

## UNIVERSIDADE ESTADUAL DE SANTA CRUZ PRO-REITORIA DEPESQUISA E PÓSGRADUAÇÃO

Programa De Pós-Graduação Em Modelagem Computacional Em Ciência E Tecnologia

Miquéias Amorim Santos Silva

## ANÁLISE DE CONCRETOS USANDO TÉCNICAS DE CLUSTERIZAÇÃO E LÓGICA *FUZZY*

## **PPGMC-UESC**

Ilhéus - Ba 2020 Miquéias Amorim Santos Silva

# ANÁLISE DE CONCRETOS USANDO TÉCNICAS DE CLUSTERIZAÇÃO E LÓGICA *FUZZY*

### **PPGMC-UESC**

Trabalho apresentado 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. Paulo Eduardo Ambrósio

## MIQUÉIAS AMORIM SANTOS SILVA

### ANÁLISE DE CONCRETOS USANDO TÉCNICAS DE CLUSTERIZAÇÃO E LÓGICA FUZZY

Ilhéus, 30/03/2021

Comissão Examinadora

**Prof<sup>a</sup>. Dr<sup>a</sup>. Susana Marrero Iglesias** Universidade Estadual de Santa Cruz / UESC (Orientadora)

**Dr. Franco Dani Rico Amado** Universidade Estadual de Santa Cruz / UESC

**Dr. Diego Gervasio Frías Suárez** Universidade do Estado da Bahia/ UNEB

Dedico este trabalho em memória de Agnaldo, ensinava a todos através do exemplo.

### AGRADECIMENTOS

A Deus, por ter permitido que eu tivesse saúde e determinação para não desanimar durante a realização deste trabalho. A minha família em especial a minha esposa Andressa Amorim pelo apoio. Aos amigos, que sempre estiveram ao meu lado, pela amizade incondicional e pelo apoio demonstrado ao longo de todo o período de tempo em que me dediquei a este trabalho, em especial aos amigos Thiago e Givaldo. Aos professores do programa, em especial a minha orientadora Dr<sup>a</sup>. Susana pelas correções e ensinamentos que me permitiram apresentar um melhor desempenho no meu processo de formação acadêmica ao longo do curso. A todos que participaram, direta ou indiretamente do desenvolvimento deste trabalho de pesquisa, enriquecendo o meu aprendizado. À CAPES pelo suporte financeiro, à Universidade Estadual de Santa Cruz e ao Programa de Pós Graduação em Modelagem Computacional, essenciais no meu processo de formação acadêmica, pela dedicação, e por tudo o que aprendi nesta caminhada.

"A experiência não permite nunca atingir a certeza absoluta. Não devemos procurar obter mais que uma probabilidade "

(Russell, Bertrand)

#### ANÁLISE DE CONCRETOS USANDO TÉCNICAS DE CLUSTERIZAÇÃO E LÓGICA FUZZY.

#### **RESUMO**

Nos últimos anos, diferentes soluções têm sido apresentadas para o reaproveitamento de resíduos sólidos. Assim, diferentes indústrias podem reciclar esses resíduos como componentes na sua própria produção. Dentre essas indústrias, está a construção civil, em função da variedade de materiais que utiliza, tornando-se uma excelente alternativa para o reaproveitamento de resíduos sólidos. O reuso de materiais tem um grande impacto ambiental e é a chave para a manutenção do nível de consumo na sociedade moderna e, para a sobrevivência do nosso planeta. O EVA da indústria calçadista é um resíduo de difícil descarte, mas pode ser utilizado como agregado leve para argamassas e concretos. Proporciona a essas misturas boas características acústicas e térmicas e uma baixa massa específica. No entanto, sua adição causa perda de propriedades mecânicas. Isso pode ser contornado usando fibras nas misturas que funcionam como pontes de tensão evitando a transmissão de fissuras. Um exemplo de fibra natural é a piaçava, proveniente de uma planta endêmica do sul da Bahia. Esses novos compósitos precisam ser examinados e caracterizados e, para isso, estão surgindo modernas técnicas de análise. Dentre essas técnicas destaca-se a microtomografia computadorizada, um teste não destrutivo que permite a obtenção de imagens internas bidimensionais e tridimensionais dos objetos analisados e que podem ser utilizadas na caracterização do material. São muitas as técnicas utilizadas no processamento de imagens entre elas, as técnicas fuzzy têm se destacado por sua capacidade na classificação de elementos e problemas que apresentam características difusas ou sobrepostas. Neste trabalho, foi desenvolvida uma metodologia utilizando técnicas de processamento de imagens, clusterização e abordagem fuzzy baseada na metodologia de inferência de Takagi-Sugeno-Kang para a análise e classificação de agregados e poros em amostras de concreto. A partir desta metodologia foi possível determinar diversas características como porosidade, apresentando um valor de 5,41% para o concreto de referência e valores entre 4% e 15,28% para o concreto leve, porcentagem de agregado graúdo com valores entre 45,18% e 54,74% e porcentagem de agregado leve, onde foram apresentados melhores resultados para o sistema com a base de 27 regras. Esses percentuais foram comparados com a literatura e os dados experimentais, apresentando valores satisfatórios. Os resultados mostram que o uso de microtomografia computadorizada combinada com técnicas fuzzy pode ser usado para caracterizar amostras de concretos incorporados com EVA e fibra.

Palavras-chave: Lógica Fuzzy, Processamento de Imagem, Concretos Leves.

#### CONCRETE ANALYSIS USING CLUSTER TECHNIQUES AND FUZZY LOGIC

#### ABSTRACT

In recent years, different solutions have been presented for the reuse of solid waste. Thus, different industries can recycle this waste as components in their own production. Among these industries is the civil construction industry, due to the variety of materials it uses, making it an excellent alternative for the reuse of solid waste. The reuse of materials has a great environmental impact and is the key to maintaining the level of consumption in modern society and the survival of our planet. The EVA from the footwear industry is a residue of difficult disposal, but can be used as lightweight aggregate for mortar and concrete. It provides these mixtures with good acoustic and thermal characteristics and a low specific mass. However, its addition causes loss of mechanical properties. This can be circumvented by using fibers in the mixtures that act as tension bridges preventing the transmission of cracks. An example of a natural fiber is piassava, which comes from a plant endemic to southern Bahia. These new composites need to be examined and characterized and, for this, modern analysis techniques are emerging. Among these techniques is the computerized microtomography, a nondestructive test that allows obtaining internal two and three-dimensional images of the objects analyzed and that can be used in the characterization of the material. There are many techniques used in image processing, among them, the *fuzzy* techniques have stood out for their ability to classify elements and problems that present diffuse or overlapping characteristics. In this work, a methodology was developed using image processing techniques, clustering and *fuzzy* system based on Takagi-Sugeno-Kang inference for the analysis and classification of aggregates and pores in concrete samples. From this methodology it was possible to determine several characteristics such as porosity, presenting a value of 5.41% for the reference concrete and values between 4% and 15.28% for the lightweight concrete, coarse aggregate percentage with values between 45.18% and 54.74% and percentage of lightweight aggregate, where the best results were presented for the system with a base of 27 rules. These percentages were compared with literature and experimental data, presenting satisfactory values. The results show that the use of computed microtomography combined with *fuzzy* techniques can be used to characterize concrete samples.

Keywords: Fuzzy Logic, Image Processing, Lightweight Concrete.

# ÍNDICE DE ILUSTRAÇÕES

## FIGURAS

Figura 1 - Comparativo entre as normas para classificação de concreto leve	16
Figura 2 -Esquema de transferência de tensões em uma matriz cimentícia reforçada por	fibras
	17
Figura 3 - Representação esquemática de um sistema de microtomografia de raios X	20
Figura 4 - Amostragem e quantização de uma imagem	21
Figura 5 - Aplicação dos filtro de média e mediana para remoção de ruido	22
Figura 6 – Exemplo de aplicação de um filtro gaussiano.	23
Figura 7 - Imagem limiarizada utilizando diferentes limiares.	25
Figura 8 – Histograma e limiar	26
Figura 9 – Imagem limiarizada utilizando o algoritmo de otsu.	26
Figura 10 – Representação espacial do algoritimo de k-means.	27
Figura 11 - Exemplos de elementos estruturantes.	28
Figura 12 - Morfologias de dilatação, erosão, abertura e fechamento	29
Figura 13 – Fronteiras e eixos de uma ROI para o cálculo de excentricidade	30
Figura 14 - Folha da samambaia apresentando características fractais	31
Figura 15 - Representação das malhas de quadrados do algoritimo box-counting en	n duas
iterações.	32
Figura 16 - Funcões de pertinência.	34
Figura 17 - Fluxograma de um sistema <i>fuzzy</i>	40
Figura 18 - Sistema baseado em mandani	42
Figura 19 - Sistema baseado em takagi-sugeno	43
Figura 20 - Takagi–sugeno como uma aproximação linear suavizada por peças de uma t	funcão
não linear	43
Figura 21 - Fluxograma do processo da metodologia aplicada.	52
Figura 22 - Exemplo de imagem digital original gerada pelo ensaio de microCT do co	orpo de
prova 1EG15.	54
Figura 23 - Segmentação por diferentes técnicas	56
Figura 24 – Processo de segmentação da pedra	57
Figura 25 - Imagem binária contendo máscara que representa a área total da amostra	57
Figura 26 - Segmentação do CR apontando a dimensão fractal para um dos elementos in	ternos.
	59
Figura 27 - Funcões de pertinência dos subconjuntos <i>fuzzy</i> baixo, médio e alto, das va	riáveis
área, dimensão fractal e excentricidade.	63
Figura 28 - fluxograma do sistema de inferência baseado em TSK	66
Figura 29 - Exemplo de imagem de controle com 7 objetos para validação do sistema	67
Figura 30 - Percentual de objetos encontrados em cada fatia na segmentação do poro. 1	EVA e
fibra da amostra	69
Figura 31- Percentual de objetos encontrados em cada fatia na segmentação do agregado s	graúdo
da amostra.	69
Figura 32 - Variação abrupta da pedra no concreto para um intervalo de 100 fatias no	1EF05
	70

Figura 33 - Histograma dos valores percentuais do total de objetos encontrados em cada u	ma
das amostras, poros, eva ou fibras	70
Figura 34 - Histograma dos valores percentuais médios de agregado graúdo encontrados	em
cada uma das amostras	71
Figura 35 - Histograma do diâmetro dos poros do CR em micrômetros (MM)	73
Figura 36 - Histograma do percentual médio de agregados graúdos encontrados em ca	ada
amostra, e o valor estimado através dos dados experimentais de cada traço	74
Figura 37 - Variação dos valores da classificação dos elementos internos do CR usando no	ove
regras	76
Figura 38 - Variação dos valores da classificação de cada elemento interno do CR usando vi	nte
e sete regras para 600 elementos	76
Figura 39 - Comparativo entre os percentuais médios encontrados nas amostras utilizando	0 O
classificador com 27 regras, 9 regras e a estimativa através do traço para cada objeto	80

## QUADROS

Quadro 1 - Tabela verdade: conjunção	. 37
Quadro 2 - Tabela verdade: disjunção	. 37
Quadro 3 - Tabela verdade: implicação	. 38
Quadro 4 - Tabela verdade: negação	. 38
Quadro 5 - Obtenção da relação R	. 41
Quadro 6 - Convenção de siglas utilizadas para os corpos de prova de acordo com	a as
porcentagens e características utilizadas na sua confecção	. 53
Quadro 7 - Resultados para a classificação com a base de nove regras	. 78
Quadro 8 - Resultados para a base com vinte e sete regras	. 79

## TABELAS

Tabela 1 - Primeiros elementos da base de dados de uma fatia do CR com seus respectivos
descritores, área em pixels e excentricidade e dimensão fractal, adimensionais 60
Tabela 2 - Exemplo de uma matriz de pertinência para 4 elementos (el) e 3 clusters (cl) 61
Tabela 3 - Base de regras considerando a combinação entre as variáveis
Tabela 4 - Saídas da base de regras considerando a combinação entre as variáveis 64
Tabela 5 - Base de regras do modelo simplificado
Tabela 6 - Valores percentuais da quantidade de objetos encontrados, na amostra
Tabela 7 - Valores percentuais de agregado graúdo encontrado, na amostra
Tabela 8 - Valores referentes aos percentuais de cada objeto presente em cada corpo de prova
e do valor estimado da porosidade72
Tabela 9 - Percentual de pedra encontrada através da microCT e estimada através do traço . 74

1.	INT	roi	DUÇÃO	12
2.	RE	FER	ENCIAL TEÓRICO	14
2	2.1.	Mat	eriais utilizados	14
	2.1.	1.	Concreto leve	14
	2.1.	2.	EVA	16
	2.1.	3.	Fibra de piaçava	16
2	2.2.	Proc	cessamento de imagens	17
	2.2.	1.	Captura	19
	2.2.	2.	Imagem digital	20
	2.2.	3.	Filtragem espacial	21
	2.2.	4.	Segmentação de imagens	24
	2.2.	5.	Extração de características	29
	2.2.	6.	Classificação usando lógica <i>fuzzy</i>	32
2	2.3.	Esta	do da arte	44
3.	ME	TOL	OOLOGIA	52
3	8.1.	Obte	enção das amostras e imagens	53
3	3.2.	Segi	mentação das imagens Microtomográficas.	54
3	3.3.	Vali	dação da segmentação	57
3	3.4.	Proc	cesso de extração de características	58
3	3.5.	Infe	rência por Takagi-Sugeno-Kang	60
3	8.6.	Vali	dação da Classificação	67
4.	RE	SUL	ΓADOS	68
5.	CO	NCL	USÃO	80
RE	FER	ÊNC	CIAS	83
AN	EXC	<b>) I</b> – I	Função de Segmentação da Pedra e determinação da área da amostra em	
cao	la fat	ia		89
AN	EXC	) II –	Limiar por K-Means	91
AN	EXC	) III ·	– Cálculo do percentual de um objeto em relação à área total da amostra e	m
cao	la fat	ia		92
	EXC	) IV -	- Função de extração dos descritores	93
AN fro	EXC	) V –	Função que separa cada objeto da imagem para o cálculo da dimensão	05
11 a	IFY(	) VI	_ Função que calcula a dimensão fractal atravás do mátodo de boy count	, J 06
	IFV(	) 1/11 ) 1/11	-r unção que calcula a unifensao fractar au aves uo filetouo de DOX couffi.	20 00
		, , 11	r unçav mangeu constrant Otsu	10

# SUMÁRIO

### 1. INTRODUÇÃO

O concreto é um dos materiais mais consumidos do mundo, devido a aspectos como a sua durabilidade, baixo custo, assim como a sua versatilidade e resistência à água, essas características o diferem de materiais como o aço e a madeira, uma vez que estes se deterioram mais facilmente quando expostos a intempérie (ISAIA, 2017).

Esse material compósito consiste na mistura entre um meio aglomerante, que seria o cimento, e os agregados, que se diferenciam por sua granulometria; usualmente, utiliza-se a pedra britada como agregado, mas também podem ser empregados diversos outros aditivos para que o concreto tenha o comportamento específico desejado.

O concreto leve, concreto com massa especifica menor que um concreto tradicional, é uma alternativa muito utilizada para reduzir o peso próprio das estruturas de elementos cimentícios e conseguir por exemplo, vencer vãos maiores, ou ser aplicado como enchimento e/ou vedação térmica e acústica. Para conseguir obter um concreto de baixa massa específica, existem artifícios, tais como a incorporação de ar e/ou a substituição da pedra britada de forma parcial ou utilização de elementos de menor massa específica (MENDES, 2014).

Em peças pré-moldadas de concreto, se evidencia também a vantagem do uso de um concreto leve pelo fato de facilitar o transporte da fábrica até o local da obra, como também o manuseio durante a etapa de execução. (MENDES, 2014).

Uma alternativa para compor um concreto leve é o etileno acetato de vinila também conhecido como EVA; resíduo da indústria esportiva e calçadista, é um material polimérico produzido a partir do petróleo, e não remoldável, que pode ser incorporado em concretos e argamassas, em substituição aos agregados convencionais.

Dessa forma, o uso do EVA aplicado ao desenvolvimento de concretos mais leves, é um caminho para redução de impactos ambientais associados ao não aproveitamento e descarte usual desse material, que através dos processos existentes destina até 20% de sua produção para este fim (GREVEN & GARLET, 1997).

No entanto, ressalta-se que os concretos leves têm como efeito colateral a diminuição de sua resistência à compressão e tração e, para corrigir esse déficit uma das alternativas é incorporação de fibras vegetais, como a *Attalea funifera Martius* também conhecida como piaçava ou piaçaba; uma espécie endêmica do estado da Bahia, normalmente utilizado para produção de vassouras, coberturas de cabanas e outros produtos de trabalhos manuais e

artesanato. Essas fibras otimizam a distribuição das tensões internas no concreto, permitindo maior resistência às solicitações no material (SOUZA, 2012).

Com a chegada de novos materiais e a incorporação destes nos processos produtivos surge a necessidade de caracterizá-los, assim como conhecer a influência de suas características internas nas propriedades do material. Dentre as técnicas de análise não destrutivas, têm-se a Microtomografia Computadorizada de Raios-X (microCT). Nesse contexto, a microCT possibilita a obtenção de imagens da estrutura interna dos objetos em duas e três dimensões, tornando viáveis a análise e a caracterização desses materiais a partir do emprego de técnicas de Processamento Digital de Imagens (PDI).

Na literatura, diversos trabalhos mostram o uso frequente de PDI na análise e caracterização dos poros em amostras de concreto, suas propriedades, desempenho e eficiência do material, além de detecção de elementos internos, como fibras, na matriz cimentícia (PETROU, MARIA MP; PETROU, 2010; BURGER; BURGE, 2013; CHUNG et. al., 2017; SOLTANI et. al., 2018; YANG, 2019; YANG et. al., 2020; CHUNG et. al., 2020; ZHU et. al., 2020; MILETIĆ et. al., 2020; SIDIQ et. al., 2020; LIU et. al., 2020).

As características dos elementos constituintes desse concreto leve: poros, grãos de EVA e fibras de Piaçava apresentam uma natureza difusa que dificultam a sua classificação através de imagens de microCT e técnicas convencionais de PDI (IGLESIAS et. al., 2018). Neste contexto, uma solução poderia ser o uso de um sistema baseado em lógica *fuzzy*, pois diferente dos sistemas baseados em lógica clássica, poderia contemplar os graus de incerteza associados a classificação dos diferentes objetos. (BASSANEZI, 2006). Além de conseguir exprimir o raciocínio aproximado, por vezes necessário para modelar um sistema especialista.

Devido a estes aspectos, atualmente diversos problemas têm recebido uma abordagem *fuzzy* na literatura, desde aplicações médicas, sensoriamento remoto, aplicações em controle, entre outros (SILVEIRA, DE BARROS, 2015; SOLTANI et al., 2018; YAZID, GARRATT, SANTOSO, 2019; XU et al., 2019). Este trabalho aplica técnicas de processamento de imagens e lógica *fuzzy* para a análise e classificação dos elementos internos de concretos leves.

#### 1.1. OBJETIVO GERAL

O objetivo geral deste trabalho é aplicar técnicas de processamento de imagens e lógica *fuzzy* para a análise e classificação de concretos leves.

#### 1.2. OBJETIVOS ESPECÍFICOS

Este objetivo geral pode ser atingido através dos seguintes objetivos específicos:

- Realizar a segmentação das imagens.
- Realizar extração de características dos objetos segmentados nas diferentes amostras.
- Desenvolver um sistema especialista baseado em lógica *fuzzy* para classificação dos objetos internos da amostra

#### **1.3. JUSTIFICATIVA**

Os métodos de ensaios não destrutivos são extremamente vantajosos para a construção civil, uma vez que são formas não invasivas permitem inspecionar de forma integral algum componente, possibilitam prevenir falhas e detectar defeitos.

Uma vez que instrumentos computacionais podem fazer verificações de forma mais precisa e com volume maior de informação, é conveniente procurar métodos algorítmicos para realizar a caracterização e análise do material.

A visão computacional e processamento de imagem são uma área do conhecimento que tem avançado muito, observam-se diversas aplicações desses conhecimentos em diversas áreas da ciência, desde astronomia, até mesmo aplicações médicas, fazendo-se necessário o continuo aperfeiçoamento e estudo dessas técnicas para assim contribuir para de alguma forma para o melhoramento delas.

### 2. REFERENCIAL TEÓRICO

Este capitulo tem o objetivo de apresentar resumidamente o embasamento teórico das técnicas e conceitos utilizados nesta pesquisa. Primeiramente serão apresentados conceitos importantes referentes aos materiais utilizados para confecção dos corpos de prova, assim como a obtenção das imagens de microCT. Em seguida, são descritas as técnicas de processamento de imagens, desde a definição das áreas de interesse até a extração das características dessas regiões, e uma introdução à lógica *fuzzy* e sistemas de inferência *fuzzy* usadas na classificação.

#### 2.1. MATERIAIS UTILIZADOS

#### 2.1.1. Concreto leve

O concreto de cimento Portland é considerado o material mais importante e mais consumido da construção civil atualmente, só ficando atrás da água. É usualmente obtido a partir da mistura da água, cimento Portland, agregado graúdo, agregado miúdo, como também podem ser empregados aditivos para mudar o comportamento do material, de acordo com o que se precisa alcançar (ISAIA, 2017).

Especificamente, os concretos leves se diferenciam dos demais por conta de sua menor massa especifica. Existem diversas formas de se obter concretos leves, uma delas é utilizando agregados leves, uma vez que contribuem significativamente para diminuição da massa total de um volume da mistura, ou através da incorporação de ar.

Devido a sua baixa massa especifica o concreto leve diminui significativamente o peso próprio das estruturas contribuindo para uma maior economia por exemplo da infraestrutura. O uso desse tipo de material contribui para uma maior produtividade, facilitando o transporte das peças pré-moldadas e materiais, resultando na redução do custo final da edificação. (HER-YUNG, 2009; BORJA, 2011; MA, *et al*, 2013)

Também costumam ser bons isolantes térmicos, reduzindo a absorção e transferência de calor tendo aplicações em vedações e coberturas (EUROLIGHT, 1998; HOLM, BREMMER, 2000) além de ótimos isolantes acústicos. Porém com a menor massa especifica vem o aumento da quantidade de ar presente no material o que resulta numa menor resistência mecânica que a de um concreto convencional (NEVILLE, 2013).

