

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**MÉTODO DE PROCESSAMENTO DIGITAL DE
IMAGENS PARA INFERÊNCIA DA
QUALIDADE DE MATERIAIS PREPARADOS
COM FIBRAS VEGETAIS**

BRUNO SEIJI MIYAMOTO

ORIENTADOR: PROF. DR. PAULO E. CRUVINEL.

São Carlos - SP
Agosto/2013

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**MÉTODO DE PROCESSAMENTO DIGITAL DE
IMAGENS PARA INFERÊNCIA DA
QUALIDADE DE MATERIAIS PREPARADOS
COM FIBRAS VEGETAIS**

BRUNO SEIJI MIYAMOTO

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Processamento de imagens e Sinais.

Orientador: Dr. Paulo Estevão Cruvinel.

São Carlos – SP
Agosto/2013

**Ficha catalográfica elaborada pelo DePT da
Biblioteca Comunitária da UFSCar**

M685mp

Miyamoto, Bruno Seiji.

Método de processamento digital de imagens para inferência da qualidade de materiais preparados com fibras vegetais / Bruno Seiji Miyamoto. -- São Carlos : UFSCar, 2013.
83 f.

Dissertação (Mestrado) -- Universidade Federal de São Carlos, 2013.

1. Processamento de imagens. 2. Materiais - controle de qualidade. 3. Análise baseada em textura. 4. Método dos momentos (Estatística). I. Título.

CDD: 006.42 (20^a)

Universidade Federal de São Carlos

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

“Método de Processamento Digital de Imagens para Inferência da Qualidade de Materiais preparados com Fibras Vegetais”

Bruno Seiji Miyamoto

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação

Membros da Banca:



Prof. Dr. Paulo Estevão Cruvinel
(Orientador – Embrapa Instrumentação Agropecuária)



Prof. Dr. Marcio Merino Fernandes
(DC/UFSCar)



Prof. Dr. Mauricio Fernando Lima Pereira
(UFMT)

São Carlos
Agosto/2013

AGRADECIMENTOS

Primeiramente agradeço a Deus Parens por este corpo saudável o qual me foi concedido para exercer o livre arbítrio e completar mais essa fase em vida.

A minha família pelo apoio sempre que foi necessário, tanto financeiramente quanto psicologicamente.

Ao meu orientador por não ser um simples orientador e sim um amigo nos momentos mais difíceis desta etapa em minha vida.

Também agradeço ao professor Dr. Gil de Carvalho, do Instituto Politécnico da Universidade Estadual do Rio de Janeiro, pelas primeiras discussões realizadas no âmbito deste trabalho.

Aos meus amigos e colegas que sempre estiveram presentes nos estudos, tanto nos momentos alegres quanto tristes, me animando e dizendo que no final tudo ia dar certo.

Aos Professores que me deram nota baixa, pois isso me fortaleceu e tomei como incentivo para melhorar.

Aos Professores que me deram nota alta, por cobrarem nos testes e exames exatamente aquilo que haviam nos ensinado em sala de aula.

Aos Professores José Manoel Marconcini e Luiz Henrique Capparelli Mattoso, também ao Vitor Brait Carmona por todo apoio oferecido para a realização deste projeto.

A EMBRAPA Instrumentação Agropecuária de São Carlos pelo apoio a esse trabalho.

Por fim agradeço a todos que me ajudaram direta ou indiretamente com o apoio psicológico, torcendo pelo sucesso deste Mestrado.

"Nos mandamentos do samurai não estão incluídos os confucionistas, budistas, atores de kabuki, professores de etiqueta, os atores de teatro noh. No entanto, mesmo trilhando um caminho diferente, se aprofundarem os conhecimentos, é possível que chegue a compreendê-los. O importante é que o homem busque o aperfeiçoamento na sua área de atividade."

Musashi Miyamoto- O Livro dos Cinco Anéis - 1645

RESUMO

Este trabalho apresenta o desenvolvimento de um método baseado em processamento de imagem que viabiliza a verificação e análise da qualidade da mistura das fibras vegetais em amido termoplástico (TPS). Para a realização das análises foi implementado um módulo na linguagem de programação Python, capaz de realizar o cálculo dos momentos invariantes de Hu e cálculos estatísticos, para quantificar a homogeneidade, aplicado às imagens tomográficas de alta resolução dos materiais resultantes da mistura de amido termoplástico e das fibras. Composições TPS têm recebido recentemente muita atenção tanto do meio acadêmico como da indústria, como uma das opções mais econômicas para a produção de plásticos biodegradáveis. Embora promissor, o uso do TPS esbarra em duas limitações principais, sua fragilidade mecânica e elevada sensibilidade à água. Uma solução para este problema é a mistura do TPS com outros materiais fibrosos e de origem vegetal, mantendo dessa forma sua biodegradabilidade, e oferecendo maior resistência às intempéries. Atualmente existem métodos, técnicas e equipamentos utilizados para se determinar a resistência mecânica, a absorção de água e a cristalinidade de uma amostra de compósitos biodegradáveis, porém há uma carência de métodos utilizados especificamente para a medição da homogeneidade da distribuição das fibras vegetais em TPS, que possa auxiliar dessa forma, a verificação da qualidade da produção da amostra. Como resultado deste trabalho foi obtido um método que infere a qualidade do processo de fabricação de novos materiais biodegradáveis, produzidas a partir da mistura de fibras vegetais em TPS, tomando por base a homogeneidade e o grau de rugosidade das amostras produzidas.

Palavras chaves: processamento de imagens, qualidade de materiais, análise baseada em textura, momentos invariantes.

ABSTRACT

This Dissertation presents a method development based on image processing techniques, which enables the verification and quality analysis of organic fibers mixture in thermoplastic starch (TPS). In order to do this analysis, we implemented a Python programming language module, which is able to compute invariant moments of Hu and other statistical calculations to quantify homogeneity, we applied this calculations to a set of high resolution tomography images of materials resulting from the mixture of thermoplastic starch and fibers. TPS based compositions, have recently received much attention, from industry and academia, for being one of the most economical options to produce biodegradable plastics. Although promising, there are two major limitations to the use of TPS: their mechanical fragility and sensibility to water. A solution to this problem is to mix TPS with vegetable fibers materials, maintaining its biodegradability, thus offering greater mechanic and humidity resistance. Nowadays there are methods techniques and equipment used to check mechanical resistance, water absorption and crystallinity of biodegradable samples. However, there is a lack of methods used specifically for the measurement of organic fibers homogeneity distribution in TPS, therefore assisting the production quality verification of those samples. As a result of this work, we obtained a method which infers the manufacturing process quality of new biodegradable materials, produced from the mixture of vegetable fibers and TPS, based on the homogeneity and the roughness degree of the samples produced.

Keywords: Image processing, materials quality, texture based analysis, invariant moments.

LISTA DE FIGURAS

Figura 1 - Fotomicrografias obtidas por microscopia eletrônica de Varredura (MEV), superfície do amido granular (a), TPS com grãos desestruturados (b) (CARMONA, 2011).....	3
Figura 2 - Cálculo das matrizes de co-ocorrência para todas as direções com distância um.	12
Figura 3 - Diagrama de blocos do processo de análise.	20
Figura 4 - Fotos do Acuri - <i>Attalea phalerata</i> (a), Gravatá - <i>Bromelia balansae</i> Mez (b) e Carandá - <i>Copernicia australis</i> (c).	21
Figura 5 - Amostras de novos materiais. TPS 100% (a), Acuri 5% (b), Acuri 10% (c), Acuri 15% (d), Acuri 20% (e), Carandá 5% (f), Carandá 10%(g), Carandá 15%(h), Carandá 20% (i), Gravatá 5%(j), Gravatá 10%(k), Gravatá 15%(l), Gravatá 20%(m).....	22
Figura 6 - Fotomicrografias de MEV de TPS / Acuri 5% (a) (200X); TPS / Acuri 20% (b) (500x); TPS / Carandá 5% (c) (200x); TPS / Carandá 20%(d) (500x); TPS / Gravatá 5% (e) (200x) e TPS / Gravatá (f) (500x); (CARMONA, 2011).	23
Figura 7 - Imagem da tomografia da amostra TPS 100%, pseudo-cor (esquerda) e escala de cinza (direita)	24
Figura 8 - Imagem da tomografia da amostra Acuri 5% pseudo-cor (esquerda) e escala de cinza (direita)	25
Figura 9 - Imagem da tomografia da amostra Carandá 5% pseudo-cor (esquerda) e escala de cinza (direita)	25
Figura 10 - Imagem tomografia da amostra Gravatá 5% pseudo-cor (esquerda) e escala de cinza (direita)	25
Figura 11 - Comandos para abrir uma imagem.....	27
Figura 12 - Transformando uma imagem em uma matriz	28
Figura 13 - Função “normaliza”	29
Figura 14 - Matriz imagem após normalização.....	30
Figura 15 - Função que gera uma primitiva de imagem	31
Figura 16 - Momentos bidimensionais.....	31
Figura 17 - Momento central	32
Figura 18 - Momentos centrais normalizados.....	32

Figura 19 - Momentos invariantes de primeira a quarta ordem	33
Figura 20 - Momentos invariantes de quinta, sexta e sétima ordem	34
Figura 21 - Variância	35
Figura 22 - Desvio padrão	36
Figura 23 - Coeficiente de variação de Pearson	36
Figura 24 - Janela principal do sistema de análise de textura TeAS.....	37
Figura 25 - Diagrama de blocos II - Processo de análise realizado pelo TeAS.....	38
Figura 26 - Carregando uma imagem no TeAS.....	39
Figura 27 - Obtendo coordenadas de um pixel	40
Figura 28 - Selecionando a janela para análise	40
Figura 29 - Seleção do momento invariante.....	41
Figura 30 - Vetor de momentos invariantes das primitivas.....	41
Figura 31 - Cálculo da homogeneidade da imagem.....	42
Figura 32 - Imagens amostrais para o primeiro experimento, a) "Parede"; b) "Isopor"; c) "Tecido"; d) "Arte abstrata"; e) "Madeira"; f) "Grama"; g) "Mármore"; h) " Pedras"	44
Figura 33 - Imagens tomográficas da amostra de TPS utilizadas para análise.....	49
Figura 34 - Imagens tomográficas da amostra de Acurí 5% utilizadas para análise .	51
Figura 35 - Imagens tomográficas da amostra de Acurí 10% utilizadas para análise	53
Figura 36 - Imagens tomográficas da amostra de Acurí 15% utilizadas para análise	55
Figura 37 - tomográficas da amostra de Acurí 20% utilizadas para análise.....	57
Figura 38 - Imagens tomográficas da amostra de Carandá 5% utilizadas para análise	59
Figura 39 - Imagens tomográficas da amostra de Carandá 10% utilizadas para análise.....	61
Figura 40 - Imagens tomográficas da amostra de Carandá 15% utilizadas para análise.....	63
Figura 41 - Imagens tomográficas da amostra de Carandá 20% utilizadas para análise.....	65
Figura 42 - Imagens tomográficas da amostra de Gravatá 5% utilizadas para análise	67
Figura 43 - Imagens tomográficas da amostra de Gravatá 10% utilizadas para análise.....	69

Figura 44 - Imagens tomográficas da amostra de Gravatá 15% utilizadas para análise.....	71
Figura 45 - Imagens tomográficas da amostra de Gravatá 20% utilizadas para análise.....	73

LISTA DE TABELAS

Tabela 1 - Composições das amostras para análise.....	21
Tabela 2 - Resultado da análise de homogeneidade da imagem "Parede"	44
Tabela 3 - Resultado da análise de homogeneidade da imagem "Isopor"	45
Tabela 4 - Resultado da análise de homogeneidade da imagem "Tecido"	45
Tabela 5 - Resultado da análise de homogeneidade da imagem "Arte abstrata".....	45
Tabela 6 - Resultado da análise de homogeneidade da imagem "Madeira"	46
Tabela 7 – Resultado da análise de homogeneidade da imagem “Gramma”	46
Tabela 8 – Resultado da análise de homogeneidade da imagem "Mármore"	46
Tabela 9 - Resultado da análise de homogeneidade da imagem "Pedras".....	47
Tabela 10 - Resultado da análise da amostra de TPS.....	50
Tabela 11 - Resultado da análise da amostra com 5% de Acurí.....	52
Tabela 12 - Resultado da análise da amostra com 10% de Acurí.....	54
Tabela 13 - Resultado da análise da amostra com 15% de Acurí.....	56
Tabela 14 - Resultado da análise da amostra com 20% de Acurí.....	58
Tabela 15 - Resultado da análise da amostra com 5% de Carandá	60
Tabela 16 - Resultado da análise da amostra com 10% de Carandá	62
Tabela 17 - Resultado da análise da amostra com 15% de Carandá	64
Tabela 18 - Resultado da análise da amostra com 20% de Carandá	66
Tabela 19 - Resultado da análise da amostra com 5% de Gravatá	68
Tabela 20 - Resultado da análise da amostra com 10% de Gravatá	70
Tabela 21 - Resultado da análise da amostra com 15% de Gravatá	72
Tabela 22 - Resultado da análise da amostra com 20% de Gravatá	74

LISTA DE ABREVIATURAS E SIGLAS

TPS – Amido Termoplástico (*Thermoplastic Starch*).

PLA – Poli (ácido láctico).

PVA – Poli (álcool vinílico).

PCL – policaprolactona.

MEV – Microscopia Eletrônica de Varredura.

LNNA – laboratório de Nanotecnologia da EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária).

TC – Tomografia Computadorizada.

PIL – *Python Imaging Library*.

SciPy – *Scientific Python*.

CNPDIA – Centro Nacional de Pesquisa e Desenvolvimento de instrumentação Agropecuária.

TeAS – Sistema de Análise de Textura (*Texture Analysis System*).

SUMÁRIO

CAPÍTULO 1 - NOVOS MATERIAIS BASEADOS EM FIBRAS VEGETAIS DA FLORA BRASILEIRA	1
1.1 Plásticos	1
1.1.1 Amido termoplástico	2
1.1.2 Novos materiais baseados em fibras vegetais da flora brasileira	4
1.1.3 Extração de características	4
1.2 Conclusão do Capítulo	5
CAPÍTULO 2 - TÉCNICAS DE DESCRIÇÃO DE TEXTURAS	6
2.1 Introdução	6
2.2 Introdução à análise por textura	6
2.2.1 Descrição estatística de textura	8
2.2.1.1 Momentos estatísticos do histograma de intensidade	8
2.2.1.2 Métodos baseados em frequências espaciais	9
2.2.1.3 Matrizes de co-ocorrência	11
2.2.1.4 Frequência de borda	13
2.2.2 Descrição sintática	14
2.2.3 Descrição híbrida	15
2.2.4 Abordagens espectrais	16
2.2.5 Momentos invariantes	16
2.2.5.1 Momentos bidimensionais	16
2.2.5.2 Momento Central	17
2.2.5.3 Momentos Centrais Normalizados	17
2.2.5.4 Momentos Invariantes de Hu	17
2.3 Conclusão do capítulo	18
CAPÍTULO 3 - DESENVOLVIMENTO DO MÉTODO E MATERIAIS UTILIZADOS	19
3.1 Descrição do trabalho desenvolvido	19
3.2 Tomografia	20
3.2.1 Novos materiais e tomografias de alta resolução para ensaio de qualidade	20
3.3 Sistema de análise e avaliação de homogeneidade de amostras	26

3.3.1 A linguagem Python	26
3.3.1.1 Carregando uma imagem.....	27
3.3.2 Desenvolvimento de um módulo em Python para cálculo dos momentos invariantes e outras funções básicas para a análise de homogeneidade	28
3.3.2.1 Normalização dos dados da matriz imagem.....	28
3.3.2.2 Gerando primitivas da imagem.....	29
3.3.2.3 Implementação dos momentos invariantes	31
3.3.2.4 Verificação da homogeneidade das amostras.....	34
3.3.3 Interface gráfica para interação com o usuário	36
3.4 Conclusão do capítulo	42
CAPÍTULO 4 - RESULTADOS E DISCUSSÕES	43
4.1 Validação do método.....	43
4.2 Aplicação do método	48
4.3 Conclusão do Capítulo	75
CAPÍTULO 5 - CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS	77
5.1 Conclusões.....	77
5.2 Proposta de trabalho futuro	78
REFERÊNCIAS BIBLIOGRÁFICAS	79

Capítulo 1

NOVOS MATERIAIS BASEADOS EM FIBRAS VEGETAIS DA FLORA BRASILEIRA

Neste capítulo são tratados aspectos sobre os plásticos industriais comuns, seus prós e contras, as possíveis soluções para amenizar os impactos ambientais, os principais meios de extração das características de amostras de compósitos biodegradáveis e aspectos relacionados ao objetivo deste trabalho.

1.1 Plásticos

Os usos dos plásticos industriais, tais como, polietileno, poliestireno, policloreto de vinila e polipropileno são comuns. Por serem leves resistentes, produzidos a baixo custo e fáceis de processar, os plásticos, muitas vezes substituem com vantagem o ferro, o alumínio e a madeira em muitas aplicações.

Apesar da importância dos plásticos na sociedade moderna, eles representam uma ameaça ao meio ambiente, pois muitos deles levam mais de 100 anos para se decomporem.

Para amenizar problemas ambientais, algumas soluções vêm sendo estudadas, tais como métodos de reciclagem e a substituição dos plásticos convencionais por polímeros biodegradáveis (CORRADINI *et al.*, 2007).

Polímeros biodegradáveis são materiais que se decompõem completamente por meio da ação de microorganismos naturais, entre eles, bactérias, fungos e algas (ASTM, 1999).

Os polímeros biodegradáveis podem ser classificados em duas principais classes:

- Polímeros naturais, os quais são formados na natureza por alguns organismos envolvendo processos metabólicos complexos. Assim como os polissacarídeos como amido e celulose, proteínas e poliésteres (como por exemplo: os poli-hidroxi-butiratos) (TEIXEIRA, 2007; CHANDRA & RUSTGI, 1998).
- Polímeros químico-sintéticos, os quais são sintetizados a partir de monômeros derivados de recursos renováveis, como o poli (ácido láctico) (PLA) ou de origem petroquímica, como o poli (álcool vinílico) (PVA) e policaprolactona (PCL) (TEIXEIRA 2007; AVÉROUS, 2004).

O uso de polímeros biodegradáveis pode ser uma opção em muitos casos. O amido termoplástico (TPS), por exemplo, pode ser uma alternativa para parcialmente substituir os polímeros sintéticos em situações em que sua aplicação não exija um longo período de uso, tais como embalagens, potes para plantio, pratos e talheres descartáveis (WANG *et al.* 2003).

Uma das maiores vantagens do amido termoplástico com relação aos outros polímeros biodegradáveis é que o amido pode ser obtido através de fontes renováveis, de baixo custo e grande disponibilidade, podendo ser processado em equipamentos de plásticos industriais convencionais (TEIXEIRA, 2007).

1.1.1 Amido termoplástico

A literatura mostra que estudos relacionados a plásticos derivados de amido tiveram início em meados dos anos 70. O amido foi utilizado como carga (suplemento), em sua forma nativa em grânulos, em matrizes (materiais utilizados como base de matéria prima) poliméricas sintéticas (CURVELO *et al.*, 2001). Essas misturas apresentam fracas propriedades mecânicas devido a pouca adesão entre a carga e a matriz. (CORRADINI *et al.*, 2007).

No início dos anos 90, foram feitas as primeiras referências ao amido termoplástico, não como uma carga para outras matrizes perimétricas, mas sim como uma matriz (RÖPER & KOCH, 1990; SHOGREN, *et al.*, 1993).

O amido em sua forma granular não possui características termoplásticas. Porém, quando submetido à pressão, cisalhamento, temperaturas entre 90-180°C e misturado com algum plastificante, como água e/ou glicerol, o amido é transformado em um material fundido. Ao ser fundido, no material, as cadeias de amilose e

amilopectina ficam intercaladas, e a estrutura semicristalina original é destruída. Este então é chamado de amido termoplástico, TPS, amido desestruturado ou amido plastificado (AVÉROUS, 2004).

As estruturas do amido natural e do TPS podem ser vistas na Figura 1. Com o processamento a estrutura granular é destruída, dando origem a uma fase totalmente contínua.

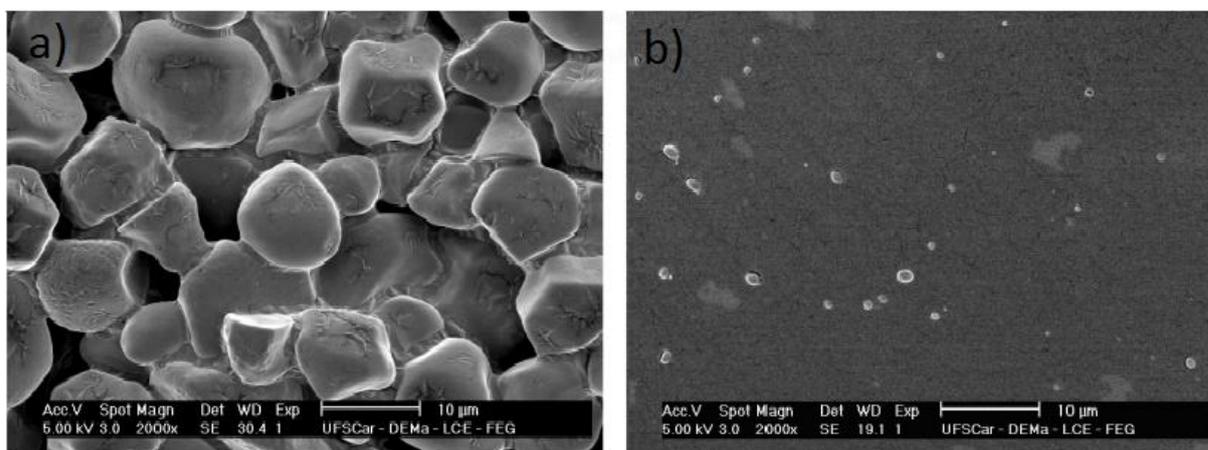


Figura 1 - Fotomicrografias obtidas por microscopia eletrônica de Varredura (MEV), superfície do amido granular (a), TPS com grãos desestruturados (b) (CARMONA, 2011).

Apesar de o amido termoplástico apresentar vantagens com relação aos plásticos convencionais, existem algumas limitações para o seu uso, como por exemplo, sua fragilidade mecânica e alta sensibilidade a água.

Existem vários estudos realizados sobre modificações químicas do amido com o objetivo de se reduzir o seu enfraquecimento perante a presença de água. Porém essas modificações podem desviar o material do seu propósito original que é a sua biodegradabilidade, além do seu custo/benefício (WILLET *et al.*, 1997).

Outros estudos propõem misturas de TPS com polímeros sintéticos, como policloreto de vinila, polietileno, polipropileno, entre outros (MANI & BHATACHARYA, 1998; THAKORE *et al.*, 2001). Essas misturas obtiveram um bom resultado com relação às propriedades mecânicas e uma menor sensibilidade à umidade, entretanto, os materiais resultantes dessas misturas passam a não ser mais totalmente biodegradável (CORRADINI *et al.*, 2007).

1.1.2 Novos materiais baseados em fibras vegetais da flora brasileira

Substituir materiais sintéticos por fibras de origem vegetal como reforço ao TPS é uma opção interessante, tendo em vista que as fibras vegetais são naturalmente biodegradáveis e podem ser obtidas de fontes renováveis de baixo custo, o que auxilia na proteção do meio ambiente, além de sofrerem danos mínimos durante os métodos convencionais de processamento de polímeros possuindo uma densidade menor que as fibras inorgânicas convencionais.

Outro fator de destaque é que o Brasil é um dos países de maior biomassa do mundo, juntamente com uma das maiores extensões cultiváveis, cujo potencial deve ser bem utilizado (CARMONA, 2011).

1.1.3 Extração de características

Atualmente existem técnicas, métodos e equipamentos utilizados para se, medir a resistência mecânica, a absorção de água das amostras e até mesmo sua cristalinidade.

