enviadas para os serviços de controle do drone. Os serviços do drone são responsáveis pela garantia da qualidade do dado capturado e identificação do local da imagem. Após a verificação do serviço do drone as imagens são enviadas para os serviços de perda de arroz. Durante o processo dos serviços de perda de arroz as imagens são armazenadas no banco de dados. Os dados das imagens também são repassados para o classificador.

O classificador e a base de conhecimento são itens relacionados a fronteira de pesquisa. A fronteira de pesquisa é o produto dessa dissertação e tem como objetivo treinar e criar o clas-

Figura 5 – A ferramenta Deméter, representando as fronteiras do estudo.




Fonte: Autor.

sificador responsável pela detecção da perda. O classificador recebe as imagens dos possíveis locais de perda e realiza a detecção, informando se aquele local representa uma perda do grão ou não. A base de conhecimento tem como objetivo armazenar e oferecer insumos para o treinamento do classificador.

Feature Models (FMs) ajudam a modelar e validar determinadas configurações de produtos, usados principalmente em linhas de produto de software para determinar configurações individuais (DAVRIL et al., 2013). Objetivando separar em funcionalidades a ferramenta Deméter e propor uma visão detalhada das necessidades do projeto, a Figura 6 demonstra a configuração dos recursos da ferramenta Deméter.

Deméter é a raiz dos recursos e engloba toda a ferramenta Deméter. A funcionalidade *Rice Loss Manager* engloba toda a estrutura necessária para realizar a contagem do grão e a escolha dos locais de captura de amostras na lavoura. Adicionalmente, existe uma funcionalidade necessária para a visualização do usuário, chamada de *Admin Rice Loss Manager* que tem

Figura 6 – *Feature Model* da ferramenta Deméter.



Fonte: Autor.

como requisito a funcionalidade *Rice Loss Manager*.


A funcionalidade *Drone Manager* engloba todo o ciclo de captura de imagens do drone e também movimentação. O *App Drone* existe com o objetivo de apresentar a interface gráfica para o usuário e tem a necessidade da existência do *Drone Manager*. A funcionalidade *Data Capture* existe com o objetivo de manter a captura de dados dentro da funcionalidade *Drone Manager*. A funcionalidade *Location and Movement Controller* existe com o objetivo de realizar o controle da movimentação do drone e rastreo dos locais necessários para captura.

Os recursos *Grain Detector* e *Classifier Trainer* são responsáveis pelo treinamento do classificador e uso do mesmo em uma detecção da ausência do grão. *Grain Detector* está ligado ao recurso *Grain Loss Counter*, responsável pela contagem da perda em determina imagem de uma planta.

Cada um dos recursos demonstrados na Figura 6 podem ter diferentes tecnologias relacionadas com o objetivo de garantir as funcionalidades descritas no FMs. A Figura 7 demonstra uma solução baseada em microserviços dos recursos *Grain Detector* e *Classifier Trainer*, objetivando garantir a detecção e treinamento do classificador de perda de grãos. Uma arquitetura baseada em *microservices* proporciona um baixo acoplamento da solução, permite as equipes realizar a manutenção de *microservices* isolados, facilita a entrega (pequenos projetos de software) e também aumenta a escalabilidade e resiliência da solução (THÖNES, 2015).

A Figura 7 demonstra duas grandes relações da solução de detecção de ausência do grão. O treinamento, apresentado com os insumos da Base de Conhecimento para o serviço

Figura 7 – Arquitetura de microserviços do Deméter considerando as *features* de *Grain Detector*, *Classifier Trainer* e *Grain Loss Counter*.



Fonte: Autor.


CLASSIFIER TRAINER MICROSERVICE. O reconhecimento, demonstrado com o uso do classificador (*Classifier*) através do serviço *Grain Detector Microservice*. O serviço *Grain Detector Microservice* é responsável pela gestão da imagem segmentada e uso do classificador, com base na imagem segmentada recebida o mesmo oferece como resposta o resultado do classificador, informando se a determinada imagem segmentada é um local que o grão foi perdido ou não. As imagens são segmentadas no serviço de *Image Segmentation Microservice*, que recebe a imagem da planta de arroz e identifica os possíveis locais de ausência do grão.

4.2 Classificador: detecção da ausência do grão do arroz

Esta seção tem como objetivo apresentar o processo de criação do classificador e de seu respectivo microserviço para treinamento demonstrado na Figura 7 do capítulo anterior. Um classificador é um modelo matemático responsável pela classificação de uma determinada informação, e nesse estudo o modelo tem a responsabilidade de classificar um local da planta de arroz com a ausência de grão.

