



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS DE RUSSAS**  
**CURSO DE GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

**DENISE CARVALHO DE FREITAS**

**AFERIÇÃO DA POROSIDADE DO CLÍNQUER: UMA SOLUÇÃO AUTOMÁTICA**

**RUSSAS**

**2022**

DENISE CARVALHO DE FREITAS

AFERIÇÃO DA POROSIDADE DO CLÍNQUER: UMA SOLUÇÃO AUTOMÁTICA

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

Orientadora: Prof. Dra. Rosineide Fernando da Paz

Coorientador: Prof. Dr. Rafael Fernandes Ivo

RUSSAS

2022

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

---

- F936a Freitas, Denise Carvalho de.  
Aferição da porosidade do clínquer : uma solução automática / Denise Carvalho de Freitas. – 2022.  
44 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Russas,  
Curso de Ciência da Computação, Russas, 2022.  
Orientação: Prof. Dr. Rosineide Fernando da Paz.
1. Análise de Imagem.. 2. Clínquer. 3. Porosidade do Clínquer. 4. Automação industrial. I. Título.  
CDD 005
-

DENISE CARVALHO DE FREITAS

AFERIÇÃO DA POROSIDADE DO CLÍNQUER: UMA SOLUÇÃO AUTOMÁTICA

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

Aprovada em:

BANCA EXAMINADORA

---

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

---

Prof. Dr. Rafael Fernandes Ivo (Coorientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dra. Maria Nilde Fernandes Barreto Frederico  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Anderson Feitoza Leitão Maia  
Universidade Federal do Ceará (UFC)

Dedico o resultado desta caminhada acadêmica, em primeiro lugar, à família que estou construindo, base da minha força. Esta é uma de muitas conquistas que virão para nos alegrar.

## **AGRADECIMENTOS**

A Deus, pela minha vida, e por me permitir ultrapassar todos os obstáculos encontrados ao longo da realização deste trabalho.

Aos meus pais Denisio e Cleide e ao meu irmão Diêgo por por todo o esforço investido na minha educação, por estarem ao meu lado e por me fazer ter confiança nas minhas decisões.

Ao meu esposo e companheiro Nicolas Vieira, por compreender os meus momentos e dificuldades. Seu valioso e incansável apoio foi definitivo em todos os momentos deste trabalho.

A mãe e irmã que a vida me presenteou nesse percurso Valquíria e Larissa, pela companhia constante e tão querida, sacrifício ilimitado em todos os sentidos, orações, palavras, abraços e aconchego.

A minha amiga Mirela Gomes, que sempre esteve ao meu lado, pela amizade incondicional e pelo apoio demonstrado durante o período que me dediquei a este trabalho.

A Prof. Dra. Rosineide Paz, por ter sido minha orientadora e por todos os conselhos, pela ajuda e pela paciência com a qual guiaram o meu aprendizado.

Ao Prof. Dr. Rafael que me deu suporte com suas correções e incentivos.

A todos os meus professores do curso de ciência da computação da Universidade Federal do Ceará pela excelência da qualidade técnica de cada um.

## RESUMO

O clínquer é responsável por 90% da composição do cimento Portland, é uma mistura de argila e pedra calcária. Para dar origem ao clínquer, é necessário o aquecimento da mistura para que surjam quatro fases principais: alita, belita, aluminato e ferrita; as quais definem a sua qualidade. Um aspecto importante do clínquer é a sua porosidade, por influenciar a qualidade do produto final. Assim, uma técnica para acompanhar a quantidade de poros em amostras de clínquer é por meio de observação das imagens microscópicas do produto. Com isso, o intuito dessa pesquisa é facilitar o trabalho do profissional de controle de qualidade, contribuindo para a construção de um sistema de visão computacional capaz de realizar análises automáticas das amostras e decida se está ou não em um estado poroso (muitos poros). Para isso, técnicas de processamento e análise de imagens são aplicadas às imagens de amostras de clínquer. As técnicas estudadas e testadas nesse trabalho poderão ser integradas ao sistema em desenvolvimento no projeto "Medusa's Eyes", conduzido por integrantes do Laboratório de Tecnologias Inovadoras, do Campus da Universidade Federal do Ceará, em parceria com a cimenteira Apodi, localizada em Quixeré - Ce, Brasil.

**Palavras-chave:** Análise de Imagem. Clínquer. Porosidade do Clínquer. Automação industrial.

## ABSTRACT

Clinker is responsible for 90% of the composition of Portland cement, it is a mixture of clay and limestone. To originate the clinker, it is necessary to heat the mixture so that four main phases appear: alite, belite, aluminat and ferrite; which define its quality. An important aspect of clinker is its porosity, as it influences the quality of the final product. Thus, a technique to monitor the amount of pores in clinker samples is through the observation of microscopic images of the product. Thus, the purpose of this research is to facilitate the work of the quality control professional, contributing to the construction of a computer vision system capable of performing automatic analysis of the samples and decide whether or not it is in a porous state (many pores). For this, image processing and analysis techniques are applied to the images of clinker samples. The techniques studied and tested in this work may be integrated into the system under development in the "Medusa's Eyes" project, conducted by members of the Innovative Technologies Laboratory, from the Federal University of Ceará Campus, in partnership with the Apodi cement company, located in Quixeré - Ce , Brazil.

**Keywords:** Analyze. Clinker. Porous. Automation.



## LISTA DE FIGURAS

Figura 1 – Poros presentes em amostra de clínquer. . . . .	16
Figura 2 – Diferença na resolução espacial. . . . .	18
Figura 3 – Diferença na resolução de cores. . . . .	18
Figura 4 – Canais RGB. . . . .	20
Figura 5 – Sistema de Cores HSV. . . . .	21
Figura 6 – Conversão para tons de cinza. . . . .	22
Figura 7 – Coordenas do <i>pixel p</i> e seus vizinhos. . . . .	23
Figura 8 – Vizinhança de pixels. . . . .	24
Figura 9 – Inserção de ruídos . . . . .	25
Figura 10 – Suavização de ruídos. . . . .	26
Figura 11 – Detecção de bordas . . . . .	27
Figura 12 – Segmentação com K-means . . . . .	29
Figura 13 – Segmentação com Limiarização . . . . .	31
Figura 14 – Máscara Limiarização. . . . .	37
Figura 15 – Distribuição do Erro - Algoritmo de Limiarização. . . . .	37
Figura 16 – Máscara de Poros. . . . .	38
Figura 17 – Máscara K-means. . . . .	39
Figura 18 – Distribuição do Erro - Algoritmo K-means. . . . .	40
Figura 19 – Máscara gerada manualmente. . . . .	41
Figura 20 – Distribuição do Erro por Imagem. . . . .	42
Figura 21 – Comparação entre máscaras. . . . .	42
Figura 22 – Proporção de Poros. . . . .	43

## LISTA DE TABELAS

Tabela 1 – Comparativo de trabalhos . . . . .	34
---	----

## LISTA DE ALGORITMOS

Algoritmo 1 – Busca Melhor Limiar. . . . .	36
Algoritmo 2 – Busca Melhor Número de <i>Clusters</i> . . . . .	39

## SUMÁRIO

1	<b>INTRODUÇÃO</b>	12
2	<b>OBJETIVOS</b>	14
2.1	Objetivo geral	14
2.2	Objetivo específicos	14
3	<b>FUNDAMENTAÇÃO TEÓRICA</b>	15
3.1	Clínquer	15
3.2	<i>Pixel</i>	17
3.3	Imagem Digital	17
3.4	Sistema de Cores	18
3.5	Conversão de imagens para tons de cinza	21
3.6	Vizinhança de um <i>pixel</i>	22
3.7	Pré-Processamento	24
3.7.1	<i>Eliminação de Ruídos</i>	24
3.7.2	<i>Detecção de Bordas</i>	26
3.8	Segmentação	27
3.8.1	<i>K-means</i>	28
3.8.2	<i>Limiarização</i>	29
4	<b>REVISÃO BIBLIOGRÁFICA</b>	32
4.1	Características mineralógicas e microestruturais do clínquer	32
4.2	Microestrutura do clínquer com microscópio eletrônico	32
4.3	Análise quantitativa do clínquer	33
4.4	Comparativos	33
5	<b>PROCEDIMENTOS METODOLÓGICOS</b>	35
5.1	Estudo do limiar na segmentação de poros	35
5.2	Estudo do número de <i>clusters</i> do algoritmo K-means	38
6	<b>ANÁLISE E INTERPRETAÇÃO DOS RESULTADOS</b>	41
7	<b>CONCLUSÃO</b>	44
	<b>REFERÊNCIAS</b>	45

## 1 INTRODUÇÃO

Portland é a classe de cimento comumente preferida entre os profissionais, pois apresentam resistência, durabilidade e versabilidade, chegando a alcançar até 90% dos cimentos fabricados ao redor do mundo. Esse tipo de cimento é composto principalmente de clínquer, o qual é misturado a gesso e/ou cinzas volantes. O clínquer é produzido pela mistura de matérias-primas de argila e pedra calcária nas quantidades adequadas e calcinado, de modo a obter fases de clínquer estáveis, em sua composição, e pó morfologicamente homogêneo no final do processo. Uma vez que o clínquer tem um papel significativo nas características do cimento e do concreto, é crucial controlar as suas propriedades durante o processo fabricação. Assim, ocorrências das fases que apresenta em sua produção, comportamento de sinterização e aspectos de porosidade são investigados a fim de obter clínquer de alta qualidade com o menor custo, e com isso obter cimento de boa qualidade de modo sustentável do ponto de vista econômico e ambiental (TAO *et al.*, 2018; KAVAS *et al.*, ).