Como exemplo, pode-se citar o equipamento EMIC DL3000 utilizado para avaliar a resistência (propriedades mecânicas) de amostras.

A absorção de umidade dos materiais pode ser verificada ao acondicionar as amostras em recipientes herméticos contendo soluções químicas, e então são pesados em sucessivos intervalos de tempo para verificar as mudanças ocorridas.

A cristalinidade de uma amostra pode ser obtida através da difração de raios x onde os índices de cristalinidade são calculados pela deconvolução dos picos dos difratogramas.

A interação entre as fibras vegetais e a matriz de TPS pode ser observada pela microscopia eletrônica de varredura (MEV) (CARMONA, 2011)

Apesar de todos os equipamentos e testes existentes para se extrair características de amostras, pode-se dizer que na literatura há uma carência quando se trata de métodos utilizados para realizar especificamente a análise da homogeneidade em amostras de compósitos biodegradáveis.

A afirmação da homogeneidade é normalmente obtida a partir da simples observação do material de maneira subjetiva, sem envolver um processo minucioso de análise.

Este trabalho teve como objetivo o desenvolvimento de um método baseado em processamento de imagem e análise de textura para a verificação da qualidade da distribuição das fibras vegetais em amido termoplástico de amostras de compósitos biodegradáveis a partir de imagens tomográficas de alta resolução.

1.2 Conclusão do Capítulo

Neste capítulo foi apresentado um estudo sobre os plásticos convencionais, os fatores ambientais relacionados e algumas das alternativas utilizadas para contornar esses problemas, bem como a reciclagem e a utilização de materiais biodegradáveis em substituição ao plástico industrial convencional.

Em especial foi apresentado o amido termoplástico que por sua versatilidade, pode ser utilizado como alternativa ao plástico convencional. Porém, por apresentar dois problemas principais, fragilidade mecânica e sensibilidade à água, foi aplicada uma solução que consiste na mistura do TPS com fibras vegetais provenientes da flora brasileira.

Foram apresentadas ainda as principais formas de extração de características de amostras de compósitos biodegradáveis utilizadas atualmente. Também, uma breve discussão sobre a carência de métodos de análise de homogeneidade utilizados para verificar a qualidade da distribuição de fibras vegetais em matrizes de TPS, o que motivou o desenvolvimento deste trabalho.

Capítulo 2

TÉCNICAS DE DESCRIÇÃO DE TEXTURAS

Este capítulo apresenta um estudo sobre os métodos de processamento de imagens digitais para a análise de textura, bem como os principais métodos e abordagens, em particular os momentos invariantes de Hu, os quais foram utilizados para o desenvolvimento deste trabalho.

2.1 Introdução

Pode-se definir uma imagem como uma função bidimensional, $f(x, y)$, em que x e y são coordenadas em um plano e f em qualquer par de coordenadas (x, y) é chamado de intensidade ou nível de cinza da imagem.

O campo do processamento digital de imagens se refere ao processamento de imagens digitais por um computador digital. Uma imagem digital é composta de um número finito de elementos, cada um com localização e valor específicos, esses elementos são chamados de pixels (GONZALEZ & WOODS, 2010).

Uma das formas de se extrair características de uma imagem é a análise de textura, que fornece informações com relação à superfície de uma imagem como, sua rugosidade, homogeneidade ou mesmo identificação de formas e objetos.

2.2 Introdução à análise por textura

Segundo Vieira (2013) o campo de pesquisa em textura tem concentrado esforços para desenvolver métodos computacionais que recuperem características de imagens e interpretem seu conteúdo a partir das suas propriedades texturais. Devido à subjetividade do termo textura, varias descrições foram desenvolvidas e

introduzidas ao longo dos anos e dependendo da perspectiva, há problemas para os quais alguns métodos funcionam de forma adequada e outros não.

Textura se refere às propriedades que representam a ordem do arranjo de uma estrutura ou superfície de um objeto, sendo amplamente utilizada na área de processamento de imagem.

Entretanto, não há na literatura uma definição precisa sobre as várias texturas existentes, mas é possível verificar que uma textura apresenta elementos mutuamente relacionados, ou grupos de pixels relacionados, sendo, altamente dependente de escala (HARALICK, 1979).

A textura consiste de primitivas ou elementos de textura, que também podem ser chamados de *texels*. Uma primitiva de textura é um conjunto de pixels contíguos que possuem alguma propriedade tonal ou regional em comum.

Pode-se classificar uma textura de duas formas principais: Texturas rugosas, que são constituídas de primitivas grandes e possuem baixa frequência espacial e Texturas lisas, constituídas de pequenas primitivas que possuem alta frequência espacial. As características texturais estão diretamente ligadas ao tamanho das primitivas.

A descrição de uma textura baseia-se nas tonalidades e na estrutura que as compõem. A tonalidade descreve as propriedades de intensidade de um pixel na primitiva, enquanto quando se diz estrutura se refere à relação espacial entre as primitivas (SONKA *et al.*, 1998).

O objetivo da análise de textura não é definir condições sob as quais uma região seja classificada como possuindo uma textura organizada, mas apenas descrever a textura visual de uma imagem, ou de uma região estatisticamente homogênea (CASTELLANO, 2012).

Existem quatro modos principais para se descrever uma determinada textura:

1. Métodos estatísticos, que calculam diferentes propriedades da textura e que são adequados quando a primitiva utilizada possuir tamanho comparável a pixels;
2. Métodos sintáticos, que são adequados quando as propriedades das primitivas de textura podem facilmente ser determinadas;
3. Métodos híbridos, que consideram tanto os métodos estatísticos como os métodos sintáticos.

4. Métodos espectrais, que tem base em propriedades do espectro de Fourier para descrever padrões globais de textura.

Os métodos sintáticos e híbridos são utilizados quando for possível classificar uma primitiva, isso significa que primitivas podem ser descritas por uma variedade de propriedades além das propriedades tonais, como por exemplo, a descrição de sua forma.

Segundo Julesz (1981), a habilidade que o ser humano possui em reconhecer rapidamente uma textura está baseada principalmente nos *textons*, que são micro estruturas em imagens naturais que possuem alguma forma reconhecível como retângulos, elipses, segmentos lineares, bordas, entre outros.

2.2.1 Descrição estatística de textura

Métodos de descrição estatística de textura expõem a textura de forma adequada para o reconhecimento de padrões, ou seja, esses podem ser calculados formalmente através de fórmulas matemáticas.

Os resultados desses métodos podem ser apresentados como um vetor de propriedades que representam um ponto em um espaço multidimensional.

O objetivo principal de se usar esse tipo de descrição é apresentar uma regra de decisão determinística ou probabilística para associar a textura a alguma classe específica.

2.2.1.1 Momentos estatísticos do histograma de intensidade

Uma das abordagens para descrição de textura é baseada no uso dos momentos estatísticos do histograma de intensidade de toda a imagem por estudo ou região. O momento ρ_α de z em torno da média pode ser formalizado como:

$$\rho_\alpha(z) = \sum_{i=0}^{L-1} (z_i - \beta)^\alpha p(z_i) \quad (2.1)$$

Onde z é uma variável aleatória que denota intensidade, α = ordem, $p(z_i)$ é o histograma correspondente a z , $i = 0, 1, 2 \dots L - 1$, onde L é o número de níveis distinto de intensidades, β é o valor médio de z (intensidade média):

$$\beta = \sum_{i=0}^{L-1} z_i p(z_i) \quad (2.2)$$

O segundo momento estatístico, a variância, fornece uma medida de contraste de intensidade, usado para determinar a suavidade relativa.

$$\rho_2(z) = Var(z) \quad (2.3)$$

O desvio padrão também é utilizado, pois seus valores tendem a ser mais intuitivos em alguns casos. O terceiro momento é uma medida da assimetria do histograma:

$$\rho_3(z) = \sum_{i=0}^{L-1} (z_i - \beta)^3 p(z_i) \quad (2.4)$$

O quarto momento mede quão plano é o histograma, o quinto e os demais momentos mais elevados não se relacionam de forma direta com o formato do histograma, mas fornecem medidas adicionais sobre a textura.

As medidas calculadas apenas pelo histograma não possuem informações sobre as posições relativas entre pixels, sendo que para descrever uma textura de forma adequada é importante considerar tanto as intensidades quanto a distribuição espacial dos pixels, por isso é importante incorporar a análises de textura não apenas a distribuição de intensidades, mas também as posições relativas dos pixels contidos em uma imagem (GONZALES & WOODS, 2010).

Entre outros exemplos para métodos de descrição estatística de textura podem ser citados os métodos baseados em freqüências espaciais, matrizes de co-ocorrência, freqüência de borda, entre outros.

2.2.1.2 Métodos baseados em freqüências espaciais

As medidas de freqüências espaciais servem de base para um grande grupo de métodos de reconhecimento de textura.

As características de textura estão diretamente relacionadas ao tamanho das primitivas, enquanto que texturas rugosas possuem primitivas grandes e baixa freqüência espacial, as texturas lisas possuem primitivas pequenas e alta freqüência espacial.

Dentre os métodos baseados em freqüências é possível destacar a função de autocorrelação de uma textura, transformada óptica de imagem e a transformada discreta de imagem.

- **Função de autocorrelação de uma textura**

Neste tipo de modelo, um único pixel pode ser considerado uma primitiva de textura e a propriedade tonal é o nível de cinza. A organização espacial da textura neste caso é descrita pelo coeficiente de correlação que avalia a relação espacial linear entre as primitivas. De acordo com o modelo (CASTLEMAN, 1996), a textura pode ser descrita avaliando-se os coeficientes de correlação de forma que:

$$C_{ff}(e, g) = \frac{MN}{(M - e)(N - g)} \frac{\sum_{x=1}^{M-e} \sum_{y=1}^{N-g} f(x, y)f(x + e, y + g)}{\sum_{x=1}^M \sum_{y=1}^N f^2(x, y)} \quad (2.5)$$

onde e, g representam a diferença de posição na direção x, y e M, N são as dimensões da imagem.

- **Transformação óptica de imagem**

Frequências espaciais também podem ser determinadas a partir de uma transformação óptica da imagem (SHULMAN, 1970), uma grande vantagem é que ela pode ser calculada em tempo real.

O valor médio em ondas específicas de energia e anéis de espectro de Fourier pode ser usado como propriedade de descrição de textura.

Propriedades avaliadas a partir de anéis refletem a rugosidade de uma textura, se a energia é alta em um anel de raio grande é possível classificar a textura como sendo lisa (alta frequência espacial), enquanto que se a energia é baixa e o raio do anel é pequeno pode-se dizer que a textura é rugosa (baixa frequência espacial).

- **Transformação discreta de imagem**

Uma imagem de textura é normalmente dividida em pequenos quadros de sub-imagem não sobrepostos. Se o tamanho da sub-imagem for $M \times M$, a escala de cinza de seus pixels pode ser interpretada como um vetor de dimensão M^2 e a imagem representada por um conjunto de vetores.

Aplicando a transformada de Fourier, Hadamard, ou outra transformação discreta de imagem nesses vetores, são obtidas novas coordenadas em relação à

frequência espacial da imagem original, que podem ser usadas para a descrição de textura (ROSENFELD & DWYER, 1976).

2.2.1.3 Matrizes de co-ocorrência

O método das matrizes de co-ocorrência de descrição de textura baseia-se na repetição de configurações de escala de cinza. Estas configurações, de acordo com a distância, variam em frequência convergindo de forma rápida em texturas lisas e vagarosamente em texturas rugosas (HARALICK *et al.*, 1973).

As ocorrências de níveis configurações de níveis de cinza podem ser descritas por matrizes de frequências relativas, chamadas de matrizes de co-ocorrência, apresentando quão freqüente é o aparecimento de dois pixels com determinados tons de cinza com uma determinada distância e direção angular. As matrizes são simétricas ao definí-las da seguinte forma:

$$\begin{aligned}
 P_{0^\circ,d}(a,b) &= |\{(k,l),(r,s) \in D: k-r=0, |l-s|=d, f(k,l)=a, f(r,s)=b\}| \\
 P_{45^\circ,d}(a,b) &= |\{(k,l),(r,s) \in D: (k-r=d, l-s \\
 &= -d) \text{ OU } (k-r=-d, l-s=d), f(k,l)=a, f(r,s)=b\}| \\
 P_{90^\circ,d}(a,b) &= |\{(k,l),(r,s) \in D: |k-r|=d, l-s=0, f(k,l)=a, f(r,s)=b\}| \quad (2.7) \\
 P_{135^\circ,d}(a,b) &= |\{(k,l),(r,s) \in D: (k-r=d, l-s \\
 &= d) \text{ OU } (k-r=-d, l-s=-d), f(k,l)=a, f(r,s)=b\}|
 \end{aligned}$$

onde em uma imagem de tamanho $M \times N$, $P_{\theta,d}(a,b)$ é a matriz de frequências relativas com dois pixels com escala de cinza a, b separados por uma distância d na direção θ , sendo $|\{\dots\}|$ referente ao conjunto de cardinalidade e $D = (M * N) * (M * N)$.

A partir de uma matriz imagem as matrizes de co-ocorrência podem ser calculadas para todas as direções e distâncias.

As matrizes resultantes armazenam a quantidade de vezes que dois pixels se repetem na determinada direção e distância.

A Figura 2 apresenta um exemplo, onde é realizado o cálculo das matrizes de co-ocorrência para todas as direções com distância igual a um a partir de uma matriz imagem em escala de cinza.

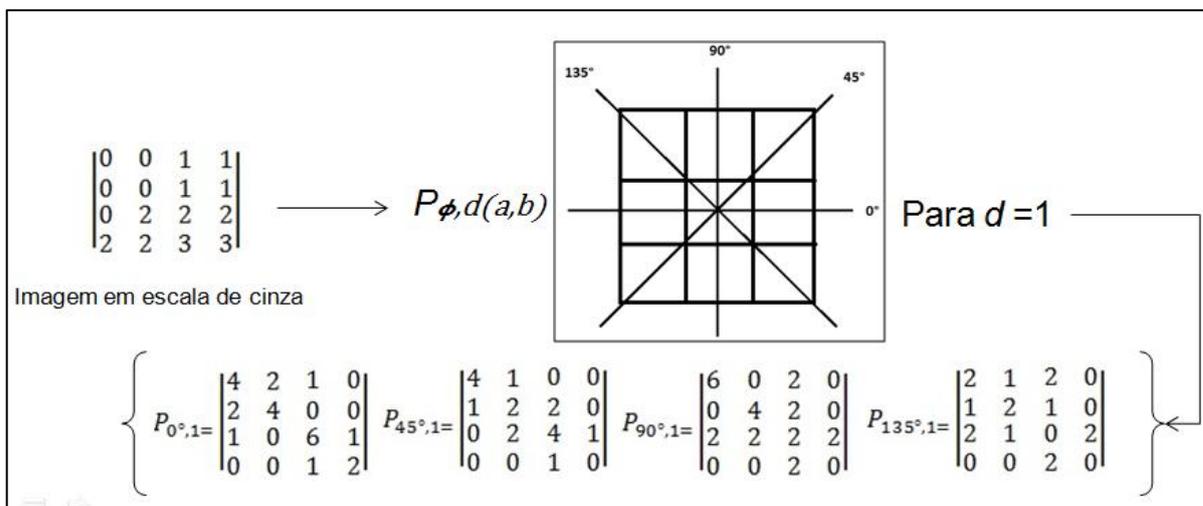


Figura 2 - Cálculo das matrizes de co-ocorrência para todas as direções com distância um.

Tendo as informações sobre a textura contidas nas matrizes de co-ocorrência é possível derivá-la para se obter características de textura. Haralick *et al.* (1973) extraíram 14 características de textura a partir das matrizes de co-ocorrência. Porém segundo SONKA *et al.*(1998) apenas seis são amplamente utilizados, são eles:

- **Energia ou segundo momento angular:** verifica a uniformidade da textura em uma imagem. Valores altos representam uma imagem bem ordenada. O segundo momento angular pode ser dado por:

$$f_{sma} = \sum_{a,b} P^2_{\theta,d}(a,b) \quad (2.8)$$

- **Entropia:** mede o grau de dispersão dos níveis de cinza. A entropia pode ser dada por:

$$f_{ent} = \sum_{a,b} P_{\theta,d}(a,b) \log_2 P_{\theta,d}(a,b) \quad (2.9)$$

- **Máxima probabilidade:** verifica se a matriz possui um máximo, indicando qual a direção mais importante da textura a ser examinada. A máxima probabilidade pode ser dada por:

$$f_{mp} = \max_{a,b} P_{\theta,d}(a,b) \quad (2.10)$$

- **Contraste:** retorna a medida de contraste entre as intensidades de um pixel e seu vizinho, auxiliando na detecção de bordas (tipicamente $\kappa = 2, \delta = 1$). O contraste pode ser dado por:

$$f_{con} = \sum_{a,b} |a - b|^k P_{\theta,d}^{\delta}(a, b) \quad (2.11)$$

- **Momento de diferença inversa:** verifica distorções da imagem apresentando valores baixos se a matriz P possuir valores pequenos na diagonal principal. O momento de diferença inversa pode ser dado por:

$$f_{mdi} = \sum_{a,b;a \neq b} \frac{P_{\theta,d}^{\delta}(a, b)}{|a - b|^k} \quad (2.12)$$

- **Correlação:** mede o grau de correlação entre um pixel e seu vizinho, (uma medida de linearidade de imagem), ou seja:

$$f_{cor} = \frac{\sum_{a,b} [(ab)P_{\theta,d}(a, b)] - \varphi_a \varphi_b}{\sigma_a \sigma_b} \quad (2.13)$$

onde φ_a, φ_b são as médias e σ_a, σ_b os desvios padrões, dados por:

$$\begin{aligned} \varphi_a &= \sum_a a \sum_b P_{\theta,d}(a, b) \\ \varphi_b &= \sum_b b \sum_a P_{\theta,d}(a, b) \\ \sigma_a &= \sum_a (a - \varphi_x)^2 \sum_b P_{\theta,d}(a, b) \\ \sigma_b &= \sum_b (b - \varphi_x)^2 \sum_a P_{\theta,d}(a, b) \end{aligned}$$

Uma das propriedades do método das matrizes de co-ocorrência é a capacidade de descrever a relação espacial entre os pixels tonais e as transformações monotônicas de escala de cinza.

Por outro lado, o método não considera as formas das primitivas e por isso não é recomendado quando as primitivas são grandes.

Apesar do método das matrizes de co-ocorrência fornecer bons resultados com relacionados à textura, o método é computacionalmente custoso e não recomendado em algumas situações (SONKA *et al.*, 1998).

2.2.1.4 Frequência de borda

A abordagem pela frequência de borda é uma descrição realizada a partir da frequência do aparecimento de bordas na textura.

Bordas podem ser identificadas como micro bordas ou macro bordas, utilizando máscaras operadoras de bordas pequenas e grandes respectivamente (DAVIS & MITCHE, 1980). A operação mais simples que serve para este propósito é a do cálculo do operador de Robert, mas virtualmente qualquer outro detector de borda pode ser usado.

2.2.2 Descrição sintática

Descrição sintática de textura tem como base uma analogia entre as relações espaciais de uma primitiva de textura e a estrutura de uma linguagem formal.

Modelos de descrição sintáticos baseiam-se na idéia de que texturas consistem de primitivas localizadas em relações quase regulares.

Uma das mais eficientes formas de descrever a estrutura da relação entre primitivas é a utilização de uma gramática que represente uma regra para a construção de uma textura a partir de primitivas, aplicando regras de transformação a um limitado conjunto de símbolos. Símbolos representam os tipos de primitivas. Regras de transformações representam a relação espacial entre primitivas.

A descrição sintática pode descrever texturas reais, desde que regras variáveis sejam incorporadas nas gramáticas de descrição. Gramáticas não determinísticas ou estocásticas devem ser usadas (FU, 1974).

Como exemplo de métodos de descrição sintática de textura pode-se citar:

- **Gramática encadeada de formas:** é a mais simples gramática que pode ser usada na descrição de textura. Ela gera texturas começando por um símbolo inicial seguido pela aplicação das regras de transformação de forma (BALLARD & BROWN, 1982).
- **Gramática de grafo:** é uma abordagem que constrói o *layout* de um grafo plano de primitivas. Classes de primitivas e relações espaciais das primitivas devem ser conhecidas para se construir o grafo; relações espaciais entre primitivas de textura refletem na estrutura do grafo. O problema de classificação de textura é então transformado em um problema de reconhecimento de grafo (SONKA *et al.*, 1998).

A abordagem sintática é valorada pela sua habilidade de descrever um caractere de textura em vários níveis hierárquicos.

2.2.3 Descrição híbrida

Os métodos de descrição híbridos de textura combinam as abordagens estatísticas e sintáticas, sendo que a parte técnica é a parte sintática, pois as primitivas são exatamente definidas, e a parte estatística é a relação espacial entre as primitivas que são baseadas em probabilidades (CONNERS & HARLOW, 1980).

A abordagem híbrida de descrição de textura distingue texturas que possuem baixa relação espacial das que possuem alta relação espacial regular.

A parte sintática das texturas que possuem baixa relação espacial divide uma imagem em regiões com base em propriedades tonais (por exemplo, regiões com escala de cinza constante) que podem ser consideradas primitivas de textura.

O próximo passo constrói histogramas dos tamanhos e formas de todas as primitivas de textura contidas na imagem.

Se a imagem pode ser segmentada em dois conjuntos de regiões de texturas homogêneas, o histograma é bi-modal e cada primitiva é tipicamente de um padrão de textura, que poder utilizado para segmentação de textura.

Se o histograma inicial não possui picos significantes, uma segmentação completa não pode ser alcançada. A segmentação baseada em histograma pode ser repetida para cada região de textura homogênea prévia.

Se cada região de textura consiste em mais de um tipo de primitiva, o método não pode ser usado e a relação espacial entre as primitivas precisa ser calculada (HARALICK, 1979) (SONKA *et al.*, 1998).

Descrição de texturas por primitivas com alta relação espacial regular baseia-se na relação espacial das primitivas e interações bi-direcionais entre primitivas parecem ter grande parte da informação.

A primitiva de textura mais simples é um pixel e sua propriedade de escala de cinza, enquanto o conjunto máximo de pixels com escala de cinza constante é a primitiva de textura mais complexa (WANG & ROSENFELD, 1981). Tal primitiva pode ser descrita pelo seu tamanho, alongamento, orientação, escala de cinza média, entre outros.

A descrição de textura inclui a relação espacial entre primitivas baseado na distância e na relação de adjacência. O uso de primitivas mais complexas retorna mais informações sobre a textura. Por outro lado, todas as propriedades de

primitivas simples ficam imediatamente disponíveis sem a necessidade de envolver cálculos extensivos nas propriedades das primitivas.

2.2.4 Abordagens espectrais

Além dos métodos estatísticos, sintáticos e híbridos, destacam-se também as abordagens espectrais.

As abordagens espectrais se baseiam em propriedades do espectro de Fourier e são utilizadas principalmente para detectar a periodicidade global em uma imagem pela identificação de picos de alta energia no espectro de Fourier.

Três características do espectro de Fourier podem ser consideradas úteis para a descrição de textura, picos no espectro fornecem a direção principal dos padrões de textura, a localização dos picos no plano de frequência fornecem o período espacial fundamental dos padrões e por fim, realizando a eliminação de quaisquer componentes periódicos através de filtragem, os elementos não periódicos restantes podem ser descritos por meio de técnicas estatísticas (GONZALES & WOODS, 2010).

2.2.5 Momentos invariantes

Além dos quatro tipos de métodos de descrição de texturas é possível citar os momentos invariantes, não como um método de descrição, mas como forma de se obter um novo método de descrição estatístico.

Os momentos de um objeto são medidas estatísticas que não fazem de fato a caracterização específica de um objeto, como os métodos mencionados, mas sim medidas que se relacionam com a caracterização de um objeto (SANTOS, 2008, 2009) (HU, 1962).