A etapa de seleção dos dados é demonstrada na Seção 4.2.1 e demonstra o processo de escolha das informações que são usadas como insumo para a criação do classificador. A Seção 4.2.2 apresenta as técnicas usadas para preparar a imagem selecionada para o processo de segmentação e treinamento. A Seção 4.2.3 apresenta as técnicas usadas para separar as áreas de interesse da imagem usadas no treinamento do classificador. A Seção 4.2.4 apresenta as técnicas utilizadas para extrair as características de cada imagem, focando no uso de HOG. A Seção 4.2.5 apresenta o processo de treinamento do classificador demonstrando quais os

Figura 8 – Método de treinamento do classificador.



Fonte: Autor.

algoritmos utilizados no processo.

4.2.1 Seleção dos Dados

O arroz é formado por sua raiz, folha, caule, panícula e grão. A panícula após formada é exposta a partir do caule da planta. Os grãos durante a fase de reprodução são gerados na panícula. Logo, existem conectores entre o grão e a panícula, e durante o desenvolvimento essa conexão pode ser perdida após algum evento externo, doença ou mesmo secamento do grão. A panícula é a principal fonte de informação para o projeto, visto que apresenta informações da conexão entre os grãos e suas possíveis perdas.

As imagens da panícula foram capturadas inicialmente utilizando uma câmera de celular de 48 MB. As imagens focam na captura de exemplos da panícula com possíveis perdas de grão. Foram capturados 2 vídeos e em torno de 50 imagens de panículas diferentes de plantas de arroz.

A segunda base de imagens, utilizadas posteriormente também no treinamento dos algoritmos, foi capturada através de um drone DJI Mini Se. O Drone captura imagens em resolução 2.7k (2704 x 1520) em 40 Mpbs. A captura de vídeo é feita na resolução de 2.7k a 30 FPS, onde a velocidade do drone pode chegar a 46,8 Km/h facilitando a captura de imagens em grande escala. Foram selecionadas 500 imagens de áreas do arroz com exemplos de áreas aleatórias do arroz e exemplos de áreas onde existia uma perda do arroz.

4.2.2 Pré-Processamento da Imagem

Não usamos nenhum filtro complexo para mudar a imagem. O objetivo é evitar mudar as características da imagem. Aplicamos apenas um simples filtro para transformar a imagem para uma estrutura de escala de cinza. Para realizar a mudança, utilizamos como ferramenta a biblioteca Scikit-learn.



Figura 9 – Exemplo de panícula do arroz. Fonte: Autor.

4.2.3 Segmentação das Áreas de Interesse

A segmentação tem como objetivo capturar a área de interesse da imagem. A segmentação é realizada com base nos dados existentes que são as imagens da planta de arroz capturadas.

A segmentação foi focada com o objetivo de criação uma população de imagens agrupadas em: imagem com o grão conectado com a panícula, imagem com a panícula sem o grão e imagens sem relação com o grão.

As imagens foram segmentadas manualmente e o tamanho padrão de cada segmentação foi de 16 x 16 pixels. As cores da imagem segmentada seguiu o padrão em escalas de cinza.

4.2.4 Extração das Características

As características da imagem foram extraídas a partir do histograma da imagem usando HOG. HOG considera as características de forma da imagem e pode ser configurado com base nas necessidades do problema.

O método HOG foi executado através do uso da biblioteca Scikit Learn. A biblioteca oferece o algoritmo pronto para a extração de *features* usando HOG e um conjunto de parâmetros para mudar os possíveis resultados da extração. O Algoritmo *feature* HOG:

Listing 4.1 – Algoritmo para a extração do extrator de feature HOG.

```
from skimage.feature import hog
fd, hog_image = hog(data, orientations=4,
                    pixels_per_cell=(2, 2),
                    cells_per_block=(2, 2),
                    visualize=True)
```

Considerando nosso projeto, criamos uma função denominada `EXTRACTFEATUREHOG` para realizar a extração das features de um conjunto de imagens já segmentadas, o Algoritmo 4.2 demonstra o uso da função.

Listing 4.2 – Iteração para realizar a extração da feature de cada imagem.

```
for image in self.images:
    self.extractFeatureHog(image)
```

4.2.5 Treinamento do Classificador

Os algoritmos utilizados para o treinamento do classificador foram SVM, *Random Forest* e *Decision Tree*.