O clínquer apresenta diversas fases. No entanto, para garantir a qualidade apenas quatro delas são cuidadosamente avaliadas: alita, belita, aluminato e ferrita. O silicato de tricálcio ( $C_3S$ ), também conhecido como alita é o componente responsável pela resistência inicial do cimento (primeiros 28 dias), por outro lado têm-se o silicato de dicálcio ( $C_2S$ ), conhecido como Belita, responsável pela resistência final do cimento (após 28 dias). Conhecida como uma fase líquida (fases responsáveis pela aceleração das reações químicas) têm-se o aluminato de tricálcio ( $C_3A$ ) que é a fase mais reativa do clínquer. Esta fase garante a consistência e solidificação (enrijecimento) do cimento Portland. O ferroaluminato de tetracálcio ( $C_4AF$ ), que também é uma fase líquida, tem como principal propriedade a resistência à corrosão química, sendo também responsável pela coloração cinzenta do clínquer. O processo responsável pelo aparecimento das fases de clínquer é conhecido como clinquerização. Para saber mais a respeito da composição e obtenção do clínquer, veja, por exemplo, Tenório *et al.* (2003), Kirchheim *et al.* (2010).

Durante essas fases podem ocorrer o surgimento de poros, que podem ser visualizados microscopicamente. Poros são "buracos", áreas do clínquer que possuem ausência de material. O ideal seria produzir um clínquer com quantidade de poros entre 30% e 40%, abaixo de 30% têm-se um clínquer com baixa porosidade e acima de 40% considera-se alta porosidade. A partir das análises realizadas em laboratório pode-se concluir em qual estado a porosidade do clínquer se encontra.

Para iniciar a análise, amostras de clínquer são coletadas e destas uma porção é

esmagada e peneirada até que se tenha partículas de 2 - 4 mm. Essas partículas são envoltas e embutidas em resina para posterior lixamento e confecção do molde. Finalmente, a amostra é analisada com uso de um microscópio. Ao dar início a análise, a amostra é submetida a imersões em soluções específicas que ressaltam a características de seus componentes. Assim, pode ser possível realizar a aferição do estado dos componentes mineralógicos (BÖHM; LIPUS, 2015)

A fim de realizar a análise, as imagens são capturadas e avaliadas manualmente por um analista que manuseia o microscópio, interpretando os dados conforme seu conhecimento sobre as características ressaltadas nas imagens. Todavia, estas análises podem ser demoradas, provocando, também, uma demora para obtenção dos resultados finais. Assim, a agilidade sobre a conformidade do processo produtivo ficam prejudicados. Além disso, uma vez que nesse cenário a análise é feita com muita subjetividade, a precisão dos resultados também pode ficar prejudicada. Uma solução para esses problemas seria a automação do processo de microscopia do clínquer. No entanto, trabalhos abordando esse tema ainda são escassos na literatura.

Pelo exposto, nesse trabalho, é proposta a investigação de uma solução para automação da verificação da presença de poros em amostras de clínquer via microscopia digital. Para essa investigação, imagens, bem como análises realizadas por analistas da área da química, fornecidas pela companhia de cimento Apodi (APODI, 2018) são analisadas através de algoritmos para tratamento e análise de imagens, usando métodos de segmentação de imagens. Alguns desses métodos já vem sendo estudados por outros integrantes em um projeto de parceria mantido entre a empresa APODI e a Universidade Federal do Ceará.

## **2 OBJETIVOS**

### **2.1 Objetivo geral**

Automatizar a detecção de porosidade em amostras microscópicas de clínquer.

### **2.2 Objetivo específicos**

- Discorrer sobre extração de informações de pixels de imagens de clínquer;
- Discorrer sobre o método tido como mais comum (K-means);
- Discorrer sobre o método de Limiarização;
- Comparar os métodos K-means e Limiarização;
- Comparar os métodos escolhidos e análises feitas manualmente;
- Identificar e caracterizar poros em imagens de clínquer fazendo o uso dos métodos abordados no trabalho.

### 3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo expõe o problema tratado no trabalho. Assim como, conceitos básicos de processamento de imagens, a fim de facilitar a compreensão dos métodos abordados neste trabalho.

#### 3.1 Clínquer

Um composto responsável por 90% da composição do cimento Portland é o clínquer, que vem de uma mistura de argila e pedra calcária. O preparo deste componente é por meio do cozimento da mistura homogênea desses compostos, comumente referida como farinha. A temperatura no processo de cozimento (ou queima da farinha) pode chegar até a 1450 °C (sinterização) e em seguida é realizado o resfriamento para que as reações químicas alcançadas sejam mantidas. Como resultado dessas reações, surgem, principalmente, quatro fases mineralógicas de clínquer (alita, belita, aluminato e ferrita). Essas fases influenciam a qualidade do produto final.

Essas fases têm diferentes estruturas cristalinas, o que significa que diferentes propriedades podem ser encontradas. A alita é a fase que confere a resistência de curto prazo ao cimento. Sua composição  $3\text{CaO} \cdot \text{SiO}_2$  é abreviada por  $\text{C}_3\text{S}$  e deve representar a composição majoritária do clínquer após o seu processamento. Enquanto que a belita proporciona a resistência de longo prazo ao produto final. Tendo composição  $2\text{CaO} \cdot \text{SiO}_2$ , com abreviatura  $\text{C}_2\text{S}$ , a belita é o primeiro complexo de cal e sílica que se forma no aquecimento. Finalmente, o aluminato e a ferrita têm impactos razoáveis na resistência do cimento. O aluminato é encontrado principalmente na forma de  $3\text{CaO} \cdot \text{Al}_2\text{O}_3$ , abreviado por  $\text{C}_3\text{A}$ . Já a ferrita aparece principalmente na forma  $4\text{CaO} \cdot \text{Al}_2\text{O}_3\text{Fe}_2\text{O}_3$ , abreviado por  $\text{C}_4\text{AF}$  (STUTZMAN, 2012; FERRARI *et al.*, 2012).

A fim de verificar se o processo de queima ocorreu como esperado, são realizadas análises laboratoriais a partir de amostras de clínquer cuidadosamente preparadas. A partir dessas análises é possível checar se as fases que aparecem nas amostras estão na medida certa. Pois, caso isso não ocorra, pode-se obter um cimento de má qualidade como produto final.


As análises laboratoriais de clínquer incluem a investigação feita a partir de imagens de clínquer, as quais são obtidas por meio de um microscópio. Esse procedimento é conhecido como microscopia do clínquer.

Um dos problemas que podem afetar a qualidade do clínquer é a formação de poros, que também podem ser visualizados microscopicamente. A Figura 1 mostra poros



em determinada amostra de clínquer, que estão destacados com uma marcação em vermelho. Normalmente esses poros aparecem na imagem na coloração preta. Com isso, o intuito dessa pesquisa é facilitar o trabalho do profissional de controle de qualidade, que atua na análise dessas imagens, possibilitando uma ágil e precisa conclusão se o clínquer está em um estado poroso.

Figura 1 – Poros presentes em amostra de clínquer.



Fonte: Elaborado pela Autora (2021)

Uma quantidade de poros entre 30% e 40% é o ideal, abaixo disso têm-se um clínquer com baixa porosidade e acima de 40% um clínquer com alta porosidade.

A alta porosidade de um clínquer normalmente é decorrente da queima insuficiente (pouco cozimento) e reações incompletas. Esse fator pode ser ocasionado pela falta de alumínio e ferro e pela deficiência na moagem da matéria-prima, caracterizada pela presença de CaO livre. A presença de poros indica a reação de clínquerização deficiente, onde se têm ausência de pontos de contato que irá dificultar as reações.