2.2.5.1 Momentos bidimensionais

O momento bidimensional padrão é uma função projetada em $f(x, y)$, representando uma imagem através de uma função polinomial. Pode-se definir o momento bidimensional de ordem $(p+q)$ de uma imagem digital $f(x, y)$ de tamanho $M \times N$ como:

$$m_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} x^p y^q f(x, y) \quad (2.21)$$

Onde $p, q \in N$

2.2.5.2 Momento Central

Os momentos bidimensionais podem não ser invariantes a transformações como translação ou rotação, esses atributos podem ser obtidos através do cálculo do momento central. O momento central correspondente de ordem $(p + q)$ é definido como:

$$\mu_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (2.22)$$

Para $p, q \in N$ sendo:

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad e \quad \bar{y} = \frac{m_{01}}{m_{00}} \quad (2.23)$$

onde (\bar{x}, \bar{y}) é o centróide da imagem $f(x, y)$.

2.2.5.3 Momentos Centrais Normalizados

Apesar de o momento central ser invariante a translações ou rotações, ainda não é invariante a mudança de escala, a invariância à escala pode ser obtida pelo cálculo dos momentos centrais normalizados.

Os momentos centrais normalizados, chamados de η_{pq} , são definidos como:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma} \quad (2.24)$$

Sendo:

$$\gamma = \frac{p + q}{2} + 1 \quad (2.25)$$

Para $p + q = 2, 3, \dots, n$

2.2.5.4 Momentos Invariantes de Hu

Os momentos invariantes de Hu, também são chamados de momentos invariantes absolutos, pois são relativamente invariantes sob qualquer transformação linear que a imagem possa sofrer (HU, 1962).

Os sete momentos invariantes são momentos derivados do segundo e terceiro momentos. São eles:

$$\Phi_1 = \eta_{20} + \eta_{02} \quad (2.26)$$

$$\Phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (2.27)$$

$$\Phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (2.28)$$

$$\Phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \quad (2.29)$$

$$\begin{aligned} \Phi_5 = & (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 \\ & - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \\ & [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned} \quad (2.30)$$

$$\begin{aligned} \Phi_6 = & (\eta_{20} + \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ & + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \end{aligned} \quad (2.31)$$

$$\begin{aligned} \Phi_7 = & (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 \\ & - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) \\ & [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned} \quad (2.32)$$

O 7º momento invariante pode ser utilizado para detectar o espelhamento da imagem.

2.3 Conclusão do capítulo

Neste capítulo foi apresentado um estudo sobre os principais métodos utilizados para a análise de texturas em imagens.

Capítulo 3

DESENVOLVIMENTO DO MÉTODO E MATERIAIS UTILIZADOS

Neste capítulo são apresentadas as etapas realizadas para o desenvolvimento do método de análise. Foram implementados os momentos invariantes de Hu. Neste contexto, foram desenvolvidos cálculos estatísticos para análises de homogeneidade em imagens tomográficas.

3.1 Descrição do trabalho desenvolvido

O desenvolvimento deste trabalho foi baseado em técnicas do processamento de imagem e buscou estabelecer um método para a verificação e análise da qualidade da mistura das fibras vegetais em TPS.

Para a realização das etapas de análise, foram utilizadas imagens tomográficas de alta resolução de amostra de materiais feitos da mistura de TPS e das fibras vegetais de plantas nativas da flora brasileira, Acuri (*Attalea phalerata*), Gravatá (*Bromelia balansae Mez*) e Carandá (*Copernicia australis*).

Para realizar a avaliação dessas amostras, foram utilizadas técnicas de análise não linear que permitem avaliar a entropia das imagens em função da homogeneidade da mistura das fibras.

Para ilustrar o processo de desenvolvimento a Figura 3 apresenta um diagrama de blocos que com as etapas e a lógica do método de análise, onde foram consideradas fases que vão desde a obtenção das imagens tomográficas das amostras até o cálculo do grau de homogeneidade das mesmas.

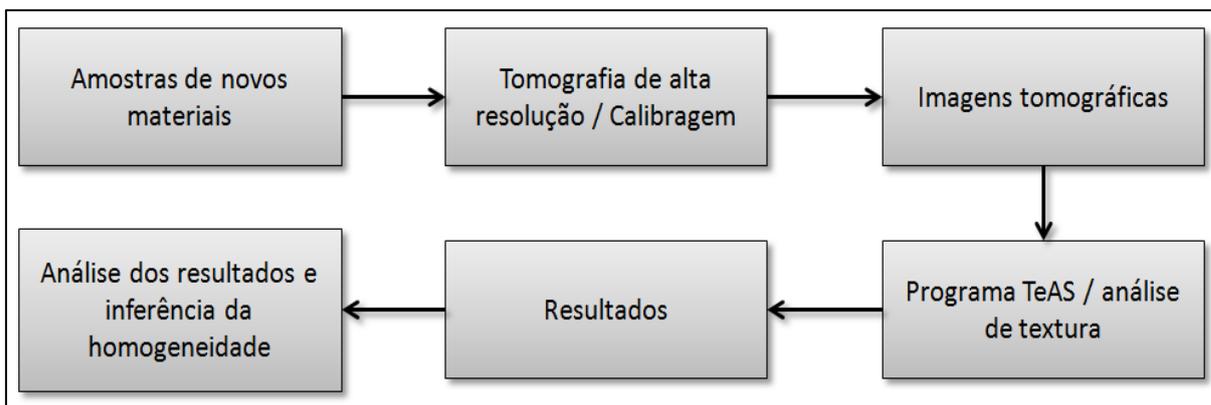


Figura 3 - Diagrama de blocos do processo de análise.

Cada uma das etapas apresentadas no diagrama está descrita nos itens seguintes deste capítulo.

3.2 Tomografia

A tomografia computadorizada (TC) de raios-x tem sido amplamente utilizada como método para se obter imagens do interior de objetos.

Atualmente vários tomógrafos que usam raios-X ou raios- γ como fonte estão disponíveis tanto para uso médico quanto para aplicações multidisciplinares.

Em 1987 um minitomógrafo foi desenvolvido na EMBRAPA Instrumentação (Empresa Brasileira de Pesquisa Agropecuária) e vem sendo utilizado em vários trabalhos multidisciplinares no centro nacional de pesquisa e desenvolvimento de instrumentação agropecuária (CNPDIA) (CRUVINEL, 1987, 1990, 1996).

A TC permite a reconstrução de objetos por secções também chamadas de “camadas” posicionadas sobre um eixo. Essa técnica foi primeiramente utilizada por Cormack e Hounsfield em 1973 (CORMACK, 1973) (HOUNSFIELD, 1973).

Em uma TC, as imagens relativas ao eixo podem ser armazenadas em forma de vetores com valores de atenuação em determinado ângulo numéricas bidimensionais ou tridimensionais (MINATEL & CRUVINEL, 1998).

3.2.1 Novos materiais e tomografias de alta resolução para ensaio de qualidade

As amostras utilizadas neste trabalho foram desenvolvidas no LNNA - Laboratório de Nanotecnologia da EMBRAPA. Em cada uma das amostras está misturado TPS com diferentes proporções de fibras vegetais, são elas: Acuri (*Attalea*

phalerata), Gravatá (*Bromelia balansae* Mez), Carandá (*Copernicia australis*) (Figura 4).

Apesar da importância extrativista para as comunidades locais do Pantanal, por serem utilizadas na confecção de artesanatos, ainda são pouco conhecidas pela comunidade científica com relação às possibilidades técnicas e econômicas dessas espécies em outras aplicações (CARMONA, 2011).



Figura 4 - Fotos do Acuri - *Attalea phalerata* (a), Gravatá - *Bromelia balansae* Mez (b) e Carandá - *Copernicia australis* (c).

Para ilustrar as proporções das amostras obtidas foi esboçada a seguinte tabela:

Tabela 1 - Composições das amostras para análise

	Acuri	Gravatá	Carandá
TPS 100%	0%	0%	0%
TPS 95%	5%	5%	5%
TPS 90%	10%	10%	10%
TPS 85%	15%	15%	15%
TPS 80%	20%	20%	20%

Como resultado da mistura do TPS com as fibras vegetais foram obtidas 13 amostras de material biodegradável, apresentadas na Figura 5, sendo 12 amostras com diferentes proporções de TPS e fibras e uma produzida com TPS puro, para que fossem analisadas.

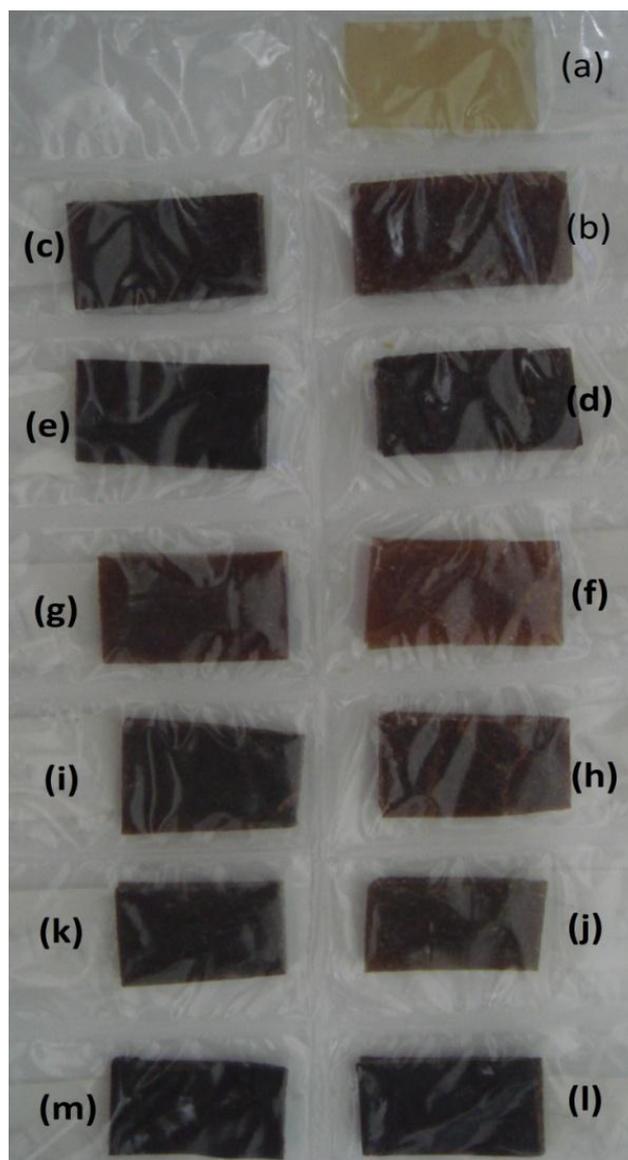


Figura 5 - Amostras de novos materiais. TPS 100% (a), Acuri 5% (b), Acuri 10% (c), Acuri 15% (d), Acuri 20% (e), Carandá 5% (f), Carandá 10%(g), Carandá 15%(h), Carandá 20% (i), Gravatá 5%(j), Gravatá 10%(k), Gravatá 15%(l), Gravatá 20%(m).

É possível perceber como as fibras interagem com o TPS através das fotomicrografias de microscopia eletrônica de Varredura (MEV) de algumas das misturas na Figura 6.

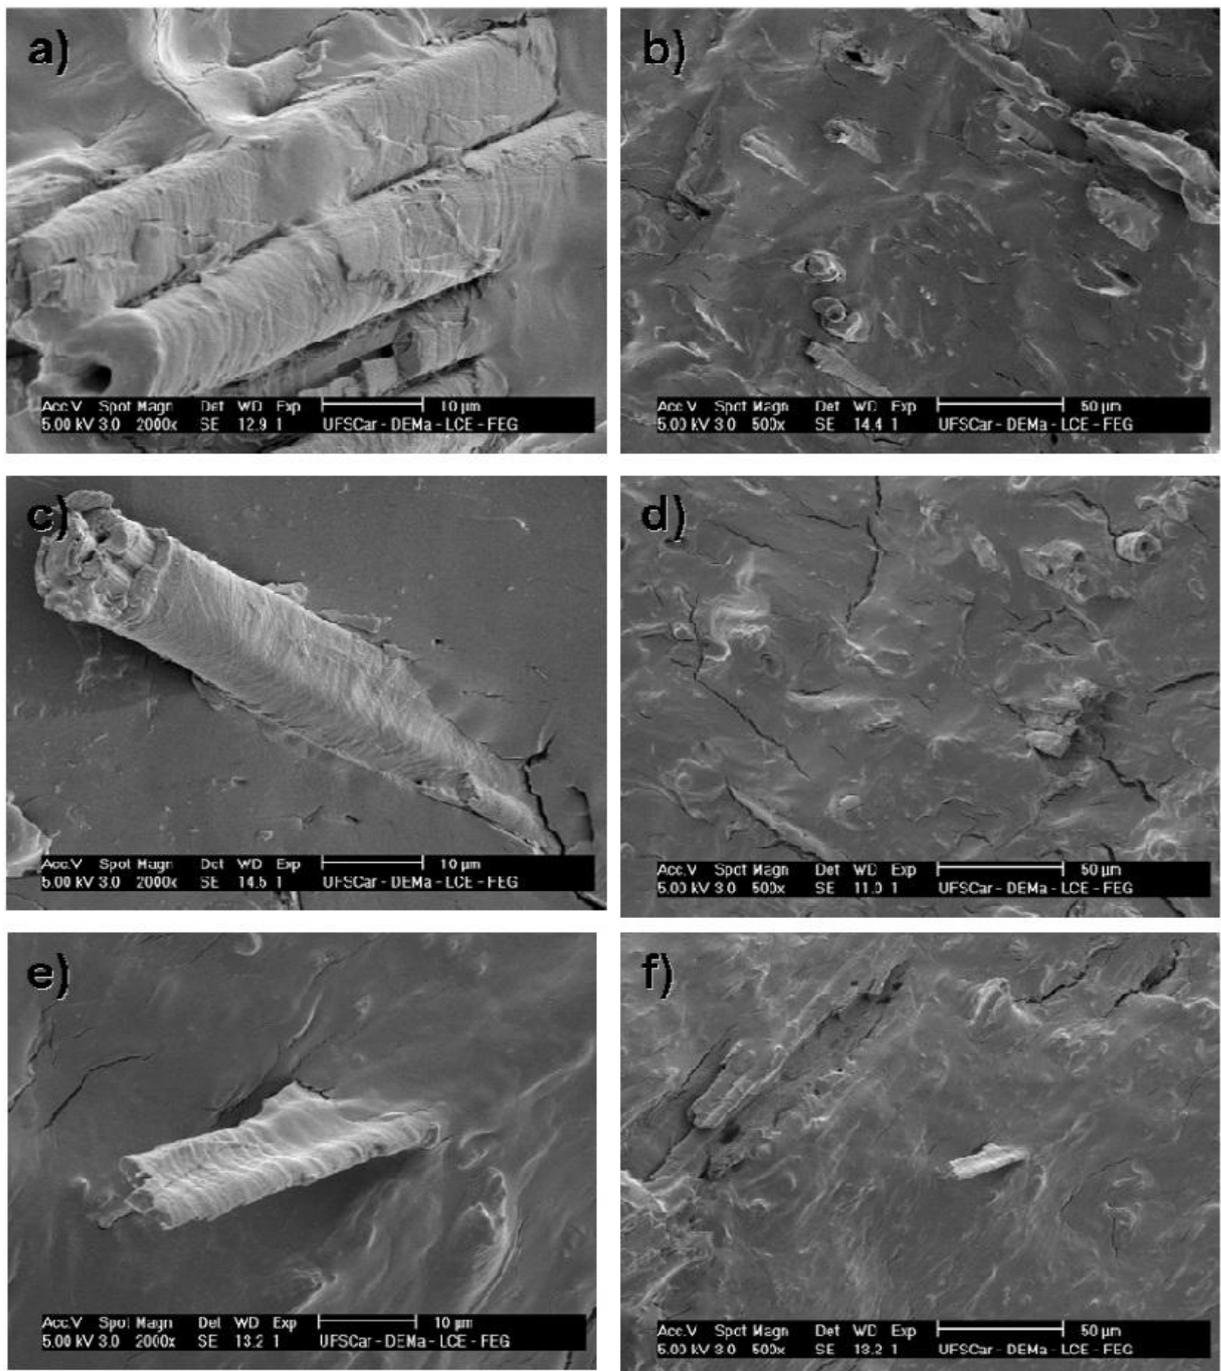


Figura 6 - Fotomicrografias de MEV de TPS / Acari 5% (a) (200X); TPS / Acari 20% (b) (500x); TPS / Carandá 5% (c) (200x); TPS / Carandá 20%(d) (500x); TPS / Gravatá 5% (e) (200x) e TPS / Gravatá (f) (500x); (CARMONA, 2011).

Segundo Carmona (2011), as amostras com fibras naturais misturadas ao TPS tiveram uma significativa melhora em sua resistência mecânica, obtendo uma resistência a tração de até 20 vezes maior, uma absorção de água até 40% menor, quando comparadas à matriz de TPS sem a mistura de fibras vegetais.

Pode-se afirmar ainda, que a qualidade das amostras está diretamente ligada à forma como as fibras se aderem ao TPS e sua distribuição pelo material, pois

quanto maior a homogeneidade e aderência melhor é a atuação das fibras no fortalecimento do TPS.

As tomografias das amostras foram obtidas a partir de um micro tomógrafo de raios-X *SkyScan 1172*¹ de alta resolução. Foram obtidas 1960 imagens para cada amostra e cerca de 90 Gigabytes de imagens no total e todas estão no formato Bitmap (bmp) 8 bits.

Apesar das imagens possuírem uma alta resolução e uma taxa de contraste considerável, é bastante comum que haja artefatos e ruídos provenientes da própria reconstrução.

Em algumas das imagens obtidas é possível perceber claramente artefatos com forma circular, isso pode ser devido ao recipiente circular onde as amostras foram depositadas para realização das tomografias.

As Figuras 7, 8, 9 e 10, são imagens de tomografias, com aplicação de pseudo-cor e em escala de cinza.

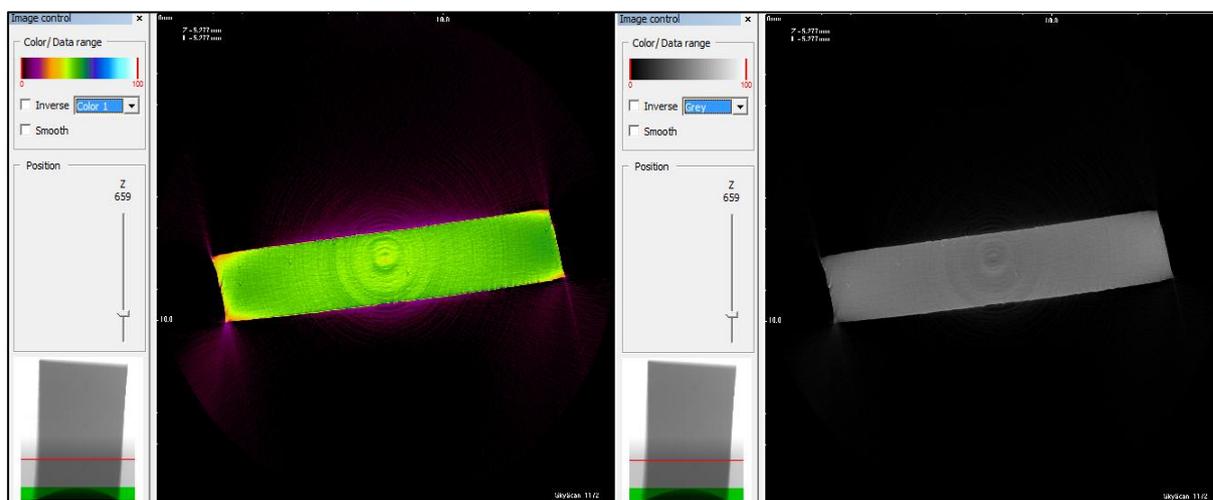


Figura 7 - Imagem da tomografia da amostra TPS 100%, pseudo-cor (esquerda) e escala de cinza (direita)

¹ Micro tomógrafo de raios-X *SkyScan 1172*: micro tomógrafo composto por um tubo de raios-X de micro foco com fonte de alta tensão (100kV), um porta amostra com manipulador de precisão e um detector baseado em uma câmera CCD de 10Mp (4000x 2300 pixel conectados a um computador de controle e aquisição de dados (host) interligado em rede a um cluster e computadores utilizado na reconstrução das imagens tomográficas.

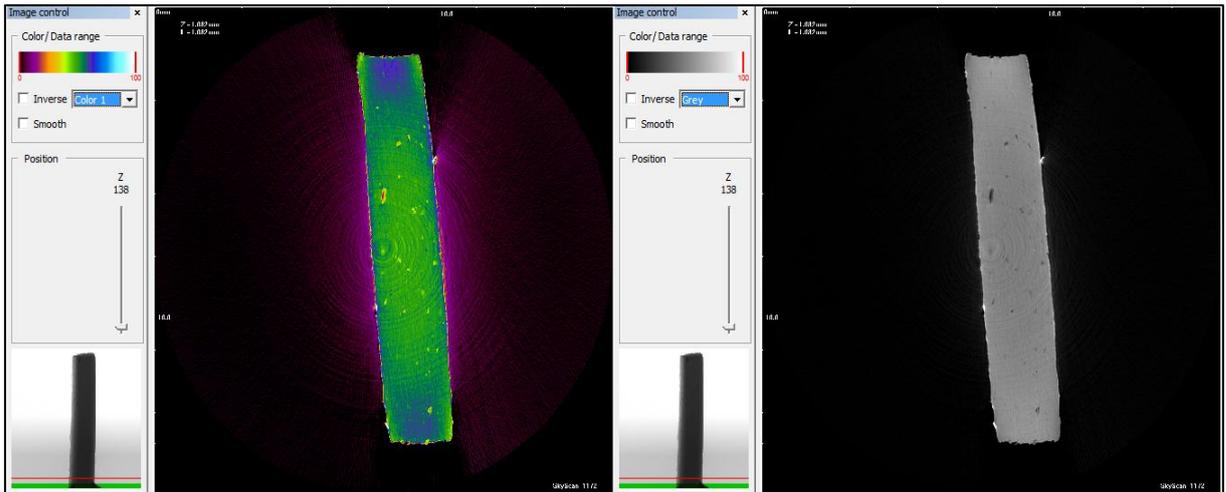


Figura 8 - Imagem da tomografia da amostra Acuri 5% pseudo-cor (esquerda) e escala de cinza (direita)

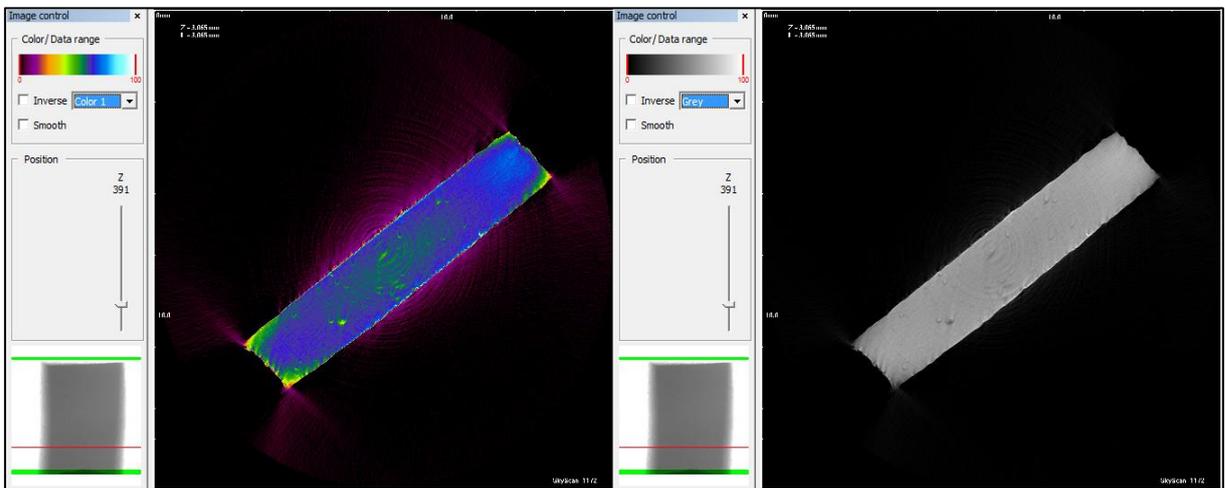


Figura 9 - Imagem da tomografia da amostra Carandá 5% pseudo-cor (esquerda) e escala de cinza (direita)

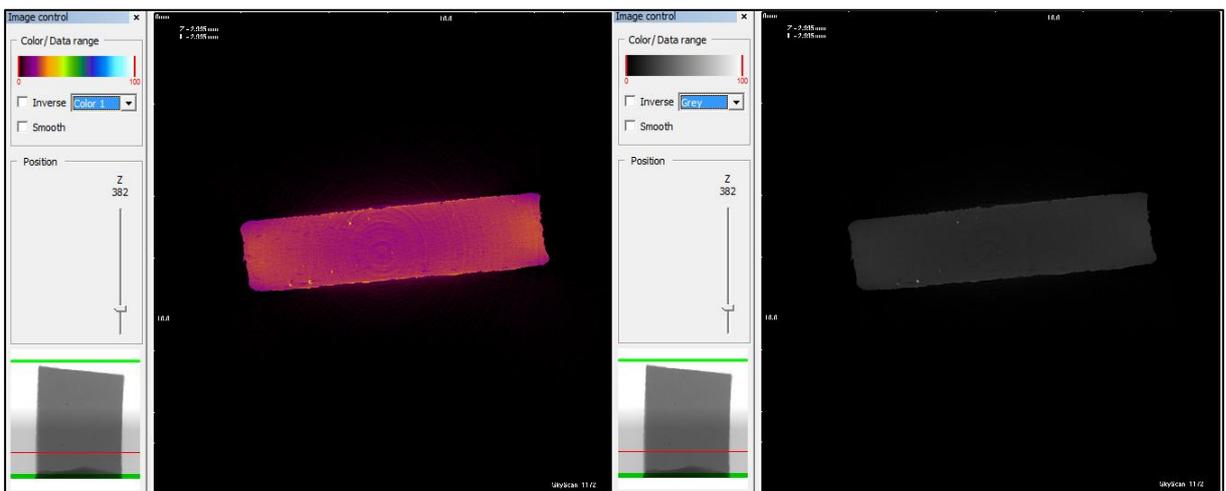


Figura 10 - Imagem tomografia da amostra Gravatá 5% pseudo-cor (esquerda) e escala de cinza (direita)

3.3 Sistema de análise e avaliação de homogeneidade de amostras

Para realizar a avaliação das amostras com relação à homogeneidade foi desenvolvido um sistema, para interação com o usuário, capaz de analisar e avaliar a entropia das imagens em função da homogeneidade através do cálculo de momentos invariantes em áreas das imagens.

