



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS RUSSAS**  
**CURSO DE GRADUAÇÃO EM ENGENHARIA DE SOFTWARE**

**THIAGO NÁTALYS RIBEIRO SILVA**

**ESTUDO E COMPARAÇÃO DE ALGORITMOS DE CLASSIFICAÇÃO DE IMAGENS  
PARA IDENTIFICAÇÃO DE CRISTAIS DE ALITA (C3S)**

**RUSSAS**

**2025**

THIAGO NÁTALYS RIBEIRO SILVA

ESTUDO E COMPARAÇÃO DE ALGORITMOS DE CLASSIFICAÇÃO DE IMAGENS  
PARA IDENTIFICAÇÃO DE CRISTAIS DE ALITA (C3S)

Trabalho de Conclusão de Curso apresentado ao  
Curso de Graduação em Engenharia de Software  
do Campus Russas da Universidade Federal do  
Ceará, como requisito parcial à obtenção do  
grau de bacharel em Engenharia de Software.

Orientadora: Prof. Dra. Rosineide Fer-  
nando da Paz

RUSSAS

2025

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- S584e Silva, Thiago Nátalys Ribeiro.  
Estudo e Comparação de Algoritmos de Classificação de Imagens para Identificação de Cristais de Alita (C3s) / Thiago Nátalys Ribeiro Silva. – 2025.  
45 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Russas, Curso de Ciência da Computação, Russas, 2025.  
Orientação: Profa. Dra. Rosineide Fernando da Paz.
1. Microscopia do clínquer. 2. Classificação de imagens. 3. Aprendizado de Máquina. 4. Algoritmos. I. Título.

CDD 005

---

THIAGO NÁTALYS RIBEIRO SILVA

ESTUDO E COMPARAÇÃO DE ALGORITMOS DE CLASSIFICAÇÃO DE IMAGENS  
PARA IDENTIFICAÇÃO DE CRISTAIS DE ALITA (C3S)

Trabalho de Conclusão de Curso apresentado ao  
Curso de Graduação em Engenharia de Software  
do Campus Russas da Universidade Federal do  
Ceará, como requisito parcial à obtenção do  
grau de bacharel em Engenharia de Software.

Aprovada em: 08 de agosto de 2025.

BANCA EXAMINADORA

---

Prof. Dra. Rosineide Fernando da Paz (Orientadora)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Dmontier Pinheiro Aragão Junior  
Universidade Federal do Ceará (UFC)

---

Lazuli Costa de Andrade  
Solo Agtech

À minha família, amigos e professores que me apoiaram nesta jornada.

## **AGRADECIMENTOS**

Desejo expressar meus agradecimentos primeiro à Universidade Federal do Ceará, pela sólida formação acadêmica e pelo ambiente de aprendizado durante todos os anos.

Aos meus pais, Vilma Ribeiro e Antonio Gilson Pereira, meu agradecimento pelo apoio incondicional, pelos ensinamentos e pela motivação em cada etapa desta jornada.

Aos amigos Mateus Andrade, Kelen Ferreira, Deusdedit Teixeira, Pedro Carvalho e Rômulo Alves, obrigado pelas conversas, pelo suporte nas horas de dificuldade e pelos momentos de descontração que mantiveram meu ânimo.

A minha orientadora Professora Dra. Rosineide da Paz, pelas orientações objetivas e pela ajuda na revisão de etapas importantes neste TCC.

“A ciência é o conhecimento organizado. A sabedoria é a vida organizada.”

(Emanuel Kant)

## RESUMO

Para a produção do cimento *Portland*, a qualidade do clínquer é fundamental, representando o maior desafio para as indústrias cimenteiras. O clínquer é um insumo sinterizado e peletizado, produzido a partir da queima de uma mistura de farinha de calcário e argila a uma temperatura de 1450 °C. Durante sua fase final de produção ocorre a inspeção que fornece dados sobre a qualidade do material. Essa verificação pode ser conduzida mediante técnicas como a difração de raios-x e a microscopia, sendo esta última a mais frequente. Por ser realizada manualmente, a análise microscópica pode sofrer com falhas humanas, resultando em atrasos na detecção de problemas na produção e em resultados de análise inconstantes. Surge, portanto, uma necessidade por uma solução, a partir da classificação de cristais Alitas (C3s) que contribua a um processo que traga resultados e possa contribuir para a indústria cimenteira. A morfologia e distribuição desses cristais nas imagens são indicadores cruciais da qualidade do clínquer produzido. Por meio da classificação eficaz desses cristais, é possível automatizar análises que dependem da avaliação de sua morfologia. Tal avanço agilizaria o processo de avaliação de qualidade, mas também ampliaria sua precisão, beneficiando significativamente a indústria de produção de cimento. Neste contexto, este trabalho irá focar em três algoritmos: KNN (*K-Nearest Neighbors*), SVM (*Support Vector Machines*) e Árvores de Decisão, juntamente com técnicas para extração de características para a classificação de cristais de C3S em imagens microscópicas de clínquer. Ao final desta pesquisa será contemplado os resultados do estudo comparativo entre os 3 modelos supervisionados na sua capacidade de classificar os cristais de Alita. O modelo de Árvore de Decisão apresentou o desempenho mais elevado na classificação morfológica de cristais de C3S, alcançando 97,19% de acurácia e 97,16% de F1-Score, resultados superiores aos obtidos pelos algoritmos SVM e KNN. As curvas de aprendizado apontaram para um alto poder de discriminação e boa generalização do modelo, evidenciando um leve sobreajuste. O estudo enfrentou limitações, principalmente a escassez de literatura sobre a fase Alita e um conjunto restrito de imagens para treinamento. A pesquisa contribui para o avanço da análise morfológica automatizadas. Futuras investigações devem focar na ampliação da base de dados, na exploração de arquiteturas de aprendizado profundo e na incorporação de novos atributos para aprimorar a robustez dos modelos preditivos.

**Palavras-chave:** microscopia do clínquer; classificação de imagens; aprendizado de máquina; algoritmos.



## ABSTRACT

For the production of Portland cement, clinker quality is fundamental, representing the greatest challenge for cement industries. Clinker is a sintered and pelletized material, produced from the burning of a mixture of limestone and clay raw meal at a temperature of 1450°C. During its final production stage, an inspection is carried out to provide data on the material's quality. This verification can be conducted using techniques such as X-ray diffraction and microscopy, with the latter being the most frequent. Because it is performed manually, microscopic analysis can suffer from human error, resulting in delays in detecting production problems and inconsistent analysis results. Therefore, a need arises for a solution based on the classification of Alite (C3S) crystals that contributes to a process that yields results and can benefit the cement industry. The morphology and distribution of these crystals in images are crucial indicators of the produced clinker's quality. Through the effective classification of these crystals, it is possible to automate analyses that depend on the evaluation of their morphology. Such an advancement would expedite the quality assessment process and also increase its precision, significantly benefiting the cement production industry. In this context, this work focuses on three algorithms: KNN (K-Nearest Neighbors), SVM (Support Vector Machines), and Decision Trees, along with feature extraction techniques for the classification of C3S crystals in microscopic clinker images. This research concludes by presenting the comparative results of the three supervised models regarding their capacity to classify Alite crystals. The Decision Tree model showed the highest performance in the morphological classification of C3S crystals, achieving 97.19% accuracy and a 97.16% F1-Score, which were superior results to those obtained by the SVM and KNN algorithms. The learning curves indicated a high discriminative power and good model generalization, showing only slight overfitting. The study faced limitations, mainly the scarcity of literature on the Alite phase and a limited set of images for training. The research contributes to the advancement of automated morphological analysis. Future investigations should focus on expanding the database, exploring deep learning architectures, and incorporating new attributes to enhance the robustness of the predictive models.

**Keywords:** clinker microscopy; image classification. machine learning; algorithms.

## LISTA DE FIGURAS

Figura 1 – Amostra de clínquer . . . . .	18
Figura 2 – Captura microscopica do clínquer . . . . .	19
Figura 3 – Microscopia do clínquer . . . . .	19
Figura 4 – Exemplo de segmentação de Imagem . . . . .	21
Figura 5 – Vista da UNICAMP classificada . . . . .	22
Figura 6 – Metodologia do trabalho . . . . .	32
Figura 7 – Mascara delimitando os limites de um cristal . . . . .	33
Figura 8 – Exemplo de cristais regulares . . . . .	34
Figura 9 – Exemplo de cristais irregulares . . . . .	34
Figura 10 – SVM . . . . .	39
Figura 11 – KNN . . . . .	40
Figura 12 – Árvore de decisão . . . . .	40

## LISTA DE TABELAS

Tabela 1 – Comparação entre os trabalhos relacionados e a pesquisa atual . . . . .	31
Tabela 2 – Características extraídas do cristal pela rede neural . . . . .	33
Tabela 3 – Contagem . . . . .	37
Tabela 4 – Validação cruzada estratificada e embaralhada . . . . .	37
Tabela 5 – Desempenho dos Algoritmos por Classes . . . . .	38

## LISTA DE ABREVIATURAS E SIGLAS

C3s	<i>Alita</i>
SVM	Support Vector Machine
KNN	K-Nearest Neighbors
VC	Visão Computacional
PCA	Análise de Componentes Principais
LDA	Análise Discriminante Linear
AM	Aprendizado de Máquina