Um clínquer com baixa porosidade indica que a reação de clínquerização foi longa ou de alta temperatura e moagem elevada afetando a granulometria (parâmetro de qualidade). Esse tipo de clínquer dificultará a moagem, proporcionando um aumento no custo do cimento produzido. Uma referência sobre a presença de poros no clínquer é CARVALHO *et al.* (1997)

Devido a preocupação das empresas cimenteiras com a boa qualidade do cimento produzido, realizou-se uma parceria entre a empresa Apodi e a Universidade Federal do Ceará -

Campus de Russas. Essa parceria motivou esse trabalho, que tem como foco principal analisar as imagens de amostras de clínquer fornecidas pela empresa, a fim de quantificar os poros. Com isso, será possível uma análise mais rápida sobre a quantidade de poros na amostra e, conseqüentemente, ocorrerá uma contribuição para a automação da análise de imagens microscópicas de clínquer.

### **3.2 Pixel**

O termo *pixel* vem do inglês *picture element*, sendo *pix* a abreviação para *pictures*. Um *pixel* é o menor elemento de uma imagem digital, a qual é formada por vários *pixels* que é comumente conhecida como Bitmap (MICROSOFT, 2017). As quantidades de pixel na largura e altura de uma imagem digital definem a sua resolução. Assim, quanto mais *pixels* maior a resolução, tornando a imagem digital mais próxima da imagem real da cena.

As telas dos dispositivos atuais utilizam o sistema Raster (GRHAPHICS, 2021), um método de varredura para que as imagens sejam exibidas, percorrendo todos os *pixels* da imagem para exibir corretamente a cena conforme os dados armazenados em cada *pixel*, permitindo a manipulação por *pixel*. Um *pixel* possui uma posição e uma cor referente ao sistema de cores que é definido pela quantidade de bits da cor a ser representada.

### **3.3 Imagem Digital**

Uma imagem digital é representada por um conjunto de pontos finitos, que são os *pixels*, que se distribuem em duas dimensões formando uma matriz. A quantidade de matrizes dependerá da forma que a imagem será processada (colorida, escala cinza ou binária) (NOGUEIRA, 2016). Os tópicos que tem relação com uma imagem digital, são: captura (entrada), visualização (saída), armazenamento e processamento (SCURI, 2002).

O trabalho proposto por Scuri (2002) define captura como sendo o meio pelo qual a imagem é obtida. Normalmente essa aquisição vem de equipamentos digitalizadores, um exemplo seria uma câmera digital. A visualização seria a forma como essa imagem capturada estaria sendo representada.

Além dessas relações Nogueira (2016) apresenta dois aspectos importantes que definem uma imagem, a resolução e a cor. A resolução de cores da imagem determina a quantidade máxima de cores distintas que tal imagem poderá possuir e a resolução espacial que

define as dimensões de uma matriz para representar a imagem.

Figura 2 – Diferença na resolução espacial.

(a) Original - 750x500 *pixels*.

(b) 200x133 *pixels* (ampliada).



Fonte: Elaborado pela Autora (2021)

A Figura 2a apresenta uma resolução superior a Figura 2b, exemplificando a diferença de resolução espacial de uma imagem. As Figura 3a e 3b apresentam a diferença na resolução de cores de uma imagem, onde a Figura 3a apresenta uma quantidade máxima de cores distintas em relação a Figura 3b.

Figura 3 – Diferença na resolução de cores.

(a) Original - 24 bits de cores.

(b) Paleta reduzida - 2 bits de cores.



Fonte: Elaborado pela Autora (2021)

### 3.4 Sistema de Cores

O sistema de cores, também conhecido como modelo de cores ou espaço de cores, tem como finalidade facilitar a especificação de cores seguindo um padrão. Um modelo de

cores é especificado por um sistema de coordenadas e um subespaço dentro desse sistema, onde cada cor é representada por um único ponto. Os modelos de cores são normalmente orientados em direção ao hardware (dispositivos eletrônicos) ou orientados a aplicações que envolvem manipulação de cores (criação de imagens) (GONZALEZ; WOODS, 2009). Este trabalho irá focar em dois padrões de cores, o sistema de cores RGB e o sistema de cores HSV.

O sistema de cores RGB (do *inglês red, green and blue* - vermelho, verde e azul) foi criado com base na teoria de Percepção de Cores de Young-Helmholtz (NERY, 1894), e dado continuidade por Herman Von Helmholtz. O cientista Herman Von Helmholtz propôs que o olho contém três receptores de cores, que respondem aos comprimentos de ondas das cores vermelho(R), verde(G) e azul(B) (JULIO; BECHEL, 2013).

O padrão RGB combina suas três cores bases para produzir outras cores (sistema aditivo). Esse modelo de cores é o principal modelo utilizado em dispositivos eletrônicos como *smartphones* e monitores (NOGUEIRA, 2016). A demonstração dos componentes espectrais primários de forma separada são mostrados nas Figuras 4b, 4c e 4d e a Figura 4a mostra a composição desses três componentes.

Figura 4 – Canais RGB.

(a) Composição dos três canais.




(b) Extração do canal R (*red*).



(c) Extração do canal G (*green*).




(d) Extração do canal B (*blue*).



Fonte: Elaborado pela Autora (2021)

HSV é um outro modelo de cores, também definido por três componentes: *hue* (matiz), *saturation* (saturação) e *value* (valor). Matiz define o tipo de cor dominante, incluindo todas as cores do espectro (do vermelho ao violeta), tendo como possíveis valores do 0 ao 360. Algumas aplicações normalizam esses valores para de 0% a 100%. Saturação determina o nível de pureza da cor, variando de 0% a 100%. Quanto menos pura é a cor, mais próxima de uma tonalidade de cinza ela se torna. Valor indica o nível de brilho da cor e também é escalado de 0% a 100%. A Figura 5 mostra o sistema de cores HSV em forma de círculo de acordo com a inicial de cada um de seus componentes.

Figura 5 – Sistema de Cores HSV.



Fonte: (WAPCAPLET, 2003)

### 3.5 Conversão de imagens para tons de cinza

A Escala de Cinza de uma imagem é quando o valor de cada *pixel* é convertido do seu sistema de cores em um nível de intensidade de tom de cinza, que varia entre o preto, a menor intensidade, e o branco, a intensidade máxima. Imagens em tons de cinza se caracterizam como uma espécie de monocromático (JOHNSON, 2006).

Para realizar a conversão do sistema RGB para escala de cinza, existem dois métodos mais populares, o da média aritmética e o da média ponderada. No método da média é feito a média dos valores RGB das seguintes formas:

$$\text{Escala de Cinza} = (R + G + B)/3 \text{ ou} \quad (3.1)$$

$$\text{Escala de Cinza} = R/3 + G/3 + B/3. \quad (3.2)$$

O mais viável seria implementar esse método utilizando a Equação 3.2. Pois ao aplicar a Equação 3.1 pode ocorrer um *overflow* (quando não é possível representar um número dentro da memória do equipamento) na representação da cor que é guardada em variáveis de 8 bits, onde se pode armazenar valores até 255. Assim a soma de cada cor ultrapassa esse valor. Para evitar esse resultado cada cor deve ser calculada de forma separada como mostra a Equação 3.2.

Outro método desenvolvido é a média ponderada, que utiliza diferentes porcentagens de cada cor do sistema RGB conseguindo uma conversão viável. Os pesos obtidos nesse método tem relação com a percepção visual humana. Como o ser humano enxerga melhor a cor verde ela tem o maior peso. Neste método, os pesos atribuídos a cada componente de cor normalmente são 30% de Vermelho (*Red*), 59% de Verde (*Green*) e 11% de Azul (*Blue*) e realizado o somatório

com os valores resultantes, como segue:

$$\text{Escala de Cinza} = (0.299 \times R) + (0.587 \times G) + (0.114 \times B). \quad (3.3)$$

Para maior entendimento sobre os métodos de conversão citados veja, por exemplo, Dynamsoft (2019).

Para facilitar o processo de conversão para tons de cinza, podem ser utilizadas funções que já estão implementadas em bibliotecas. Das existentes até o momento, uma que é bastante utilizada é "cvtColor" da OpenCV (OPENCV, 2019), que utiliza o método ponderado.

Figura 6 – Conversão para tons de cinza.

(a) Imagem original.



(b) Imagem convertida para tons de cinza.



Fonte: Elaborado pela Autora (2021)

Na Figura 6b pode ser observada a conversão de uma imagem para tons de cinza utilizando a biblioteca cvtColor.

### 3.6 Vizinhança de um *pixel*

Nogueira (2016) explica que cada *pixel* possui 8 vizinhos, imagine um *pixel*  $p$  com coordenadas  $(x,y)$ , quatro são vizinhos horizontais e verticais e quatro diagonais, cujas coordenadas podem ser observadas na Figura 7.

Figura 7 – Coordenadas do *pixel*  $p$  e seus vizinhos.

