



**UNIVERSIDADE ESTADUAL DE SANTA CRUZ**  
**PRO-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**

Programa de Pós-Graduação em Modelagem Computacional em Ciência  
e Tecnologia

**GABRIEL DE MELLO LOUREIRO**

**PROPOSTA DE METODOLOGIA PARA A ANÁLISE DE  
IMAGENS TOMOGRÁFICAS DE ARGAMASSAS LEVES  
REFORÇADAS COM FIBRAS UTILIZANDO TÉCNICAS  
*FUZZY* E ALGORITMOS DE *CLUSTERIZAÇÃO***

**PPGMC - UESC**

**ILHÉUS – BA**

**2016**

**GABRIEL DE MELLO LOUREIRO**

**PROPOSTA DE METODOLOGIA PARA A ANÁLISE DE  
IMAGENS TOMOGRÁFICAS DE ARGAMASSAS LEVES  
REFORÇADAS COM FIBRAS UTILIZANDO TÉCNICAS  
*FUZZY* E ALGORITMOS DE *CLUSTERIZAÇÃO***

**PPGMC - UESC**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional em Ciência e Tecnologia da Universidade Estadual de Santa Cruz, como parte das exigências para obtenção do título de Mestre em Modelagem Computacional em Ciência e Tecnologia.

Orientadora: Prof. Dra. Susana Marrero Iglesias

Coorientador: Prof. Dr. Eduardo Silva Palmeira

**ILHÉUS – BA**

**2016**

L892

Loureiro, Gabriel de Mello.

Proposta de metodologia para a análise de imagens tomográficas de argamassas leves reforçadas com fibras utilizando técnicas fuzzy e algoritmos de clusterização / Gabriel de Mello Loureiro. – Ilhéus, BA: UESC, 2016.

105 f.: Il.

Orientadora: Susana Marrero Iglesias.

Dissertação (Mestrado) – Universidade Estadual de Santa Cruz. Programa de Pós-Graduação em Modelagem Computacional em Ciência e Tecnologia. Inclui referências e apêndice.

1. Processamento de imagens. 2. Tomografia. 3. Materiais. 4. Piaçaba. 5. Aglomeração. 6. Argamassa. 6. Lógica difusa. I. Título.

CDD 621.367

**GABRIEL DE MELLO LOUREIRO**

**PROPOSTA DE METODOLOGIA PARA A ANÁLISE DE  
IMAGENS TOMOGRÁFICAS DE ARGAMASSAS LEVES  
REFORÇADAS COM FIBRAS UTILIZANDO TÉCNICAS  
FUZZY E ALGORITMOS DE CLUSTERIZAÇÃO**

**PPGMC - UESC**

Ilhéus, 28 de Novembro de 2016.

Comissão examinadora



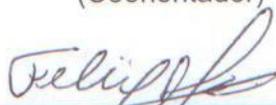
---

**Dra. Susana Marrero Iglesias**  
UESC  
(Orientadora)



---

**Dr. Eduardo Silva Palmeira**  
UESC  
(Coorientador)



---

**Dr. Felix Mas Milian**  
UESC



---

**Dr. Rogério Rodrigues de Vargas**  
UNIPAMPA

## **AGRADECIMENTOS**

Agradeço em primeiro lugar a Deus que iluminou o meu caminho durante esta caminhada.

A toda minha família que, com muito carinho e apoio, não mediram esforços para que eu culminasse esta etapa de minha vida.

Aos amigos, pelo incentivo e pelo apoio constante.

A minha professora orientadora, pelo convívio, pelo apoio, pela compreensão e pela amizade.

Ao meu professor coorientador, pela disponibilidade de ajudar no desenvolvimento do trabalho.

Ao professor Dany Dominguez, pelo grande apoio e sugestões no desenvolvimento da pesquisa.

Aos professores participantes da banca examinadora, que se disponibilizaram para a avaliação e sugestões no meu trabalho.

Ao NBCGIB, por ceder sua infraestrutura para que eu trabalhasse no desenvolvimento de pesquisas desde a graduação.

À UESC, por nos oferecer este curso de pós-graduação.

A todos os professores do PPGMC, que foram importantes na minha vida acadêmica e no desenvolvimento deste trabalho.

Aos colegas da turma 2014.2, Tarcila Matos, Rogério Rocha e Rodrigo Mendonça pelo excelente trabalho em equipe.

Aos colegas das turmas 2014.1 e 2015.1 pela convivência e amizade durante o curso.

Aos colegas de curso que compõem o grupo do Whatsapp "DCET", pelos momentos de descontração.

# PROPOSTA DE METODOLOGIA PARA A ANÁLISE DE IMAGENS TOMOGRÁFICAS DE ARGAMASSAS LEVES REFORÇADAS COM FIBRAS UTILIZANDO TÉCNICAS *FUZZY* E ALGORITMOS DE *CLUSTERIZAÇÃO*

## RESUMO

Um das formas de reduzir o impacto ambiental de resíduos perigosos como é o caso do *Etileno-Acetato de Vinila* (EVA) é sua reutilização em misturas utilizadas por outras indústrias. Este é o caso a da construção civil, na qual é possível utilizar misturas de argamassas leves, com boas características acústicas e térmicas sem precisar do aumento da espessura. A diminuição da massa específica também diminui custos de produção e traslado. Não entanto a adição deste agregado muda suas características mecânicas aumentando as possibilidades de fissura quando submetido a carga. Fibras podem ser utilizadas para seu reforço, funcionando como pontes de tensão. Neste trabalho estudamos uma mistura de argamassa leve com resíduos de EVA e reforçada com fibras de piaçaba. Para analisar a estrutura destas misturas construímos uma metodologia de caracterização que utiliza como base imagens tomográficas de amostras do material e analisa suas características usando algoritmos de *clusterização* (*k-means* e *c-means*) e um controlador *fuzzy*, que permitem agrupar objetos no interior da imagem da amostra usando critérios de similaridade como densidade, área, cor e excentricidade.

**Palavras chaves:** micro tomografia, caracterização de materiais, processamento de imagens, *clustering*, lógica *fuzzy*, argamassas leves, EVA, fibras de piaçaba.

# A METHODOLOGY PORPOSE FOR TOMOGRAPHIC IMAGE ANALYSIS OF LIGHTWEIGHT MORTAR REINFORCED WITH FIBERS USING FUZZY TECHNIQUES AND CLUSTERING ALGORITHMS

## ABSTRACT

A way to reduce the environmental problem caused by industrial residues like the Ethylene Vinyl Acetate is to reuse them in mixtures used by other industries. This the case of civil construction industry, where is possible to use, lightweight mortars with good acoustic and thermal characteristics without increasing the thickness of the structures. The specific mass decrease also reduces, the transportation and production costs. However, the inclusion of these aggregates change the mechanical characteristics of the mortar mixtures increasing the cracks propagation when a load is applied. One solution for this problem is to introduce fibers in the mixtures. The fibers act as stress bridges, reinforcing the final product. In this work we study a lightweight mortar mixture with EVA residues and reinforced with piassaba fibers. A characterization methodology is built based on microtomographic images of the different mixtures and using clusterization algorithms (k-means and c-means) and a fuzzy controller. This methodology allows to group the objects in the images using similarity criteria like density, area, color and eccentricity.

**Key words:** microtomography, material characterization, three-dimensional images, parallel processing, lightweight mortar, EVA, piassaba fibers.

## LISTA DE FIGURAS

Figura 1 – Sistema de TC. ....	9
Figura 2 – Imagem monocromática e a convenção utilizada para os eixos x e y. ....	12
Figura 3 – Representação matricial de uma imagem com perspectiva tridimensional. ....	12
Figura 4 – Imagem em escala de cinza. ....	13
Figura 5 – Histograma dos tons de cinza da imagem da figura 4. ....	13
Figura 6 – Histogramas de tipos básicos de imagem: (a) escura, (b) clara, (c) baixo contraste e (d) alto contraste. ....	14
Figura 7 – Copo com água parcialmente cheio. ....	17
Figura 8 – Gráfico da função característica para classificar o copo como cheio. ....	19
Figura 9 – Gráfico da função de pertinência para classificar o copo como cheio. ....	20
Figura 10 – Esquema de um controlador <i>fuzzy</i> . ....	28
Figura 11 – Corte das amostras enviadas ao micro tomógrafo <i>Skyscan</i> ® 1173. ....	41
Figura 12 – Imagens geradas por micro tomografia para as amostras: (a) mistura A, (b) mistura B e (c) mistura C. ....	41
Figura 13 – Imagem da mistura C: (a) imagem original e (b) imagem após a eliminação do ruído. ....	42
Figura 14 – Imagem original. ....	43
Figura 15 – Imagem da figura 14 <i>clusterizada</i> com $k=2$ : (a) <i>cluster 1</i> e (b) <i>cluster 2</i> . ....	44
Figura 16 – Imagem <i>clusterizada</i> com $k=3$ : (a) <i>cluster 1</i> , (b) <i>cluster 2</i> e (c) <i>cluster 3</i> . ....	44
Figura 17 – Imagem <i>clusterizada</i> com $k=4$ : (a) <i>cluster 1</i> , (b) <i>cluster 2</i> , (c) <i>cluster 3</i> e (d) <i>cluster 4</i> . ....	45
Figura 18 – Imagem resultante da primeira aplicação do <i>k-means</i> . ....	46
Figura 19 – Imagem <i>reclusterizada</i> com $k=2$ : (a) <i>cluster 1</i> e (b) <i>cluster 2</i> . ....	46
Figura 20 – Imagem <i>reclusterizada</i> com $k=3$ : (a) <i>cluster 1</i> , (b) <i>cluster 2</i> e (c) <i>cluster 3</i> . ....	47
Figura 21 – Imagem resultante da aplicação do <i>k-means</i> removendo a argamassa na amostra C. ....	49
Figura 22 – Imagem após aplicação do <i>FCM</i> com $c=3$ para a amostra C: (a) <i>cluster 1</i> , (b) <i>cluster 2</i> e (c) <i>cluster 3</i> . ....	49
Figura 23 – Ruído. ....	50
Figura 24 – Bordas que representam ruído. ....	51
Figura 25 – Imagem <i>clusterizada</i> com o <i>FCM</i> : (a) antes da remoção da borda e (b) depois da remoção da borda. ....	51
Figura 26 – Resultado da terceira aplicação do <i>FCM</i> na amostra C com $c=3$ . ....	52
Figura 27 – Arquitetura do controlador <i>fuzzy</i> utilizado nesta metodologia para a classificação dos elementos das amostras. ....	53
Figura 28 – Resultado do controlador utilizando a excentricidade (cores fornecidas para melhorar a visualização). ....	56
Figura 29 – Imagem de teste para a validação dos algoritmos. ....	57
Figura 30 – Diagrama de fluxo da metodologia aplicada às imagens das amostras das diferentes misturas obtidas por $\mu$ TC. ....	59
Figura 31 – Imagem de teste TA. ....	60
Figura 32 – Imagem de teste TB. ....	61

Figura 33 – Imagem de teste TC. ....	61
Figura 34 – Imagem de teste TA após aplicação do controlador <i>fuzzy</i> .....	64
Figura 35 – Imagem de teste TB após aplicação do controlador <i>fuzzy</i> .....	64
Figura 36 – Imagem de teste TC após aplicação do controlador <i>fuzzy</i> .....	64
Figura 37 – Imagem de teste TC após nova aplicação do controlador <i>fuzzy</i> .....	67
Figura 38 – Histograma dos tons de cinza das imagens das amostras A, B e C. ....	69
Figura 39 – Matriz de pertinência para cada elemento a cada <i>cluster</i> considerando a área. ....	72
Figura 40 – Histograma dos valores das áreas dos objetos da mistura A. ....	73
Figura 41 – Histograma dos valores das áreas dos objetos da mistura B. ....	73
Figura 42 – Histograma dos valores das áreas dos objetos da mistura C.....	74
Figura 43 – Histograma dos valores das áreas dos objetos das misturas A, B e C.....	74
Figura 44 – Gráfico que representa a matriz de pertinência obtida após uma aplicação do <i>FCM</i> .....	75
Figura 45 – Gráfico que representa a matriz de pertinência obtida após a segunda aplicação do <i>FCM</i> . ....	76
Figura 46 – Histograma dos valores das áreas dos objetos da amostra A após aplicações do <i>FCM</i> .....	78
Figura 47 – Histograma dos valores das áreas dos objetos da amostra B após aplicações do <i>FCM</i> .....	78
Figura 48 – Histograma dos valores das áreas dos objetos da amostra C após aplicações do <i>FCM</i> .....	79
Figura 49 – Gráfico que representa a matriz de pertinência dos valores das áreas obtida após a segunda aplicação do <i>FCM</i> .....	80
Figura 50 – Gráfico que representa a matriz de pertinência dos valores das excentricidades obtida com a aplicação do <i>FCM</i> .....	80
Figura 51 – Gráfico que representa a matriz de pertinência dos valores das áreas após a aplicação do $\alpha$ -corte de 0,8. ....	81
Figura 52 – Gráfico que representa a matriz de pertinência dos valores das excentricidades após a aplicação do $\alpha$ -corte de 0,6. ....	82

## LISTA DE TABELAS

Tabela 1 – Classificação da argamassa quanto à densidade.....	5
Tabela 2 – Tabela verdade da negação.....	23
Tabela 3 – Tabela verdade da conjunção.....	23
Tabela 4 – Tabela verdade da disjunção.....	23
Tabela 5 – Tabela verdade da implicação.....	24
Tabela 6 – Tabela verdade da equivalência.....	24
Tabela 7 – Modelo de base de regras <i>fuzzy</i> .....	27
Tabela 8 – Base de regras.....	55
Tabela 9 – Comparação dos resultados do teste de validação da área.....	58
Tabela 10 – Comparação dos resultados do teste de validação da excentricidade.....	58
Tabela 11 – Quantidade de objetos de cada material nas imagens de teste.....	62
Tabela 12 – Base de regras aplicada às imagens de teste.....	63
Tabela 13 – Quantidade de objetos de cada material identificado pelo controlador nas imagens de teste.....	65
Tabela 14 – Base de regras aplicada às imagens de teste na segunda aplicação.....	66
Tabela 15 – Quantidade de objetos de cada material identificado pelo controlador na imagem de teste TC.....	66
Tabela 16 – Quantidade de <i>pixels</i> eliminados no pré-processamento.....	68
Tabela 17 – Intervalo dos tons e cinza correspondentes a cada <i>cluster</i> .....	70
Tabela 18 – Quantidade de <i>pixels</i> dos materiais nas imagens da amostra A.....	70
Tabela 19 – Quantidade de <i>pixels</i> dos materiais nas imagens da amostra B.....	70
Tabela 20 – Quantidade de <i>pixels</i> dos materiais nas imagens da amostra C.....	70
Tabela 21 – Quantidade de objetos em cada mistura após a aplicação do algoritmo <i>k- means</i> .....	71
Tabela 22 – Quantidade de <i>pixels</i> dos materiais e ruídos após o <i>FCM</i> nas imagens da amostra A.....	76
Tabela 23 – Quantidade de <i>pixels</i> dos materiais e ruídos após o <i>FCM</i> nas imagens da amostra B.....	77
Tabela 24 – Quantidade de <i>pixels</i> dos materiais e ruídos após o <i>FCM</i> nas imagens da amostra C.....	77
Tabela 25 – Quantidade total de objetos que representam os materiais após eliminação de ruídos com o <i>FCM</i> .....	77
Tabela 26 – Resultados da aplicação do controlador <i>fuzzy</i> nas imagens da amostra com a mistura A.....	82
Tabela 27 – Resultados da aplicação do controlador <i>fuzzy</i> nas imagens da amostra com a mistura B.....	82
Tabela 28 – Resultados da aplicação do controlador <i>fuzzy</i> nas imagens da amostra com a mistura C.....	83
Tabela 29 – Quantidade total de <i>pixels</i> e massa de cada material na mistura A.....	83
Tabela 30 – Quantidade total de <i>pixels</i> e massa de cada material na mistura B.....	84
Tabela 31 – Quantidade total de <i>pixels</i> e massa de cada material na mistura C.....	84

## LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
CP	Corpo de Prova
END	Ensaio Não Destrutivo
EVA	Etileno-Acetato de Vinila
FCM	<i>Fuzzy C-Means</i>
KV	Quilovolts
LiDAR	<i>Light Detection And Ranging</i>
Mpa	Mega Pascal
MRI	Imagem de Ressonância Magnética
NBCGIB	Núcleo de Biologia Computacional e Gestão de Informações Biotecnológicas
NBR	Norma Brasileira
PCA	Problema de <i>Clusterização</i> Automática
PDI	Processamento Digital de Imagens
PPGMC	Programa de Pós-Graduação em Modelagem Computacional
ROI	Região de Interesse
RGB	<i>Red, Green e Blue</i>
SBRF	Sistemas Baseados em Regras <i>Fuzzy</i>
TC	Tomografia Computadorizada
UESC	Universidade Estadual de Santa Cruz
$\mu$ A	Micro Ampère
$\mu$ CT	Micro Tomografia Computadorizada

## SUMÁRIO

1 INTRODUÇÃO.....	1
2 REVISÃO BIBLIOGRÁFICA.....	5
2.1 Argamassa leve .....	5
2.1.1 Agregados .....	6
2.1.2 Elementos de Reforço .....	7
2.2 Tomografia computadorizada de raios X.....	8
2.3 Processamento de imagens digitais .....	10
2.3.1 Imagens digitais.....	11
2.3.2 Histograma de uma imagem.....	13
2.3.3 Segmentação de imagens .....	15
2.3.3.1 Limiarização.....	15
2.3.4 Volume e área de superfícies.....	16
2.4 Teoria <i>fuzzy</i> .....	16
2.4.1 Teoria dos conjuntos <i>fuzzy</i> .....	17
2.4.1.1 Função de pertinência.....	18
2.4.1.2 Operações sobre conjuntos <i>fuzzy</i> .....	21
2.4.2 Conceitos da lógica <i>fuzzy</i> .....	22
2.4.2.1 Lógica clássica .....	22
2.4.2.1 Lógica <i>fuzzy</i> .....	24
2.4.3 Sistemas baseados em regras <i>fuzzy</i> .....	26
2.4.3.1 Base de Regras.....	27
2.4.3.2 Controlador <i>fuzzy</i> .....	27
2.5 Algoritmos de <i>clusterização</i> .....	29
2.5.1 Algoritmo <i>k-means</i> .....	31
2.5.2 Algoritmo <i>fuzzy c-means</i> .....	32
2.6 Estado da arte .....	34
3 MATERIAIS E MÉTODOS.....	39
3.1 Imagens das amostras.....	39
3.2 Pré-processamento .....	42
3.3 Algoritmo <i>k-means</i> .....	43
3.4 Algoritmo <i>fuzzy c-means</i> .....	47
3.5 Controlador <i>fuzzy</i> .....	53

3.5.1 Módulo de <i>fuzzificação</i> com o algoritmo <i>fuzzy c-means (FCM)</i> .....	54
3.5.2 Base de regras.....	54
3.5.3 Método de inferência de Mamdani Clássico .....	55
3.6 Validação dos critérios de classificação.....	56
4 RESULTADOS E DISCUSSÕES .....	59
4.1 Imagens de teste do controlador <i>fuzzy</i> .....	60
4.1.1 Criação das imagens .....	60
4.1.2 Aplicação das bases de regras .....	62
4.2 Imagens de micro tomografia computadorizada.....	67
4.2.1 Eliminação das bordas .....	68
4.2.2 Separação da argamassa usando o algoritmo <i>k-means</i> .....	69
4.2.3 Algoritmo <i>fuzzy c-means</i> .....	71
4.2.4 Controlador <i>fuzzy</i> .....	79
5 CONCLUSÕES E TRABALHOS FUTUROS.....	86
REFERÊNCIAS BIBLIOGRÁFICAS .....	89
APÊNDICE A – ALGORITMO DE PRÉ-PROCESSAMENTO EM MATLAB .....	95
APÊNDICE B – ALGORITMO <i>K-MEANS</i> EM MATLAB.....	96
APÊNDICE C – ALGORITMO FUZZY C-MEANS EM MATLAB .....	100
APÊNDICE D – CONTROLADOR FUZZY EM MATLAB.....	102

## 1 INTRODUÇÃO

Nos últimos anos os avanços tecnológicos e o crescente processo de urbanização vem agredindo cada vez mais o meio ambiente, principalmente no alto índice de exploração de recursos naturais e no descarte de resíduos sólidos na natureza.

Uma alternativa que reduz este problema da degradação e gera um aumento nos lucros é a reciclagem e reutilização de resíduos provenientes de processos industriais.

No Brasil se encontra um dos maiores parques industriais calçadistas e um mercado consumidor muito grande, gerando milhares de toneladas de resíduos por ano. Dentre estes resíduos está o EVA (*Etileno-Acetato de Vinila*), polímero que não é biodegradável e de difícil reciclagem ou descarte, pois sua incineração gera gases tóxicos e o material não pode ser reintegrado ao seu processo de produção. Outro problema com o EVA é a sua baixa densidade, o que torna necessário grandes área para estocar os grandes volumes gerados.

A indústria de construção civil possui uma vasta opção de matérias primas e um grande número de componentes aplicados nos processos construtivos que podem ser utilizados resíduos de outras indústrias, como minerais e agroindustriais.

Essas indústrias da construção civil produzem concretos e argamassas chamados de especiais, devido às suas características diferenciadas das misturas de concretos e argamassas tradicionais. Entre esses concretos e argamassas especiais estão os concretos e argamassas leves, que tem como característica a sua baixa massa específica, obtida pela substituição de materiais sólidos por ar. Essa substituição é feita com a incorporação de ar, espumas ou outros agregados com altos índices de vazios.

Entre as soluções de reutilização de resíduos industriais que agridem o meio ambiente estão as misturas de cimento com resíduos de EVA resultantes da indústria calçadista (GARLET; GRAVEN, 1997). Essas misturas melhoram as

propriedades acústicas e térmicas do ambiente sem um aumento significativo na espessura do material (MEHTA; MONTEIRO, 1994).

Entretanto, a introdução destes resíduos diminui as propriedades mecânicas do concreto, produto do aumento dos vazios dentro da mistura. Uma das soluções encontradas para neutralizar este efeito é a introdução de fibras nas misturas que funcionam como reforço (SILVA et al., 2011).

Existe uma gama de tipos de fibras que podem ser usadas para esse fim, dentre eles estão as fibras vegetais. Uma fibra vegetal encontrada em abundância na região do sul da Bahia é a fibra de piaçaba, extraída da palmeira *Attalea Funifera Martius*.

As novas misturas como é o caso da argamassa com EVA reforçada com fibras, precisam ser caracterizadas na sua estrutura e comportamento mecânico. As técnicas para o estudo da estrutura interna dos materiais podem ser separadas em métodos destrutivos e métodos não destrutivos.

As técnicas de ensaios destrutivos proporcionam alguma avaria à amostra para analisar a sua estrutura interna. Já as técnicas de ensaios não destrutivos permitem a análise dessas estruturas proporcionando pouco ou nenhum dano às mesmas, permitindo o uso da amostra para outros fins após os ensaios. Muitos dos ensaios que verificam as propriedades dos materiais são realizados através de processos destrutivos. Porém, nos últimos anos as técnicas não destrutivas vêm ganhando importância pela redução de custos que este tipo de técnicas proporciona.

A micro tomografia de raios X é uma técnica não destrutiva, que permite a obtenção de imagens 2D da estrutura interna dos materiais e, a partir destas, recriar os modelos 3D via reconstrução digital do objeto. Com estas imagens podem ser realizados estudos que permitam conhecer melhor a estrutura e composição destes materiais. Técnicas modernas podem ser utilizadas com esse objetivo (MENDES, 2010), inclusive técnicas de processamento de imagens para caracterização de amostras de concreto (ASSIS et al., 2007).

Usando as imagens obtidas por micro tomografia é possível utilizar algoritmos de mineração de dados consistem em agrupar dados de acordo com características semelhantes (FAYYAD et al., 1996). A aplicação desses algoritmos no estudo de

imagens é uma técnica moderna que permite classificar regiões da imagem considerando as características específicas destas como, por exemplo, densidade ou cor. Basicamente o algoritmo consiste em agrupar num *cluster* objetos com características similares e diferentes dos agrupados em outros *clusters*.

Em trabalhos anteriores foram realizadas tentativas de caracterização destes materiais utilizando imagens de micro tomografia e aplicando métodos baseados na lógica clássica, como é o caso de Lopes dos Santos (2015) que utilizou a análise de Fourier, Meira Silva (2012) autor que aplicou algoritmos de processamento de imagens como a manipulação de histogramas e algoritmos de reconhecimento de padrões e Silva Mendonça (2016) que utilizou algoritmos de manipulação de histogramas e reconhecimento de padrões aplicando técnicas de processamento paralelo. A partir destes trabalhos foi observado que algumas características dos objetos como área e excentricidade tem um alto grau de incerteza. Com o objetivo de tratar melhor estas incertezas foi escolhido o algoritmo *fuzzy c-means* para realizar a caracterização destes objetos utilizando a área e excentricidade dos objetos como critério de classificação.

Conjuntamente com a *clusterização* das imagens é possível utilizar técnicas como a teoria *fuzzy* para a sua classificação. A lógica *fuzzy* permite interpretar dados de uma forma diferente à lógica clássica, considerando sistemas com certo grau de incertezas e permitindo sua modelagem. A caracterização utilizando teoria *fuzzy* nos permite também implementar um controlador *fuzzy* com uma base de regras contendo a combinação de mais de um critério para realizar a classificação.

O objetivo deste trabalho é caracterizar a porosidade e concentração de agregados em amostras de argamassas leves a partir de imagens de micro tomografia computadorizada. Para esta caracterização são aplicados algoritmos de *clusterização* e teorias *fuzzy*. Esta metodologia pode também ser aplicada no estudo da microestrutura de outros materiais.

O trabalho está dividido em 5 capítulos.

O primeiro capítulo apresenta uma introdução ao tema com motivação, objetivos específicos e a justificativa da pesquisa.

No segundo capítulo apresentamos a revisão bibliográfica dos principais conceitos necessários para o desenvolvimento do projeto como: argamassas leves, processamento de imagens, teoria *fuzzy*, algoritmos de *clusterização* e como foram validados alguns algoritmos. Além disso, é mostrado uma contextualização dos elementos principais do projeto em pesquisas atuais.

No terceiro capítulo é mostrada a metodologia desenvolvida, incluindo como foram obtidas as misturas de argamassa, como foi realizado o pré-processamento e as etapas da caracterização das imagens das amostras utilizando os algoritmos de *clusterização*.

No quinto capítulo são mostrados e discutidos os resultados de cada etapa da metodologia.

Finalmente, o capítulo seis mostra as conclusões que pudemos tirar usando os resultados obtidos e propomos alguns trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo faremos uma revisão de alguns temas necessários para o desenvolvimento desta pesquisa. Alguns conceitos relacionados a argamassas com imagens de micro tomografia computadorizada serão expostos e no final faremos uma contextualização das últimas pesquisas nestas áreas.

### 2.1 Argamassa leve

Materiais com propriedades de aderência e endurecimento utilizados em construções civis resultante da mistura de agregados miúdos, areia, água e cimento são chamados de argamassa. A argamassa pode ser classificada de acordo com sua massa específica como leve, normal ou pesada (MEHTA; MONTEIRO, 1994).

De acordo com Carasek (2007), como é mostrado na tabela 1, quando a argamassa tem densidade menor que  $1,4\text{g/cm}^3$  é classificada como leve, quando a densidade está entre  $1,4\text{g/cm}^3$  e  $2,3\text{g/cm}^3$  é classificada como normal e quando esta densidade é maior que  $2,3\text{g/cm}^3$  é classificada como pesada. A argamassa leve é usada em isolamentos térmicos e acústicos, a argamassa normal é utilizada em aplicações convencionais e a argamassa pesada é utilizada na blindagem de radiação.

Tabela 1 – Classificação da argamassa quanto à densidade.

Argamassa	Densidade
Leve	Menor que $1,4\text{g/cm}^3$
Normal	Entre $1,4\text{g/cm}^3$ e $2,3\text{g/cm}^3$
Pesada	Maior que $2,3\text{g/cm}^3$

Essas argamassas leves melhoram a relação resistência/peso das construções e melhoram o isolamento térmico e acústico destas construções sem que seja preciso o aumento da espessura das camadas de argamassa. Isso torna possível a construção em solos com menor capacidade de suporte (MEHTA; MONTEIRO, 1994).

Segundo a NBR 12655 (ABNT, 2015), O concreto é constituído pela mistura de cimento, agregados miúdos e graúdos e água. Mehta e Monteiro (2006) expõem

que o que difere a argamassa do concreto é a ausência de agregados graúdos na argamassa.

Para a argamassa ser considerada leve deve-se reduzir a densidade substituindo o material sólido por ar, introduzindo ar, espumas ou outros agregados com altos índices de vazios, que são chamados de agregados leves.

### 2.1.1 Agregados

Agregados são materiais que constituem a estrutura do concreto e que são unidos pelo cimento (TARTUCE, RONALDO GIOVANNETTI, 1990). São materiais granulares, sem forma e volumes definidos e com propriedades e dimensões específicas para o uso em obras. Esses agregados tem grande influência sobre concretos e argamassas, como por exemplo, a melhora de algumas características como retração e o aumento da resistência mecânica.

Segundo Mehta e Monteiro (1994), os agregados podem ser classificados pela dimensão de suas partículas, sua origem e pela sua massa específica. Quanto à dimensão das partículas são classificados em agregados graúdos e miúdos, quanto à massa específica são classificados em agregados leves e densos ou pesados, e quanto à origem são classificados em naturais e artificiais.