Segundo a ABNT NBR 8953:2015 que trata da classificação de concretos estruturais por massa especifica, grupos de resistência e consistência, são considerados concretos leves, aqueles que apresentam massa especifica menor que 2000 kg/m<sup>3</sup>.

A classificação de concreto leve não é estabelecida de forma igual em todas as normas de todos os países, não existe um consenso em relação ao intervalo em que ele se classifica como pode-se observar na figura 1 um comparativo entre as normas de diferentes países.

Enquanto no Brasil adota-se o limiar supracitado, que é o mesmo utilizado pelas normas internacionais RILEM de 1975 e CEB-FIP de 1977, a norma BS EN 1991-1-1 da união europeia de 2002 entende como concretos leves aqueles que estejam no intervalo aberto de 900 kg/m<sup>3</sup> à 2200 kg/m<sup>3</sup>, já a ACI 213 de 2003 dos Estados Unidos adota o intervalo aberto de 1400 kg/m<sup>3</sup> à 1850 kg/m<sup>3</sup>, por sua vez no Canadá, a norma CSA A23.3 de 2004 classifica como concreto leve aqueles que tenham massa especifica menor que 1850 kg/m<sup>3</sup> (MENDES, 2014).

Norma (País, ano)	Critério para massa específica γ (kg/m³)
NBR 6118 (Brasil, 2014)	$\gamma < 2000$
RILEM (Internacional, 1975)	$\gamma < 2000$
CEB-FIP (Internacional, 1977)	$\gamma < 2000$
BS EN 1991-1-1 (União Europeia, 2002)	$900 < \gamma < 2200$
ACI 213 (EUA, 2003)	1400 < γ <1850
CSA A23.3 (Canadá, 2004)	γ < 1850

Figura 1 - Comparativo entre as normas para classificação de concreto leve. Fonte: Adaptado de Mendes (2014, pg. 26).

#### 2.1.2. EVA

O EVA é formado por etileno acetato de vinila encadeadas de forma aleatória. Esse material que surge como uma alternativa em substituição ao couro em torno dos anos 70, tem como propriedades: boa processabilidade, estabilidade térmica, capacidade de resistência ao impacto, resistência à fadiga, resiliência, tenacidade e flexibilidade. (ILDEFONSO, 2007; GARLET, 1998; MELO; MENDONÇA, 2016).

O fato de possui uma maior resistência ao impacto em relação a outros materiais motiva o uso desse material, normalmente com teores de acetato de vinila em torno de 18% a 28% na indústria calçadista, sendo utilizado principalmente para fabricação de palmilhas e solados de calçados. (ZATTERA, *et. al.* 2005).

A depender do teor de acetato de vinila, o EVA se torna termofixo, ou seja, a sua rigidez não se altera com a temperatura, de modo que não pode ser fundido e remodelado, o que dificulta sua reutilização. O percentual de resíduos gerados pelo EVA a partir dos processos utilizados fica em torno de 12% a 20% (GREVEN & GARLET, 1997).

Como todo produto plástico seu descarte na natureza é um grande problema. Portanto devem-se buscar alternativas para o uso desse material depois de descartado, um caminho é a sua utilização como agregado para obtenção de concretos leves. Para contornar as perdas de resistência que o concreto leve apresenta, uma alternativa é a utilização de fibras vegetais como, por exemplo, a fibra de piaçava (SOUZA, 2012).

#### 2.1.3. Fibra de piaçava

O uso de fibras como reforço de concretos e argamassas vem sendo amplamente estudadas na literatura. Para esta aplicação podem ser empregadas fibras sintéticas como aço, propileno e vidro, ou mesmo materiais naturais como fibra de coco, celulose, sisal e a piaçava (NEVILLE, 2013; MEHTA; MONTEIRO, 2014).

De acordo com o site da comissão executiva do plano da lavoura cacaueira – CEPLAC a *Attalea funifera Martius*, conhecida como "piaçava" ou "piaçaba" é uma palmeira endêmica do litoral dos estados da Bahia, Sergipe e Alagoas encontrada dentro de uma faixa estrita da Mata Atlântica, o seu nome é de origem tupi e se traduz como "planta fibrosa". (GUIMARÃES; SILVA, 2012).

Sendo utilizada como matéria prima de vassouras, cordas e artesanatos em geral, uma das características da piaçava encontrada no sul da Bahia é sua impermeabilidade e capacidade de permanecer com sua elasticidade quando úmida. por conta dessas e outras características o material poderia ser utilizado como fase de reforço em compósitos (AQUINO, 2002), várias pesquisas foram desenvolvidas a fim de avaliar a eficiência da fibra como pontes de tensão, pré-fissuração e pós-fissuração em matrizes cimentícias (BENTUR & MINDESS, 2006).

De acordo com os estudos de Ni (1995) nas regiões de maior tensão a fibra pode se despregar da matriz como ilustrado pela fibra 1 da figura 2. Pode-se ter tensão suficiente transferida para o material (fibra 2) de modo que haja ruptura como ilustrado pela fibra 4 da figura 2. Explica ainda que uma fibra pode ser arrancada da matriz (fibra 3) onde grande parte da energia é perdida em forma de atrito. No caso de a fibra ficar intacta enquanto a fissura se propaga, ela atua como ponte de tensão.



Figura 2 -Esquema de transferência de tensões em uma matriz cimentícia reforçada por fibras Vegetais. Fonte: Adaptado de (NI, 1995)

#### 2.2. PROCESSAMENTO DE IMAGENS

Esta secção introduz brevemente a área de processamento digital de imagens, desde a representação de uma imagem digital, técnicas de filtragens e segmentação, até a extração de características para análise e reconhecimento de padrões.

Pode-se definir processamento de imagens como técnicas voltadas para análise de dados multidimensionais, ou manipulação de imagem computadorizada, que tem como entrada e saída uma imagem (GONZALEZ, 2002).

O processamento de imagens está definido em três grupos: baixo nível, que compreende operações mais simples como o pré-processamento da imagem, diminuição de ruído, aumento de contraste; médio nível, onde temos operações de segmentação, identificação dos contornos da imagem, divisão por regiões, até mesmo identificação de objetos; e por fim, alto nível, onde temos operações de análise e interpretação das imagens (GONZALEZ, 2002).

De acordo com os estudos de MARQUES (1999) uma das primeiras aplicações para o processamento de imagens foi aprimorar a qualidade da impressão de imagens digitais que eram transmitidas através do sistema Bartlane, sistema de transmissão de imagens via cabo submarino, entre Nova York e Londres, no início da década de 1920, mas teria sido com o programa espacial dos Estados Unidos três décadas depois, aplicando técnicas de processamento nas imagens captadas pela sonda ranger para corrigir as distorções de lente, que o processamento de imagens teria sido impulsionado.

Hoje em dia o processamento de imagens tem sido aplicado a diversas áreas do conhecimento, na medicina com a aplicação de equipamentos que trabalham com processamento de imagens para diagnóstico médico, facilitando e tornando mais precisos as análises. Em biologia na contagem de células de um microscópio ou até mesmo a utilização para interpretação de imagens de satélite, para geoprocessamento e meteorologia, e até mesmo aplicações em robótica, com a visão computacional. O sistema de processamento de imagens, em geral, pode ser sintetizado em quatro operações, a saber: aquisição, armazenamento, processamento e saída. (GONZALEZ, 2002).

Na etapa de aquisição como o nome sugere, é onde se obtém a imagem com formato adequado para ser processado, para isso é necessário um equipamento físico como uma câmera digital, ou outros que possam capturar e digitalizar essa imagem.

No armazenamento são guardados os dados digitais em algum tipo de memória, assim para cada tipo de operação temos um tipo de memória adequada, onde, quantidades maiores de dados necessitam de memórias com maior capacidade. O processamento é definido através de algoritmos que modificam e tratam a imagem de entrada, para tal são aplicados filtros, limiarizações, e transformações de forma adequada para se obter o resultado desejado. (GONZALEZ, 2002).

E por fim tem-se a exibição dos resultados, são utilizados para tal, monitores, impressoras e outros equipamentos similares que possam evidentemente exibir o resultado do processamento. Um sistema de visão computacional pode ser definido como um sistema capaz de realizar o processamento, análise e interpretação de uma imagem. Sua estrutura básica pode ser sintetizada nas seguintes etapas (MARQUES, 1999).

- Aquisição e pré-processamento;
- Segmentação: que consiste em dividir a imagem em regiões únicas que representem algum objeto de interesse.
- Extração de características: das imagens segmentadas são extraídos dados que discriminem e diferencie-o de outros objetos, ou seja busca características únicas para aquele objeto.
- Reconhecimento e interpretação: é nessa etapa onde são atribuídos rótulos aos objetos baseados nas suas características

Todas essas etapas dependem fundamentalmente da base de conhecimento, ou seja, o conhecimento sobre o problema que está sendo analisado. Utilizando esta estrutura básica podese desenvolver um sistema de classificação de objetos em uma imagem, nos próximos parágrafos serão explicados os conceitos mais importantes de cada uma destas etapas. E que foram utilizados no desenvolvimento da metodologia proposta.

#### 2.2.1. Captura

Os ensaios não destrutivos são técnicas de inspeção aplicadas aos materiais que não provocam danos físicos ou mecânicos. Das técnicas utilizadas, para a aplicação em concreto têm-se a inspeção visual, radiografia, análise de vibrações, emissão acústica, ultrassom, potencial elétrico, termografia, microCT, entre outras, que de modo geral podem ser utilizadas para identificar dimensões, características físicas dos materiais ou parâmetros associados à integridade estrutural. (PETTRES & LACERDA, 2012).

Das técnicas citadas a MicroCT apresenta grande potencial para análise de estruturas de concreto. A microCT é uma técnica que consiste na capacidade que os materiais têm de absorver os raios X de forma diferente dependendo da sua composição química e densidade (REIS NETO, et al., 2011).

Para se obter uma imagem utilizando esta técnica o objeto é colocado entre uma fonte e um detector de raios x e rotacionado axialmente o objeto à 360°, em cada rotação tem-se uma projeção a partir dos valores de radiação absorvidos pelo objeto pelo detector, como é mostrado na figura 3 (DOMINGUEZ et al., 2017). Com o uso de algoritmos de reconstrução se obtém centenas de imagens bidimensionais que correspondem às seções transversais do objeto.



Figura 3 - Representação esquemática de um sistema de microtomografia de raios X. Fonte: (FINA, 2013).

Com estas imagens é possível analisar as estruturas internas do objeto, bi e tridimensionalmente, como é o caso das amostras de concreto. A microCT é amplamente utilizada na literatura para este fim (PETROU, MARIA MP, PETROU, 2010; CHUNG et. al., 2017; SIDIQ et. al., 2020).

#### 2.2.2. Imagem digital

De acordo com GONZALEZ (2002) uma imagem digital monocromática é representada como uma função de duas dimensões (eq. 1), sendo x e y as coordenadas do ponto no espaço do ponto, que carrega uma intensidade de luz, então é denominada imagem ao conjunto desses pontos arranjados.

As cores do objeto real, vide a figura 4 (a), é quantizada em um intervalo discreto (figura 4 (b)) onde cada célula representa uma unidade básica ou elemento da imagem bidimensional, denominada pixel, a intensidade luminosa no ponto (x, y) pode ser fatorada como um componente de iluminação e i(x, y) que se traduz como a quantidade de luz que incide sobre o ponto, e um componente r(x, y) que pode ser entendida pela reflectância, ou seja, a quantidade de luz que reflete sobre o ponto. Assim obtemos o produto:

$$f(x, y) = i(x, y).r(x, y).$$
 (1)



Figura 4 - Amostragem e quantização de uma imagem. Fonte: (GONZALEZ, 2002, pg 54).

Para uma imagem colorida pode-se estender essa notação, por exemplo, considerando o espaço de cores Red - Green - Blue (RGB) compondo as três intensidades monocromáticas, ou seja, somando as três funções como na eq. 2.

$$f(x,y) = f_{R}(x,y) + f_{G}(x,y) + f_{B}(x,y)$$
(2)

É conveniente representar a imagem em forma de uma matriz de dimensões M x N onde cada elemento da matriz representa uma intensidade f(x,y) da posição (x, y) da imagem de acordo com a eq. 3.

$$F \approx \begin{cases} f(0,0) & \dots & f(0,N-1) \\ \vdots & \ddots & \vdots \\ f(0,M) & \dots & f(M-1,N-1) \end{cases}$$
(3)

#### 2.2.3. Filtragem espacial

Da etapa de aquisição muitas vezes as imagens podem vir com ruídos, imperfeições, intensidade de brilho e contraste inadequados, que podem atrapalhar as etapas subsequentes, portanto se faz necessário a aplicação de técnicas para realizar o melhoramento dessas imagens. Essa etapa é chamada de pré-processamento.(MARQUES FILHO, OGÊ; VIEIRA NETO, 1999).

Se considera filtragem espacial à aplicação de operações de um filtro no plano dos pixels da imagem, na forma g(x, y)=T [f(x, y)], definida em uma vizinhança do pixel (x, y), onde os valores dos pixels vão sendo alterados por meio de operações matemáticas de acordo com sua vizinhança sendo a saída é uma nova imagem filtrada.

Neste caso consideramos que um pixel p de coordenadas (x, y) tem dois vizinhos horizontais, dois verticais e quatro diagonais, os vizinhos horizontais e verticais tem coordenadas, (x+1, y), (x-1, y),(x, y+1) e (x, y-1) e denomina-se de 4-vizinhança. Os vizinhos Diagonais tem coordenadas, (x+1, y+1), (x-1, y-1),(x-1, y+1) e (x+1, y-1). Quando se tem 4 vizinhos diz 4-vizinhança, e quando se tem em adição vizinhos diagonais, diz 8-vizinhança.

Essa filtragem espacial pode ser através de operações, diretamente aos próprios valores da vizinhança, ou através de uma convolução entre a imagem e um *kernel* também conhecido como máscara espacial. O tipo de operação determina a natureza do processo.

Chamamos de convolução o processo de calcular o valor de um pixel baseado na intensidade dos seus vizinhos considerando pesos para cada um deles, esses pesos estão organizados numa máscara ou *kernel*, essas máscaras podem ter qualquer dimensão, menor ou igual a dimensão da imagem. Para uma imagem f e um *kernel* w de dimensões mxn, a convolução \* é dada através da eq. 4, onde a = (m-1)/2 e b = (n-1)/2 (JESUS; COSTA, 2015).

$$w(x, y)*f(x, y) = \sum_{s=-a}^{a} \sum_{t=-b}^{b} w(s, t) f(x-s, y-t)$$
(4)

Dentre os filtros existentes, os filtros de passa baixa, ou seja, que permitem a passagem apenas das baixas frequências a partir de um certo limiar, tem o efeito de suavização da imagem, ocorrendo uma suavização das bordas dos objetos presentes (GONZALEZ & WOODS, 2009).

Dois filtros de suavização bastante utilizados para redução de ruídos são os filtros de média e mediana, elas são obtidas através da média e mediana respectivamente, da vizinhança de cada pixel. Pode-se observar na figura 5 as diferenças entre: a imagem original e as imagens filtradas com as suas respectivas operações, na figura 5 (a) temos a imagem ruidosa, na figura 5 (b) a imagem filtrada pela média, na figura 5 (c) a imagem filtrada pela mediana.



Figura 5 - Aplicação dos filtro de média e mediana para remoção de ruido. (a) imagem ruidosa, (b) imagem filtrada pela média, (c) imagem filtrada pela mediana. Fonte: Acervo pessoal.

No caso da fig. 5 o filtro da mediana desempenhou melhor a filtragem, porém a depender da imagem e das diferenças de intensidades de cor que se quer preservar, a média pode ser uma melhor solução. Outro tipo de filtro de suavização é o filtro gaussiano, outro filtro de passa baixa, é definido através de uma distribuição gaussiana dada pela eq. 5 (JESUS; COSTA, 2015)

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{\frac{-x^2 + y^2}{2\sigma^2}}$$
(5)

Como uma imagem digital é discreta é necessária uma forma discreta para a aplicação desta máscara. Existem, portanto, aproximações da gaussiana em numa forma discretizada, como por exemplo o *kernel* apresentado na eq. 6.

	1	4	7	4	1
	4	16	26	16	4
$\frac{1}{273}$	7	26	41	26	7
_ / 0	4	16	26	16	4
	1	4	7	4	1

A convolução entre o *kernel* da gaussiana e a imagem produz uma saída suavizada, ou seja, com ruído atenuado, como pode-se observar na figura 6 (a), a imagem ruidosa e na figura 6 (b) a imagem filtrada (suavizada).



Figura 6 – Exemplo de aplicação de um filtro gaussiano. (a) imagem ruidosa, (b) imagem filtrada. Fonte: Acervo pessoal.

#### 2.2.4. Segmentação de imagens

A segmentação de imagens é a segunda fase do processamento e consiste em dividir uma imagem em duas ou mais regiões, de modo que se possa trabalhar individualmente com a região de interesse (ROI) da análise MARQUES (1999).

Essa etapa é extremamente importante, pois o próximo passo é a extração de características da região segmentada, ou seja, falhas nessa etapa podem acarretar em erros enormes nos resultados finais.

#### 2.2.4.1. Limiarização

Entende-se uma função de transformação de intensidade, como um filtro espacial que não depende da vizinhança do pixel a ser transformado, consistindo em, dado um valor k de intensidade os pixels com valores maiores que k tem sua intensidade aumentada, e os pixels com valores menores que k diminuídos. Aumentando o contraste da imagem em questão.(GONZALEZ & WOODS, 2009). Entre as técnicas de segmentação uma das mais comuns é a limiarização.

O processo de limiarização de uma imagem consiste em uma função de transformação de intensidade levada ao extremo, aos pixels maiores que k, denominado limiar, são atribuídos o valor máximo da escala, ou seja, branco; e os valores menores que o limiar, o menor valor, preto; dessa forma a imagem é separada em duas classes, fundo e frente da imagem. A esse processo também pode-se chamar de binarização. (MARQUES; HUGO; NETO, 1999). Pode-se observar na figura 7 um exemplo de imagem limiarizada para quatro valores de limiar diferentes, respectivamente 0,1, 0,2, 0,4 e 0,8, na escala de [0, 1]. Existem diversos métodos utilizados para determinar o limiar ótimo que separe a imagem em duas regiões, que representem de forma adequada a área de interesse em um desses grupos, uma das que se destacam é o método de Otsu.



Figura 7 - Imagem limiarizada utilizando diferentes limiares, respectivamente 0,1, 0,2, 0,4 e 0,8, na escala de [0, 1]. Fonte: Acervo pessoal.

O método de Otsu foi desenvolvido por Nobuyuki Otsu e consiste em uma técnica de limiarização automática de uma imagem em tons de cinza. Tem como objetivo separá-la em dois grupos de pixels. (OTSU, 1975).

A ideia é de forma iterativa, passar por todos os possíveis valores de limiar L buscando um valor ótimo que minimize a soma da variância intraclasse da imagem  $\sigma_w^2(L)$ . Essa formulação é expressa através da eq. 7.

$$\arg\min_{L \in [0 1]} \sigma_{w}^{2}(L) \text{ onde } \sigma_{w}^{2}(L) = w_{b}\sigma_{b}^{2} + w_{f}\sigma_{f}^{2}$$
(7)

Onde os índices b e f representam respectivamente o grupo de fundo e frente da imagem, e W corresponde ao peso do grupo que é calculado como a quantidade de pixels no grupo dividido pela quantidade de pixels totais da imagem e  $\sigma^2$  representa a variância do grupo

Como esse processo é calculado para todos os possíveis valores de limiar ele é custoso computacionalmente, por isso Otsu demonstrou que é possível substituir o processo descrito na eq. 7 por encontrar o valor ótimo que maximize a variância interclasse, esse processo está descrito na eq. 8, onde  $\mu$  representa a média dos grupos. Depois de encontrar o limiar atribui aos pixels que tem valor abaixo do limiar a cor preta e os pixels com valor acima do limiar a cor branca, nas figuras 8 (a) e 8 (b) observa-se o processo para um limiar de 3 no histograma, e

na figura 9 a figura 9 (a) com valor atribuído automaticamente por Otsu, a imagem foi dividida em dois grupos, cor de frente e fundo como visto na figura 9 (b), a figura 9 (c) apresenta o seu histograma e o limiar encontrado por Otsu.



**Figura 8** – Histograma e limiar, (a) Histograma da imagem, (b) Imagem Binarizada, Tomando como limiar o valor 3 da escala de cinza. **Fonte:** (LABBOOKPAGES, 2020).



Figura 9 – Imagem limiarizada utilizando o algoritmo de Otsu. (a) Imagem Original em Tons de cinza b) imagem limiarizada. (c) histograma da imagem e o limiar encontrado por Ostu. Fonte: Acervo pessoal.

#### 2.2.4.2. Limiarização usando k-Means

Já o K-Means é um método de clusterização que objetiva particionar n observações dentre *k* grupos onde, cada observação pertence ao grupo que tem seu centro mais próximo dele. Esse algoritmo pode também ser utilizado para segmentar uma imagem. E pode-se dividir em 5 passos segundo (PIMENTEL, VILMA e OMAR, 2003).

- I. Recebe o número k de Grupos
- II. Seleciona k pontos aleatórios como os centros dos k Grupos
- III.Coloca cada ponto no grupo mais próximo
- IV. Recalcula os centros como os centroides dos grupos

#### V. Repete os passos III e IV até a convergência

Na figura 10 (a) têm-se os dados representados espacialmente; em 10 (b) os centros iniciados aleatóriamente; já na figura 10 (c), 10 (d) e 10 (e) os elementos sendo distribuidos nos clusters e os centros sendo atualizados, por fim na figura 10 (f) o critério de parada é atingido.