$(x-1, y+1)$ $V_7$	$(x, y+1)$ $V_3$	$(x+1, y+1)$ $V_5$
$(x-1, y)$ $V_2$	$(x, y)$ $P$	$(x+1, y)$ $V_1$
$(x-1, y-1)$ $V_8$	$(x, y-1)$ $V_4$	$(x+1, y-1)$ $V_6$

Fonte: Elaborado pela Autora (2021)

Um *pixel* pode ter dois tipos de vizinhança: vizinhança 4, definida pelo *pixel* central  $p$  e seus 4 vizinhos equidistantes ( $v1, v2, v3, v4$ ), ou vizinhança 8, onde os vizinhos da diagonal ( $v5, v6, v7, v8$ ) são mais distantes que os vizinhos que se encontram na horizontal e vertical do *pixel*  $p$ . Normalmente essa abordagem é utilizada em combinação, por exemplo, a vizinhança 4 para representar objetos e a vizinhança 8 para o fundo (SCURI, 2002).

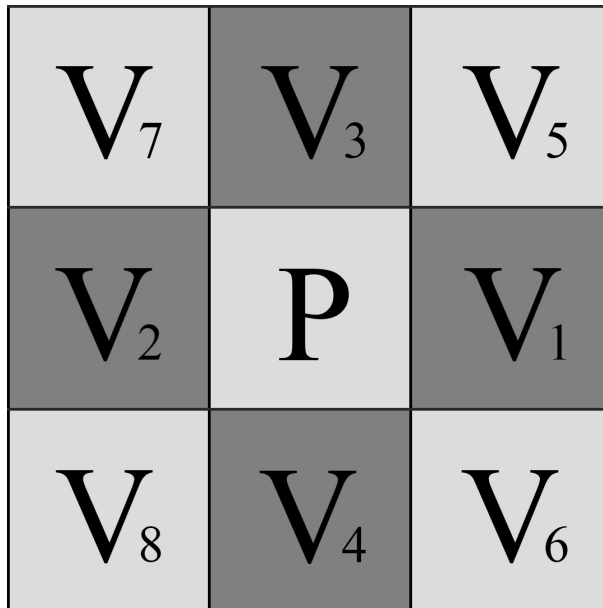
A abordagem dos dois tipos de vizinhança apresentada acima é válida para imagens com grade de *pixels* regulares. As grades hexagonais possuem abordagem semelhante, mas não terá importância no foco deste trabalho.

As Figuras 8a e 8b mostram os dois tipos de vizinhança. A vizinhança 4, onde os vizinhos equidistante de  $p$  são representados pela cor cinza mais escuro, e vizinhança 8, onde pode ser vista a diferença de distância entre os *pixels* das diagonais e laterais em relação a  $p$ .

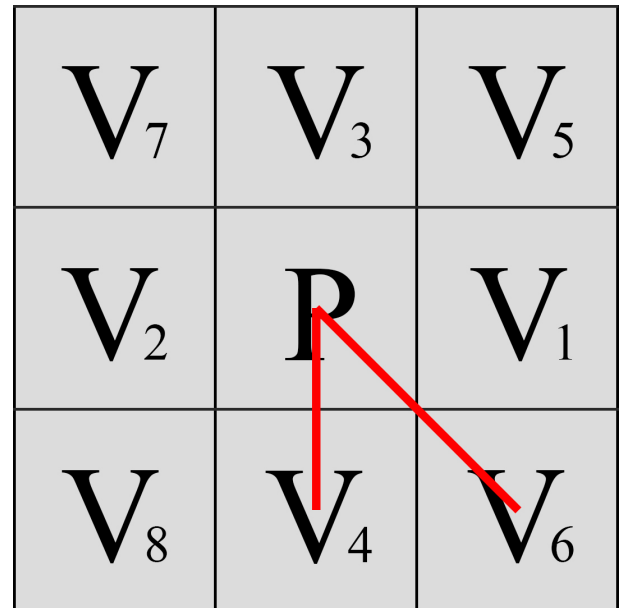


Figura 8 – Vizinhança de pixels.

(a) Vizinhança 4.



(b) Vizinhança 8.



Fonte: Elaborado pela Autora (2021)

### 3.7 Pré-Processamento

Nessa seção serão abordados alguns métodos de pré-processamento que poderão ser utilizados no presente trabalho. O pré-processamento é um procedimento muito importante, é nele que são utilizados filtros. Esta é uma etapa que precede a segmentação em análise de imagens.

#### 3.7.1 Eliminação de Ruídos

Ruídos são alterações na intensidade e cor de um *pixel*, com relação ao que está sendo capturado ou transmitido. Essas deformidades podem ser decorrentes de fatores externos, como falhas na transmissão ou leitura. O ruído de saturação (também conhecido como ruído de sal e pimenta) ocorre quando os valores dos *pixels* atingidos são alterados para seu valor mínimo e máximo (FENSTERSEIFER, 2014).

Um outro ruído, também muito frequente, é o denominado gaussiano. Geralmente esse ruído é decorrente de má iluminação, altas temperaturas ou problemas de transmissão. A Figura 9b exemplifica os dois tipos de ruídos (sal e pimenta e gaussiano) presentes em uma imagem e as Figuras 9c e 9d exemplificam os ruídos sal e pimenta e gaussiano, respectivamente. Uma forma de reduzir os ruídos é utilizar filtros que os suavizam diretamente na imagem


(MAZZA, 2017). Um exemplo de filtro implementado em *software* é o "GaussianBlur" da biblioteca OpenCV do *software* python (FOUNDATION, 2021) .

Figura 9 – Inserção de ruídos

(a) Imagem original



(b) Imagem com inserção dos ruídos



(c) Imagem com inserção do ruído sal e pimenta



(d) Imagem com inserção do ruído gaussiano



Fonte: Elaborado pela Autora (2021)

Os filtros de médias e medianas são os mais utilizados atualmente. Pois apresentam resultados satisfatórios, não necessitam de muito poder computacional nem muito armazenamento. Esses tipos de filtros calculam a média ou mediana da vizinhança de determinado *pixel* e determinam seu valor. Alguns métodos utilizam também uma análise de contexto maior, a partir de um levantamento estatístico da imagem para utilizar o cálculo local (FENSTERSEIFER, 2014).

Um exemplo de método desse tipo é o filtro bilateral, um filtro de suavização não linear, que preserva as bordas e reduz os ruídos. Este método pode ser adotado para várias aplicações, como remoção de textura, compressão de faixa e aprimoramento de fotografia. É um filtro não iterativo, o que acaba possibilitando o alcance de um resultado satisfatório em uma única passagem do método. Sua avaliação computacional é considerada cara, por ser um filtro

não linear (PARIS; DURAND, 2006).

Figura 10 – Suavização de ruídos.

(a) Imagem com ruído.



(b) Imagem com suavização dos ruídos.



Fonte: Elaborado pela Autora (2021).

Na Figura 10b, pode-se observar a suavização de ruídos da Figura 10a, utilizando a função "bilateralFilter" da OpenCV.

### 3.7.2 Detecção de Bordas

Os algoritmos de detecção de borda analisam três tipos de características em uma imagem: os pontos isolados, as linhas e as bordas. Pode-se considerar uma linha como segmento de borda, onde a intensidade do fundo de cada linha ou é muito superior ou muito inferior à intensidade dos *pixels* da linha (GONZALEZ; WOODS, 2009).

Um método clássico para detecção de bordas é o filtro Sobel, no qual é calculado o gradiente da imagem para diferenciação e direção da variação de claro para escuro. Assim, tem-se uma noção da variância de luminosidade em cada ponto. Desta forma, é estimada a transição de claro para escuro e sua orientação, podendo assim definir as fronteiras do objeto trabalhado na cena.

Nesse método, são utilizadas duas matrizes  $3 \times 3$  que são convoluídas com a imagem original, para calcular as aproximações das derivadas para as variações horizontais e verticais, tendo, assim, um método direcional. Finalmente, deve-se combinar o filtro horizontal e o vertical para obter a detecção de bordas por completo.


As Figuras 11c e 11d mostram um exemplo de o realce nas bordas verticais e horizontais, respectivamente. Na Figura 11b pode-se notar a combinação dos dois realces, obtendo assim o filtro de Sobel completo.

Figura 11 – Detecção de bordas


(a) Imagem original



(b) Filtro de Sobel combinado



(c) Realce vertical



(d) Realce horizontal



Fonte: Elaborado pela Autora (2021)

### 3.8 Segmentação

Agrupamento ou segmentação é uma técnica que agrupa *pixels* com intensidades semelhantes em um mesmo conjunto, onde cada conjunto define uma característica da imagem (CARVALHO, 2020).