De acordo com a NBR 7211 (ABNT, 2009) os agregados são considerados miúdos quando contêm partículas que tem dimensões entre 75 $\mu$ m e 4,75mm, e os agregados graúdos tem dimensões entre 4,75mm e 50mm.

Quanto à massa específica, foi definido pela NBR 12655 (ABNT, 2015) que o agregado leve possui massa específica baixa, com valores até 2000kg/m<sup>3</sup>, e o agregado denso ou pesado possui uma alta massa específica, com valores acima de 3000 kg/m<sup>3</sup>.

São classificados como agregados naturais os que são extraídos diretamente em jazidas, eles não são muito utilizados em concretos estruturais devido à variabilidade de suas propriedades. Já os agregados classificados como artificiais são os obtidos em processos industriais, que podem ser produzidos com diversos tipos de matéria prima e processos de fabricação (ROSSIGNOLO, 2003). Muitos

agregados também são obtidos por meio da reciclagem de resíduos das indústrias, por exemplo, resíduos de pneus e EVA (SANTIAGO, 2008).

Foram realizados alguns estudos na utilização de resíduos de EVA em diferentes proporções misturados para a formação de concretos leves com a finalidade de avaliar mudanças de resistência, rigidez e massa específica dos compósitos. Garlet e Graven (1997) concluíram que a resistência à compressão e a massa específica do concreto são reduzidos à medida que o teor de EVA aumenta nas misturas.

Araújo et al. (2011) verificaram que com o aumento da quantidade de EVA tiveram maiores perdas de resistência para certas proporções. Afirmaram também que este material pode ser aplicado em situações que sua leveza é um fator importante, como é o caso da fabricação de elementos de vedação.

Uma grande vantagem na utilização do EVA é a diminuição do peso do compósito resultante. Porém a desvantagem maior está na perda de resistência devido ao aumento de vazios ocupados por este material. Para compensar esta perda, podem ser adicionadas fibras como elemento de reforço nestas misturas.

### 2.1.2 Elementos de Reforço

O concreto possui em seu interior alguns poros que aumentam a fragilidade do material, que quando sujeita a esforços pode sofrer um rompimento. No caso de argamassas leves a presença dos agregados como é o caso do EVA, aumenta a sua fragilidade. Assim, torna-se necessário acrescentar algum reforço nesses materiais (CARVALHO et al., 2007). Uma alternativa para este reforço é o uso de fibras nas misturas. Essas fibras podem ser de vários materiais, como aço, plástico, vidro e materiais naturais, como sisal, coco, juta e piaçava. Quando inseridas na mistura, as fibras absorvem parte da força atuante sobre o corpo, funcionando como pontes de tensão, diminuindo a tensão sobre esse corpo e o torna mais resistente (PERET et al., 2003).

O estudo da aplicação de fibras vegetais como reforço de concretos e argamassas vem despertando cada vez mais o interesse de muitos autores, pois

possui baixo custo, economiza energia e não afeta o meio ambiente (JÚNIOR, 2000).

Toledo et al. (1997) fez uma avaliação quanto à adição de fibras de sisal e coco afeta o comportamento em compressão da argamassa. Lopes et al. (2011) fizeram experimentos com a utilização de fibras de piaçava como elemento de reforço de argamassas leves. Araújo et al. (2011) estudou o acréscimo de fibras de piaçava como reforço em um compósito de cimento que utiliza EVA como agregado leve com a finalidade de aumentar a resistência a fissuras.

## **2.2 Tomografia computadorizada de raios X**

Para o estudo de nova misturas, como é o caso de argamassas leves, ensaios devem ser realizados. Muitos ensaios que verificam a estrutura interna e as propriedades dos materiais são realizados por técnicas destrutivas, que destroem o material a ser estudado para avaliar sua estrutura interna. Além dos destrutivos existem também os ensaios não destrutivos (END), que permitem estudar as propriedades de um objeto sem alterar suas características e sem comprometer o seu uso para outros fins (CALLISTER; RETHWISCH, 2009).

Dentre as técnicas de END está a tomografia computadorizada (TC) de raios X, que permite o estudo da estrutura interna de objetos de vários materiais, inclusive variações na densidade e composição atômica (MEES et al., 2003).

A TC vem sendo usada por muitos autores em diversas áreas, como é o caso da análise de ossos e dentes, caracterização de materiais, determinação de volumes e defeitos em amostras de concreto, controle de qualidade de produtos, etc. Essa técnica foi revolucionária na medicina, pois permite que os médicos visualizem o interior do paciente com precisão e segurança (CARVALHO, 2007).

Esta técnica pode ser usada para o estudo da estrutura interna de amostras de misturas de argamassas. Através das imagens resultantes é possível analisar a porosidade, as imperfeições, o tamanho e distribuição dos agregados na mistura (MENDES, 2010).

Desde a descoberta dos raios X que eles vêm sendo utilizados para diagnosticar doenças, e cada vez mais sendo aprimorado com o avanço dos aparelhos em termo de qualidade e potência, entre os que se encontram os micro tomógrafos (CARVALHO, 2007).

Domínguez (2012) descreve como é o processo de captura das imagens por meio da TC, onde inicialmente são posicionados uma fonte de raios X e um detector em lados opostos do objeto. A fonte de raios X emite uma radiação contra a amostra, que absorve parte dessa radiação de acordo com seu coeficiente de absorção. De acordo com a quantidade de radiação que chega ao detector é possível calcular o coeficiente de atenuação do material e gerar imagens bidimensionais das seções da amostra. Essas imagens passam por um algoritmo de reconstrução que a partir das imagens bidimensionais gera uma imagem tridimensional do objeto. Esse sistema de tomografia é ilustrado na figura 1.

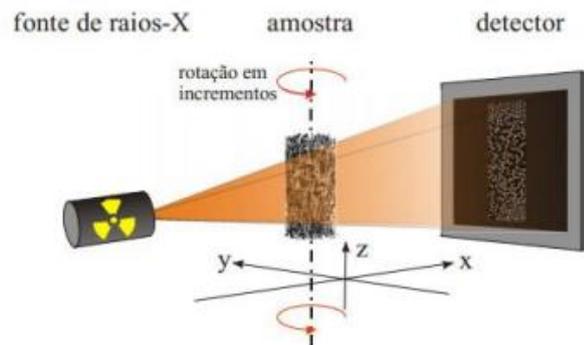


Figura 1 – Sistema de TC.

Fonte: Argenta et al. (2010).

A tomografia de raios X é limitada pela resolução de suas imagens (CNUUDE et al., 2006). A micro tomografia computadorizada ( $\mu$ CT) de raios X, possibilita uma análise em microescala dos materiais (NETO et al., 2011).

A  $\mu$ CT de raios X fornece imagens 2D e 3D da estrutura interna das amostras em escalas micrométricas e por isso esta técnica pode ser aplicada em diversas áreas. Os equipamentos de  $\mu$ CT oferecem configurações tais como voltagem e corrente que permitem realizar alterações na qualidade das imagens geradas de acordo com a regulação escolhida.

Em uma amostra de concreto a  $\mu$ CT permite uma análise mais detalhada de imperfeições, fissuras, agregados, presença de vazios e outras características que podem comprometer a estrutura ou mudar as características do concreto analisado.

### **2.3 Processamento de imagens digitais**

Ao obter imagens 2D ou 3D é possível utilizar técnicas de processamento de imagens para a extração de características.

O conjunto de técnicas que captura, transforma e analisa imagens por meio de dispositivos eletrônicos é chamado de processamento de imagens digitais (PDI). A demanda por estes métodos vem cada vez mais aumentando, pois possui inúmeras aplicações, como melhoria de imagens para interpretação humana e análise de suas características através de computadores (GONZALEZ; WOODS, 2010).

O processamento de imagens digitais nos permite melhorar a qualidade de imagens de modo que possamos visualizar melhor e extrair informações importantes, identificar estruturas, padrões e objetos (QUOIRIN, NILTON SERGIO RAMOS, 2004). As imagens podem ser analisadas considerando a sua forma, textura, tons de cinza ou as cores dos objetos nela contidos.

As técnicas de processamento de imagens digitais podem ser aplicadas em diversas áreas, por exemplo, no tratamento de imagens médicas, análise de ambientes, geologia, cartografia, sensoriamento remoto, na ciência dos materiais, etc.

Segundo Gomes (2001), os sistemas de processamento de imagens digitais são divididos em três partes básicas, a aquisição, o processamento e a análise de imagens. Na aquisição, temos como entrada uma amostra e envolve a formação e digitalização da imagem, fornecendo um arquivo digital com a imagem. O bloco de processamento tem como entrada uma imagem digital e retorna uma imagem processada como saída. O bloco de análise extrai atributos e reconhece padrões e classifica a imagem, recebe uma imagem processada e retorna dados numéricos como saída. Existem três níveis de processos computacionais no processamento de

imagens digitais, o nível baixo, o nível médio e o nível alto (GONZALEZ; WOODS, 2010).

Um processo de nível baixo atua diretamente nos *pixels* das imagens e envolve técnicas de pré-processamento de imagens como contraste, suavização e redução de ruídos (GONZALEZ; WOODS, 2010).

Um processo de nível médio envolve procedimentos mais complexos, como segmentar uma imagem, determinar regiões de interesse (ROI) e reconhecer objetos. No processo de nível médio a entrada é uma imagem e a saída são atributos dela extraídos, tais como contornos, objetos, etc (GONZALEZ; WOODS, 2010).

Um processo de nível alto interpreta o conteúdo de uma imagem e tenta executar funções cognitivas associadas à visão humana. Esse processamento é associado a análise de imagens digitais (GONZALEZ; WOODS, 2010).

### 2.3.1 Imagens digitais

Segundo Gonzalez e Woods (2010), uma imagem é definida como uma função bidimensional  $f(x, y)$ , onde  $x$  e  $y$  correspondem às coordenadas espaciais desta imagem e o valor desta função em qualquer ponto  $(x, y)$  é a intensidade ou nível de cinza da imagem neste ponto. No caso da imagem estar no sistema (RGB), o valor da função  $f$  será um terno ordenado que representa a intensidade de cada um dos canais (vermelho, verde e azul) no determinado ponto da imagem. Uma imagem digital é formada por esse conjunto de pontos  $(x, y)$  contendo cada um o seu valor, esses pontos são chamados de *pixel*.

Segundo Jahne (2002), cada *pixel* tem uma posição seguindo a notação de uma matriz, onde o primeiro índice ( $m$ ) refere-se à posição da linha e o segundo ( $n$ ) índice refere-se à coluna em que se encontra o *pixel*. Sendo assim, uma imagem possui  $m \times n$  *pixels*, que variam no intervalo entre 0 e 255 no caso das imagens em tons de cinza, que são as tratadas neste trabalho. Por uma questão de convenção, a numeração das coordenadas tem início no canto superior esquerdo conforme é ilustrado na figura 2.

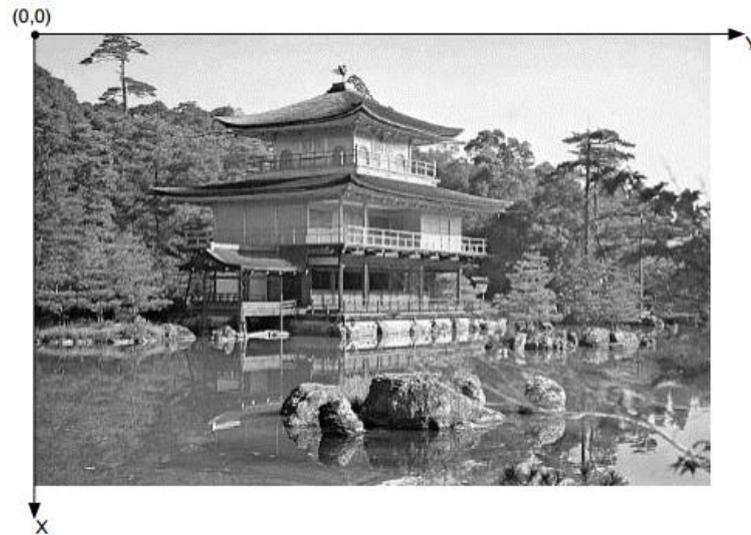


Figura 2 – Imagem monocromática e a convenção utilizada para os eixos x e y.

Fonte: Marques Filho e Vieira Neto (1999).

As imagens digitais também podem ser representadas com uma perspectiva tridimensional (3D), onde se utiliza uma matriz com três dimensões para representá-las. As dimensões  $m \times n$  de um *pixel* nestas imagens e o espaçamento dentre os cortes  $d$ , a extensão do *pixel* em 3D forma um pequeno paralelepípedo de dimensões  $m \times n \times d$  formando uma descrição geométrica que é chamada de *voxel*, e representam um elemento de volume da imagem 3D (JÚNIOR, 2008). A representação matricial de uma imagem em três dimensões é mostrada na figura 3.

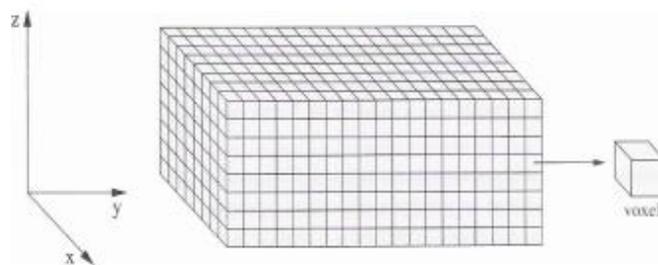


Figura 3 – Representação matricial de uma imagem com perspectiva tridimensional.

Fonte: Pedrini e Schwartz (2008).

### 2.3.2 Histograma de uma imagem

Quando tratamos uma imagem digital diferentes filtros ou modificações podem ser aplicados. Filtros no espaço ou na frequência. Entre eles se encontra o histograma. Segundo Gonzalez e Woods (2010) o histograma de uma imagem é uma função discreta  $h(r_k) = n_k$  onde  $r_k$  é o  $k$ -ésimo valor de intensidade e  $n_k$  é o número de *pixels* da imagem com intensidade  $r_k$ . Um histograma representa a distribuição dos valores dos *pixels*, Estes valores são normalmente representados por um gráfico de barras que fornece para cada nível de cinza o número (ou o percentual) de *pixels* correspondentes na imagem. Um exemplo de histograma é mostrado na figura 5, onde é representado o histograma da imagem da figura 4.



Figura 4 – Imagem em escala de cinza.

Fonte: Pedrini e Schwartz (2008).

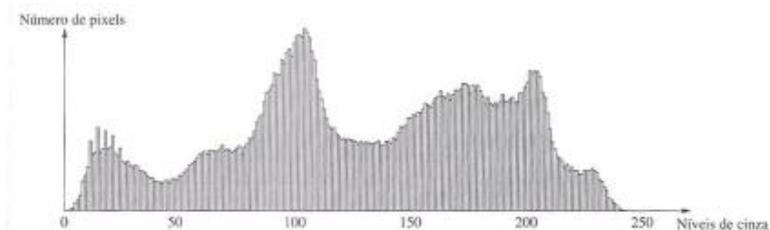


Figura 5 – Histograma dos tons de cinza da imagem da figura 4.

Fonte: Pedrini e Schwartz (2008).

Segundo Pedrini e Schwartz (2008) o histograma de uma imagem pode nos fornecer medidas estatísticas como os valores de mínimo e máximo, valor médio, variância e o desvio padrão dos seus níveis de cinza. O contraste de uma imagem também pode ser avaliado a partir de seu histograma. Em imagens escuras os componentes do histograma estão concentrados no lado inferior da escala de intensidades, onde estão os tons de cinza de menor valor, já em imagens claras, os componentes do histograma se agrupam do lado superior da escala, onde estão os tons de cinza de maior valor (GONZALEZ; WOODS, 2010). Exemplos de histogramas para os tipos básicos de imagem: escura, clara, baixo contraste e alto contraste são apresentados na figura 6.

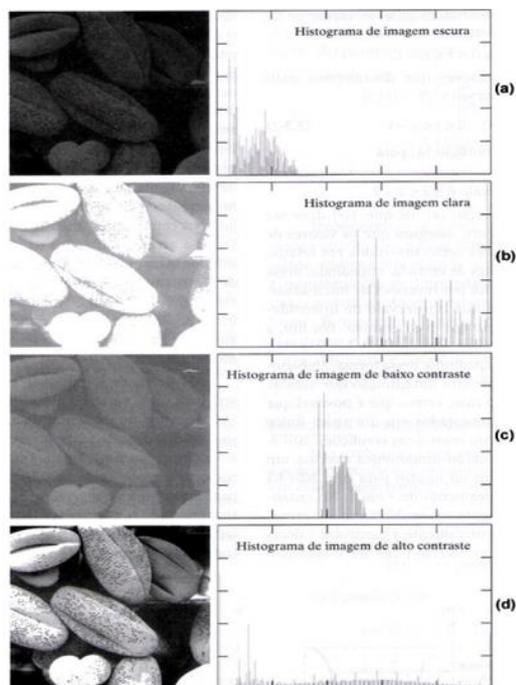


Figura 6 – Histogramas de tipos básicos de imagem: (a) escura, (b) clara, (c) baixo contraste e (d) alto contraste.

Fonte: Gonzalez e Woods (2010).

Uma técnica que permite normalizar a distribuição dos níveis de cinza de imagens digitais é chamada de normalização de histograma. Esta técnica permite obter a densidade média de *pixels* em função dos níveis de cinza na imagem. A equalização de histograma modifica o histograma da imagem original de tal forma

que a imagem transformada possua uma distribuição mais uniforme dos seus níveis de cinza (GONZALEZ; WOODS, 2010).

### 2.3.3 Segmentação de imagens

Quando processamos imagens digitais é possível querer tratar ou quantificar determinadas partes ou características das imagens. Os métodos de segmentação têm como objetivo processar uma determinada região de interesse, que é conhecida como *ROI* (do inglês *Region Of Interest*). Essa região contém as informações desejadas para uma determinada análise. A segmentação separa a imagem em regiões e as distingue como objetos independentes (GOMES, 2001). O resultado da segmentação pode ser uma imagem binária, onde o fundo é representado por uma cor e os objetos que serão destacados representados por outra cor.

De acordo com Rabelo (2002), ao tratarmos de processamento de imagens científicas, é comum que seja necessário obter dados relacionados com objetos contidos na imagem. Com isso, torna-se necessário aplicar métodos de segmentação para isolar a região de interesse e extrair os parâmetros necessários para o estudo.

#### 2.3.3.1 Limiarização

Entre os métodos de segmentação encontra-se a limiarização. A limiarização, também conhecida como *thresholding*, é a mais simples das técnicas de segmentação de imagens. Esta técnica nos permite separar os objetos de uma imagem com base nos valores de intensidade dos seus tons de cinza. Para essa segmentação é escolhido um limiar  $L$ , que define como serão classificados os objetos da imagem. Os *pixels* que possuem um valor de intensidade menor que o limiar é atribuído um valor equivalente a uma cor e aos restantes, valor equivalente a outra cor, geralmente são usadas as cores preto e branco (GONZALEZ; WOODS, 2010). O valor do limiar geralmente é obtido com a análise do histograma da imagem.

Gonzalez e Woods (2010) representam a limiarização através da equação (1):

$$g(x, y) = \begin{cases} 1, & \text{se } f(x, y) > L \\ 0, & \text{se } f(x, y) < L \end{cases} \quad (1)$$

Onde  $L$  é o limiar escolhido,  $g(x, y)$  é o novo valor do *pixel* após a limiarização e  $f(x, y)$  é o valor do *pixel* da imagem antes da limiarização.

#### 2.3.4 Volume e área de superfícies

Entre as características que podem ser extraídas de imagens digitais temos volume e área de superfície. A área de uma região em uma imagem bidimensional (2D) é definida como o número de *pixels* na região, já que o *pixel* é a menor unidade de uma imagem 2D. Já nas imagens adquiridas por tomógrafos, que são tridimensionais, o seu volume é definido pelo número de *voxels*. O *voxel*, como já mencionado é a menor unidade das imagens tridimensionais e o seu tamanho pode variar em diferentes tomógrafos (CAMPOS, 2009). O volume total de objetos em imagens 3D é dado pela soma de todos os *voxels* desse objeto, representada pela equação (2):

$$a = \sum_{i=1}^t c_i \quad (2)$$

Onde  $t$  é o número de *voxels* presentes no objeto e  $c_i$  é o volume de um *voxel*.

#### 2.4 Teoria *fuzzy*

Para a análise de dados é possível utilizar a lógica clássica que considera a ideia de que um elemento possa pertencer ou não a um conjunto. No caso de dados que contém um certo grau de incerteza é possível utilizar a lógica *fuzzy*, uma forma aprimorada da lógica clássica onde o elemento possui um grau de pertinência que indica o quanto ele vai pertencer a determinado conjunto.

A lógica *fuzzy*, foi criada pelo matemático *Lotfi Asker Zadeh* em 1965 como forma de tentar aprimorar a lógica clássica para trabalhar com incertezas. Na lógica clássica, as proposições são consideradas apenas como verdadeira ou falsa. Já na lógica *fuzzy* associamos a cada proposição  $p$  um valor  $\mu(p)$ , que indica o seu grau de veracidade ou de pertinência a determinado conjunto. Esta lógica modela dados de raciocínio imprecisos, usando os casos precisos como situações limite.

A função  $\mu(p)$  tem como imagem os valores do intervalo  $[0;1]$ , caso  $p$  seja totalmente verdadeira será associada ao grau de pertinência 1, caso  $p$  seja falsa terá o grau de pertinência 0. Desta forma, a lógica *fuzzy* permite infinitos graus de veracidade para a proposição  $p$ , que são todos os valores entre 0 e 1.

Por exemplo, se desejamos classificar o copo mostrado na figura 7 como cheio ou vazio usando a lógica clássica teremos problemas, pois o copo não está totalmente cheio e o conceito de cheio ou vazio depende do observador. Já utilizando a lógica *fuzzy* para fazer esta classificação, podemos atribuir um grau de pertinência para o conjunto cheio e outro grau para o conjunto vazio, como 0,6 cheio e 0,4 vazio.



Figura 7 – Copo com água parcialmente cheio.

#### 2.4.1 Teoria dos conjuntos *fuzzy*

Segundo a definição de um conjunto clássico, um objeto de um dado universo pode pertencer ou não pertencer a este conjunto. O critério que define quando o elemento vai pertencer ou não ao conjunto é bem rigoroso. Porém, a propriedade que caracteriza o elemento do conjunto deve estar bem definida, senão podem

aparecer situações de subjetividade na classificação. Para tratar estas propriedades mais subjetivas, foi introduzida a Teoria dos Conjuntos *Fuzzy* pelo matemático *Lotfi Asker Zadeh* (ZADEH, 1965). Esses conjuntos nos permitem tratar de termos subjetivos como “aproximadamente”, “em torno de”, etc.

Por exemplo, um indivíduo acha que determinada pessoa é alta, porém podem existir pessoas que discordem, ou concordem parcialmente, ou seja, não alta ou que achem razoavelmente alta. Assim, os critérios diferentes de alto ou baixo, geram ambiguidades e são subjetivos. Podemos tratar este caso utilizando a definição de conjunto *fuzzy* (BARROS; BASSANEZI, 2006).

A teoria dos conjuntos *fuzzy* trata esses tipos de casos atribuindo a cada elemento um grau de pertinência ao conjunto, que pode ser um valor entre zero e um, onde o grau zero indica que o elemento não pertence ao conjunto e quanto mais próximo o grau estiver de um indica que ele pertence mais ao conjunto.

A formalização matemática de um conjunto *fuzzy* foi baseada nos conjuntos clássicos, levando em conta que todo conjunto clássico é caracterizado por uma função chamada de função característica, mostrada na equação (3) (TERANO et al., 1994).

$$\chi_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases} \quad (3)$$

Seguindo a regra acima, temos que  $\chi_A(x) = 1$  indica que o elemento  $x$  está em  $A$ , enquanto  $\chi_A(x) = 0$  indica que  $x$  não é elemento de  $A$ . Então, esta função descreve o conjunto  $A$ , indicando quais elementos do universo pertencem a esse conjunto. Porém, nos casos em que a pertinência dos elementos não é tão precisa é necessário utilizar os conjuntos *fuzzy* para fazer essa caracterização. Estes conjuntos são definidos a partir da função de pertinência.

#### 2.4.1.1 Função de pertinência

Um conjunto *fuzzy*  $A$  definido no universo de discurso  $X$  é caracterizado por uma função de pertinência  $\mu_A$  que mapeia os elementos de  $X$  no intervalo  $[0;1]$ .

Assim, a função de pertinência associa um número real  $\mu_A(x)$  a cada elemento  $x$  do universo. Este valor representa o grau de pertinência do elemento  $x$  ao conjunto  $A$  e pertence ao intervalo  $[0;1]$ . Neste caso, uma sentença pode ser parcialmente verdadeira e parcialmente falsa (TERANO et al., 1994).

Para exemplificar, podemos utilizar a imagem do copo mostrada na figura 7, supondo que a capacidade total do copo seja de 200 ml. Considerando que o copo está cheio se tiver 190ml ou mais, podemos representar a sua função característica através da equação (4):

$$\chi_{Cheio}(x) = \begin{cases} 1, & \text{se } x \geq 190 \\ 0, & \text{se } x < 190 \end{cases} \quad (4)$$

Essa função característica também pode ser representada pelo gráfico mostrado na figura 8.

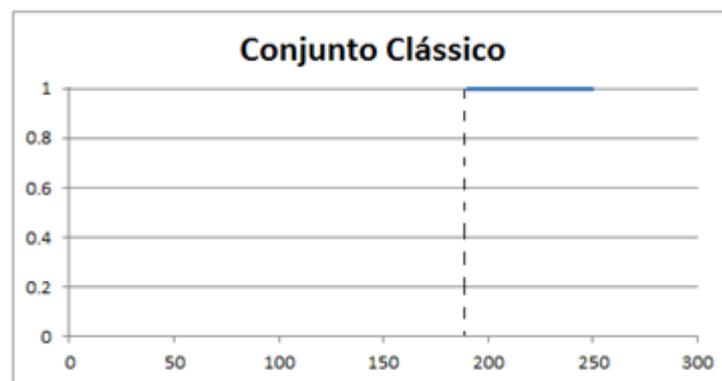


Figura 8 – Gráfico da função característica para classificar o copo como cheio.

Podemos observar que esta função característica não nos dá resultados precisos. Por exemplo, se o copo tiver com 170ml será considerado vazio, sendo que ele está mais próximo de estar cheio do que vazio.

Para trabalhar com esta subjetividade na classificação podemos utilizar conjuntos *fuzzy*. Porém, em alguns casos se torna difícil representar uma função de pertinência computacionalmente devido ao universo ser infinito. Para isso, é necessário transformar esse universo em uma forma finita fazendo o uso de expressões matemática que o representam. Assim, podemos representar uma função de pertinência por uma ou mais expressões matemáticas definidas dentro do

universo, desde que o resultado seja valores no intervalo [0;1] (BARROS; BASSANEZI, 2006). Considerando a função de pertinência mostrada na equação (5) podemos caracterizar com mais precisão o quanto o copo está cheio:

$$\mu_{Cheio}(x) = \begin{cases} 1, & \text{se } x \geq 190 \\ 0,0052x, & \text{se } x < 190 \end{cases} \quad (5)$$

A função de pertinência também pode ser analisada através do gráfico mostrado na figura 9. Assim, é possível verificar o quanto este copo pertence ao conjunto *fuzzy* cheio mesmo ele não estando totalmente cheio.

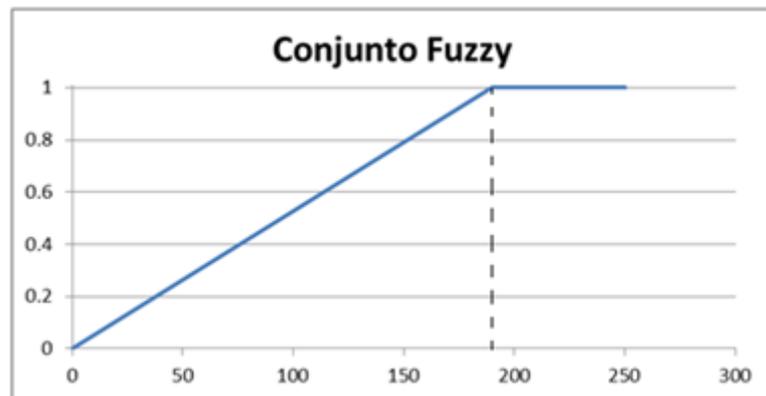


Figura 9 – Gráfico da função de pertinência para classificar o copo como cheio.

Um conjunto *fuzzy* A é expresso como um conjunto de pares ordenados. Neste par, o primeiro termo corresponde ao valor do objeto em alguma unidade de medida (metros, graus, quilos, *pixels*, etc.), e o segundo termo é o grau de pertinência deste objeto ao conjunto *fuzzy* em questão. Esse grau de pertinência é obtido através da função de pertinência do conjunto *fuzzy*. Esse conjunto é totalmente caracterizado por esta função de pertinência (BARROS; BASSANEZI, 2006).

Na equação (6) é mostrado como é representado um conjunto *fuzzy* A. Esse conjunto é expresso pelo par ordenado  $(x, \mu(x))$ , onde  $x$  é o valor do objeto em alguma unidade de medida e  $\mu(x)$  é o seu grau de pertinência ao conjunto A, sendo que  $x$  deve pertencer a um conjunto universo X.

$$A = \{(x, \mu(x)) | x \in X\} \quad (6)$$

Formalmente, o conjunto *fuzzy* difere do conjunto clássico apenas pelo amplo contradomínio, já que o do conjunto clássico é o conjunto  $\{0, 1\}$  e o do conjunto *fuzzy* está no intervalo  $[0; 1]$ . Então podemos afirmar que um conjunto clássico é um caso particular de um conjunto *fuzzy*, cuja função de pertinência é a sua função característica. Este subconjunto clássico do conjunto *fuzzy* é chamado de subconjunto *crisp*.