Para o desenvolvimento do sistema foi utilizada a linguagem de programação Python em sua versão 2.7.3.

Python é uma linguagem interpretada de alto nível, orientada a objetos possuindo uma tipagem dinâmica e consistente. Conta com vários recursos que facilitam a programação ao usuário, além de ser multiplataforma e funcionar em vários sistemas operacionais. Possui seu código aberto e é gerenciada por uma organização sem fins lucrativos (*Python Software Foundation*) e uma extensa biblioteca de módulos para os mais diversos usos e aplicações (<http://www.python.org.br>).

Porém por ser uma linguagem de programação interpretada, sua velocidade de execução nem sempre se iguala a velocidade de execução de linguagens compiladas.

Para a implementação do sistema foi possível separar o desenvolvimento em etapas, as quais também incluem as etapas de aprendizado da linguagem de programação.

3.3.1 A linguagem Python

Foram estudados os módulos de manipulação de imagens, da linguagem Python e em particular para este projeto foram usados os módulos PIL (*Python Imaging Library*) e SciPy (*Scientific Python*).

O módulo PIL ou *Python Imaging Library* permite que o interpretador Python realize o processamento de imagens. Sua biblioteca suporta uma extensa lista de formatos de imagens e possui grande capacidade para realização do processamento.

O núcleo da biblioteca foi desenvolvido para realizar acessos rápidos aos dados armazenados em formatos básicos de pixels (LUNDH & ELLIS, 2002).

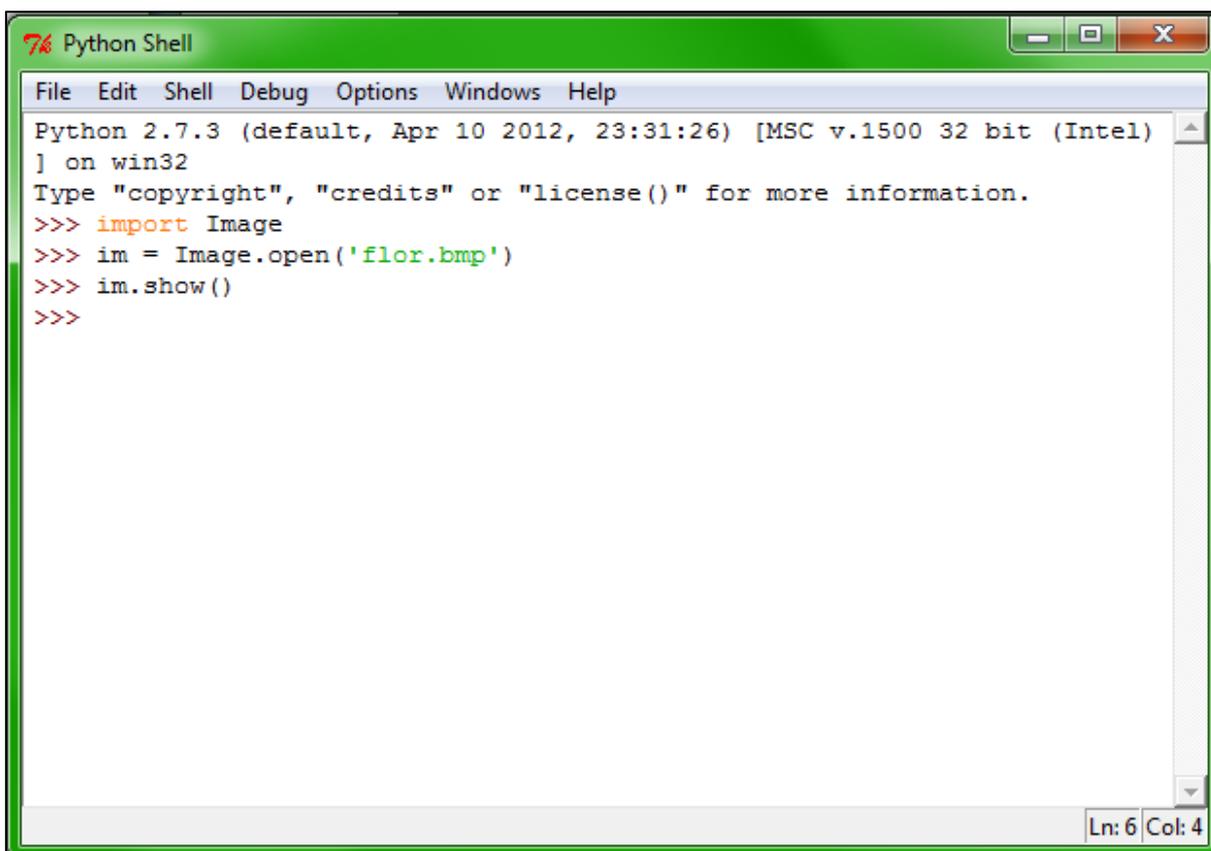
O módulo SciPy é uma coleção de ferramentas dedicadas a realização de cálculos científicos, que inclui módulos para otimização estatística, álgebra linear,

transformada de Fourier, processamento de imagens e sinais, entre outros. (*Numpy and SciPy documentation*)

3.3.1.1 Carregando uma imagem

Antes de realizar qualquer análise é necessário carregar a imagem, para tal o Python pode realizar esta operação através de comandos simples importando o módulo PIL. Porém, ao carregar a imagem com o módulo PIL há a necessidade de se readequar a forma como a imagem é apresentada ao usuário.

O módulo PIL simplesmente se encarrega de abrir uma imagem quando realizado o comando “*show ()*” no próprio visualizador do sistema operacional nativo. A Figura 11 mostra as linhas de comandos necessárias para exibir uma imagem com a linguagem Python.

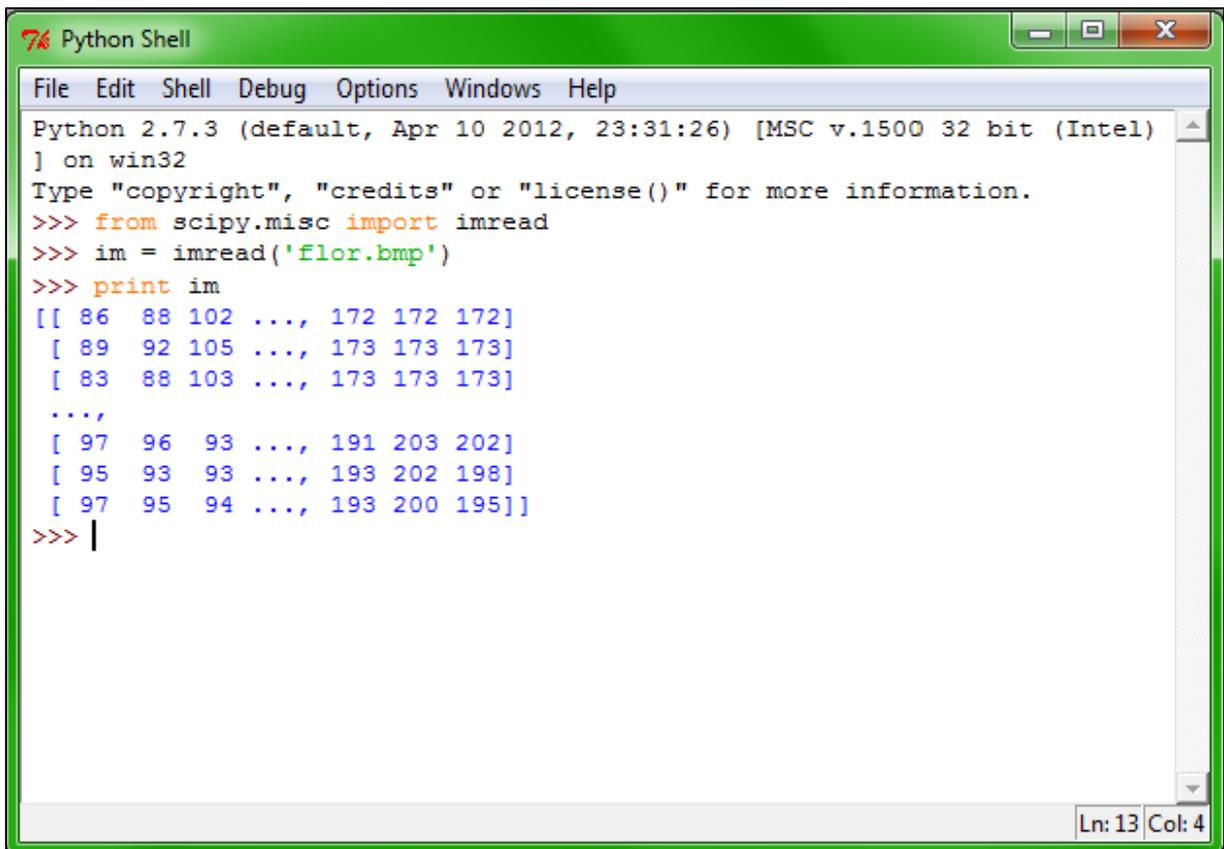
A screenshot of a Python Shell window titled "Python Shell". The window has a menu bar with "File", "Edit", "Shell", "Debug", "Options", "Windows", and "Help". The main text area shows the following code:

```
Python 2.7.3 (default, Apr 10 2012, 23:31:26) [MSC v.1500 32 bit (Intel)
] on win32
Type "copyright", "credits" or "license()" for more information.
>>> import Image
>>> im = Image.open('flor.bmp')
>>> im.show()
>>>
```

The status bar at the bottom right indicates "Ln: 6 Col: 4".

Figura 11 - Comandos para abrir uma imagem

Para realizar qualquer análise é necessário transformar a imagem em uma matriz de valores em escala de cinza, para realizar este processo foi utilizado o módulo SciPy. A Figura 12 apresenta a matriz de intensidades de uma imagem.



```
Python Shell
File Edit Shell Debug Options Windows Help
Python 2.7.3 (default, Apr 10 2012, 23:31:26) [MSC v.1500 32 bit (Intel)
] on win32
Type "copyright", "credits" or "license()" for more information.
>>> from scipy.misc import imread
>>> im = imread('flor.bmp')
>>> print im
[[ 86  88 102 ..., 172 172 172]
 [ 89  92 105 ..., 173 173 173]
 [ 83  88 103 ..., 173 173 173]
 ...,
 [ 97  96  93 ..., 191 203 202]
 [ 95  93  93 ..., 193 202 198]
 [ 97  95  94 ..., 193 200 195]]
>>> |
```

Figura 12 - Transformando uma imagem em uma matriz

A partir da matriz imagem, cujos elementos representam a intensidade de escala de cinza de cada um dos pixels em sua posição x e y do plano, é possível realizar cálculos e análises.

3.3.2 Desenvolvimento de um módulo em Python para cálculo dos momentos invariantes e outras funções básicas para a análise de homogeneidade

Para realizar a análise de homogeneidade nas imagens tomográficas foi implementado um módulo capaz de realizar o cálculo dos momentos invariantes em imagens em escala de cinza, além de outras funções necessárias à análise das mesmas, como normalizações de dados e cálculos estatísticos.

3.3.2.1 Normalização dos dados da matriz imagem

Foi implementada uma função para realizar a normalização dos níveis de intensidade da escala de cinza. Existem 256 tons de cinza, onde 0 para preto e 255 para branco, para normalizar esses dados na matriz da imagem todos os elementos

foram divididos por 255, desta forma os valores ficam entre 0 e 1. A função responsável por realizar esta transformação foi chamada de “normaliza” apresentada na Figura 13, onde é necessário fornecer como parâmetro a matriz de intensidades da imagem.

```
#normaliza a matriz da imagem em valores entre 0-1
def normaliza(imgMtrx):
    imgMtrx = imgMtrx.astype(float) / 255

    return imgMtrx
```

Figura 13 - Função “normaliza”

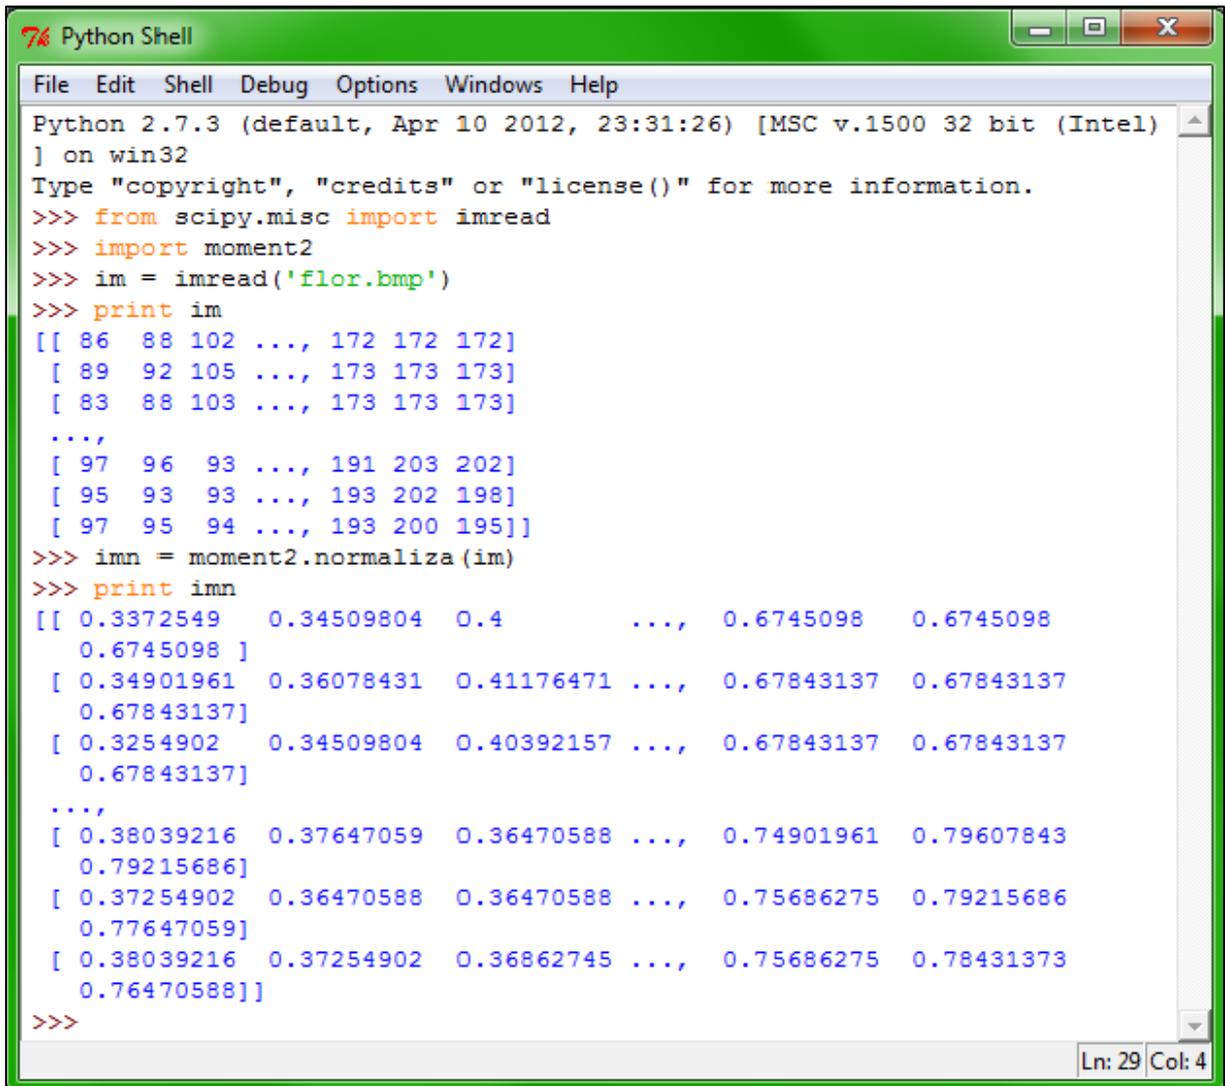
Após a normalização, os dados da matriz imagem se tornam mais fáceis de manipular, por se tratarem apenas de valores baixos. A normalização das intensidades da matriz imagem pode ser observada na Figura 14.

3.3.2.2 Gerando primitivas da imagem

Os momentos invariantes são normalmente aplicados em imagens inteiras e levam em consideração a posição de cada pixel como um fator para seus cálculos. Porém, nas imagens tomográficas existem áreas que não devem ser consideradas nas análises.

Para resolver este problema foi implementada uma função, apresentada na Figura 15, na qual a partir do conhecimento *a priori* das áreas que devem ser analisadas é possível selecionar apenas trechos de imagens ou “janelas”, de forma a torná-las reconhecíveis aos momentos invariantes.

Ao selecionar um ponto no plano cartesiano e o tamanho da nova sub-imagem, da matriz original da imagem, a função gera uma primitiva de imagem. A partir dessa seleção os elementos da matriz original são armazenados em um vetor, no qual serão aplicados os momentos invariantes.



```
Python Shell
File Edit Shell Debug Options Windows Help
Python 2.7.3 (default, Apr 10 2012, 23:31:26) [MSC v.1500 32 bit (Intel)
] on win32
Type "copyright", "credits" or "license()" for more information.
>>> from scipy.misc import imread
>>> import moment2
>>> im = imread('flor.bmp')
>>> print im
[[ 86  88 102 ..., 172 172 172]
 [ 89  92 105 ..., 173 173 173]
 [ 83  88 103 ..., 173 173 173]
 ...,
 [ 97  96  93 ..., 191 203 202]
 [ 95  93  93 ..., 193 202 198]
 [ 97  95  94 ..., 193 200 195]]
>>> imn = moment2.normaliza(im)
>>> print imn
[[ 0.3372549  0.34509804  0.4      ...,  0.6745098  0.6745098
 0.6745098 ]
 [ 0.34901961 0.36078431 0.41176471 ..., 0.67843137 0.67843137
 0.67843137]
 [ 0.3254902  0.34509804 0.40392157 ..., 0.67843137 0.67843137
 0.67843137]
 ...,
 [ 0.38039216 0.37647059 0.36470588 ..., 0.74901961 0.79607843
 0.79215686]
 [ 0.37254902 0.36470588 0.36470588 ..., 0.75686275 0.79215686
 0.77647059]
 [ 0.38039216 0.37254902 0.36862745 ..., 0.75686275 0.78431373
 0.76470588]]
>>>
```

Ln: 29 Col: 4

Figura 14 - Matriz imagem após normalização

```
#cria sub imagem
def mtrxPri(x, y1, lim, imgMtrx):
    pri = []
    tmp = 0.0
    lim1 = x+lim
    lim2 = y1+lim

    for x in range(x, lim1):

        for y in range(y1, lim2):

            tmp = imgMtrx[x][y]

            pri = pri + [tmp]
        y = y1
    return pri
```

Figura 15 - Função que gera uma primitiva de imagem

Para criar uma primitiva é preciso fornecer como parâmetro as coordenadas do pixel em que a primitiva tem início, o tamanho dela e a matriz de intensidades, já normalizada, original.

3.3.2.3 Implementação dos momentos invariantes

Para se implementar os cálculos dos momentos invariantes foi necessário implementar antes a fórmula dos momentos bidimensionais, momentos centrais e a fórmula dos momentos centrais normalizados.