Figura 10 –Representação espacial do algoritimo de k-means. (a) Dados representados espacialmente, (b) Centros iniciados aleatóriamente. (c), (d) e (e) Elementos sendo distribuidos nos clusters e centros sendo atualizados (f) critério de parada atingido. Fonte: (PIECH, 2013).

A partir dos estudos de CARLANTONIO (2001) e JAIN, MURTY & FLYNN (1999) sabemos que a medida de similaridade entre os objetos é expressa como uma função que mede a distância em relação aos centroides dos grupos. Uma das funções mais utilizadas é conhecida como função de Minkowski e definida pela eq. 9. Onde i e j são os objetos, q a dimensão, e p a p-ésimo atributo de coordenada.

$$d(i, j) = \sqrt[q]{(x_{i1} - x_{j1})^q + (x_{i2} - x_{j2})^q + \dots + (x_{ip} - x_{jp})^q}$$
(9)

Se por acaso utilizar um valor de q = 2, então a distância é a euclidiana definida na eq. 10.

$$d(i,j) = \sqrt[2]{(x_{i1}-x_{j1})^2 + (x_{i2}-x_{j2})^2 + \dots + (x_{ip}-x_{jp})^2}$$
(10)

2.2.4.3. Operações morfológicas

Uma vez segmentada a imagem, pode-se usar operações morfológicas para realizar filtragens na imagem, remover imperfeições e até extrair informações em relação a forma e estrutura da imagem. A morfologia é baseada na teoria dos conjuntos, esses conjuntos representam objetos encontrados na imagem, como por exemplo o conjunto dos pixels brancos em uma imagem binarizada. Neste trabalho foram utilizados operações para filtragem e conectar regiões contíguas da imagem binária (GONZALEZ, RAFAEL C.; WOODS, 2009).

Os conjuntos de uma imagem binária pertencem a  $Z^2$ , e (x, y) são as coordenadas dos elementos, vetores, desses conjuntos. Para que se possa trabalhar com alguns tipos de operações serão definidos os conceitos de reflexão e translação.

A reflexão pela origem de um conjunto A é representada por e pode ser entendida no espaço bidimensional como a substituição das coordenadas dos elementos do grupo por seu oposto, ou seja, (x, y) por (-x, -y). Sendo assim a reflexão é definida pela eq. 11. (GONZALEZ, RAFAEL C.; WOODS, 2009).

$$\hat{A} = \{\hat{a} : \hat{a} = -a\}, \text{ para } a \in A$$
(11)

Já a translação pode ser entendida como um deslocamento do grupo pela imagem adicionando às coordenadas dos elementos do grupo o valor do deslocamento em cada um dos eixos, ou seja (x, y) por  $(x + z_1, y + z_2)$ . Sendo assim a translação é definida pela eq. 12. (GONZALEZ, RAFAEL C.; WOODS, 2009).

$$(A)_{z} = \{a_{z} : a_{z} = a + z\}, \text{ para } a \in A$$
 (12)

Os elementos estruturantes são pequenos conjuntos, matrizes, subimagens, usadas para examinar imagens buscando propriedades de interesse. Pode-se gerar um elemento estruturante de várias geometrias e tamanhos diferentes. (GONZALEZ, RAFAEL C.; WOODS, 2009). Um elemento estruturante circular, ou também chamado disco, é classificado pelo seu raio, assim, quanto maior o raio, maior o elemento estruturante e o seu efeito na operação. Na figura 11 pode-se observar alguns exemplos, a função do elemento estruturante se tornará mais clara com a definição de erosão e dilatação nos próximos parágrafos.



Figura 11 - Exemplos de elementos estruturantes. Fonte: (GONZALEZ & WOODS, 2009).

A erosão é uma operação fundamental da morfologia. A erosão de um conjunto A pelo conjunto B, ou, a imagem A erodida pelo elemento estruturante B,  $(A \ominus B)$ , consiste nos pontos de B que transladados por x cabem em A, definida pela eq. 13 (POLIN, 2020).

Entretanto a dilatação de A por B representada por A  $\oplus$  B pode ser entendida como o conjunto de todas as translações z, de forma que  $\hat{B}$  e A se sobreponham pelo menos por um elemento, e é definida pela eq. 14 (POLIN, 2020).

#### $A \bigoplus B = [(A)' \ominus \widehat{B}]'$

Outras operações morfológicas importantes são as operações de abertura (*open*) e fechamento (*Close*). A abertura pode ser definida como uma erosão seguida de uma dilatação, e o fechamento como uma dilatação seguida de uma erosão. Dizemos que são operações duais, expressas nas equações 15 e 16 (POLIN, 2020).

$$\mathbf{A} \circ \mathbf{B} = (\mathbf{A} \ominus \mathbf{B}) \oplus \mathbf{B} \tag{15}$$

$$\mathbf{A} \bullet \mathbf{B} = (\mathbf{A} \bigoplus \mathbf{B}) \bigoplus \mathbf{B}$$

A figura 12 apresenta um exemplo da aplicação de uma operação de dilatação, erosão, abertura e fechamento, a dilatação expande a linha lateralmente, enquanto a erosão diminui, a abertura elimina o ruido enquanto o fechamento conecta as regiões contíguas na parte interior da letra.



Figura 12 - Morfologias de dilatação, erosão, abertura e fechamento. Fonte: (POLIN, 2020).

### 2.2.5. Extração de características

Após a etapa de segmentação, ou seja, após a determinação da ROI pode-se extrair características dessas regiões a fim de analisa-las e classificá-las. Nessa secção serão apresentados alguns tipos de descritores utilizados nesta pesquisa, esses descritores irão

(13)

(14)

(16)

compor, posteriormente, as variáveis de entrada do sistema de inferência baseados em lógica *fuzzy*.

#### 2.2.5.1. Descritores regionais

Existem diversos descritores regionais que podem ser utilizados para a classificação dos elementos na ROI, elas dependem do problema a ser resolvido. Dos diversos descritores regionais existentes dois são relevantes para serem apresentados neste trabalho, eles são a área e excentricidade.

A área de uma região binária conectada, contido em um retângulo de dimensões  $m \times n$ é calculada através da quantidade de pixels presentes naquela região de valor 1, aqui considerado como valor que representa os objetos de frente da imagem, consequentemente o valor 0 é considerado como objeto de fundo. A eq. 17 apresenta a formulação matemática da área de uma região (GONZALEZ & WOODS, 2009).

$$\text{Årea} = \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x,y)$$
(17)

De acordo com GONZALEZ & WOODS (2009) dado a fronteira B de uma região numa imagem, pode-se definir o seu diâmetro como:

$$Di\hat{a}m(B) = \max_{i,j}^{max} [D(p_i, p_j)];$$
 (18)

onde D é uma medida de distância e  $p_i$  e  $p_j$  são pontos na fronteira.

Pode-se chamá-lo também de eixo maior, de modo que o eixo menor é definido como uma linha perpendicular onde uma caixa que passa pelos quatro pontos envolve completamente a fronteira. A razão entre o eixo maior e o eixo menor é denominada excentricidade e é considerado outro descritor regional, que mede assim a deformação relativa de uma região. Como pode-se ver na figura 13 que descreve a região de fronteira e seus eixos.



Figura 13 – Fronteiras e eixos de uma ROI para o calculo de excentricidade (a) região e sua fronteira, (b) eixos, maior e menor.
Fonte: (Gonzalez & Woods, 2009).

#### 2.2.5.2. Dimensão fractal

Outro descritor relevante neste trabalho é a dimensão fractal. Fractais são objetos que não existem de fato no mundo físico, são puramente matemáticos e apresentam as seguintes características que as definem: autossemelhança, complexidade infinita e dimensão fractal, esta última representa o nível de complexidade de ocupação no espaço euclidiano. Quanto maior o nível de ocupação, mais complexa é a estrutura do fractal. (BACKES, 2010)

Existem alguns objetos físicos que em certa escala possuem características fractais, como é o caso de algumas folhas, vide figura 14. Essa característica nos permite utilizar a dimensão fractal para análise de complexidade, em especial em processamento de imagens para descrição de regiões. (CARLIN, 2000; DE OLIVEIRA PLOTZE et al., 2005)



Figura 14 - Folha da Samambaia apresentando características fractais, como a auto similiaridade entre suas estruturas. Fonte: (CONSTANT, 2012).

Suponha que se deseje calcular a dimensão fractal de uma linha de tamanho L; tomando por exemplo outra linha de tamanho u onde L > u, calculando o número de vezes N que u cabe em L temos N =  $\frac{L}{u}$ , de modo que se fizesse isso para um quadrado de lado *L* com outro de lado *u* encontraríamos a relação N =  $(\frac{L}{u})^2$ . Com o objeto de uma dimensão se obtêm um expoente em  $\frac{L}{u}$  igual a 1, no objeto de duas dimensões se encontra o expoente 2, assim, pode-se generalizar a relação como na eq. 19.

$$N = \left(\frac{L}{u}\right)^{D}$$
(19)

onde D é a dimensão fractal. Extraindo o logarítimo em ambos os lados se obtém a relação direta como na eq. 20.

$$D = \frac{\ln(N)}{\ln(L/u)}$$
(20)

Caso o objeto seja uniforme e compacto então a dimensão será inteira, como no caso dos objetos de uma, duas e três dimensões por exemplo, mas no caso de fractais o valor de *D* será um número fracionário. (FALCONER, 1990; TRICOT, 1995, SHROEDER, 1996)

Um dos métodos mais conhecidos e utilizados para se obter a dimensão fractal de um objeto é o *Box-Counting* (COELHO; COSTA, 1995), isso por conta da sua facilidade de implementação. Ele consiste em cobrir a imagem com uma malha de quadrados, como pode-se observar na figura 15, e contar número N de quadrados que são necessários para cobrir a forma numa escala *s*, depois o processo é repetido em uma escala menor de modo que a dimensão fractal é estimada através do coeficiente angular  $\propto$  do diagrama da eq. 21. (COELHO; COSTA, 1995).

$$D = \alpha = \frac{\ln(N)}{\ln(1/s)}$$
(21)

Figura 15 - Representação das malhas de quadrados do algorítimo Box-Counting em duas iterações. Fonte: (MACEDO, et al., 2020).

#### 2.2.6. Classificação usando lógica fuzzy

Nesta secção estão definidos os conceitos de conjuntos, lógica e sistemas de inferência *fuzzy*, através da ideia de extensão dos conceitos matemáticos da lógica clássica para lógica difusa, estes conceitos são importantes para modelagem de problemas onde existem proposições incertas, realizando a ponte entre variáveis linguísticas que não conseguem ser traduzidas corretamente pela lógica clássica, ou, que não tem um valor matemáticamente preciso.

Para GOMIDE (1994) a lógica *fuzzy*, ou lógica difusa, é uma lógica que se baseia na teoria *fuzzy*, e nela o valor verdade representa um subconjunto, de um conjunto parcialmente ordenado qualquer. Em um sistema lógico clássico, o valor verdade só pode assumir dois valores, (1) para verdadeiro e (0) para falso. Assim, pode-se definir através de uma função de característica para um elemento x, se ele pertence ou não a um conjunto A usando a função definida na eq. 22. (MORÉ, 2004).

$$\chi_{A}(\mathbf{x}) = \begin{cases} 1 \text{ para } \mathbf{x} \in \mathbf{A}, \\ 0 \text{ para } \mathbf{x} \notin \mathbf{A}, \end{cases} \text{ OU } \chi_{A} \colon \mathbf{U} \to \{0, 1\} \end{cases}$$
(22)

Sendo o valor de  $\chi_A(x)$ , o grau que determina se o elemento x pertence a A em um conjunto universo U.

No caso da lógica *fuzzy* o valor verdade assume a nuance da forma linguística, e cada termo é visto como um subconjunto *fuzzy* de um intervalo unitário. De forma comparativa, em um sistema binário os predicados devem ser exatos, já no *fuzzy* os predicados são nebulosos, como por exemplo: alto, baixo, pesado e leve (GOMIDE, 1994).

Outra característica são os quantificadores lógicos, que na lógica binária se resume aos quantificadores existencial e universal, mas na lógica *fuzzy* permite uma quantidade maior de quantificadores, como pouco, vários e muitos (GOMIDE, 1994).

A lógica clássica inicia definindo sentenças tais que podem ser atribuídos os valores lógicos, verdadeiro ou falso, e depois se constroem sentenças compostas por intermédio de conectivos onde seu valor lógico é avaliado por meio de tabelas verdade.

Uma sentença clássica deve levar consigo, portanto, máxima precisão, não sendo possível utilizar-se de um raciocínio aproximado, como é o caso de quando se diz que alguém é alto ou baixo, ou que João comeu pouco no almoço; esse raciocínio não é preciso, pelo que não é possível atribuir um valor extremo de verdadeiro ou falso (GOMIDE, 1994).

Em outras palavras pode-se dizer que a lógica *fuzzy* trata de sistemas com grau de incerteza, e este talvez seja um dos motivos de ela ter tantas aplicações, pois todo sistema real tem algum grau de incerteza ou imprecisão. Considerando um conjunto clássico também chamado *crisp* A definido pela eq. 23.

$$A = \{x: x \in [a, b]\},$$
(23)

Pode-se definir se um elemento pertence ou não a A utilizando uma função característica, mas ao invés de abordar esse problema de maneira bivalente, pode-se utilizar graus de certeza, para determinar se o elemento pertence ou não a esse conjunto, simplesmente utilizando uma função de pertinência. A figura 16 ilustra uma função de pertinência onde o valor 25 tem pertinência absoluta no conjunto, já para outros valores a pertinência, ou grau desse elemento no conjunto é menor.



Figura 16 - Funções de pertinência. Fonte: (GOMIDE, 1994).

Assim, ZADEH (1965) explica que se pode estender uma função característica em uma função de pertinência, onde o fator ou grau de pertencimento passa a assumir quaisquer valores no intervalo [0, 1], de modo que 0 representa a completa exclusão do valor no conjunto, e 1 a completa pertinência, definida pela eq. 24.

$$\varphi_{A}: U \to [0, 1] \tag{24}$$

Dessa forma pode-se representar o conjunto A como um conjunto *fuzzy* onde cada elemento é o par (x,  $\varphi_A(x)$ ) onde x é um elemento *crisp*, e  $\varphi_A$  é o valor de pertinência daquele elemento x, onde X é o conjunto universo do elemento de discurso, ou seja (eq. 25).

$$A = \left(x, \varphi_A(x) : x \in X\right) \tag{25}$$

Alguns conceitos importantes sobre as funções de pertinência são a união, onde, sejam A e B subconjuntos *fuzzy* de U, a pertinência da união entre A e B é dado pela eq. 26.

$$\varphi_{(A\cup B)}(x) = \max\{\varphi_A(x), \varphi_B(x)\}, x \in U$$
(26)

Já a pertinência da intersecção de A e B, subconjuntos *fuzzy* de U, entre A e B é dado pela eq. 27.

$$\varphi_{(A\cap B)}(x) = \min\{\varphi_A(x), \varphi_B(x)\}, x \in U$$
(27)

Por último a pertinência do complementar de A, subconjunto *fuzzy* de U, é dada pela eq. 28.

$$\varphi_{A'}(x) = 1 - \varphi_A(x), x \in U$$
 (28)

Estas definições cumprem as seguintes propriedades (GOMIDE, 1994).

- AUB=BUA
- $A \cap B = B \cap A$

- AU(BUC)=(AUB)UC
- $A \cap (B \cap C) = (A \cap B) \cap C$
- AUA=A
- A∩A=A
- $AU(B\cap C)=(AUB)\cap(AUC)$
- $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$
- $A \cap \emptyset = \emptyset e A \cup \emptyset = A$
- $A \cap U = A e A \cup U = U$
- $(A \cup B)' = A' \cap B' e (A \cap B)' = A' \cup B'$

Sendo que essas ultimas, são as Leis de De Morgan.

#### 2.2.6.1. α-nível

É possível definir um subconjunto *fuzzy* de um conjunto *fuzzy* A qualquer, tal que os elementos desse conjunto contenham elementos de A com grau de pertinência maior que um  $\alpha \in [0,1]$ , ou seja, informando que o que se deseja é um conjunto onde para que o elemento x pertença a ele, x deve ter um grau mínimo especificado  $\alpha$ .

Assim podemos definir o  $\alpha$ -nível de um subconjunto *fuzzy* A de U onde  $\alpha \in [0,1]$ ,  $\alpha$ -nível é o subconjunto dado pela eq. 29 (BARROS, 1997).

$$[A]^{\alpha} = \{ x \in U: \varphi_A(x) \ge \alpha \} \text{ para } 0 \le \alpha \le 1$$
(29)

Seja A um subconjunto *fuzzy* pertencente a U, o suporte de A é definido pela eq. 30 (BARROS, 1997).

$$supp A = \{x \in U: \varphi_A(x) > 0\}$$
(30)

Quando  $\alpha = 0$  em um  $\alpha$ -nível de um conjunto *fuzzy*, A têm-se o fecho do suporte de A. Dizse que o  $\alpha$ -nível de um dado conjunto A é conhecido também como  $\alpha$ -corte de A.

#### 2.2.6.2. Princípio de extensão de Zadeh

A teoria *fuzzy* se propõe como uma extensão da lógica clássica, por isso uma maneira de estender os conceitos matemáticos não-*fuzzy* em *fuzzy* é uma necessidade constante. Uma extensão de relações e operadores clássicos em *fuzzy* serão primeiramente descritos, em seguida, relações e operadores *fuzzy*.
A extensão de Zadeh ou princípio de extensão é um dos conceitos básicos que promove essa ponte entre os operadores e relações clássicas e *fuzzy*. As propriedades sobre o princípio de extensão para funções do tipo f:  $R \times R \rightarrow R$  foram inicialmente estudadas por (NGUYEN, 1978).

Seja f uma função tal que f: X  $\rightarrow$  Z e A um subconjunto *fuzzy* de X. A extensão de Zadeh de f é a função f que, aplicada a A, fornece o subconjunto *fuzzy* f(A) de Z, cuja função de pertinência é dada pela eq. 31, onde f<sup>-1</sup>(Z) = {x: f(x)=z} é a pré-imagem de z (BARROS, 1997).

$$\varphi_{\hat{f}(A)}(Z) = \begin{cases} \sup \varphi_A(x) \text{ se } f^1(Z) \neq \emptyset \\ 0 \quad \text{se } f^1(Z) = \emptyset \end{cases}$$
(31)

2.2.6.3. Relação fuzzy

Através da ideia de relação se pode medir se há alguma associação entre dois ou mais conjuntos, de modo que a relação entre eles é definida como um subconjunto do produto cartesiano, que pode ser representado como uma função característica  $\chi R: U_1 \times U_2 \times$  $... \times U_n \rightarrow \{0,1\}$  que define a regra de associação. Na teoria clássica a relação R clássica entre conjuntos definida sobre  $U_1 \times U_2 \times ... \times U_n$ , é qualquer subconjunto desse produto cartesiano. Se o produto cartesiano for formado por apenas dois conjuntos  $U_1 \times U_2$ , a relação é denominada relação binária sobre  $U_1 \times U_2$ . Se  $U_1 = U_2 = \cdots = U_n = U$ . Diz-se que R é uma relação sobre U. onde a função característica que define a relação pode ser expressada pela eq. 32. como (GOMIDE, 1994).

$$\chi R(x_1, x_2, \dots, x_n) = \begin{cases} 1 \ se(x_1, x_2, \dots, x_n) \in R \\ 0 \ se(x_1, x_2, \dots, x_n) \notin R \end{cases}$$
(32)

Usando a teoria *fuzzy* além de medir se há uma associação, se mede também o grau dessa relação. Isto posto, de forma análoga ao que já foi apresentado para um conjunto *fuzzy* anteriormente, para definir uma relação *fuzzy* estende-se essa noção de uma função característica em uma função de pertinência.

Assim uma relação fuzzy R sobre  $U_1 \times U_2 \times ... \times U_n$ , é qualquer subconjunto fuzzy de  $U_1 \times U_2 \times ... \times U_n$  sendo que R é definida por uma função de pertinência  $\varphi R: U_1 \times U_2 \times ... \times U_n \rightarrow [0,1]$ . Se o produto for formado por apenas dois conjuntos  $U_1 \times U_2$  a relação é chamada de fuzzy binária sobre  $U_1 \times U_2$ .

Já o produto cartesiano *fuzzy*, dos subconjuntos *fuzzy*  $A_1 \times A_2 \times ... \times A_n$  de  $U_1 \times U_2 \times ... \times U_n$ , respectivamente, é a relação *fuzzy*  $A_1 \times A_2 \times ... \times A_n$ , cuja função de pertinência é dada pela eq. 33, onde  $\wedge$  representa o mínimo.

$$\varphi_{A_1 \times A_2 \times \dots \times A_n}(x_1, x_2, \dots, x_n) = \varphi_{A_1}(x_1) \wedge \varphi_{A_2}(x_2) \wedge \dots \wedge \varphi_{A_n}(x_n)$$
(33)

## 2.2.6.4. Operadores lógicos

Os valores lógicos de uma proposição composta são calculados através da definição dos operadores, ou conectivos; se atribui como verdadeiro o valor 1 e como falso 0, de modo que para a conjunção "e" utiliza-se a notação  $\Lambda$ , e é calculado como o mínimo dos valores das duas proposições.

Para a disjunção inclusiva V utiliza-se o máximo entre os valores, e para negação e implicação definidos respectivamente através dos símbolos  $\neg$ ,  $\Rightarrow$ . Sejam as proposições  $P_1$ ,  $P_2$  a tabela verdade clássica dos conectivos estão apresentados nos quadros 1, 2, 3 e 4.

<i>P</i> <sub>1</sub>	<i>P</i> <sub>2</sub>	$P_1 \wedge P_2$
1	1	1
1	0	0
0	1	0
0	0	0

Quadro 1: Tabela verdade: conjunção

Fonte: Acervo pessoal.

Quadro 2: Tabela verdade: disjunção

P <sub>1</sub>	<i>P</i> <sub>2</sub>	$P_1 \vee P_2$
1	1	1
1	0	1
0	1	1
0	0	0

Fonte: Acervo pessoal.