## SUMÁRIO

1	INTRODUÇÃO . . . . .	14
2	OBJETIVOS . . . . .	17
2.1	Objetivo geral . . . . .	17
2.2	Objetivos específicos . . . . .	17
3	FUNDAMENTAÇÃO TEÓRICA . . . . .	18
3.1	A microscopia do clínquer e os cristais de Alita (C3S) . . . . .	18
3.2	Aprendizado de Máquina . . . . .	20
3.3	Visão Computacional e a segmentação de imagens . . . . .	21
3.4	Classificação de imagens . . . . .	22
3.5	Algoritmos Tradicionais de Classificação . . . . .	24
4	TRABALHOS RELACIONADOS . . . . .	27
4.1	Classificação automática do tipo de ferro fundido utilizando Reconheci- mento de Padrões em imagens de Microscopia Óptica . . . . .	27
4.2	<i>Recognition of clinker phases by automatic image analysis</i> . . . . .	28
4.3	Automação da Identificação de C3S na Microscopia do Clínquer . . . . .	29
4.4	Estudo da identificação automática do cristal de C3S em imagens micros- cópicas de Clínquer e sua relevância para o Monitoramento do Funcio- namento de Fornos Rotativos de plantas de cimento . . . . .	30
4.5	Comparação de Trabalhos . . . . .	31
5	METODOLOGIA . . . . .	32
5.1	Extração das características dos cristais . . . . .	32
5.2	Classificação manual . . . . .	33
5.3	Treinamento dos modelos de classificação . . . . .	34
5.4	Avaliação e comparação entre os modelos . . . . .	35
6	RESULTADOS . . . . .	37
6.1	Classificação Manual . . . . .	37
6.2	Desempenho Geral dos Modelos . . . . .	37
6.3	Métricas dos Modelos por Classe . . . . .	38
6.4	Matrizes de confusão e Curvas de Aprendizado . . . . .	39
7	CONCLUSÕES E TRABALHOS FUTUROS . . . . .	41

<b>REFERÊNCIAS</b>	42
--------------------	----

## 1 INTRODUÇÃO

O desafio das indústrias cimenteiras é assegurar a qualidade do clínquer, o principal insumo para a produção do cimento *Portland* (MORAIS, 2021). O clínquer é um produto sinterizado e peletizado adquirido da queima da mistura de farinha de calcário e argilas submetidas a uma temperatura de 1450°C (CAMPBELL, 1999).

Moraes (2021) traz uma definição do clínquer como a composição de diferentes cristais, que desempenham papéis essenciais na formação do cimento. Um destes cristais é o *Alita* (C3s), conhecido como silicato tricálcico, é o responsável pela resistência preliminar do cimento, principalmente em seu primeiro mês de cura. O tamanho sublimite do C3s varia entre 23 e 25 micrômetros, sendo determinado pelo tempo de temperatura exposta.

Para garantir um clínquer de qualidade, é essencial controlar a composição química da farinha por meio de análises que determinam os parâmetros fundamentais. Além do controle da qualidade da farinha, é fundamental monitorar todas as variáveis do processo de clinquerização, sendo a temperatura um dos fatores mais críticos. Durante a alimentação da farinha na torre de ciclones e, posteriormente, no forno, equipamentos onde ocorrem as principais transformações químicas, a mistura é gradativamente exposta a temperaturas que desencadeiam as reações necessárias para a formação do clínquer (MORAIS, 2021).

Após a formação do clínquer, pode ser utilizada a microscopia para analisar os cristais dos elementos formados em sua composição. Essa técnica permite a observação de estruturas invisíveis a olho nu por meio do uso de microscópios (SOUZA *et al.*, 2002).

No processo de fabricação do clínquer, a microscopia revela detalhes sobre o tamanho, a morfologia, a abundância e a distribuição dos cristais, possibilitando a correlação desses aspectos com a composição da matéria-prima e as condições de queima (SOUZA *et al.*, 2002). A classificação manual dos cristais no clínquer na microscopia é um processo demorado e suscetível a erros humanos. A automação dessa tarefa, por meio de técnicas avançadas, pode não somente melhorar a qualidade do produto final, mas também reduzir custos operacionais e desperdícios de material, tornando a produção de cimento mais eficiente e sustentável (FREITAS, 2022).

Conforme descrito por Freitas (2022), a análise é realizada por um analista que captura e avalia manualmente as imagens no microscópio, interpretando os dados com base em seu conhecimento sobre as características visíveis. No entanto, esse método demanda tempo, atrasando a obtenção dos resultados e comprometendo a agilidade na verificação da

conformidade do processo produtivo. Além disso, a subjetividade envolvida pode afetar a precisão das análises. Uma alternativa para esses desafios, é a automação da microscopia do clínquer, por meio de algoritmos de classificação de imagens para a identificação de cristais de Alita que irá proporcionar maior eficiência e confiabilidade ao processo.

Um dos desafios desta pesquisa, é a escassez de imagens cedidas pela empresa parceira, a Companhia Industrial de Cimento Apodi, fundada em 2008 pelo grupo M. Dias Branco (NETO, 2018). Suas operações estão divididas entre duas unidades: a planta de Quixeré executa desde a mineração de calcário até a produção e expedição de clínquer, enquanto a planta de Pecém foca na moagem deste clínquer, além do ensacamento e distribuição final do produto (NETO, 2018). Essa limitação implica na quantidade de dados disponíveis para treinamento e teste dos algoritmos. Para mitigar o problema, este estudo visa extrair o máximo de informações possíveis das imagens disponíveis, com o uso de algoritmos de classificação e técnicas que evidenciem as divisões entre cristais.

Os objetivos específicos desta monografia são: identificar algoritmos para classificação de imagens, comparar os algoritmos em termos de esforço computacional e complexidade, a fim de definir o melhor método para classificar e reconhecer os cristais de Alita, em um sistema de visão computacional baseado em rede neural.

O estudo comparou o desempenho dos modelos Support Vector Machine (SVM), K-Nearest Neighbors (KNN) e Árvore de Decisão na classificação de alitas regulares e irregulares, com base em um conjunto de dados desbalanceado (65% regulares e 35% irregulares). A Árvore de Decisão obteve os melhores resultados em todas as métricas, com acurácia de 97,19% e F1-score de 97,16%, superando o SVM (95,87%) e o KNN (93,98%). Também apresentou melhor desempenho por classe, especialmente na detecção de alitas irregulares (F1-score de 95,5%). As matrizes de confusão confirmaram sua superioridade, com menor número de erros, e as curvas de aprendizado indicaram alta capacidade de generalização, mesmo com leve overfitting. Esses resultados demonstram que a Árvore de Decisão é o modelo mais eficaz para a tarefa proposta.

Este trabalho atingiu seu objetivo central ao comparar algoritmos de classificação para identificar cristais de C3s em imagens microscópicas de clínquer, evidenciando a superioridade da Árvore de Decisão, que obteve acurácia de 97,19% e equilíbrio entre precisão e sensibilidade nas duas classes analisadas. O estudo enfrentou limitações, como a escassez de literatura acadêmica sobre a fase Alita e a restrita quantidade de imagens disponíveis, o que comprometeu a variedade de amostras.



Este estudo estende investigações anteriores de identificação e segmentação de cristais de Alita. Reutilizou-se e adaptou-se o código de Padilha (2023), que emprega *Mask R-CNN* para segmentação automática de C3s; apoiou-se nos agrupamentos manuais de cristais propostos por Lima (2023), para anotação das máscaras e amplia o método de Andrade (2025), que introduziu um algoritmo genético para otimização de filtro bilateral e algoritmos de extração de descritores de forma.

Este trabalho está estruturado da seguinte forma: o Capítulo 2, apresenta os objetivos gerais e específicos, o Capítulo 3 apresenta a Fundamentação teórica; no Capítulo 4, trabalhos relacionados; no Capítulo 5, a metodologia utilizada; no Capítulo 6, os resultados obtidos; e por fim, no Capítulo 7, as conclusões.

## **2 OBJETIVOS**

Neste capítulo, são apresentados os objetivos gerais e específicos deste trabalho.

### **2.1 Objetivo geral**

Classificar cristais de C3s em imagem microscópicas de clínquer, utilizando algoritmos de classificação de imagens.

### **2.2 Objetivos específicos**

São objetivos específicos deste trabalho:

1. Listar algoritmos capazes de realizar a classificação das imagens nos grupos desejados;
2. Apresentar um método para a realização da classificação do cristal;
3. Comparar os algoritmos analisados em termos de esforço computacional e complexidade;
4. Concluir sobre o melhor método para ser aplicado na classificação da Alita em um sistema de visão computacional que recorre a uma rede neural.

### 3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é apresentada a fundamentação teórica, composta de conceitos sobre o processo de fabricação do clínquer, cristais de Alita, visão computacional e algoritmos tradicionais de classificação de imagens.

#### 3.1 A microscopia do clínquer e os cristais de Alita (C3S)

As condições de fabricação, relatadas por Rodrigues (2024), como a temperatura do forno, o tempo de queima e a taxa de resfriamento, exercem influência direta na microestrutura do clínquer, impactando a qualidade final do cimento. Para a análise dessa microestrutura, emprega-se a técnica de microscopia, que consiste na seleção de grãos representativos do clínquer, os quais são submetidos a processos de lixamento e polimento. Posteriormente, as amostras recebem uma resina com alto índice de refração, facilitando a observação detalhada das características microscópicas do material. A Figura 1 apresenta um exemplo de amostra de clínquer pronto para visualização.

Figura 1 – Amostra de clínquer




Fonte: Lima (2023).