Neste trabalho serão abordados dois métodos de agrupamento, para que sejam realizadas comparações em relação a esforço computacional e melhor estimativa das características estudadas. Assim, foram escolhidos métodos bastante conhecidos e utilizados na prática, sendo eles o K-means e Limiarização.

### 3.8.1 K-means

O algoritmo K-means foi introduzido primeiramente por MacQueen (1967), embora a ideia precedente foi advinda de Steinhaus (1957). O K-means tem sido utilizado na área de aprendizado de máquina, mais especificamente em aprendizado não supervisionado. A ideia global é agrupar dados em conjuntos disjuntos, de forma que a união de todos os subconjuntos obtidos é igual ao conjunto inicial (obter uma partição). Assim, o objetivo final é predizer a qual grupo cada ponto de dados pertence.

Na implementação do K-means, o usuário define  $K$ , o número de *clusters* que deseja particionar o conjunto de objeto de dados. Em seguida obtém uma partição inicial, em que cada *cluster* é representado por seu centróide, que geralmente é a média dos pontos atribuídos ao mesmo. Então, cada elemento a ser agrupado é atribuído a um *cluster*, cujo centróide é aquele mais próximo. Assim, cada conjunto de pontos atribuídos a um centróide forma um novo *cluster*. Finalmente, o centróide de cada *cluster* é atualizado de acordo com os pontos que lhes foram atribuídos. Os *clusters* são atualizados até que nenhum ponto mude de *cluster*.

Para uma melhor descrição do método K-means em sua forma clássica, suponha  $D = \{x_1 \dots x_n\}$ , um conjunto de ponto (ou objeto) de dados que devem ser agrupados. Cada ponto será atribuído ao *cluster* cujo centróide é o mais próximo, seguindo a equação:

$$\min_{\{m_k\}, 1 \leq k \leq K} \sum_{k=1}^K \sum_{\mathbf{x} \in C_k} \pi_{\mathbf{x}} \text{dist}(\mathbf{x}, \mathbf{m}_k), \quad (3.4)$$

em que  $\pi_{\mathbf{x}}$  é o peso atribuídos a  $\mathbf{x}$ ,  $C_k$  o  $k$ -ésimo *cluster*,  $\mathbf{m}_k = \sum_{\mathbf{x} \in C_k} \frac{\pi_{\mathbf{x}} \mathbf{x}}{n_k}$  é o centróide do *cluster*  $C_k$ , com  $n_k$  sendo o número de objetos de dados atribuídos a  $C_k$ ,  $K$  é o número de *clusters* definido pelo usuário e  $\text{dist}$  é uma função que calcula a distância entre o ponto  $\mathbf{x}$  e o centróide  $\mathbf{m}_k$ . Maiores detalhes sobre o método de agrupamento K-means veja, por exemplo, (WU, 2012).

Existem diferentes formas de implementação desse método para encontrar o centróide e muitos pesquisadores estão buscando desenvolver novos métodos. Um exemplo seria o trabalho de Purohit e Joshi (2013), onde o mesmo consegue reduzir o erro quadrático médio do cluster final sem sacrificar o tempo de execução. Esse método é mais indicado para conjunto de dados denso do que para um conjunto esparso.

Nazeer e Sebastian (2009) apresentaram um algoritmo aprimorado para melhorar a precisão e eficiência dos agrupamentos do método K-means. Essa abordagem conseguiu reduzir o tempo de execução sem sacrificar a precisão dos clusters.

As Figuras 12b, 12c e 12d mostram três exemplos da aplicação do método K-means alterando somente o parâmetro  $k$ .

Figura 12 – Segmentação com K-means

(a) Imagem original



(b)  $k = 2$



(c)  $k = 4$



(d)  $k = 8$



Fonte: Elaborado pela Autora (2022)

### 3.8.2 Limiarização

Shapiro e Stockman (2000) descreve limiarização como o método mais simples de segmentação de imagens e que também pode ser usado no processo de binarização. Esse método consiste na escolha de um ponto, conhecido como limiar. A partir desse ponto é gerada uma nova imagem de acordo com alguns comparativos realizados em uma imagem que será dada como parâmetro de entrada.

A escolha deste limiar pode assumir um critério subjetivo humano ou algum método que faça tal escolha automaticamente, esses métodos podem ser baseados em critérios entrópicos ou estatísticos da imagem e também aqueles que utilizam mecanismos de buscas mais robustos

(LOPES, 2003).

No processo de limiarização, o limiar é utilizado para fornecer uma nova imagem, onde cada *pixel* da imagem original é comparado com esse limiar e após comparar todos os *pixels* da imagem será fornecida uma nova imagem formadas por valores pretos e brancos, alguns algoritmos permitem que sejam escolhidos outros valores. Para melhor entendimento, considere  $P_n$  os *pixels* de uma imagem, onde  $n$  seria o número de *pixels* que formam essa imagem e  $T$  o limiar escolhido. Suponha que a imagem de entrada esteja em escala de cinza e queremos destacar somente os *pixels* com coloração superior a 50. Logo temos que se  $T \leq P_i$  o *pixel*  $i$  irá receber valores brancos na nova imagem, caso contrário recebe valores pretos, ou vice versa. Esse comparativo pode ser visto no artigo de Moura (2018).

A biblioteca OpenCV possui a função "threshold" que pode ser utilizada para aplicar o método de limiarização em uma imagem. Essa função tem como entrada quatro parâmetros. O primeiro é a imagem que será aplicada a limiarização, o segundo é o limiar, o terceiro é o novo valor de pixel que o pixel irá receber caso o limiar seja atingido e o último parâmetro é o tipo de limiarização que será utilizado. Essa função será utilizada no algoritmo de limiarização proposto.

Nas Figuras 13b, 13c e 13d podem ser observados exemplos do método de limiarização, cada figura apresenta um limiar diferente.

Figura 13 – Segmentação com Limiarização  
(a) Imagem original



(b) *Limiar* = 40



(c) *Limiar* = 80



(d) *Limiar* = 120



Fonte: Elaborado pela Autora (2022)



## **4 REVISÃO BIBLIOGRÁFICA**

Aqui, serão descritos os trabalhos relacionados. Adicionalmente, são realizadas comparações entre alguns trabalhos já existentes na literatura e que possuem tema parecido com o presente trabalho.

### **4.1 Características mineralógicas e microestruturais do clínquer**

O projeto desenvolvido por Souza *et al.* (2002b) estuda o alto custo da fabricação de cimento, devido as características mineralógicas e microestruturais do clínquer. No trabalho é utilizado um microscópio óptico e uma lupa pra analisar amostras de clínquer de uma fábrica localizada no sul do Brasil. Após essas análises, notou-se que existe um grande volume de poros nas amostras, ocorrido por uma distribuição irregular da fase líquida. Amostras de clínquer como as analisadas apresentam uma grande facilidade no processo de moagem.

Na análise realizada com microscópio óptico pode-se notar corrosões nos cristais de silicato de bicálcio, instabilidades de tricálcio, que se decomporia em cal livre e silicato bicálcio. Enquanto a análise com a lupa manifestou o mesmo padrão estrutural, porém em maior escala. Também, nota-se que as reações entre os minerais de cimento, e os minerais usados no agregado, poderiam causar fissuramentos em estruturas.

### **4.2 Microestrutura do clínquer com microscópio eletrônico**

O trabalho proposto por Souza *et al.* (2002a) é uma continuação do estudo visto em Souza *et al.* (2002b). As análises são realizadas utilizando um microscópio eletrônico de varredura (MEV), este mostrou a existência de microfissuras e de corrosão dos cristais de alita e belita.

O MEV foi importante para analisar o grau de corrosão dos cristais presentes, tal informação não seria possível com um microscópio óptico. Entre os resultados obtidos, destacam-se as análises quantitativas e qualitativas, as quais revelam a relação da microestrutura do clínquer com a porosidade.

### 4.3 Análise quantitativa do clínquer

Stutzman *et al.* (2016) apresenta em seu trabalho *Quantitative Imaging of Clinker and Cement Microstructure* (Imagem Quantitativa de Clínquer e Microestrutura de Cimento), a utilização de um microscópio eletrônico de varredura (MEV) a fim de analisar a estrutura do clínquer e do cimento. O MEV produz imagens com alta resolução, os constituintes minerais são extraídos digitalmente da microestrutura. Para isso, é usado o processamento e análise das imagens. Este trabalho coleta e processa os dados extraídos das imagens e tem a finalidade de fornecer estimativas quantitativas da macroestrutura do clínquer e cimento.

### 4.4 Comparativos

A Tabela 1 apresenta comparações realizadas entre os trabalhos citados e o presente trabalho, levando em consideração o foco da pesquisa de cada trabalho.