A Figura 16 apresenta a função dos momentos bidimensionais, onde é necessário passar como parâmetro a ordem, p e q , o tamanho da primitiva, e o vetor de dados que representam a primitiva de imagem.

```
#Formula dos momentos 2D
def mom2d(p, q, lim, imgPri):
    c = 0
    Mpq = 0.0

    for i in range(0, lim):
        for j in range(0, lim):

            Mpq += (imgPri[c]) * (i**p) * (j**q)
            c = c + 1

    return Mpq
```

Figura 16 - Momentos bidimensionais

A partir da fórmula dos momentos bidimensionais é possível então implementar a fórmula dos momentos centrais, apresentada na Figura 17. O momento central recebe como parâmetro os mesmos itens da função dos momentos bidimensionais.

```
#Calculo do momento central
def momCent(p,q,lim,imgPri):
#Calcula x linha
    m00 = mom2d(0,0,lim,imgPri)
    m10 = mom2d(1,0,lim,imgPri)
    xL = m10/m00
    x = 0
#calcula y linha

    m01 = mom2d(0,1,lim,imgPri)
    yL = m01/m00
    y = 0

    Upq = 0.0

    c = 0

    for i in range(0,lim):
        for j in range(0,lim):
            Upq = Upq + (((i-xL)**p)*((j-yL)**q)*(imgPri[c]))
            c = c+1

    return Upq
```

Figura 17 - Momento central

Na Figura 18 pode ser observado que assim como o momento central depende do momento bidimensional, o momento central normalizado também depende do momento central e recebe os mesmos parâmetros.

```
#momentos centrais normalizados
def momCN(p,q,lim,imgPri):
    if p+q >= 2:
        gama = ((p+q)/2)+1
        Npq = (momCent(p,q,lim,imgPri))/(momCent(0,0,lim,imgPri)**gama)

    return Npq
```

Figura 18 - Momentos centrais normalizados

No caso dos momentos invariantes a ordem, $p + q$, já vem pré-definida na fórmula e não se altera, para essas funções é necessário informar como parâmetro apenas o tamanho da primitiva e o vetor de dados da primitiva. Na Figura 19 está

ilustrada a implementação dos momentos invariantes de Hu de primeira, segunda, terceira e quarta ordem (fórmulas 2.26 a 2.29 do Capítulo 2).

```
def hu1(lim,imgPri):  
  
    n20 = momCN(2,0,lim,imgPri)  
    n02 = momCN(0,2,lim,imgPri)  
  
    h1 = n20 + n02  
  
    return h1  
  
def hu2(lim,imgPri):  
  
    n20 = momCN(2,0,lim,imgPri)  
    n02 = momCN(0,2,lim,imgPri)  
    n11 = momCN(1,1,lim,imgPri)  
  
    h2 = ((n20 - n02)**2) + (4*(n11**2))  
  
    return h2  
  
def hu3 (lim,imgPri):  
  
    n30 = momCN(3,0,lim,imgPri)  
    n03 = momCN(0,3,lim,imgPri)  
    n12 = momCN(1,2,lim,imgPri)  
    n21 = momCN(2,1,lim,imgPri)  
  
    h3 = ((n30 - (3*n12))**2) + (((3*n21) - n03)**2)  
  
    return h3  
  
def hu4 (lim,imgPri):  
  
    n12 = momCN(1,2,lim,imgPri)  
    n21 = momCN(2,1,lim,imgPri)  
    n30 = momCN(3,0,lim,imgPri)  
    n03 = momCN(0,3,lim,imgPri)  
  
    h4 = (n30+n12)**2 + (n21+n03)**2  
  
    return h4
```

Figura 19 - Momentos invariantes de primeira a quarta ordem

A implementação dos momentos invariantes de quinta, sexta e sétima ordem estão ilustrados na Figura 20 (fórmulas 2.30 a 2.32 do Capítulo 2).

A partir do resultado do cálculo do momento invariante de apenas uma primitiva não é possível realizar análises estatísticas, portanto é necessário que o usuário realize esse cálculo para várias primitivas de mesmo tamanho em diferentes posições.

```

def hu5 (lim, imgPri):

    n12 = momCN(1,2,lim, imgPri)
    n21 = momCN(2,1,lim, imgPri)
    n30 = momCN(3,0,lim, imgPri)
    n03 = momCN(0,3,lim, imgPri)

    h5 = (n30 - (3*n12))*(n30 + n12)*((n30+n12)**2) - 3*((n21+n03)**2) +
        ((3*n21) - n03)*(n21+n03) * ((3*((n30+n12)**2)) - ((n21+n03)**2))

    return h5

def hu6 (lim, imgPri):

    n20 = momCN(2,0,lim, imgPri)
    n02 = momCN(0,2,lim, imgPri)
    n11 = momCN(1,1,lim, imgPri)
    n12 = momCN(1,2,lim, imgPri)
    n21 = momCN(2,1,lim, imgPri)
    n30 = momCN(3,0,lim, imgPri)
    n03 = momCN(0,3,lim, imgPri)

    h6 = ((n20-n02)*((n30+n12)**2) - ((n21+n03)**2)) +
        ((4*n11)*(n30+n12)*(n21+n03))

    return h6

def hu7 (lim, imgPri):

    n12 = momCN(1,2,lim, imgPri)
    n21 = momCN(2,1,lim, imgPri)
    n30 = momCN(3,0,lim, imgPri)
    n03 = momCN(0,3,lim, imgPri)

    h7 = (((3*n21) - n03)*(n30+n12)*((n30+n12)**2) -
        (3*((n21+n03)**2))) + (((3*n12)-n30)*(n21+n03)*
        (3*((n30+n12)**2) - ((n21+n03)**2)))

    return h7

```

Figura 20 - Momentos invariantes de quinta, sexta e sétima ordem

3.3.2.4 Verificação da homogeneidade das amostras

A homogeneidade de imagens é relativa ao tamanho da imagem ou área analisada e a distribuição espacial dos tons de cinza dos pixels.

Para a verificação da qualidade da homogeneidade das amostras foram utilizadas as medidas de variância, desvio padrão e do coeficiente de variação de Pearson.

Para estes cálculos estatísticos o resultado é inversamente proporcional à homogeneidade, ou seja, valores baixos definem alta homogeneidade.

- **Medida da Variância**

A variância Var é uma medida de dispersão estatística, que avalia o nível de dispersão em uma série de dados, sendo dada por:

$$Var = \sum_{i=1}^n \frac{(x_i - Me)^2}{n} \quad (3.1)$$

Onde n é o número de elementos da série, x_i é o valor do elemento na posição i do vetor de dados e Me é a média da série de dados. A figura 21 mostra a função implementada para realizar o cálculo da variância.

```
def variancia(vetor):
    media = 0
    soma = 0
    somatorio = 0
    var=0

    for i in range(0,len(vetor)):
        soma = soma + vetor[i]

    media = soma / len(vetor)

    for j in range(0,len(vetor)):
        somatorio = somatorio + ((vetor[j]- media)**2)

    var = somatorio / len(vetor)

    return var
```

Figura 21 - Variância

- **Medida do Desvio Padrão**

Assim como a variância o desvio padrão σ também é uma medida de dispersão estatística, ele apresenta como resultado um valor que indica a homogeneidade de uma série de dados, quanto menor o seu valor menor a dispersão dos dados, ou seja, mais homogênea é a série de dados:

$$\sigma = \sqrt{Var} \quad (3.2)$$

A Figura 22 apresenta a implementação da fórmula da medida do desvio padrão.

```
def desvPadrao(var):  
    dp = sqrt(var)  
  
    return dp
```

Figura 22 - Desvio padrão

- **Medida do Coeficiente de variação de Pearson**

O coeficiente de variação de Pearson (CVP) é uma medida de dispersão relativa, enquanto que o desvio padrão é uma medida de dispersão absoluta. Essa medida é dada pela razão entre o desvio padrão e a média referentes aos dados de uma mesma série, ou seja:

$$CVP = \frac{\sigma}{Me} \cdot 100 \quad (3.3)$$

Assim como o desvio padrão, quanto menor for o valor do CVP mais homogênea será a série, a implementação da formula é apresentada na Figura 23.

```
def coefVarPear(vetor, dp):  
    media = 0  
  
    for elem in range(0, len(vetor)):  
        media = media + vetor[elem]  
  
    media = media / len(vetor)  
  
    CVP = (dp/media) * 100  
  
    return CVP
```

Figura 23 - Coeficiente de variação de Pearson

3.3.3 Interface gráfica para interação com o usuário

Para facilitar o uso do módulo desenvolvido e realizar a interação do usuário com o sistema de análise foi desenvolvida uma interface gráfica para análise de imagens que realiza a análise de textura e fornece dados com relação a grau de homogeneidade do processo de fabricação das amostras. Ao sistema de análise foi

dados o nome de TeAS (*Texture Analysis System*). Na figura 24 é apresentada a Janela principal do TeAS.

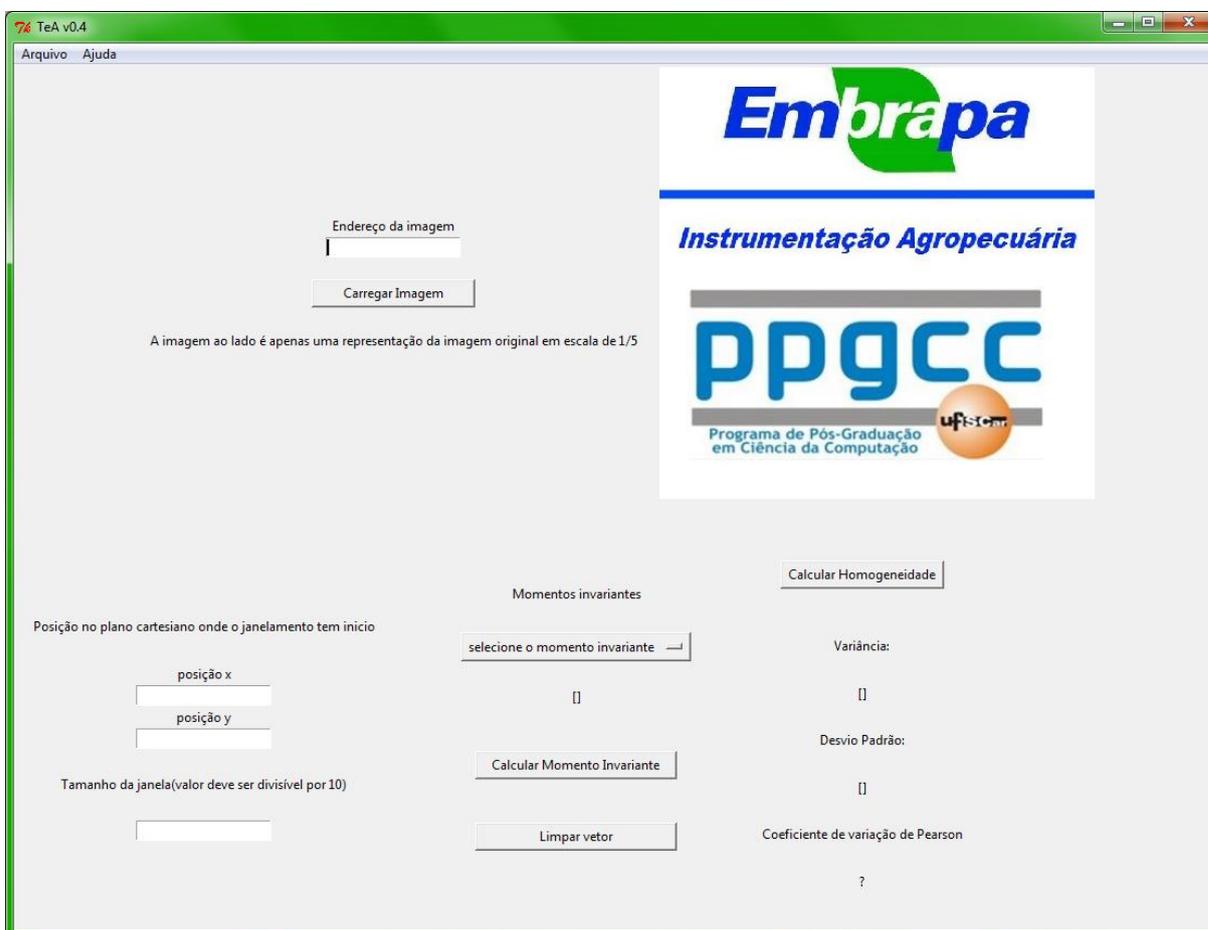


Figura 24 - Janela principal do sistema de análise de textura TeAS

A TeAS é uma interface gráfica que possui apenas os comandos necessários para realizar a análise de homogeneidade de partes selecionadas de uma determinada imagem.

A interface gráfica foi gerada a partir da ferramenta TkInter, sendo nativa da linguagem Python não necessita da instalação de nenhum módulo extra da linguagem.

Para exemplificar o processo realizado pelo TeAS desde o carregamento da imagem até a obtenção do grau de homogeneidade da imagem foi esboçado o diagrama de blocos apresentado na Figura 25.

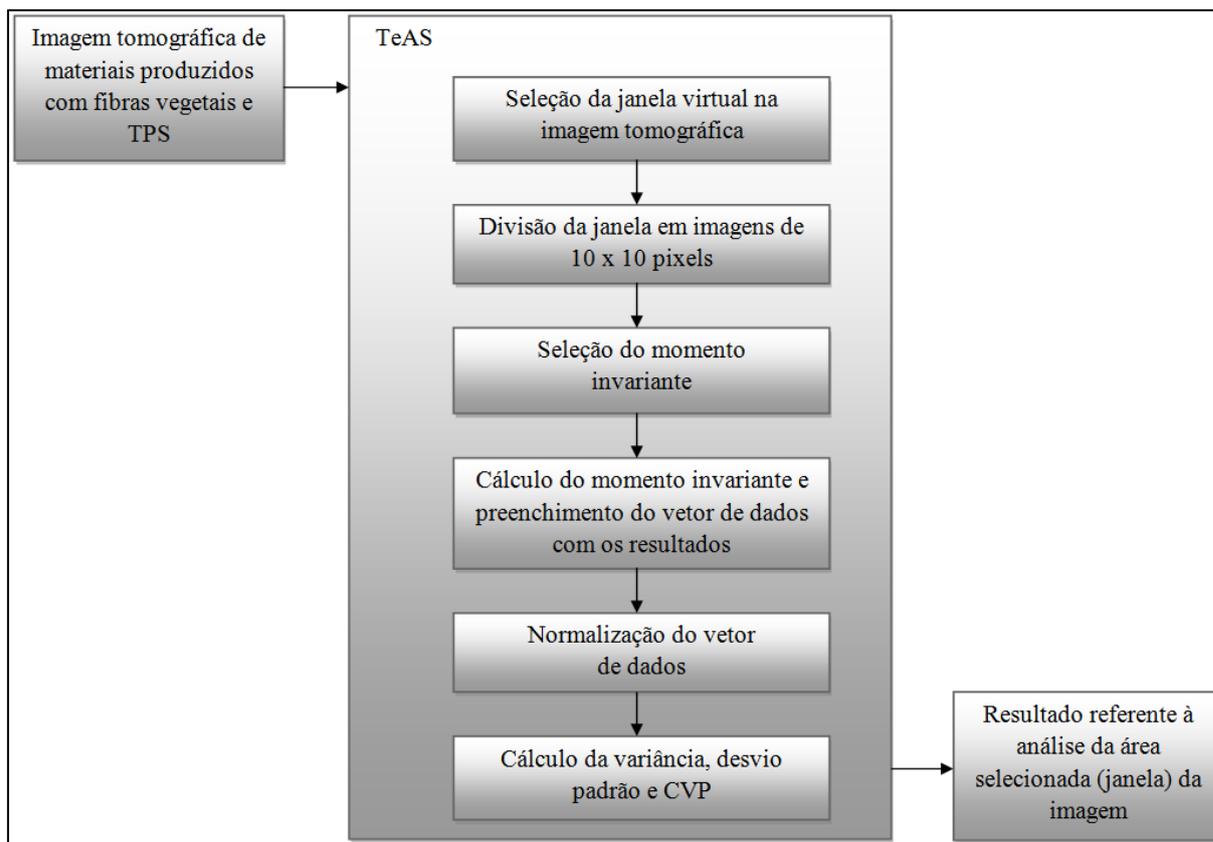


Figura 25 - Diagrama de blocos II - Processo de análise realizado pelo TeAS

Para realizar a análise o seguinte procedimento deve ser seguido:

- 1) O usuário fornece o endereço de onde a imagem se encontra na caixa de texto;
- 2) Clicar no botão “*Carregar Imagem*”, ao fazer esta ação, a imagem que está no endereço que foi fornecido será carregada e será visualizada no painel. Cada imagem tem o tamanho de 2000 x 2000 pixels, e no painel são mostradas imagens com 1/5 (400 x 400 pixels) de seu tamanho original.

O sistema apresenta capacidade de carregamento, de uma imagem por análise, sendo que, se houver a necessidade de se analisar várias imagens, o usuário devera fazê-lo considerando uma imagem de cada vez. Com esta ação a imagem também é transformada em uma matriz de intensidades e normalizada, ações e

operações ocorrem de forma transparente ao usuário. Na Figura 26 está apresentado o painel onde a imagem é carregada no sistema;

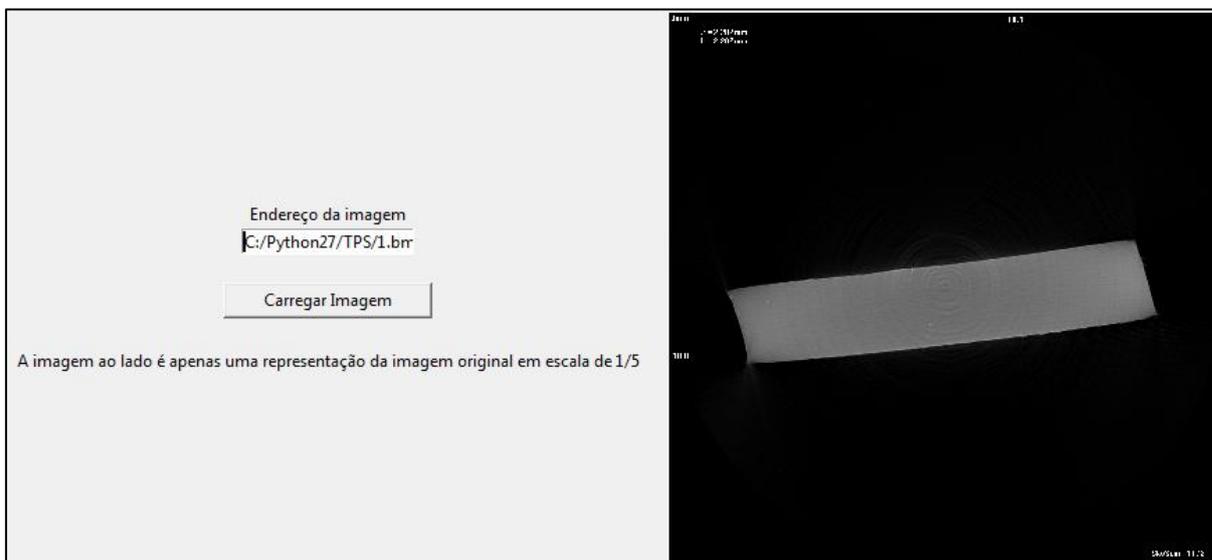


Figura 26 - Carregando uma imagem no TeAS

- 3) Em seguida o usuário deve escolher o pixel e seu posicionamento considerando de onde se dará início o janelamento da área da imagem que será analisada. As coordenadas desse pixel podem ser obtidas ao se clicar no local desejado na representação da imagem que é visualizada.

A Figura 27 mostra como as coordenadas são apresentadas ao se clicar na imagem apresentada no painel;

- 4) Informar qual o tamanho da janela que será utilizada (Figura 28). No módulo desenvolvido existe a função para a criação de apenas uma primitiva.

Para facilitar o trabalho do usuário foi implementado um algoritmo no qual o usuário faz a seleção de uma janela que será dividida em várias primitivas.

O janelamento é a seleção de uma área de tamanho quadrado que será dividida em primitivas com tamanho de 10 x 10 pixels, por isso o tamanho da área escolhida precisa ter um tamanho divisível por 10;

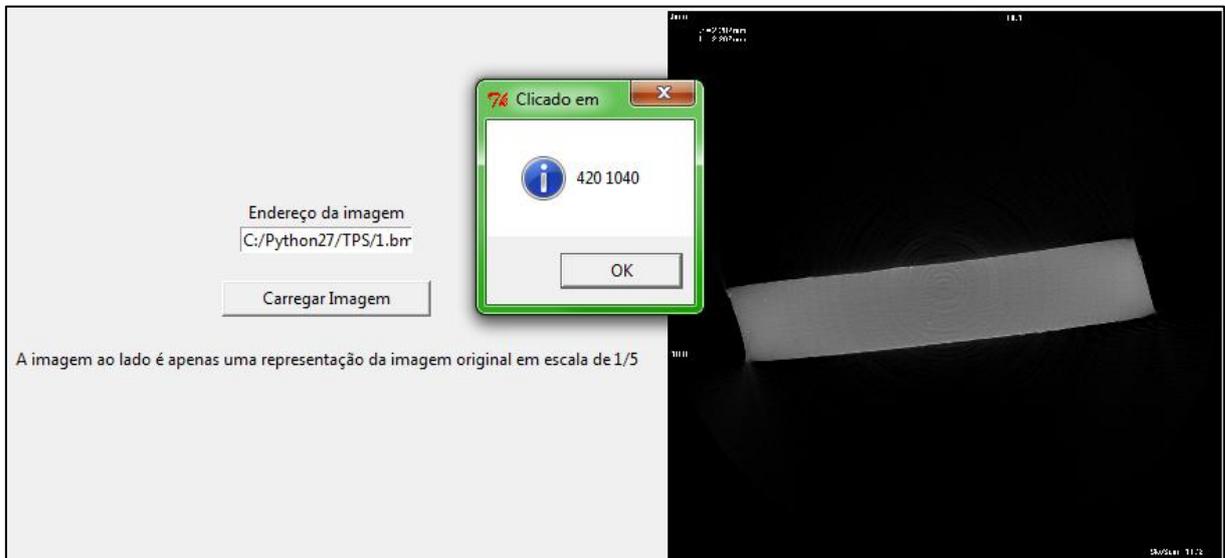


Figura 27 - Obtendo coordenadas de um pixel

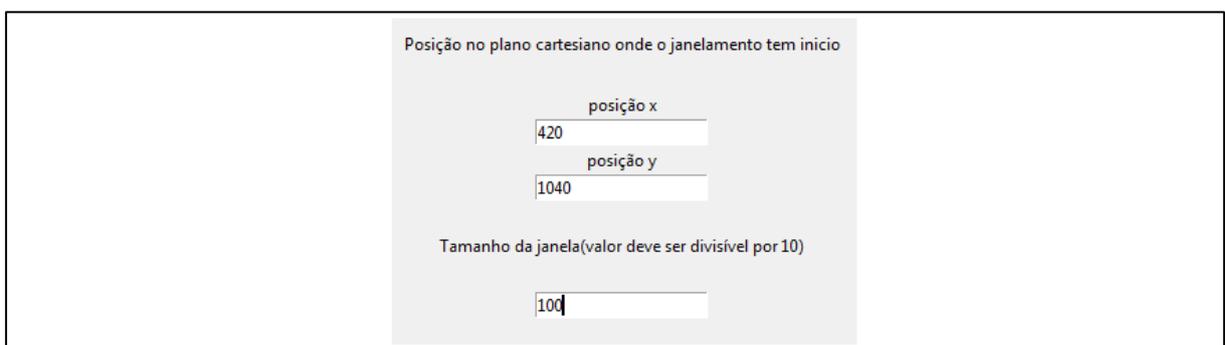


Figura 28 - Selecionando a janela para análise

- 5) Escolher o momento invariante desejado. Foi implementado um “*selection box*” no qual é possível selecionar entre o momento invariante de primeiro grau (1) até o momento de sétimo grau (7) (Figura 29).

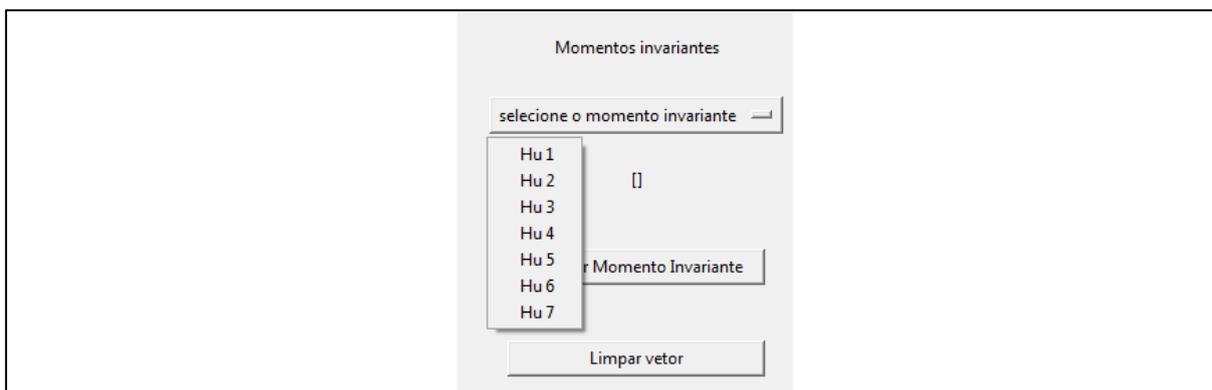


Figura 29 - Seleção do momento invariante

- 6) A seguir ao clicar no botão “*Calcular Momentos Invariantes*” será gerado um vetor com o resultado do momento invariante em cada uma das primitivas que foram criadas no janelamento (Figura 30).