Após a preparação das amostras, imagens da microestrutura do clínquer são obtidas por microscopia digital e analisadas em computador para avaliar a distribuição, o tamanho e a forma dos cristais presentes. Entre os principais componentes estão a Alita (C3s), a belita (C2S), o aluminato de cálcio (C3A) e a ferrita (C4AF), sendo a Alita o principal indicador da qualidade do clínquer, diretamente influenciada pelas condições de operação do forno (RODRIGUES, 2024). A Figura 2, apresenta uma captura obtidas por microscopia digital, cedidas pela empresa

parceira.


Figura 2 – Captura microscópica do clínquer



Fonte: obtido pelo autor (2025).

Com sua estrutura cristalina, o C3s, apresenta diferentes polimorfos, variando conforme condições térmicas e a presença de íons substituintes no desenvolvimento das resistências mecânicas iniciais do cimento (MOCHIZUKI, 2022). Essas variações na estrutura do C3s, influenciam nas propriedades do clínquer, tornando o cristal um elemento de aprimoramento do processo de fabricação (MENINO, 2015). A Figura 3 exibe um registro da Alita (marrom), belita (azul), ferrita (branca) e aluminato (cinza).

Figura 3 – Microscopia do clínquer



Fonte: Stutzman (2001).

Na sua composição química, o C3s, é uma solução sólida  $Ca_3SiO_5$  com óxidos menores. Este composto, apresenta um polimorfismo extenso, podendo ser identificado até sete

variações estruturais: três formas triclínicas, três monoclínicas e uma trigonal. Branco (2008) define os sistemas minerais com estas estruturas como:

- **Trigonal:** possui três eixos iguais a  $120^\circ$  e um eixo vertical distinto, perpendicular aos demais, com simetria ternária e 25 grupos espaciais (BRANCO, 2008).
- **Monoclínicas:** possui três eixos de diferentes comprimentos, permite 13 grupos espaciais e geralmente possui um eixo de simetria binário, um plano de simetria ou ambos (BRANCO, 2008).
- **Triclínico:** possui três eixos e ângulos diferentes, exibindo simetria translacional ou inversão, e permite somente dois grupos espaciais (BRANCO, 2008).

O trabalho de Maki (1986), expressa que a formação do C3s ocorre a partir da fundição de componentes do clínquer em temperaturas próximas de  $1450^\circ\text{C}$ , cristalizando-se na forma romboédrica. Após o resfriamento, pode se transformar em polimorfos de menor temperatura. Essa transição entre os polimorfos do C3s está diretamente relacionada às condições de resfriamento e à incorporação de íons.

### 3.2 Aprendizado de Máquina

O trabalho de Monard e Baranauskas (2003a) define o aprendizado de máquina como uma área da inteligência artificial que busca desenvolver métodos para que computadores adquiram conhecimento automaticamente. Um sistema de aprendizado de máquina é capaz de tomar decisões com base em experiências passadas, resolvendo novos problemas a partir de exemplos já conhecidos. Esse processo pode ocorrer de diferentes formas, como no aprendizado supervisionado, em que os dados de treino vêm acompanhados de respostas corretas, ou no aprendizado não supervisionado, em que o sistema precisa identificar padrões e agrupamentos sem rótulos prévios.

Os algoritmos de aprendizado de máquina podem ser classificados em diferentes paradigmas. Entre eles, destacam-se o simbólico, que usa regras e representações lógicas; o estatístico, baseado em modelos matemáticos e probabilísticos; o conexionista, inspirado em redes neurais biológicas; o baseado em exemplos, que compara novos casos com situações já conhecidas; e o genético, que utiliza princípios da evolução natural para otimizar soluções. Cada paradigma tem suas vantagens e limitações, e não existe um único algoritmo que funcione melhor para todos os problemas (MONARD; BARANAUSKAS, 2003a).

### 3.3 Visão Computacional e a segmentação de imagens

De acordo com Szeliski (2022), a Visão Computacional (VC) é um campo de estudo e tecnologia dedicado a proporcionar aos computadores a capacidade de interpretar informações visuais com um alto nível de compreensão, a partir de imagens ou vídeos. Esse campo envolve o desenvolvimento de algoritmos e técnicas específicas voltadas para a extração e interpretação de informações relevantes contidas nos dados visuais, para aproximar o desempenho das máquinas à forma como os seres humanos percebem e compreendem o ambiente visual.

Esses algoritmos analisam e processam imagens para identificar e localizar objetos, reconhecer padrões ou características, e fazer inferências ou decisões baseadas na informação visual (BHOWMIK, 2024). A VC é usada nas mais diversas áreas: inspeção de máquinas, veículos autônomos, modelagem 3D, reconhecimento facial e digital, logística de armazém e dentre outras.

Ao longo das várias tarefas de VC, a segmentação de imagens é uma delas (BHOWMIK, 2024). A segmentação de imagens é a divisão da imagem em áreas não sobrepostas (SNYDER; QI, 2017). A Figura 4 é um exemplo visual de como a segmentação é realizada. Inicialmente a imagem é lida e os algoritmos desenvolvidos observam quais os objetos que compõem a imagem, ao serem identificados, eles são delimitados de forma que se tenha a separação em diferentes partes que neste caso a sua separação está indicada em cores diferentes.

Figura 4 – Exemplo de segmentação de Imagem



Fonte: Lei e Nandi (2022)

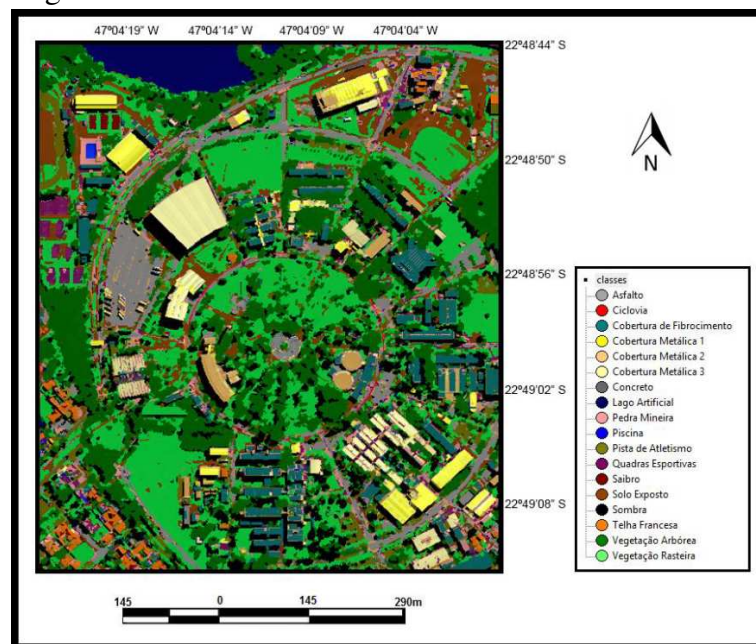
A segmentação inicial é relativamente simples, que aborda principalmente alguns problemas provenientes da detecção de defeitos industriais, detecção do alvo e aprimoramento de imagem. Devido à limitação da tecnologia da imagem inicial, as primeiras imagens digitais têm algumas características como baixa resolução, desfoque, ruído e assim por diante que necessitam de ajustes para uma melhor segmentação. Não somente a segmentação de imagem pode efetivamente extrair o contorno e outros detalhes de uma imagem, mas como também ela pode ser usada para melhorar os efeitos visuais da imagem (LEI; NANDI, 2022).

### 3.4 Classificação de imagens

O processo de classificação de imagens, equivale na decisão de um grupo de *píxeis* que será definida a um tipo/categoria, por sistemas computacionais que contribuem para o usuário na tomada de decisão (VENTURIERI; SANTOS, 1998). Os modos de classificação podem ser diferenciados com base em uma presença ou ausência na fase de treinamento do algoritmo, onde um analista pode ou não interagir com o computador. Quando o método é considerado não-supervisionado, o modelo classificador define sem possuir nenhum conhecimento anterior sobre as classes existentes, atribuindo a cada *píxel* uma classe específica. O algoritmo define essas classes com base em regras estatísticas pré-selecionadas (RICHARDS; JIA, 2022).

Para ser considerado supervisionado, o modelo dispõe de conhecimento prévio, possibilitando a seleção de amostras para treinamento (VENTURIERI; SANTOS, 1998; ADENIYI, 1985). Ambos os modos de classificação, podem ser aplicadas de forma simultânea para abater as limitações de cada método, trazendo eficiência na caracterização dos *píxeis* (VENTURIERI; SANTOS, 1998). Um exemplo de uso da classificação de imagens, pode se dar pelo trabalho de Anjos *et al.* (2015), onde foi identificado materiais urbanos, por meio dos algoritmos: máquinas de vetores de suporte, árvores de decisão e redes neurais convolucionais. Anjos *et al.* (2015) utilizaram de materiais previamente rotulados, capturadas sob condições controladas.

Figura 5 – Vista da UNICAMP classificada



Fonte: Anjos *et al.* (2015)

O processo de pré-processamento envolveu etapas como a normalização dos dados,

a remoção de artefatos indesejados que poderiam interferir nas análises e o realce das principais características presentes nas imagens. Para a extração dessas características, foram empregados métodos, incluindo histogramas de textura, técnicas espectrais e abordagens baseadas na análise de padrões geométricos, para capturar informações relevantes para a posterior etapa de classificação (ANJOS *et al.*, 2015). A Figura 5, representa a imagem classificada pela árvore de decisão.