$P_1$	<i>P</i> <sub>2</sub>	$P_1 \Longrightarrow P_2$
1	1	1
1	0	0
0	1	1
0	0	1

Quadro 3: Tabela verdade, implicação

Fonte: Acervo pessoal.

Quadro 4: Tabela verdade, negação

<i>P</i> <sub>1</sub>	$\neg P_1$		
1	0		
0 1			
Fonte: Acervo pessoal.			

Na lógica *fuzzy* os valores lógicos assumem todos os possíveis valores do intervalo [0,1]; dessa forma das sentenças onde não era possível atribuir um valor verdade na lógica clássica devido a sua imprecisão, na lógica *fuzzy* ela pode apresentar qualquer valor real, de modo que quando 1 é dito que é absolutamente verdadeiro, e quando 0, absolutamente falso, definindo uma extensão da lógica clássica. Assim, o operador  $\triangle:[0,1]\times[0,1]\rightarrow[0,1], \ \triangle(x, y) = x \triangle y$  é uma T-norma se satisfizer as seguintes condições:

*t1*) elemento neutro:  $\triangle$  (1, y) = 1  $\triangle$  y = x

- *t2*) *comutativa*:  $\triangle$  (*x*, *y*) = *x*  $\triangle$  *y* = *y*  $\triangle$  *x* =  $\triangle$  (*y*, *x*)
- *t3*) associativa:  $x \bigtriangleup (y \bigtriangleup z) = (x \bigtriangleup y) \bigtriangleup z$
- *t4*) monotonicidade: se  $x \le u e y \le v$ , então  $x \bigtriangleup y \le u \bigtriangleup v$

O operador de T- norma estende a operação ∧ de conjunção que modela o conectivo 'e'. de acordo com (MEZZOMO, 2016) alguns exemplos de T-normas são:

- **Gödel:**  $\Delta(x, y) = T_G = min(x, y)$
- **Produto:**  $\Delta(x, y) = T_p = x. y$
- Lukasiewicz:  $\Delta(x, y) = T_L = max(0, x + y 1)$
- **Drastic:**  $\Delta(x, y) = T_D = \begin{cases} 0 & se(x, y) \in [0, 1[^2; \\ min(x, y) & c.c. \end{cases}$

Já no que se refere ao operador de T-conorma têm-se  $\nabla: [0,1] \times [0,1] \rightarrow [0,1]$ ,  $\nabla(x,y) = x \nabla y$  se satisfaz as seguintes condições:

c1) elemento neutro:  $\nabla(0, y) = 0\nabla y = x$ c2) comutativa:  $\nabla(x, y) = x\nabla y = y\nabla x = \nabla(y, x)$ c3) associativa:  $x\nabla(y\nabla z) = (x\nabla y)\nabla z$ c4) monotonicidade: se  $x \le u e y \le v$ , então  $x\nabla y \le u\nabla v$ 

O operador de T- conorma estende a operação V de disjunção que modela o conectivo 'ou' e de acordo com (MEZZOMO, 2016) alguns exemplos de T-conormas são:

- **Gödel:**  $\Delta(x, y) = S_G = max(x, y)$
- Soma Probabilística:  $\Delta(x, y) = S_p = x + y x. y$
- Lukasiewicz:  $\Delta(x, y) = S_L = min(x + y, 1)$
- **Drastic Sum:**  $\Delta(x, y) = S_D = \begin{cases} 1 & se(x, y) \in [0, 1]^2; \\ max(x, y) & c.c. \end{cases}$

Já a negação é uma aplicação  $n: [0,1] \rightarrow [0,1]$  que satisfaz as seguintes condições:

$$n1$$
) fronteiras  $n(0) = 1 e n(1) = 0$ 

**n2**) involução n(n(x)) = x

n3) monotonicidade n é decrescente

Quando a t-norma  $\Delta$ , t-conorma  $\nabla$  e uma negação n satisfazem uma das leis de De Morgan dizemos que são N-duais em relação a n. Um exemplo de t-norma, t-conorma n-duais em relação a negação *n* são:

- T-norma  $\triangle$ :  $[0,1] \times [0,1] \rightarrow [0,1]$ ;  $\Delta(x, y) = min\{x, y\} = x \land y$
- *T*-conorma  $\nabla$ :  $[0,1] \times [0,1] \rightarrow [0,1]; \nabla(x,y) = max\{x,y\} = x \lor y$
- Negação  $n: [0,1] \rightarrow [0,1]; n = 1 x$

Por fim se tem o operador de implicação  $fuzzy \implies: [0,1] \times [0,1] \rightarrow [0,1]$  que satisfaz as seguintes condições:

II) Reproduzir a tabela de implicação clássica

*I2)* For decrescente na primeira variável, ou seja, para cada  $x \in [0,1]$  tem-se  $(a \Rightarrow x) \le (b \Rightarrow x)$  se  $a \ge b$ ;

**I3**) For crescente na segunda variável, ou seja, para cada  $x \in [0,1]$  tem-se  $(x \Rightarrow a) \le (x \Rightarrow a)$  se  $a \ge b$ ;

2.2.6.5. Inferência *fuzzy* 

Os sistemas inferência *fuzzy*, são baseados em regras que fazem uso de variáveis linguísticas para executar processos de tomada de decisão, normalmente consideram-se entradas *crisp* que são resultados de observações e medições, por isso essas entradas precisam ser convertidas, (*fuzzyficadas*), ou seja, de dados precisos a conjuntos *fuzzy*, chamamos também essa etapa de pré-processamento. (DE ANDRADE LIRA RABÊLO et al., 2011)

Após essa etapa adentra-se na base de regras, onde cada valor de entrada e sua pertinência em cada um dos conjuntos *fuzzy* ativam um conjunto de regras, que irão definir através de um modulo de inferência, uma saída para o sistema. Quando temos uma saída *fuzzy*, é necessário que seja implementado um modulo de *defuzificação*, que irá traduzir a saída *fuzzy* em uma saída *crisp*. A figura 17 exemplifica o fluxo de todo processo (GOMIDE, 1994).



Figura 17 - Fluxograma de um sistema *fuzzy*. Fonte: Acervo pessoal.

A base de regras do sistema é agregada como uma relação *fuzzy*, de modo que a pertinência *R* do módulo é calculado como (GOMIDE, 1994).

$$\varphi R(\mathbf{x}, \mathbf{u}) = \nabla \left( \varphi R_{i}(\mathbf{x}, \mathbf{u}) \right), \text{ com } 1 \le i \le r$$
(34)

Onde  $\nabla$  é uma t-conorma, x e u são respectivamente a entrada e a saída de  $R_i$  que é uma relação *fuzzy* obtida da regra i, onde sua pertinência é obtida através de algum método. O controle B para um estado A, é dado por uma regra de composição de inferência: B(A) = R(A), onde sua função de pertinência é calculada como na eq. 35, onde  $\Delta$  é uma T-norma  $\varphi$  B(u)= sup <sub>x</sub>( $\varphi$  R(x, u) $\Delta \varphi$  A(x)) (35)

Para ilustrar a obtenção da inferência do sistema *fuzzy*, pode-se usar um *modus ponens* generalizado assim como no quadro 5 (BASSANEZI, 2014).

Quadro 5: Obtenção da relação R

	$R_1$ :" se $x_1$ é $A_{11}$ ee $x_n$ é $A_{1n}$ então $u_1$ é $B_{11}$ ee $u_m$ é $B_{1m}$ "
ои	$R_2$ :" se $x_1 \in A_{21} \in \ldots \in x_n \in A_{2n}$ então $u_1 \in B_{21} \in \ldots \in u_m \in B_{2m}$ "
: ou	:
	$R_r$ :" se $x_1$ é $A_{r1}$ ee $x_n$ é $A_{rn}$ então $u_1$ é $B_{r1}$ ee $u_m$ é $B_{rm}$ "
fato	$A=x_1 \notin A_1 e A=x_2 \notin A_2 e \dots e A=x_n \notin A_n$
conclusão	u é B=R(A)

Fonte: (BASSANEZI, 2014)

#### 2.2.6.6. Mamdani

Mamdani é um sistema de inferência amplamente utilizado e propõe uma relação *fuzzy* binária M entre x e u, e é baseado na composição de inferência Max – Min. Seu procedimento pode ser resumido da seguinte forma: em cada regra, a implicação é modelada através da T-norma do mínimo. Para o agregador, conectivo 'ou', a T-conorma do máximo. (BASSANEZI, 2014).

Como o operador utilizado na etapa de implicação não respeita as propriedades para ser denominado implicação *fuzzy*, não é correto dizer que se trata de uma implicação de *Mamdani*. A relação M é formalmente definida como um subconjunto *fuzzy*  $X \times U$  onde a função de pertinência é modelada através da eq.36.

$$\varphi_{M}(x,u) = \max_{1 \le j \le r} (\varphi_{R_{j}}(x,u)) = \max_{1 \le j \le r} [\varphi_{A_{j}}(x,u) \land \varphi_{B_{j}}(x,u)],$$
(36)

A figura 18 exemplifica a aplicação do método de *Mamdani*, como pode-se observar, dado os subconjuntos *fuzzy*  $A_{ij}$  é calculado para cada regra um novo subconjunto, através da tnorma do mínimo, iterando para o valor x seu mínimo em cada um dos conjuntos pertencentes às regras, depois ocorre a agregação das regras, através da t-conorma do máximo, no final da etapa de inferência se obtém um conjunto *fuzzy* de saída, que por fim é *defuzzyficada* em um valor *crisp*.



Figura 18 - Sistema baseado em Mandani, com duas regras e dois conjuntos A e B, para as entradas x e y ocorrem as ativações em cada um dos subconjuntos A<sub>1</sub>, A<sub>2</sub>, B<sub>1</sub> e B<sub>2</sub>. E em cada regra, através da T-norma do mínimo inferem uma pertinência no conjunto C que através da T-conorma do máximo obtêm-se um conjunto *fuzzy* de saída, depois através do centróide o valor *crisp* de saída é inferido. Fonte: (RUSTUM et al., 2020).

Para defuzificação, existem alguns métodos utilizados na literatura, o mais comum é o método do centroide, ou centro de gravidade, onde o valor da coordenada u que representa a saída defuzificada do sistema, é calculado através das repectivas expressões dicretas e continuas.(eq. 37 e eq. 38)

$$\boldsymbol{G}(\boldsymbol{B}) = \frac{\sum_{i=0}^{n} u_i \varphi \boldsymbol{B}(u_i)}{\sum_{i=0}^{n} \varphi \boldsymbol{B}(u_i)}$$
(37)

$$G(B) = \frac{\int_{\mathbb{R}} u_i \varphi B(u_i)}{\int_{\mathbb{R}} \varphi B(u_i)}$$
(38)

2.2.6.7. TSK

O método de Takagi-Sugeno-Kang (TKS) é um sistema de inferência que difere de Mamdani na forma da implicação e no processo de defuzificação, a saída do sistema TKS é dado explicitamente por uma função, que recebe os valores de entrada da regra, seja uma base de regras *fuzzy* com *r* regras e para cada regra temos *n* entradas  $(x_1, x_2,...,x_n) \in \mathbb{R}$  e uma saída  $u \in \mathbb{R}$  a função de saída é dada pela eq. 39.

$$\mathbf{u} = \mathbf{f}_{r}(\mathbf{x}_{1}, \mathbf{x}_{2}, \dots, \mathbf{x}_{n}) = \frac{\sum_{j=1}^{r} \mathbf{w}_{j} \cdot \mathbf{g}_{j}(\mathbf{x}_{1}, \mathbf{x}_{2}, \dots, \mathbf{x}_{n})}{\sum_{j=1}^{r} \mathbf{w}_{j}} = \frac{\sum_{j=1}^{r} \mathbf{w}_{j} \cdot \mathbf{u}_{j}}{\sum_{j=1}^{r} \mathbf{w}_{j}}$$
(39)

Onde os pesos  $w_j$  corresponde à contribuição da regra para saída do sistema e são dados por  $w_j = \varphi A_{j1}(x_1) \Delta \varphi A_{j2}(x_2) \Delta ... \Delta \varphi A_{jn}(x_n)$ , onde  $\Delta$  é uma T-norma. Quando se tem um sistema de duas regras com duas variáveis de entrada, onde temos a saída como uma função linear afim, chamamos de Takagi-Sugeno. A figura 19 exemplificam o processo, onde em cada regra, das duas entradas x e y são calculadas as suas pertinências em cada subconjunto e depois a T -norma entre eles, isso é usado como peso W para saída de cada regra são funções lineares, a saída como a média ponderada entre o peso e sua respectiva função.

A figura 20 exemplifica como cada função ou regra é ativada de acordo com o subconjunto pequeno, médio e grande é ativado, suavizando uma função.



Figura 19 - Sistema baseado em Takagi-Sugeno, em cada regra, das duas entradas x e y são calculadas as suas pertinencias em cada subconjunto e depoisa T -norma entre eles, isso é usado como peso W para saída de cada regra são funções lineares, a saída como a média ponderada entre o peso e sua respectiva função. Fonte: (SUGENO; KANG, 1988)



Figura 20 - Takagi–Sugeno como uma aproximação linear suavizada por peças de uma função não linear. Cada função é ativada de acordo com os subconjuntos *fuzzy* abaixo criando uma curva suavizada. Fonte: (BABUŠKA, 1998).

### 2.2.6.8. Fuzzy C-means

O método *fuzzy c-means* é um método de clusterização amplamente utilizada na etapa de *fuzzificação* de um sistema de inferência *fuzzy*, foi proposto por BEZDEK (1981) onde, dado um conjunto  $X = (x_{k1}, x_{k2}, ..., x_{kp}) \in \mathbb{R}^p$  para todo  $k \in (1, 2, ..., n)$  o problema da clusterização *fuzzy* é encontrar uma partição *fuzzy* que representa melhor a estrutura de dados. A partição *fuzzy* de X é uma família de C subconjuntos *fuzzy* de X representada por  $P = \{A_1, A_2, ..., A_c\}$  de modo que satisfaz a eq. 40 e eq. 41.

$$\sum_{i=1}^{c} A_i(X_k) = 1$$
(40)

$$0 \leq \sum_{i=1}^{c} A_i(X_k) \leq n \tag{41}$$

Para todo  $K \in (1, 2, ..., n)$  onde n é o número de elementos do conjunto. Portanto a soma dos graus de pertinência de um elemento em todos os subconjuntos deve ser igual a 1. Pode-se resumir o algoritmo nos passos a seguir:

I. Para os C clusters defina uma partição  $P = (A_1, A_2, ..., A_c)$ atribuindo graus de pertinência aos elementos de forma aleatória.

II. Forneça os C centros dos clusters  $V = (v_1, v_2, ..., v_c)$ para a primeira iteração, para as próximas iterações  $v_i$  é calculado através da eq. 42.

$$v_{i} = \frac{\sum_{k=1}^{n} [A_{i}(x_{k})]^{m} x_{k}}{\sum_{k=1}^{n} [A_{i}(x_{k})]^{m}}$$
(42)

onde m > 1 é chamado índice de Fuzzificação ou expoente de fuzzificação da matriz de partição. Quanto maior o valor de m, maior é a sobreposição entre os conjuntos, ou seja, maior a pertinência de um mesmo elemento em outros conjuntos, principalmente aqueles à fronteira dos clusters.

III. Atualize a partição seguindo os seguintes passos: para cada  $x_k \in X$  e todo  $i \in (1, 2, ..., c)$  se  $||x_k-v_i||^2 > 0$  calcule o grau de pertinência de  $x_i$  através da eq. 43

$$A_{i}(x_{k}) = \sum_{k=1}^{n} \left\{ \left\{ \frac{(|x_{k}-v_{i}|)^{2}}{(|x_{k}-v_{j}|)^{2}} \right\}^{\frac{1}{(m-1)}} \right\}^{-1}$$
(43)

Pare caso  $|P_n - P_{(n+1)}| < \varepsilon$  onde  $\varepsilon$  é o erro esperado.

### 2.3. ESTADO DA ARTE

Para encerrar a revisão bibliográfica, nesta secção estão apresentados um resumo de trabalhos recentes que abordam as temáticas deste trabalho, envolvendo: processamento de imagens, concreto e sua caracterização, sistema *fuzzy* e especialmente sistema de inferência baseado em TSK.

Nos últimos anos técnicas de processamento de imagem 2D e 3D para caracterização dos poros das amostras de microCT de concreto, propriedades, desempenho e eficiência do material tem sido desenvolvido. Entretanto não foram encontradas aplicações de sistema *fuzzy* para classificações de elementos internos em amostras de microCT de concreto, nem encontrados sistemas especialistas *fuzzy* baseados em TSK, contudo, esta aplicação foi vista nas áreas médicas, de sensoriamento remoto, aplicações em controle, entre outros.

Por exemplo no trabalho intitulado "Comparação das distribuições de tamanhos de poros de concretos com diferentes dosagens de mistura de retenção de ar usando abordagens de imagem 2D e 3D"(CHUNG et al., 2020, Tradução Nossa) Os autores propõem investigar a distribuição do tamanho dos poros em materiais cimentícios, utilizando imagens de microCT de raios X.

Através de uma variação do método de Otsu as imagens foram binarizadas, depois passaram por uma variação da técnica chamada Watershed (CHUNG et al., 2017) para que as regiões dos poros que tivessem intersecções entre suas fronteiras pudessem ser separadas.

Destas imagens foram montados os modelos 3D para visualização e análise. A correlação entre as características dos poros e as propriedades mecânicas das amostras foi examinada, com os resultados indicando que a distribuição de tamanho de poro descrita usando a distribuição de comprimento de corda é mais eficaz que o método convencional baseado em volume. (CHUNG et al., 2020).

No trabalho intitulado "Estudo comparativo da evolução de danos em mezo-escala de concretos sob carga de tração estática e dinâmica, usando tomografia computadorizada de raios-X e análise de imagens digitais" (ZHU et al., 2020, Tradução Nossa) os autores propõem, através de imagens de tomografia computadorizada de raios-X de concreto e de técnicas de processamento de imagem digital investigar a deterioração do material cimentício sob carga de tração estática e dinâmica.

Após a obtenção das imagens, elas são segmentadas manualmente baseadas no nível de cinza do histograma, adotando após alguns testes um limiar de 0.64 na escala [0, 1], também foi utilizado o método de Otsu para binarização, para separar a pedra da argamassa.

Dessas regiões foram extraídas características quantitativas para avaliar as diferenças da distribuição inicial de defeitos em mezo-escala, e as diferenças na evolução dos danos em amostras de concreto sob dois modos de carregamento diferentes. Também é realizado o cálculo da fração de vazios com objetivo de estimar o grau de dano e investigar as diferenças na distribuição espacial do dano sob diferentes deformações.

Os resultados mostraram que os defeitos na mezo-escala de amostras heterogêneas de concreto, podem ser identificados com base nos valores relativos da escala de cinza das imagens de microCT, e podem ser caracterizados por indicadores, como fração agregada, fração de argamassa, fração de vazios, média e variância desses valores. Além disso, a análise da evolução local dos danos contribuiu para prever a localização da fratura de amostras de concreto.

No estudo intitulado "Método de detecção de fibra baseado em gradiente na imagem de Microtomografia, para definir o viés de orientação da fibra em concreto de ultraelevado desempenho" (MILETIĆ et al., 2020, Tradução Nossa) os autores argumentam que as propriedades do concreto de ultra elevado desempenho (CUED) dependem em grande parte da fração, orientação e distribuição do volume de fibra dentro da matriz cimentícia.

Para contornar a dificuldade de determinação desses parâmetros, essa pesquisa se utiliza imagens de microCT do concreto, os testemunhos cilíndricos de CUED foram extraídas de uma amostra de teste e as imagens de microCT de alta resolução foram adquiridas. Após a reconstrução tridimensional e o processamento de imagens, foram obtidas informações quantitativas sobre as fibras.

Em relação a segmentação os autores ainda testam diferentes técnicas para separar a região da fibra metálica, entre elas estão o algoritmo de Knee, Erro-mínimo e método de Otsu (BURGER; BURGE, 2013; PETROU, MARIA MP; PETROU, 2010) apresentando este último como mais eficiente dentre estes que citei.

Os autores propuseram uma nova técnica de pós-processamento de imagem baseada no gradiente de intensidade local, onde observou-se uma melhora significante na detecção de fibra cruzada em comparação com outras técnicas existentes.

A fração estimada do volume de fibra está próxima do design das amostras e dos valores medidos experimentalmente. As fibras em formato reto e em gancho na amostra de CUED foram identificadas e segmentadas com sucesso utilizando essa nova técnica.

No estudo intitulado "Técnicas de alta eficiência e parâmetros microestruturais para avaliar autocura de concreto usando tomografia de raios X e Porosimetria baseada em intrusão de mercúrio: uma revisão" (SIDIQ et al., 2020, Tradução Nossa) os autores avaliam através de uma revisão bibliográfica a autocura do concreto, que é a habilidade de fechar as aberturas das fissuras que lhes são acometidas de forma autônoma.

Das técnicas de análise apresentadas temos as qualitativas e quantitativas, das qualitativas ele apresenta a microCT de raios X, onde através das imagens das secções transversais pode-se montar um modelo 3D e dessa forma realizar uma análise visual dos poros e estruturas internas.

Das técnicas de análise quantitativas ele apresenta a porcentagens de vazios, o tamanho dos poros e das microfissuras, e os seu volume, esses dados podem ser obtidos através da binarização das imagens e extração das respectivas características. Utilizando imagens de tomografia de raios X associado a técnicas de processamento de imagens, e posimetria baseada em intrusão de mercúrio que são revisadas como as metodologias de teste não destrutivas mais avançadas para a avaliação da autocura do concreto à nível microestrutural segundo os autores revisados.

Os recursos dos dois métodos de correlação com a autocura em materiais cimentícios são apresentados através do conteúdo vazio, medidas de diâmetro de largura do poro e do volume de fissuras.