As classes utilizadas como saída do classificador são 1 e 0. O 1 representa o local onde existe a ausência do grão. A classificação 0 representa o local onde atualmente existe um grão ou mesmo não é um local que deveria existir qualquer grão.

Uma imagem demonstrando o final da panícula, com o ponto onde deve ser conectado o grão mas atualmente está ausente é considerado como classificação 1. Uma imagem demonstrando a folha da planta é considerada como classificação 0. Adicionalmente, uma imagem contendo um grão conectado na panícula é considerada como classificação 0.

Atualmente estamos usando hiperparâmetros definidos com base em uma listagem de valores. Essa listagem permite o uso de uma grade de parâmetros ao qual é gerado com base em um intervalo. O algoritmo SVM considera um intervalo de 1 a 10 para o parâmetro C. O parâmetro degree considera um intervalo de 1 a 5. O parâmetro gamma considera um intervalo de 0.1 a 0.3. Considerando o uso do algoritmo *Random Forest*, os intervalos para *max depth* e *random state* são respectivamente de 1 a 4 e 0 a 3. O algoritmo *Decision Tree* teve um intervalo para o *max depth* de 1 a 10.

A Tabela 6 demonstra as configurações usadas até o momento para o treinamento do classificador.

Tabela 6 – Configuração do algoritmo e população utilizado para treinamento do classificador.

			Algoritmo		População de Imagens
SVM			Randon Forest	Decision Tree	
Linear	Poly	RBF			
•	•	•	•	•	Imagens Panícula sem Grão
					Imagens Panícula com Grão
					Imagens de Background Planta Arroz

Fonte: Autor.

4.3 Lições do Capítulo

Este capítulo demonstrou que o processo de reconhecimento é um processo de várias etapas e envolve conhecimentos de processamento de imagens e inteligência artificial. Adicio-

nalmente, são apresentadas métricas utilizadas para avaliar os classificadores.

Os algoritmos *SVM*, *Random Forest* e *Decision Tree* demonstram uma variedade de possibilidades, dependendo do conjunto de imagens utilizada, das características extraídas das mesmas e dos parâmetros selecionados para treinamento. Além disso a quebra do conjunto de dados de treinamento e teste é muito importante no processo, podendo influenciar positivamente ou negativamente no desempenho do classificador.

5 RESULTADOS

Este capítulo tem como objetivo apresentar os resultados da pesquisa, demonstrando na seção 5.1 os resultados do desempenho do classificador e na seção 5.2 um caso de uso do classificador em imagens reais de uma lavoura de arroz através de um microserviço.

5.1 Resultados do Classificador

O melhores resultados separados por algoritmo são apresentados na Tabela 7. Os resultados consideram a *accuracy*, *recall*, *precision* e *F1-Score* como métricas de desempenho do classificador. Os hiperparâmetros dos algoritmos foram definidos utilizando uma grade de parâmetros, o que auxiliou na criação de vários modelos com base na combinação de diferentes hiperparâmetros.

A grade de parâmetros para o algoritmo SVM focou nos parâmetros de Kernel, C, degree e Gamma. Escolhemos três Kernels para o treinamento, aos quais são usualmente utilizados em treinamentos de classificadores de imagens: linear, RBF e Poly. O parâmetro C teve a escala usada de 1 a 10, o degree de 1 a 5 e a *gamma* com valores de 0.1, 0.2 e 0.3. As escalas e valores definidos foram combinadas, gerando um conjunto de hiperparâmetros de teste. As escalas foram selecionadas a partir de testes empíricos, observando o desempenho com determinados valores.

O algoritmo *Decision Tree* focou nos parâmetros apenas de *max depth*, com valores em uma escala de 1 a 10. O algoritmo *Random Forest* foi configurado com uma grade de parâmetros focando em *max depth* e *random state* com escalas respectivas de 1 a 4 e 0 a 3.

Após a geração de todos os classificadores e geração do resultados das métricas, o algoritmo SVM foi selecionado como resultado mais performático. Os parâmetros com a melhor performance foram C com o valor 7, degree com valor 2, *gamma* com valor 0.1 e *kernel* linear. O *kernel* como *poly* teve valores aproximados porém com o valor de C elevado a 10. O segundo algoritmo mais performático foi *Random Forest* com valores próximos de *precision* e *recall* ao resultado encontrado no melhor classificador gerado com o algoritmo SVM.