O processamento de dados de alta dimensionalidade exige técnicas para otimizar sua representação e minimizar desafios computacionais. As principais abordagens empregadas para alcançar essa otimização são a Redução de Dimensionalidade e a Extração de Características. Ambas pretendem reduzir a complexidade dos dados processados, ao mesmo tempo, em que buscam preservar as informações mais relevantes. Dessa forma, garantem que a capacidade do sistema em discriminar entre diferentes classes ou padrões seja mantida, evitando perdas significativas de desempenho nas etapas posteriores de análise ou classificação (JULIO, 2019).

A Redução de Dimensionalidade visa diminuir o número de variáveis do conjunto de dados, preservando a maior quantidade possível de informações relevantes. Segundo Bianchi (2006), esse processo pode ser realizado por meio de técnicas lineares, como a Análise de Componentes Principais (PCA), que projeta os dados em um novo espaço de menor dimensão com base na variabilidade dos atributos originais. Outra abordagem comum é a Análise Discriminante Linear (LDA), que busca maximizar a separação entre classes, sendo amplamente utilizada em problemas de classificação. Essa redução não somente melhora a eficiência computacional dos algoritmos de Aprendizado de Máquina (AM), como também ajuda a minimizar os efeitos da “maldição da dimensionalidade”, um fenômeno que impacta o desempenho de modelos quando há inúmeros atributos com baixa amostragem relativa.

A Extração de Características refere-se à transformação dos dados originais em um conjunto de atributos mais representativos, enfatizando padrões de relevância para determinadas tarefas. Como descrito por Filho (2013), esse processo pode ser realizado por meio de técnicas estatísticas, transformadas espectrais ou métodos baseados em AM, dependendo da natureza dos dados. A extração permite que características discriminativas sejam utilizadas para a construção de modelos completos, facilitando a segmentação, reconhecimento de padrões e outras aplicações em visão computacional e processamento de sinais.

Araujo e Coelho (2009) definem a PCA como uma técnica utilizada na análise multivariada, cujo objetivo é reduzir a dimensionalidade de um conjunto de dados com múltiplas



variáveis, preservando, ao mesmo tempo, a maioria da variabilidade presente nesses dados. O PCA busca identificar e extrair um novo conjunto de variáveis, denominadas componentes principais, as quais são combinações lineares das variáveis originais. Estes componentes são selecionados para serem não correlacionados entre si e ordenados segundo a importância, medida pela variância explicada.

O procedimento inicial para conduzir uma PCA envolve a padronização dos dados, o que assegura que todas as variáveis tenham média zero e variância unitária, garantindo assim que cada uma tenha igual peso na análise. Em seguida, é calculada a matriz de covariância, a qual permite a extração dos autovalores e autovetores, fundamentais para identificar os componentes principais. Os componentes são organizados de maneira que o primeiro componente principal explicará a maioria da variância dos dados, seguido pelos demais componentes em ordem decrescente de importância (ARAUJO; COELHO, 2009).

### 3.5 Algoritmos Tradicionais de Classificação

Algoritmos tradicionais de classificação, como *KNN*, *SVM* e Árvores de Decisão, estabeleceram as bases para abordagens mais complexas e avançadas, esses algoritmos continuam sendo relevantes devido à sua simplicidade, eficiência computacional e facilidade de implementação (BORGES, 2024).

- **KNN (k-Nearest Neighbors)**

Guo *et al.* (2003) definem o algoritmo *KNN* (*tradução livre: k-Vizinhos Mais Próximos*), como uma técnica de aprendizado de máquina supervisionado amplamente empregada em tarefas de classificação. Sua popularidade se deve à simplicidade conceitual e à facilidade de implementação, o que o torna uma escolha comum em diferentes aplicações, como reconhecimento de padrões e sistemas de recomendação.

O KNN tem a característica de aprendizado preguiçoso (*lazy learning*), ou seja, não realiza uma fase explícita de treinamento, pois o modelo é construído durante a fase de classificação. Seu funcionamento consiste em armazenar o conjunto de dados de treinamento, composto por instâncias com atributos e classes conhecidas, e, a partir disso, realizar a classificação de novas instâncias seguindo alguns passos: primeiramente, define-se o valor de  $k$ , que representa o número de vizinhos mais próximos a serem considerados, sendo essa escolha fundamental para o desempenho do algoritmo (GUO *et al.*, 2003).

Guo *et al.* (2003) afirmam que, em seguida, é realizado o cálculo da distância entre a nova instância e todas as instâncias do conjunto de treinamento — utilizando geralmente a distância Euclidiana, embora outras métricas possam ser empregadas conforme a natureza dos dados. Depois disso, selecionam-se as  $k$  instâncias com as menores distâncias e, por fim, a nova instância recebe a classe mais comum entre seus vizinhos mais próximos, podendo essa decisão ser feita por votação simples ou ponderada pela distância, dando mais peso aos vizinhos mais próximos.

Na mesma referência, Guo *et al.* (2003), afirmam que a principal vantagem do KNN é a simplicidade e facilidade de implementação, com uma lógica intuitiva e estrutura menos complexa em comparação a outros métodos de aprendizado de máquina. Por ser um algoritmo não paramétrico, o KNN não pressupõe uma distribuição específica dos dados, o que o torna flexível e aplicável a uma variedade de problemas. Sua versatilidade permite que ele seja utilizado com diferentes tipos de dados, sejam eles numéricos ou categóricos, desde que se adote uma métrica de distância adequada. Outro ponto positivo é seu bom desempenho em problemas multimodais, nos quais há múltiplas concentrações de classes, lidando melhor com esses casos do que algoritmos que buscam uma fronteira de decisão global.

- **SVM (Support Vector Machine)**

O SVM é uma técnica de aprendizado supervisionado, utilizada para tarefas de classificação. Sua aplicação tem se destacado em contextos complexos e com muitos dados, como na genômica do câncer, onde é comum lidar com informações genéticas de difícil interpretação e em abundância (HUANG *et al.*, 2018).

De forma simplificada, o SVM procura encontrar uma linha (ou plano, em dimensões maiores) que melhor separa dois grupos de dados diferentes. Essa linha é definida de modo a manter a maior distância possível dos pontos mais próximos de cada grupo, chamados de *vetores de suporte*. Quanto maior essa distância, maior é a confiança da separação feita pelo modelo. Quando os dados não podem ser separados de forma simples, o SVM utiliza uma técnica chamada *função núcleo* (*kernel*), que permite transformar os dados para um novo espaço onde a separação é possível. Isso amplia o poder de aplicação do método, tornando-o útil mesmo em situações em que a separação entre os grupos não é visível diretamente Huang *et al.* (2018).

O SVM pode ser adaptado para lidar com mais de duas classes de dados, usando abordagens específicas como a *one-vs-rest* (“um contra o resto”, em tradução literal). Também

existem variações do método, como o SVM-RFE (*Recursive Feature Elimination*), que ajudam a selecionar quais características dos dados são mais relevantes para a tarefa em questão (HUANG *et al.*, 2018).

- **Árvore de Decisão**

A árvore de decisão é um modelo de aprendizado supervisionado que representa uma sequência de decisões de forma hierárquica e intuitiva. Trata-se de um grafo em formato de árvore, no qual cada nó interno corresponde a um teste sobre um atributo, cada ramo representa o resultado possível desse teste e cada folha indica a classe ou o valor previsto. Esse processo de particionamento recursivo transforma o conjunto de treinamento em subconjuntos mais homogêneos, até que se satisfaçam critérios de parada, como profundidade máxima ou pureza do nó (quando todas as instâncias pertencem à mesma classe), tornando o modelo fácil de interpretar (MONARD; BARANAUSKAS, 2003b).

Valle (2011) apresenta que a árvore pode ser aplicada tanto à classificação quanto à regressão, mas com algumas limitações. A construção ótima de árvores é um problema *NP-hard*, ou seja, inatingível por algoritmos exatos em tempo polinomial, razão pela qual se utilizam heurísticas gulosas, como o algoritmo *CART*, que realiza particionamentos binários para minimizar medidas de impureza. Isso torna os modelos sensíveis a ruídos e alterações nos dados de treinamento, exigindo métodos de *poda* ou definição de parâmetros restritivos para evitar o sobre ajuste dos dados. Ainda assim, sua simples estrutura e interpretabilidade são vantagens apreciadas em muitas aplicações científicas e industriais.

## 4 TRABALHOS RELACIONADOS

Neste capítulo apresenta trabalhos relacionados que exploram diversas abordagens para a análise automática de microestruturas de materiais. As metodologias abrangem desde a aplicação de técnicas clássicas de inteligência computacional, que utilizam descritores de textura e forma para classificar com alta precisão os tipos de ferro fundido, até o uso de modelos matemáticos específicos para aprimorar a segmentação de imagens sob iluminação não uniforme.

### 4.1 Classificação automática do tipo de ferro fundido utilizando Reconhecimento de Padrões em imagens de Microscopia Óptica

O estudo de Rodrigues *et al.* (2016) apresenta uma proposta metodológica voltada à automação da classificação de ferros fundidos por meio de técnicas de Inteligência Computacional e Reconhecimento de Padrões. Tal abordagem emerge como resposta às limitações dos métodos tradicionais, que dependem da análise visual realizada por especialistas, frequentemente marcada por subjetividades e longos tempos de processamento. A classificação correta dos tipos de ferro fundido é fundamental para assegurar seu uso adequado nas mais diversas aplicações industriais, sendo diretamente influenciada pelas formas e distribuições das grafitas em sua estrutura micrográfica.