A pesquisa intitulada "Modelo de elementos finitos de concreto baseado em Microtomografia computadorizada, utilizando tecnologia de processamento de imagens." (YANG, 2019, Tradução Nossa) o autor justifica que, com o desenvolvimento de pesquisas em relação ao desempenho do concreto surgiram vários modelos de elementos finitos de microestrutura como por exemplo, o modelo de treliça, modelo de feixe de partículas e modelo de agregado aleatório.

Ainda segundo o autor com os surgimentos da tecnologia de microCT foi possível se realizar uma análise não destrutiva da microestrutura interna das amostras do material, propõe por tanto que se puder ser estabelecido um modelo de mezo-estrutura real ou próximo do real de elementos finitos através de imagens de microCT haverá um impacto na distribuição numérica da simulação de concretos.

O autor explica que os elementos internos de interesse, pedra, pasta de cimento e poro, por conta da diferença obvia entre suas densidades diferem nas características de suas cores, onde a pedra tende ao branco, os poros ao preto e a pasta de cimento fica entre elas.

Neste artigo são utilizadas técnicas de processamento digital de imagens para segmentar e as regiões de interesse e extrair informações de geometria e posição de cara um destes elementos.

Na parte de pré-processamento, as imagens são transformadas em imagens de índices e depois a cor e a saturação são reduzidas a partir da função *ind2gray* (MATLAB, 2020a), após essa etapa, o histograma das imagens são homogeneizadas, o que aumenta o contraste delas.

Por fim as imagens são binarizadas através do método de Otsu. A partir destas informações é construído um modelo de elementos micro finitos e após a simulação os resultados são comparados com outros métodos, apresentando como conclusão que esta técnica pode compensar certas deficiências do modelo tradicional e refletir melhor as características dos materiais de concreto.

Em "Características dos poros e seus efeitos nas Propriedades do material de concreto celular leve avaliado usando imagens Microtomografia e abordagens numéricas" de (CHUNG et al., 2017, Tradução Nossa) os autores utilizam um conjunto de amostras de concreto leve para investigar os efeitos da densidade do material nas características dos poros, assim como as propriedades físicas dos materiais.

As características de distribuição dos poros dessas amostras são analisadas usando imagens de microCT de raios x, as imagens tem seu contraste aumentado utilizando o algoritmo de Bronnikov, e então limiarizadas através do método de Otsu.

A imagem binarizada em 3D é obtida empilhando 1000 imagens binarizadas de duas dimensões. Dos objetos são avaliados descritores como a anisotropia, fator de circularidade dos poros e a densidade relativa da espessura da célula.

A condutibilidade térmica, o módulo direcional e a resistência de cada amostra de concreto celular leve são calculadas usando simulações numéricas e comparadas com os resultados experimentais.

No trabalho intitulado "Caracterização 4D de Mecanismos de Dano e Fratura de Concreto de ultra alta performance reforçado com fibra através de testes in situ de Microtomografia computadorizada por raios X" (YANG et al., 2020, Tradução Nossa) os autores realizaram uma sequência de imagens de microCT de raios X para diferentes carregamentos nas amostras de concreto.

Através de técnicas de processamento de imagem as microestruturas internas das amostras são caracterizadas. Foram definidos limiares para separar os objetos, também foram testados para as imagens em duas dimensões diferentes limiares e seu respectivo percentual de vazios estimado. Dessa forma pôde-se avaliar a sensibilidade do volume de vazios em relação aos limiares, graficamente pode-se ver o abrupto crescimento do valor de vazios próximo do limiar 26 numa escala de [0, 255] indicando que um volume significativo de argamassa foi considerado como poro, ou seja o limiar de 25 foi adotado como suficiente para separa os poros do restante dos elementos internos.

Para segmentação das fibras foi utilizado um limiar de 40 numa escala de [0, 255] esta segmentação foi utilizada para identificar a orientação geral das fibras. Um código foi implementado pelos autores para identificar a linha central do esqueleto de cada uma das fibras. Foram também realizadas análises e caracterizações das fissuras.

Após a segmentação 3D das amostras é possível visualizar a evolução das micro e macro fissuras. as imagens de microCT revelam os efeitos significativos das fibras de aço: suprimindo

a propagação das microfissuras, levando a dispersas múltiplas menores fissuras e contribuindo para desviar a fenda originalmente vertical em direção a orientação geral das fibras através das fissuras.

No artigo "Estudo da microestrutura e distribuição da composição da zona da superfície do concreto com base na teoria fractal e na tecnologia de Microtomografia computadorizada de raios X" (LIU et al., 2020, Tradução nossa), os autores investigaram as variações da microestrutura, distribuição dos elementos e relação entre a porosidade e a massa da camada superficial do concreto através de imagens de microCT de raios x e tecnologia de retificação de perfis, também foram estudadas as variações de conteúdo de agregado grosso e pasta com profundidade na superfície do concreto.

Os resultados mostram que o conteúdo agregado grosso na camada superficial do concreto aumenta, mas a porosidade aumenta e depois diminui com o aumento da profundidade da superfície do concreto. Finalmente, todos eles tendem a ser constantes quando a profundidade é maior que um determinado valor.

Os autores calculam a dimensão fractal do agregado grosso, pedra, das amostras, eles explicam que diferentes objetos têm diferentes dimensões fractais, por tanto pode ser utilizado para representar características da imagem. foi utilizado o algoritmo de *box Count* para isto. A dimensão fractal do volume do agregado grosso e a dimensão fractal da gradação do agregado grosso no concreto encontrado foi de cerca de 1,35 e 2,68 (Adimensional), respectivamente.

(SOLTANI et al., 2018, Tradução Nossa) seu "Um novo sistema especialista baseado em lógica *fuzzy* e algoritmos de processamento de imagem para diagnóstico precoce de glaucoma", apresentam um sistema especialista baseado em lógica *fuzzy* para diagnóstico precoce de glaucoma.

As imagens de retinografia são pré-processadas usando filtros apropriados para atenuação de ruído como o filtro gaussiano e de média. O algoritmo *Canny*, que é um detector de bordas, é então usado para detectar os contornos da região. Os principais parâmetros são então extraídos, após a identificação das formas elípticas do disco óptico e nervo ótico. Esta operação é realizada usando a *Randomized Hough Transform*.

Em fim um sistema de classificação baseado em lógica *fuzzy* é proposto para determinar as condições dos pacientes. esse sistema segundo os autores se apresenta vantajoso na medida em que leva em consideração parâmetros instrumentais e fatores de risco como idade, raça, histórico familiar, contribuem de forma importante para a identificação de casos suspeitos de glaucoma. O sistema proposto foi testado em um conjunto de dados real de imagens oftalmológicas, com casos normais e glaucomatosos. Observou-se que comparados com outros sistemas existentes, os resultados experimentais que O percentual de verdadeiros positivos é superior a 96%, alcançando uma melhora de 1 a 9% em relação a outros métodos.

No trabalho "Classificação de imagens de sensoriamento remoto através do algoritmo de *fuzzy* C-Means de intervalo adaptativo semi-supervisionado tipo 2" (XU et al., 2019, Tradução nossa) os autores apresentam um método para classificação de regiões de imagens de sensoriamento remoto utilizando um sistema semi-supervisionado baseado em lógica *fuzzy*, pois devido à natureza difusa nas imagens desse tipo, um algoritmo tradicional de classificação não consegue ser muito preciso.

Os autores propõem um método de classificação baseada em *fuzzy C-means* do tipo 2 conseguindo uma precisão 5% maior que outros métodos em geral, onde são usados alguns poucos rótulos para supervisionar o sistema, ou seja, para auxiliar a convergência correta dos clusters.

O artigo "Análise do risco de dengue através da média do modelo baseado em Takagi – Sugeno" (SILVEIRA; DE BARROS, 2015, Tradução Nossa) propõe uma análise da evolução do risco de dengue no sul da cidade de Campinas-SP, a partir de um modelo do tipo Takagi – Sugeno em que a consequência de cada regra difusa é uma eq. diferencial parcial. O sistema de inferência combina as regras e a eq. resultante que chamamos de modelo global, que é então solucionado numericamente através de métodos que segundo os autores são de alta ordem de acurácia.

As funções de pertinência dos subconjuntos baixo, médio e alto risco são modeladas, assim como subconjuntos para a precipitação, habitantes humanos e recipientes de reprodução de mosquito, essas últimas três variáveis linguísticas são utilizadas para inferir através de um sistema *fuzzy* num parâmetro que o autor chama de k, que é a difusão espacial do risco de dengue, esse e o outro coeficiente a também tem modelado seus subconjuntos *fuzzy* que são usados como parâmetros das equações diferenciais de saída do sistema de takaki-sugeno.

Todo sistema é baseado em regras difusas e informações fornecidas por especialistas. Os resultados mostraram que uma ação eficaz para reduzir o risco de dengue é combater severamente os locais potenciais de criação de mosquitos.

No artigo "Controle de posição de um drone quadcopter usando algoritmos evolutivos com autoajuste baseado em Takagi – Sugeno – Kang de primeira ordem, lógica *fuzzy* aplicado em pilotos automáticos"(YAZID; GARRATT; SANTOSO, 2019, Tradução Nossa) os autores

propõe um sistema de autoajuste baseado em algoritmos evolutivos para Takagi de primeira ordem - Controlador lógico *fuzzy* (FLC) do tipo Sugeno-Kang.

Os antecedentes são sinais de controle e as consequentes funções lineares que ajustam parâmetros relacionados a dinâmica do motor e orientação espacial do Drone, toda saída de controlador passa por um processo de algoritmo genético que altera certos parâmetros de entrada do sistema, foram consideradas três principais otimizações para os algoritmos genéticos, algoritmo genético, otimização de enxame de partículas e colônia artificial de abelhas para facilitar a sintonia automática. A eficácia dos esquemas de controle propostos foi testada e comparada sob várias condições de voos diferentes.

Por fim no trabalho "Proposta de metodologia para a análise de imagens tomográficas de argamassas leves reforçadas com fibras utilizando técnicas *fuzzy* e algoritmos de clusterização" (LOUREIRO, et. al, 2015) os autores estudam uma mistura de argamassa leve com adição de EVA e reforçada com fibras de piaçava com o objetivo de analisar a estrutura destas misturas. Para isto foi desenvolvida uma metodologia de caraterização que utiliza como base imagens de microCT do material e analisa suas caraterísticas usando algoritmos de clusterização (k-means e c-means) e um sistema especialista *fuzzy*, que possibilitam agrupar objetos no interior da imagem da amostra usando critérios de similaridade como densidade, área, cor e excentricidade.

A pesquisa utilizou três misturas diferentes de argamassa, uma de argamassa pura, outra com adição de EVA e por fim, uma com EVA e fibra. Após a aquisição das imagens de microCT e da etapa de pré-processamento, para determinação do ROI foi utilizado o algoritmo de K-Means e *fuzzy C-Means* clusterizados em três grupos, separando com sucesso a pasta de cimento do restante dos outros objetos, porém a tentativa de reclusterizar, ou seja, dividir a região que contém poro, EVA e fibra em sub-regiões não obteve sucesso.

Para classificar esses objetos foi desenvolvido um sistema *fuzzy* baseado em Mamdani utilizando as características de área e excentricidade e uma base de nove regras. Na identificação da argamassa das imagens das amostras a metodologia apresentou resultados satisfatórios, porém apresentou dificuldades na separação dos poros, EVAs e fibras de piaçava. De acordo com os autores esta imprecisão se dá devido à similaridade das áreas e excentricidades destes objetos.

# 3. METODOLOGIA

Este capítulo tem por objetivo descrever os métodos utilizados na pesquisa. Primeiramente serão apresentados a aquisição das amostras e das imagens. Em seguida como foi realizado a segmentação das imagens para separar agregado graúdo e por último a segmentação para separar o restante dos objetos presentes na amostra (poro, EVA e fibra).

Para cada segmentação será apresentado o processo de validação assim como, os métodos utilizados para a extração das características de cada uma das regiões. Por fim a modelagem do sistema de inferência baseada em Takagi-Sugeno-Kang e a sua validação.

Após a obtenção das amostras e das imagens, todo processo pode ser resumido através do fluxograma apresentado na figura 21, é realizado a segmentação das imagens para duas regiões, uma que contém o agregado graúdo e outra que contém o restante dos elementos (figura 21 (a)). Em seguida, é realizada a extração de características das regiões computacionalmente (figura 21 (b)) e a validação da segmentação; depois, a classificação dos objetos em suas respectivas classes a partir do sistema de inferência (figura 21 (c)). Por fim é realizada a análise dos resultados (figura 21 (d)).



Figura 21 - Fluxograma do processo da metodologia aplicada. (a) é realizado a segmentação das imagens para duas regiões, uma que contém o agregado graúdo e outra que contém o restante dos elementos, (b) é realizada a extração de características das regiões computacionalmente, (c) a classificação dos objetos em suas respectivas classes a partir do sistema de inferência, (d) é realizada a análise dos resultados Fonte: Acervo pessoal.

### 3.1. OBTENÇÃO DAS AMOSTRAS E IMAGENS

Para a confecção dos corpos de prova deste trabalho, Dias (2017) utilizou cimento Portland CP II E 40 RS, água, areia fina como agregado miúdo, britas 0 e 1 como agregados graúdos, superplastificante, EVA moído e fibras de piaçava.

Os agregados de EVA utilizados foram divididos em duas categorias, de acordo com seu diâmetro, os elementos com diâmetros entre 2,36 mm e 1,18 mm foram denominados EVA grosso (EG) e, os agregados de EVA com diâmetros menores que 850 µm foram denominados como EVA fino (EF). No caso da fibra de piaçava o comprimento adotado de 2 cm (DIAS, 2017).

Os corpos de prova foram moldados em fôrmas cilíndricas com 100 mm de diâmetro e 200 mm de altura de acordo com a NBR 5738 (ABNT, 2015b). O EVA e as fibras de piaçava foram incorporados ao traço (proporção de todos os materiais constituintes do material) do concreto por substituição em volume do agregado graúdo. O concreto sem adição de fibra e/ou grãos de EVA foi denominado concreto de referência (CR). O Quadro 6 apresenta o esquema com as siglas e porcentagens utilizadas na confecção dos corpos de prova.

GRÃOS DE EVA							
EVA FINO					EVA GROSSO		
FIBRAS	0%	5%	15%	25%	15%		
0%	CR	EF5	EF15	EF25	EG15		
1%	-	1EF5	1EF15	1EF25	1EG15		

**Quadro 6:** Convenção de siglas utilizadas para os corpos de prova de acordo com as porcentagens e características utilizadas na sua confecção.

Fonte: (Dias, 2017).

Utilizando esses corpos de prova as imagens microtomográficas foram obtidas usando um microtomógrafo SkyScan® 1173, versão 1.6, do Laboratório de Instrumentação Nuclear da COPPE - RJ. Para que fosse possível ajustar os espécimes ao tomógrafo, foi necessário extrair dos corpos de prova, um testemunho com 25 mm de diâmetro e 40 mm de altura. As projeções foram reconstituídas através do software NRecons® versão 1.7.7.0

As amostras foram submetidas a ensaios de compressão e geraram, para cada testemunho, em torno de 2100 imagens da sua seção transversal, todas em escala de cinza (8 bits) com 2240x2240 pixels cada imagem. A Figura 22 mostra como exemplo uma secção da

amostra de 1EG15 gerada pelo microtomógrafo indicando exemplos dos objetos: fibra, poro e EVA.



Figura 22 – Exemplo de imagem digital original gerada pelo ensaio de microCT do corpo de prova 1EG15 (vide Quadro 6). Fonte: Acervo pessoal.

## 3.2. SEGMENTAÇÃO DAS IMAGENS MICROTOMOGRÁFICAS.

Após a obtenção e classificação das imagens, deu-se início ao processo de segmentação, a fim de separar os elementos contidos no interior das amostras, pedra, poros, EVA moído e fibras de piaçava este processo foi iniciado a partir da binarização das imagens.

Para definição do limiar de binarização é comum que se utilize o histograma da imagem, e escolha através da sua observação o valor a ser utilizado. Porém, este método de definição do limiar está sujeito a uma observação humana e, portanto, sujeito a uma margem de erro maior. (DU PLESSIS; BOSHOFF, 2019).

A fim de tentar diminuir o erro na escolha do limiar, e assim otimizar este processo, foram desenvolvidas rotinas no software MATLAB® de algoritmos conhecidos como K-means (Anexo II), Fuzzy C-means, Otsu e range-constrained Otsu (AnexoVII), automatizando a definição do limiar ótimo de binarização.

É definido a partir da matriz de imagem um vetor contendo as intensidades de cor de cada pixel como entrada para os algoritmos de K-Means e Fuzzy C-Means. Para ambas as técnicas foram utilizados 3 clusters, de modo que tivéssemos a separação dos pixels com intensidade baixa, média e alta. Em relação ao fuzzy C-Means foi definido que os pixels pertencem à classe de maior grau de pertinência.

Após a clusterização, usando estas duas técnicas para definição dos limiares, utilizouse a média entre os centros do primeiro e segundo cluster para segmentar os elementos de baixa densidade, Poro, EVA e Fibra, e a média entre o segundo e terceiro cluster para separar a pedra dos demais objetos.

Em relação a técnica de *Otsu* o limiar é definido diretamente seguindo o algoritmo já discutido na secção **2.2.4.1.** do referencial teórico. Em todos os casos, antes, as imagens passaram por um filtro gaussiano para diminuição de ruído.

Em relação à separação do Poro, EVA e Fibra do restante dos elementos, as técnicas Kmeans e Fuzzy C-means apresentaram valores idênticos de limiar, mas falharam ao separar os objetos com dimensões menores, como aquelas mais próximas a 1 pixel. Por este motivo, o método de *Otsu* se mostrou mais preciso.

Apesar de satisfatório, o limiar definido pelo método de *Otsu* pode ser tendencioso para a classe com maior variância intraclasse (XU et al., 2011), neste caso, as regiões mais claras da imagem, desta forma, o método acaba por classificar de forma errônea alguns objetos, colocando-os no mesmo grupo da pasta de cimento.

Como Xu (et al., 2011) tiveram sucesso em eliminar essa tendência do método de Otsu, desenvolvendo o algoritmo chamado por eles, de *range-constrained Otsu*. Foi realizado essa modificação, e este mostrou resultados satisfatórios, separando bem os objetos e solucionando o problema com o Otsu original. A figura 23 exibe exemplos de uma mesma imagem (a) binarizada através dos métodos de K-means 23 (b), Fuzzy C-means 23 (c), Otsu 23 (d) e range-constrained Otsu 23 (e).



Figura 23 – Segmentação por diferentes técnicas, imagem original da amostra EF25 (a) e imagens da mesma amostra Binarizada pelos métodos: K-Means (b), *Fuzzy* C-Means (c), de OTSU (d) e de Range-Constrained Otsu (e).
Fonte: Acervo pessoal.

Baseado nos parâmetros descritos, o Range-Constrained Otsu foi o método escolhido para segmentar os elementos contidos na pasta de cimento. A partir deste ponto todo o processo de extração e classificação dos elementos se deu a partir das imagens Binarizadas a partir desta técnica.

No caso da segmentação do agregado graúdo foi utilizado o *K-means*, (Anexo I) isso se deve ao fato de que a técnica apresentou melhores resultados na etapa de testes. O limiar foi definido como já explicado anteriormente, com a média entre os centros dos dois últimos clusters. Depois de definido o limiar e binarizado as imagens, deu-se início às operações morfológicas para filtragem e melhoramento da segmentação.

Foram utilizadas operações de *closing* e *opening* nesta ordem, para conectar regiões que tiveram vizinhos atribuídos a classe de fundo quando deveriam ser de frente, e eliminar elementos que foram atribuídos erroneamente como classe de frente, ou seja, os ruídos presentes na imagem binarizada.

Utilizando um elemento estruturante do tipo disco com raio 15 e 10 respectivamente, valor definido manualmente. Podemos ver na figura 24 (a) a imagem original, na figura 24 (b) os resultados da binarização, e na figura 24 (c) a imagem após aplicação das operações morfológicas.



Figura 24 – Processo de segmentação da pedra, (a) Imagem Original CR, (b) Imagem binarizada através do limiar de K-Means e (c) imagem processada através das operações morfológicas (O.M.) de abertura e fechamento.
Fonte: Acervo pessoal.

# 3.3. VALIDAÇÃO DA SEGMENTAÇÃO

Obtidos os resultados da binarização, foi possível então realizar a validação deste método através do cálculo do percentual de objetos nas amostras e sua comparação com os valores experimentais de porosidade encontrados na literatura. Para tal, foi necessário definir a área que diz respeito apenas à amostra de concreto, sem que fossem consideradas as bordas da imagem.

Assim, foi desenvolvido um algoritmo do tipo crescimento de regiões, que cria uma máscara gerada especificamente para cada imagem, definindo o limite entre a amostra de concreto e a borda da imagem, e representa a área total da amostra, como pode ser observado na figura 25(a). Esta máscara foi somada à imagem binarizada, gerando uma nova imagem contendo apenas os objetos 25(b).



Figura 25 - Imagem binária contendo máscara que representa a área total da amostra (EF25) (a), e (b) amostra binarizada após aplicação da máscara. Fonte: Acervo pessoal.

Após a obtenção da imagem segmentada e a área total da amostra, foi realizada a etapa de extração de características para cada objeto (Anexo IV), nesse módulo são rotulados cada uma das regiões pretas, utilizando um algoritmo de reconhecimento de regiões, conhecido como *Blob Detection* (ZHANG; RUSINKIEWICZ, 2018) e, para cada região rotulada calcula-se a sua área em pixels e ao final da aplicação o programa retorna uma tabela contendo-as.

Por fim, foi realizado o cálculo da razão entre o somatório da quantidade de pixels que representam cada um dos elementos contidos no concreto (área dos elementos) em cada fatia da imagem e a quantidade de pixels total da amostra (área total da amostra). Como demonstrada na eq. 44. (Anexo III)

No caso da pedra não foi necessário a aplicação da máscara da borda, uma vez que a após a binarização e a operação morfológica obtemos uma imagem que apresenta em uma das classes a ROI e na outra a região de fundo. Ou seja, já retorna uma imagem sem borda.