Tabela 7 – O melhor resultado de cada algoritmo usado na criação do classificador.

Param	Algoritmo			
	Accuracy	Precision	Recall	F1-Score
SVM				
C= 7, degree= 2, gamma= 0.1, kernel= linear	70%	0.666	0.5	0,571
Random Forest				
max depth= 9	66%	0.5	0.660	0,568
Decision Tree				
max depth= 1, random state = 0	55%	0.5	0.55	0,366

Fonte: Autor.

5.2 Microserviço de reconhecimento da perda de grãos

O microserviço responsável pela contagem de perda usa o classificador apresentado anteriormente como meio para a detecção da quantidade de grãos faltando em uma determinada planta de arroz. O classificador é um dos recursos usados mais importantes dentro do microserviço para possibilitar a contagem. O desempenho do classificador reflete na qualidade do produto do microserviço para a contagem da perda.

O microserviço foi desenvolvido como uma API RESTful em Python. O mesmo possui dois *resources* denominados de *recognize* e *trainner*. O *resource trainner* é usado para realizar o treinamento do classificador e gerar as métricas disponibilizadas na seção anterior. Nesta seção utilizamos o *resource recognize* para realizar o reconhecimento da perda em determinada imagem.

O *resource recognize* funciona através de uma requisição POST e espera receber uma imagem em seu *body* da requisição. A imagem deve ser capturada por um drone preferencialmente e possibilitar visualizar a imagem da planta do arroz, especificamente a panícula. A Figura 10 apresenta uma imagem exemplo de uma captura realizada na lavoura de arroz utilizando um drone e que pode ser usada como entrada no microserviço.

Figura 10 – Imagem usada como entrada no microserviço para contagem de perda.



Fonte: Autor.

Considerando que a imagem capturada através do drone seja de boa qualidade, o software inicia o processo de detecção da perda do arroz. A imagem 11 demonstra o primeiro passo de identificação que é usar o algoritmo *Harris Corner Detection*, identificando possíveis locais onde a perda de grãos pode estar e ajudando no processo de reconhecimento. Os pontos vermelhos na imagem destacam os possíveis locais. O segundo passo do reconhecimento no

Figura 11 – Imagem usada como entrada no microserviço para contagem de perda e armazenada após a detecção de bordas usando *Harris Corner Detection*.



Fonte: Autor.

microserviço é a etapa de uso do classificador treinado. O classificador recebe a cada etapa as imagens detectadas pelo algoritmo Harris Corner e coloca como entrada no classificador após a imagem ter sua feature extraída. A Figura 12 demonstra a imagem com os pontos detectados pelo classificador como uma possível perda de grãos circulos de verde. Podemos identificar visualmente que ainda ele não detectou todos os pontos com a ausência do grão pois o classificador ainda não está com uma *accuracy* próxima de 100%. A contagem manual determinaria a perda de 7 grãos na imagem e o resultado foi 4 no microserviço.

Figura 12 – Imagem usada como entrada no microsserviço para contagem de armazenada e salva após o processo de identificação usando o classificador treinado



Fonte: Autor.

5.3 Lições do Capítulo

Os resultados demonstraram um nível de acerto promissor. O algoritmo SVM demonstrou a melhor performance com relação aos demais algoritmos. A quantidade de dados capturada está sendo aumentada a cada período de produção do arroz, possibilitando em trabalhos futuros a melhoria e ajuste do classificador. O aumento de exemplos com diferentes tipos de eventos desastrosos podem melhorar o desempenho do classificador. O número de exemplos negativos a ausência do arroz é comumente mais fácil de ser encontrados, contudo o grão perdido é mais difícil. Outro ponto importante é o processo de reconhecimento do microsserviço. O classificador é parte de todo o processo, considerando que o algoritmo Harris Corner auxilia na pré-seleção dos possíveis casos de perda. A qualidade da foto capturada também pode influenciar no momento do reconhecimento.

6 CONSIDERAÇÕES FINAIS

Este documento teve como objetivo apresentar o estado atual da pesquisa para a detecção da ausência de grãos na panícula do arroz. A identificação da ausência do grão de arroz em locais comuns da existência do mesmo pode indicar problemas na planta, possibilitando os agricultores tomar iniciativas para tentar identificar o problema e diminuir a perda da produção.