Para atingir o objetivo, o trabalho emprega um conjunto de técnicas de extração de características e algoritmos de aprendizado de máquina. Foram utilizados descritores de textura, como a matriz de coocorrência em níveis de cinza (GLCM) e o *Local Binary Pattern* (LBP), além de descritores baseados na forma, como os momentos estatísticos, centrais e invariantes. Esses atributos foram extraídos a partir de imagens obtidas por microscopia óptica e utilizados como entrada para classificadores como *Bayes*, *SVM*, *Perceptron Multicamadas* (MLP), *KNN* e *K-Means*, compondo um fluxo de processamento sistematizado e replicável.

A metodologia proposta foi estruturada em duas etapas distintas. Na primeira, realizou-se o reconhecimento individual das grafitas segmentadas nas imagens. Na segunda, as imagens completas foram analisadas, sendo classificada como pertencente a uma determinada categoria de ferro fundido aquela cuja grafita predominante mais se repetisse na amostra. Essa abordagem permitiu maior robustez na classificação, reduzindo o impacto de imperfeições pontuais nas amostras e promovendo maior representatividade da estrutura do material analisado.

Os resultados experimentais evidenciam a eficácia da proposta. A análise quantitativa,

baseada em validação cruzada do tipo *Hold-Out* com cinco iterações, demonstrou que os classificadores baseados em textura, sobretudo o SVM com *kernel* linear e o MLP, obtiveram os melhores desempenhos quando associados aos descritores GLCM e LBP. Destaca-se o desempenho do classificador SVM, que obteve acurácia de até 99,4% na classificação individual das grafitas e quase 100% na classificação por imagem completa utilizando o kernel RBF, indicando o potencial da abordagem para aplicações em sistemas comerciais de apoio à decisão em contextos industriais e acadêmicos.

#### **4.2 Recognition of clinker phases by automatic image analysis**

O estudo desenvolvido por Jourlin *et al.* (2001) introduz uma abordagem alternativa para a segmentação de imagens digitais, fundamentada no modelo de *Processamento de Imagens Log-Valoradas* (LIP). Esse modelo considera as propriedades físicas da formação da imagem e a natureza não-linear da percepção luminosa, oferecendo uma estrutura matemática mais compatível com variações de iluminação, fator crítico em aplicações industriais e biomédicas.

O objetivo principal do trabalho foi construir um método de segmentação capaz de identificar regiões homogêneas em imagens mesmo sob condições de iluminação não uniformes. Para isso, os autores definem operadores específicos na aritmética do modelo LIP, como o *Logarithmic Contrast*, além de adaptarem operadores morfológicos clássicos para operar nesse novo contexto matemático. Em testes com imagens industriais e médicas, o método demonstrou ganhos consistentes de desempenho em comparação com técnicas clássicas. Por exemplo, em imagens com baixa razão sinal-ruído e variação significativa de iluminação, o uso do contraste logarítmico resultou em um aumento de até 20% na precisão da segmentação em relação a operadores lineares convencionais.

Além disso, o critério morfológico adaptado ao modelo LIP permitiu manter uma taxa de acerto superior a 90% na identificação de regiões homogêneas em imagens complexas, como aquelas utilizadas em inspeções visuais automáticas. Os autores também destacam a estabilidade do método frente a alterações de brilho global: em situações simuladas de variação de intensidade luminosa, o desempenho da segmentação log-valorada se manteve praticamente constante, com variações inferiores a 5% nos resultados. Esses números evidenciam o diferencial da abordagem proposta, especialmente em cenários onde a iluminação representa um desafio relevante para a consistência da análise de imagens.

### 4.3 Automação da Identificação de C3S na Microscopia do Clínquer

A pesquisa realizado por Padilha (2023) busca desenvolver um sistema automatizado para a identificação e segmentação de cristais de C3s em imagens microscópicas de clínquer, utilizando redes neurais convolucionais (CNN), com foco no algoritmo *Mask R-CNN*. A relevância da pesquisa está na automação do processo, que atualmente é realizado manualmente, resultando em inconsistências e atraso na análise. O problema central é a dificuldade na identificação precisa dos cristais de C3S devido à qualidade variada das imagens e à ausência de um modelo robusto capaz de lidar com cristais muito próximos ou pouco definidos.

A metodologia adotada foi baseada na aplicação do algoritmo Mask R-CNN para segmentação e classificação de cristais de C3s em imagens microscópicas. A pesquisa envolveu a coleta de imagens microscópicas de clínquer, o pré-processamento das imagens, aplicação de técnicas de segmentação como K-Means e K-Nearest Neighbors (KNN), e a utilização de redes neurais convolucionais (CNN) para a classificação. O Mask R-CNN foi treinado inicialmente sem pré-processamento das imagens e, posteriormente, utilizando um filtro bilateral para melhorar a precisão da segmentação. Os parâmetros do filtro bilateral foram otimizados por um algoritmo genético. A base de dados utilizada incluiu 300 imagens de clínquer, divididas em conjunto de treino, teste e validação.

Os resultados comprovaram que o Mask R-CNN conseguiu identificar cristais de C3s com precisão satisfatória, porém com limitações na separação de cristais muito próximos ou com divisões discretas. O uso do filtro bilateral contribuiu para a redução dos erros de classificação, principalmente distinguindo poros de cristais de C3s, mas não foi suficiente para alcançar uma precisão comparável à análise manual por especialistas. Os resultados indicam que a qualidade das imagens e a diversidade da base de dados são fatores determinantes para a eficácia do modelo.

As principais limitações do estudo foram a baixa qualidade das imagens utilizadas e a ausência de um especialista em microscopia de clínquer durante o processo de validação dos resultados. Além disso, o modelo enfrentou dificuldades na separação de cristais de C3s muito próximos, especialmente aqueles que apresentavam divisões discretas ou imperceptíveis. A base de dados restrita em quantidade e qualidade também impactou negativamente a generalização do modelo.

#### **4.4 Estudo da identificação automática do cristal de C3S em imagens microscópicas de Clínquer e sua relevância para o Monitoramento do Funcionamento de Fornos Rotativos de plantas de cimento**

O estudo de Lima (2023) teve como objetivo propor a realização de agrupamentos manuais de cristais de C3s em imagens microscópicas de clínquer, classificados de acordo com suas formas (idiomorfismo), para posterior uso no treinamento do algoritmo *Mask Region based Convolutional Neural Network (MRCNN)*. A proposta busca facilitar e agilizar o processo de identificação dos cristais automatizada, contribuindo assim para o monitoramento das condições operacionais dos fornos rotativos em plantas de cimento. O problema identificado está relacionado à necessidade de um método mais eficiente para a análise microscópica dos cristais de alita em clínquer, que atualmente é realizada manualmente, demandando tempo e atrasando a obtenção de informações cruciais para o controle de qualidade do processo de clinquerização.

A metodologia adotada envolveu a utilização da microscopia de luz refletida para análise da microestrutura do clínquer. As amostras de clínquer foram preparadas, polidas e visualizadas no microscópio, com as imagens sendo capturadas e armazenadas digitalmente. A seguir, foram realizadas anotações manuais dos cristais de Alita, categorizando-os em três grupos: idiomórficos, subdiomórficos e xenomórficos, de acordo com suas características morfológicas. O *software Roboflow* foi utilizado para a marcação das imagens, sendo essas anotações posteriormente empregadas como rótulos para o treinamento do algoritmo MRCNN. O treinamento do MRCNN foi realizado com 121 imagens microscópicas de clínquer, para permitir a identificação automática dos cristais, verificando-se a precisão da classificação realizada pelo modelo.

Os resultados evidenciaram que o algoritmo MRCNN pôde identificar cristais subdiomórficos com maior precisão, devido à maior quantidade desse tipo de cristal nas amostras utilizadas para o treinamento. Em contrapartida, a identificação dos cristais idiomórficos e xenomórficos apresentou baixa precisão, devido à quantidade insuficiente de amostras representativas dessas classes no banco de imagens. Em imagens com abundância de cristais, o modelo apresentou dificuldades em detectar todos os elementos, indicando a necessidade de mais amostras e refinamento do treinamento. Em imagens com poucos cristais, a identificação foi mais precisa e consistente, indicando um desempenho mais eficiente do algoritmo em situações com menor densidade de cristais.

A principal limitação do estudo foi a quantidade restrita de imagens disponíveis para o treinamento do algoritmo, o que impactou negativamente na identificação dos cristais

idiomórficos e xenomórficos. Além disso, a variação na quantidade de cristais presentes em cada imagem dificultou a identificação em imagens com maior densidade de cristais. Outra limitação foi a utilização de um único algoritmo para a identificação dos cristais, sem a aplicação de técnicas complementares ou métodos híbridos que poderiam melhorar a precisão da classificação.

#### 4.5 Comparação de Trabalhos

Nesta seção, são comparados os trabalhos relacionados mencionados anteriormente, com foco em objetivo, base de dados e algoritmos. Os estudos abordam desde a classificação automática de ferros fundidos utilizando técnicas de reconhecimento de padrões, até a identificação de cristais de C3s em imagens microscópicas de clínquer.

Os trabalhos selecionados utilizam uma variedade de abordagens, incluindo métodos supervisionados e não supervisionados, técnicas de segmentação, extração de características e aplicação de algoritmos de classificação. A Tabela 1 resume as principais características desses trabalhos, permitindo uma visualização clara das metodologias, bases de dados utilizadas, algoritmos empregados e principais resultados obtidos.