De acordo com a Tabela 1, nota-se que os trabalhos vistos na literatura tem como foco maior estudar a microscopia do clínquer. Na presente pesquisa o foco é automatizar a detecção de poros e para isso é necessário analisar a microestrutura do clínquer. Além da detecção, será realizada análises quantitativas de poros, permitindo que essas medidas sejam obtidas de forma automática.

Tabela 1 – Comparativo de trabalhos

	A presente pesquisa	(SOUZA <i>et al.</i> , 2002b)	(SOUZA <i>et al.</i> , 2002a)	(STUTZMAN <i>et al.</i> , 2016)
Microscópio óptico digital	✓	✓	✗	✗
Microestrutura do clínquer	✓	✓	✓	✓
Análise dos poros	✓	✓	✗	✗
Impacto dos poros no processo de produção do cimento	✓	✗	✗	✗
Análises qualitativas nos poros	✓	✓	✓	✗
Análises quantitativas nos poros	✓	✗	✗	✓
Automação detecção de poros	✓	✗	✗	✗

Fonte: Elaborado pela Autora (2021)

## **5 PROCEDIMENTOS METODOLÓGICOS**

Este capítulo será dividido em duas seções, a primeira seção descreve a análise da técnica de limiarização aplicada na segmentação dos poros em uma imagem microscópica de clínquer; a segunda seção descreve a análise da técnica k-means aplicada ao mesmo problema.

Os parâmetros de ambas as técnicas estudadas foram determinados através de testes de estresse. As imagens segmentadas obtidas pelas técnicas foram comparadas com uma máscara gerada manualmente e por fim foram utilizados os parâmetros do teste que teve melhor resultado, ou seja, da máscara gerada pelo algoritmo mais parecida com a máscara manual.

### **5.1 Estudo do limiar na segmentação de poros**

A análise com limiarização consiste em gerar uma nova imagem em escala cinza a partir da imagem coletada. Em seguida, é passado um filtro para eliminar os ruídos e por último aplicar o método de limiarização, sendo assim gerada a máscara de poros.

Para realizar a limiarização é necessário encontrar um limiar que será utilizado como parâmetro, com isso foi necessário descobrir qual o melhor limiar que destacasse os poros da imagem. Esse limiar foi encontrado a partir de vários testes em uma determinada imagem, onde era alterado somente o valor do limiar. Após realizar vários testes foi feito um comparativo das máscaras geradas pelo algoritmo com a máscara gerada manualmente a partir da imagem.

---

**Algoritmo 1:** Busca Melhor Limiar.
 

---

**Input:** *img, mascarManual*
**Output:** Melhor Limiar.

```

1 begin
2   imgEscalaCinza = escala_cinza(img);
3   imgPreProcessada = filtro_bilateral(imgEscalaCinza);
4   mascaraLimiarizacao = [];
5   for i = 0:255 do
6     |   mascaraLimiarizacao = insere(limiarizacao(imgPreProcessada, i));
7   end
8   arrayDiferencas = [];
9   for i = 0:255 do
10    |   arrayDiferencas = insere(diferencaAbsoluta(mascaraLimiarizacao[i,
11    |   mascarManual)) ;
12   end
13   return posicao(minimo(arrayDiferencas));
14 end

```

---


Pode-se observar na linha 2 do algoritmo 1 que a imagem original foi convertida para uma imagem em escala de cinza, onde se utilizou a função "cvtColor". Na linha seguinte, os ruídos são reduzidos utilizando a função "medianBlur". As máscaras do teste de limiarização são geradas no *loop* utilizando a função "threshold". Por fim, foi computada a diferença absoluta das 256 máscaras com a máscara manual da imagem de entrada, para realizar esse cálculo foi utilizada a função "absdiff" da OpenCV. Com isso a menor diferença foi selecionada e o limiar que a correspondia foi retornado.

O melhor limiar encontrado foi utilizado na análise feita com limiarização. O limiar escolhido foi  $T = 45$ , ou seja, a coloração dos *pixels* destacados seria superior a 45. Na Figura 14b pode se observar a máscara de poros que foi gerada pelo algoritmo de limiarização.


O erro é a diferença absoluta da máscara gerada pelo algoritmo de limiarização entre a máscara manual. Com base nessa informação, foi realizado um estudo para observar como a variação desse limiar se comporta em relação ao erro. Foram selecionadas 3 imagens de uma mesma amostra e geradas 256 máscaras para cada imagem. Toda máscara possui um limiar diferente que vai de 0 a 255. A Figura 15 representa o gráfico para valores de erros encontrados.

Figura 14 – Máscara Limiarização.

(a) Imagem original.

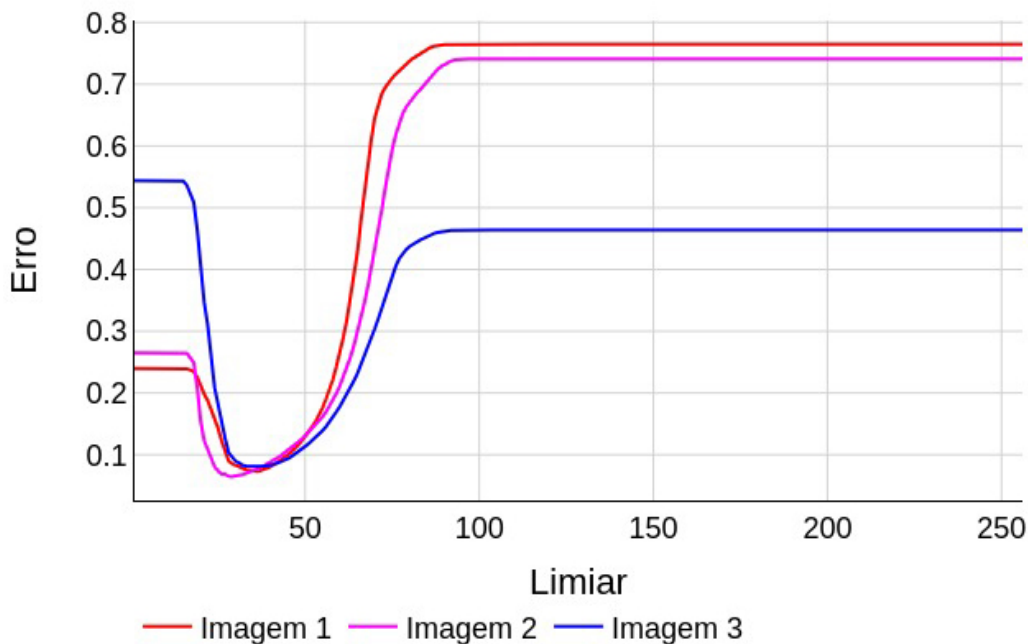


(b) Máscara gerada por limiarização.



Fonte: Elaborado pela Autora (2022).

Figura 15 – Distribuição do Erro - Algoritmo de Limiarização.



Fonte: Elaborado pela Autora (2022)

De acordo com o gráfico acima, pode se observar que o menor erro está concentrado entre o valor 25 e 45. O algoritmo utilizado para realizar o teste de melhor limiar testa todas as possibilidades de entrada, ou seja, todos os valores possíveis (0 à 255), dessa forma o tempo de execução do algoritmo não é satisfatório. Mesmo o algoritmo não sendo otimizado ele foi utilizado para apresentar a distribuição do erro de todas as possibilidades. Na realização de outros teste poderia ser utilizado outros algoritmos mais otimizados um exemplo seria o algoritmo de

busca binária.


## 5.2 Estudo do número de *clusters* do algoritmo K-means

Antes da aplicação do método de segmentação K-means, foi realizado um pré-processamento nas imagens escolhidas. Após a segmentação de imagens foi necessário desenvolver uma função para gerar a máscara de poros da imagem.


O algoritmo utilizado para gerar a máscara percorre toda a imagem, faz um teste pela cor e seleciona a cor escolhida com base na imagem gerada pelo K-means. A cor escolhida é a que representa os poros, sendo ela a mais escura. A função criada seleciona a camada de cores que representa os poros e gera uma nova imagem sendo ela preta e branca, onde os poros seriam os *pixels* pretos da imagem. A Figura 16b mostra a máscara da imagem de uma segmentação feita no K-means.

Figura 16 – Máscara de Poros.

(a) Imagem com K-means.



(b) Máscara gerada.




Fonte: Elaborado pela Autora (2022).


O número de *clusters* foi escolhido através testes de estresse, onde o melhor resultado foi obtido com  $k = 3$ . O teste consiste em escolher uma imagem e gerar sua máscara manual, em seguida o algoritmo é executado várias vezes alterando somente o número  $k$ . Ao final dos testes foram comparados os resultados com a máscara manual. O  $k < 3$  destaca outros elementos que não são poros e para  $k > 3$  ocorre uma perda nos poros que devem ser selecionados. Um exemplo da aplicação desse método, pode ser observada a Figura 17b que mostra a máscara de poros gerada a partir da Figura 17a.