Nota-se o uso de algoritmos de aprendizado de máquina, inicialmente SVM, e adicionado posteriormente *Random Forest* e *Decision Tree* para a criação de classificadores responsáveis pela classificação de possíveis locais sem o grão de arroz. Essa classificação é realizada após a segmentação de determinada local com uma possível perda.

A solução apresentada não limita-se apenas ao classificador e sim ao uso do mesmo através de uma arquitetura de micro serviços. Logo, este estudo também apresenta a arquitetura da solução e sua ligação com técnicas de pre-processamento, segmentação e classificação.

O desempenho do classificador foi aceitável e o melhor resultado foi obtido através do classificador gerado com o algoritmo SVM. O acerto dos locais com ausência de grão ainda podem ser melhorado conforme o aumento da exemplificação e a avaliação de outros algoritmos de aprendizado de máquina.

6.1 Contribuições

As contribuições atuais do estudo serão apresentadas abaixo, considerando o estado atual da pesquisa:

- Revisão sistemática da literatura das soluções para detecção de grãos de arroz.
- Base de dados de imagens de arroz capturadas durante o período de colheita.
- Classificadores treinados para a detecção de ausência do grão na panícula do arroz de imagens 16 x 16 com 70% de acurácia.

6.2 Limites

O nosso escopo de pesquisa atualmente limita-se a criação de parte da solução Deméter. A pesquisa foca-se nos serviços de segmentação e classificação da ausência do grão do arroz. Este estudo não aborda os serviços de localização e movimentação do drone, aplicativo do drone, aplicativo para gerenciamento de perda de arroz, captura de dados e busca na lavoura.

REFERÊNCIAS

- AGUINIS, H.; GOTTFREDSON, R. K.; JOO, H. Best-practice recommendations for defining, identifying, and handling outliers. **Organizational Research Methods**, Sage Publications Sage CA: Los Angeles, CA, v. 16, n. 2, p. 270–301, 2013.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 39, n. 12, p. 2481–2495, 2017.
- BAITE, M. S. et al. Disease incidence and yield loss in rice due to grain discolouration. **Journal of Plant Diseases and Protection**, Springer, v. 127, n. 1, p. 9–13, 2020.
- BHATTACHARYA, S. et al. Deep learning and medical image processing for coronavirus (covid-19) pandemic: A survey. **Sustainable cities and society**, Elsevier, v. 65, p. 102589, 2021.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, p. 5–32, 2001.
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: **IEEE. 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)**. [S.l.], 2005. v. 1, p. 886–893.
- DAVRIL, J.-M. et al. Feature model extraction from large collections of informal product descriptions. In: **Proceedings of the 2013 9th Joint Meeting on Foundations of Software Engineering**. [S.l.: s.n.], 2013. p. 290–300.
- DESAI, S.; KANPHADE, R. Image processing using median filtering for identification of leaf disease. In: **Nanoelectronics, Circuits and Communication Systems**. [S.l.]: Springer, 2021. p. 17–23.
- DEVI, V. A.; NAYYAR, A. Fusion of deep learning and image processing techniques for breast cancer diagnosis. In: **Deep learning for cancer diagnosis**. [S.l.]: Springer, 2021. p. 1–25.
- DOUGHERTY, G. **Digital image processing for medical applications**. [S.l.]: Cambridge University Press, 2009.
- FOMBA, S.; SINGH, N. Crop losses caused by rice brown spot disease in mangrove swamps of northwestern sierra leone. **International Journal of Pest Management**, Taylor & Francis, v. 36, n. 4, p. 387–393, 1990.
- GAO, H. et al. Rice kernel shape description using an improved fourier descriptor. In: **SPRINGER. International Conference on Computer and Computing Technologies in Agriculture**. [S.l.], 2011. p. 104–114.
- GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. [S.l.]: Editora Blucher, 2000.
- GRUBBS, F. E. Procedures for detecting outlying observations in samples. **Technometrics**, Taylor & Francis, v. 11, n. 1, p. 1–21, 1969.