Tabela 1 – Comparação entre os trabalhos relacionados e a pesquisa atual

<b>Autores</b>	<b>Objetivo</b>	<b>Base de Dados</b>	<b>Algoritmos Utilizados</b>
<b>Rodrigues <i>et al.</i> (2016)</b>	Classificação de ferro fundido usando inteligênciacomputacional e descritores de textura e forma.	Imagens obtidas por microscopia óptica.	Bayes, SVM, Perceptron Multicamadas (MLP), KNN e K-Means.
<b>Jourlin <i>et al.</i> (2001)</b>	Segmentação de imagens com base no modelo LIP, que considera a física da formação da imagem e a percepção não linear da luz.	Imagens industriais e médicas com iluminação não uniforme.	Contraste Logarítmico e operadores morfológicos clássicos adaptados para o modelo LIP.
<b>Padilha (2023)</b>	Sistema automatizado para identificar e segmentar cristais de C3S em imagens de clínquer, usando redes neurais convolucionais, com foco no Mask R-CNN.	300 imagens de clínquer, divididas em conjuntos de treino, teste e validação.	Mask R-CNN, K-Means, K-Nearest Neighbors (KNN) e um algoritmo genético para otimizar um filtro bilateral.
<b>Lima (2023)</b>	Agrupamento manual de cristais de C3S por forma em imagens de clínquer para treinar o algoritmo Mask R-CNN.	121 imagens microscópicas de clínquer.	MRCNN (Mask R-CNN) e o software Roboflow para anotação das imagens.
<b>Autor deste trabalho</b>	Estudo comparativo dos algoritmos árvores de decisão, KNN e SVM na classificação de cristais de C3S, usando técnicas de extração de características.	Imagens microscópicas de clínquer cedidas por uma empresa parceira.	Árvores de Decisão, KNN (K-Nearest Neighbors) e SVM (Support Vector Machines).

Fonte: elaborado pelo autor (2025).



## 5 METODOLOGIA

Neste capítulo é apresentada a metodologia do estudo de comparação de algoritmos de classificação de imagens para identificação de cristais de C3s. A Figura 6 representa um resumo das seções que serão apresentadas a seguir.

Figura 6 – Metodologia do trabalho



Fonte: elaborado pelo autor (2025).

### 5.1 Extração das características dos cristais

A primeira etapa da metodologia consiste na extração de características dos cristais C3s chamadas de descritores de forma, apresentados no trabalho de Andrade *et al.* (2025). Este processo transforma os dados visuais das imagens microscópicas em um conjunto de atributos representativos e numéricos, que podem ser processados pelos algoritmos de classificação. O objetivo é enfatizar os padrões relevantes que permitem identificar os cristais, facilitando o reconhecimento e a segmentação consecutiva.

Estas características de C3s obtidas são apresentadas como: circularidade, *aspect ratio* (proporção), retangularidade e solidez.

- A circularidade é uma medida que quantifica o quão semelhante uma forma é a um círculo perfeito. Um círculo é a forma que possui a maior área para um dado perímetro.
- O *aspect ratio* descreve a proporcionalidade de um objeto. É definido como a razão entre a largura e o comprimento (ou altura) do retângulo de contorno mínimo.
- A retangularidade mede o quão bem a forma de um objeto se ajusta a um retângulo. É calculada pela razão entre a área do objeto e a área do menor retângulo que o circunscreve (conhecido como retângulo de contorno mínimo).

- A solidez descreve a convexidade de um objeto, medindo a densidade da sua forma. É calculada como a razão entre a área do objeto e a área de seu fecho convexo (a menor forma convexa que contém o objeto, como se um elástico fosse esticado ao seu redor).

Na Figura 7 é exemplificado a ilustração para a identificação das Alitas, seguida da transformação com a utilização de máscaras para que seja possível a extração das características. Inicialmente, a rede treinada recebe a imagem com os cristais de C3s, e dessa imagem é feita uma segmentação para identificar as Alitas que estão presentes. Para cada cristal detectado é criada uma máscara, sinalizado na terceira partição da figura, caracterizado por um cristal delimitado por uma coloração branca.

Figura 7 – Mascara delimitando os limites de um cristal



Fonte: elaborado pelo autor (2025).

Com as imagens segmentadas pelas máscaras, é aplicado um algoritmo<sup>1</sup> publicado por Andrade (2025), desempenhando a extração dos descritores de forma para cada cristal identificado pela segmentação, criando um conjunto de dados com as características citadas. A saída do algoritmo destina-se em um *dataframe* para posteriormente ser classificado na próxima etapa, adicionando os rótulos para cada instância do conjunto. A Tabela 2 exemplifica a saída das características do cristal referenciado na Figura 7.

Tabela 2 – Características extraídas do cristal pela rede neural

<b>Circularidade</b>	<b>Aspect ratio</b>	<b>Retangularidade</b>	<b>Solidez</b>
0,60612500415	0,35949916638	0,86759382347	0,98084902649

Fonte: elaborado pelo autor (2025).

## 5.2 Classificação manual

Após a conclusão da etapa de extração das características dos cristais, procedeu-se à classificação morfológica manual das instâncias de C3s segmentadas pela rede. O processo consistiu na avaliação visual de cada máscara para atribuir ao cristal de Alita correspondente

<sup>1</sup> Disponível em: <https://github.com/la-zu-li/pca-measuring-c3s-clinker/>

uma classe morfológica. Adotou-se um sistema de classificação binário, no qual cada instância foi rotulada como regular ou irregular com base em seus atributos visuais. Os cristais podem receber dois rótulos, durante a classificação manual, como segue.

- **Regular (0):** onde os cristais possuem contornos mais definidos e uniformes; limites claros que não se confundem com outros cristais ou poros; formato íntegro; não fragmentado. A Figura 8 apresenta as máscaras segmentadas do tipo regular.

Figura 8 – Exemplo de cristais regulares



Fonte: elaborado pelo autor (2025).

- **Irregular (1):** considerado quando sua forma, contorno ou apresentação na imagem microscópica dificultam sua delimitação precisa. A Figura 9 apresenta as máscaras segmentadas do tipo irregular.

Figura 9 – Exemplo de cristais irregulares



Fonte: elaborado pelo autor (2025).

### 5.3 Treinamento dos modelos de classificação

Nesta fase da metodologia, o conjunto de dados, composto pelos vetores de características extraídos anteriormente e pelos rótulos definidos na etapa de classificação manual, é utilizado para treinar os modelos. O conjunto de dados é particionado em subconjuntos de treino e teste. Adotando uma abordagem comum na literatura, pode-se dividir o *dataset* em proporções como 70% para treinamento, 30% para teste. Essa separação é importante para treinar os modelos supervisionados e para avaliá-los de forma imparcial, evitando o superajuste (SANTOS *et al.*, 2019).

## 5.4 Avaliação e comparação entre os modelos

A fase final da metodologia é dedicada à avaliação quantitativa e à análise comparativa do desempenho dos modelos treinados. Para esta etapa, é utilizado o conjunto de dados de teste, que não foi empregado durante o treinamento ou a validação, buscando uma avaliação imparcial da capacidade de generalização de cada modelo. A comparação é multifacetada, abrangendo tanto a precisão da classificação quanto a eficiência computacional.

---

### **Algorithm 1** Treinamento, Avaliação e Visualização de Modelos de Classificação

---

```

Importar bibliotecas (dados, visualização, modelos, métricas);
Carregar dados a partir de arquivo CSV;
Tratar dados: corrigir decimais e remover valores inválidos;
Definir variáveis explicativas  $X$  e resposta  $y$ ;
Configurar validação cruzada estratificada (10 dobras);

Inicializar modelos:
SVM com padronização;
KNN com padronização;
Árvore de Decisão sem padronização;

for cada modelo do
    Avaliar com cross_validate usando Acurácia, Precisão, Recall e F1-Score (ponderados);
    Armazenar médias dos scores;
end
Exibir resultados como tabela;
Dividir dados em treino e teste (70% / 30%);

for cada modelo do
    Treinar com os dados de treino;
    Prever com os dados de teste;
    Calcular matriz de confusão;
end

for cada modelo do
    Gerar curva de aprendizado com tamanhos variados
    ; Calcular médias e desvios;
    Plotar curvas com incerteza;
end

```

---

Fonte: elaborado pelo autor (2025).

Para avaliar modelos de aprendizado supervisionado como SVM e KNN, são utilizadas métricas de classificação padrão que comparam as previsões do modelo com os rótulos verdadeiros do conjunto de teste. Essas métricas incluem a acurácia, a porcentagem geral de

classificações corretas; a precisão, que mede a proporção de classificações positivas que foram de fato corretas, avaliando a taxa de falsos positivos; o recall (ou sensibilidade), que mede a proporção de positivos reais corretamente identificados, avaliando a taxa de falsos negativos; e o F1-Score, média harmônica entre precisão and recall, fornecendo uma métrica única que equilibra ambas as medidas (BRUNO *et al.*, 2018).

Os resultados obtidos em todas as métricas são compilados e analisados. Aqui é realizada uma comparação direta entre os algoritmos, com o auxílio de tabelas e gráficos, para identificar qual modelo oferece o melhor equilíbrio entre precisão de classificação e custo computacional. Esta análise permite concluir sobre o método mais adequado para a classificação de cristais no contexto deste estudo. O algoritmo utilizado pode ser visualizado no pseudo código apresentado em Algorithm 1.

## 6 RESULTADOS

Neste capítulo será abordado os resultados gerados pelos modelos treinados na etapa de metodologia e a comparação entre os modelos.