As funções de pertinência podem ser classificadas em diversos tipos de acordo com sua representação gráfica. Alguns desses tipos são: trapezoidal, triangular, senoidal, semi-trapezoidal, etc (BARROS; BASSANEZI, 2006).

#### 2.4.1.2 Operações sobre conjuntos *fuzzy*

Como os conjuntos *fuzzy* são uma extensão dos conjuntos clássicos, assim como para conjuntos clássicos, também temos as operações de união, intersecção e complemento para os conjuntos *fuzzy*.

Sejam A e B dois conjuntos *fuzzy* sobre um universo U com funções de pertinência  $\mu_A$  e  $\mu_B$ , respectivamente. Para todo  $x \in U$  temos definidas as operações de:

- União:  $\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x))$
- Intersecção:  $\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x))$
- Complemento:  $\mu_{\bar{A}}(x) = 1 - \mu_A(x)$

Essas operações satisfazem algumas propriedades, tais como: comutatividade, associatividade, involução, idempotência, Elemento neutro, elemento absorvente, distributividade, leis de De Morgan, leis de absorção. Porém, as leis do terceiro excluído e a da contradição só se aplicam aos conjuntos clássicos (TERANO et al., 1994).

Existem outras operações aplicáveis aos conjuntos *fuzzy*, entre elas está o  $\alpha$ -corte. O  $\alpha$ -corte considera apenas os valores do conjunto com valor maior que  $\alpha$ .

#### 2.4.2 Conceitos da lógica *fuzzy*

O termo “lógica *fuzzy*” pode ser utilizado para representar informações imprecisas na tomada de decisões, usando a teoria dos conjuntos *fuzzy* e suas funções de pertinência. Também pode ser usado para se referir a uma extensão da lógica clássica (BARROS; BASSANEZI, 2006).

Nos subitens 2.1.2.1 e 2.4.2.2 mostramos as diferenças entre os conceitos básicos da lógica *fuzzy* e a lógica clássica.

##### 2.4.2.1 Lógica clássica

Na lógica clássica temos alguns conectivos lógicos que são muito utilizados. Esses conectivos são símbolos que nos permitem construir expressões lógicas a partir de proposições. Estas proposições também podem ser chamadas de fórmulas atômicas, que são os elementos indivisíveis da lógica. São utilizadas letras minúsculas para representar estas proposições em uma expressão lógica, mas quando são muitas as proposições costuma-se utilizar a letra  $p$  acompanhada de um número natural para representá-las ( $p_0, p_1, p_2, \dots$ ). São utilizados parênteses como delimitadores que separam as expressões, com a finalidade de evitar ambiguidades.

Os conectivos lógicos utilizados são:

$\neg$  Negação (não)

$\wedge$  Conjunção (e)

$\vee$  Disjunção (ou)

$\rightarrow$  Implicação (se ... então)

$\leftrightarrow$  Equivalência (se, e somente se)

Os conectivos de conjunção, disjunção, implicação e equivalência são operadores matemáticos binários, ao contrário do conectivo de negação, que é um operador unário (BARROS; BASSANEZI, 2006). Eles são usados em sentenças do tipo “Se  $p$  e  $q$ , então  $r$  ou não  $s$ .” e o valor lógico dessas sentenças formadas é obtido por meio da composição de tabelas verdade dos conectivos presentes na sentença.

Na lógica clássica, as sentenças verdadeiras tem valor lógico 1, já as sentenças lógicas falsas tem valor lógico 0. Assim podemos formar as tabelas 2, 3, 4, 5 e 6 que representam a tabela verdade de cada um dos conectivos lógicos, considerando as proposições  $p$  e  $q$ .

Tabela 2 – Tabela verdade da negação.

$p$	$\neg p$
1	0
0	1

Tabela 3 – Tabela verdade da conjunção.

$p$	$q$	$p \wedge q$
1	1	1
1	0	0
0	1	0
0	0	0

Tabela 4 – Tabela verdade da disjunção.

$p$	$q$	$p \vee q$
1	1	1
1	0	1
0	1	1
0	0	0

Tabela 5 – Tabela verdade da implicação.

$p$	$q$	$p \rightarrow q$
1	1	1
1	0	0
0	1	1
0	0	1

Tabela 6 – Tabela verdade da equivalência.

$p$	$q$	$p \leftrightarrow q$
1	1	1
1	0	0
0	1	0
0	0	1

Analisando as tabelas verdade, podemos observar que a conjunção dos valores lógicos  $p$  e  $q$  sempre terá como resultado o menor valor entre eles, e que na disjunção sempre teremos como resultado o maior valor entre  $p$  e  $q$ .

#### 2.4.2.1 Lógica *fuzzy*

Par avaliar logicamente uma expressão por meio dos conectivos da lógica clássica, a expressão deve assumir apenas valores 0 ou 1. Porém, ao trabalhar com conjuntos *fuzzy* essa avaliação já não se torna possível. Pois, na lógica *fuzzy* é atribuído um valor que indica o quanto a proposição é verdadeira, e este valor está no intervalo  $[0; 1]$  (BARROS; BASSANEZI, 2006).

Devemos estender os conectivos para que seja possível trabalhar com lógica *fuzzy*. Tais extensões são obtidas por meio de normas e conormas triangulares. Esses operadores vêm de estudos de Espaços Métricos Estatísticos (MENGER, 1942). Essas normas são denominadas de t-normas e t-conormas.

Os conectivos que utilizamos para trabalhar com lógica *fuzzy* são: t-norma, t-conorma, negação e implicação *fuzzy*. Mas, para esses conectivos serem válidos

devem satisfazer algumas propriedades. A operação t-norma estende o operador  $\wedge$  do conectivo “e” e a operação t-conorma estende o operador  $\vee$  do conectivo “ou” (BARROS; BASSANEZI, 2006).

Um operador  $\Delta: [0, 1] \times [0, 1] \rightarrow [0, 1]$ ,  $\Delta(x, y) = x \Delta y$  é uma t-norma se ele satisfaz as seguintes propriedades:

- a) Elemento neutro:  $\Delta(1, x) = 1 \Delta x = x$ ;
- b) Comutativa:  $\Delta(x, y) = x \Delta y = y \Delta x = \Delta(y, x)$ ;
- c) Associativa:  $x \Delta (y \Delta z) = (x \Delta y) \Delta z$ ;
- d) Monotonicidade: se  $x \leq u$  e  $y \leq v$ , então  $x \Delta y \leq u \Delta v$ .

Um operador  $\nabla: [0, 1] \times [0, 1] \rightarrow [0, 1]$ ,  $\nabla(x, y) = x \nabla y$  é uma t-conorma se satisfaz as seguintes propriedades:

- a) Elemento neutro:  $\nabla(0, x) = 0 \nabla x = x$ ;
- b) Comutativa:  $\nabla(x, y) = x \nabla y = y \nabla x = \nabla(y, x)$ ;
- c) Associativa:  $x \nabla (y \nabla z) = (x \nabla y) \nabla z$ ;
- d) Monotonicidade: se  $x \leq u$  e  $y \leq v$ , então  $x \nabla y \leq u \nabla v$ .

Um operador  $\eta: [0, 1] \rightarrow [0, 1]$  é uma negação se satisfaz as seguintes propriedades:

- a) Fronteiras:  $\eta(0) = 1$  e  $\eta(1) = 0$ ;
- b) Involução:  $\eta(\eta(x)) = x$ ;
- c) Monotonicidade:  $\eta$  é decrescente.

Um operador  $\Rightarrow: [0, 1] \times [0, 1] \rightarrow [0, 1]$  é uma implicação *fuzzy* se satisfaz as seguintes propriedades:

- a) reproduz a tabela da implicação clássica;
- b) é decrescente na primeira variável, ou seja, para cada  $x \in [0, 1]$  tem:

$$(a \rightarrow x) \leq (b \rightarrow x) \text{ se } a \geq b;$$

- c) é crescente na segunda variável, ou seja, para cada  $x \in [0, 1]$  tem:

$$(x \rightarrow a) \geq (x \rightarrow b) \text{ se } a \geq b.$$

Na lógica *fuzzy* as implicações não tem a mesma forma que na lógica clássica. Essas implicações são denominadas de S-implicação, Q-implicação e R-implicação, e tem a forma:

- S-implicação:  $(x \rightarrow y) = N(x) \nabla y$  União:  $\mu A \cup B(x) = \max(\mu A(x), \mu B(x))$
- Q-implicação:  $(x \rightarrow y) = N(x) \nabla (x \Delta y)$
- R-implicação:  $(x \rightarrow y) = \sup\{z \in [0, 1]: x \Delta z \leq y\}$

Em Barros e Bassanezi (2006) temos algumas t-normas, t-conormas, negações e implicações *fuzzy* que podemos utilizar, dentre elas estão a de Goguen, de Lukasiewicz, de Reichenbach, e uma das mais usadas que é a de Mamdani, a qual é utilizada neste trabalho.

O modelo de inferência de Mamdani Clássico faz uso da t-norma do mínimo para o conectivo lógico “e” e a t-conorma do máximo para o conectivo “ou”.

#### 2.4.3 Sistemas baseados em regras *fuzzy*

Os sistemas baseados em regras *fuzzy* são utilizados em diversas áreas, como por exemplo em aparelhos domésticos. Estes sistemas nos permitem traduzir termos linguísticos em fórmulas matemáticas com a ideia de controlar certas tarefas. Este controle é feito por meio da linguagem usual utilizando variáveis linguísticas, que traduzidas por conjuntos *fuzzy* transcrevem uma base de conhecimento através de uma coleção de regras, denominada base de regras *fuzzy*. Através desta base de regras é obtida a saída para cada possível entrada (BARROS; BASSANEZI, 2006).

Os controladores *fuzzy* reproduzem a estratégia de um controlador humano. Eles são um caso típico de Sistemas Baseados em Regras *Fuzzy* (SBRF). Ou seja, são sistemas que produzem saídas *crisp* para as entradas *fuzzy* (BARROS; BASSANEZI, 2006).

### 2.4.3.1 Base de Regras

Num sistema SBRF é a base de regras quem traduz matematicamente a base de conhecimentos do sistema. Para isso, em cada caso específico ela deve ser elaborada por um especialista da área para evitar imprecisões nos resultados.

Nos SBRF cada proposição está na forma: Se “estado” então “resposta”, sendo que cada estado e cada resposta são variáveis linguísticas modeladas pelo conjunto *fuzzy*. Os conjuntos *fuzzy* que compõem o estado são chamados de antecedentes e os que compõem a resposta são chamados de consequentes. Uma base de regras *fuzzy* tem a forma mostrada na tabela 7.

Tabela 7 – Modelo de base de regras *fuzzy*.

Regra	Proposição
R1	Se “estado_1” então “resposta_1”
R2	Se “estado_2” então “resposta_2”
...	...
Rn	Se “estado_n” então “resposta_n”

### 2.4.3.2 Controlador *fuzzy*

Outra parte que compõe um SBRF é conhecida como controlador *fuzzy*. Estes controladores modelam sistemas que possuem certo grau de incerteza, trabalhando com variáveis linguísticas e graus de pertinência. É formado por alguns módulos, cada um responsável por uma etapa na geração da saída. Os módulos são: módulo de fuzzificação, módulo de tomada de decisão e módulo de defuzzificação, sendo que o módulo de tomada de decisão é dividido em subsistemas (BARROS; BASSANEZI, 2006). A figura 10 ilustra a ideia do funcionamento de um controlador *fuzzy*.

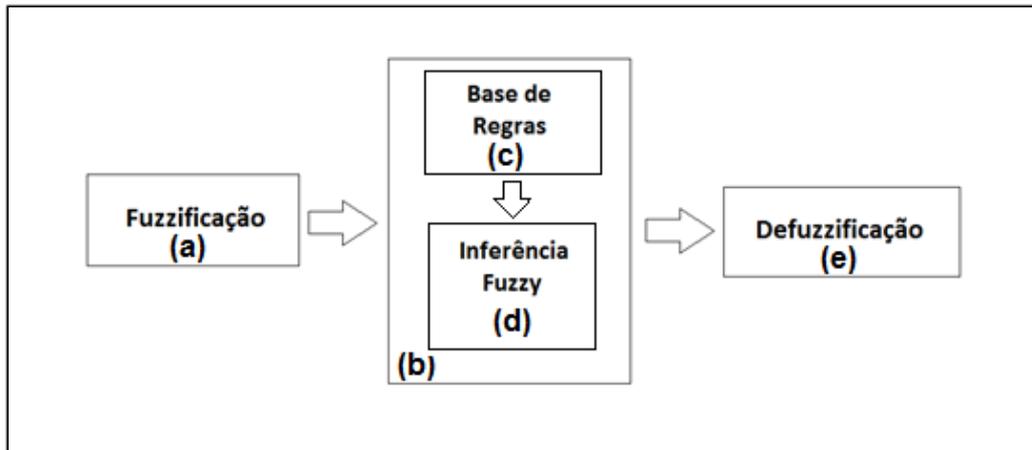


Figura 10 – Esquema de um controlador *fuzzy*.

No módulo de *fuzzificação* (figura 10 a) é onde se realiza a modelagem das entradas para os conjuntos *fuzzy*. É necessária a participação de especialistas na área para a formulação das funções de pertinência dos conjuntos envolvidos no processo. Caso a entrada seja *crisp*, deve ser *fuzzificada* por meio de sua função característica (BARROS; BASSANEZI, 2006).

O módulo de tomada de decisão (figura 10 b) encontra-se dividido em dois subsistemas, o sistema de base de regra e o sistema de inferência.

O sistema de base de regras (figura 10 c) é composto por proposições escritas na forma “Se  $x_1$  é  $A_1$  e  $x_2$  é  $A_2$  e ...  $x_n$  é  $A_n$  então  $u_1$  é  $B_1$  e  $u_2$  é  $B_2$  e ...  $u_m$  é  $B_m$ ”. Onde “ $x_1$  é  $A_1$ ”, “ $x_2$  é  $A_2$ ” e “ $x_n$  é  $A_n$ ” são estados e “ $u_1$  é  $B_1$ ”, “ $u_2$  é  $B_2$ ” e “ $u_m$  é  $B_m$ ” são respostas da base de regras. É nele que são feitas as classificações e modelagens *fuzzy* das variáveis e funções de pertinência.

Já o sistema de inferência *fuzzy* se encarrega de fazer as traduções de cada proposição *fuzzy*. São definidas as t-normas e t-conormas e regras de inferência para modelar a base de regras. É o sistema de inferência que examina a base de regras e dá a saída *fuzzy* do controlador.

As t-normas e t-conormas utilizadas são definidas pelo modelo de inferência. Na maioria dos controladores *fuzzy* é utilizado o modelo de inferência de Mamdani Clássico, porém existem outros que também podem ser utilizados como, por exemplo, o TSK, Larsen e Tsukamoto. Para definir qual modelo usar deve-se

entender o sistema modelado para se saber o que se espera obter como resposta (BARROS; BASSANEZI, 2006).

Finalmente o módulo de *defuzzificação* (figura 10 e) é o encarregado de converter a saída do módulo de inferência em saídas *crisp*.

Como toda entrada do módulo de inferência é *fuzzy* devido ao processo de *fuzzificação*, ele sempre retornará uma saída *fuzzy*. Porém, se a entrada deste controlador for *crisp*, espera-se que a saída também seja *crisp*.

Alguns métodos de *defuzzificação* comuns são: Centro de gravidade, centroide ou centro de área, centro dos máximos e a média dos máximos (BARROS; BASSANEZI, 2006).

## 2.5 Algoritmos de *clusterização*

Algoritmos de agrupamento de dados (ou *clusterização*) consistem em separar dados em agrupamentos chamados de *clusters* de acordo com características semelhantes. Esse agrupamento separa os objetos da base de dados de acordo com seu grau de similaridade, ou seja, objetos mais similares ficam no mesmo *cluster* e objetos menos similares ficam em *clusters* diferentes (YONAMINE et al., 2002).

Na *clusterização* é escolhida uma medida de proximidade e definida uma função de critério. Os objetos são agrupados de acordo com sua semelhança. A medida de proximidade e a função de critério definem o quanto os objetos podem ser semelhantes para pertencerem ao mesmo *cluster* (YONAMINE et al., 2002).

Um passo importante na *clusterização* é a escolha de um critério que meça a similaridade entre dois objetos, ou seja, um critério que diga o quanto dois objetos são semelhantes ou distintos. Quanto maior o valor encontrado, mais dissimilares são os objetos. Quanto menor o valor, mais similares (YONAMINE et al., 2002). A escolha do critério de semelhança depende basicamente do tipo de variável envolvida. Para cada tipo existe uma ou mais medidas de similaridade a ser aplicada.

A similaridade entre dois pares de objetos pode ser calculada por qualquer medida de distância. Dentre as medidas de distância, a Euclidiana é a mais usual. Para calcular a distância entre dois objetos ( $i$  e  $j$ ) com dimensão  $p$  (número de variáveis), ela é definida na equação (7):

$$d(i, j) = \sqrt{\sum_{l=1}^p (x_{il} - x_{jl})^2} \quad (7)$$

A distância Euclidiana possui uma gama de derivações, tais como: Distância Euclidiana Média, Distância Euclidiana Padronizada, Coeficiente da Distância Euclidiana Padronizada e Distância Euclidiana Ponderada. Segundo Bussab et al. (1990), uma derivação muito usada na *clusterização* é Distância Euclidiana Média (DEM), onde a soma das diferenças ao quadrado é dividida pelo número total de objetos, conforme é mostrado na equação (8):

$$d(i, j) = \sqrt{\frac{\sum_{l=1}^p (x_{il} - x_{jl})^2}{p}} \quad (8)$$

Além das medidas de distância já citadas, existem outras medidas que podem ser usadas como, por exemplo, o Valor Absoluto e a distância Manhattan. Outras medidas de distância poderão ser definidas, segundo Pison et al. (1999) e Berry e Linoff (1997).

A quantidade de *clusters* pode ser conhecida ou não. Caso este valor seja fornecido como parâmetro para a solução, o problema é referenciado na literatura como “problema de  $k$  *clusterização*” (FASULO, 1999). Caso contrário, isto é, caso não seja estimado previamente, o problema é chamado de “problema de *clusterização* automática” (PCA) e a obtenção deste valor faz parte do processo de solução do problema, como em (DOVAL et al., 1999).

Os métodos de *clusterização* vêm sendo cada vez mais aplicados na solução de problemas em diversas áreas do conhecimento, por exemplo, computação

gráfica, biologia computacional, redes de comunicações, engenharia de transportes, entre outras.

A aplicação desses algoritmos no estudo de imagens é uma técnica moderna que permite classificar regiões da imagem considerando as características específicas destas como, por exemplo, densidade e cor. Basicamente o algoritmo consiste em agrupar em um *cluster* objetos com características similares e diferentes dos agrupados em outros *clusters*.

### 2.5.1 Algoritmo *k-means*

Dentre os algoritmos de *clusterização* um dos mais comumente utilizado é o *k-means*. Segundo MacQueen (1967), o *k-means* é baseado em médias que particiona um conjunto de pontos em *k clusters*. A ideia deste algoritmo é fornecer uma classificação de informações de acordo com os próprios dados. Possui um grande número de variações que o adaptam a diversos tipos de problemas e é considerado como um algoritmo de mineração de dados não supervisionado, ou seja, gera suas saídas de acordo com os dados de entrada sem interferências.

O *k-means* inicia escolhendo os *k* objetos que serão os centros iniciais. Estes centros são os elementos representativos de cada *cluster*, pois eles que influenciam nas iterações seguintes. Sua escolha pode ser feita de diversas formas, como por exemplo, escolhendo *k* centros aleatoriamente, escolhendo os *k* primeiros objetos, ou até mesmo escolhendo *k* objetos que sejam muito diferentes.

Depois de ter os centros iniciais selecionados, é calculada a distância de cada objeto em relação a cada um desses centros. Cada objeto será agrupado no *cluster* que o centro tiver menor distância em relação a ele. Assim é feito o primeiro agrupamento.

Com todos os objetos agrupados em seus respectivos *clusters*, são calculados novos centros para cada *cluster*. O novo centro é calculado tirando a média dos elementos que pertencem ao *cluster*, conforme a equação (9) (MACQUEEN, 1967):

$$c_j = \frac{\sum_{i=1}^{n^{(j)}} x_i^{(j)}}{n^{(j)}} \quad (9)$$

Onde  $x_i^{(j)}$  é um elemento associado ao *cluster*  $j$  e  $n^{(j)}$  é o número de elementos do *cluster*  $j$ .

A partir desses novos centros dos *clusters* os objetos são reagrupados de acordo com a sua distância em relação a esses novos centros. Este passo é repetido até que não haja mais alteração nos *clusters* ou um determinado número de iterações seja atingido (MACQUEEN, 1967).

### 2.5.2 Algoritmo *fuzzy c-means*

Outro algoritmo utilizado na *clusterização* de dados é o *fuzzy c-means* (FCM). O algoritmo de *clusterização* FCM foi proposto por (DUNN, 1973) e estendido por (BEZDEK, 1981). Este algoritmo tem como entrada o número desejado de *clusters*  $C$ , os dados que serão agrupados, uma distância  $m > 1$  que define a distância permitida entre os objetos e o centro do *cluster* e também é chamada de índice de *fuzzificação*, um número pequeno  $\varepsilon > 0$  que é utilizado como critério de parada. Quanto maior o valor de  $m$ , são inclusos elementos com menos similaridades no *cluster*, gerando ruídos na *clusterização*. Esse parâmetro é escolhido de acordo com o problema considerado. A ideia basicamente é de que o conjunto de objetos seja dividido em  $C$  *clusters*, o resultado do agrupamento é expresso por uma matriz contendo os graus de pertinência de cada objeto a cada *cluster*.

O algoritmo FCM é definido nos 4 passos a seguir (YONAMINE et al., 2002):

1º passo: Na primeira iteração, que é a iteração  $t=0$  devem ser definidos os valores de  $C$ ,  $\varepsilon$ ,  $m$  e as matrizes de pertinência  $A_i$  de cada *cluster*  $i$ , onde  $i=1$  até  $C$ . Com a definição inicial destas matrizes, é obtida a partição  $P^{(0)} = \{A_1, A_2, \dots, A_C\}$ . Ainda na primeira iteração devem ser definidos os centros dos *clusters* iniciais  $v_1^{(0)}, v_2^{(0)}, \dots, v_c^{(0)}$ . A inicialização dos valores das matrizes de pertinência e dos centros dos *clusters* podem ser feitas de forma aleatória ou inseridas pelo usuário.

2º passo: A partir da iteração  $t=1$ , os novos centros  $v_1^{(t)}, v_2^{(t)}, \dots, v_c^{(t)}$  são recalculados seguindo a equação (10):

$$v_i = \frac{\sum_{k=1}^n [A_i(x_k)]^m x_k}{\sum_{k=1}^n [A_i(x_k)]^m} \quad (10)$$

Onde  $n$  é a quantidade de objetos contidos no *cluster*  $i$  e  $x$  são esses objetos. Esse cálculo é a média ponderada dos dados de  $A_i$ .

3º passo: As matrizes de pertinência são atualizadas neste passo. É calculada a distância de todo objeto aos centros de todos os *clusters* e para os *clusters* que a distância for maior que 0, é calculado o grau de pertinência do objeto em relação a ele seguindo a equação (11):

$$A_i^{(t+1)}(x_k) = \left[ \sum_{j=1}^c \left( \frac{\|x_k - v_i^{(t)}\|^2}{\|x_k - v_j^{(t)}\|^2} \right)^{\frac{1}{m-1}} \right]^{-1} \quad (11)$$

Levando em conta que  $\|x_k - v_i^{(t)}\|^2$  representa a distância entre  $x_k$  e  $v_i$ . Nessa fórmula é comparada a distância do objeto ao centro do *cluster*  $A_i$  com a distância desse mesmo objeto aos centros dos outros *clusters*, para que seja atribuído um grau de pertinência do objeto ao *cluster*  $A_i$  que seja proporcional ao seu grau de pertinência aos outros *clusters*.

Se a distância do objeto ao centro do *cluster*  $A_i$  for igual a 0, considera-se que ele é o centro do *cluster*. Então deve ser atribuído o grau de pertinência 1 a este objeto no *cluster*  $A_i$  e 0 aos demais *clusters*.

4º passo: Nesta etapa é verificado o critério de parada do algoritmo. É calculada a distância de  $P^{(t)}$  e  $P^{(t+1)}$ , representada por  $|P^{(t)} - P^{(t+1)}|$  que é calculada com a equação (12) que verifica se a máxima diferença entre o grau de pertinência de qualquer elemento  $x$  a um *cluster*  $A_i$  na iteração atual e na iteração anterior é menor que o erro definido:

$$|P^{(t)} - P^{(t+1)}| = \max_{i \in N_c, k \in N_n} |A_i^{(t+1)}(x_k) - A_i^{(t)}(x_k)| \quad (12)$$

Caso  $|P^{(t)} - P^{(t+1)}| \leq \varepsilon$ , o algoritmo para de ser executado e retorna as matrizes de pertinência atuais.

Após a última iteração, as matrizes de pertinência devem ser testadas para verificar se os objetos dos *clusters* estão fortemente associados e fracamente associados com os objetos de outro *cluster*. Para isso podemos utilizar o índice de desempenho  $J_m(P)$ , que mede a soma das distancias de cada elemento a cada um dos centros dos *clusters*. Quanto menor o seu valor, melhor a *clusterização*. O índice  $J_m(P)$  é calculado com a equação (13):

$$J_m(P) = \sum_{k=1}^n \sum_{i=1}^c [A_i(x_k)]^m \|x_k - v_i\|^2 \quad (13)$$

## 2.6 Estado da arte

O presente trabalho pretende caracterizar a estrutura interna de argamassas leves reforçadas com fibras de piaçaba, usando processamento de imagens obtidas por micro tomografia computadorizada e aplicando algoritmos de *clusterização* e SBRF.

A utilização de agregados leves como é o caso de EVA, em misturas de argamassas para a utilização na construção civil, é desejável, dadas suas características acústicas e térmicas entre outras. Estudos sobre a utilização deste tipo de resíduos vêm sendo realizados.

Garlet e Graven (1997) pesquisaram o reaproveitamento de resíduos de EVA da indústria calçadista em concretos leves e blocos de concreto pré-moldados e concluíram que tanto para os corpos-de-prova de concreto quanto para os blocos analisados, houve uma redução da resistência à compressão, e da massa específica, à medida que o teor de agregado de EVA era aumentado.

Em Garlet (1998) é descrito o estudo para o aproveitamento, na construção civil, do resíduo de EVA (*Ethylene Vinyl Acetate*), polímero muito utilizado na indústria calçadista para a confecção de solados e palmilhas internas de calçados.

Santiago et al. (2009) estudaram sobre o comportamento mecânico de concretos reciclados de misturas de resíduos de demolição e EVA. São realizados experimentos sobre o comportamento mecânico sob compressão a temperatura ambiente depois de submetidos a temperaturas moderadas.

Nivaldo et al. (2012) Desenvolveram elementos construtivos para forros e divisórias, a partir de matrizes cimentícias com incorporação de resíduos industriais (resíduo cerâmico, etil vinil acetato - EVA) e fibras de sisal. Desenvolveram técnicas de moldagem em matrizes cimentícias auto adensáveis e se avaliou a resistência mecânica dos novos compósitos.

Souza (2012) avalia o contributo das argamassas leves para o desempenho dos elementos onde estão integrados, apresentando-se uma sistematização do conhecimento existente. Faz uma síntese da normalização sobre argamassas e seus constituintes, define as características das argamassas leves, analisa uma solução prática inovadora existente no mercado, que é o reboco isolante. Deste modo, apresenta-se uma fundamentada caracterização das argamassas leves avaliando sua aplicação no reboco e assentamento de alvenarias.

Com a aparição destes materiais compostos, estudos se fazem necessários e a micro tomografia, como foi anteriormente descrita é uma alternativa não destrutiva para o estudo da estrutura interna desses materiais. Diversos estudos são realizando usando este método.

Quoirin (2004) aplicou a TC como técnica não destrutiva de avaliação de defeitos em madeira, que se mostrou eficiente para a visualização do interior de corpos de madeira. No trabalho foi desenvolvido um programa para controle do sistema tomográfico (rotação do objeto, aquisição e armazenamento de dados) e reconstrução de imagens, o que permitiu visualizar as seções transversais das amostras e verificar a presença e o comportamento de defeitos internos, possibilitando a avaliação da integridade física e dimensional. A técnica pode ainda ser aplicada à visualização dos anéis de crescimento e a alguns estudos fisiológicos.

Temos em Piekarz (2006) uma aplicação da TC para medir o volume de vazios existentes em isoladores poliméricos de linhas de distribuição de energia. A técnica mostrou-se eficiente para obtenção do volume em vazios no interior desses objetos até volumes inferiores a um milímetro cúbico. O autor utilizou técnicas do processamento de imagens para eliminação de ruídos presentes nas imagens.

Assis et al. (2007) calcularam o índice de porosidade da matriz do concreto a partir de imagens obtidas por  $\mu$ CT, utilizando técnicas de processamento de imagens e morfologia matemática. As imagens das amostras de concreto foram obtidas num sistema micro tomógrafo que gera imagens com 256 tons de cinza, ajustadas em contraste, binarizadas e filtradas utilizando a operação de erosão com elemento estruturante circular para a remoção de pontos isolados, interpretados como ruído. Nessas imagens são contados os vazios obtidos para determinar o índice de porosidade da matriz.