- HADJIELEFTHERIOU, M.; KOUDAS, N.; SRIVASTAVA, D. Incremental maintenance of length normalized indexes for approximate string matching. In: **Proceedings of the 2009 ACM SIGMOD International Conference on Management of data**. [S.l.: s.n.], 2009. p. 429–440.
- HARRIS, C. G.; STEPHENS, M. et al. A combined corner and edge detector. In: CITESEER. **Alvey vision conference**. [S.l.], 1988. v. 15, n. 50, p. 10–5244.
- HAWKINS, D. M. **Identification of outliers**. [S.l.]: Springer, 1980. v. 11.
- ITOH, J.-I. et al. Rice plant development: from zygote to spikelet. **Plant and cell physiology**, Oxford University Press, v. 46, n. 1, p. 23–47, 2005.
- JOACHIMS, T. **Making large-scale SVM learning practical**. [S.l.], 1998.
- KIM, M.-K.; PANG, A. Climate change impact on rice yield and production risk. **Journal of Rural Development/Nongchon-Gyeongje**, v. 32, n. 1071-2016-86914, p. 17–29, 2009.
- KITCHENHAM, B. Procedures for performing systematic reviews. **Keele, UK, Keele University**, v. 33, n. 2004, p. 1–26, 2004.
- KITPO, N.; INOUE, M. Early rice disease detection and position mapping system using drone and iot architecture. In: IEEE. **2018 12th South East Asian Technical University Consortium (SEATUC)**. [S.l.], 2018. v. 1, p. 1–5.
- KUMAR, G.; BHATIA, P. K. A detailed review of feature extraction in image processing systems. In: IEEE. **2014 Fourth international conference on advanced computing & communication technologies**. [S.l.], 2014. p. 5–12.
- KUMAR, S.; KARALIYA, S. K.; CHAUDHARY, S. Precision farming technologies towards enhancing productivity and sustainability of rice-wheat cropping system. **Int. J. Curr. Microbiol. App. Sci**, v. 6, n. 3, p. 142–151, 2017.
- LANSIGAN, F.; SANTOS, W. De los; COLADILLA, J. Agronomic impacts of climate variability on rice production in the philippines. **Agriculture, ecosystems & environment**, Elsevier, v. 82, n. 1-3, p. 129–137, 2000.
- LI, J.; YUAN, L. et al. Hybrid rice: genetics, breeding, and seed production. **Plant breeding reviews**, v. 17, p. 15–158, 2000.
- LI, Y. et al. Implementation of deep-learning algorithm for obstacle detection and collision avoidance for robotic harvester. **Computers and Electronics in Agriculture**, Elsevier, v. 174, p. 105499, 2020.
- MASSERONI, D. et al. Towards a smart automated surface irrigation management in rice-growing areas in italy. **Journal of Agricultural Engineering**, University of Southern Queensland, v. 47, n. 585, p. 42–48, 2017.
- MILLETARI, F.; NAVAB, N.; AHMADI, S.-A. V-net: Fully convolutional neural networks for volumetric medical image segmentation. In: IEEE. **2016 fourth international conference on 3D vision (3DV)**. [S.l.], 2016. p. 565–571.
- MÜLLER, D.; KRAMER, F. Miscnn: a framework for medical image segmentation with convolutional neural networks and deep learning. **BMC Medical Imaging**, BioMed Central, v. 21, n. 1, p. 1–11, 2021.

PATRO, S.; SAHU, K. K. Normalization: A preprocessing stage. **arXiv preprint arXiv:1503.06462**, 2015.

PRODANOV CLEBER CRISTIANO DE FREITAS, E. C. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico-2ª Edição**. [S.l.]: Editora Feevale, 2013.

RAFI, S. A. et al. Crop condition analyzer robot with image processing feedback to assist farmer. In: IEEE. **2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)**. [S.l.], 2021. p. 188–192.

RISH, I. et al. An empirical study of the naive bayes classifier. In: **IJCAI 2001 workshop on empirical methods in artificial intelligence**. [S.l.: s.n.], 2001. v. 3, n. 22, p. 41–46.

SANTOS, C. M. d. C.; PIMENTA, C. A. d. M.; NOBRE, M. R. C. The pico strategy for the research question construction and evidence search. **Revista latino-americana de enfermagem**, SciELO Brasil, v. 15, n. 3, p. 508–511, 2007.

STAVRAKOUDIS, D. et al. Estimating rice agronomic traits using drone-collected multispectral imagery. **Remote Sensing**, MDPI, v. 11, n. 5, p. 545, 2019.

THÖNES, J. Microservices. **IEEE software**, IEEE, v. 32, n. 1, p. 116–116, 2015.

WASSMANN, R. et al. Rice and global climate change. **Rice in the global economy: Strategic research and policy issues for food security**, International Rice Research Institute Manila, Philippines, p. 411–432, 2010.

YUAN, L.; FU, X. et al. **Technology of hybrid rice production**. [S.l.]: Food and Agriculture Organization (FAO), 1995.