Percentual de elementos = 
$$\frac{\text{Área total dos elementos encontrados}}{\text{Área total da amostra}} \times 100$$
 (44)

O percentual definido na eq. 44 foi calculado para cada seção transversal de cada amostra, de modo que a partir dos traços das amostras (DIAS, 2017) foi possível calcular o volume de EVA e fibra presente em cada uma delas e seu percentual estimado, levando em consideração que cada traço representa o volume de 21 corpos de prova e como a distribuição dos elementos nesses corpos de prova pode não ser homogênea, ao final, obtemos uma aproximação dos valores de porosidade nas amostras.

## 3.4. PROCESSO DE EXTRAÇÃO DE CARACTERÍSTICAS

Após a determinação da ROI descrita na secção **3.3.** se dá a extração de características que permitirão posteriormente classificar os objetos.

Para realizar a extração das características foram realizadas rotinas no MATLAB. Para extração da área e da excentricidade, foi utilizado a função *regionprops()* da biblioteca de processamento de imagens do próprio programa (MATLAB, 2020b) a função toma como entrada a imagem segmentada sem borda, onde a área de interesse é representada pela cor branca.

Para a extração do descritor de dimensão fractal, foi desenvolvido uma função *DimFract()* que toma uma imagem binaria e da região branca através do algoritmo de *Box*  *Count,* encontra a dimensão fractal através de um método iterativo que para tanto atinge convergência do valor, para uma mudança pequena entre um passo e outro pré-definido.

Como cada imagem segmentada tem diversas regiões de objetos das quais se quer extrair a característica fractal, a imagem foi reconstruída para cada objeto da seguinte forma (Anexo V), seja uma imagem  $J_i$  e seja k o k-ésimo objeto da i-ésima imagem, uma nova imagem  $I_{i,k}$  é criada apenas com o objeto k.

Depois cada  $I_{i,k}$  (imagem gerada para o objeto k da i-ésima imagem) é chamada dentro da função *DimFract()* de modo que no final para cada i-ésima imagem temos um *array* contendo k elementos com suas respectivas dimensões fractais (Anexo VI). Na figura 26 podemos ver um exemplo de uma imagem reconstruída para um objeto e sua respectiva dimensão fractal.



Figura 26 - Segmentação do CR apontando a dimensão fractal para um dos elementos internos. Fonte: Acervo pessoal.

No final desse processo, o programa retorna uma tabela onde para cada elemento da imagem, ou seja, linha da tabela, temos os descritores de área, excentricidade, e dimensão fractal. Com cada tabela que representa a discrição de cada imagem, é criado uma base de dados unindo-as, na tabela 1 pode ser observado um exemplo com os primeiros elementos de uma imagem do concreto de referência.

Objeto	Área	Excentricidade	Dimensão Fractal
1	11	0,83	0,24
2	1	0,00	0,00
3	176	0,80	0,57
4	4	0,97	0,09
5	2	0,87	0,03

**Tabela 1:** Primeiros elementos da base de dados de uma fatia do CR com seus respectivos descritores, Área em pixels e excentricidade e Dimensão fractal, adimensionais.

Fonte: Acervo pessoal.

### 3.5. INFERÊNCIA POR TAKAGI-SUGENO-KANG

Com a extração da base de dados com as características extraídas para cada objeto de cada amostra, é possível classificar esses objetos como poro, EVA ou fibra. Para essa classificação escolhemos uma inferência baseado em Takagi-Sugeno-Kang (TSK), essa inferência permite considerar as características difusas da nossa classificação.

Dos dois sistemas *fuzzy* mais utilizados na literatura, além do TSK, têm-se a inferência por Mamdani, que como já visto na secção **2.2.6.6.** necessita de um conjunto *fuzzy* como consequente, sendo necessário uma variável que separe as classes, para que se pudesse modelar por Mamdani seria necessário definir empiricamente três funções de pertinência adotando intervalos sem significado objetivo. Para contornar esses problemas decidiu-se utilizar o TSK, de modo a escolha da função de saída do sistema, tem um significado direto dentro do modelo, apresentando-se como um caminho mais natural. Este trabalho é o primeiro a modelar um sistema de classificação *fuzzy* baseado em TSK.

O sistema de inferência baseado em TSK foi modelado tomando como entrada a tabela contendo os descritores dos objetos encontrados numa amostra; extrai, portanto, da tabela cada coluna de características e salva num *array* diferente que chamamos X, Y e Z; sendo X a área, Y dimensão fractal e Z a excentricidade.

Para modelar os subconjuntos que representam as variáveis linguísticas, BAIXO, MÉDIA e ALTA, para cada X, Y e Z, utilizamos a técnica de clusterização de *Fuzzy C-Means*, para isto, usamos a função *fcm()* do MATLAB. Particionamos, portanto, cada variável em três clusters, onde cada cluster representando uma variável linguística.

A função retorna: os *arrays* contendo os centros de cada agrupamento, e uma matriz de pertinência para cada variável. Pode-se observar na tabela 2 um exemplo de uma matriz de pertinência para 4 elementos (coluna), e três clusters (linha) de uma variável. Veja que o elemento 1 tem uma pertinência de 0.86 no cluster 1, pertinência de 0 no cluster 2 e pertinência de 0.14 no cluster 3.

**Tabela 2:** Exemplo de uma matriz de pertinência para 4 elementos (El) e 3 clusters (Cl), cada linha representa um cluster e cada coluna o elemento, ou seja, a matriz dá a pertinência de cada elemento em cada agrupamento, veja por exemplo que a maior pertinência do elemento 4 é no agrupamento 3.

<sup>El</sup> / <sub>Cl</sub>	1	2	3	4
1	0,86	0,75	0	0.01
2	0	0.25	0,17	0
3	0.14	0	0,83	0,99

Fonte: Acervo pessoal.

Depois que os dados são *fuzificados*, eles são os dados de entrada no módulo de inferência, que contém a base de regras e a função objetiva que realiza o cálculo da saída do Sistema. A base de regras foi modelada considerando todas as 27 possíveis combinações entre as variáveis linguísticas. Na tabela 3 é mostrado a base de regras considerando a combinação entre as variáveis.

Foram consideradas como saída do sistema de inferência três funções constantes, que representam as três classes que se quer classificar, valor 1 para o poro, valor 2 para o EVA e o valor 3 para a fibra. Definindo, portanto, as constantes 1, 2 e 3 para cada uma respectivamente.

Como o EVA tem uma maior similaridade em relação ao seu formato e densidade com o poro colocamos um intervalo menor entre eles, de forma análoga, como a fibra tem uma diferença maior, escolheu-se uma constante com intervalo maior em relação ao poro.

Cada regra tem como saída uma dessas funções constantes, que de acordo com as variáveis linguísticas, valendo-se de uma base de conhecimento em relação aos materiais estudados pôde-se atribuir a cada uma, uma classe. Como já visto na secção **2.2.6.7.** o peso *w* de cada regra é calculado através da T-norma entre cada uma das variáveis, que nesse sistema *a priori*, foi utilizada a T-norma do mínimo e a saída como uma média ponderada de cada saída com seu respectivo peso. Computacionalmente isso é feito de forma discreta para cada objeto presente na amostra, toma-se, portanto, a matriz de pertinência de cada descritor de características e são calculados através do módulo de inferência a sua saída, e esse resultado é gravado num *array*. Na saída do sistema de inferência temos objetos em que o valor é

exatamente uma dessas três constantes e em outras algo dentro de um dos dois intervalos, [1, 2] ou [2, 3].

Regra	Área	Excentricidade Dimensão fr	
R1	Pequeno	Baixo	Baixo
R2	Pequeno	Baixo	Médio
R3	Pequeno	Baixo	Alto
R4	Pequeno	Médio	Baixo
R5	Pequeno	Médio	Médio
R6	Pequeno	Médio	Alto
R7	Pequeno	Alto	Baixo
R8	Pequeno	Alto	Médio
R9	Pequeno	Alto	Alto
R10	Médio	Baixo	Baixo
R11	Médio	Baixo	Médio
R12	Médio	Baixo	Alto
R13	Médio	Médio	Baixo
R14	Médio	Médio	Médio
R15	Médio	Médio	Alto
R16	Médio	Alto	Baixo
R17	Médio	Alto	Médio
R18	Médio	Alto	Alto
R19	Grande	Baixo	Baixo
R20	Grande	Baixo	Médio
R21	Grande	Baixo	Alto
R22	Grande	Médio	Baixo
R23	Grande	Médio	Médio
R24	Grande	Médio	Alto
R25	Grande	Alto	Baixo
R26	Grande	Alto	Médio
R27	Grande	Alto	Alto

**Tabela 3:** Base de Regras considerando a combinação entre as variáveis.

Fonte: Acervo pessoal.



Figura 27 - Funções de pertinência dos subconjuntos *fuzzy* BAIXO, MÉDIO e ALTO, das variáveis área, dimensão fractal e excentricidade em (a), (c) e (e) e seus respectivos alpha cortes de 0.28, 0.3 e 0.3 em (b), (d) e (f). Fonte: Acervo pessoal.

Para a tomada de decisão utilizou-se então uma função que atribui a classe final do objeto de acordo com a menor distancia a um dos clusters, ou seja, se um objeto qualquer obtiver da saída do sistema de inferência um valor de 1.4 lhe será atribuída a classe 1 pois está mais próximo da classe de poro que das demais.

Caso o valor esteja no valor médio de um intervalo o sistema retorna a classe com valor menor, ou seja, caso um objeto obtenha uma saída como 2.5 lhe seria atribuída a classe 2, isso porque a frequência de poro é maior que a de EVA que é maior que a de Fibra nas amostras, então é mais provável que o objeto observado pertença à classe menor.

Regra	Saída
R1	PORO
R2	EVA
R3	PORO
R4	PORO
R5	EVA
R6	PORO
R7	PORO
R8	PORO
R9	PORO
R10	PORO
R11	FIBRA
R12	FIBRA
R13	PORO
R14	FIBRA
R15	FIBRA
R16	PORO
R17	FIBRA
R18	PORO
R19	FIBRA
R20	EVA
R21	FIBRA
R22	FIBRA
R23	EVA
R24	FIBRA
R25	PORO
R26	EVA
R27	EVA

Tabela 4: Saídas da Base de Regras considerando a combinação entre as variáveis.

Fonte: Acervo pessoal.

Para refinar o sistema de modo que ele classifique melhor os objetos ainda foram realizados um alpha corte de modo que eliminasse a pertinência de certos objetos em certos subconjuntos, essa filtragem foi realizada com o valor de 0.28 para área e 0.3 para

excentricidade e dimensão fractal. Esses valores foram definidos analisando o comportamento do sistema para diferentes cortes, além da análise gráfica das funções de pertinência. Pode-se ver na figura 27 as funções de pertinência de cada uma das variáveis linguísticas, para Área, excentricidade e Dimensão fractal e seus respectivos alpha cortes.

Para cada combinação de regras foram modeladas saídas de acordo com a base de conhecimento em relação aos elementos a serem identificados, a *priori* foram definidas saídas para as respectivas regras como se vê na tabela 4.

Para a realização de testes foi considerado, além dessas combinações de regras, também um modelo mais simplificado que leva em conta apenas a Área e a Excentricidade, adotamos a mesma modelagem dos subconjuntos *fuzzy* e utilizamos a base de regras modelada por LOUREIRO (*et. al,* 2015), como se pode ver na tabela 5.

Regra	Áraa	Frantricidada	Saída	Saída
	Area	Excentricidade	Salua	adotada
<b>R</b> 1	Pequeno	Baixo	Poro	Poro
R2	Pequeno	Médio	Poro	Poro
R3	Pequeno	Alto	Poro/EVA	Poro
R4	Médio	Baixo	Poro	Poro
R5	Médio	Médio	EVA/Fibra	Fibra
<b>R6</b>	Médio	Alto	Fibra	Fibra
<b>R7</b>	Grande	Baixo	Poro/Fibra	Fibra
<b>R8</b>	Grande	Médio	EVA	EVA
R9	Grande	Alto	Fibra	Fibra

Tabela 5: Base de regras do modelo simplificado.

Fonte: Adaptado de (LOUREIRO, et. al, 2015).



Figura 28: Fluxograma do sistema de inferência baseado em TSK Fonte: Acervo pessoal.

Para que se pudesse realizar uma comparação mais adequada e também para adaptar a base de regras em nosso contexto, onde o autor utilizou Poro/EVA utilizamos Poro, ou seja na saída de nosso sistema foi utilizado a constante 1, e onde ele utilizou EVA/Fibra e Poro/Fibra adotou-se fibra, ou seja constante 3, o restante se segue da mesma forma que modelamos a outra base de regras.

A saída do sistema para cada objeto ainda nesse caso são valores entre 1 e 3, logo, caso o sistema retorne como resultado um valor mais próximo de 1.5 então pode-se entender que ele classifica como Poro/EVA, já que está no valor médio entre as duas funções. Portanto, não sendo necessário outras constantes para representar essas classes intermediárias. O fluxograma da figura 28 o resume o funcionamento do sistema de inferência.

## 3.6. VALIDAÇÃO DA CLASSIFICAÇÃO

Com objetivo de validar as bases de regras e o sistema de inferência, foram elaboradas imagens de controle, selecionando manualmente das imagens originais, regiões que compreendem poros, EVA e fibra. Após identificadas, de cada região foram extraídos os descritores de área, excentricidade e dimensão fractal, e por fim, classificados utilizando o sistema de inferência. Na figura 29 pode-se observar um exemplo de uma amostra de 1EG15 utilizada para criar uma imagem segmentada de controle, na figura 29 (a) temos a imagem original, na figura 29 (b) a segmentação manual, e na figura 29 (c) a saída do sistema para alguns dos elementos.



Figura 29: Exemplo de imagem de controle com 7 objetos para validação do sistema. Imagem original de 1EG15 em (a). Imagem Segmentada manualmente para definir os objetos de interesse (b). Classificação pelo sistema de inferência para alguns elementos (c).
Fonte: Acervo pessoal.

# 4. RESULTADOS

Neste trabalho foi desenvolvida uma metodologia para a segmentação automatizada, extração de características e classificação dos componentes de concretos leves com EVA e reforçados com fibra de piaçava, para sua caracterização.

Assim a partir da metodologia adotada foram obtidos, por exemplo, o percentual de agregados graúdos e agregados leves em conjunto com os poros de todas as amostras. Podemos observar nas figuras 30 e 31 o percentual encontrado para cada fatia em cada caso.

A variação dos objetos encontrados assim como a variação da porosidade em cada uma das amostras é elevada, essa variação é natural em amostras de micro tomografia de raios X de concreto. Esses valores dependem também da resolução da varredura do micro tomógrafo que afeta consideravelmente o percentual de porosidade encontrado como foi sinalizado em (DU PLESSIS et al., 2016).

Se observa em relação ao percentual de objetos em cada fatia, que para o CR esses valores ficam em torno dos 5% de objetos. Já nas amostras com maior presença de EVA e fibra, proporcionalmente, esses valores são maiores como é o caso do 1EF15 onde esses valores ficam entre 20% e 25% de objetos encontrados.

Isso se deve tanto a uma quantidade maior de EVA e fibra na amostra, que tem como consequência um maior percentual de objetos na segmentação, como também um percentual maior de porosidade devido um maior percentual de agregados leves na mistura (GARLET, 1998).

Se observa também, através da figura 30, que nas amostras que contém EVA ou EVA e fibra, se tem uma variação mais abrupta em algumas faixas da segmentação, em alguns intervalos de fatias, isso se deve ao fato de que esses objetos não se distribuem de forma tão homogênea na amostra, como é o caso do EG15 que na faixa das fatias 500 a 1000 chega a valores entre 10% e 15% de objetos encontrados e na faixa das fatias entre 1500 e 1750 chega a valores entre 17% e 28% de objetos encontrados.



Figura 30: Percentual de objetos encontrados em cada fatia na segmentação do Poro, EVA e Fibra da amostra.

Fonte: Acervo pessoal.



Figura 31: Percentual de objetos encontrados em cada fatia na segmentação do agregado graúdo da amostra. Fonte: Acervo pessoal.

Em relação ao agregado graúdo de modo geral, como é mostrado na figura 31, ocupa o maior espaço nas amostras, a depender da posição da pedra e de sua geometria podemos obter uma secção transversal de pedra que ocupa uma área menor numa fatia, como é o caso do EF5 que entre as primeiras 500 fatias chegam a apresentar menos de 20%, e em seguida uma secção que ocupa uma área consideravelmente maior, chegando a mais de 90% entre as fatias 1500 e 2000.

Pode-se observar a natureza desta variação abrupta de agregado graúdo em torno das amostras, como consequência da heterogeneidade do concreto, isto pode ser também compreendido através da análise visual das imagens das amostras, que para um intervalo pequeno de fatias apresenta uma configuração completamente diferente quanto posição e quantidade de pedra. Na figura 32 tem-se um exemplo de duas fatias do 1EF05 com uma diferença de 100 fatias entre elas.



Figura 32: Variação abrupta da pedra no concreto para um intervalo de 100 fatias no 1EF05 Fonte: Acervo pessoal.

O percentual representativo de objetos encontrados considerado, foi a média dos valores da distribuição em torno de cada amostra, podemos observar nas figuras 33 e 34 esses valores para a segmentação que compreende o Poro, EVA e fibra, e o Agregado graúdo, esses valores médios também estão discriminados nas tabelas 6 e 7 respectivamente.



Figura 33: Histograma dos valores percentuais do total de objetos encontrados em cada uma das amostras, Poros, EVA ou Fibras. Fonte: Acervo pessoal.



Figura 34: Histograma dos valores percentuais médios de agregado graúdo encontrados em cada uma das amostras. Fonte: Acervo pessoal.

Na tabela 6 o percentual médio dos agregados leves e poros da amostra obtido foi de 5,41% para o CR, 8,17% para o EF5, 15,58% para o EF15, 23,35% para o EF25, 17,86% para o EG15, 4,07% para o 1EF05, 22,86% para o 1EF15, 22,42% para o 1EF25 e por fim 14,86% para o 1EG15.

Tabela 6: Valores percentuais da quantidade de objetos encontrados, na amostra.

Objetos	CR	EF5	EF15	EF25	EG15	1EF05	1EF15	1EF25	1EG15
encontrados									
(%)	5.41	8.17	15.58	23.35	17.86	4.07	22.86	22.42	14.83

Fonte: Acervo pessoal.

No caso dos agregados graúdos pode-se observar na tabela 7 que o percentual médio foi de 45,18% para o CR, 52,95 para o EF5, 44,19% para o EF15, 42,49% para o EF25, 54,79% para o EG15, 55,51% para o 1EF05, 49,31% para o 1EF15, 38,69% para o 1EF25 e por fim 54,74% para o 1EG15.

Tabela 7: Valores percentuais de Agregado graúdo encontrado, na amostra.

Pedra	CR	EF5	EF15	EF25	EG15	1EF05	1EF15	1EF25	1EG15
encontrada									
(%)	45.18	52.95	44.19	42.49	54.79	55.51	49.31	38.69	54.74

Fonte: Acervo pessoal.
Após obter um valor representativo dos objetos encontrados, através dos traços dos concretos utilizados para montar os corpos de prova descritos em Dias (2017), foi possível calcular o volume relativo de agregado graúdo, agregados leves de EVA e de fibras de piaçava em cada uma das amostras.

Por meio dos valores estimados do EVA e fibra em cada testemunho, realizou-se a aproximação dos valores de porosidade. Pode-se observar, na tabela 8 o resultado desta análise. Em relação ao CR, por não haver adição de EVA nem fibra, a porcentagem de objetos encontrados corresponde a nossa porosidade estimada, em relação as outras amostras descontou-se o porcentual de EVA e Fibra para que restassem apenas os vazios, não se considerou assim a porosidade relativa aos agregados.

Na tabela 8 pode-se observar que a porosidade para cada amostra foi de 5,41% para o CR; 5,95% para o EF5; 8,98% para o EF15; 12,31% para o EF25; 11,21% para o EG15; 0,86% para o 1EF05; 15,28% para o 1EF15; 10,39% para o 1EF25 e por fim 7,20% para o 1EG15. Todos estes valores encontram-se no intervalo de porosidade encontrado na literatura para este tipo de material.

Amostra	Percentual	EVA	Fibra	Porosidade estimada
CR	5,41	-	-	5,41
EF5	8,17	2,223611	-	5,95
EF15	15,58	6,596712	-	8,98
EF25	23,35	11,04393	-	12,31
EG15	17,86	6,651902	-	11,21
1EF05	4,07	2,223611	0,98	0,86
1EF15	22,86	6,596712	0,98	15,28
1EF25	22,42	11,04393	0,98	10,39
1EG15	14,83	6,651902	0,98	7,20

**Tabela 8:** Valores referentes aos percentuais de cada objeto presente em cada corpo de prova e do valor estimado da porosidade.

Fonte: Acervo pessoal.

No caso do CR onde a porosidade estimada obtida foi de 5,41% de porosidade, Kim et al. (2012) e Lu et. al. (2017) obtiveram valores de ar contido em uma amostra de concreto

comum entre 2,5% e 6,2%, realizando ensaios de MicroCT e utilizando-se de técnicas de PDI. Já para concretos leves por adição de agregados leves estes autores encontraram valores entre 4% e 15,28%, de forma comparativa Chung (et al., 2020) encontra valores entre 4.28% e 15.46% para suas amostras em seus estudos, sendo que o maior valor aferido se referia a um concreto com ar incorporado. Neste trabalho, a amostra com maior índice de vazios aparente foi a EG15, que apresentou valor de 15,28% (tabela 8). valor de porosidade dentro da faixa esperada na literatura.

Utilizando o mesmo traço Dias (2017) calculou o índice de vazios através da técnica de absorção de água encontrando um percentual de 11,61% para o CR, 13,26 para o EF5 e 18,14 para o EF25. Por sua vez Nascimento (2019) utilizando a técnica de posimetra por intrusão de mercúrio encontrou um percentual de 1,51% para o CR, 4,21% para o EF5 e 16,45% para o EF25. Neste trabalho os valores encontrados através da MicroCT apresentaram valores entre os valores de absorção de água e intrusão de mercúrio, sendo eles 5,41% para o CR, 5,95% para o EF5 e 12,31% para o EF25.