Os valores apresentados no vetor são normalizados antes de realizar os cálculos estatísticos, onde todos os elementos do vetor são divididos pelo maior valor obtido. Mas para a exibição ao usuário são apresentados os dados sem a normalização e apenas os cinco primeiros resultados, uma vez que não há espaço em tela para uma exibição completa.

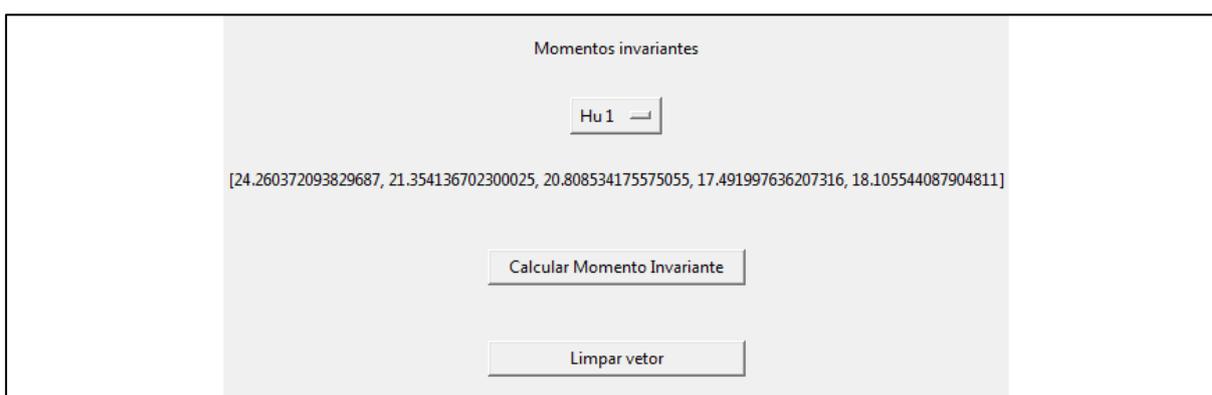


Figura 30 - Vetor de momentos invariantes das primitivas

- 7) Ao clicar o botão “*limpar vetor*” os valores contidos no vetor responsável por armazenar os dados obtidos do cálculo do momento invariante das primitivas é esvaziado.

- 8) Com o vetor preenchido com os momentos invariantes das primitivas é possível realizar agora os cálculos estatísticos, o que ocorre ao clicar no botão “*Calcular Homogeneidade*”. Assim serão retornados três valores estatísticos com base no vetor de dados, a variância, o desvio padrão e o coeficiente de variação de Pearson (Figura 31).



Figura 31 - Cálculo da homogeneidade da imagem

As imagens tomográficas são imagens extraídas de diferentes profundidades ou planos ao longo do material exposto de forma que a partir de um conjunto é possível reconstituí-lo em 3D. Essas imagens também são conhecidas como secções, camadas, fatias, cortes, entre outros.

O TeAS não é capaz de analisar grupos de imagens, pois em alguns casos, para cada secção o material se encontrava em uma posição diferente no plano em comparação a imagem anterior ou posterior.

3.4 Conclusão do capítulo

Neste capítulo foram apresentadas as etapas realizadas para o desenvolvimento do método com base no processamento digital de imagens para análise da qualidade de novos materiais baseados em fibras vegetais.

Capítulo 4

RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados e as discussões sobre os experimentos realizados para a avaliação do método desenvolvido.

4.1 Validação do método

Primeiramente, foi realizado um experimento para validar o método, antes de aplicá-lo as imagens tomográficas das amostras de novos materiais biodegradáveis.

O experimento consistiu em analisar quatro imagens amostrais, para verificar sua homogeneidade. As imagens foram batizadas de “Parede”, “Isopor”, “Tecido”, “Arte abstrata”, “Madeira”, “Gramma”, “Mármore”, “Pedras” (Figura 32).

As imagens utilizadas foram escolhidas apresentando diferentes níveis de homogeneidade, sendo que, por simples observação é possível dizer que a imagem “Parede” é a mais homogênea, seguida pelas imagens “Isopor”, “Tecido”, “Arte abstrata”, “Madeira”, “Gramma”, “Mármore” e “Pedras”.

Uma vez que o TeAS foi desenvolvido originalmente para analisar imagens tomográficas que normalmente são apresentadas em escala de cinza, as imagens foram convertidas para escala de cinza contendo apenas 256 níveis diferentes de cinza. Foram também redimensionadas, assumindo o tamanho de 400 x 400 pixels, por questão de padronização.

Para o teste, foi selecionada de cada uma das imagens, uma janela de 50 x 50 pixels, gerando um total de 25 primitivas, com 10 x 10 pixels cada e conseqüentemente um vetor de dados com 25 elementos para cada um dos 7 momentos invariantes.

Em seguida foi realizada a normalização dos dados, onde o maior valor do vetor de dados é dividido por todos os elementos do mesmo, em seguida foram aplicadas as fórmulas da variância, desvio padrão e CVP.

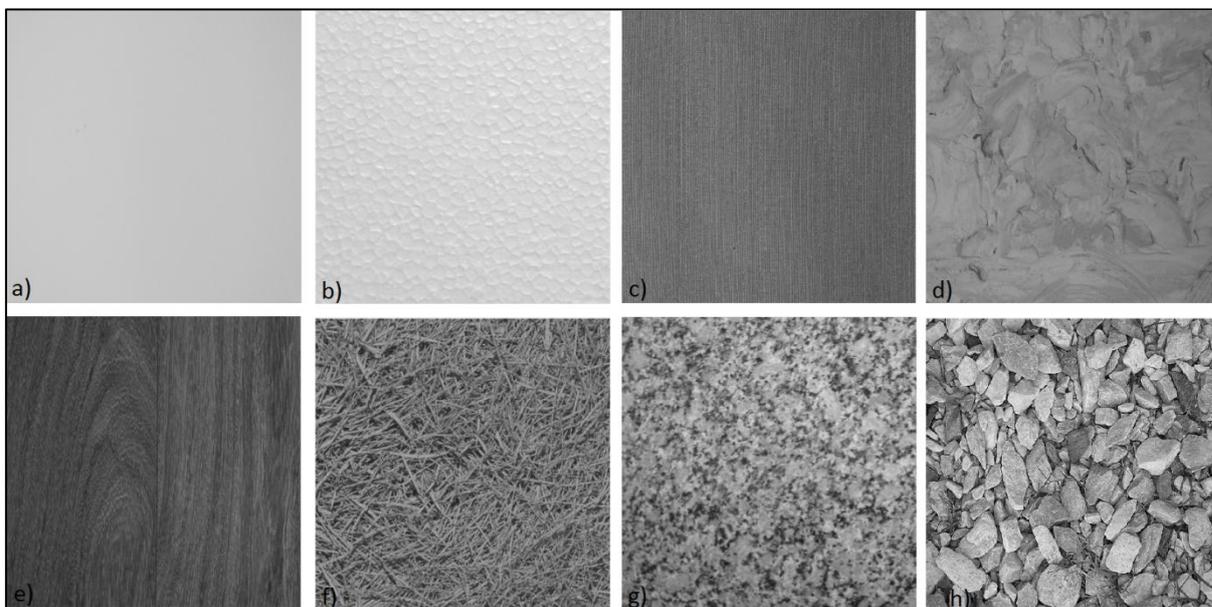


Figura 32 - Imagens amostrais para o primeiro experimento, a) "Parede"; b) "Isopor"; c) "Tecido"; d) "Arte abstrata"; e) "Madeira"; f) "Gramma"; g) "Mármore"; h) "Pedras".

Os valores esperados como resultado dos cálculos estatísticos para a análise das imagens amostrais são valores crescentes sendo que os menores valores devem ser da imagem "Parede", seguida das imagens "Tecido", "Arte abstrata" e "Pedras" respectivamente. Para os casos apresentados o cálculo do desvio padrão deve apresentar valores entre 0 e 1 e para o CVP valores entre 0 e 100.

Logo nos resultados da imagem "Parede" é possível observar que para o momento invariante Φ_5 o desvio padrão ultrapassa o resultado esperado e nos momentos invariantes Φ_2 , Φ_3 , Φ_5 , Φ_6 e Φ_7 o CVP também não apresentam o resultado dentro do esperado (Tabela 2).

Tabela 2 - Resultado da análise de homogeneidade da imagem "Parede"

<i>Parede</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,99	2,74E-01	2,08E-01	2,83E-01	-3,90E-01	2,95E-02	8,90E-02
<i>Var</i>	3,47E-05	7,62E-02	4,64E-02	7,40E-02	1,07	2,45E-01	6,86E-02
<i>D.P</i>	5,887E-03	2,76E-01	2,15E-01	2,72E-01	1,04	0,495	2,62E-01
<i>CVP</i>	0,59	101	104	96,103	-265,92	1678,31	294,10

Na análise da imagem “Isopor” os momentos Φ_5 , Φ_6 e Φ_7 , os resultados do cálculo do CVP, ultrapassam o valor esperado, para o cálculo do desvio padrão dos momentos Φ_2 e Φ_5 , o esperado é que os valores fossem maiores que os obtidos na imagem “Parede” (Tabela 3).

Tabela 3 - Resultado da análise de homogeneidade da imagem "Isopor"

<i>Isopor</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,966	0,222	0,294	0,294	0,017	0,012	0,101
<i>Var</i>	1,35E-04	0,073	0,081	0,088	0,076	0,352	0,136
<i>D.P</i>	0,012	0,271	0,284	0,296	0,275	0,594	0,368
<i>CVP</i>	1,204	21,964	96,539	100,888	1645,036	4949,768	363,477

Na análise da imagem “Tecido” momentos invariantes os Φ_5 , Φ_6 e Φ_7 , os resultados para o cálculo do CVP, não são os esperados.

É possível perceber também que para os momentos invariantes Φ_4 , Φ_6 e Φ_7 o desvio padrão não foi maior do que na análise da imagem “Parede” (Tabela 4).

Tabela 4 - Resultado da análise de homogeneidade da imagem "Tecido"

<i>Tecido</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,955	3,14E-01	4,40E-01	2,58E-01	-7,16E-02	-4,38E-03	-6,08E-02
<i>Var</i>	3,18E-04	7,61E-02	9,36E-02	4,96E-02	3,04E-01	2,98E-01	1,00E-01
<i>D.P</i>	0,017	2,76E-01	3,06E-01	2,23E-01	5,51E-01	0,545	3,16E-01
<i>CVP</i>	1,86	88	70	86,37	-769,47	-12449,6	-520

Na análise da imagem “Arte abstrata” os momentos invariantes Φ_2 , Φ_3 , Φ_4 , Φ_5 , Φ_6 e Φ_7 não retornam os resultados esperados para o cálculo do CVP e os momentos invariantes Φ_2 , Φ_3 , Φ_4 e Φ_5 apresentam valores menores do que os já obtidos nas imagens anteriores (Tabela 4).

Tabela 5 - Resultado da análise de homogeneidade da imagem "Arte abstrata"

<i>Arte Abstrata</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,951	1,78E-01	1,04E-01	1,51E-0	8,09E-02	7,10E-02	-0,023
<i>Var</i>	1,08E-03	5,70E-02	4,04E-02	6,06E-02	7,20E-02	3,31E-01	1,44E-01
<i>D.P</i>	0,032	2,39E-01	2,01E-01	2,46E-01	2,68E-01	0,575	3,80E-01
<i>CVP</i>	3,45	134	194	163,05	331,818	810,99	-1650,5

Na análise da imagem “Madeira” os momentos invariantes Φ_4 , Φ_5 , Φ_6 e Φ_7 não retornam valores esperados no cálculo do CVP e para o cálculo do desvio padrão os mesmos apresentam valores inferiores aos obtidos na imagem “Arte abstrata”, o esperado eram valores maiores, representando uma maior rugosidade que as imagens anteriores (Tabela 6).

Tabela 6 - Resultado da análise de homogeneidade da imagem "Madeira"

<i>Madeira</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,897	0,284	0,363	0,149	0,077	-0,033	0,066
<i>Var</i>	1,52E-3	0,062	0,094	0,056	0,061	0,312	0,063
<i>D.P</i>	0,039	0,250	0,306	0,237	0,246	0,558	0,251
<i>CVP</i>	4,358	87,960	84,282	159,211	318,043	-1667,937	379,858

Na análise da imagem “Grama” Φ_3 , Φ_4 , Φ_5 , Φ_6 e Φ_7 não retornam os resultados esperados para o cálculo do CVP e no cálculo do desvio padrão dos momentos Φ_3 , Φ_4 e Φ_6 retornaram um valor menor que os obtidos na imagem “Madeira” (Tabela 7).

Tabela 7 – Resultado da análise de homogeneidade da imagem “Grama”

<i>Grama</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,821	0,343	0,175	0,111	0,013	0,013	-0,043
<i>Var</i>	6,13E-3	0,092	0,055	0,045	0,062	0,126	0,136
<i>D.P</i>	0,078	0,303	0,234	0,213	0,249	0,355	0,368
<i>CVP</i>	9,539	88,209	133,509	191,788	1897,243	2776,445	-860,525

Na análise da imagem “Mármore” os momentos invariantes Φ_2 , Φ_3 , Φ_4 , Φ_5 , Φ_6 e Φ_7 não apresentam os valores esperados no cálculo do CVP e o desvio padrão para o momento invariante Φ_2 foi menor que o da imagem “Grama” (Tabela 8).

Tabela 8 – Resultado da análise de homogeneidade da imagem "Mármore"

<i>Mármore</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,749	0,243	0,191	0,219	0,057	0,037	-0,094
<i>Var</i>	0,012	0,068	0,065	0,082	0,096	0,206	0,295
<i>D.P</i>	0,109	0,261	0,256	0,286	0,309	0,453	0,543
<i>CVP</i>	14,551	107,330	134,010	130,498	544,539	1241,460	-580,397

Na análise da imagem “Pedras” os momentos invariantes Φ_2 , Φ_3 , Φ_4 , Φ_5 , Φ_6 e Φ_7 não apresentam os valores esperados no cálculo do CVP e o desvio padrão para os momentos invariantes Φ_2 , Φ_3 , Φ_4 , foram menores que os obtidos na imagem “Mármore” e no momento invariante Φ_5 o valor ultrapassou o resultado esperado (Tabela 9).

Tabela 9 - Resultado da análise de homogeneidade da imagem "Pedras"

<i>Pedras</i>	<i>M.I. 1</i>	<i>M.I. 2</i>	<i>M.I. 3</i>	<i>M.I. 4</i>	<i>M.I. 5</i>	<i>M.I. 6</i>	<i>M.I. 7</i>
<i>Média</i>	0,64	1,69E-0	1,06E-01	9,92E-02	-2,94E-01	-0,111	-0,299
<i>Var</i>	2,61E-02	5,54E-02	4,15E-02	4,38E-02	2,92	2,20E-01	9,95E-01
<i>D.P</i>	0,16	2,35E-01	2,04E-01	2,09E-01	1,71	0,468	9,98E-01
<i>CVP</i>	25,22	139	193	211,06	-581,99	-420,09	-332,8

De acordo com o experimento pôde-se notar que apenas o momento invariante Φ_1 apresenta resultados de forma crescente e dentro dos resultados esperados, no cálculo do CVP e no desvio padrão.

Os resultados de Φ_1 obtidos pelo cálculo do CVP e desvio padrão representam a homogeneidade, porém através de tipos de dados diferentes, que não necessariamente possuem uma relação direta. Sendo que no cálculo do CVP o resultado é dado em porcentagem, e é inversamente proporcional a homogeneidade, por exemplo, a área analisada da imagem “Parede” retornou como resultado o valor 0,59 pelo cálculo do CVP, isso significa que a janela analisada é 99,41% homogênea.

Já os resultados apresentados pelo desvio padrão apresentam o grau de dispersão dos valores da série de dados com relação à média, ou neste caso pode ser considerado como sendo o grau de rugosidade das imagens variando entre 1 e 0 sendo que quanto maior o valor maior a rugosidade.

O próximo passo trata-se de aplicar o método nas imagens tomográficas das amostras de novos materiais biodegradáveis.

Como o experimento anterior revelou que apenas Φ_1 apresentou resultados dentro do interesse, o mesmo foi usado para a aplicação do método nas imagens tomográficas.

4.2 Aplicação do método

Para este segundo experimento, cada um dos grupos de imagens tomográficas foi dividido em cinco grupos menores e duas imagens de cada grupo foram selecionadas aleatoriamente.

Não foram utilizadas todas as imagens tomográficas, pois devido ao tempo limite estabelecido para o desenvolvimento deste projeto, não foi possível desenvolver um algoritmo que realizasse a tarefa de forma automática, sendo que como explicado no capítulo anterior só é possível carregar uma imagem por análise no TeAS.

Como explicado no capítulo anterior, às imagens tomográficas são secções que percorrem todo material reconstituindo-o em três dimensões. Porém, muitas vezes a amostra de material não possui forma regular e a posição do material muda no plano de acordo com o nível em que a secção se encontra.

Desenvolver uma solução adequada para este problema demandaria uma grande quantidade de tempo e ultrapassaria o prazo de entrega deste trabalho. Porém foi aplicada uma solução parcial para amenizar este problema, onde pequenos ajustes foram feitos no momento de escolher o posicionamento do janelamento em cada uma das imagens tomográficas.

Na seleção da janela foi contada a distância em pixels percorrida pela amostra entre uma imagem e outra e desta forma na escolha da janela esse valor foi adicionado ou subtraído de acordo com o deslocamento no plano.

Para cada imagem tomográfica (Figuras 33 a 45) foi selecionada uma janela de 100 x 100 pixels, gerando 100 imagens menores de 10 x 10 pixels para cada janela e conseqüentemente um vetor de dados com 100 elementos.

Para uma melhor visualização foi aplicado um filtro de pseudo-cor nas imagens. Porém, as imagens utilizadas para análise estão todas em escala de cinza.

Após os cálculos do desvio padrão e CVP para cada uma das 10 imagens, foi possível calcular a média desses valores, e dessa forma a homogeneidade média da janela selecionada das amostras. O resultado obtido neste experimento é apresentado nas páginas seguintes.

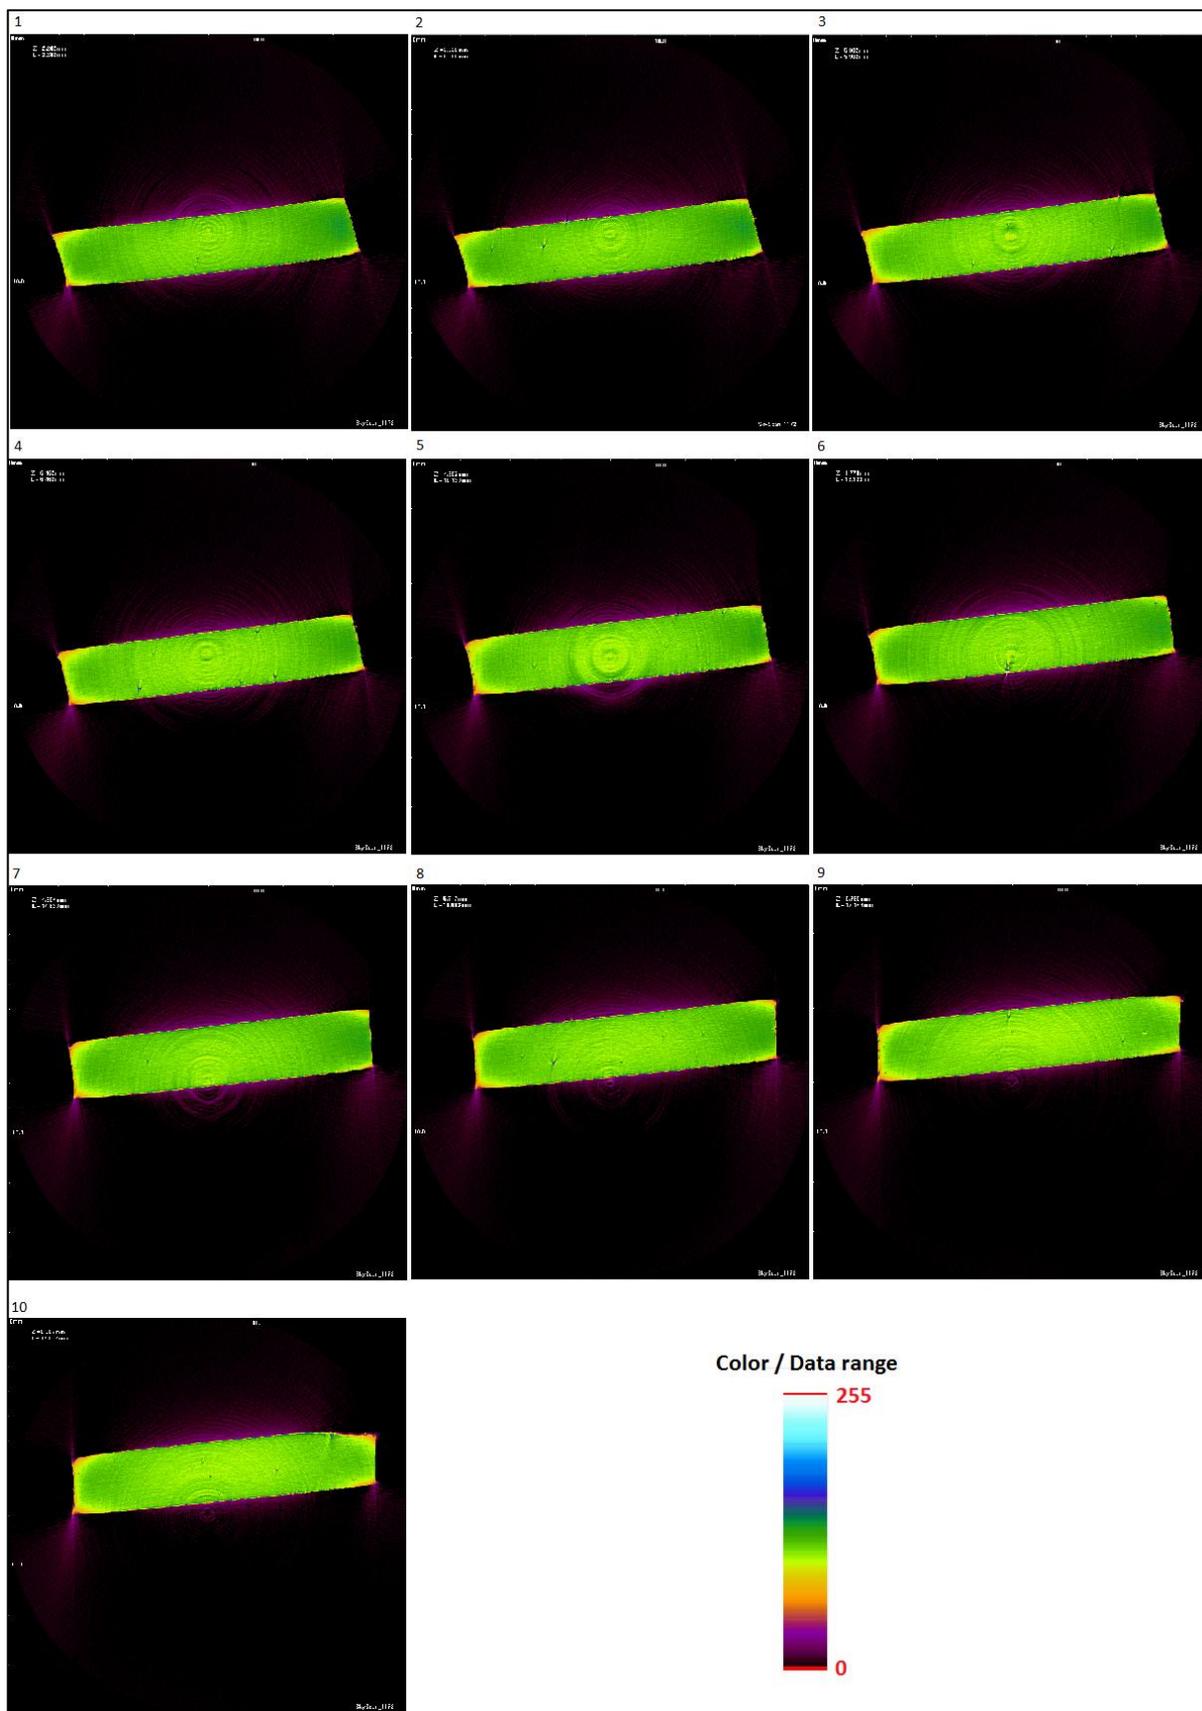


Figura 33 - Imagens tomográficas da amostra de TPS utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra de TPS, na janela selecionada a homogeneidade média obtida foi de 69,41% pelo cálculo do CVP e um grau de rugosidade de 0,137 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 10).