### 6.1 Classificação Manual

O capítulo anterior apresenta a metodologia que envolve classificação manual das máscaras e atribuição manual dos rótulos: 0 para alitas regulares e 1 para alitas irregulares. Das 320 instâncias avaliadas, 210 (aproximadamente 65%) são alitas regulares e 110 (aproximadamente 35%) são alitas irregulares. A Tabela 3 apresenta os resultados dessa classificação:

Tabela 3: Contagem

Rótulo	Tipo	Contagem
Regular	0	210
Irregular	1	110

Fonte: elaborado pelo autor (2025).

Esse desbalanceamento entre as classes pode comprometer o desempenho dos modelos de classificação, pois a classe majoritária tende a influenciar as predições. Para contornar esse problema, o algoritmo desenvolvido aplica técnicas de balanceamento baseadas em recursos de linguagem antes de alimentar os classificadores.

### 6.2 Desempenho Geral dos Modelos

No experimento de validação cruzada estratificada e embaralhada (Tabela 4), o SVM apresentou desempenho robusto, com acurácia de 95,94%, precisão de 96,10%, *recall* de 95,94% e *F1-Score* de 95,87%. Esses resultados indicam que o SVM equilibra bem a capacidade de classificação entre as classes, minimizando tanto falsos positivos quanto falsos negativos.

Tabela 4: Validação cruzada estratificada e embaralhada

Modelo	Acurácia	Precisão	Recall	F1- Score
SVM	0.959375	0.961004	0.959375	0.958683
KNN	0.940625	0.942798	0.940625	0.939763
Árvore de Decisão	0.971875	0.973179	0.971875	0.971615

Fonte: elaborado pelo autor (2025).

O KNN, por sua vez, obteve acurácia de 94,06%, precisão de 94,28%, recall de

94,06% e F1-Score de 93,98%. Mesmo satisfatório, esse desempenho é inferior ao do SVM, sugerindo que a dependência do KNN na proximidade entre instâncias pode ser menos eficaz em cenários de alta dimensionalidade ou com amostras ruidosas.

Já a Árvore de Decisão alcançou os melhores resultados entre os três métodos, com acurácia de 97,19%, precisão de 97,32%, recall de 97,19% e F1-Score de 97,16%. Esses valores superlativos demonstram que o modelo não somente classifica corretamente a maioria das instâncias, mas também mantém um excelente equilíbrio entre precisão e sensibilidade.

Em confronto direto, observa-se que a Árvore de Decisão supera tanto o SVM quanto o KNN em todas as métricas analisadas. Enquanto o SVM mantém vantagem sobre o KNN, a capacidade da árvore de capturar interações não lineares e hierarquizar critérios de separação contribui para sua atuação, tornando-a o modelo mais indicado para a classificação.

### 6.3 Métricas dos Modelos por Classe

Na Tabela 5, são apresentados os resultados de precisão, *recall* e F1-score separados por classe para os três algoritmos. As cores mais escuras de azul indicam valores mais altos, facilitando a visualização das métricas de cada modelo em função da classe avaliada.

Tabela 5: Desempenho dos Algoritmos por Classes

Modelo	Classe	Precisão	Recall	F1-Score
SVM	0	0.938	0.952	0.945
	1	0.906	0.879	0.892
KNN	0	0.924	0.968	0.946
	1	0.933	0.848	0.889
Árvore de Decisão	0	0.984	0.968	0.976
	1	0.941	0.970	0.955

Fonte: elaborado pelo autor (2025).

O SVM atingiu, para alitas regulares (classe 0), precisão de 93,8%, *recall* de 95,2% e F1-score de 94,5%; para alitas irregulares (classe 1), obteve precisão de 90,6%, *recall* de 87,9% e F1-score de 89,2%. Já o KNN registrou, na classe 0, precisão de 92,4%, recall de 96,8% e F1-score de 94,6%, mas apresentou queda no *recall* da classe 1, com 84,8%, apesar de precisão de 93,3% e F1-score de 88,9%.

Em contraste, a Árvore de Decisão superou ambos os métodos em todas as métricas: para alitas regulares, marcou precisão de 98,4%, *recall* de 96,8% e F1-score de 97,6% — a tonalidade mais escura de azul — e, para alitas irregulares, alcançou precisão de 94,1%,


*recall* de 97,0% e *F1-score* de 95,5%. Esse resultado evidencia a capacidade de lidar com o desbalanceamento e capturar padrões não lineares, garantindo classificação extremamente assertiva. Ressalte-se ainda que, mesmo com poucas instâncias de alitas irregulares, todos os modelos mantiveram desempenho elevado nesse grupo, sobretudo a Árvore de Decisão.

#### 6.4 Matrizes de confusão e Curvas de Aprendizado

Nesta seção, apresenta-se a análise visual dos resultados de desempenho de cada modelo, SVM, KNN e Árvore de Decisão, por meio de matrizes de confusão e curvas de aprendizagem. São destacados os padrões de erro (falsos positivos e falsos negativos), a evolução da acurácia em função do volume de dados de treino e a capacidade de generalização de cada algoritmo.

Na matriz de confusão do SVM, Figura 10, observam-se 60 verdadeiros negativos e 29 verdadeiros positivos, com 3 falsos positivos e 4 falsos negativos. Isso indica um baixo índice de confusão entre classes, embora haja ligeiro viés em classificar algumas alitas irregulares como regulares. A curva de aprendizagem mostra que a acurácia de treinamento se mantém estável em torno de 96,7%, enquanto a de validação evolui de aproximadamente 90,3% para 96,0% à medida que o conjunto de treino cresce. O estreitamento progressivo da banda de confiança sugere bom ajuste aos dados sem *overfitting* significativo.

Figura 10: SVM



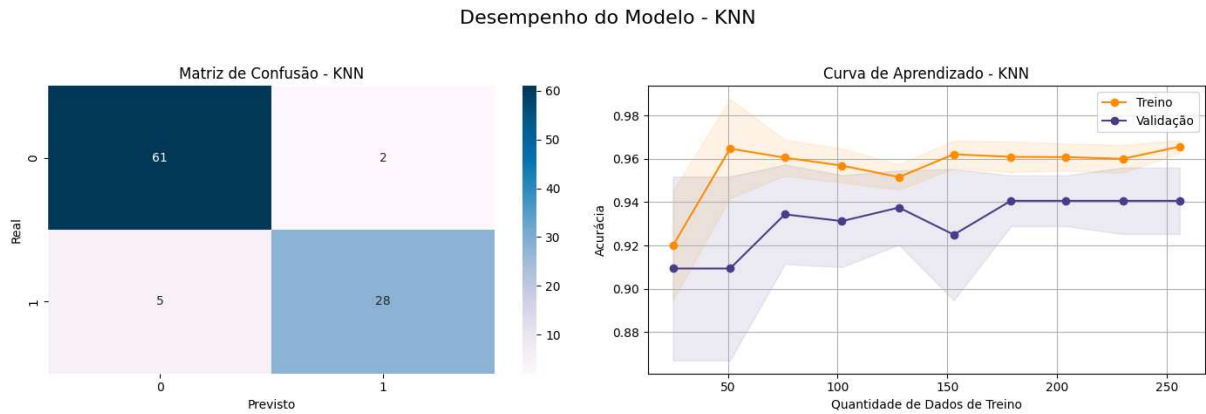
Fonte: elaborado pelo autor (2025).

No KNN, Figura 11, a matriz de confusão registra 61 verdadeiros negativos e 28 verdadeiros positivos, com 2 falsos positivos e 5 falsos negativos, evidenciando maior dificuldade em identificar alitas irregulares. A curva de aprendizagem revela acurácia de treino que salta de 92,0% para cerca de 96,5% com mais dados, enquanto a de validação parte de 91,0% e



estabiliza próximo a 94,0%. A diferença moderada entre treino e validação e a leve oscilação inicial indicam que o KNN capta padrões locais eficazmente, porém sofre um pouco com a variabilidade das amostras.


Figura 11: KNN



Fonte: elaborado pelo autor (2025).

A matriz de confusão da Árvore de Decisão, Figura 12, apresenta 61 verdadeiros negativos e 32 verdadeiros positivos, com somente 2 falsos positivos e 1 falso negativo, demonstrando classificação quase impecável. Na curva de aprendizagem, a acurácia de treino permanece em 100%, enquanto a de validação flutua entre 98,7% e 97,5% à medida que os dados de treino aumentam, com banda de confiança estreita. Esse comportamento reflete alto poder discriminativo e leve *overfitting* que, contudo, não compromete a generalização. Dentre os três modelos, a Árvore de Decisão destaca-se visualmente pelas tonalidades mais escuras nas métricas, sinalizando sua superioridade em classificação assertiva.

Figura 12: Árvore de decisão



Fonte: elaborado pelo autor (2025).

## 7 CONCLUSÕES E TRABALHOS FUTUROS

Com base nos resultados obtidos, este trabalho alcançou seu objetivo principal de comparar diferentes algoritmos de classificação para a identificação de cristais de C3s em imagens microscópicas de clínquer. A análise de desempenho revelou que, dentre os algoritmos avaliados, a Árvore de Decisão apresentou a maior eficácia, com uma acurácia de 97,19%. Este modelo demonstrou superioridade não somente na classificação geral, mas também no equilíbrio entre precisão e sensibilidade para as classes de cristais regulares e irregulares.

Durante o desenvolvimento, destacaram-se duas dificuldades fundamentais. A primeira foi a escassez de publicações acadêmicas específicas sobre a fase Alita; a segunda foi a quantidade restrita de imagens fornecidas pela empresa parceira, reduzindo a diversidade das amostras para treinamento e validação dos modelos.