Em relação ao tamanho dos poros, foi utilizado o diâmetro equivalente dos objetos encontrados na segmentação, considerando que o CR deve conter apenas poros, pôde-se analisar a frequência dos poros em relação ao seu tamanho. Se obtiveram poros na amostra do concreto de referência com dimensões de até 2689.164  $\mu$ m. Contando a quantidade de objetos na faixa entre 0 e 300  $\mu$ m viu-se que ela representa 98,99% dos poros presentes na amostra. Du Plessis (et al., 2016) explica que a tendência geral é que os vazios menores sejam mais abundantes, e que à medida que a resolução do micro tomografia aumenta os vazios ainda menores se apresentam como mais frequentes. Explica também que quanto maior a escala, o maior vazio detectável fica menor. Na figura 35 pode-se observar o histograma do diâmetro dos poros no CR onde podemos ver essa tendência, onde grande parte dos poros estão na faixa de 0 a 100  $\mu$ m.



Figura 35: Histograma do diâmetro dos Poros do CR em Micrômetros (μm). Fonte: Acervo pessoal.

Comparando os valores esperados de agregado graúdo nas amostras através do traço do concreto, e os valores calculados através das técnicas de processamento de imagens, pode-se observar na figura 36, o histograma dos valores estimados do agregado graúdo na amostra, onde os pontos ligados em vermelho que representam os valores estimados a partir do traço.

Esses valores estão discriminados também na tabela 9 onde se observa do encontrado em relação ao estimado respectivamente 45.18% e 44.16% para o CR, 52.95% e 41.95% para o EF5, 44.19% e 37.55% para o EF15, 42.49% e 33.12% para o EF25, 54.79% e 37.53 para o EG15, 55.51% e 41.54% para o 1EF05, 49.51% e 37.18% para o 1EF15, 38.69% e 32.80% para o 1EF25 e 54.74% e 37.16% para o 1EG15.



Figura 36: Histograma do percentual médio de agregados graúdos encontrados em cada amostra, e o valor estimado através dos dados experimentais de cada traço. Fonte: Acervo pessoal.

	CR	EF5	EF15	EF25	EG15	1EF05	1EF15	1EF25	1EG15
Encontrado (%)	45,18	52,95	44,19	42,49	54,79	55,51	49,31	38,69	54,74
Estimado do traço (%)	44,16	41,95	37,55	33,12	37,53	41,54	37,18	32,80	37,16

**Tabela 9:** Percentual de pedra encontrada através da microCT e estimada através do traço

Fonte: Acervo pessoal.

Como o percentual de EVA é calculado em substituição ao agregado graúdo (DIAS, 2017), através da figura 36 e da tabela 9, comparando as amostras de EF5, EF15 e EF25, notase como esperado, que o percentual de pedra encontrado através do processamento é menor para as amostras com maior adição de EVA, o mesmo ocorre com as amostras 1EF5, 1EF15 e 1EF25. Considerando que o concreto é um material heterogêneo, os valores encontrados são coerentes com os valores experimentais.

Como afirma Garlet (1998), o aumento do teor de EVA na mistura de concreto é proporcional ao aumento das propriedades de porosidade, absorção de água e permeabilidade, portanto, como era esperado com a adição do agregado leve, o valor da porosidade nas amostras aumenta, sendo esse aumento um pouco maior na amostra com o EVA grosso.

É possível também, observar uma queda no valor da porosidade das amostras que contém adição da Fibra de piaçava. De acordo com Bentur & Mindess (2006) a fibra vegetal, quando adicionada à pasta de concreto absorve água, causando uma redução da porosidade.

Após analisar a porosidade e percentual estimado de agregado graúdo nas amostras de concreto, foram realizadas as rotinas de classificação dos elementos internos utilizando o sistema *fuzzy* a fim de agrupá-los nas classes, poro, EVA ou Fibra, e fazer uma análise mais detalhada da estrutura interna das amostras.

Inicialmente foram realizados testes com a base de nove regras (tabela 5) que utiliza as variáveis, área e excentricidade. Aplicando esta base de regras ao concreto de referência 99% dos objetos foi classificado corretamente como poros (considerando que nesta amostra só continha poros) o sistema classificou incorretamente apenas 1% da classe 1 (poro) esses objetos são considerados falsos negativos.

Nesta figura 37 pode-se observar o comportamento da classificação usando a base de regras menor para o CR. No eixo X temos o índice do objeto e no eixo Y temos a saída do sistema, que é um valor real entre 0 e 3. As linhas horizontais representam as constantes que são os centros das classes, Poro, Eva e Fibra, indicadas por cores diferentes. Foi atribuído a cada elemento à classe de maior proximidade, sendo que em caso de valor médio, 1.5 e 2.5, foi atribuído à classe logo abaixo,1 ou 2 respectivamente (secção **3.5.).** 



Figura 37: Variação dos valores da classificação dos elementos internos do CR usando nove regras (tabela 5) para 600 elementos. As linhas horizontais representam as classes, Poro, EVA e Fibra, o objeto é classificado à classe de maior proximidade. Fonte: Acervo pessoal.

Também foram realizados testes com a base de vinte sete regras mostrada na tabela 3 usando as variáveis, área, excentricidade e dimensão fractal. A rotina retornou em torno de 70% de objetos classificados como poro. Na figura 38 é mostrado os valores percentuais da classificação de cada objeto detectado no CR utilizando as 27 regras, definido na tabela 3.



Figura 38: Variação dos valores da classificação de cada elemento interno do CR usando vinte e sete regras para 600 elementos. As linhas horizontais representam as classes, Poro, EVA e Fibra, o objeto é classificado à classe de maior proximidade.
Fonte: Acervo pessoal.

Em relação a uma base de regras maior, e melhor refinado, espera-se um maior falso positivo nesse tipo de teste com o CR, uma vez que temos subconjuntos modelando as variáveis linguísticas, Baixo, Médio e Alto para um conjunto de dados que contém apenas poros, incorre que as diferenças das grandezas de forma relativa a um conjunto de dados completo, ou seja, que contenha EVA e fibra, aquele objeto considerado alto por exemplo nos dados do CR seria considerado médio ou baixo nos dados com todos os elementos.

Assim após essa análise preliminar as rotinas foram executadas para todas as amostras, incluindo as imagens de controle desenvolvidas para validação do algoritmo, utilizando as duas bases de regras com o mesmo alpha corte, expoente de fuzzificação e T-norma do Mínimo.

A classificação nos retorna uma matriz indicando a classe de cada elemento, de modo que a soma das áreas dos objetos para cada classe, associado com a área total da amostra em cada fatia nos retorna uma distribuição do percentual de objetos de cada classe em cada amostra. Tomando a média dos valores é possível comparar com os valores estimados do traço como se pode ver nos quadros 7 e 8.

No caso das imagens de controle tem-se resultados satisfatórios para a base maior classificando corretamente todos os objetos, já em relação a base menor, apresentou problemas para diferenciar o poro da fibra de piaçava, obtendo em torno de 70% de verdadeiro positivo na classificação.

É importante pontuar que na análise preliminar utilizando o CR observamos que a base de regras menor, em contraste com a base maior, classificou a maior parte dos objetos como poros, contudo, considerando a área dos objetos observa-se que para ambas as bases de regras para o CR o sistema tem um resultado semelhante, classificando muitos poros como fibra ou EVA (quadro 7 e 8).

De um sistema com maior base de regras, que defina melhor as características que separam os elementos de agregado leve em relação ao poro na pasta de concreto, espera-se um melhor desempenho utilizando uma base completa, ou seja que contenha os três objetos, uma base menor por não conseguir expressar a sutil diferença entre os elementos tem a tendência de classificar as fibras como poros (quadro 7).

Como o CR contém apenas vazios é natural que para ambas as bases ocorram maiores erros de classificação, mesmo que a diferença absoluta do percentual da classificação em relação à referência seja menor para a base menor (figura 39).

Dito isto, foram obtidos para a classificação com a base de regras menor, em relação à porosidade: 3,01% para o CR; 3,82% para o EF5; 6,75% para o EF15; 10,47% para o EF25; 5,33% para o EG15; 1,82% para o 1EF05; 12,96% para o 1EF15; 9,58% para o 1EF25 e por fim 4,47\% para o 1EG15. Em relação ao percentual de EVA e fibra respectivamente: 1,50% e 0,88% para o CR; 2,67% e 1,66% para o EF5; 4,44% e 3,80% para o EF15; 5,75% e 6,25% para o EF25; 4,05% e 4,96% para o EG15; 1,41% e 0,81% para o 1EF05; 4,13% e 6,28% para o 1EF15; 5,42% e 6,56% para o 1EF25 e por fim 3,29% e 4,65% para o 1EG15. (quadro 7).

Resultados para a base com nove regras								
	Estimado do traço							
	Poro	EVA	Fibra	Poro	EVA	Fibra		
EF5 (%)	3,823207	2,673707	1,6671	5,95	2,223611	0		
EF15 (%)	6,749551	4,443118	3,805947	8,98	6,596712	0		
EF25 (%)	10,47031	5,755132	6,25226	12,31	11,04393	0		
EG15(%)	5,33456	4,053415	4,962518	11,21	6,6519	0		
<b>CR</b> (%)	3,015995	1,506377	0,880801	5,41	0	0		
1EF5 (%)	1,821092	1,412843	0,813889	0,86	2,223611	0,98		
1EF15 (%)	12,96142	4,137625	6,281604	15,28	6,596712	0,98		
1EF25 (%)	9,58478	5,428093	6,560637	10,39	11,04393	0,98		
1EG15 (%)	4,472421	3,29738	4,654578	7,20	6,651902	0,98		

**Quadro 7:** Resultados para a classificação com a base de nove regras. Porcentagem de cada objeto identificada em cada amostra em comparação com os valores estimados experimentalmente a partir do traço.

Fonte: Acervo pessoal.

Utilizando a base de regras maior mostrada em **3.5.** se obteve uma porosidade de 2,63% para o CR; 5,71% para o EF5; 7,83% para o EF15; 10,57% para o EF25; 7,13% para o EG15; 1,34% para o 1EF05; 16,54% para o 1EF15; 12,56% para o 1EF25 e por fim 6,00% para o 1EG15. Em relação ao percentual de EVA e fibra respectivamente, 1,76% e 0,13% para o CR; 5,71% e 0,52% para o EF5; 3,12% e 0,54% para o EF15; 7,72% e 2,54% para o EF25; 2,78% e 1,11% para o EG15; 0,98% e 0,20% para o 1EF05; 6,84% e 0,15% para o 1EF15; 7,73% e 1,67% para o 1EF25 e por fim 4,75% e 1,03% para o 1EG15. Esse resultado está resumido no quadro 8.

Resultados para a base com vinte e sete regras								
Classific	Estimado do traço							
	Poro	EVA	Fibra	Poro	EVA	Fibra		
EF5 (%)	5,712491	3,128145	0,524227	5,95	2,223611	0		
EF15 (%)	7,834397	5,543576	0,540344	8,98	6,596712	0		
EF25 (%)	10,57361	7,722711	2,549984	12,31	11,04393	0		
EG15 (%)	7,13577	2,78657	1,114383	11,21	6,6519	0		
<b>CR</b> (%)	2,637147	1,764187	0,134244	5,41	0	0		
1EF5 (%)	1,348422	0,977085	0,202777	0,86	2,223611	0,98		
1EF15 (%)	16,54043	6,841975	0,157497	15,28	6,596712	0,98		
1EF25 (%)	12,56818	7,379641	1,678072	10,39	11,04393	0,98		
1EG15 (%)	6,002894	4,755323	1,038617	7,20	6,651902	0,98		

**Quadro 8:** Resultados para a base com vinte e sete regras. Porcentagem de cada objeto identificada em cada amostra em comparação com os valores estimados experimentalmente a partir do traço.

Fonte: Acervo pessoal.

A base de regras menor obtém resultados para os percentuais de EVA e fibra que somados representam valores próximos aos valores estimados, já a base de regras maior em relação ao EVA e fibra de acordo com os dados, tendem a diminuir o erro das duas classes, de modo a classificar melhor esses dois objetos, principalmente nas amostras que contém uma maior quantidade de cada classe.

A diferença média absoluta entre o esperado e o percentual de elementos, em relação à porosidade, da classificação, diminui de 2,36% utilizando a base menor para 1,96% utilizando a base maior; em relação ao EVA, diminui de 2,69% para 2,28%, e em relação à fibra de 3,58% para 0,80%. Na figura 39 tem-se o percentual estimado a partir do traço para cada classe em cinza, e os valores da classificação com 27 regras em azul, bem como os valores da classificação com 9 regras em laranja, observa-se que a classificação com maior base de regras se aproxima melhor dos valores estimados do traço.



Figura 39: Comparativo entre os percentuais médios encontrados nas amostras utilizando o classificador com 27 regras, 9 regras e a estimativa através do traço para cada objeto. Fonte: Acervo pessoal.

A maior acurácia do sistema é alcançada nas amostras que contenham todos os elementos procurados pelo sistema e quanto maior a representatividade dos elementos na amostra a diferença absoluta entre o esperado e classificado diminui, isso pode ser concluído facilmente a partir da natureza intrínseca de um algoritmo de clusterização.

Foram realizados testes com outras duas T-normas utilizando as bases de regras. A Tnorma do produto apresentou resultados semelhantes às da T-norma do mínimo, não apresentando diferenças relevantes. A T-norma de Lukasiewicz apresentou resultados insatisfatórios, havendo um aumento no percentual da classe de EVA, e diferindo muito do percentual esperado através do traço. Alguns testes realizados no expoente de fuzzificação não apresentaram melhora do sistema dentro dessa modelagem.

## 5. CONCLUSÃO

Neste trabalho foram utilizadas amostras de concreto de referência sem adição de agregados, assim como concretos leves obtidos através da substituição de um percentual de agregado graúdo por EVA e reforçados com fibra de piaçava. A classificação dos elementos das amostras permitiu determinar, usando esse ensaio não destrutivo, a estrutura interna de cada amostra estimando as quantidades de cada objeto presentes nas amostras. Dados como a porosidade e percentual de pedra também foram determinados através desta metodologia.

Os elementos incialmente foram segmentados utilizando o algoritmo K-Means para separar o agregado graúdo do concreto do resto da pasta de cimento que contém os outros agregados. Os valores estimados de agregado graúdo para cada amostra foram comparados com os valores estimados deste elemento usando os valores experimentais de construção dos corpos de prova, obtendo para a amostra com menor diferença 1% de variação, e a amostra com maior diferença 17,58% de variação. Para essas amostras foi observado em relação ao percentual de pedra encontrado, através da metodologia proposta, que os valores representam bem o percentual real das amostras.

Utilizando uma técnica modificada de Otsu, os agregados leves e os vazios também foram segmentados de forma automática, de modo que foi possível estimar o valor da porosidade das amostras. Comparando os valores encontrados com os valores da literatura se observa que esses se encontram dentro da faixa esperada, obtendo para o concreto de referência 5.54% onde Kim et al. (2012) e Lu et. al. (2017) encontram valores na faixa de 2,5% e 6,2%, para o mesmo material utilizando microCT, e para o concreto leve se obtiveram valores entre 4% e 15,28% onde na literatura os valores estão entre 4.28% e 15.46% Chung (et al., 2020).

Comparando os valores de índice de vazios por absorção de água encontrados em Dias (2017), os valores utilizando a técnica de porosimetria por intrusão de mercúrio encontrados em Nascimento (2019) e os valores encontrados por esta pesquisa para as amostras de CR, EF5 e EF25 tem-se que os valores de microCT encontram-se entre os outros dois valores. Isto posto, a metodologia utilizada para determinação do percentual de porosidade apresentou resultados satisfatórios.

Após a determinação da área de interesse na etapa de segmentação e realizadas as analises supracitadas, foi realizado a extração de características de área, excentricidade e dimensão fractal de cada região e modelados os subconjuntos *fuzzy* que representam as variáveis linguísticas. Foi desenvolvido o um sistema especialista *fuzzy* baseado em TSK com o objetivo de realizar a classificação dos elementos internos das amostras, primeiro sistema baseado em TSK para classificação, utilizando duas bases de regras. A base de regras menor, 9 regras, foi modelada utilizando as variáveis de área e excentricidade, enquanto que a base de regras maior, 27 regras, utiliza em adição a dimensão fractal em sua análise.

Para realizar o teste do sistema com ambas as bases de regras, foram desenvolvidas imagens de controle a partir das imagens originais, separando e rotulando manualmente regiões que representassem cada objeto, a base de regras maior classificou corretamente todos os objetos, tendo a base menor um percentual menor de acerto em sua classificação.

Em seguida o sistema foi testado para todas as amostras de modo que a base de regras maior apresentou valores percentuais dos objetos, próximos aos valores estimados através do traço, principalmente para as amostras que continham uma representação maior de cada um dos objetos. O sistema com a base de regras maior conseguiu realizar uma melhor diferenciação dos poros e fibra, poro e EVA utilizando esses descritores regionais, apresentando, portanto, bons resultados em sua classificação.

Através dos estudos realizados e dos resultados obtidos é possível observar a maleabilidade do sistema, de modo que é possível ajusta-lo através dos parâmetros a fim de melhorar a classificação. Outrossim, o uso de imagens de microCT e sistema *fuzzy* podem ser utilizados para caracterizar amostras de concreto com agregados leves em EVA e fibras de piaçava. Considerando o caráter abrangente desta metodologia, ela poderá ser aplicada a outras amostras de misturas de concreto e outros materiais, modificando a base de regras e adaptando às características de cada material.

Para trabalhos futuros sugere-se implementar a base de regras considerando outros descritores, como descritores de cor ou textura, realizar alguns testes variando as constantes de saída do sistema, que tem por interpretação aumentar ou diminuir a distância entre as classes, compreendendo-os mais semelhantes ou menos semelhantes. Pode-se realizar também uma classificação hierárquica dois a dois entre os elementos.

## REFERÊNCIAS

AQUINO, R.C.M.P; D'ALMEIDA, J.R.M.; MONTEIRO, S.N. **Desenvolvimento de compósitos de matriz polimérica e piaçava, como substituto de produtos de madeira**. Vértices, v.4, n.1, p.42- 47, 2002.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). NBR 5738: Concreto Procedimento para moldagem e cura de corpos de prova. Rio de Janeiro, 2015b.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NM35 - Agregados leves para concreto estrutural, especificações. Rio de janeiro, 1995.

BABUŠKA, R. Fuzzy Systems, Modeling and Identification. 2001

BACKES, A. R. Estudos de métodos de análise de complexidade em imagens. Universidade de São Paulo, 2010.

BARROS, L.C. **Sobre sistemas dinâmicos** *fuzzy*: teoria e aplicações. Tese de doutorado em Matemática Aplicada, Instituto de Matemática Estatística e Computação Científica. Universidade Estadual de Campinas, Campinas, SP. 103p, 1997.

BASSANEZI, R. C. **Tópicos de Lógica Fuzzy e Biomatemática**. Terceira edição, IMECC-Unicamp. ISBN: 85-87185-05-5, 2010.

BENTUR, A.; MINDESS, S. **Fibre reinforced cimentitious composites**. Spon Press, Segunda edição. p. 625, ISBN: 041525048X, 2006.

BEZDEK, J. C. **Pattern Recognition with Fuzzy Objective Function Algorithms**. Plenum Press, New York, 1981. Apud (Klir e Yuan, 1995).

BORJA, E.V. Efeito da adição da argila expandida e adições minerais na formulação de concretos estruturais leves autoadensáveis. Tese de doutorado, Universidade Federal do Rio Grande do Norte, Natal, 2011.

BURGER, W.; BURGE, M. J. Automatic Thresholding. In: **Principles of Digital Image Processing. Undergraduate Topics in Computer Science.** London: Springer, London, p. 5–50. 2013.

CARLANTONIO, L. M. Di. Novas metodologias para clusterização de dados. Dissertação (Mestrado)-Programa de Pós-Graduação em Engenharia, Universidade Federal do Rio de Janeiro, RJ, Brasil. 2001.

CARLIN, M. **Measuring the complexity of non-fractal shapes by a fractal method.** Pattern Recognition Letters, v. 21, n. 11, p. 1013–1017, 2000.

CHUNG, S. Y. et al. Comparison of the pore size distributions of concretes with different airentraining admixture dosages using 2D and 3D imaging approaches. **Materials Characterization**, v. 162, p. 110182, 1 abr. 2020.

CHUNG, S. Y. et al. Pore characteristics and their effects on the material properties of foamed concrete evaluated using micro-CT images and numerical approaches. Applied Sciences (Switzerland), v. 7, n. 6, 2017.

COELHO, R.C.; COSTA, 1 f. The box-Counting Fractal. Dimension: Does it provide an accurate Subsidy for Experimental Shape Characterization? If So, how to use It? Anais do Sibgrapi 95: P. 183-191, 1995.

CONSTANT, D. Fractal Matemático: O que é um Fractal? Disponível em: <a href="http://fractalmatematico.blogspot.com/2011/09/o-que-e-um-fractal.html">http://fractalmatematico.blogspot.com/2011/09/o-que-e-um-fractal.html</a>. Acesso em: 20 ago. 2020.

DE ANDRADE LIRA RABÊLO, R. et al. Uma abordagem baseada em sistemas de inferência fuzzy takagi-sugeno aplicada ao planejamento da operação de sistemas hidrotérmicos de geração. **Controle y Automacao**, v. 22, n. 1, p. 49–64, 2011.

DE OLIVEIRA PLOTZE, R. et al. Leaf shape analysis using the multiscale Minkowski fractal dimension, a new morphometric method: A study with Pass flora (Passifloraceae). **Canadian Journal of Botany**, v. 83, n. 3, p. 287–301, mar. 2005.

DIAS, Leonardo Alves. **CONCRETO INCORPORADO COM EVA E FIBRAS DE PIAÇAVA: uma alternativa sustentável na construção civil**. Dissertação de Mestrado. Programa de Pós-graduação em Ciência, Inovação e Modelagem de Materiais, Universidades Estadual de Santa Cruz, Ilhéus. 94p, 2017.