Tabela 10 - Resultado da análise da amostra de TPS

<i>TPS</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I* pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
<i>1</i>	410x1060	0,0170	0,130	26,820
<i>2</i>	410x1060	0,0162	0,127	35,168
<i>3</i>	410x1035	0,0248	0,157	30,136
<i>4</i>	410x1035	0,0174	0,132	31,549
<i>5</i>	410x975	0,0179	0,133	37,258
<i>6</i>	410x975	0,0256	0,160	31,995
<i>7</i>	410x865	0,0183	0,135	28,644
<i>8</i>	410x865	0,0173	0,131	30,725
<i>9</i>	410x785	0,0190	0,138	27,337
<i>10</i>	410x785	0,0169	0,130	26,304
	<i>Média</i>	0,0190	0,137	30,593

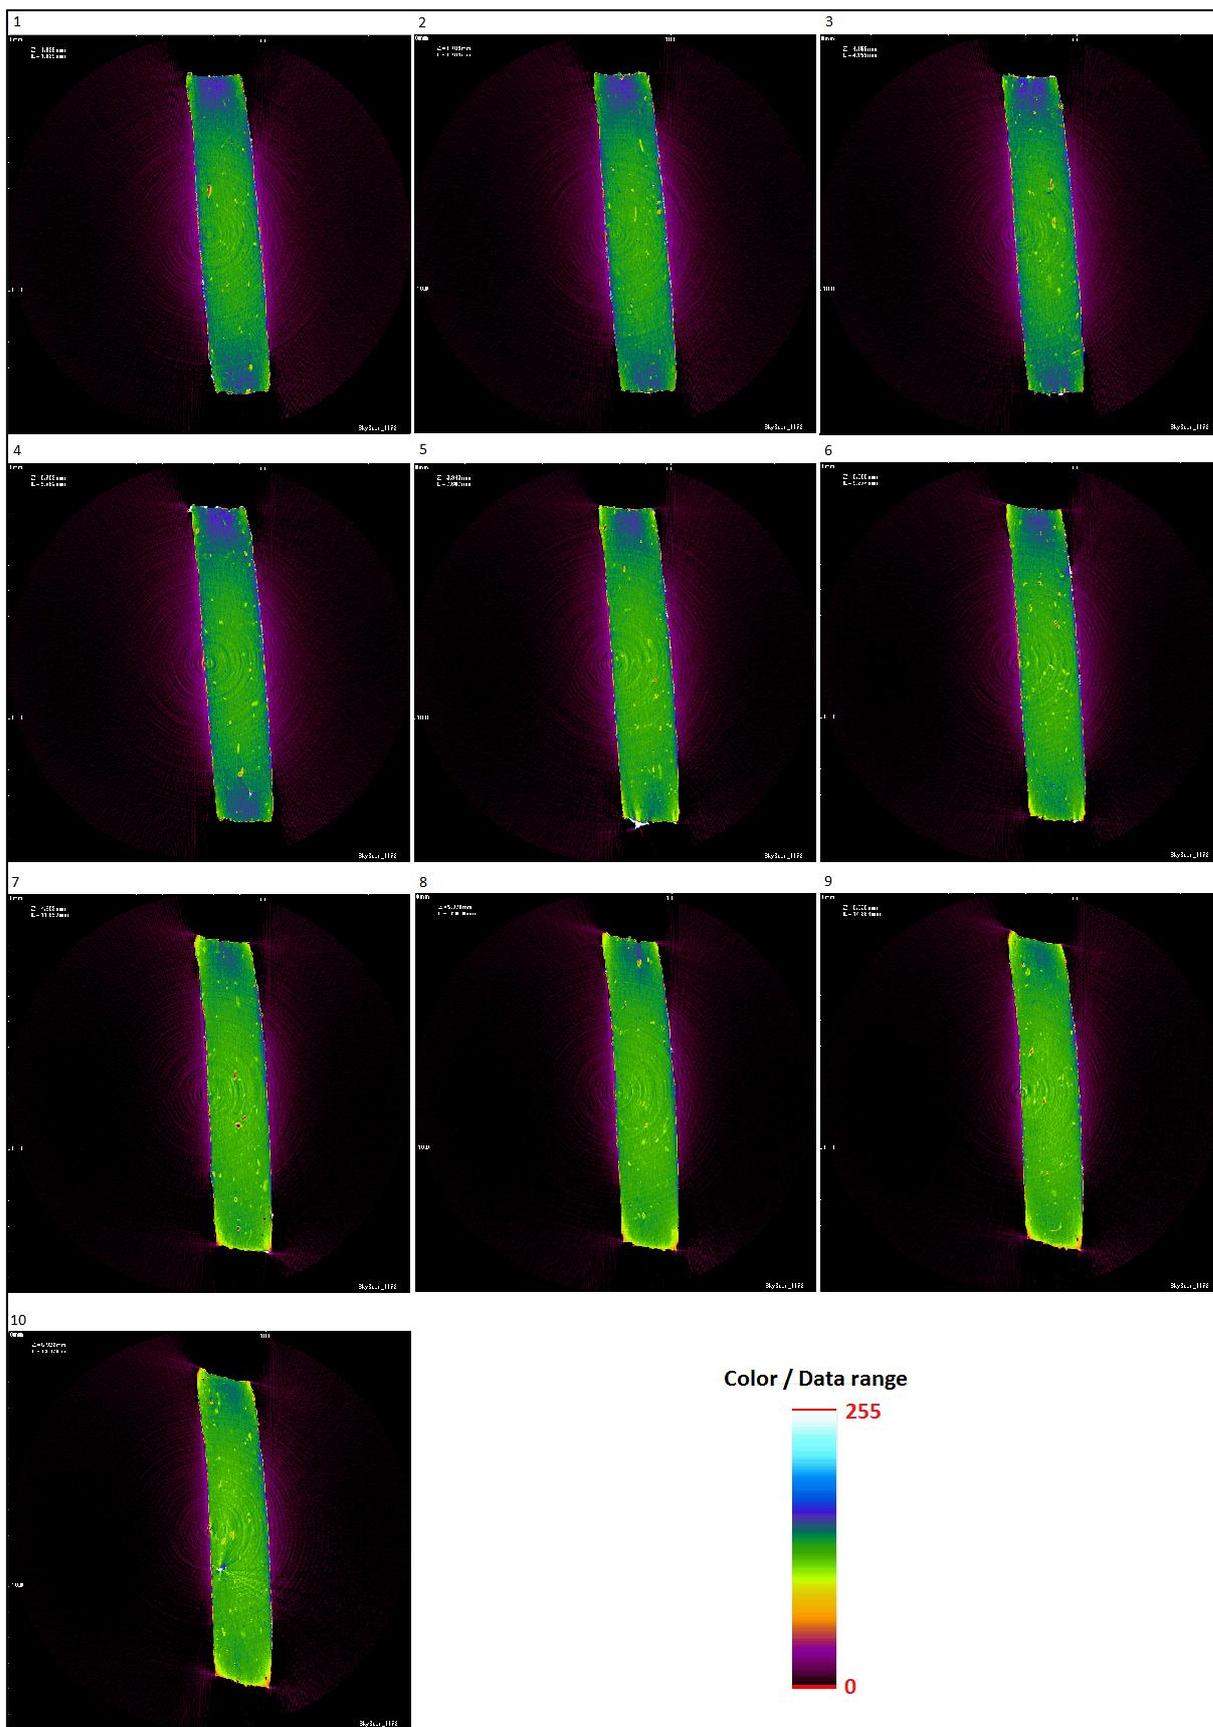


Figura 34 - Imagens tomográficas da amostra de Acurí 5% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 5% de Acurí, na janela selecionada a homogeneidade média obtida foi de 53,84% pelo cálculo do CVP e um grau de rugosidade de 0,147 pelo cálculo do desvio padrão (Tabela 11).

Tabela 11 - Resultado da análise da amostra com 5% de Acurí

<i>Acuri 5%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I* pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
1	1130x1430	0,0192	0,138	22,960
2	1130x1430	0,0164	0,128	21,857
3	1140x1430	0,0162	0,127	23,126
4	1140x1430	0,0147	0,121	25,183
5	1157x1430	0,0207	0,143	43,446
6	1157x1430	0,0276	0,166	42,206
7	1157x1430	0,0218	0,147	71,763
8	1157x1430	0,0384	0,196	53,414
9	1157x1430	0,0223	0,149	61,619
10	1157x1430	0,0244	0,156	95,960
	<i>Média</i>	0,0222	0,147	46,153

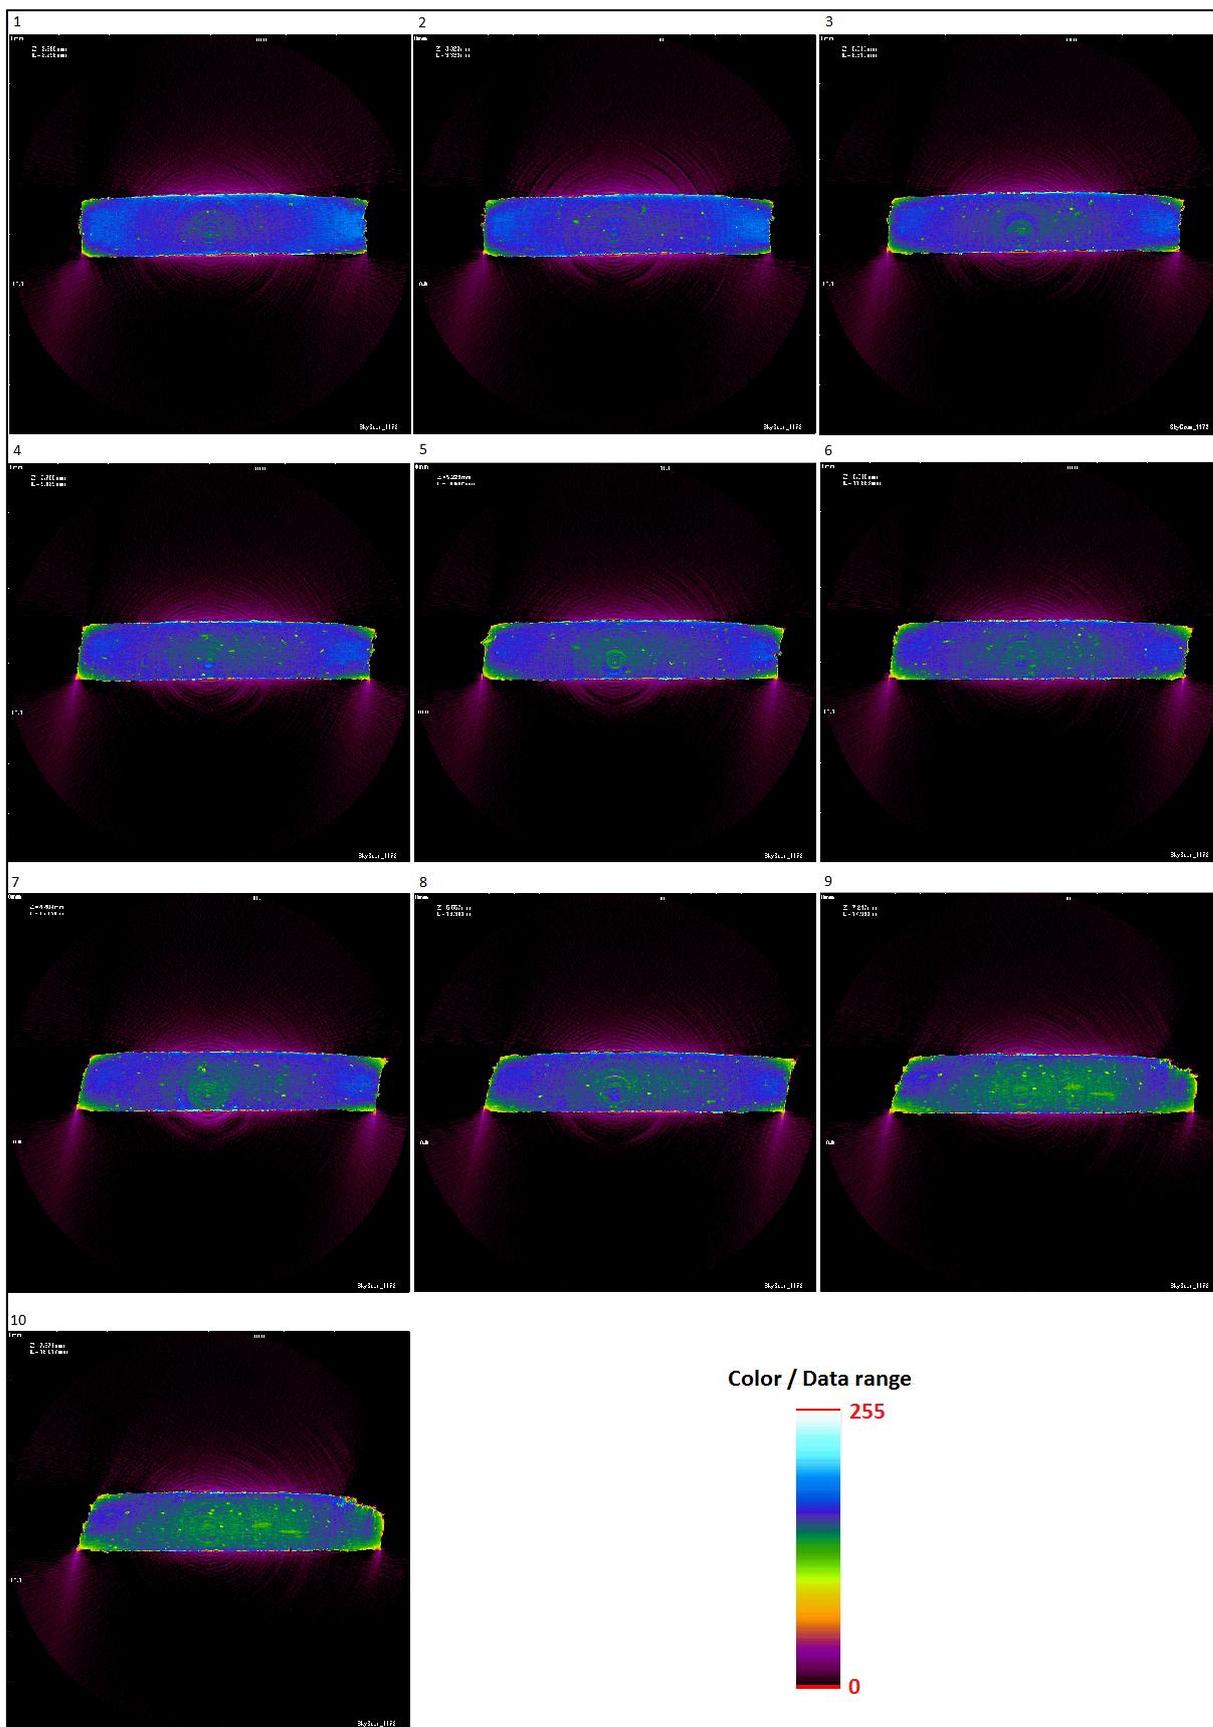


Figura 35 - Imagens tomográficas da amostra de Acríl 10% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 10% de Acurí, na janela selecionada a homogeneidade média obtida foi de 72,37% pelo cálculo do CVP e um grau de rugosidade de 0,137 pelo cálculo do desvio padrão do momento invariante Φ_1 (Tabela 12).

Tabela 12 - Resultado da análise da amostra com 10% de Acurí

<i>Acurí 10%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição 1° pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
1	460x930	0,0159	0,126	22,823
2	460x930	0,0239	0,154	25,869
3	460x930	0,0187	0,136	25,379
4	460x930	0,0258	0,160	27,432
5	460x930	0,0160	0,126	30,831
6	460x930	0,0239	0,154	30,340
7	460x930	0,0140	0,118	29,061
8	460x930	0,0239	0,154	30,340
9	460x930	0,0140	0,118	29,061
10	460x930	0,0146	0,121	25,146
	<i>Média</i>	0,0191	0,137	27,628

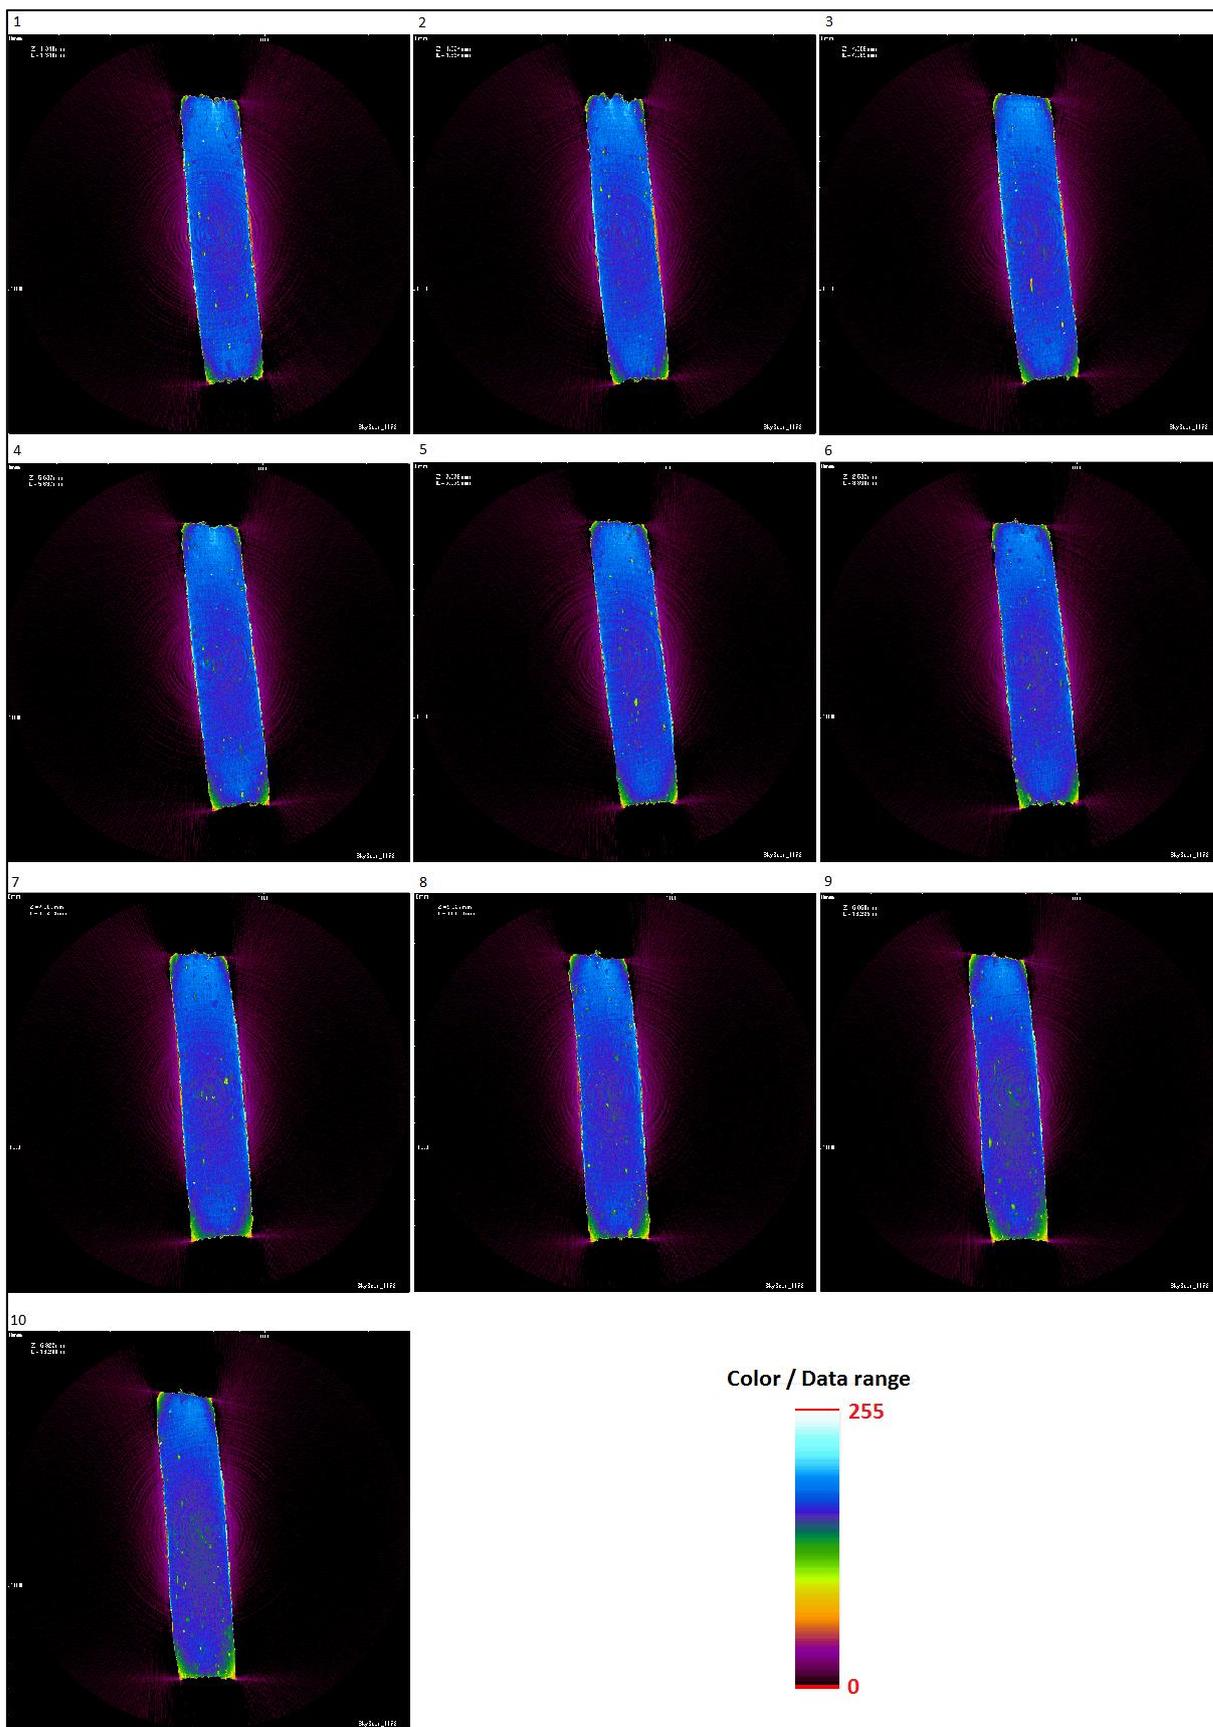


Figura 36 - Imagens tomográficas da amostra de Acurí 15% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 15% de Acurí, na janela selecionada a homogeneidade média obtida foi de 21,03% pelo cálculo do CVP e um grau de rugosidade de 0,157 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 13).