Em seu trabalho, Mendes (2010) analisou o concreto retirado de uma usina hidrelétrica. O trabalho apresentou uma metodologia para a visualização interna, obtenção do volume de britas, de vazios e de argamassa em estruturas de concreto além da estimativa da massa específica do concreto utilizando a TC.

Este é o caso Belini et al. (2011), que aplicou a  $\mu$ CT na análise da anatomia da madeira de *Amburana cearensis* e de *Pinus sp.* A  $\mu$ CT possibilitou a obtenção de imagens da estrutura macro e microscópica da madeira das duas espécies, permitindo a sua caracterização, descrição e comparação com a da literatura.

Silva et al. (2013) avaliaram a estrutura interna de misturas de argamassas leves, por análise de imagens a partir de  $\mu$ CT de raios X. A intenção desta pesquisa foi avaliar a resistência da mistura de argamassa com EVA e fibras de piaçava. Assim, o efeito de reforço com o elemento piaçava poderia ser medido. Também realizaram testes mecânicos para avaliar a resistência à tração em ensaios de flexão de três pontos e a resistência à compressão de compósitos. A incorporação de EVA resultou em perdas de resistência, mas foi parcialmente recuperada com o acréscimo das fibras. As fibras de piaçava, grãos de EVA, poros e micro fissuras foram identificados, quantificados e classificados a partir da aplicação de descritores de região tais como a área e a excentricidade.

As imagens bidimensionais e tridimensionais dos materiais obtidas usando micro tomografia podem ser manipuladas usando técnicas modernas de processamento de imagens.

Em seu trabalho, Albuquerque e Albuquerque (2000) dão uma visão da área de processamento digital de imagens e suas aplicações. Abordam conceitos importantes sobre a representação espacial de um *pixel*, a medida de distâncias, a segmentação de uma imagem e o reconhecimento de formas. Utilizam situações reais para exemplificarmos as técnicas apresentadas. Ao final discutem sobre os diversos pacotes existentes para processamento digital de imagens e apresentam uma bibliografia que nos permite que nos aprofundemos em processamento de imagens e visão por computador.

Em Pessôa et al. (2011) foram utilizados métodos não destrutivos (END), como a  $\mu$ CT com raio X e técnicas de obtenção e processamento de imagens, para obtenção da porosidade do concreto. Foram utilizados dois métodos, onde no primeiro as imagens foram obtidas por meio de micro tomografia por raio X e no segundo foi utilizado um escâner comercial para obtenção das imagens. Os resultados obtidos por micro tomografia foram mais confiáveis, mas o método utilizando o escâner comercial se apresentou como um método aceitável por seus resultados e principalmente por seu baixo custo e facilidade de operação.

Os materiais contidos nas amostras das imagens podem ser caracterizados por meio da aplicação de algoritmos de *clusterização*. Dentre estes algoritmos temos alguns que são aplicações da lógica *fuzzy*.

Cinque et al. (2004) apresentam uma abordagem baseada em agrupamentos para segmentação de imagens com base em uma abordagem *fuzzy* modificada para o modelo de segmentação de imagens. O objetivo da abordagem proposta é encontrar um modelo simples capaz de encontrar um protótipo para cada *cluster* evitando complexas fases de pós-processamento. Também é discutida a comparação com outros modelos similares apresentados na literatura e realizadas avaliações qualitativas e quantitativas para comprovar a validade da abordagem proposta.

Takahashi et al. (2005) apresentam a definição de imagens digitais intervalares e faz o estudo do seu processamento. Nesse processamento é descrita a segmentação de imagens digitais intervalares utilizando o método *k-means* intervalar, que é baseado no método de agrupamento *k-means* tradicional.

O objetivo do trabalho de Guiera et al. (2005) é identificar linhas de transmissão de energia elétrica em nuvens de pontos adquiridas pela técnica de mapeamento digital a laser, ou *LiDAR (Light Detection And Ranging)*, demonstrando uma aplicação bastante útil dessas imagens. Essa identificação das linhas de transmissão é feita processando o algoritmo de agrupamentos *FCM*. A técnica consiste em utilizar os níveis de cinza e altura, obtidos pelo processamento dos dados do *LiDAR*, e submetê-los à *clusterização*.

Em seu trabalho, Oke et al. (2012) focam em algoritmos de *clusterização*, especificamente no *k-means* e *FCM*. Fazem a combinação entre esses algoritmos para chegar em um método resultante, que é chamado de algoritmo de *clusterização fuzzy k-c-means*, que tem um melhor desempenho em termos de utilização do tempo. O algoritmo foi testado e comparado com o *k-means* e o *FCM* com Imagens de Ressonância Magnética (MRI) do cérebro humano.

Anuratha et al. (2012) mostra um estudo baseado na segmentação de imagens utilizando uma adaptação do algoritmo *fuzzy c-means*. O algoritmo *FCM* melhorado é composto pela modificação da medição de distância do algoritmo *FCM* original. A distância euclidiana no algoritmo *FCM* original é substituída pela distância de correlação no algoritmo *FCM* melhorado. O algoritmo adquirido é mais robusto, quando associado com o algoritmo *FCM* original.

Em Coelho et al. (2012) é apresentado o método de *clusterização FCM*, aplicado na segmentação de imagens dermatoscópicas de lesões de pele. Este tipo de segmentação é baseado no método de crescimento de região que o difere dos métodos convencionais de *clusterização* por utilizar o conceito de números *fuzzy*, uma vez que são apropriados para lidar com incertezas referentes as regiões de uma dada imagem. O método consiste em calcular o grau de pertinência de um dado *pixel* em relação as regiões que ele pode pertencer, definida por uma determinada vizinhança. Os autores aplicaram o método em três imagens de lesão

de pele sendo, dois melanomas e um nervo, obtendo-se três classes de *clusters* para cada imagem.

Em seu trabalho, Yambal e Gupta (2013) apresenta um recente levantamento de diferentes tecnologias utilizadas na segmentação de imagens médicas utilizando o algoritmo *FCM*. O algoritmo é utilizado para a segmentação do tecido cerebral para a detecção de tumor.

Estes *clusters* foram utilizados para calcular dois valores de limiar. Estes limiares foram aplicados no algoritmo de binarização, para a segmentação da imagem. Com o intuito de se verificar a eficiência deste método nestes tipos de imagem, as imagens segmentadas por meio do método *FCM* foram comparadas com as mesmas imagens segmentadas por meio de outro algoritmo de segmentação chamado de algoritmo de Otsu, obtendo-se assim uma segmentação visivelmente melhor do algoritmo *FCM* em relação ao de Otsu, isto ocorre devido à influência dos números *fuzzy*, onde um *pixel* pode pertencer a mais de uma região, porém com diferentes graus de pertinência.

### **3 MATERIAIS E MÉTODOS**

Neste capítulo é descrito o processo de caracterização das amostras de argamassa leve a partir de imagens adquiridas com micro tomografia computadorizada. É mostrado o processo de *clusterização* e a aplicação do controlador *fuzzy* na caracterização das amostras. O processo de caracterização das imagens inclui a aquisição e pré-processamento das imagens e a aplicação dos métodos de *clusterização* propostos

#### **3.1 Imagens das amostras**

Nesta seção abordaremos como foram preparados os corpos de prova, a aquisição por  $\mu$ CT das imagens e o pré-processamento destas imagens.

Os corpos de prova utilizados neste trabalho foram criados em (SILVA, 2011) para ensaios de resistência a compressão e tração na flexão e para a aquisição de

imagens por  $\mu$ CT. Foi utilizado cimento Portland tipo CP II – E 30, areia natural (agregado miúdo), água, grãos de EVA e fibras de piaçava na preparação destes corpos de prova.

Foram analisados corpos de prova de três tipos de misturas:

- Mistura A – água, cimento e areia;
- Mistura B – água, cimento, areia e agregado leve de EVA;
- Mistura C – água, cimento, areia, agregado leve de EVA e fibras de piaçava.

Estas amostras foram preparadas seguindo a norma brasileira de fabricação e endurecimento de corpo-de prova de concreto cilíndrico ou prismático (NBR 5738, 2003). A relação água/cimento para todas as misturas foi de 0,4 e a proporção de agregado leve de EVA e fibra de piaçava adicionada na mistura foi pré-determinada em 1% da massa de areia, cimento e água. A distribuição do tamanho das partículas de EVA varia entre 850 e 1180  $\mu$ m. As fibras de piaçava *in natura* foram separadas, limpadas e cortadas em pedaços de 1 cm de comprimento e utilizados os pedaços de sua parte mais dura. O Cimento Portland tipo CP II - E 30, utilizado em obras da construção civil, têm como características a resistência de 30 MPa aos 28 dias de cura e massa específica de 3,00 kg/cm<sup>3</sup>. Como agregado miúdo foi utilizado a areia natural, obtida em obras de construção civil da região.

Estes elementos foram misturados com auxílio de uma argamassadeira e moldados em fôrmas de 4,0 cm de largura e altura, e 16 cm de comprimento, para a produção dos corpos de prova prismáticos e em fôrmas com 5,0 cm de diâmetro e 10 cm de altura, para os corpos de prova cilíndricos.

Depois de realizadas as misturas, foram obtidas imagens das 1800 fatias 2D de 1148x1148 *pixels* em escala de tons de cinza que formam as imagens 3D usando um micro tomógrafo *Skyscan*® 1173 com corrente 61 $\mu$ A e tensão 130kV.

Devido às dimensões do porta amostras do micro tomógrafo, foi preciso cortar as amostras dos corpos de prova prismáticos em seções menores para realizar a aquisição das imagens. Para extrair estas amostras, os corpos de prova foram cortados na transversal em fatias de 2,5 cm de comprimento, 4 cm de altura e 4 cm de largura. Estas fatias transversais foram cortadas em sub amostras com

dimensões de 2,5 x 2,5 x 4 cm para serem enviadas ao micro tomógrafo, como está ilustrado na figura 11.

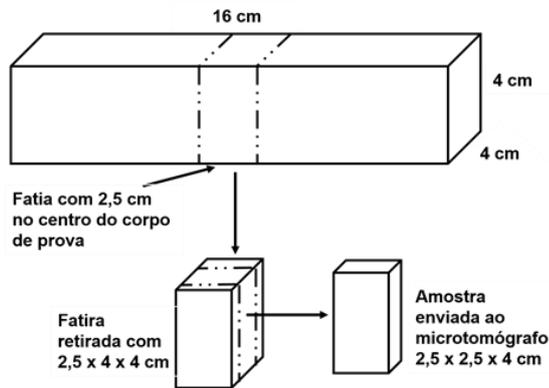


Figura 11 – Corte das amostras enviadas ao micro tomógrafo *Skyscan*® 1173.

Fonte: Almeida (2014).

A figura 12 mostra uma imagem gerada pelo *Skyscan*® 1173 para cada tipo de mistura (A, B e C):

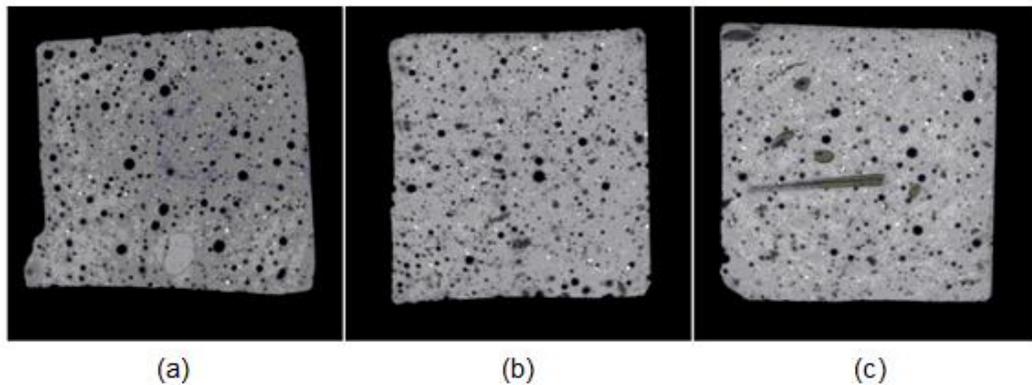


Figura 12 – Imagens geradas por micro tomografia para as amostras:

(a) mistura A, (b) mistura B e (c) mistura C.

Na figura 12 (a) temos uma imagem da amostra da mistura A, que contém apenas argamassa e poros (ar). A figura 12 (b) mostra uma das imagens da amostra com a mistura B, contendo argamassa, resíduos de EVA e poros (ar). A imagem mostrada na figura 12 (c) pertence à amostra com a mistura C, contendo argamassa, resíduos de EVA, poros (ar) e fibras de piaçava.

Foram utilizadas neste trabalho apenas as amostras que não passaram por nenhum tipo de ensaio, pois o objetivo é a identificação dos agregados. Trabalhos

futuros poderão utilizar a metodologia proposta para a identificação e análise de fissuras para CP ensaiados.

### 3.2 Pré-processamento

Utilizando as imagens obtidas por  $\mu$ CT, estas passaram pela fase de pré-processamento. Ao observar as imagens das amostras foi notado que além da região de interesse havia bordas totalmente pretas, ou seja, que possuem tom de cinza zero. Estas bordas são resultantes do processo de aquisição das imagens e sua presença acarreta em imprecisão na análise dos resultados. Para reduzir esta imprecisão foi desenvolvido um algoritmo de pré-processamento que elimina o tom de cinza zero das extremidades da amostra.

Este algoritmo percorre a imagem partindo das extremidades e indo para o centro, eliminando todos os pontos que possuem o tom de cinza zero até que encontre um tom de cinza de outro valor. Assim é feito para todas as amostras até que todas estejam sem bordas e possam ser processadas com melhor precisão. Este método gera uma pequena perda caso exista algum material representado pelo tom 0 próximo à borda, porém esta perda é mínima em comparação à possível imprecisão na *clusterização* das imagens com bordas pretas. A figura 13 mostra uma imagem de uma das fatias antes e depois do pré-processamento.

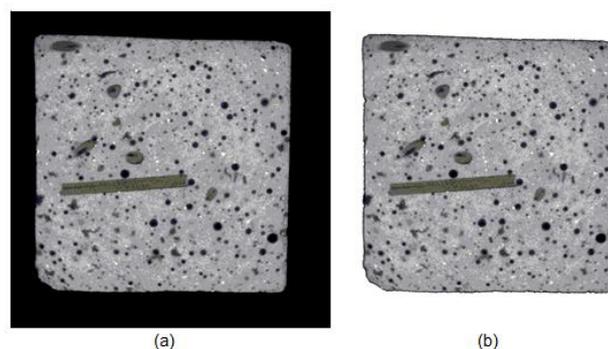


Figura 13 – Imagem da mistura C: (a) imagem original e (b) imagem após a eliminação do ruído.

A figura 13 corresponde a uma imagem que corresponde a uma fatia presente nas amostras da mistura C. Na figura 13 (a) temos a imagem original e na figura 13

(b) temos a imagem após a aplicação do algoritmo de pré-processamento para a eliminação dos ruídos nas bordas.

### 3.3 Algoritmo *k-means*

A primeira etapa de *clusterização* corresponde à aplicação do algoritmo *k-means* para *clusterizar* o intervalo de tons de cinza da imagem em  $k$  partes, sendo que tal intervalo está entre 0 e 255. A quantidade de *clusters* deve ser definida de acordo com a quantidade de materiais presentes nas amostra, devido à consideração de que a cor está relacionada com a densidade deste material. O algoritmo tem o valor de  $k$  inserido pelo usuário e o número máximo de 1000 iterações.

Foram realizados alguns testes e inspeções visuais para definir esta quantidade  $k$  de *clusters*, conforme está ilustrado nas figuras 15, 16 e 17 que mostram a *clusterização* dos tons de cinza da imagem mostrada na figura 14 com  $k=2$ ,  $k=3$  e  $k=4$ , respectivamente.

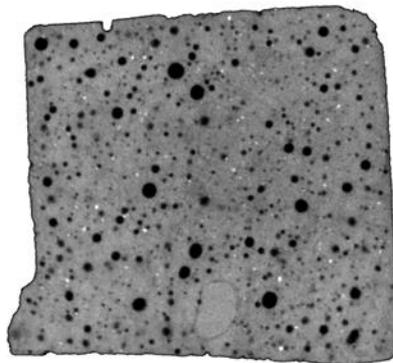


Figura 14 – Imagem original.

Na figura 15 é mostrado o resultado da aplicação do algoritmo *k-means* para *clusterizar* os tons de cinza da imagem ilustrada na figura 14 com  $k=2$ :

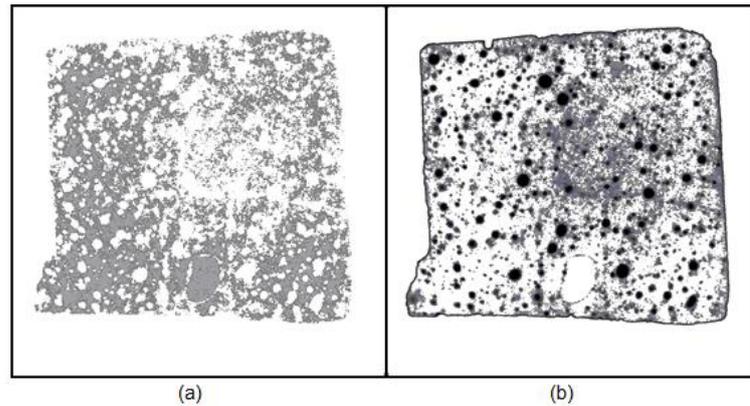


Figura 15 – Imagem da figura 14 *clusterizada* com  $k=2$ : (a) *cluster 1* e (b) *cluster 2*.

Conforme podemos observar na figura 15, a aplicação do *k-means* com  $k=2$  para essa *clusterização* não nos dá resultados satisfatórios. Pois, comparando com resultados obtidos por Meira Silva (2012) Almeida (2014) e Silva Mendonça (2016), no *cluster 2* estão contidos tons de cinza que representam tanto a argamassa quanto os demais materiais.

Na figura 16 temos o resultado da aplicação do algoritmo *k-means* para *clusterizar* os tons de cinza da imagem ilustrada na figura 14 com  $k=3$ :

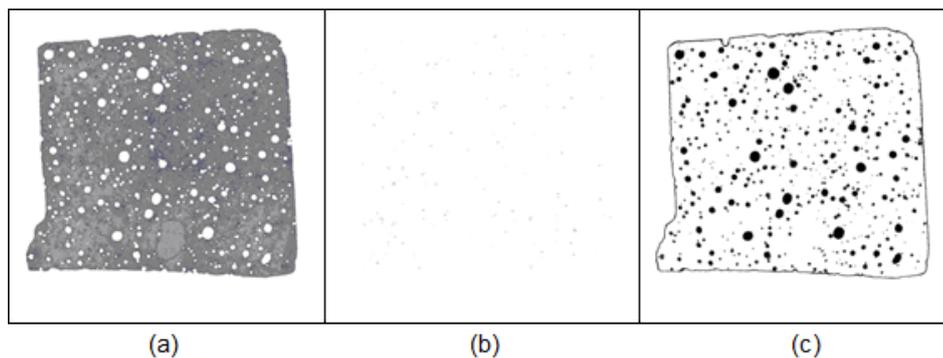


Figura 16 – Imagem *clusterizada* com  $k=3$ : (a) *cluster 1*, (b) *cluster 2* e (c) *cluster 3*.

Na figura 16, podemos afirmar que os *clusters 1* e *2* contém tons de cinza que representam a argamassa contida na amostra. No *cluster 1* este agrupamento está mais evidente, uma vez que no *cluster 2* estão contidos os tons de cinza mais claros que quase que são imperceptíveis na imagem. O *cluster 3* contém os tons de cinza

mais escuros, estes tons que representam os demais materiais contidos nas amostras, são eles: os poros (ar), o EVA e as fibras de piaçava.

Nos *clusters* resultantes da aplicação do algoritmo *k-means* com  $k=4$  nos tons de cinza da figura mostrada na figura 14 estão representados na figura 17:

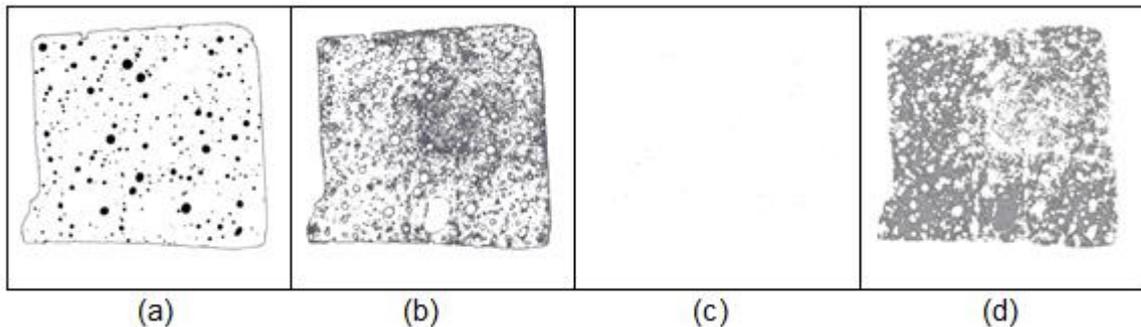


Figura 17 – Imagem *clusterizada* com  $k=4$ : (a) *cluster* 1, (b) *cluster* 2, (c) *cluster* 3 e (d) *cluster* 4.

Podemos observar na figura 17 que o *cluster* 1 contém os tons de cinza que representam o ar, o EVA e as fibras de piaçava nas imagens, que são os tons mais escuros. Por consequência, os demais *clusters* representarão a argamassa contida nas amostras.

Percebemos então que se utilizarmos o valor  $k=3$  ou  $k=4$  teremos resultados muito próximos, levando em conta que nas duas a argamassa foi separada dos demais materiais. Concluímos que os agregados não diferem muito, e ficam separados dos tons de cinza correspondentes à argamassa e que são semelhantes aos resultados obtidos por Meira Silva (2012), Almeida (2014) e Silva Mendonça (2016).

No entanto, com o valor de  $k=4$  temos uma separação desnecessária entre o *cluster* 2 e 4 já que ambos representam a argamassa. Porém, o intervalo de tons de cinza para as amostras é muito pequeno e os tons contidos neste *cluster* são muito próximos e os objetos ficam sempre no mesmo *cluster*. Então, para o nosso trabalho utilizamos o valor  $k=3$  para *clusterização* destes tons de cinza.

Foi realizada uma nova tentativa de *clusterização* no intervalo de tons de cinza que contém os agregados, ou seja, uma *reclusterização* com o *cluster* obtido na primeira *clusterização*. Na figura 18 é mostrada uma imagem que foi

*reclusterizada*. Os resultados deste experimento podem ser analisados nas figuras 19 e 20, que mostram os *clusters* resultantes da segmentação dos tons de cinza da imagem mostrada na figura 18.

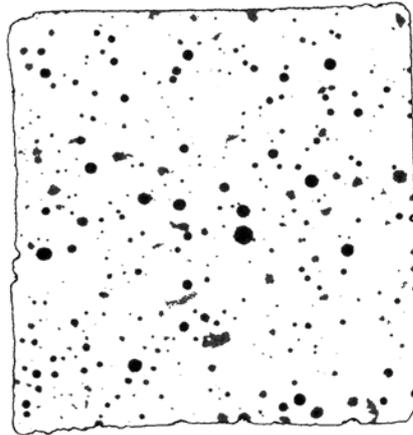


Figura 18 – Imagem resultante da primeira aplicação do *k-means*.

Na figura 19 é mostrada a *reclusterização* da imagem da figura 18 com o algoritmo *k-means* usando o valor de  $k=2$ .

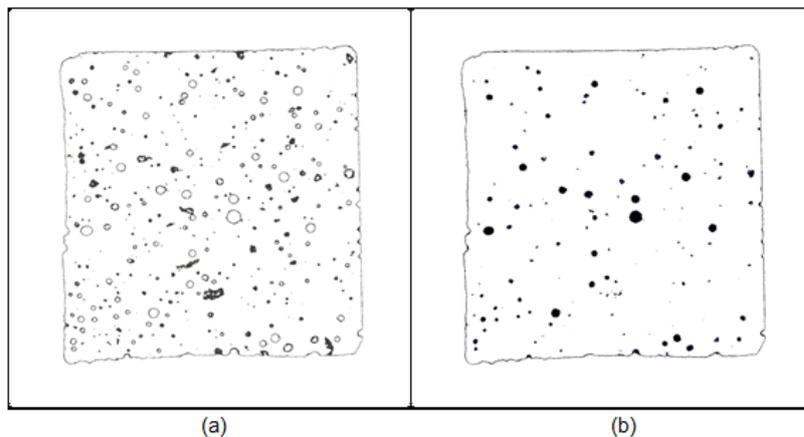


Figura 19 – Imagem *reclusterizada* com  $k=2$ : (a) *cluster 1* e (b) *cluster 2*.

A figura 20 mostra o resultado do processo de *reclusterização* utilizando o algoritmo *k-means* com o valor de  $k=3$ .

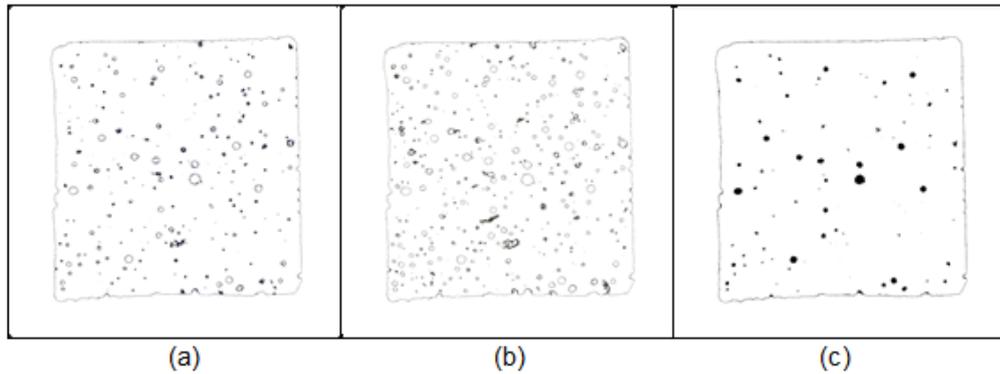


Figura 20 – Imagem *reclusterizada* com  $k=3$ : (a) *cluster 1*, (b) *cluster 2* e (c) *cluster 3*.

Observando os resultados ilustrados nas figuras 19 e 20 podemos concluir que esta *reclusterização* de um intervalo menor de tons de cinza, os que representam os poros, o EVA e as fibras de piaçava, não nos ajuda na *caracterização* destes materiais. Sendo assim, a aplicação do *k-means* no intervalo de tons de cinza torna-se limitada para a *caracterização* completa de todos os materiais das amostras, pois foi possível fazer apenas a separação da argamassa dos demais materiais (poros, EVA e fibras). Outras estratégias como a utilização da teoria *fuzzy* e SBRF foram necessárias.

### 3.4 Algoritmo *fuzzy c-means*

Após a aplicação do algoritmo *k-means* utilizando a cor como critério de *clusterização*. Para separar os elementos dos poros, EVA e fibras contidas nas amostras. Analisamos outros critérios como é o caso da área e excentricidade considerando as diferenças geométricas dos agregados. Os poros tendem a ser mais redondos e com área menor que os demais agregados, o EVA tende a ter uma excentricidade e uma área média e a fibras de piaçava tendem a ter uma excentricidade alta e uma área de tamanho maior que os demais materiais. Esta classificação é dada pelo conhecimento prévio de construção das amostras.

Aplicamos o algoritmo *FCM* primeiramente utilizando a área dos objetos (em *pixels*) como critério de *clusterização* nas imagens resultantes da extração dos tons de cinza que representam a argamassa da amostra, que foram identificados na primeira *clusterização*. Escolhemos um algoritmo *fuzzy* já que com ele é possível

trabalhar com as incertezas, pois determinado valor de área pode estar associado a mais de um *cluster*.

Antes da aplicação do algoritmo *FCM*, foi necessário desenvolver um programa para percorrer todas as imagens de todas as amostras para obter os valores das áreas e excentricidades de todos os objetos contidos nas imagens. Este programa utiliza a função *regionprops* implementada no MATLAB que identifica os objetos contidos na imagem e retorna alguns de seus atributos, como a sua área e excentricidade.

Após a aplicação desta função foi possível encontrar o menor e o maior valor de área e excentricidade possível nas amostras. Com este intervalo encontrado foram realizadas duas aplicações do algoritmo *FCM*, uma para o intervalo das áreas e outra para o das excentricidades. Ambas as aplicações utilizaram o valor de  $C = 3$ , pois o objetivo é caracterizar três tipos de objetos nas imagens, o ar, o EVA e as fibras de piaçava. Uma divisão qualitativa foi realizada considerando objetos com áreas menores caracterizados como ar, com área de tamanho médio como EVA e com maior área caracterizados como fibra de piaçava.

O *FCM* retorna as matrizes de pertinência neste caso uma para as áreas dos objetos e outra para as excentricidades. Estas matrizes expressam o grau de pertinência de cada objeto a cada um dos *clusters* definidos. Com a matriz de pertinência calculada, foi definido o valor de corte para definir a partir de qual grau de pertinência o objeto pertence àquele *cluster*.

Foi definido o corte 0,3 para a matriz de pertinência. O valor de  $m$  utilizado foi  $m=2$  e o número máximo de 100 iterações, valores *default* da função *fcm* implementada no MATLAB.