DOMINGUEZ, D. S.; ALMEIDA, H. C.; IGLESIAS, S. M.; LOPES, R. T.; ALVES, H. D. **Processamento de imagens microtomográficas de alta resolução na caracterização de amostras de argamassa leve**. Revista de Engenharia da Universidade Católica de Petrópolis, v. 11, n. 1, p. 13–21. ISSN 23180692. 2017

DU PLESSIS, A. et al. Simple and fast porosity analysis of concrete using X-ray computed tomography. Materials and Structures/Materiaux et Constructions, v. 49, n. 1–2, p. 553–562, 2016.

DU PLESSIS, Anton; BOSHOFF, William P. A review of X-ray computed tomography of concrete and asphalt construction materials. Construction And Building Materials, Stellenbosch, v. 199, p.637-651, fev. 2019

EUROLIGHTCON – Economic Design and Construction with Lightweight Aggregate Concrete. LWAC Materials Properties, State-of-the-art. Project BE96-3942/R2, Noruega, 1998.

FALCONER, K.J. Fractal geometry: mathematical and applications. new york, john wiley, 1990.

FINA, Rodrigo. Estudo de liberação das fases minerais em minérios de ferro. ISQN:10.13140, 2013.

GARLET, G. Aproveitamento de resíduos de E.V.A. (Ethylene Vinyl Acetate) como agregado para concreto leve na construção civil. Tese (Doutorado). Universidade Federal de Feira do Rio Grande do Sul, 1998.

GOMES, Paulo César Correia et al. **Obtenção de concreto leve utilizando agregados reciclados. Ambiente Construído**, v. 15, n. 3, p. 31-46, 2015.

GOMIDE, Fernando Antonio Campos; GUDWIN, Ricardo Ribeiro. **Modelagem, controle, sistemas e lógica** *fuzzy*. SBA controle & Automação, v. 4, n. 3, p. 97-115, 1994.

GONZALEZ, R., WOODS, P. Digital Image Processing. Prentice Hall, 2nd ed. 2002

GONZALEZ, RAFAEL C.; WOODS, R. E. Processamento digital de imagem. In: INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (Ed.). **Processamento digital de imagem**. Cambridge: Pearson Universidades; Edição: 3 (3 de dezembro de 2009), v. 10. 624p. 2009.

GREVEN, A.; GARLET, G. Concreto leve utilizando resíduos de eva da indústria calçadista. Encontro Nacional sobre Edificações e Comunidades Sustentáveis, v. 1, n. 1.997, p. 93–100, 1997.

GUIMARÃES, C. A. L.; SILVA, L. A. M. Piaçava da Bahia (Attalea funifera Martius): do extrativismo à cultura agrícola. Ilheus - BA: Editus. 262 p. ISBN 9788574552828. 2012

HER-YUNG, W. Durability of self-consolidating lightweight aggregate concrete using dredged silt. In: Construction and building materials, n.23, p.2332-2337, 2009.

HOLM, T. A.; BREMNER, T. W. State-of-the-art report on high-strength, high-durability structural low density concrete for applications in severe marine enviroNBRents. US Army Corps of Engineers – Engineer Research in Development Center, ERDC/SL TR00-3, 2000.

IGLESIAS, Susana Marrero; MENDONÇA, Rodrigo Silva; ORELLANA, Esbel Tomás Valero; DOMINGUEZ, Dany Sanchez. New approaches of three-dimensional image processing applied to the study of lightweight mortars with EVA aggregates and piassava fibres. International Journal of Applied Pattern Recognition, v. 5, n. 4, p. 305, 2018. DOI: 10.1504/ijapr.2018.097106.

ILDEFONSO, J. S. Análise da viabilidade técnica da utilização do copolímero etileno acetato de vinila (EVA) descartado pela indústria calçadista em misturas asfálticas (processo seco). Dissertação de Mestrado. Universidade de São Paulo, 2007.

ISAIA, G. C. *Materiais de Construção Civil e Princípios de Ciência e Engenharia de Materiais.* 3° ed. São Paulo, IBRACON, Vol. 1. 2017.

JAIN, A.K., MURTY, M.N., FLYNN, P.J. Data Clustering: A Review, ACM Computing Surveys, Vol. 31, No. 3, setembro. 1999.

JESUS, E. O.; COSTA, R. A Utilização de Filtros Gaussianos na Análise de Imagens Digitais A Curva de Gauss. Proceeding Series of the Brazilian Society of Applied and Computational Mathematics, Vol. 3, N. 1.Trabalho apresentado no XXXV CNMAC, Natal-RN, 2014. 2015.

LABBOOKPAGES. **Otsu Thresholding - The Lab Book Pages**. Disponível em: <<u>http://www.labbookpages.co.uk/software/imgProc/otsuThreshold.html></u>. Acesso em: 20 ago. 2020.

LIU, P. et al. Study on micro structure and composition distribution of concrete surface zone based on fractal theory and XCT technology. **Construction and Building Materials**, v. 263, p. 120209, 10 dez. 2020.

LOUREIRO, G. M.; IGLESIAS, S. M. ; PALMEIRA, E. S. ; DOMINGUEZ, D. S. . Caracterização de misturas de concretos leves usando tomografia computadorizada e algoritmo de clustering. Dissertação (Mestrado em modelagem computacional em ciência e tecnologia) – Universidade Estadual de Santa Cruz. Ilhéus. 2015.

MA, H.L.; Cui, C.; Li, X.; Hu, S.L. Study on mechanical properties of steel fiber reinforced autoclaved lightweight shell-aggregate concrete. Materials and Design, p.565-571, 2013.

MACEDO, M. et al. **Dimensão Fractal**. Disponível em: <<u>http://www.cbpf.br/~maysagm/></u>. Acesso em: 17 ago. 2020.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens,** Rio de Janeiro: Brasport, ISBN 8574520098. 1999.

MATLAB. **Convert indexed image to grayscale image - MATLAB ind2gray**. Disponível em: <a href="https://www.mathworks.com/help/images/ref/ind2gray.html#d120e169596">https://www.mathworks.com/help/images/ref/ind2gray.html#d120e169596</a>>. Acesso em: 26 jul. 2020a.

MATLAB. **Measure properties of image regions - MATLAB regionprops**. Disponível em: <a href="https://www.mathworks.com/help/images/ref/regionprops.html">https://www.mathworks.com/help/images/ref/regionprops.html</a>). Acesso em: 27 jul. 2020b.

MEHTA, P.; MONTEIRO, P. Concreto: Microestrutura, Propriedades e Materiais. IBRACON. ISBN 9788598576213. 2014.

MELO, A. B.; MENDONÇA, T. N. M. Blocos cimentícios com resíduos de eva para telhado verde extensivo modular: contribuição dos componentes no isolamento térmico. RIEM-IBRACON Structures and Materials Journal, v. 10, n. 1, 2016.

MENDES, Julia Castro. **Modelagem computacional de concreto leve utilizando o programa cast3m**. Monografia em Engenharia civil – UFJF, juiz de fora, pg 26. 2014.

MEZZOMO, Ivan; BEDREGAL, B. **Ordinal Sums of De Morgan Triples**. Tendências em Matemática Aplicada e Computacional, [S. l.], p. 181-196, 1 jan. 2018. DOI 10.5540. Disponível em: https://www.scielo.br/pdf/tema/v19n2/2179-8451-tema-19-02-181.pdf. Acesso em: 1 jun. 2020.

MILETIĆ, M. et al. Gradient-based fibre detection method on 3D micro-CT tomographic image for defining fibre orientation bias in ultra-high-performance concrete. **Cement and Concrete Research**, v. 129, p. 105962, 1 mar. 2020.

MORÉ, Jesús Domech. Aplicação da lógica *Fuzzy* na avaliação da confiabilidade humana nos ensaios não destrutivos por ultra-som. Tese de Doutorado. Tese de Doutorado submetida ao programa de pós-graduação de Engenharia Metalúrgica e dos Materiais da Universidade Federal do Rio de Janeiro, COPPE. 2004.

NASCIMENTO, flávia lopes de almeida. Análise da porosidade em concretos leves reforçados com fibras depiaçava utilizando técnicas de processamento de imagens em microtomografias de raios x. Dissertação de Mestrado. Programa de Pós-graduação em Ciência, Inovação e Modelagem de Materiais, Universidades Estadual de Santa Cruz, Ilhéus. 2019.

NEVILLE, A. M. **Tecnologia do concreto**. Segunda edição, Editora Bookman, ISBN: 8582600720, p. 466, 2013.

NGUYEN, H.T.- A note on the extension principle for *fuzzy* seis- Jour. Math. Analysis and Applications 64, 369-380. 1978.

NI, Yong. Natural fibre reinforced cement composites. 1995. Tese de doutorado. Victoria University of Technology, 1995.

OTSU, N. A threshold selection method from gray-level histograms. Automatica, 11(285-296), p. 23-27. 1975.

PETROU, MARIA MP; PETROU, C. Image processing: the fundamentals. John Wiley & Sons, v. 1, n. 2, p. 781, 2010.

PETTRES, Roberto; LACERDA, Luiz Alkimin. Técnica não destrutiva para diagnóstico de

**concreto a partir de termografia e redes neurais artificiais**. Journal of the Brazilian Neural Network Society, Vol. 10, Iss.1, p. 36-50, 2012.

PIECH, C. **K Means**. Disponível em: <a href="https://stanford.edu/~cpiech/cs221/handouts/kmeans.html">https://stanford.edu/~cpiech/cs221/handouts/kmeans.html</a>. Acesso em: 20 ago. 2020.

PIMENTEL, E. P., FRANÇA, V. F. De, OMAR, N. A identificação de grupos de aprendizes no ensino presencial utilizando técnicas de clusterização, Instituto Tecnológico da Aeronáutica (ITA), São José dos Campos, SP, Brasil, 2003.

PIMENTEL, L. L. **Durabilidade de argamassas modificadas por polímeros e reforçadas com fibras vegetais.** Tese de Doutorado — Universidade Estadual de Campinas,2004

POLIN, L. **Erosion and Dilation in Tensorflow**. Disponível em: <https://ai-pool.com/d/erosion-and-dilation-in-tensorflow>. Acesso em: 17 ago. 2020.

QUEIROZ, José Eustáquio Rangel de; Gomes, Herman Martins. Introdução ao Processamento Digital de Imagens. Universidade Federal do Rio grande do sul, RS, 2014

REIS NETO, J. M. d.; FIORI, A. P.; LOPES, A. P.; MARCHESE, C.; PINTO-COELHO, C. V.; VASCONCELLOS, E. M. G.; SILVA, G. F. da; SECCHI, R. A microtomografia computadorizada de raios x integrada à petrografia no estudo tridimensional de porosidade em rochas. Revista Brasileira de Geociências, v. 41, n. 3, p. 498–508, 2011.

RUSTUM, R. et al. Sustainability Ranking of Desalination Plants Using Mamdani Fuzzy Logic Inference Systems. Sustainability, v. 12, n. 2, p. 631, 15 jan. 2020.

SHROEDER, M. Fractals, Chaos, Power Laws - Minutes From an infinite Paradise. New York, W.H. Freeman and company, 1996.

SIDIQ, A. et al. High-efficiency techniques and micro-structural parameters to evaluate concrete self-healing using X-ray tomography and Mercury Intrusion Porosimetry: A reviewConstruction and Building MaterialsElsevier Ltd, , 20 ago. 2020.

SILVEIRA, G. P.; DE BARROS, L. C. Analysis of the dengue risk by means of a Takagi-Sugeno-style model. Fuzzy Sets and Systems, v. 277, p. 122–137, 15 out. 2015.

SOLTANI, A. et al. A new expert system based on fuzzy logic and image processing algorithms for early glaucoma diagnosis. Biomedical Signal Processing and Control, v. 40, p. 366–377, 1 fev. 2018.

SOUZA, Thiago Francisco de. **Avaliação da resistência de compósitos de argamassas leves de eva reforçadas com fibras de piaçava**. Dissertação de mestrado de Ciência, Inovação e Modelagem em Materiais - UESC. ILHÉUS - BA, p. 42. 2012.

SUGENO, M.; KANG, G. T. Structure identification of fuzzy model. **Fuzzy Sets and Systems**, v. 28, n. 1, p. 15–33, out. 1988.

TRICOT, C. Curves and Fractal Dimension. New York: Springer-Verlag. 1995.

XU, J. et al. Remote sensing image classification based on semi-supervised adaptive interval type-2 fuzzy c-means algorithm. **Computers and Geosciences**, v. 131, p. 132–143, 1 out. 2019.

XU, X. et al. Characteristic analysis of Otsu threshold and its applications. **Pattern Recognition Letters**, v. 32, n. 7, p. 956–961, 2011.

YANG, W. Finite element model of concrete material based on CT image processing

technology. Journal of Visual Communication and Image Representation, v. 64, p. 102631, 1 out. 2019.

YANG, Z. J. et al. 4D characterisation of damage and fracture mechanisms of ultra high performance fibre reinforced concrete by in-situ micro X-Ray computed tomography tests. **Cement and Concrete Composites**, v. 106, p. 103473, 1 fev. 2020.

YAZID, E.; GARRATT, M.; SANTOSO, F. Position control of a quadcopter drone using evolutionary algorithms-based self-tuning for first-order Takagi–Sugeno–Kang fuzzy logic autopilots. **Applied Soft Computing Journal**, v. 78, p. 373–392, 1 maio 2019.

ZADEH, L. Fuzzy Sets - Information and Control, vol.8, p 338-353, 1965.

ZATTERA, Ademir J. et al. Caracterização de resíduos de copolímeros de etileno-acetato de vinila - EVA. Polímeros, São Carlos, v. 15, n. 1, p. 73-78, Mar. 2005.

ZHANG, Linguang; RUSINKIEWICZ, Szymon. Learning to detect features in texture images. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. p. 6325-6333. 2018.

ZHU, L. et al. Comparative study on the meso-scale damage evolution of concrete under static and dynamic tensile loading using X-ray computed tomography and digital image analysis. **Construction and Building Materials**, v. 250, p. 118848, 30 jul. 2020.

## ANEXO I – Função de Segmentação da Pedra e determinação da área da amostra em cada fatia.

function [AreaCirculo] = SegmentacaoPedra(n,Diretorio,NomeSaida)

## %Faz a leitura das imagens que estão no diretório

#### for i = 1:n

## %Transforma cada valor de 'i' do laço em uma string

z = int2str(i);

## %cria a string com o caminho do arquivo 'i' de imagem

ArquivoEntrada = strcat(Diretorio,' (', z ,').bmp');

## %Lê a imagem 'i' e aplica um filtro gaussiano

imE = imread(ArquivoEntrada);

im = imgaussfilt(imE,2);

im=mat2gray(im);

## %Toma o limiar a partir do método de K-Means

[bw\_man, lvl] = KMthres(im,1,0.015);

## %Aplica as operações morfológicas

se=strel('disk',15);

bw2\_man = imclose(bw\_man, se);

se=strel('disk',10);

bw2\_man = imopen(bw2\_man, se);

bw2\_man = imfill(bw2\_man,'holes');

## %Determinando a area da amostra nessa fatia por Ranged constrain OTSU

- lvl = graythresh(im); imG = mat2gray(im);
- im2 = mat2gray(imG, [(1/255) (1 lvl)]);

```
lvl2 = graythresh(im2);
```

bw2 = im2bw(im, lvl2);

## % Área da amostra

[j, ~] = bwlabel(L);

P = regionprops(j,L,'Area');

PA = P(1).Area;

PArea = table(PA);

AreaCirculo(i,:) = PArea(:,:);

## **ANEXO II – Limiar por K-Means**

```
function [bw,level] = KMthres(IM,sw,corr)
```

if (nargin<1)

error('Falta a imagem.');

elseif (nargin==1)

sw=0;

elseif (sw~=0 && sw~=1)

error('sw tem que ser 0 ou 1.');

end

```
data = reshape(IM,[],1);
```

if sw==0

```
[~, center]=kmeans(data, 3,'distance', 'cityblock');
```

else

[~, center]=kmeans(data, 3);

end

```
[center, ~] = sort(center);
```

level = ((center(2) + center(3))/2) - corr;

bw = im2bw(IM,level);

# ANEXO III – Cálculo percentual de um objeto em relação à área total da amostra em cada fatia.

#### %Calcula o Percentual do objeto em relação a àrea da amostra

```
function [PCAvazios] = CalcArea(NomeEntrada,n,AreaCirculo)
```

```
for i = 1:n
```

```
z = int2str(i);
```

ArquivoEntrada = strcat(NomeEntrada,'(', z ,').csv');

Tabela\_dados = readtable(ArquivoEntrada);

temp = Tabela\_dados{:,2};

AreaCirculo{i,1};

AreaSeg = sum(temp);

PCAvazios(i) = (AreaSeg/AreaCir)\*100;

**PCAvazios** 

end

end

## ANEXO IV - Função de extração dos descritores

```
function [Tabela_dados] = RegionProps(n,NomeEntrada,NomeSaida)
```

for i = 1:n

z = int2str(i);

#### %Lê a imagem já passado a máscara.

ArquivoEntrada = strcat(NomeEntrada,'( ', z ,').bmp');

im = imread(ArquivoEntrada);

%inverte as cores

im\_c = imcomplement(im);

#### %Rotula as regiões segmentadas

[L, ~] = bwlabel(im\_c);

#### %Extrai as características de cada região

Prop = regionprops(L,im\_c,'all');

#### %Extrai a dimensão fractal de cada região

DimFract = DimFract(im);

#### %Extrai o a área e a excentricidade

for n=1:size(Prop,1)

Index(n) = n;

 $Prop\_Area(n) = Prop(n).Area;$ 

Prop\_Eccentricity(n) = Prop(n).Eccentricity;

end

Index = reshape(Index,[],1);

Prop\_Area = reshape(Prop\_Area,[],1);

Prop\_Eccentricity = reshape(Prop\_Eccentricity,[],1);

#### %coloca os dados em uma tabela

Data\_Table = table(Index,Prop\_Area,Prop\_Eccentricity, DimFract);

ArquivoSaida = strcat(NomeSaida,'(',z,').csv');

#### %Imprime a tabela

writetable(Data\_Table,ArquivoSaida);

#### %Retorna a tabela para consulta

Tabela\_dados = Data\_Table;

end

# ANEXO V – Função que separa cada objeto da imagem para o cálculo da dimensão fractal.

```
%Toma cada objeto da imagem e calcula a dimensão fractal
```

```
function [D] = DimFract(im)
im_c = imcomplement(im);
[L, Ne] = bwlabel(im_c);
[N, B]= size(im_c);
for i=1:Ne
  im_AUX = zeros(N, B);
  for j=1:N
     for k=1:B
      if L(j,k) == i
         \operatorname{im}_{AUX}(j,k) = 1;
      end
     end
  end
  D(i,1) = hausDim(im_AUX);
  Porc = (i/Ne)*100;
  Porc
end
end
```

## ANEXO VI – Função que calcula a dimensão fractal através do método de box count.

```
function [ D ] = hausDim( I )
```

```
% Retorna a dimensão fractal do objeto através do método de box count.
```

```
maxDim = max(size(I));
```

```
newDimSize = 2^ceil(log2(maxDim));
```

```
rowPad = newDimSize - size(I, 1);
```

colPad = newDimSize - size(I, 2);

I = padarray(I, [rowPad, colPad], 'post');

```
boxCounts = zeros(1, ceil(log2(maxDim)));
```

```
resolutions = zeros(1, ceil(log2(maxDim)));
```

boxSize = size(I, 1);

```
boxesPerDim = 1;
```

```
idx = 0;
```

```
while boxSize >= 1
```

```
boxCount = 0;
```

for boxRow = 1:boxesPerDim

```
for boxCol = 1:boxesPerDim
```

```
minRow = (boxRow - 1) * boxSize + 1;
```

maxRow = boxRow \* boxSize;

```
minCol = (boxCol - 1) * boxSize + 1;
```

maxCol = boxCol \* boxSize;

```
objFound = false;
for row = minRow:maxRow
for col = minCol:maxCol
if I(row, col)
boxCount = boxCount + 1;
objFound = true;
end;
```

```
if objFound
              break;
           end;
         end;
         if objFound
           break;
         end;
       end;
    end;
  end;
  idx = idx + 1;
  boxCounts(idx) = boxCount;
  resolutions(idx) = 1 / boxSize;
  boxesPerDim = boxesPerDim * 2;
  boxSize = boxSize / 2;
end;
```

D = polyfit(log(resolutions), log(boxCounts), 1);

D = D(1);

end

## ANEXO VII – Função Ranged constrain Otsu.

## %Binariza a imagem pelo método de Ranged Constrain Otsu

function [ImOriginal,ImBinarizada]= OtsuMelhorado(n,Diretorio,NomeSaida)

for i = 1:n

## %Transforma cada valor de 'i' do laço em uma string

z = int2str(i);

## %cria a string com o caminho do arquivo 'i' de imagem

ArquivoEntrada = strcat(Diretorio,' ( ', z ,').bmp');

%Lê a imagem 'i'

im = imread(ArquivoEntrada);

## %calcula pelo método de OTSU o primeiro limiar

lvl = graythresh(im);

## %Coloca a imagem de entrada original normalizada entre 0 e 1

imG = mat2gray(im);

## %Cria uma nova imagem a partir da imagem de entrada com niveis de cinza entre 1 e

## o primeiro limiar

```
im2 = mat2gray(imG, [(1/255) (1 - lvl)]);
```

## %calcula o segundo limiar através do método de otsu utilizando a nova imagem

lvl2 = graythresh(im2);

%binariza a imagem com o segundo limiar

bw2 = im2bw(im, lvl2);

## %dá o caminho para a saída da imagem

ArquivoSaida = strcat(NomeSaida ,'(', z,').bmp');

%salva a imagem binarizada com Otsu melhorado em formato bmp

```
imwrite(bw2, ArquivoSaida,'bmp');
```

ImOriginal = im;

ImBinarizada = bw2;

end