Figura 17 – Máscara K-means.

(a) Imagem original.



(b) Máscara gerada pelo k-means.



Fonte: Elaborado pela Autora (2022).

Segue abaixo um pseudocódigo de como foi implementado os testes para escolha do parâmetro  $k$ .

---

**Algoritmo 2:** Busca Melhor Número de *Clusters*


---

**Input:** *img*, *mascaraManual***Output:** Melhor  $k$ .

```

1 begin
2   imgPreProcessada = filtro_bilateral(img);
3   mascaraKmeans = [];
4   for  $i = 1:8$  do
5     imgSegmentada = k_means(imgPreProcessada,  $i$ );
6     mascaraKmeans = insere(gerarMascara(imgSegmentada));
7   end
8   arrayDiferencas = [];
9   for  $i = 1:8$  do
10    arrayDiferencas = insere(diferencaAbsoluta(mascaraKmeans[ $i$ ],
11      mascarManual));
12  end
13  return minimo(posicao(arrayDiferencas));
14 end

```

---

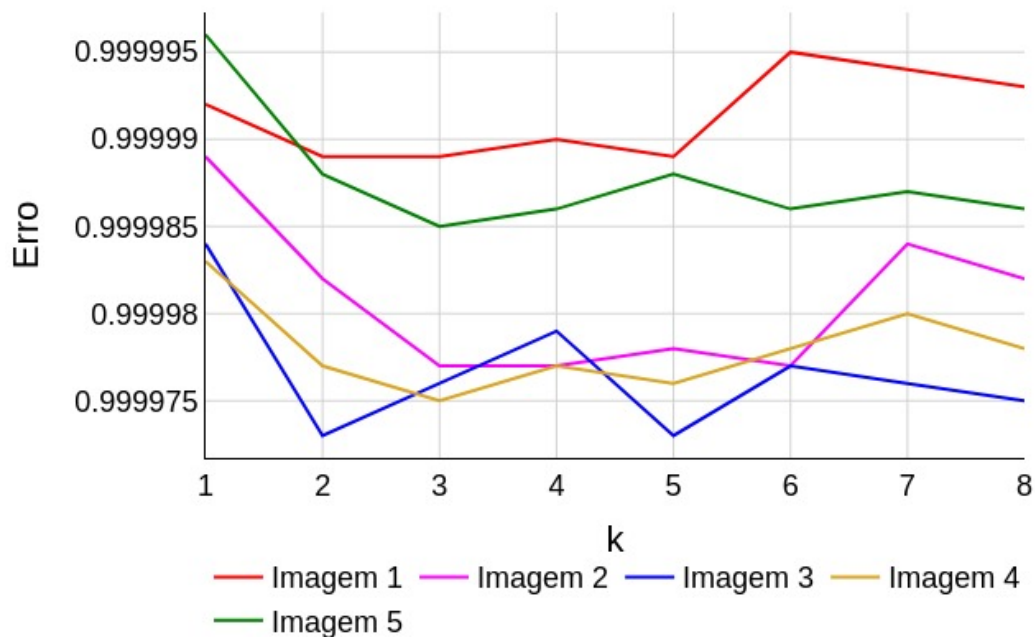
No algoritmo 2 são utilizadas quatro funções, a primeira delas é uma função para pré-processamento das imagens, a função "bilateralFilter". A função "kmeans" foi utilizada para segmentação de imagens. Foi desenvolvida uma função para que, a partir do K-means,



seja gerada uma máscara onde os poros estariam destacados. Por último, a função que calcula a diferença absoluta da máscara gerada pelo K-means com a máscara manual, a partir dessa diferença é escolhido o melhor  $K$ . Para calcular a diferença absoluta foi utilizada a função "absdiff" da OpenCV.

Mesmo com a escolha do  $k$ , foi realizado um estudo comparativo em outras 5 imagens, também da mesma amostra, para observar a diferença absoluta entre a máscara manual e a máscara gerada pelo algoritmo K-means, essa diferença é denominada erro. Com as 5 imagens escolhidas, foram geradas 8 máscaras para cada imagem, alterando somente o valor de  $k$ . Na Figura 18 pode ser observado o erro em relação ao número de  $clusters(k)$ .

Figura 18 – Distribuição do Erro - Algoritmo K-means.



Fonte: Elaborado pela Autora (2022)

Pode-se observar que no método de limiarização a relação entre erro de aproximação e o limiar é mais precisa do que a relação entre erro de aproximação e a quantidade de  $clusters$  do método K-means. É mais difícil de prever os resultados obtidos da segmentação através do método K-means. Porém das 5 imagens utilizadas no Gráfico 18, 3 tem como melhor resultado  $k = 3$ .


## 6 ANÁLISE E INTERPRETAÇÃO DOS RESULTADOS

O trabalho proposto apresenta a utilização de dois métodos aplicados na detecção de poros em amostras de clínquer. Foram realizados testes comparativos entre os resultados obtidos em tais métodos e a análise realizada manualmente, a fim de obter a escolha de um método mais eficiente.

Das imagens que foram cedidas pela empresa Apodi, 8 foram selecionadas para os testes realizados nesta seção, onde as imagens 1, 2, 3 e 4 são de uma amostra, e 5, 6, 7 e 8 são de outra amostra. Essas imagens foram analisadas manualmente e gerada máscaras respectiva a cada imagem, veja um exemplo da máscara gerada na Figura 19b.

Figura 19 – Máscara gerada manualmente.

(a) Imagem original.



(b) Máscara gerada manualmente.




Fonte: Elaborado pela Autora (2022).

Com a análise manual pronta, seria necessários as máscaras que foram geradas pelos métodos escolhidos e a partir disso foi realizado um comparativo entre as máscaras de um método e as máscaras da análise manual.

Os algoritmos se mostram eficazes na seleção de poros muito pequenos, que podem passar despercebidos na análise manual. Com isso a análise realizada pelo k-means possui 88,35% a 91,38% de semelhança aos poros selecionados na máscara manualmente, já o método de limiarização 88,92% a 92,58%.

De uma forma mais geral vamos observar o erro presente em cada imagem e cada algoritmo, ou seja, o grau de diferença absoluta entre as máscaras geradas pelos algoritmos e as máscaras manuais. A Figura 20 apresenta o erro presente nas 8 imagens escolhidas para análise.

Figura 20 – Distribuição do Erro por Imagem.




Fonte: Elaborado pela Autora (2022)

Nas Figuras 21b, 21c e 21d podem ser observadas as máscaras que foram geradas manualmente, pelo algoritmo do k-means e pelo algoritmo de limiarização, respectivamente.

Figura 21 – Comparação entre máscaras.


(a) Imagem original.




(b) Máscara gerada manualmente.



(c) Máscara gerada pelo K-means.



(d) Máscara gerada por limiarização.




Fonte: Elaborado pela Autora (2022).

Um dos problemas que pode se notar em ambos os algoritmos, ocorre quando alguns poros apresentam pequenos "buracos" no seu interior. Esse problema pode ocorrer por conta de uma pequena sujeira que ocupa o poro na hora da coleta. Uma forma de resolução seria propor algoritmos onde reconheça essas bordas internas de "buracos" e desconsidere os mesmos.

Foi realizada uma análise para se observar a proporção de poros em cada máscara gerada tanto do algoritmo de limiarização como o de K-means e também nas máscaras manuais. A computação realizada nessa análise foi feita calculando a quantidade de *pixels* de poros que uma determinada imagem possui. Matematicamente é  $\frac{Q_P}{Q_I}$ , em que  $Q_P$  é a quantidade de *pixels* de poros na imagem e  $Q_I$  a quantidade de *pixels* no total. Essa quantificação de poros pode ser observada na Figura 22.

Figura 22 – Proporção de Poros.



Fonte: Elaborado pela Autora (2022)

Analisando os gráficos das Figuras 20 e 22, pode-se notar que o algoritmo que apresenta melhor estabilidade é o algoritmo de limiarização, que apresenta um padrão nos resultados obtidos nos testes de erro e nos testes de proporção de poros.

## 7 CONCLUSÃO

Neste trabalho, foram estudados dois algoritmos que tem como finalidade propor uma solução automática para analisar a porosidade do clínquer, tendo como foco quantificar os poros em uma amostra de clínquer. Podendo assim definir se uma amostra de clínquer apresenta porosidade ideal, baixa ou alta.