A figura 21 mostra uma imagem resultante da aplicação do *k-means* em uma imagem da amostra com a mistura C (Argamassa + EVA + Fibras). O resultado da primeira aplicação do *FCM* para a *clusterização* da área dos objetos contidos na imagem da figura 21 é mostrado na figura 22.

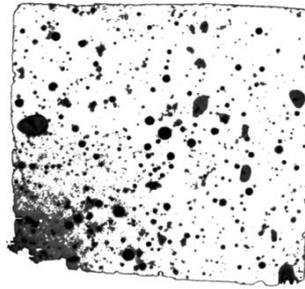


Figura 21 – Imagem resultante da aplicação do *k-means* removendo a argamassa na amostra C.

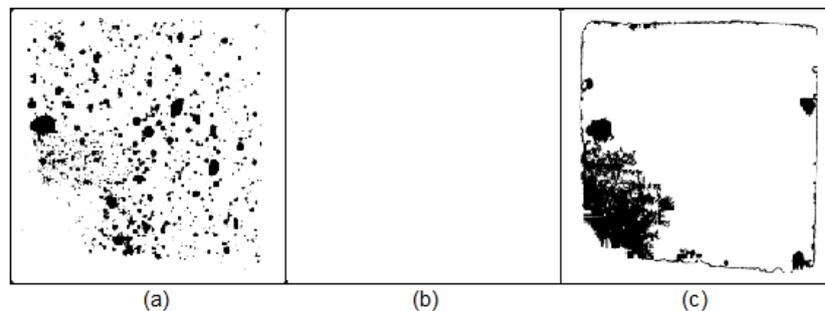


Figura 22 – Imagem após aplicação do *FCM* com  $c=3$  para a amostra C: (a) *cluster 1*, (b) *cluster 2* e (c) *cluster 3*.

Podemos observar na figura 22 (c) que o resultado da aplicação do *FCM* contém um ruído e que a figura 22 (b) não contém nenhum objeto. Esse ruído aparece devido a alguns *pixels* que representam a argamassa terem um tom de cinza mais escuro, se assemelhando aos tons que representam os demais materiais. Neste caso a causa disto é a perda de parte do objeto no momento do corte não ficando bem fixados no porta amostras já que a superfície não é plana.

Como estes *pixels* estão lado a lado na imagem, o algoritmo os interpreta como se fossem um objeto com uma área muito superior à dos objetos que representam os materiais contidos nas amostras. Isso nos dá uma imprecisão na aplicação do *FCM* devido ao intervalo não conter apenas os objetos que devem ser caracterizados.

Os objetos que representam o ar, o EVA e as fibras de piaçava foram classificados para o *cluster* dos objetos de menor área, os ruídos para o *cluster* dos

objetos maiores e o *cluster* com os objetos de tamanho médio ficaram sem nenhum objeto, devido ao intervalo onde estão contidas essas áreas ter sido muito grande.

O falso positivo é destacado na imagem mostrada na figura 23. Podemos observar nesta imagem que estão presentes alguns *pixels* que representam a argamassa.

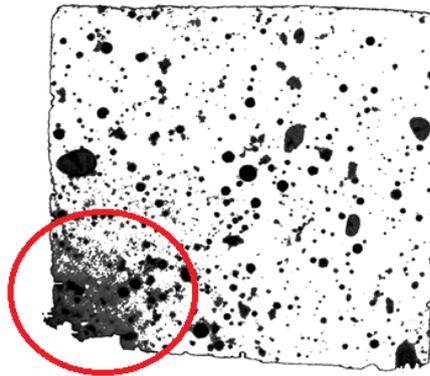


Figura 23 – Ruído.

Após a primeira aplicação do algoritmo *FCM* os objetos de área muito grande, que tinham área entre 45984 e 172813 *pixels* foram retirados das imagens e caracterizados como argamassa. Foi então realizada uma nova aplicação do *FCM* nas imagens após a retirada destes objetos, que agora considera um intervalo de área menor para os objetos, entre 1 e 45984 *pixels*.

Dentro deste intervalo menor que era para conter apenas os agregados temos outro ruído, que são algumas bordas mais finas que também eram para ser caracterizadas como argamassa. Essas bordas são consideradas pelo algoritmo como um objeto, e têm áreas significativamente maiores que os objetos de interesse na *clusterização*. Na figura 24 é mostrada esta borda em uma imagem da amostra da mistura B.

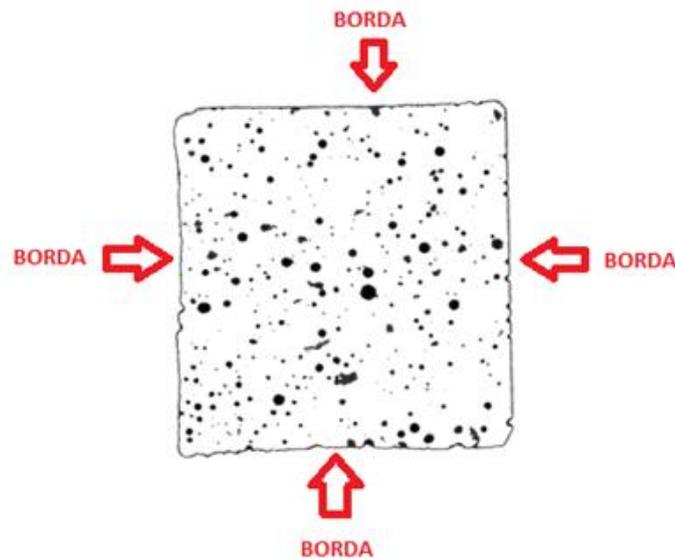


Figura 24 – Bordas que representam ruído.

Estas bordas também foram retiradas em mais duas aplicações do *FCM*, totalizando três aplicações. Após a retirada destas bordas das imagens, temos imagens contendo apenas os objetos que representam o ar, o EVA e as fibras de piaçava contidas nas amostras. A figura 25 mostra uma imagem da amostra com a mistura C antes e depois das três *clusterizações* com o algoritmo *FCM* necessárias para eliminar os ruídos.

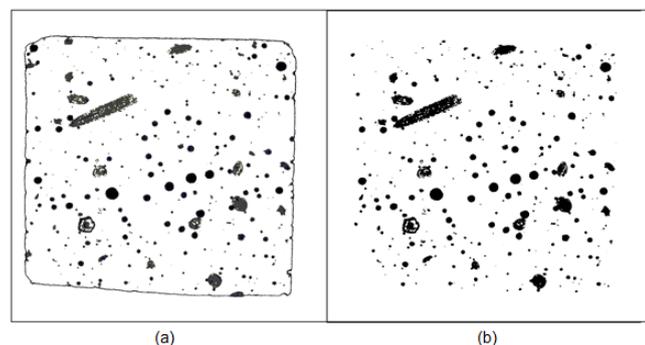


Figura 25 – Imagem *clusterizada* com o *FCM*: (a) antes da remoção da borda e (b) depois da remoção da borda.

Podemos observar que na figura 25 (b) temos uma imagem apenas com os objetos que representam os materiais que desejamos caracterizar, esta imagem é

resultado das duas aplicações do algoritmo *FCM* para agrupar os objetos contidos das imagens de acordo com a sua área.

Após remover os falsos positivos, foi feita outra tentativa de aplicação do algoritmo *FCM* para caracterizar os objetos e separá-los em cinco tons de cinza diferentes, um para os objetos classificados pelo algoritmo como ar, outro para o EVA, um para as fibras de piaçava e outros dois para as zonas *fuzzy*, que são os objetos que podem ser EVA ou ar e os que podem ser caracterizados como EVA ou fibra. O resultado desta aplicação para uma imagem da amostra da mistura C é mostrado na figura 26.

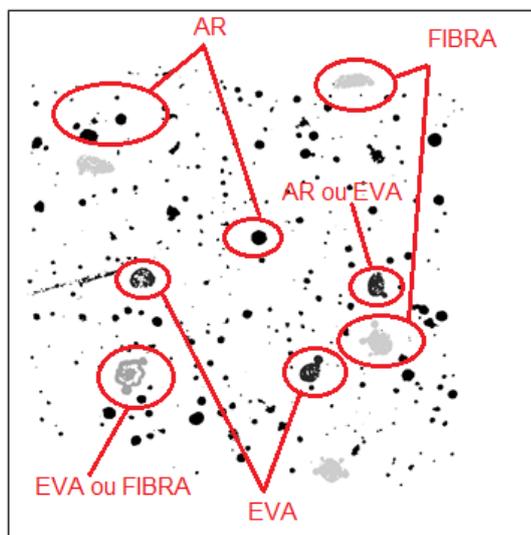


Figura 26 – Resultado da terceira aplicação do *FCM* na amostra C com  $c=3$ .

Analisando a imagem resultante da aplicação do algoritmo *FCM* pode-se observar que alguns objetos ficaram na zona *fuzzy*, ou seja, pertencem tanto a o *cluster* que representa um material quanto a outro *cluster*. Para fazer a caracterização final dos objetos precisamos de um método que nos dê um resultado preciso, visto que somente com este critério foi insuficiente. Para classificar de forma mais acurada adicionamos outros critérios de *clusterização* e utilizamos um controlador *fuzzy* para converter a saídas *fuzzy* em saídas clássicas, ou neste caso em classificação clássica.

### 3.5 Controlador *fuzzy*

Até esta etapa havia sido utilizada apenas a área dos objetos como critério de agrupamento. Objetos com a área pequena eram classificados como ar, os objetos de área média como EVA e os objetos maiores como fibras. Esta classificação não levou a uma classificação acurada, mas conseguiu eliminar objetos e bordas que representavam falsos positivos.

Para reduzir a imprecisão nos resultados da clusterização, foi analisada uma proposta de caracterizar as imagens resultantes combinando mais de um critério de *clusterização*. Uma forma de realizar esta combinação foi utilizar um controlador *fuzzy*. Os critérios de classificação utilizados por este controlador foram área e excentricidade dos objetos, ainda que outros critérios possam ser usados posteriormente, estes por sua simplicidade foram escolhidos para testar a metodologia.

Este controlador tem como entrada as variações de área e excentricidade encontradas nas amostras, e como saída as imagens das amostras onde cada material é representado em um tom de cinza. A figura 27 mostra a arquitetura do controlador *fuzzy* utilizado neste trabalho, descrita nos sub tópicos a seguir.

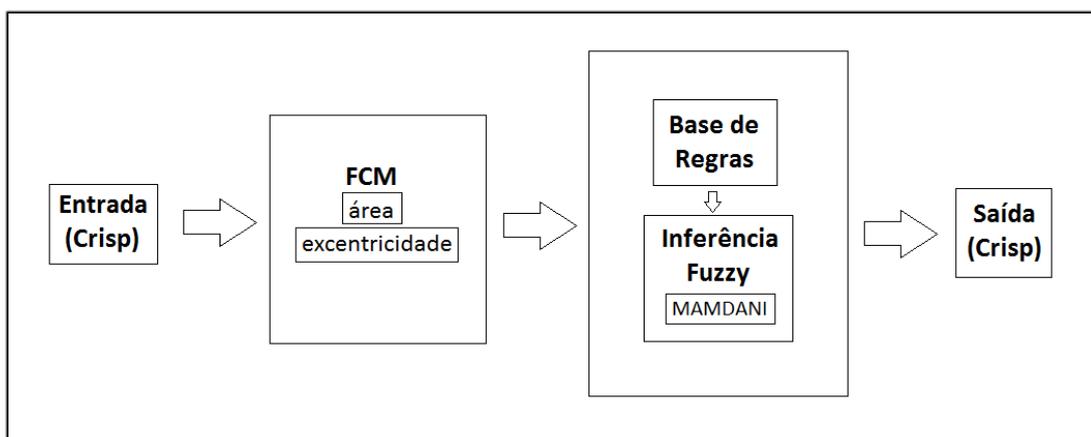


Figura 27 – Arquitetura do controlador *fuzzy* utilizado nesta metodologia para a classificação dos elementos das amostras.

O nosso controlador tem como entrada as variações de área e excentricidade dos objetos contidos nas imagens. O módulo de *fuzzificação* utiliza o algoritmo *FCM*

como método de *fuzzificação*. O módulo de tomada de decisão é formado pela base de regras que combina os clusters obtidos na *fuzzificação* e é descrita na subseção 3.5.2 e pelo modelo de inferência utilizado que é o de Mamdani Clássico. Este módulo de tomada de decisão já nos retorna a classificação do objeto como um dos três materiais (ar, Eva ou fibra de piaçava), então não é necessário o módulo de *defuzzificação* neste controlador.

### 3.5.1 Módulo de *fuzzificação* com o algoritmo *fuzzy c-means (FCM)*

O controlador *fuzzy* utilizado neste trabalho realiza a *fuzzificação* da entrada através do algoritmo *FCM*. O módulo de *fuzzificação* recebe da entrada os intervalos das áreas e excentricidades contidos nas amostras e retorna as duas matrizes de pertinência  $\mu_{\text{Área}}$  e  $\mu_{\text{Excentricidade}}$  obtidas com o algoritmo *FCM*, uma para as áreas e outra para as excentricidades, ambas com 3 *clusters*. Estas matrizes contêm os graus de pertinência, de cada área e excentricidade dos intervalos a cada *cluster*.

A função utilizada para calcular a excentricidade dos objetos tem como retorno um valor no intervalo entre 0 e 1. Para aplicar a função do algoritmo *FCM* neste intervalo foi necessário transformar estes valores em números inteiros. Para isso cada valor deste intervalo foi multiplicado por 10 para ser representado por valores inteiros entre 0 e 10.

Para adequar as matrizes de pertinências ao controlador *fuzzy*, foram definidos alguns  $\alpha$ -cortes para aproximar o gráfico de uma função trapezoidal.

### 3.5.2 Base de regras

Após definir as matrizes de pertinência, foi utilizada a base de regras mostrada na tabela 8 com as possíveis combinações de áreas e excentricidades de cada objeto e suas possíveis classificações. Esta base de regras foi construída a partir do conhecimento prévio das amostras e de especialistas na área. Como são disponíveis três classificações para as áreas e três para as excentricidades, existem 9 regras possíveis combinando estas classificações.

Tabela 8 – Base de regras.

Regra	Se tamanho é	E Excentricidade é:	Então o objeto é:
R1	Pequeno	Baixa	Ar
R2	Pequeno	Média	Ar
R3	Pequeno	Alta	Ar
R4	Médio	Baixa	Ar
R5	Médio	Média	EVA
R6	Médio	Alta	Fibra
R7	Grande	Baixa	Ar
R8	Grande	Média	EVA
R9	Grande	Alta	Fibra

### 3.5.3 Método de inferência de Mamdani Clássico

O método de inferência utilizado foi o método de Mamdani Clássico. Este método utiliza a t-norma do mínimo e a t-conorma do máximo. Isto é, o grau de pertinência do resultado da regra recebe o mínimo dos valores de pertinência das suas entradas, ou seja, o resultado da regra terá o menor valor dos graus de pertinência da área e excentricidade utilizada na regra em questão. Já no resultado final, é considerada a regra que tem valor máximo de todos os valores finais das regras ativadas.

Por exemplo, se um determinado objeto  $x$  possui  $\mu_{AG}(x) = 0,4$ ,  $\mu_{EM}(x) = 0,6$  e  $\mu_{EA}(x) = 0,3$  (grau de pertinência 0,4 ao conjunto de objetos de área grande, 0,6 aos objetos de excentricidade média e 0,3 aos objetos de excentricidade alta), ele ativa as regras R8 e R9. Nesse caso o resultado de R8 é o mínimo entre  $\mu_{AG}(x)$  e  $\mu_{EM}(x)$  e o resultado de R9 é o mínimo entre  $\mu_{AG}(x)$  e  $\mu_{EA}(x)$ , 0,4 e 0,3, respectivamente. Ou seja, o objeto  $x$  tem grau de pertinência 0,4 para o *cluster* que contém EVA e 0,3 para o *cluster* que contém fibra. Aplicando a t-conorma do máximo, consideramos o objeto  $x$  pertencente ao *cluster* que ele tem o maior grau de pertinência, que neste caso é o *cluster* do EVA. Logo, o objeto  $x$  é caracterizado como EVA no nosso controlador *fuzzy*.

Neste controlador utilizado em nosso trabalho, a saída do método de inferência já nos leva ao resultado desejado. Assim, não é necessário um *defuzzificador* para obtermos uma saída clássica.

Após a aplicação do controlador *fuzzy* nas imagens das amostras todos os objetos nelas contidos foram processados e caracterizados de acordo suas características (área e excentricidade). A figura 28 mostra uma imagem resultante da aplicação do controlador *fuzzy* na caracterização em uma imagem da amostra com a mistura C utilizando os valores de excentricidade entre 0 e 10.

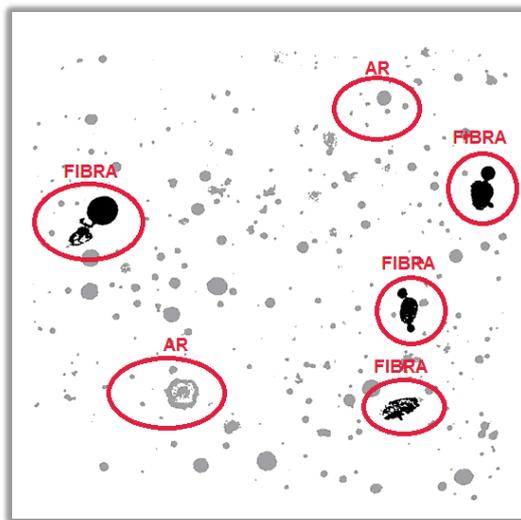


Figura 28 – Resultado do controlador utilizando a excentricidade (cores fornecidas para melhorar a visualização).

Na figura 28 é mostrada uma imagem de saída após a aplicação do controlador *fuzzy*. Podemos observar nos objetos destacados que este controlador nos dá uma saída *crisp*. Os objetos na figura 28 foram destacados em tons diferentes para melhorar sua visualização, este não é o tom original da imagem.

### 3.6 Validação dos critérios de classificação

Para encontrar a área dos objetos contidos nas imagens utilizamos a função *regionprops* que está disponível no MATLAB. Esta função tem uma imagem binarizada como entrada e retorna uma lista com os objetos nela contidos e alguns

de seus atributos, como área, excentricidade e a lista dos *pixels* que os representam.

Para comprovar que os valores de área e excentricidade retornados por esta função foi aplicado o teste com uma imagem com objetos cujas dimensões já são conhecidas, permitindo assim que tenhamos o valores de área e excentricidade exatas. Esta imagem é mostrada na figura 29:

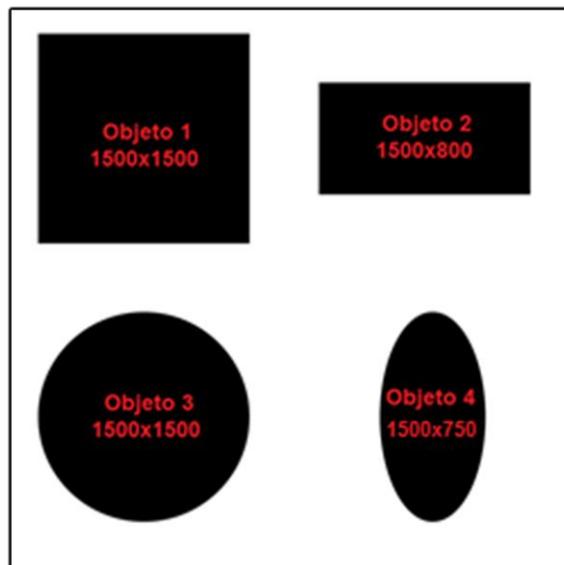


Figura 29 – Imagem de teste para a validação dos algoritmos.

Esta imagem de teste contém um círculo com 1500 *pixels* de diâmetro, uma elipse com 1500 *pixels* de altura e 750 *pixels* de largura, um quadrado com 1500 *pixels* de lado e um retângulo com dimensão de 1500x800 *pixels*. A imagem está em preto e branco, as letras em vermelho foram acrescentadas apenas para facilitar a identificação dos objetos.

Na tabela 9 temos os valores das áreas reais de cada objeto e a área retornada pela função. Na tabela 10 temos os valores das excentricidades reais de cada objeto e a excentricidade calculada pela função. A partir da análise destas tabelas é possível fazer a validação dos resultados da função *regionprops*.

Tabela 9 – Comparação dos resultados do teste de validação da área.

Objeto	Área Real	Área Calculada
1	2250000	2250000
2	1200000	1200000
3	1767139	1767139
4	883399	883399

Tanto as áreas reais quanto as áreas retornadas pela função tiveram o mesmo valor. A área do objeto 1 foi 2250000 *pixels*, o objeto 2 tem uma área de 1200000 *pixels*, o objeto 3 tem 1767139 *pixels* de área e o objeto 4 possui uma área de 883399 *pixels*.

Tabela 10 – Comparação dos resultados do teste de validação da excentricidade.

Objeto	Excentricidade Real	Excentricidade Calculada
1	0	0
2	0,84	0,84
3	0	0
4	0,87	0,87

Tanto as excentricidades reais quanto as excentricidades retornadas pela função tiveram o mesmo valor. A excentricidade do objeto 1 foi zero, o objeto 2 tem uma excentricidade 0,84, o objeto 3 tem zero de excentricidade e o objeto 4 possui excentricidade 0,87.

Conforme esperado, os resultados da função foram validados e as áreas dos objetos retornadas pela função *regionprops* estavam de acordo com as suas dimensões, garantindo desta forma a confiabilidade dos resultados.

## 4 RESULTADOS E DISCUSSÕES

Neste capítulo abordaremos os resultados da metodologia utilizada para a análise das imagens. Inicialmente serão criadas imagens de teste para validar a aplicação do controlador *fuzzy* utilizando a área e excentricidade dos objetos como critério de classificação. Após a aplicação para as imagens de teste, é feita a aplicação da metodologia para as imagens das amostras obtidas por  $\mu$ TC. Estas últimas imagens são tratadas usando a metodologia descrita na figura 30.

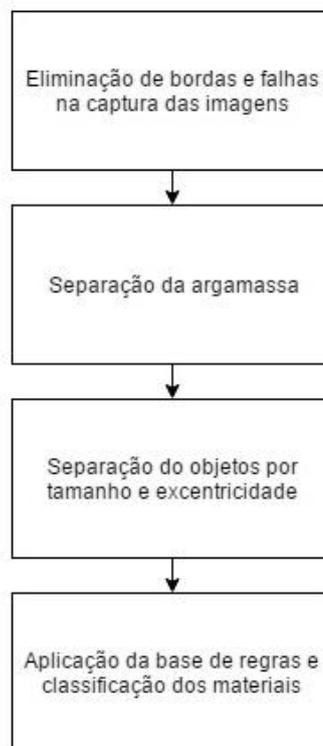


Figura 30 – Diagrama de fluxo da metodologia aplicada às imagens das amostras das diferentes misturas obtidas por  $\mu$ TC.

A primeira etapa da metodologia consistiu em aplicar o algoritmo de pré-processamento para eliminar as bordas e ruídos provenientes do processo de captura das imagens. Na segunda etapa foram separados os tons de cinza que representam a argamassa das amostras dos que representam os poros, o EVA e as fibras de piaçava contidos nas imagens através da aplicação do algoritmo *k-means*. Na terceira etapa foi aplicado o algoritmo *FCM* para gerar as matrizes de pertinência considerando a área e excentricidade do objetos que representam os poros, o EVA e

as fibras de piaçava. Na quarta e última etapa foi implementado e aplicado um controlador *fuzzy* para realizar a classificação final desses objetos.

#### 4.1 Imagens de teste do controlador *fuzzy*

Para comprovar o controlador *fuzzy* como método satisfatório na caracterização dos objetos, criamos imagens de teste com objetos com características conhecidas que representam cada material e comprovar se eles são corretamente classificados usando os critérios excentricidade e área escolhidos.

##### 4.1.1 Criação das imagens

Criamos as imagens de teste escolhendo objetos de tamanhos variados dentro das amostras e dos quais se conhece sua correta classificação como poros, EVA e fibras de piaçava. Com estes objetos criamos imagens de amostras de testes repetindo estes objetos em diferentes localizações da amostra criada. Assim a imagem TA que contém apenas poros representa a mistura A, a imagem TB que contém poros e EVA representa a mistura B e a imagem TC que contém poros, EVA e fibras de piaçava representa a mistura C. As imagens de teste criadas são mostradas nas figuras 31, 32 e 33.

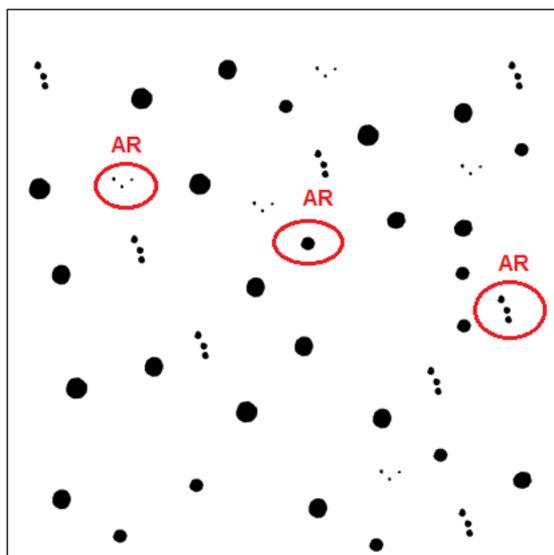


Figura 31 – Imagem de teste TA.

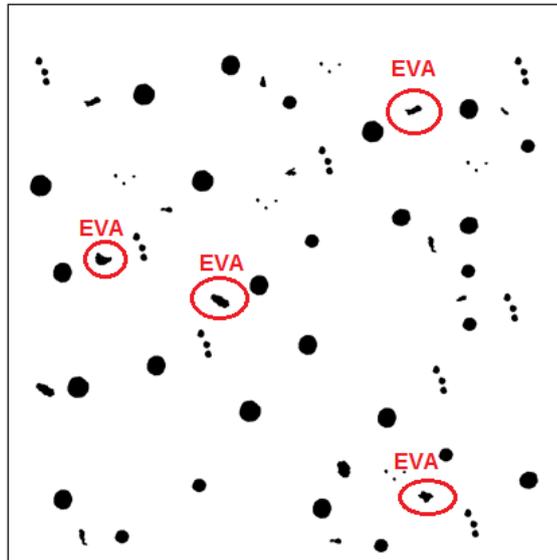


Figura 32 – Imagem de teste TB.

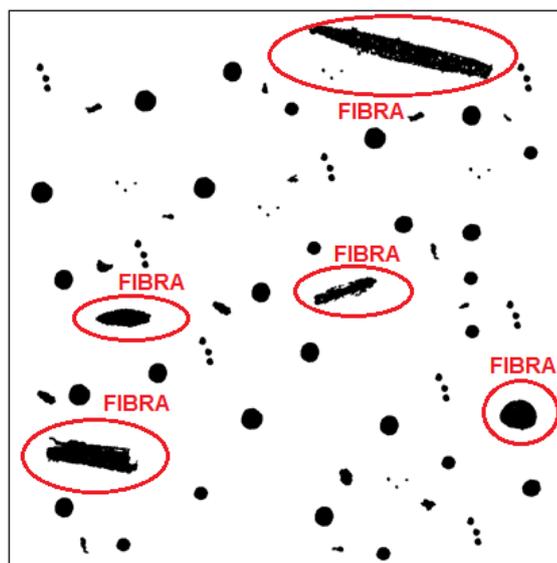


Figura 33 – Imagem de teste TC.

Na figura 31 temos a imagem que representa a mistura A. Na figura 32 temos a imagem que representa a mistura B. Na figura 33 temos a imagem que representa a mistura C. Foram destacados alguns objetos para a melhor identificação de cada material.

A tabela 11 mostra a quantidade de objetos de cada material presente em cada amostra.

Tabela 11 – Quantidade de objetos de cada material nas imagens de teste.

Imagem	Qtd de poros	% de poros	Qtd de EVA	% de EVA	Qtd de fibras	% de fibras
TA	66	100	0	0	0	0
TB	66	81,48	15	18,52	0	0
TC	66	76,74	15	17,44	5	5,81

Na imagem TA foram inseridos 66 objetos que representam os poros e zero objetos que representam o EVA e fibras de piaçava. A TB foi criada acrescentando à imagem A 15 objetos que representam EVA, totalizando 66 objetos representando os poros, 15 objetos que representam o EVA e zero objetos representando as fibras de piaçava. Já a imagem TC foi criada com o acréscimo de 5 objetos que representam as fibras de piaçava à imagem B, totalizando 66 objetos que representam os poros, 15 objetos que representam o EVA e 5 objetos que representam as fibras de piaçava.

Os objetos que representam os poros inseridos nas imagens de teste tem áreas entre 27 e 1611 *pixels*. Os objetos que representam o EVA estão entre 120 e 752 *pixels*. Os que representam as fibras de piaçava estão no intervalo entre 2849 e 14421 *pixels*. Logo, todos os objetos contidos nas três imagens de teste estão com suas áreas entre 27 e 14421 *pixels* e a nova base de regras é aplicada para este novo intervalo. O processo de *fuzzificação* para este intervalo é a aplicação do algoritmo *FCM* com um  $\alpha$ -corte 0,8.

#### 4.1.2 Aplicação das bases de regras

Após a criação das imagens de teste TA, TB e TC, foi aplicado o controlador *fuzzy* com uma base de regras definida de acordo com os intervalos de área e excentricidade dos objetos contidos nessas imagens de teste.