Para trabalhos futuros recomenda-se ampliar a base de dados com imagens em diferentes resoluções, contrastes e condições de aquisição; explorar arquiteturas de aprendizado profundo *end-to-end* (por exemplo, CNNs especializadas em morfologia); desenvolver métodos híbridos que combinem descritores clássicos de forma com representações aprendidas; e incorporar novos atributos (textura, granulometria, anisotropia) para enriquecer o conjunto de características e aprimorar a robustez e a generalização dos modelos.

## REFERÊNCIAS

- ADENIYI, P. O. Digital analysis of multitemporal landsat data for land-use/land-cover classification in a semi-arid area of nigeria. **Photogrammetric engineering and remote sensing**, v. 51, n. 11, p. 1761–1774, 1985.
- ANDRADE, I. E. C. d. **Uma aplicação da análise de componentes principais na determinação do tamanho da maior diagonal de cristais de C3S em amostras de clínquer**. Trabalho de Conclusão de Curso (Graduação em Engenharia de Software) – Universidade Federal do Ceará, Russas, CE, 2025.
- ANDRADE, I. E. C. D.; PADILHA, R. M. S.; PAZ, R. F. D.; ZUANETTI, D. A. Automated high-resolution microscopy for clinker analysis: A divide-and-conquer deep learning approach with mask r-cnn and pca for alite measurement. **Expert Systems with Applications**, Elsevier, p. 128552, 2025.
- ANJOS, C. S. dos; ALMEIDA, C. M. de; GALVÃO, L. S. Identificação de materiais urbanos por meio de métodos inovadores de classificação de imagens. In: **Anais do XVII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**. João Pessoa, PB: INPE, 2015. p. 4377–4384.
- ARAUJO, W. O. de; COELHO, C. J. **Análise de componentes principais (PCA)**. Anápolis, GO, 2009.
- BHOWMIK, M. K. **Computer Vision: Object Detection in Adversarial Vision**. Boca Raton, FL: CRC Press, 2024.
- BIANCHI, M. F. de. **Extração de características de imagens de faces humanas através de wavelets, PCA e IMPCA**. Dissertação (Dissertação de Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2006.
- BORGES, B. R. **Análise comparativa de algoritmos de classificação de texto**. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Faculdade de Computação, Universidade Federal de Uberlândia, Uberlândia, MG, 2024.
- BRANCO, P. de M. **Dicionário de mineralogia e gemologia**. São Paulo, SP: Oficina de Textos, 2008.
- BRUNO, A. E.; CHARBONNEAU, P.; NEWMAN, J.; SNELL, E. H.; SO, D. R.; VANHOUCKE, V.; WATKINS, C. J.; WILLIAMS, S.; WILSON, J. Classification of crystallization outcomes using deep convolutional neural networks. **PLOS one**, Public Library of Science San Francisco, CA USA, v. 13, n. 6, p. e0198883, 2018.
- CAMPBELL, D. H. **Microscopical Examination and Interpretation of Portland Cement and Clinker**. Skokie, Illinois: Portland Cement Association, 1999. PCA Publication SP030.
- FILHO, E. Q. d. S. **Um Sistema de visão computacional para classificação da qualidade do couro caprino**. Dissertação (Dissertação de Mestrado) – Programa de Pós-Graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, CE, 2013.
- FREITAS, D. C. d. **Aferição da porosidade do clínquer: uma solução automática**. Trabalho de Conclusão de Curso (Graduação em Engenharia de Minas) – Departamento de Engenharia de Minas, Universidade Federal de Minas Gerais, Belo Horizonte, MG, 2022.

GUO, G.; WANG, H.; BELL, D.; BI, Y.; GREER, K. KNN model-based approach in classification. In: **On the Move to Meaningful Internet Systems 2003: OTM 2003 Workshops**. [S. l.]: Springer, 2003. (Lecture Notes in Computer Science, v. 2889), p. 986–996.

HUANG, S.; CAI, N.; PACHECO, P. P.; NARRANDES, S.; WANG, Y.; XU, W. Applications of support vector machine learning in cancer genomics. **Cancer Genomics & Proteomics**, International Institute of Anticancer Research, v. 15, n. 1, p. 41–51, 2018.

JOURLIN, M.; ROUX, B.; FAURE, R.-M. Recognition of clinker phases by automatic image analysis. **Cement and Concrete Composites**, Elsevier, v. 23, n. 2-3, p. 207–214, 2001.

JULIO, J. P. E. D. **Redução de dimensionalidade: aplicação de algoritmos de seleção e extração de atributos**. Dissertação (B.S. thesis) – Universidade Tecnológica Federal do Paraná, 2019.

LEI, T.; NANDI, A. K. **Image Segmentation: Principles, Techniques, and Applications**. Hoboken, NJ: John Wiley & Sons, 2022.

LIMA, H. F. **Estudo da identificação automática do cristal de C3S em imagens microscópicas de clínquer e sua relevância para o monitoramento do funcionamento de fornos rotativos em plantas de cimento**. Trabalho de Conclusão de Curso (Graduação em Engenharia de Controle e Automação) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, MG, 2023.

MAKI, I. Relationship of processing parameters to clinker properties; influence of minor components. **Proc. 8th Int. Congr. Chem. Cement**, v. 1, p. 35–47, 1986.

MENINO, A. F. S. **Otimização de resistências mecânicas do cimento com base nas suas características químicas e mineralógicas**. Dissertação (Mestrado) – Universidade NOVA de Lisboa (Portugal), 2015.

MOCHIZUKI, V. d. L. **Efeito da distribuição de partículas cristalinas na energia de produção de clínquer e Cimento Portland**. Trabalho de Conclusão de Curso (Graduação em Engenharia de Materiais) – Centro de Tecnologia, Universidade Federal da Paraíba, João Pessoa, PB, 2022.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. In: CARVALHO, A. C. P. L. F. de; LORENA, A. C.; MONARD, M. C. (Ed.). **Sistemas Inteligentes: Fundamentos e Aplicações**. Barueri, SP: Manole, 2003. cap. 1.

MONARD, M. C.; BARANAUSKAS, J. A. Indução de regras e árvores de decisão. **Sistemas Inteligentes**. Rezende, SO Editora Manole Ltda, p. 115–140, 2003.

MORAIS, L. T. O. **O impacto do ajuste da chama no tamanho dos cristais de Alita em fornos de clínquer**. Trabalho de Conclusão de Curso (Graduação em Engenharia Química) – Universidade Federal Rural do Semi-Árido, Caraúbas, RN, 2021.

NETO, F. d. C. S. **Acompanhamento do Processo Produtivo do Cimento Portland e Avaliação da Cogeração de Energia na Unidade Fabril da Companhia Industrial de Cimento Apodi em Quixeré-CE**. Trabalho de Conclusão de Curso (Graduação em Engenharia de Energia) – Universidade Federal Rural do Semi-Árido, Mossoró, RN, 2018.

PADILHA, R. M. S. **Automação da Identificação de C3S na Microscopia do Clínquer**. Trabalho de Conclusão de Curso (Graduação em Engenharia de Software) – Universidade Federal do Ceará, Russas, CE, 2023.

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis**. 5. ed. Cham, Switzerland: Springer, 2022.

RODRIGUES, D. de A.; SANTOS, G. P. dos; FERNANDES, M. C.; SANTOS, J. C. dos; FREITAS, F. N. C.; FILHO, P. P. R. Classificação automática do tipo de ferro fundido utilizando reconhecimento de padrões em imagens de microscopia. **IX Congresso Nacional de Engenharia Mecânica**, 2016.

RODRIGUES, R. V. **Segmentação de cristais de clínquer em imagens microscópicas via redes neurais convolucionais**. Trabalho de Conclusão de Curso (Graduação em Engenharia da Computação) – Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, MG, 2024.

SANTOS, H. G. d.; NASCIMENTO, C. F. d.; IZBICKI, R.; DUARTE, Y. A. d. O.; FILHO, A. D. P. C. Machine learning para análises preditivas em saúde: exemplo de aplicação para prever óbito em idosos de são paulo, brasil. **Cadernos de Saúde Pública**, SciELO Public Health, v. 35, p. e00050818, 2019.

SNYDER, W. E.; QI, H. **Fundamentals of Computer Vision**. Cambridge, UK: Cambridge University Press, 2017.

SOUZA, V. C. G.; SAMPAIO, C. H.; TAVARES, L. M. M. Estudo da influência da microestrutura do clínquer sobre a moagem na fabricação de cimento: microscopia eletrônica de varredura. **Rem: Revista Escola de Minas**, SciELO Brasil, v. 55, p. 209–213, 2002.

STUTZMAN, P. Contributions of nist/nbs researchers to the crystallography of construction materials. **Journal of research of the National Institute of Standards and Technology**, v. 106, n. 6, p. 1051, 2001.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. 2nd. ed. Cham, Switzerland: Springer Nature, 2022.

VALLE, M. E. **Aprendizado de Máquinas**. 2011. Notas de Aula. Departamento de Matemática Aplicada, Universidade Estadual de Campinas (UNICAMP). Acessado em: 12 jul. 2025. Disponível em: <https://www.ime.unicamp.br/~valle/cursos/am/>.

VENTURIERI, A.; SANTOS, J. R. dos. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E. E. (Ed.). **Sistema de Informações Geográficas: Aplicações na Agricultura**. Brasília, DF: Embrapa-SPI, 1998. p. 165–212.