Para cada algoritmo proposto foram realizados testes para definir uma solução mais viável. O algoritmo de limiarização apresenta uma taxa de erro menor do que o algoritmo de K-means, que apresenta uma inconstância em relação ao  $k$ , quando testado em outras imagens. O que pode afetar a quantificação de poros presentes em uma imagem. Essa inconstância pode ser vista na Figura 22, onde o algoritmo do K-means não segue um padrão, diferente do algoritmo de limiarização que segue a proporção de poros da análise manual.

Com os testes apresentados no Capítulo 6 podemos concluir que o algoritmo de limiarização possui melhor resolução e consistência para o problema exposto. Esse algoritmo apresenta um grau de erro menor comparado com o outro algoritmo proposto e também uma semelhança na proporção de poros das máscaras geradas com as máscaras da análise manual.

Como melhorias ou possíveis trabalhos futuros, pode-se apresentar uma solução que identifique as bordas dos poros e não permita a presença de "buracos" nas máscaras que fossem geradas. Realizar teste com um maior conjunto de imagens e verificar o comportamento do limiar e da variável  $k$ . Construir uma rede neural para observar o comportamento das variáveis presentes no algoritmo, podendo se obter um melhor resultado. Utilizar o algoritmo de limiarização com imagens em formato RGB ou HSV, para tentar obter um melhor resultado na quantificação de poros.

## REFERÊNCIAS

- APODI, C. **Cimento Apodi**. 2018. [Online; acessado em 28/03/2021]. Disponível em: <<https://www.cimentoapodi.com.br>>.
- BÖHM, M.; LIPUS, K. Evaluation of portland cement clinker with optical microscopy—case studies iii. **Euroseminar on Microscopy Applied to Building Materials**, v. 15, p. 33–37, 2015.
- CARVALHO, T. B. A. de. Agrupamento de pixels para o reconhecimento de faces. **arXiv preprint arXiv:2006.05652**, 2020.
- CARVALHO, V. O. d.; SILVA, R. d.; MENON, G. J. Aplicação das técnicas de otimização no co-processamento de resíduos em fornos rotativos de fabricas de cimento. **Anais do ENEGEP Encontro Nacional de Engenharia de Produção (em CD-ROM), Gramado-RS**, 1997.
- DYNAMSOFT. **Image Processing 101 Chapter 1.3: Color Space Conversion**. 2019. [Online; acessado em 09/07/2021]. Disponível em: <<https://www.dynamsoft.com/blog/insights/image-processing/image-processing-101-color-space-conversion>>.
- FENSTERSEIFER, R. Aplicação de algoritmos genéticos na redução de ruído em imagens. In: . [S.l.: s.n.], 2014.
- FERRARI, L.; KAUFMANN, J.; WINNEFELD, F.; PLANK, J. Reaction of clinker surfaces investigated with atomic force microscopy. **Construction and Building Materials**, Elsevier, v. 35, p. 92–96, 2012.
- FOUNDATION, P. S. **Pythons**. 2021. [Online; acessado em 06/07/2021]. Disponível em: <<https://www.python.org/>>.
- GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens** . [S.l.]: Pearson Educación, 2009.
- GRHAPHICS, G. **Raster vs Vector**. 2021. [Online; acessado em 08/07/2021]. Disponível em: <[https://vector-conversions.com/vectorizing/raster\\_vs\\_vector.html](https://vector-conversions.com/vectorizing/raster_vs_vector.html)>.
- JOHNSON, S. **Stephen Johnson on Digital Photography**. O'Reilly Media, Incorporated, 2006. (O'Reilly Series). ISBN 9780596523701. Disponível em: <<https://books.google.com.br/books?id=0UVRXzF91gcC>>.
- JULIO, C.; BECHEL, G. O. Identificação de cores predominantes em fotos de câmeras de smartphones através de chamadas assíncronas. **Ponta Grossa**, 2013.
- KAVAS, T.; KURTULUŞ, R.; ER, M. Assessment of mechanical properties in portland cement by optical microscopy and numerical color analysis.
- KIRCHHEIM, A. P.; SOUZA, R. B. d.; MOLIN, D. C. C. D.; MONTEIRO, P. J. M. Álcalis incorporados ao aluminato tricálcico: efeitos na hidratação. **Ambiente construído**, SciELO Brasil, v. 10, n. 1, p. 177–189, 2010.
- LOPES, F. M. Um modelo perceptivo de limiarização de imagens digitais. **Universidade Federal do Paraná**, 2003.

- MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: . [S.l.: s.n.], 1967.
- MAZZA, L. O. Aplicacao de redes neurais convolucionais densamente conectadas no processamento digital de imagens para remocao de ruído gaussiano. **TCC (Graduação)-Curso de Engenharia Controle e Automação, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2017.**
- MICROSOFT. **Types of Bitmaps**. 2017. [Online; acessado em 08/07/2021]. Disponível em: <<https://docs.microsoft.com/en-us/dotnet/desktop/winforms/advanced/types-of-bitmaps?view=netframeworkdesktop-4.8>>.
- MOURA, J. C. da C. Técnicas de limiarização em imagens de retinografia. 2018.
- NAZEER, K. A.; SEBASTIAN, M. Improving the accuracy and efficiency of the k-means clustering algorithm. In: CITESEER. **Proceedings of the world congress on engineering**. [S.l.], 2009. v. 1, p. 1–3.
- NERY, M. P. Dissertação sobre a theoria da visão das cores e as leis do colorido. Brasil, 1894.
- NOGUEIRA, R. C. A. Análise de conversão de imagem colorida para tons de cinza via contraste percebido. **UNIVERSIDADE FEDERAL DE PERNAMBUCO - CENTRO DE INFORMÁTICA, 2016.**
- OPENCV. **Miscellaneous Image Transformations**. 2019. [Online; acessado em 10/07/2021]. Disponível em: <[https://docs.opencv.org/2.4/modules/imgproc/doc/miscellaneous\\_transformations.html#cvtcolor](https://docs.opencv.org/2.4/modules/imgproc/doc/miscellaneous_transformations.html#cvtcolor)>.
- PARIS, S.; DURAND, F. A fast approximation of the bilateral filter using a signal processing approach. In: SPRINGER. **European conference on computer vision**. [S.l.], 2006. p. 568–580.
- PUROHIT, P.; JOSHI, R. A new efficient approach towards k-means clustering algorithm. **International Journal of Computer Applications**, Foundation of Computer Science, 244 5 th Avenue,# 1526, New York, NY 10001 . . . , v. 65, n. 11, p. 7–10, 2013.
- SCURI, A. E. Fundamentos da imagem digital. 2002.
- SHAPIRO, L. G.; STOCKMAN, G. C. **Computer Vision**. [S.l.: s.n.], 2000.
- 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, n. 3, p. 209–213, 2002.
- SOUZA, V. C. G.; SAMPAIO, C. H.; TAVARES, L. M. M. Estudo por microscopia óptica e lupa das características mineralógicas e microestruturais do clínquer aplicado ao processo de moagem e qualidade do cimento. **Rem: Revista Escola de Minas, SciELO Brasil**, v. 55, p. 125–129, 2002.
- Steinhaus, H. Sur la division des corps matériels en parties. **Bull. Acad. Pol. Sci., Cl. III**, v. 4, p. 801–804, 1957. ISSN 0001-4095.
- STUTZMAN, P. E. Microscopy of clinker and hydraulic cements. **Reviews in Mineralogy and Geochemistry**, Mineralogical Society of America, v. 74, n. 1, p. 101–146, 2012.

STUTZMAN, P. E.; BULLARD, J. F.; FENG, P.; STUTZMAN, P. E. **Quantitative imaging of clinker and cement microstructure**. [S.l.]: US Department of Commerce, National Institute of Standards and Technology, 2016.

TAO, Y.; ZHANG, W.; SHANG, D.; XIA, Z.; LI, N.; CHING, W.-Y.; WANG, F.; HU, S. Comprehending the occupying preference of manganese substitution in crystalline cement clinker phases: A theoretical study. **Cement and Concrete Research**, Elsevier, v. 109, p. 19–29, 2018.

TENÓRIO, J. A. S.; ARAÚJO, F. G. d. S.; PEREIRA, S. S. R.; FERREIRA, A. V.; ESPINOSA, D. C. R.; BARROS, A. Decomposição da fase majoritária do cimento portland-parte ii: alita com adições de fe e al. **Rem: Revista Escola de Minas**, SciELO Brasil, v. 56, p. 113–117, 2003.

WAPCAPLET. **O sistema de cores HSV sendo visto como um círculo**. 2003. Disponível em: <[https://pt.wikipedia.org/wiki/HSV#/media/Ficheiro:Hsv\\_sample.png](https://pt.wikipedia.org/wiki/HSV#/media/Ficheiro:Hsv_sample.png)>.

WU, J. **Advances in K-means clustering: a data mining thinking**. [S.l.]: Springer Science & Business Media, 2012.