As áreas dos objetos presentes nas imagens foram agrupadas em três *clusters*, um com os objetos considerados pequenos, um com os objetos considerados de tamanho médio e outro com os objetos de tamanho considerado grande. O agrupamento dos valores das excentricidades foi feito também em três

*clusters*, um com os valores de excentricidade considerados baixos, um com os valores de excentricidade considerados médios e outro com os valores de excentricidade considerados altos.

A base de regras utilizada é mostrada na tabela 12. Esta base de regras foi criada baseada no tamanho dos objetos presentes nas imagens de teste. Podemos observar nesta tabela que os objetos de tamanho maior são classificados pelo controlador como fibras de piaçava.

Tabela 12 – Base de regras aplicada às imagens de teste.

Regra	Se tamanho é	E Excentricidade é:	Então o objeto é:
R1	Pequeno	Baixa	AR
R2	Pequeno	Média	AR
R3	Pequeno	Alta	EVA
R4	Médio	Baixa	FIB
R5	Médio	Média	FIB
R6	Médio	Alta	FIB
R7	Grande	Baixa	FIB
R8	Grande	Média	FIB
R9	Grande	Alta	FIB

As figuras 34, 35 e 36 mostram os resultados da aplicação do controlador *fuzzy* com a base de regras mostrada na tabela 12 para as imagens de teste TA, TB e TC, respectivamente. Nestas imagens os objetos foram destacados em tons diferentes para facilitar a visualização dos resultados, onde o tom mais claro representa os poros, o tom médio representa o EVA e o tom mais escuro representa as fibras de piaçava presentes na imagem.

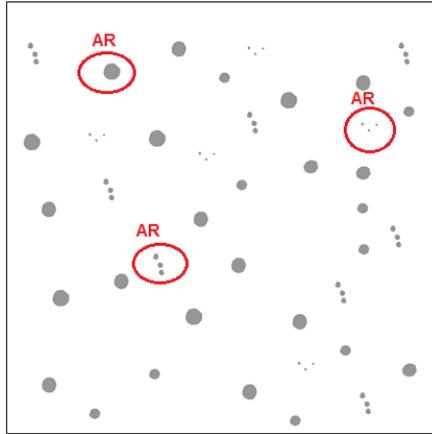


Figura 34 – Imagem de teste TA após aplicação do controlador *fuzzy*.

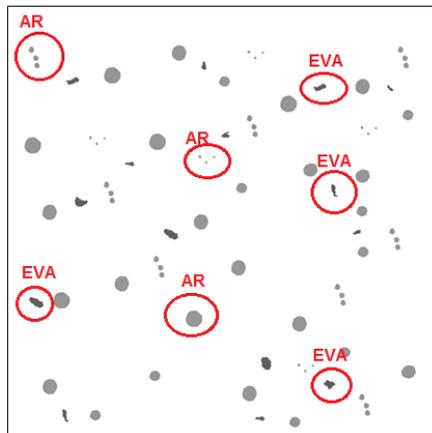


Figura 35 – Imagem de teste TB após aplicação do controlador *fuzzy*.

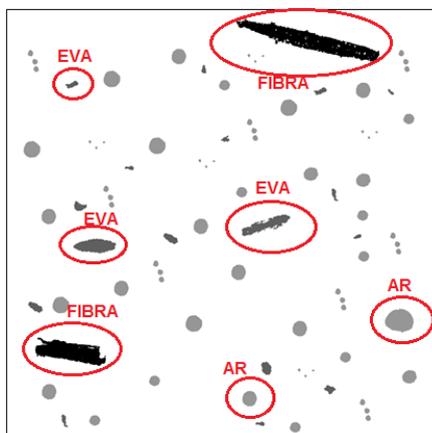


Figura 36 – Imagem de teste TC após aplicação do controlador *fuzzy*.

Observando as imagens das figuras 34, 35 e 36 podemos perceber que nas figuras 34 e 35 os objetos foram classificados corretamente, uma vez que na figura 34 todos os objetos foram classificados como ar e na figura 35 foram classificados apenas como ar e EVA. Já na figura 36 alguns objetos que representam fibras de piaçava foram classificados como ar ou EVA.

Na tabela 13 temos a quantidade de objetos identificado para cada material em cada uma das imagens após a aplicação do controlador com a base de regras mostrada na tabela 12.

Tabela 13 – Quantidade de objetos de cada material identificado pelo controlador nas imagens de teste.

Imagem	Qtd de poros	% de poros	Qtd de EVA	% de EVA	Qtd de fibras	% de fibras
TA	66	100	0	0	0	0
TB	66	81,48	15	18,52	0	0
TC	67	77,91	17	19,77	2	2,32

Na imagem TA obtivemos 100% dos objetos classificados como poros, na imagem TB 81,48% dos objetos foram classificados como poros e 18,52% como EVA e na imagem TC 77,91% dos objetos foram classificados como poros, 19,77% como EVA e 2,32% como fibras de piaçava.

Comparando os dados mostrados na tabela 13 com os valores da tabela 11 percebemos que obtivemos um resultado satisfatório para as imagens TA e TB, onde todo os objetos foram identificados corretamente. Porém, na imagem TC não tivemos uma identificação muito boa dos objetos que representam as fibras de piaçava devido a uma imprecisão na definição da base de regras. Esta imprecisão se dá devido ao intervalo das áreas serem muito grandes por causa das fibras maiores presentes na imagem.

A imprecisão destes resultados para a imagem TC se dá devido ao intervalo das áreas ser muito grande para ser *clusterizado* em apenas 3 *clusters*, considerando a maioria dos objetos com alto grau de pertinência ao *cluster* que contém os objetos menores. Assim, algumas fibras estão com área pertencente ao

*cluster* dos objetos de menor área. Logo, se faz necessário uma nova aplicação do controlador para este intervalo menor.

Devido a estes resultados inexatos para a imagem TC, foi definido um novo intervalo de áreas para a *clusterização* e definida uma nova base de regras. Esta nova base de regra considera apenas os objetos pertencentes ao *cluster* com as áreas de menor tamanho, cujo intervalo em que estão contidas está entre 27 e 6012 *pixels*.

Como essa imprecisão nos resultados ocorre apenas com a adição de fibras de piaçava na imagem, foi aplicada uma nova base de regras apenas nesta imagem. A tabela 14 mostra a nova base de regras para ser aplicada à imagem TC.

Tabela 14 – Base de regras aplicada às imagens de teste na segunda aplicação.

Regra	Se tamanho é	E Excentricidade é:	Então o objeto é:
R1	Pequeno	Baixa	AR
R2	Pequeno	Média	AR
R3	Pequeno	Alta	EVA
R4	Médio	Baixa	AR
R5	Médio	Média	FIB
R6	Médio	Alta	FIB
R7	Grande	Baixa	FIB
R8	Grande	Média	EVA
R9	Grande	Alta	FIB

Na tabela 15 estão os novos resultados da identificação dos materiais da imagem TC na aplicação do controlador com a nova base de regras mostrada na tabela 14.

Tabela 15 – Quantidade de objetos de cada material identificado pelo controlador na imagem de teste TC.

Qtd de poros	% de poros	Qtd de EVA	% de EVA	Qtd de fibras	% de fibras
66	76,74	15	17,44	5	5,81

Na imagem TC 76,74% dos objetos foram classificados como poros, 17,44% classificados como EVA e 5,81% classificados como fibras de piaçava. Comparando

os resultados mostrados na tabela 15 com os dados da tabela 11 verificamos que a classificação nos mostrou os valores exatos esperados para as imagens de teste.

A figura 37 mostra a imagem resultante do controlador *fuzzy* utilizando a nova base de regras à imagem TC. Alguns objetos foram destacados para facilitar a visualização.

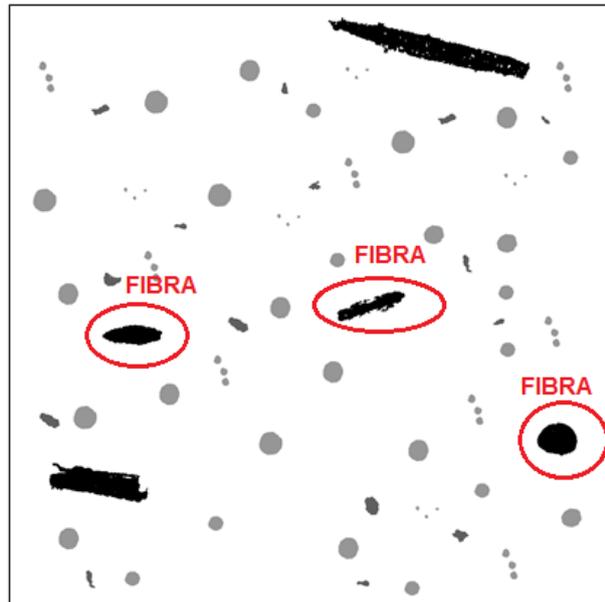


Figura 37 – Imagem de teste TC após nova aplicação do controlador *fuzzy*.

Podemos observar que após esta nova aplicação os objetos foram corretamente classificados. Os objetos que estão destacados são os que estavam causando imprecisão nos resultados na aplicação anterior do controlador *fuzzy*. Obtivemos então um resultado mais preciso em relação a aplicação anterior.

#### 4.2 Imagens de micro tomografia computadorizada

Após a comprovação do funcionamento da aplicação do controlador *fuzzy* às imagens de teste, esta metodologia foi aplicada às imagens de  $\mu$ CT. Porém, antes de aplicar o controlador foi necessária a aplicação de alguns outros algoritmos para pré processar as imagens com o objetivo de eliminar bordas e ruídos produtos do processo de captura das imagens.

#### 4.2.1 Eliminação das bordas

A primeira etapa de pré-processamento nas imagens consiste na eliminação das bordas pretas das. Na tabela 16 é mostrada a quantidade de *pixel* das imagens antes da eliminação das bordas, a quantidade de *pixels* que representa a mistura (argamassa, EVA, fibras de piaçava e ar) nestas amostras e a quantidade de *pixels* que representam a borda (ruído) que foi retirada das imagens.

Tabela 16 – Quantidade de *pixels* eliminados no pré-processamento.

Amostra	Qtd total de <i>pixels</i>	Qtd de <i>pixels</i> da mistura	Qtd de <i>pixels</i> das bordas
A	2524742656	1531829435	992913221
B	2594835456	1486459877	1108375579
C	2594835456	1630144370	964691086

A quantidade total de *pixels* de cada amostra é contabilizada considerando que as imagens tem 1184x1184 *pixels* de dimensão, assim temos uma quantidade total de 1401856 *pixels* para cada imagem nas três amostras. Na amostra A temos 1851 imagens e nas amostras B e C temos 1801 imagens para cada amostra. Então, como cada imagem tem 1401856 *pixels*, na amostra A temos uma quantidade de 2524742656 *pixels* e nas amostras B e C têm um total de 2594835456 *pixels* para cada amostra.

O número de *pixels* total das misturas foram obtidas com a implementação de um *script* no Matlab após a eliminação de bordas. Na amostra A, B e C as misturas são representadas por 1531829435, 1486459877 e 1630144370 *pixels*, respectivamente.

Nas amostras A, B e C os ruídos que foram eliminados das bordas são representados por 992913221, 1108375579 e 964691086 *pixels*, respectivamente.

#### 4.2.2 Separação da argamassa usando o algoritmo *k-means*

Após a eliminandção de ruídos derivados de possíveis erros de detecção nas imagens foi aplicado o algoritmo de *clusterização k-means* para segmentar as imagens das amostras de acordo com a cor (tons de cinza). Esta *clusterização* foi realizada considerando que os tons de cinza presentes nas imagens estão no intervalo entre 0 e 255. Na figura 38 é mostrado o histograma dos tons de cinza em cada uma das amostras (A, B e C) utilizadas.

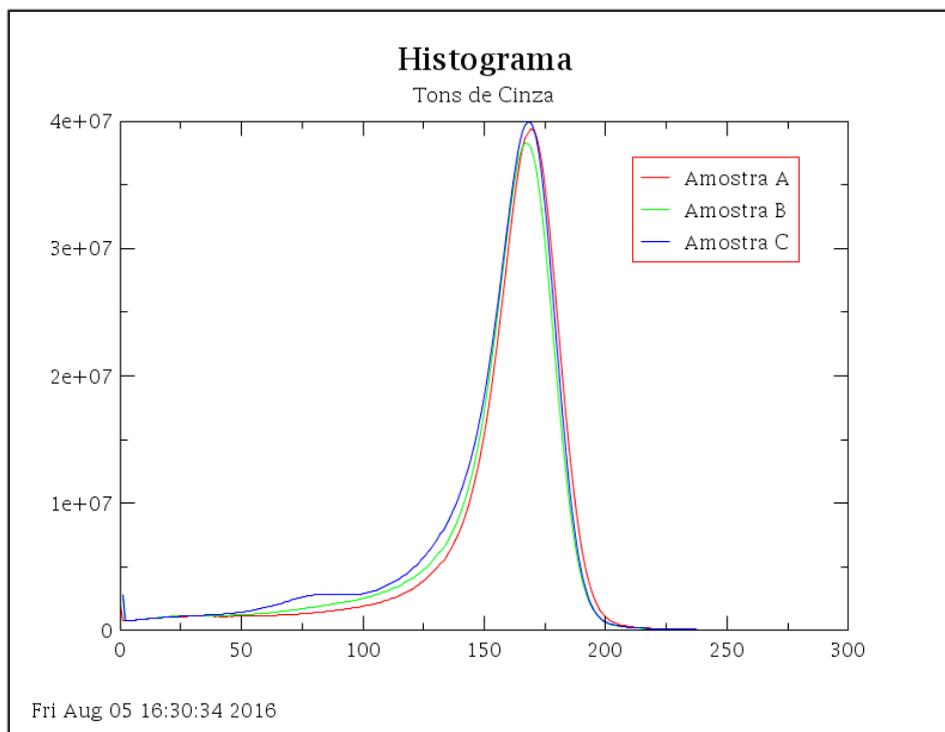


Figura 38 – Histograma dos tons de cinza das imagens das amostras A, B e C.

O algoritmo foi aplicado com diversos valores de *k*, sendo *k*=3 o melhor resultado que consegue isolar em um *cluster* todos os elementos agregados tirando todos os *pixels* correspondentes à argamassa.

De acordo com os resultados obtidos nesta *clusterização* o primeiro *cluster* contém os tons de cinza contidos no intervalo entre 86 e 171, o segundo entre 172 e 255 e o terceiro entre 0 e 85. Sendo que no *cluster* 3 ficaram os elementos

agregados e os poros que possuem valores mais próximos ao preto, já que possuem densidade menor que a argamassa. Os intervalos contidos em cada *cluster* são representados na tabela 17.

Tabela 17 – Intervalo dos tons e cinza correspondentes a cada *cluster*.

<i>Cluster</i>	Intervalo	Material
1	[86;171]	Argamassa
2	[172;255]	Argamassa
3	[0;85]	Ar, EVA e fibras

A partir da análise da tabela 17, foi desenvolvido um *script* para contar os *pixels* das amostras novamente após a *clusterização*. Nas tabelas 17, 18 e 19 é mostrada a quantidade de *pixels* que representam a argamassa e os demais agregados das amostras A, B e C, respectivamente.

Tabela 18 – Quantidade de *pixels* dos materiais nas imagens da amostra A.

Material	Qtd de <i>pixels</i>	Porcentagem de <i>pixels</i>
Argamassa	1432569252	94
Ar, EVA e fibras	99260183	6

Tabela 19 – Quantidade de *pixels* dos materiais nas imagens da amostra B.

Material	Qtd de <i>pixels</i>	Porcentagem de <i>pixels</i>
Argamassa	1375555303	93
Ar, EVA e fibras	110904574	7

Tabela 20 – Quantidade de *pixels* dos materiais nas imagens da amostra C.

Material	Qtd de <i>pixels</i>	Porcentagem de <i>pixels</i>
Argamassa	1493766135	92
Ar, EVA e fibras	136378235	8

De acordo com os resultados da aplicação do algoritmo *k-means*, na amostra A temos uma quantidade de 1432569252 *pixels* que representam a argamassa e

99260183 *pixels* que representam os demais materiais contidos na amostra. Na amostra B temos 137555303 *pixels* representando a argamassa e 110904574 *pixels* que representam os demais materiais da mistura. Na mistura C 1493766135 *pixels* representam a argamassa e 136378235 *pixels* correspondem o ar, EVA e as fibras de piaçava contidas na amostra.

Nas imagens da amostra A 94% dos *pixels* correspondem à argamassa e os outros 6% ao ar, EVA e as fibras contidas na mistura. Na amostra B 93% dos *pixels* correspondem à argamassa e os outros 7% aos demais materiais contidos na mistura. E, na amostra C 92% dos *pixels* representam a argamassa e 8% o ar, o EVA e as fibras de piaçava contidas na mistura.

Após a aplicação do algoritmo *k-means* a argamassa foi separada dos demais elementos contidos nas imagens das amostras. A tabela 21 contém a quantidade de objetos que representam o ar, EVA e as fibras de piaçava em cada uma das misturas (A, B e C).

Tabela 21 – Quantidade de objetos em cada mistura após a aplicação do algoritmo *k-means*.

Mistura	Qtd de objetos
A	604691
B	657633
C	680893

Nas imagens resultantes da *clusterização* com o algoritmo *k-means* para separar a argamassa dos agregados foram identificados 604691 objetos na mistura A, 657633 objetos na mistura B e 680893 objetos na mistura C. Estes objetos correspondem aos poros, EVA e fibras contidos em cada uma das misturas.

#### 4.2.3 Algoritmo *fuzzy c-means*

Após a aplicação do algoritmo *k-means* foram isolados os elementos agregados e poros da argamassa contida nas amostras A, B e C. Foi então aplicado

o *FCM* nas imagens das amostras após a retirada da argamassa com a finalidade de agrupar os poros, EVA e fibras de piaçava em *clusters* diferentes.

Os tons de cinza presentes nestas imagens estão no intervalo entre 0 e 85, que é um intervalo muito pequeno para uma nova *clusterização*. Isto ocorre porque a diferença entre as densidades dos agregados e poros não é significativa. O *FCM* então foi aplicado usando área e como as imagens a serem *clusterizadas* contém três tipos de materiais (Ar, EVA e fibras de piaçava) o valor escolhido foi  $C=3$ , onde o *cluster* que contém os objetos de menor área supomos que representa os poros (Ar), o *cluster* com os objetos de área com valor médio representa o EVA considerando o tamanho limite dos grãos de EVA colocados na amostra e o *cluster* com os objetos de maior área seria a fibra.

Para a aplicação do algoritmo *FCM* foi escolhida a área dos objetos como critério de agrupamento. Os objetos das misturas A, B e C contidos no *cluster* resultante após a separação da argamassa com o algoritmo *k-means* tem áreas entre 1 e 172813. O gráfico que ilustra a matriz de pertinência das áreas contidas neste intervalo gerada pelo algoritmo *FCM* é mostrado na figura 39.

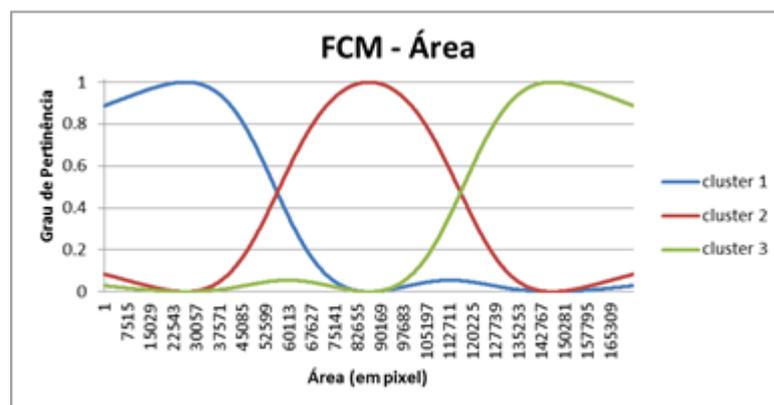


Figura 39 – Matriz de pertinência para cada elemento a cada *cluster* considerando a área.

O *cluster* 1 contém os objetos de menor área, aproximadamente entre 1 e 82655 *pixels*. No *cluster* 2 estão contidos os objetos com área de tamanho médio, aproximadamente entre 30057 e 142767 *pixels*. O *cluster* 3 contém os objetos de maior área, aproximadamente entre 90169 e 172813 *pixels*.

A frequência para cada valor de área dos objetos contidos nas amostras é representada no histograma na figura 40 para a mistura A, figura 41 para a mistura B e figura 42 para mistura C.

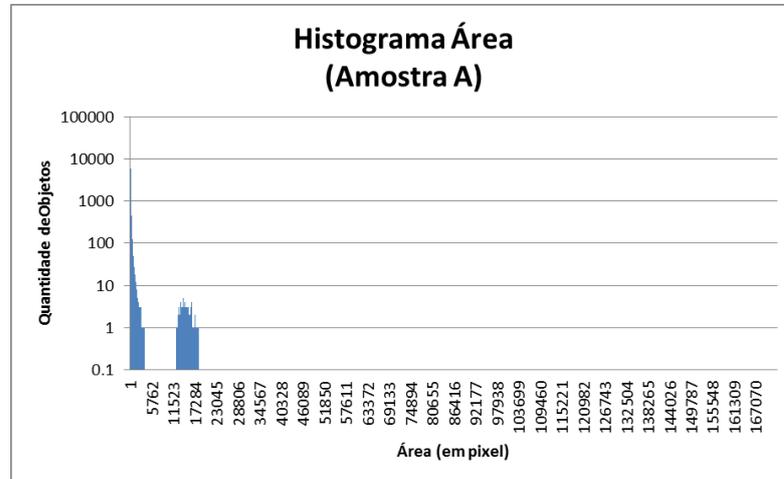


Figura 40 – Histograma dos valores das áreas dos objetos da mistura A.

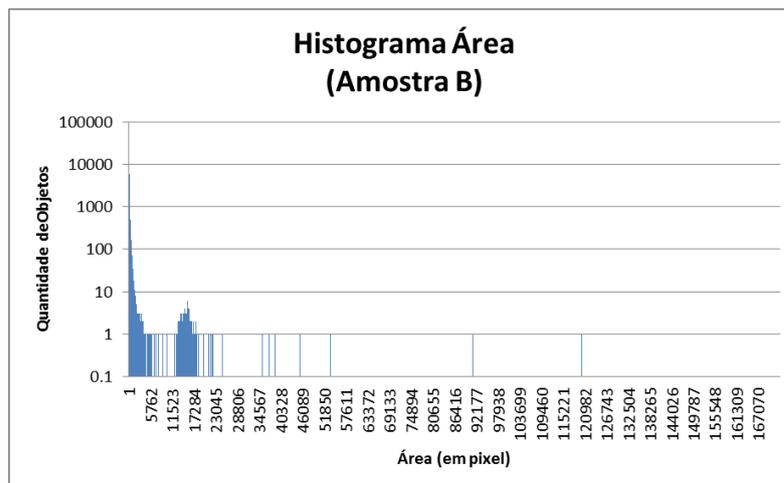


Figura 41 – Histograma dos valores das áreas dos objetos da mistura B.

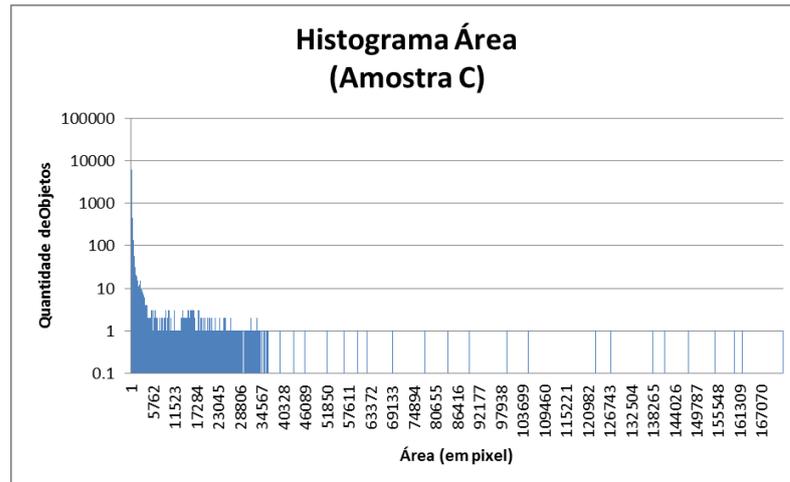


Figura 42 – Histograma dos valores das áreas dos objetos da mistura C.

Como a *clusterização* é feita com o intervalo de áreas contidas em todas as amostras, para facilitar a análise dos histogramas é mais viável criar um único histograma para as 3 amostras considerando todas as fatias 2D analisadas. Este histograma contendo os objetos das amostras A, B e C juntos é mostrado na figura 43, que nada mais é que a soma dos três histogramas das figuras 40, 41 e 42.

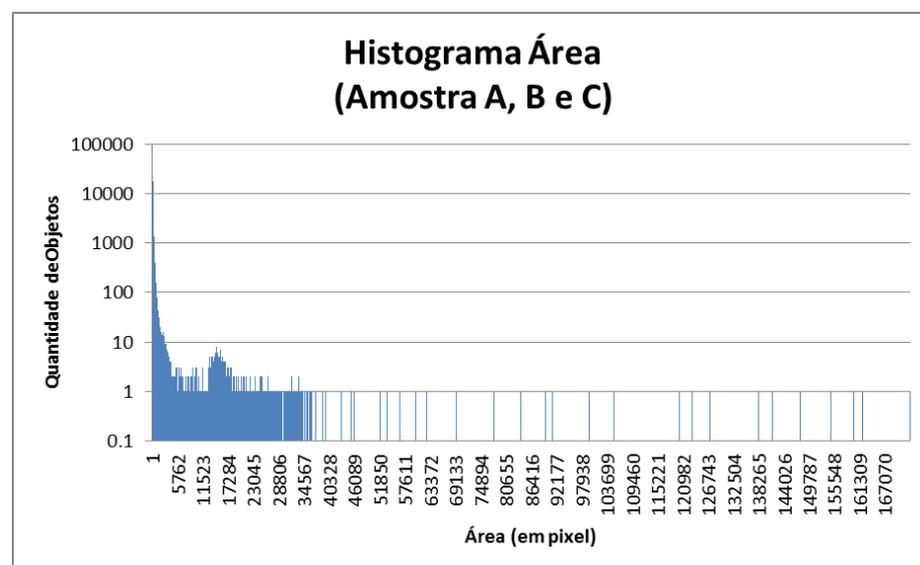


Figura 43 – Histograma dos valores das áreas dos objetos das misturas A, B e C.

A partir da análise do histograma, é possível observar que a maior parte dos objetos possui uma área com valor baixo e uma quantidade muito pequena de objetos possui uma área próxima da área máxima do intervalo. Isto se dá devido às

bordas que aparecem como falso positivo nas imagens. Estas bordas deveriam ser classificadas como argamassa na aplicação o *k-means*, porém possuem um tom de cinza muito próximo aos agregados. Com isso, temos uma imprecisão na aplicação do algoritmo *fuzzy c-means*, pois estas bordas tem uma área muito superior que a área dos materiais a serem classificados, que foram classificados em um único *cluster* pelo *FCM*.

Para eliminar estes ruídos foi preciso aplicar o algoritmo *FCM* mais duas vezes estreitando o intervalo das áreas, totalizando três aplicações consecutivas deste algoritmo, a segunda com o intervalo entre 1 e 45984 e terceira com 1 e 14973. O gráfico que representa as matrizes de pertinência da segunda e terceira aplicação do algoritmo *FCM* são ilustrados nas figuras 44 e 45:

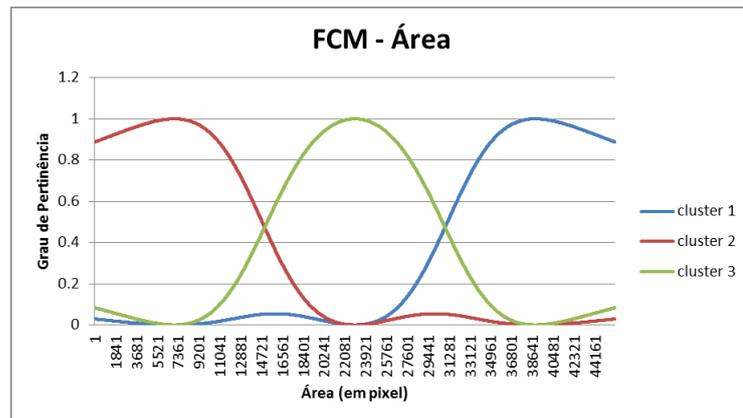


Figura 44 – Gráfico que representa a matriz de pertinência obtida após uma aplicação do *FCM*.

O *cluster 1* contém os objetos cuja área tem o maior valor, estas áreas estão aproximadamente entre 23921 e 45984 *pixels*. No *cluster 2* estão os objetos que tem uma área menor, aproximadamente entre 1 e 22081 *pixels*. O *cluster 3* contém os objetos com a área com valor médio, que estão aproximadamente entre 9201 e 38641 *pixels*.

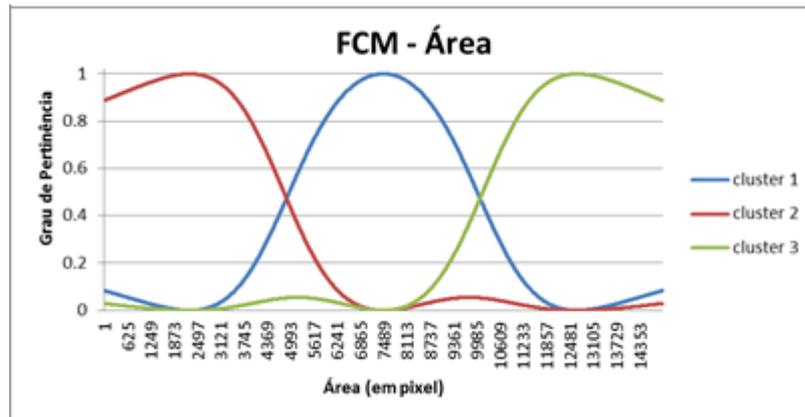


Figura 45 – Gráfico que representa a matriz de pertinência obtida após a segunda aplicação do *FCM*.

O *cluster 1* contém os objetos cuja área tem um valor médio, estas áreas estão aproximadamente entre 2497 e 12481 *pixels*. No *cluster 2* estão os objetos que tem uma área menor, aproximadamente entre 1 e 6865 *pixels*. O *cluster 3* contém os objetos com a área com maior valor, que estão aproximadamente entre 8113 e 14973 *pixels*. Estes resultados coincidem com os obtidos por Meira Silva (2012) usando métricas tradicionais de processamento de imagens digitais.

Após as três aplicações do algoritmo foi obtido um intervalo contendo apenas as áreas entre 1 e 4874 *pixels* que representam os objetos a serem classificados. Os objetos pertencentes aos demais *clusters* foram identificados como ruídos.

Após as aplicações do *FCM* 27087518 *pixels* na amostra A, 27543388 *pixels* na amostra B e 42880835 *pixels* na amostra C que representavam o Ar, EVA e fibras de piaçava passaram a ser identificados como ruídos nas imagens, pois estavam nas bordas que foram eliminadas, e 72172665 *pixels* na amostra A, 83361186 *pixels* na amostra B e 93497400 *pixels* na amostra C continuaram representando estes demais agregados. Nas tabelas 22, 23 e 24 é mostrada a quantidade de ruídos eliminada em cada amostra e a quantidade de *pixels* que está representando os objetos de cada uma das misturas (A, B e C).

Tabela 22 – Quantidade de *pixels* dos materiais e ruídos após o *FCM* nas imagens da amostra A.

Identificação	Qtd de <i>pixels</i>
Ruídos	27087518

Ar, EVA e fibras	72172665
------------------	----------

Tabela 23 – Quantidade de *pixels* dos materiais e ruídos após o *FCM* nas imagens da amostra B.

Identificação	Qtd de <i>pixels</i>
Ruídos	27543388
Ar, EVA e fibras	83361186

Tabela 24 – Quantidade de *pixels* dos materiais e ruídos após o *FCM* nas imagens da amostra C.

Identificação	Qtd de <i>pixels</i>
Ruídos	42880835
Ar, EVA e fibras	93497400

A quantidade de objetos que representam o Ar, o EVA e as fibras de piaçava contidos em cada amostra após a eliminação dos ruídos com o algoritmo *FCM* é mostrada na tabela 25.

Tabela 25 – Quantidade total de objetos que representam os materiais após eliminação de ruídos com o *FCM*.

Mistura	Qtd de objetos
A	602840
B	655813
C	678255

Após a eliminação destes ruídos, a amostra A ficou com 602840 objetos, a amostra B com 655813 objetos e a amostra C com 678255 objetos representando o Ar, o EVA e as fibras nas imagens. Desta forma, analisando as tabelas 21 e 25 podemos afirmar que na amostra A, B e C foram classificados 1851, 1820 e 2638 objetos como ruídos, respectivamente. O Ar, o EVA e as fibras de piaçava contidos nas amostras A, B e C são representados por 72172665, 83361186 e 93497400 *pixels*, respectivamente.

Após as aplicações do algoritmo *FCM*, tivemos um *cluster* somente com os objetos que correspondem ao ar, EVA e as fibras de piaçava, que são os objetos que devemos caracterizar. Nas imagens contidas neste *cluster* estão presentes objetos com a área entre 1 e 4874 *pixels*. A frequência para cada valor de área dos objetos contidos nas amostras é mostrada nos histogramas mostrados nas figuras 46, 47 e 48 para as misturas A, B e C, respectivamente.

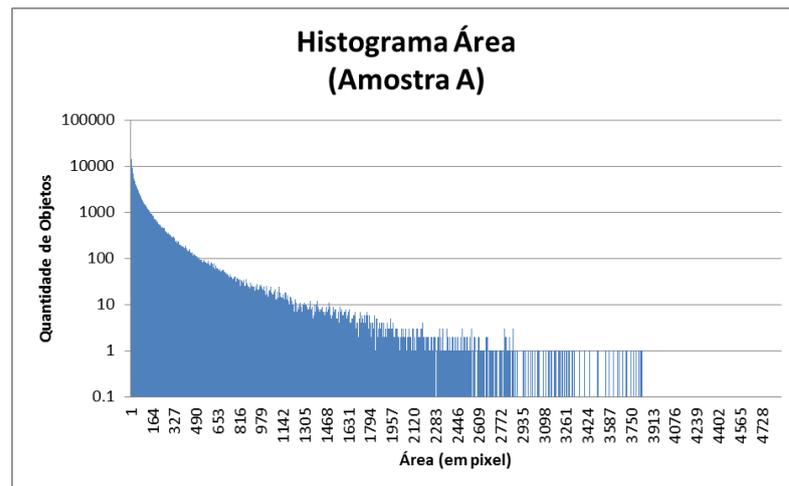


Figura 46 – Histograma dos valores das áreas dos objetos da amostra A após aplicações do *FCM*.

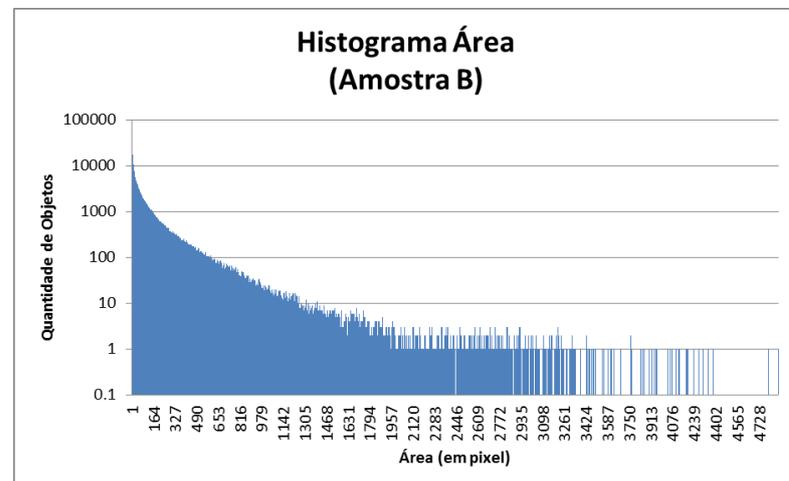


Figura 47 – Histograma dos valores das áreas dos objetos da amostra B após aplicações do *FCM*.

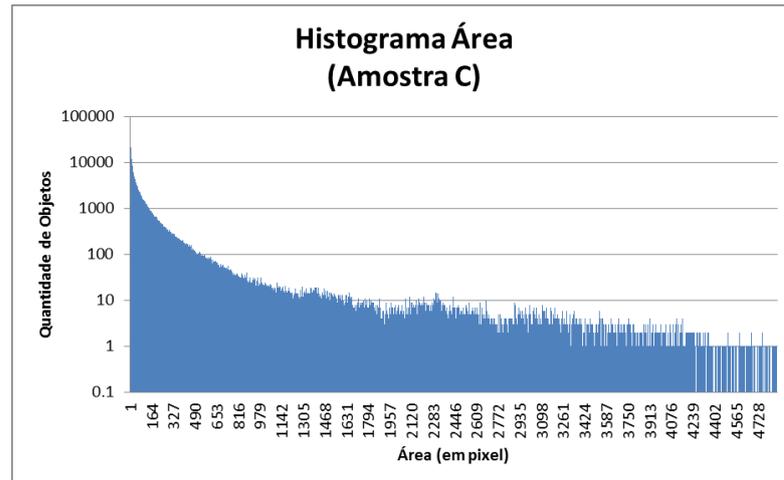


Figura 48 – Histograma dos valores das áreas dos objetos da amostra C após aplicações do *FCM*.

Podemos observar estes histogramas das áreas dos objetos de cada uma das amostras (A, B e C) para tentar identificar as áreas de alguns tipos de objetos. Como podemos ver no histograma da amostra A o histograma concentra-se mais nas áreas menores que 2609 *pixels* aproximadamente, que são os poros, já que na amostra A não temos EVA nem fibras de piaçava. Na amostra B podemos notar que com o acréscimo do EVA tivemos um aumento também no histograma com as áreas entre 2609 e 3261 *pixels*. Na amostra C, com o acréscimo das fibras de piaçava ocorreu um aumento no histograma nos objetos com área maior que 3261.

#### 4.2.4 Controlador *fuzzy*

A caracterização utilizando apenas a área para diferenciar os objetos não foi o suficiente. Então foi escolhido um controlador *fuzzy* para fazer esta classificação, uma vez que o mesmo permite a escolha de mais de um critério. Neste trabalho, foram utilizadas a área em *pixels* e a excentricidade dos objetos. Estes critérios foram escolhidos pela facilidade, levando em conta que já foram utilizados em trabalhos anteriores por Meira Silva (2012), Almeida (2014) e Silva Mendonça (2016) e podem ser enriquecidos. Os intervalos de área e excentricidade dos objetos contidos nas imagens estão entre 1 e 4874 e entre 0 e 10, respectivamente.

No módulo de *fuzzificação* do controlador foi utilizado o algoritmo *FCM*, que recebe como entrada os intervalos das áreas e excentricidades dos objetos contidos

nas amostras. Este módulo de *fuzzificação* utiliza as matrizes com os graus de pertinência de cada área e excentricidade dos intervalos. Estas matrizes de pertinência são representadas nos gráficos das figuras 49 e 50.

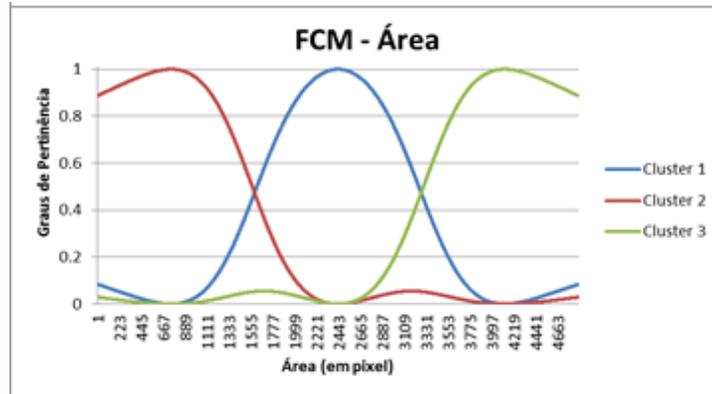


Figura 49 – Gráfico que representa a matriz de pertinência dos valores das áreas obtida após a segunda aplicação do *FCM*.

Na figura 49, podemos observar que o *cluster 1* contém os objetos cuja área tem um valor médio, estas áreas estão aproximadamente entre 889 e 3997 *pixels*. No *cluster 2* estão os objetos que tem uma área menor, aproximadamente entre 1 e 2221 *pixels*. O *cluster 3* contém os objetos com área maior, que estão aproximadamente entre 2665 e 4874 *pixels*.

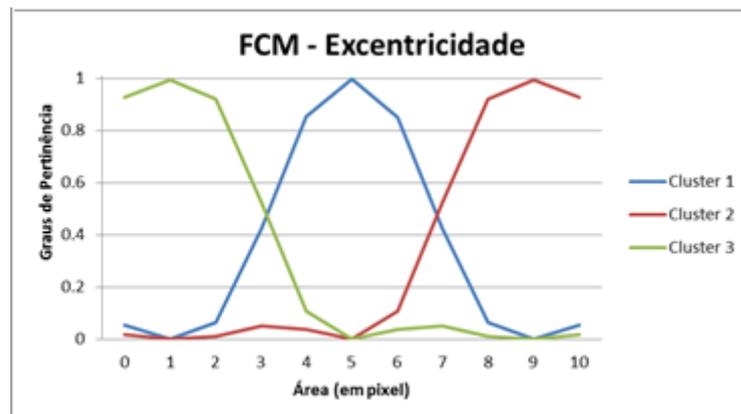


Figura 50 – Gráfico que representa a matriz de pertinência dos valores das excentricidades obtida com a aplicação do *FCM*.

Na figura 50, podemos ver que o *cluster 1* contém os objetos cuja excentricidade tem um valor médio, que estão aproximadamente entre 1 e 9. No

*cluster 2* estão os objetos que tem a excentricidade, aproximadamente entre 5 e 10. O *cluster 3* contém os objetos com menor excentricidade, que estão aproximadamente entre 0 e 5.

Foram escolhidos alguns valores de corte para os graus de pertinência baseados na matriz de pertinência para área e excentricidade (figuras 49 e 50). Primeiramente foram desconsiderados os graus de pertinência menores que o limiar 0,09, que poderiam nos dá resultados inexatos. Depois disso, foram aplicadas três combinações de  $\alpha$ -corte, a primeira foi de 0,8 para a área e 0,6 para excentricidade, a segunda foi 0,6 tanto para a área quanto para a excentricidade, e, a terceira foi 0,8 para a área e 0,9 para a excentricidade. Todas as combinações nos levaram ao resultado similar na saída do controlador, devido ao intervalo com os valores da excentricidade ser muito pequeno e estes valores estarem muito próximos.

Nas figuras 51 e 52 são mostrados os gráficos com os graus de pertinência após a aplicação dos cortes de 0,8 para a área e 0,6 para a excentricidade, respectivamente.

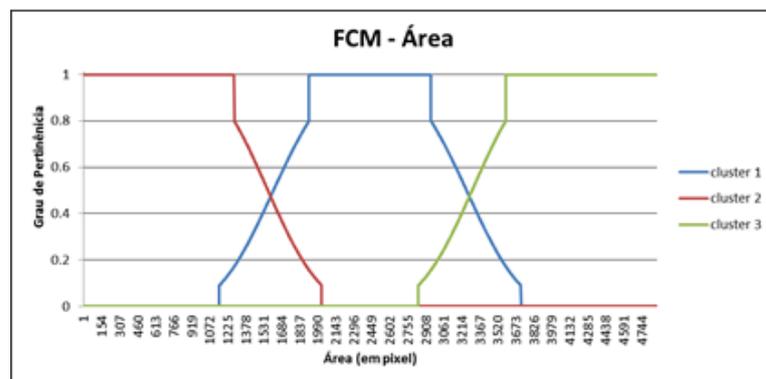


Figura 51 – Gráfico que representa a matriz de pertinência dos valores das áreas após a aplicação do  $\alpha$ -corte de 0,8.

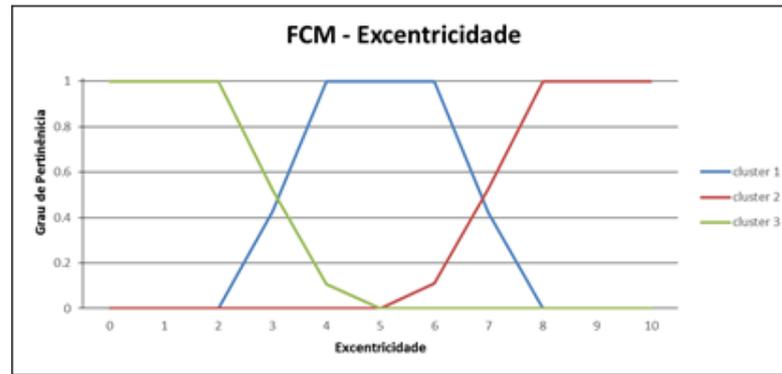


Figura 52 – Gráfico que representa a matriz de pertinência dos valores das excentricidades após a aplicação do  $\alpha$ -corte de 0,6.

Os resultados da aplicação do controlador *fuzzy* para excentricidade podem ser analisados nas tabelas 26, 27 e 28, que mostram os valores da quantidade de *pixel*, porcentagem de *pixels*, quantidade de objetos e porcentagem de objetos que representam cada material nas imagens das amostras A, B e C, respectivamente.

Tabela 26 – Resultados da aplicação do controlador *fuzzy* nas imagens da amostra com a mistura A.

Material	Qtd de <i>pixels</i>	Porcentagem de <i>pixels</i>	Qtd de objetos	Porcentagem de objetos
Ar	69586192	96,42	601569	99,79
EVA	1686965	2,34	852	0,14
Fibra	899508	1,25	419	0,07

Tabela 27 – Resultados da aplicação do controlador *fuzzy* nas imagens da amostra com a mistura B.

Material	Qtd de <i>pixels</i>	Porcentagem de <i>pixels</i>	Qtd de objetos	Porcentagem de objetos
Ar	80752184	96,87	654631	99,82
EVA	1407191	1,69	656	0,1
Fibra	1201811	1,44	526	0,08

Tabela 28 – Resultados da aplicação do controlador *fuzzy* nas imagens da amostra com a mistura C.

Material	Qtd de <i>pixels</i>	Porcentagem de <i>pixels</i>	Qtd de objetos	Porcentagem de objetos
Ar	76000816	81,29	671347	98,98
EVA	6071738	6,49	2497	0,37
Fibra	11424846	12,22	4411	0,65

Analisando a quantidade de objetos caracterizados nas misturas podemos identificar alguns falsos positivos. Grande parte deles se dão devido à grande similaridade de área e excentricidade entre os poros e o EVA contidos na amostra.

Na mistura A que não contém EVA nem fibra tivemos 852 objetos identificados como EVA e 419 objetos identificados como fibras e na mistura B que não contém fibras e segundo a classificação foram obtidos 526 objetos identificados como fibras de piaçava.

Como pode ser observado existe uma diminuição substancial de poros na amostra com fibra, esta se deve a que a fibra se comporta como uma ponte de tensão na amostra e diminui a quantidade de ar. Já a quantidade de EVA aumenta, já que as difere mais em tamanho do ar em amostras com fibra.

A partir da quantidade de *pixels* e da densidade de cada material foi possível encontrar a massa em gramas de cada material. Estes resultados são mostrados nas tabelas 29, 30 e 31 para as misturas A, B e C, respectivamente.

Tabela 29 – Quantidade total de *pixels* e massa de cada material na mistura A.

Material	Qtd de <i>pixels</i>	Massa em gramas	Porcentagem da massa total
Argamassa	1459656770	69,4946	99,974
Ar	69586192	-	-
EVA	1686965	0,0027	0,004

Fibra	899508	0,015	0,022
-------	--------	-------	-------

Tabela 30 – Quantidade total de *pixels* e massa de cada material na mistura B.

Material	Qtd de <i>pixels</i>	Massa em gramas	Porcentagem da massa total
Argamassa	1403098691	66,80188	99,967
Ar	80752184	-	-
EVA	1407191	0,0022	0,003
Fibra	1201811	0,0201	0,03

Tabela 31 – Quantidade total de *pixels* e massa de cada material na mistura C.

Material	Qtd de <i>pixels</i>	Massa em gramas	Porcentagem da massa total
Argamassa	1536646970	73,1601	99,726
Ar	76000816	-	-
EVA	6071738	0,0097	0,013
Fibra	11424846	0,191	0,26

Foi realizada uma aproximação da massa de cada material contido nas amostras a partir da quantidade de *pixels* classificados para cada um deles. Nessa aproximação tivemos 99,974% da massa representando a argamassa, 0,004% o EVA e 0,022% as fibras de piaçava presentes na amostra A. Na amostra B tivemos 99,967% de massa representando a argamassa, 0,003% o EVA e 0,03% as fibras de piaçava da amostra. A amostra C foi classificada com 99,726% de sua massa representando a argamassa, 0,013% representando o EVA e 0,26% as fibras de piaçava contidas na amostra.

A massa aproximada que obtivemos para os materiais diferem bastante com a quantidade real inserida em cada amostra, conforme descrito na seção 3.1 que

relata o processo de construção dos corpos de prova. Esta imprecisão se dá devido a alguns tons de cinza que representam a argamassa não serem retirados após a aplicação do algoritmo *k-means*. Esses tons permanecem nas imagens unindo dois objetos tornando-os apenas um objeto com formato irregular. Outra imprecisão ocorre devido ao intervalo das áreas serem muito grandes e a maioria dos objetos serem identificado como poros, que não tem massa.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

Uma solução para reduzir a degradação da natureza é a utilização de agregados como o EVA e reforços de fibra de piaçava para a produção de argamassas leves. O nosso trabalho consistiu em desenvolver uma metodologia para realizar a caracterização interna de amostras dessa argamassa leve. Essa caracterização é feita por meio do processamento e análise de imagens digitais dessas amostras, obtidas por micro tomografia por transmissão de raios X.

Neste trabalho desenvolveu-se uma metodologia que permite utilizar algoritmos de *clusterização* e SBRF para caracterizar os objetos em imagens micro tomográficas de argamassas leves reforçadas. Os resultados da metodologia foram satisfatórios para imagens de testes criadas com objetos pré identificados para a validação do controlador *fuzzy*.

As amostras de argamassa utilizadas foram criadas com três composições diferentes. A primeira mistura era composta por argamassa pura, a segunda com argamassa e EVA, e a terceira com argamassa, EVA e fibras de piaçava.

A metodologia foi primeiramente aplicada a imagens de teste construídas com objetos de classificação conhecida. Sendo que para estas imagens foi aplicado um controlador *fuzzy* baseado no método de inferência de Mamdani Clássico.

Os resultados para a aplicação do controlador foram satisfatórios, ainda que a base de regras tenha sofrido reajuste para as imagens que representam a mistura C. Esta alteração na base de regras foi necessária devido ao intervalo das áreas dos objetos ser grande.

Depois da aplicação do controlador para estas imagens de teste aplicou-se a metodologia para as imagens reais das amostras. O primeiro passo antes da caracterização dessas imagens foi a etapa de pré-processamento. Neste processo foram eliminadas algumas bordas que representavam falsos positivos provenientes do processo de captura das imagens. Estas bordas eliminadas são representadas pelo tom de cinza zero, ou seja, preto.

Após o pré-processamento, foi aplicado o algoritmo de *clusterização k-means* para agrupar os *pixels* das imagens classificando pelo tom de cinza. O algoritmo foi

aplicado com alguns valores de  $k$ , porém o que nos deu resultados mais satisfatórios foi o valor de  $k=3$ . Nesta etapa foi possível identificar os tons de cinza que representam a argamassa da mistura e separá-los dos tons que representam os demais objetos, como poros, EVA e fibras de piaçava.

Foi realizada uma tentativa de *reclusterizar* as imagens resultantes do *k-means* para tentar separar os demais objetos. Mas, devido ao intervalo dos tons de cinza serem muito pequeno não foi possível fazer essa classificação.

Uma nova tentativa de agrupar os objetos nas imagens resultantes da aplicação do *k-means* foi realizada aplicando o *FCM* nas imagens resultantes para classificar os objetos de acordo com a sua área (em *pixels*). Foram realizadas algumas aplicações e escolhe-se um corte 0,3 na matriz de pertinência e o valor de  $c=3$ , que é a quantidade de tipos de objetos contidos nas imagens (poros, EVA e fibras de piaçava).

Com a aplicação do *FCM* foi possível retirar ruídos produzidos por problemas na captura das imagens. Esses objetos causam imprecisão nos resultados devido a suas áreas serem um valor muito maior às áreas dos demais objetos.

Após remover os ruídos, foi aplicado um controlador *fuzzy* para caracterizar os objetos restantes. Este controlador utilizou a área e excentricidade dos objetos como critério para a classificação.

A aplicação desse controlador *fuzzy* gerou resultados imprecisos devido à similaridade das áreas e excentricidades destes objetos e a má identificação de alguns objetos após a retirada dos tons de cinza que representam a argamassa das imagens.

A metodologia nos deu resultados satisfatórios na identificação da argamassa nas imagens originais e dos agregados nas imagens de teste das amostras. Para a classificação das imagens originais com resultados mais exatos devem ser inseridos outros critérios de classificação no controlador e realizada uma separação mais exata da argamassa e os demais materiais.

Como trabalho futuro a esta pesquisa propomos a aplicação do controlador *fuzzy* utilizando outros critérios de classificação, como volume, densidade dos

objetos, etc. Outra sugestão também é a utilização de imagens com melhor resolução para conseguir uma caracterização melhor ao *clusterizar* os tons da imagem.

O controlador *fuzzy* depois de incrementado, pode ser aplicado também nas imagens das amostras após ensaios mecânicos. Esta aplicação pode associar os poros com as fissuras provenientes desses ensaios.

A aplicação desta metodologia ou semelhantes podem ser úteis para o processamento de outros tipos de imagens ajustando fundamentalmente os critérios e a base de regras para o problema em específico.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALBUQUERQUE, M. P. DE; ALBUQUERQUE, M. P. DE. Processamento de imagens: métodos e análises. Centro Brasileiro de Pesquisas Físicas MCT. **Anais...** , 2000.

ALMEIDA, H. C. **Processamento tridimensional de imagens micro-tomográficas aplicando caracterização de misturas de concreto leve**, 2014. Universidade Estadual de Santa Cruz - UESC.

ANURATHA, V.; SINDHU, V.; NADU, T. MODIFIED FUZZY C-MEANS ALGORITHM IN MEDICAL IMAGES. **International Journal of Scientific & Engineering Research**, v. 3, 2012.

ARAÚJO, G. A. B.; ALVIM, R. DE C.; ALVI M, R. DE; ARLÉO, A. Uso de resíduos industriais de borracha tipo “EVA” para fabricação de produtos da construção civil. **17º Seminário de Iniciação Científica e 11ª Semana de Pesquisa e Pós-Graduação**, 2011. Ilhéus.

ARGENTA, M. A.; BURIOL, T. M.; HECKE, M. B. Metodologia para a obtenção de parâmetros físicos e geométricos do osso trabecular em função de imagens de microtomografia. Congresso Ibero Latino Americano de Métodos Computacionais em Engenharia. **Anais...** , 2010. Buenos Aires: (CILANCE).

ASSIS, J. T.; EINSFELD, R. A.; CARVALHO, G.; PESSÔA, J. R. DE C. Estudo da porosidade em concretos de alto desempenho por técnicas de processamento de imagens. X Encontro de Modelagem Computacional. **Anais...** , 2007. Nova Friburgo.

ASSIS, J. T. ET AL. Caracterização da porosidade em Concreto de Alto Desempenho Utilizando Técnicas de Processamento de Imagens. X Encontro de Modelagem Computacional, 2007, Nova Friburgo. **Anais...** , 2007. Nova Friburgo: X Encontro de Modelagem Computacional: UERJ. IPRJ.

\_\_\_\_\_. NBR 10006: Procedimento para obtenção de extrato solubilizado de resíduos sólidos. Rio de Janeiro, 2004.

\_\_\_\_\_. NBR 10007: Amostragem de resíduos sólidos. Rio de Janeiro, 2004.

\_\_\_\_\_. NBR 12655: Concreto de cimento Portland — Preparo, controle, recebimento e aceitação — Procedimento. Rio de Janeiro, 2015.

\_\_\_\_\_. NBR 13281: Argamassa para assentamento e revestimento de paredes e tetos — Requisitos. Rio de Janeiro, 2005.

\_\_\_\_\_. NBR 5738. Concreto -Procedimento para moldagem e cura de corpos-de-prova. Rio de Janeiro, 2008.

\_\_\_\_\_. NBR 7211: Agregados para concreto - especificação. Rio de Janeiro, 2009.

\_\_\_\_\_. NBR 7217: Agregados - Determinação da composição granulométrica. Rio de Janeiro, 1987.

\_\_\_\_\_. NBR 9778: Argamassa e concreto endurecidos - Determinação da absorção de água por imersão - Índice de vazios e massa específica. Rio de Janeiro, 2005.

BARROS, L.; BASSANEZI, R. **Tópicos de Lógica Fuzzy e Biomatemática**. Campinas: SP: UNICAMP/IMECC, 2006.

BELINI, U. L.; AL, E. Microtomografia de raios X (microCT) aplicada na caracterização anatômica da madeira de folhosa e de conífera. **Floresta e Ambiente**, p. 30–36, 2011.

BERRY, M. J. A.; LINOFF, G. Data Mining Techniques: For Marketing, Sales, and Customer Support. New York: Wiley Computer Publishing. **Anais...** , 1997.

BEZDEK, J. Pattern Recognition with Fuzzy Objective Function Algorithms. **Norwell, MA, USA: Kluwer Academic Publishers**, 1981.

BUSSAB, W. DE O.; MIAZAKI, É. S.; ANDRADE, D. F. DE. Introdução à Análise de Agrupamentos. 9º Simpósio Nacional de Probabilidade e Estatística. **Anais...** , 1990. São Paulo:ABE.

CALLISTER, W. D.; RETHWISCH, D. G. **Materials science and engineering: an introduction**. 8ª ed. New York: Wiley, 2009.

CAMPOS, V. DE O. **Segmentação Multicritério para Detecção de Nódulos Pulmonares em Imagens de Tomografia Computadorizada**, 2009. Pontifícia Universidade Católica do Rio de Janeiro.

CARASEK, H. A. Materiais de Construção Civil e Princípios de Ciência e Engenharia dos Materiais. **ISAIA, Geraldo Cechella**. 1st ed., p.863–904, 2007. São Paulo.

CARVALHO, A. C. P. História da tomografia computadorizada. **Revista Imagem**, p. 61–66, 2007.

CARVALHO, P. P. S.; ALVIM, R. DE C. R.; ALVIM, ARLÉO, DE A. Estudo da viabilidade do aproveitamento de fibras vegetais como reforço de matrizes cimentícias. In: **XII Seminário de Iniciação Científica e 9ª Semana de Pesquisa e Pós -Graduação da UESC**, 2007. Universidade Estadual de Santa Cruz, Ilhéus.

CINQUE, L.; FORESTI, G.; LOMBARDI, L. A clustering fuzzy approach for image segmentation, *Pattern Recognition* 37. p.1797–1807, 2004.

CNUUDE, V.; CNUUDE, J. .; DUPUIS, C.; JACOBS, P. J. . Recent progress in X-ray CT as a geosciences tool. **Applied Geochemistry**. p.826–832, 2006.

COELHO, T. S. ET AL. Uso do método fuzzy c-means para segmentação de imagens dermatoscópicas de lesões de pele. **Revista Brasileira de Física Médica**, 2012.

DOMÍNGUEZ, J. S. **Paralelização do algoritmo FDK para reconstrução 3D de imagens tomográficas usando unidades gráficas de processamento e CUDA-C**. Dissertação (Mestrado). Universidade do Estado do Rio de Janeiro, Nova Friburgo, 2012.

DOVAL, D.; MANCORIDIS, S.; MITCHELL, B. S. Automatic Clustering of Software Systems using a Genetic Algorithm. 1999 International Conference on Software Tools and Engineering Practice (STEP '99). **Anais...**, 1999.

DUNN, J. C. A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters. **Journal of Cybernetics, Taylor & Francis**, v. 3, p. 32–57, 1973.

FASULO, D. An Analysis of Recent Work on Clustering Algorithms. **Technical Report, Dept. of Computer Science and Engineering**, 1999. Univ. of Washington.

FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. From Data Mining to Knowledge Discovery in Databases. **AI Magazine**, v. 17, p. 37–54, 1996.

GARLET, G. **Aproveitamento de resíduos de E.V.A. (Ethylene Vinyl Acate) como agregado para concreto leve na construção civil**. Dissertação (Mestrado). Universidade Federal do Rio Grande do Sul, Porto Alegre, 1998.

GARLET, G.; GRAVEN, H. A. Concreto leve usando resíduos de E.V.A. da indústria calçadista. Encontro Nacional sobre Edificações e Comunidades Sustentáveis, Canela, 1997. Resumos... Encontro Nacional sobre Edificações e Comunidades Sustentáveis. **Anais...** p.93–98. Porto Alegre, RS, 1997.

GOMES, O. DA F. M. **Processamento e Análise de Imagens Aplicados à caracterização Automática de Materiais**. Dissertação (Mestrado). Pontificia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2001.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. Edgard Blu ed. São Paulo, 2010.

GUIERA, A. J. A. ET AL. Segmentação por Agrupamentos Fuzzy C-means em Imagens LiDAR Aplicados na Identificação de Linhas de Transmissão de Energia Elétrica. Espaço Energia. **Anais...** p.24–31, 2005.

JAHNE, B. **Digital Image Processing**. 5ª ed. Berli, Alemanha: Editora Spring, 2002.

JÚNIOR, S. H. **Materiais à base de cimento reforçados com fibra vegetal: Reciclagem de resíduos para a construção de baixo custo**. Tese (Livre Docência). Universidade de São Paulo (USP), São Paulo, 2000..

JÚNIOR, S. R. **Análise da ruptura dielétrica em materiais isolantes elétricos de cabos isolados XLPE e EPR por Tomografia 2D e 3D.** Dissertação (Mestrado). Universidade Tecnológica Federal do Paraná, Curitiba, 2008.

LOPES DOS SANTOS, J. F. **CARACTERIZAÇÃO DE ARGAMASSAS LEVES REFORÇADAS COM FIBRAS DE PIAÇAVA UTILIZANDO TOMOGRAFIA COMPUTADORIZADA E ANÁLISE DE FOURIER.** Dissertação (Mestrado). Universidade Estadual de Santa Cruz, Ilhéus, 2015.

LOPES, P. DOS S.; ALVIM, R. DE C.; ALVIM, R. DE A. A. Tratamento de fibras de Piaçava para reforço de compósitos de cimento leve. In: UESC (Ed.); 17º Seminário de Iniciação Científica e 11ª Semana de Pesquisa e Pós-Graduação. **Anais...**, 2011. Ilhéus.

MACQUEEN, J. B. Some Methods for classification and Analysis of Multivariate Observations, Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability. p.281–297, 1967. University of California Pres.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens.** Rio de Janeiro: Brasport, 1999.

MEES, F.; AL., E. Applications of X-ray computed tomography in the geosciences. **Geological Society**, v. 215, p. 1–6, 2003.

MEHTA, K.; MONTEIRO, P. **Concreto: estrutura, propriedades e materiais.** 3ª ed. São Paulo: PINI, 1994.

MEHTA, P. K.; MONTEIRO, P. J. M. **Microstructure , Properties and Materials.** 3ª ed. McGraw-Hill, 2006.

MEIRA SILVA, R. **APLICAÇÃO DE IMAGENS MICROTOMOGRÁFICAS NA CARACTERIZAÇÃO DE COMPÓSITOS CIMENTÍCIOS LEVES REFORÇADOS COM FIBRAS DE PIAÇAVA.** Dissertação (Mestrado). Universidade Estadual de Santa Cruz, Ilhéus, 2012.

MENDES, R. **A tomografia computadorizada de raios x como método não destrutivo de análise volumétrica de concreto: estudo de caso em testemunho de concreto da usina hidroelétrica Mourão.** Dissertação (Mestrado). Universidade Federal do Paraná, Curitiba, 2010.

MENGER, K. Statistical metrics. **Proceedings of the National Academy of Sciences** 28. p.535–537, 1942.

NETO, J. M. DOS R. ET AL. A microtomografiacomputadorizada de raios x integrada à petrografia no estudo tridimensional de porosidade em rochas. **Revista Brasileira de Geociências**, p. 498–508, 2011.

NIVALDO, T. DE A. F.; DANTAS, C. P.; LEAL, A. F.; et al. Resistência mecânica de compósitos cimentícios leves utilizando resíduos industriais e fibras de sisal. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2012.

OKE, O. A. ET AL. Fuzzy kc-means clustering algorithm for medical image segmentation. ,2012.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. Thomson Le ed. 2008.

PERET, C. M.; SALOMAO, R.; ZAMBON, A. M. PANDOLFELLI, V. C. Reforço mecânico por fibras poliméricas e seus efeitos na secagem de concretos refratários. **Cerâmica**, v. 49, p. 257–261, 2003.

PESSÔA, J. R. D. C.; ASSIS, J. T. D.; LOPES, R. T.; et al. **Microtomografia com Raio X e processamento de imagem na obtenção da porosidade do concreto**. Tese (Doutorado). Universidade do Estado do Rio de Janeiro, Nova Friburgo, 2011.

PIEKARZ, A. H. **Determinação do Volume em Vazios em Isoladores Poliméricos por Técnicas de Tomografia Digital de Raios X e Processamento de Imagens**. Dissertação (Mestrado). Universidade Federal do Paraná, Curitiba, 2006.

PISON, G.; J, S. A.; PETER, R. Displaying a clustering with CLUSPLOT. **Computational Statistics & Data Analysis**. p.381–392, 1999.

QUOIRIN, N. S. R. **Diagnóstico de Defeitos em Madeira por Tomografia de Raios X**. Dissertação (Mestrado). Universidade Federal do Paraná, Curitiba, 2004.

RABELO, A. B. **Análise da Utilização de Filtros Lineares e Não-Lineares na Recuperação de Imagens Degradadas**. Dissertação (Mestrado). Universidade Estadual de Campinas, Campinas, 2002.

ROSSIGNOLO, J. A. **Concreto leve de alto desempenho modificado com SB para pré-fabricados esbeltos - dosagem, produção, propriedades e microestrutura**. Dissertação (Mestrado). Universidade de São Paulo, São Carlos, 2003.

SANTIAGO, E. Q. R. **Utilização de Agregados de EVA e RCD para obtenção de concretos leves**. Dissertação (Mestrado). Universidade Estadual de Feira de Santa (UEFS), Feira de Santana, 2008.

SANTIAGO, E. Q. R.; LIMA, P. R. L.; LEITE, M. B. Comportamento mecânico sob temperatura moderada de concreto leve reciclado produzido com resíduo de EVA e RCD. **Revista IBRACON DE ESTRUTURAS E MATERIAIS**, 2009.

SILVA MENDONÇA, R. **CARATERIZAÇÃO DE ARGAMASSAS LEVES USANDO PROCESSAMENTO TRIDIMENSIONAL DE IMAGENS E PROCESSAMENTO PARALELO**. Dissertação (Mestrado). Universidade Estadual de Santa Cruz, Ilhéus, 2016.

SILVA, R. M. Estudo da resistência mecânica de um compósito cimentício leve reforçado com fibras de piaçava. **Revista Educação, Tecnologia e Cultura**, 2011.

SILVA, R. M.; DOMINGUEZ, D. S.; ASSIS, J. T.; IGLESIAS, S. M. Characterization of Lightweight Cementitious Composites Reinforced with Piassava Fibers using Mechanical Tests and Micro-Tomography. *International Review of Chemical Engineering* (Testo Stampato). **Anais...**, 2013.

SILVA, R. M.; R.C., A.; D.S, D. Study of mechanical strength of a cementitious composite reinforced with piassava fibers. p.8:29–39, 2011. E.T.C. Educação, Tecnologia e Cultura.

SOUZA, T. F. DE. **Avaliação da resistência de compósitos de argamassas leves de EVA reforçados com fibras de piaçava**. Dissertação (Mestrado). Universidade Estadual de Santa Cruz, Ilhéus, 2012.

TAKAHASHI, A.; BEDREGAL, B. R. C.; LYRA, A. Uma versão intervalar do método de segmentação de imagens utilizando o k-means. *Trends in Applied and Computational Mathematics*. **Anais...** p.315–324, 2005.

TARTUCE, RONALDO GIOVANNETTI, E. **Princípios básicos sobre concreto de cimento Portland**. São Paulo: Editora Pini, 1990.

TERANO, T.; ASAI, K.; SUGENO, M. **Applied Fuzzy Systems**. Tokyo, Japan, 1994.

TOLEDO, R. D.; ENGLAND, G. L.; KHOSROW., G. Comportamento em compressão de argamassas reforçadas com fibras naturais. **Revista Brasileira de Engenharia Agrícola Ambiental**, p. 79–88, 1997. Campina grande.

YAMBAL, M.; GUPTA, H. Image segmentation using fuzzy C means clustering: a survey. **International Journal of Advanced Research in Computer and Communication Engineering**, 2013.

YONAMINE, F. S.; LUCIA, S.; CARVALHO, V. O. DE; NICOLETTI, M. DO C. **Aprendizado não supervisionado em domínios fuzzy – algoritmo fuzzy c - means**. Universidade Federal de São Carlos, São Carlos, 2002.

ZADEH, L. A. Fuzzy sets. **Information and Control** 8. p.338–353, 1965.

**APÊNDICE A – ALGORITMO DE PRÉ-PROCESSAMENTO EM MATLAB**

```
1 clear;
2
3 nomeEntrada = 'C:\Users\Gabriel Mello\Desktop\MESTRADO\Pesquisa\Experimentos\Maio-
4 2015_02\argeva-30naoensaiado_argeva_Rec\Cinza\30naoensaiado_argeva__rec0250.bmp';
5
6 A = imread(nomeEntrada);
7
8 [W,H] = size(A);
9
10 for col=1:W
11     lin=1;
12
13     while (lin <= H) && (A(lin, col)==0)
14         A(lin, col) = 255;
15         lin = lin+1;
16     end
17
18 end
19
20
21 for lin=1:H
22     col=1;
23
24     while((col <= W) && ((A(lin, col)==0) || (A(lin, col) == 255)))
25         A(lin, col) = 255;
26         col = col+1;
27     end
28 end
29
30 for col=1:W
31     lin = H;
32
33     while((lin>=1) && ((A(lin, col)==0) || (A(lin, col) == 255)))
34         A(lin, col) = 255;
35         lin=lin-1;
36     end
37 end
38
39 for lin=1:H
40     col = W;
41
42     while((col>=1) && ((A(lin, col)==0) || (A(lin, col) == 255)))
43         A(lin, col) = 255;
44         col=col-1;
45     end
46
47 end
48
49 imshow(A)
50
51
```

## APÊNDICE B – ALGORITMO K-MEANS EM MATLAB

```

1  clear;
2
3  %numero de clusters
4  N = 3;
5
6  pasta_entrada_ARG = 'C:\Users\ProjetoHTR10\Desktop\TRABALHO GABRIEL\K-MEANS -
7  COR\ARG\';
8
9  caminho_entrada_ARG = 'C:\Users\ProjetoHTR10\Desktop\TRABALHO
10 GABRIEL\Imagens\Novas_16bits\ARG\9_nao_ensaiado\9_naoensaiado_arg_Rec\9_naoensaiado
11 _arg__IR_rec';
12
13 caminho_saida_ARG = 'C:\Users\ProjetoHTR10\Desktop\TRABALHO GABRIEL\K-MEANS -
14 COR\ARG\';
15
16
17 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% K-MEANS %%
18
19 for i=1:N
20     centros(i) = (255*rand());
21 end
22
23 for j=1:256
24
25     %calcula as distâncias de cada centro ao tom de cinza j
26     for k=1:N
27         temp(k) = (abs((j-1) - centros(k)));
28     end
29
30     menor = temp(1);
31     indice_menor = 1;
32
33     %encontra a menor distância e o seu indice
34     for i=2:N
35         if temp(i)<menor
36             menor = temp(i);
37             indice_menor = i;
38         end
39     end
40
41     %guarda o indice do centro mais proximo de cada tom de cinza (0...255)
42
43     vetor(j) = indice_menor;
44 end
45
46
47
48 %contador para as iterações
49 iteracao = 1;
50
51 %fazer um while para realizar as iterações de recalculr os centros
52 while iteracao ~= 1000
53
54     valor = vetor(1);
55
56     min(valor) = 1;
57
58     %verificação dos valores minimo e máximo de cada cluster, para
59     %recalcular os centros
60     for i=2:256
61
62         if vetor(i) == valor

```

```

63         max(valor) = i;
64     else
65         valor = vetor(i);
66         min(valor) = i;
67     end
68 end
69
70 %faz o recálculo dos centros
71 for i=1:N
72     centros(i) = min(i) + (max(i)-min(i))/2;
73 end
74
75 %verifica de qual centro cada valor (0...255) está mais perto
76 for j=1:256
77
78     %calcula as distâncias de cada centro ao tom de cinza j
79     for k=1:N
80         temp(k) = (abs(j - centros(k)));
81     end
82
83     menor = temp(1);
84     indice_menor = 1;
85
86     %encontra a menor distância e o seu indice
87     for i=2:N
88         if temp(i)<menor
89             menor = temp(i);
90             indice_menor = i;
91         end
92     end
93
94     %guarda o indice do centro mais proximo de cada tom de cinza (0...255)
95     vetor(j) = indice_menor;
96
97 end
98
99     iteracao = iteracao+1;
100
101 end
102
103 %verifica os valores máximo e mínimo de cada cluster
104 valor = vetor(1);
105 min(valor) = 1;
106
107 %verificação dos valores minimo e máximo de cada cluster, para
108 %recalcular os centros
109 for i=2:256
110     if vetor(i) == valor
111         max(valor) = i;
112     else
113         valor = vetor(i);
114         min(valor) = i;
115     end
116 end
117
118 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
119 %%%
120 % Os intervalos correspondentes a cada cluster ja foram calculados. Agora
121 % percorremos cada imagem, verificando a qual cluster cada pixel
122 % corresponde.
123 %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
124 %%%
125
126 for indice=200:2050
127
128     %abre a imagem de entrada
129     if indice < 1000
130         nomeEntrada = strcat(caminho_entrada_ARG, '0', int2str(indice),

```

```

131     '.bmp');
132     else
133         nomeEntrada = strcat(caminho_entrada_ARG, int2str(indice), '.bmp');
134     end
135
136     A = imread(nomeEntrada);
137
138     [xt,yt] = size(A);
139     %%% eliminação de bordas
140
141     for col=1:xt
142         lin=1;
143
144         while ((lin <= yt) && ((A(lin, col)==0) || (A(lin, col) == 255)))
145             A(lin, col) = 255;
146             lin = lin+1;
147         end
148     end
149
150     for lin=1:yt
151         col=1;
152
153         while((col <= xt) && ((A(lin, col)==0) || (A(lin, col) == 255)))
154             A(lin, col) = 255;
155             col = col+1;
156         end
157     end
158
159     for col=1:xt
160         lin = yt;
161
162         while((lin>=1) && ((A(lin, col)==0) || (A(lin, col) == 255)))
163             A(lin, col) = 255;
164             lin=lin-1;
165         end
166     end
167
168     for lin=1:yt
169         col = xt;
170
171         while((col>=1) && ((A(lin, col)==0) || (A(lin, col) == 255)))
172             A(lin, col) = 255;
173             col=col-1;
174         end
175     end
176
177     end
178     %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
179
180     %verifica cada pixel da imagem e grava em seus correspondentes clusters
181     for i=1:N
182
183         for j=1:yt
184             for z=1:xt
185                 if((A(j,z) <= max(i)-1) & (A(j,z) >= min(i)-1))
186
187                     B(j,z) = A(j,z);
188
189                     else
190                         B(j,z) = 255;
191                     end
192                 end
193             end
194
195             B = uint8(B);
196
197             if indice < 1000
198                 nomeSaida = strcat(caminho_saida_ARG, '0', int2str(indice),

```

```
199     '_cluster', int2str(i), '.bmp');
200         else
201             nomeSaida = strcat(caminho_saida_ARG, int2str(indice),
202 '_cluster', int2str(i), '.bmp');
203         end
204
205             imwrite(B, nomeSaida, 'bmp');
206         end
207     end
208 end
```

## APÊNDICE C – ALGORITMO FUZZY C-MEANS EM MATLAB

```

1  clear;
2
3  C = 3;
4
5  corte = 0.2;
6
7  indice_minimo = 1;
8  indice_maximo = 12;
9
10 caminho_entrada = 'C:\Users\Gabriel Mello\Desktop\MESTRADO\Pesquisa\Experimentos\9-
11 Março-2016\5-c-means area antigas\';
12
13 caminho = 'C:\Users\Gabriel Mello\Desktop\MESTRADO\Pesquisa\Experimentos\9-Março-
14 2016\5-c-means area antigas\';
15
16 maior = 0;
17 menor = 10000;
18
19
20 for indice = indice_minimo:indice_maximo % encontra a área do maior e do menor
21 objeto
22
23     %abre a imagem de entrada
24
25     nomeEntrada = strcat(caminho_entrada, int2str(indice), '.bmp');
26
27     A = imread(nomeEntrada);
28
29     binarizada = A<100;
30
31     dados = regionprops(binarizada,'All'); % 'dados' recebe os dados de cada objeto
32 em forma de structs
33
34     [qtd, x] = size(dados); % 'qtd' recebe a quantidade de objetos contidos na
35 imagem
36
37     for i=1:qtd
38
39         if dados(i).Area > maior
40             maior = dados(i).Area;
41         end
42
43         if dados(i).Area < menor
44             menor = dados(i).Area;
45         end
46
47     end
48
49 end
50
51 %% inicialização da matriz com os dados a clusterizar
52 for i= menor:maior %indice = i-menor+1 - > i é a área
53     data(i-menor+1, 1)=i;
54 end
55
56 %% Aplicação do Fuzzy C-Means
57 [CENTER, U, OBJ_FCN] = fcm(data, C);
58
59 %
60 %%percorre imagem por imagem fazendo a clusterização
61 for indice = indice_minimo:indice_maximo

```

```

62
63     for i = 1:C
64         %abre a imagem de entrada
65
66             nomeEntrada = strcat(caminho_entrada, int2str(indice), '.bmp');
67
68             A = imread(nomeEntrada);
69
70             [xt,yt] = size(A);
71
72             for k=1:xt %cria a imagem de saida branca para ir acrescentando os
73 objetos
74                 for t=1:yt
75                     B(k, t) = 255;
76                 end
77             end
78
79             binarizada = A<100;
80
81             dados = regionprops(binarizada,'All'); % 'dados' recebe os dados de cada
82 objeto em forma de structs
83
84             test = regionprops(binarizada, 'PixelList');
85             %disp(test(1).PixelList);
86
87             [qtd, x] = size(dados); % 'qtd' recebe a quantidade de objetos contidos na
88 imagem
89
90             for j=1:qtd %verifica a área objeto por objeto
91
92                 coluna = dados(j).Area - menor + 1;
93
94                 if(U(i, coluna) >= corte)
95                     pixels = test(j).PixelList;
96
97                     for w=1:dados(j).Area
98                         x = pixels(w, 1);
99                         y = pixels(w, 2);
100
101                         B(x, y) = 0;
102
103                     end
104
105                 end
106             end
107
108             %grava a matriz de saida em uma imagem para o cluster
109             nomeSaida = strcat(caminho_entrada, int2str(indice),
110 '_FCM_cluster', int2str(i), '.bmp');
111
112             imwrite(B, nomeSaida, 'bmp');
113
114         end
115
116     end

```

## APÊNDICE D – CONTROLADOR FUZZY EM MATLAB

```

1  clear;
2
3  indice_minimo_ARG = 200;
4  indice_maximo_ARG = 2050;
5
6  caminho = 'C:\Users\ProjetoHTR10\Desktop\TRABALHO GABRIEL\C-MEANS - ÁREA -
7  RECLUSTER5-4\';
8
9  %ARG
10 caminho_entrada_ARG = 'C:\Users\ProjetoHTR10\Desktop\TRABALHO GABRIEL\C-MEANS -
11  ÁREA - RECLUSTER4\ARG\';
12 caminho_ARG = 'C:\Users\ProjetoHTR10\Desktop\TRABALHO
13  GABRIEL\SAIDAS_CONTROLADOR\ARG\';
14
15 nomeEntrada = ('C:\Users\ProjetoHTR10\Desktop\TRABALHO
16  GABRIEL\SAIDAS_CONTROLADOR\3clusters_excentricidade.txt');
17
18 arquivo = fopen(nomeEntrada);
19
20 %lê os graus de pertinência das excentricidades
21 graus_exc=fscanf(arquivo,'%d\t%f\t%f\t%f\t\n', [4 101]);
22
23 %modifica o gráfico dos graus de pertinência
24 for i=2:4
25     for j=1:101
26         if(graus_exc(i, j) > 0.9)
27             matriz_exc(j, i-1) = 1;
28
29         else if (graus_exc(i, j) < 0.09)
30             matriz_exc(j, i-1) = 0;
31
32         else
33             matriz_exc(j, i-1) = graus_exc(i, j);
34         end
35     end
36 end
37
38 %%grava em arquivo
39 nomeSaida = ('C:\Users\ProjetoHTR10\Desktop\TRABALHO
40  GABRIEL\SAIDAS_CONTROLADOR\pertinencias_exc.txt');
41
42 arq = fopen(nomeSaida,'at');
43
44 fprintf(arq,'\t');
45
46 for indices= 1:3
47     fprintf(arq, 'cluster %d\t', indices);
48 end
49
50 for cont=1:101
51     fprintf(arq, '\n%d\t', cont);
52
53     for clusters=1:3
54         fprintf(arq, '%f\t', matriz_exc(cont, clusters));
55     end
56 end
57
58 fclose(arq);
59
60 %lê os graus de pertinência das áreas
61 nomeEntrada = ('C:\Users\ProjetoHTR10\Desktop\TRABALHO

```

```

63 GABRIEL\SAIDAS_CONTROLADOR\3clusters_area.txt');
64
65 arquivo = fopen(nomeEntrada);
66
67 graus_area=fscanf(arquivo,'%d\t%f\t%f\t%f\t\n', [4 4874]);
68
69 %modifica o gráfico dos graus de pertinência
70 for i=2:4
71     for j=1:4874
72         if(graus_area(i, j) > 0.8)
73             matriz_area(j, i-1) = 1;
74
75         else if (graus_area(i, j) < 0.09)
76             matriz_area(j, i-1) = 0;
77
78         else
79             matriz_area(j, i-1) = graus_area(i, j);
80         end
81     end
82 end
83
84 %%grava em arquivo
85 nomeSaida = strcat('C:\Users\ProjetoHTR10\Desktop\TRABALHO
86 GABRIEL\SAIDAS_CONTROLADOR\pertinencias_area.txt');
87
88
89 arq2 = fopen(nomeSaida,'at');
90
91 fprintf(arq2,'\t');
92
93 for indices= 1:3
94     fprintf(arq2, 'cluster %d\t', indices);
95 end
96
97 for cont=1:4874
98     fprintf(arq2, '\n%d\t', cont);
99
100     for clusters=1:3
101         fprintf(arq2, '%f\t', matriz_area(cont, clusters));
102     end
103 end
104
105 fclose(arq2);
106
107 contadorAR_ARG = 0;
108 contadorEVA_ARG = 0;
109 contadorFIB_ARG = 0;
110
111 for indice = indice_minimo_ARG:indice_maximo_ARG
112
113     nomeEntrada = strcat(caminho_entrada_ARG, int2str(indice),
114 '_FCM_cluster_2.bmp');
115
116     A = imread(nomeEntrada);
117
118     [xt,yt] = size(A);
119
120     for k=1:xt %cria a imagem de saida branca para ir acrescentando os objetos
121         for t=1:yt
122             B(k, t) = 255;
123         end
124     end
125
126     binarizada = A<100;
127
128     dados = regionprops(binarizada,'All'); % 'dados' recebe os dados de cada objeto
129 em forma de structs
130

```

```

131     test = regionprops(binarizada, 'PixelList');
132
133     [qtd, x] = size(dados); % 'qtd' recebe a quantidade de objetos contidos na
134     imagem
135
136     %%excentricidade - > baixa: cluster 3 ; media: cluster 1 ; alta: cluster 2
137     %%area - > P: cluster 2 ; M: cluster 1 ; G: cluster 3
138
139     for j=1:qtd %verifica a área objeto por objeto
140
141         area = dados(j).Area;
142         exc = int8(dados(j).Eccentricity*100)+1;
143
144         %%%Base de regras%%
145         %%vetor de regras ativadas para o objeto
146         for i=1:9
147             regras(i)=0;
148         end
149
150         %R1
151         if (matriz_area(area, 2)~= 0) && (matriz_exc(exc, 3)~= 0 )
152             regras(1) = min(matriz_area(area, 2), matriz_exc(exc, 3));
153         end
154
155         %R2
156         if (matriz_area(area, 2)~= 0) && (matriz_exc(exc, 1)~= 0 )
157             regras(2) = min(matriz_area(area, 2), matriz_exc(exc, 1));
158         end
159
160         %R3
161         if (matriz_area(area, 2)~= 0) && (matriz_exc(exc, 2)~= 0 )
162             regras(3) = min(matriz_area(area, 2), matriz_exc(exc, 2));
163         end
164
165         %R4
166         if (matriz_area(area, 1)~= 0) && (matriz_exc(exc, 3)~= 0 )
167             regras(4) = min(matriz_area(area, 1), matriz_exc(exc, 3));
168         end
169
170         %R5
171         if (matriz_area(area, 1)~= 0) && (matriz_exc(exc, 1)~= 0 )
172             regras(5) = min(matriz_area(area, 1), matriz_exc(exc, 1));
173         end
174
175         %R6
176         if (matriz_area(area, 1)~= 0) && (matriz_exc(exc, 2)~= 0 )
177             regras(6) = min(matriz_area(area, 1), matriz_exc(exc, 2));
178         end
179
180         %R7
181         if (matriz_area(area, 3)~= 0) && (matriz_exc(exc, 3)~= 0 )
182             regras(7) = min(matriz_area(area, 3), matriz_exc(exc, 3));
183         end
184
185         %R8
186         if (matriz_area(area, 3)~= 0) && (matriz_exc(exc, 1)~= 0 )
187             regras(8) = min(matriz_area(area, 3), matriz_exc(exc, 1));
188         end
189
190         %R9
191         if (matriz_area(area, 3)~= 0) && (matriz_exc(exc, 2)~= 0 )
192             regras(9) = min(matriz_area(area, 3), matriz_exc(exc, 2));
193         end
194
195         %encontra o maximo dos minimos
196         maior = regras(1);
197         posicao_maior = 1;
198

```

```

199         for i=2:9
200             if(regras(i)> maior)
201                 maior = regras(i);
202                 posicao_maior = i;
203             end
204         end
205
206         pixels = test(j).PixelList;
207
208
209         %%define qual cluster pertence o objeto
210         if(posicao_maior == 1 || posicao_maior == 4 || posicao_maior == 7 ||
211 posicao_maior == 2) %é ar
212             for w=1:dados(j).Area
213                 x = pixels(w, 1);
214                 y = pixels(w, 2);
215
216                 B(x, y) = 150;
217
218                 contadorAR_ARG = contadorAR_ARG + 1;
219             end
220         end
221     end
222
223     if(posicao_maior == 3 || posicao_maior == 5 || posicao_maior == 8) %é eva
224         for w=1:dados(j).Area
225             x = pixels(w, 1);
226             y = pixels(w, 2);
227
228             B(x, y) = 95;
229
230             contadorEVA_ARG = contadorEVA_ARG + 1;
231         end
232     end
233 end
234
235     if(posicao_maior == 6 || posicao_maior == 9) %é fibra
236         for w=1:dados(j).Area
237             x = pixels(w, 1);
238             y = pixels(w, 2);
239
240             B(x, y) = 0;
241
242             contadorFIB_ARG = contadorFIB_ARG + 1;
243         end
244     end
245 end
246
247 end
248
249 B = uint8(B);
250
251 nomeSaida = strcat(caminho_ARG, int2str(indice), '.bmp');
252
253 imwrite(B, nomeSaida, 'bmp');
254
255 end

```