Tabela 13 - Resultado da análise da amostra com 15% de Acurí

<i>Acuri 15%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I* pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
<i>1</i>	1030x1410	0,0296	0,172	51,378
<i>2</i>	1030x1410	0,0245	0,156	55,261
<i>3</i>	1050x1410	0,0410	0,202	49,468
<i>4</i>	1050x1410	0,0136	0,116	66,983
<i>5</i>	1080x1410	0,0161	0,126	86,359
<i>6</i>	1080x1410	0,0330	0,181	54,274
<i>7</i>	975x1410	0,0293	0,171	57,935
<i>8</i>	975x1410	0,0150	0,122	98,832
<i>9</i>	905x1410	0,0389	0,197	97,362
<i>10</i>	905x1410	0,0157	0,125	171,942
	<i>Média</i>	0,0257	0,157	78,979

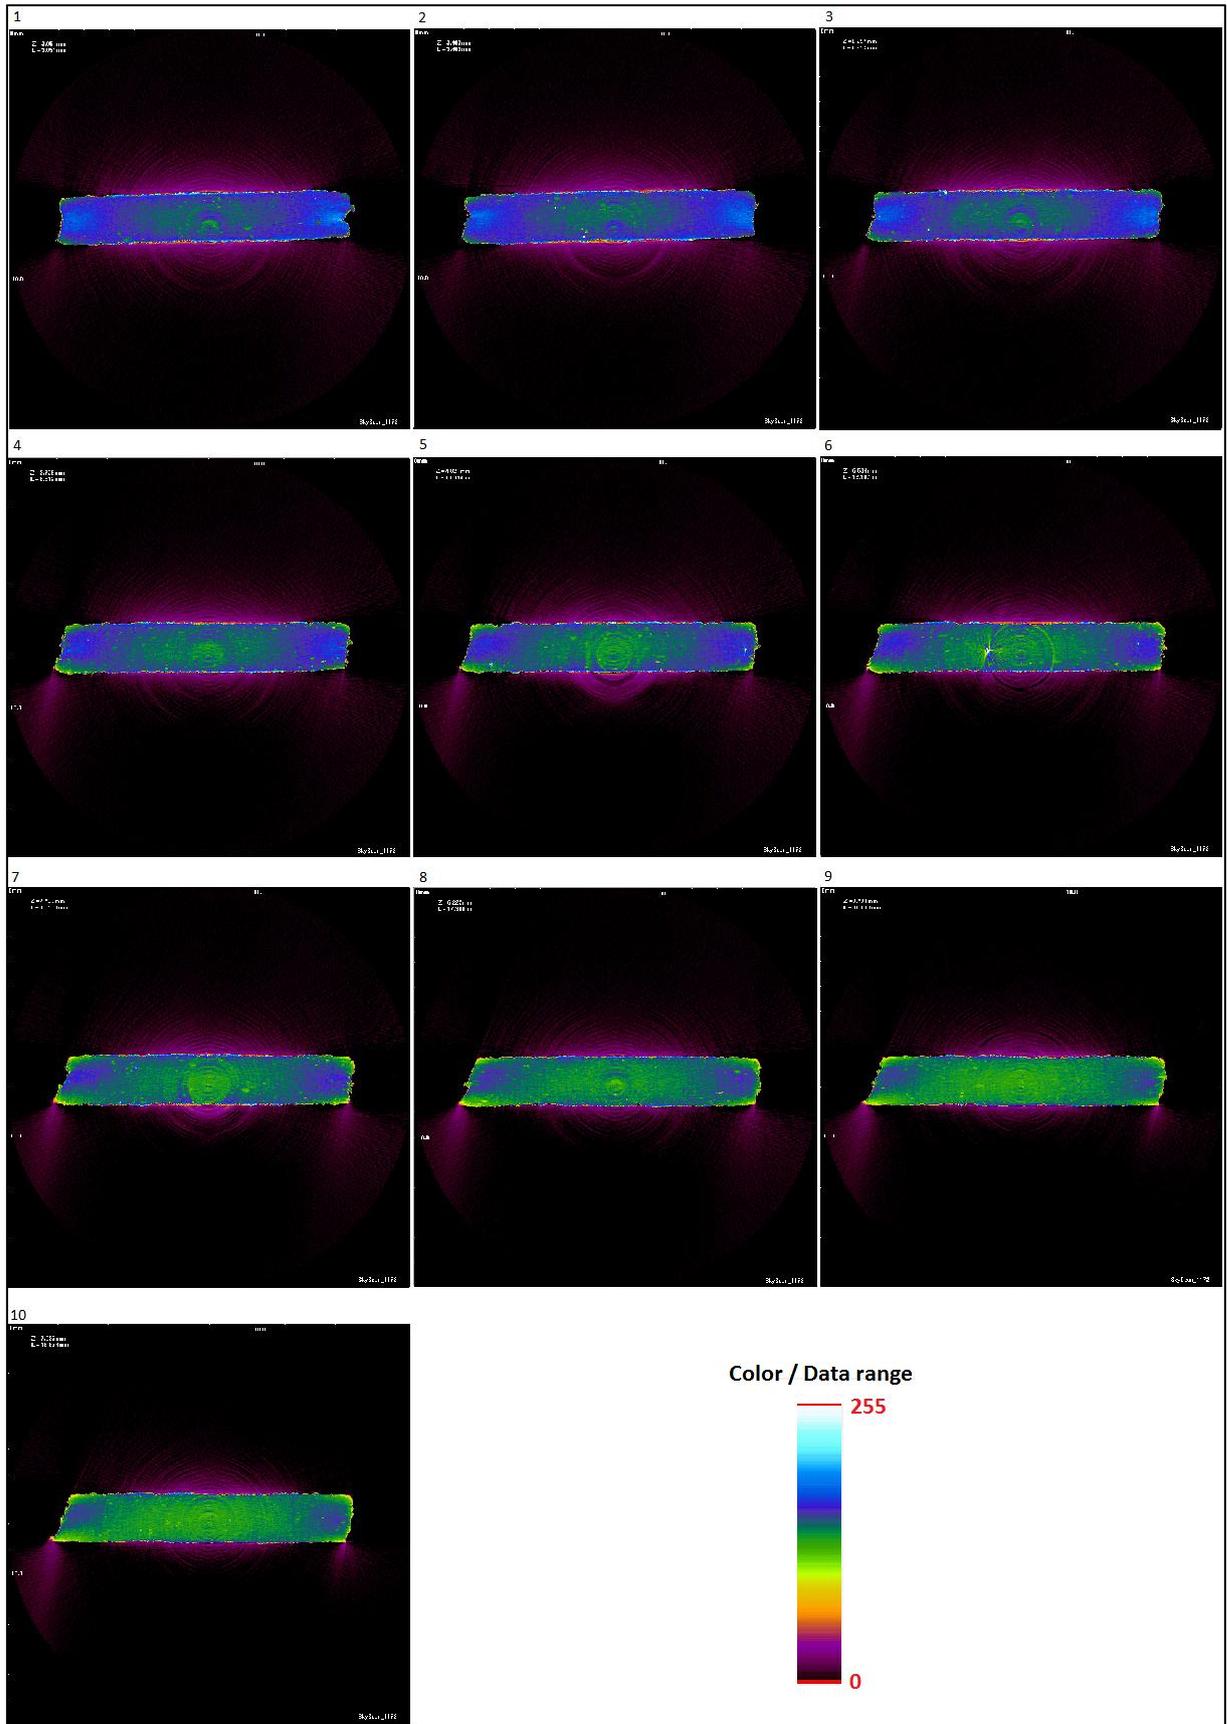


Figura 37 - tomográficas da amostra de Acurí 20% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 20% de Acurí, na janela selecionada a homogeneidade média obtida foi de 50,19% pelo cálculo do CVP e um grau de rugosidade de 0,140 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 14).

Tabela 14 - Resultado da análise da amostra com 20% de Acurí

<i>Acuri 20%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P</i>
<i>Imagem</i>	<i>Posição 1° pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
1	390x905	0,0152	0,123	31,896
2	390x905	0,0143	0,119	34,253
3	390x905	0,0210	0,145	29,959
4	390x905	0,0177	0,133	31,365
5	390x915	0,0206	0,143	30,712
6	390x915	0,0251	0,158	42,458
7	390x925	0,0215	0,146	52,347
8	390x925	0,0253	0,159	43,420
9	390x925	0,0179	0,134	82,0468
10	390x925	0,0207	0,144	119,7
	Média	0,0199	0,140	49,815

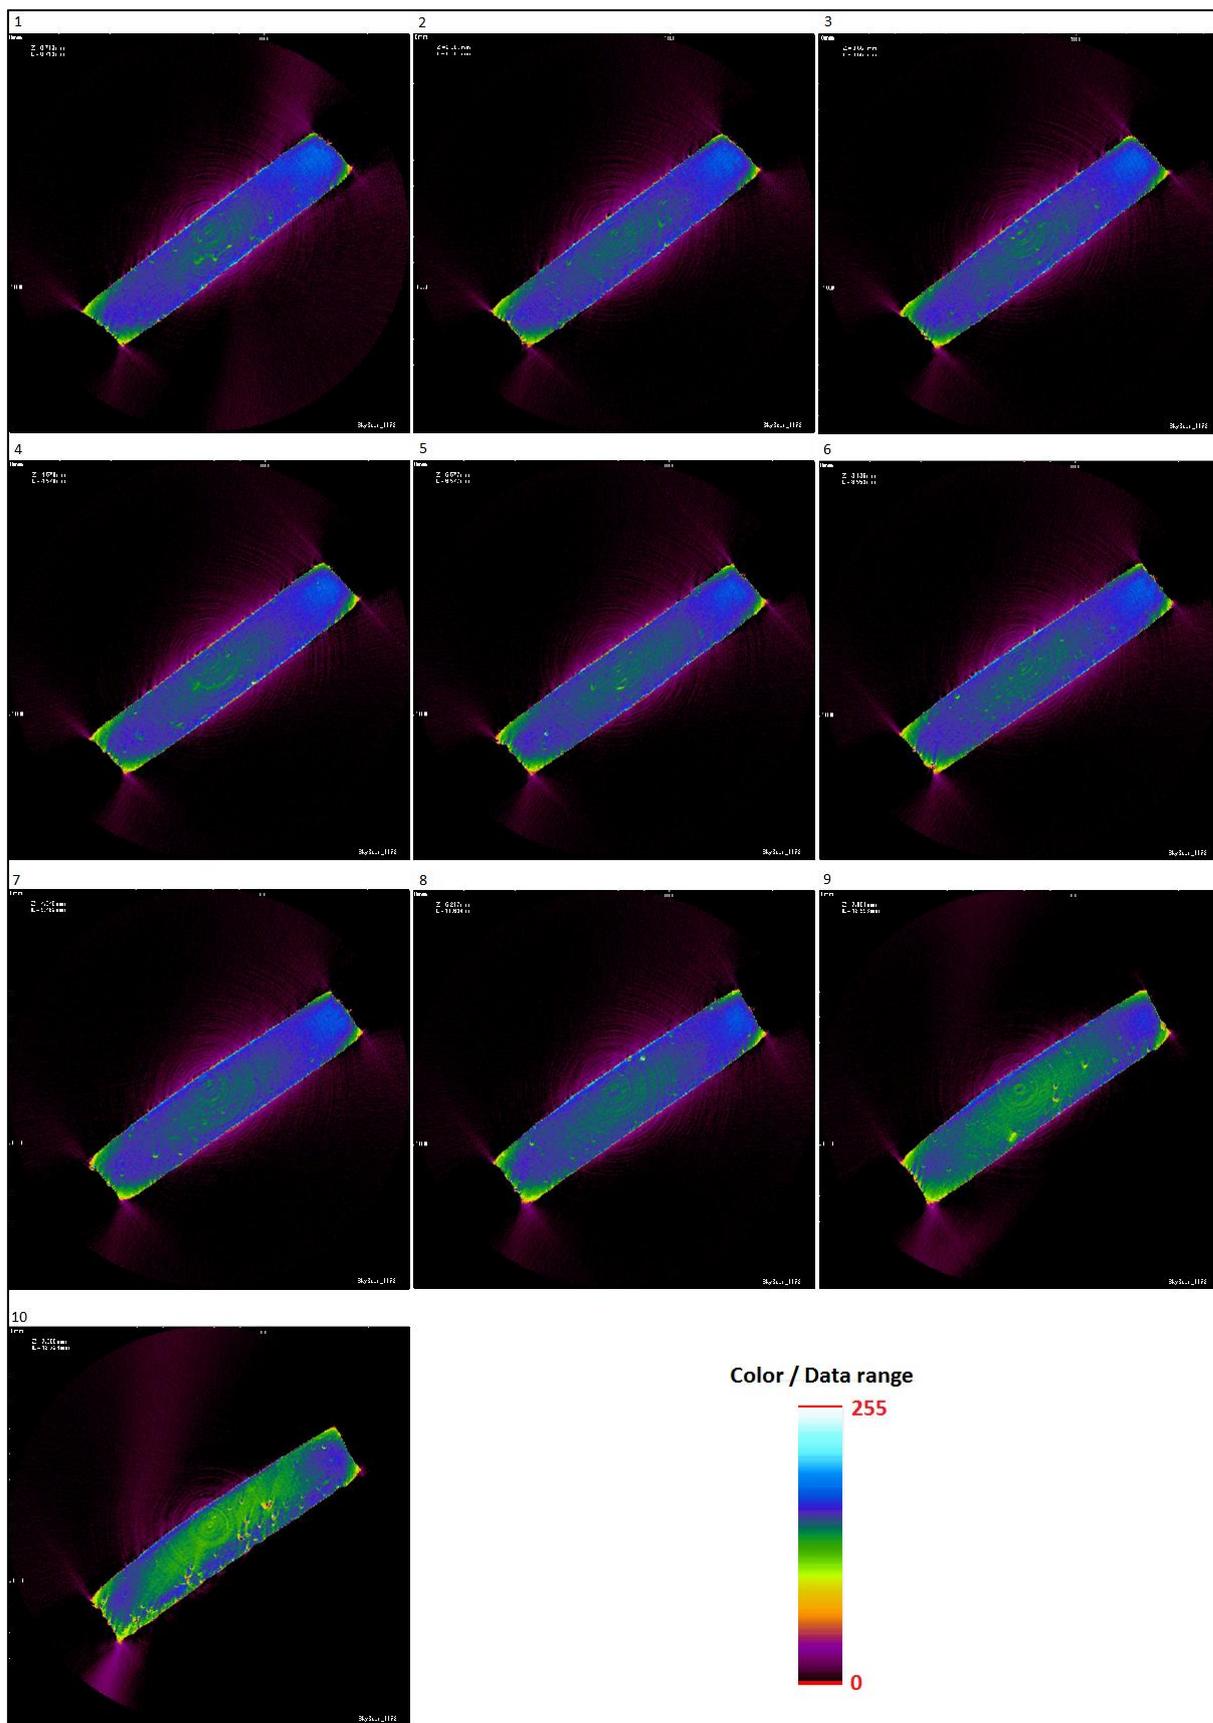


Figura 38 - Imagens tomográficas da amostra de Carandá 5% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 5% de Carandá, na janela selecionada a homogeneidade média obtida foi de -22,37% sendo que o valor esperado pelo cálculo do CVP do momento invariante Φ_1 seria entre 0 e 100, tal resultado pode ser devido a presença de ruídos e artefatos normalmente encontrados em imagens tomográficas deste tipo.

O grau de rugosidade obtido foi de 0,139 pelo cálculo do desvio padrão do momento invariante Φ_1 (Tabela 15).

Tabela 15 - Resultado da análise da amostra com 5% de Carandá

<i>Carandá 5%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I* pixel</i>	<i>HuI</i>	<i>HuI</i>	<i>HuI</i>
<i>1</i>	1240x840	0,000665	0,0258	2,696
<i>2</i>	1240x840	0,00744	0,0862	59,602
<i>3</i>	1260x860	0,0251	0,158	148,449
<i>4</i>	1260x860	0,0318	0,178	140,682
<i>5</i>	1260x860	0,0272	0,164	136,7
<i>6</i>	1260x860	0,0316	0,177	149,640
<i>7</i>	1250x850	0,0224	0,149	115,0757
<i>8</i>	1250x850	0,0395	0,198	124,934
<i>9</i>	1240x840	0,0137	0,117	90,502
<i>10</i>	1240x840	0,0175	0,132	255,464
	<i>Média</i>	0,0217	0,139	122,374

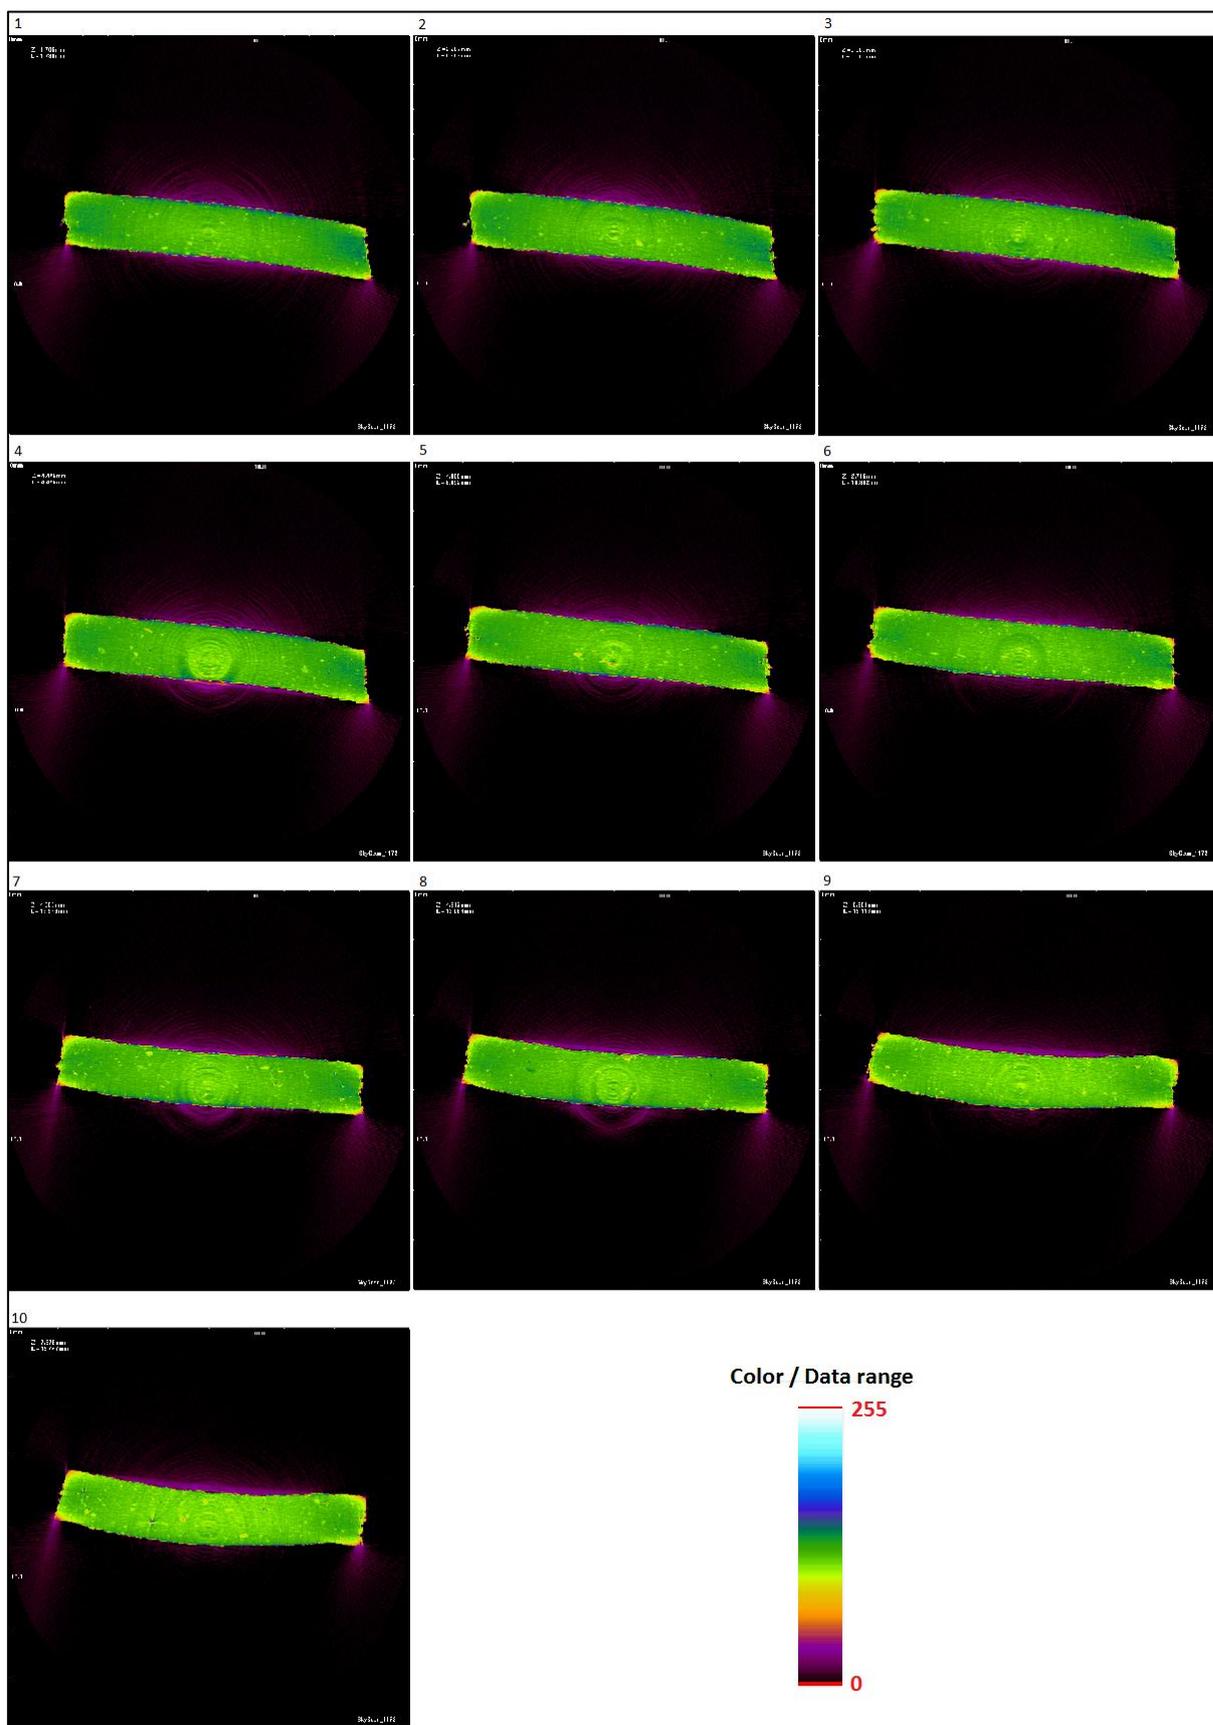


Figura 39 - Imagens tomográficas da amostra de Carandá 10% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 10% de Carandá, na janela selecionada a homogeneidade média obtida foi de 60,19% pelo cálculo do CVP e um grau de rugosidade de 0,136 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 16).

Tabela 16 - Resultado da análise da amostra com 10% de Carandá

<i>Carandá 10%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição 1° pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
1	395X860	0,0174	0,132	32,427
2	395X860	0,0150	0,122	25,237
3	395X860	0,0232	0,152	34,503
4	395X860	0,0143	0,119	31,894
5	395X820	0,0233	0,152	35,858
6	395X820	0,0191	0,138	37,878
7	395X805	0,0183	0,135	34,050
8	395X805	0,0187	0,137	42,353
9	395X805	0,0164	0,128	52,294
10	395X805	0,0224	0,149	71,573
	Média	0,0188	0,136	39,807

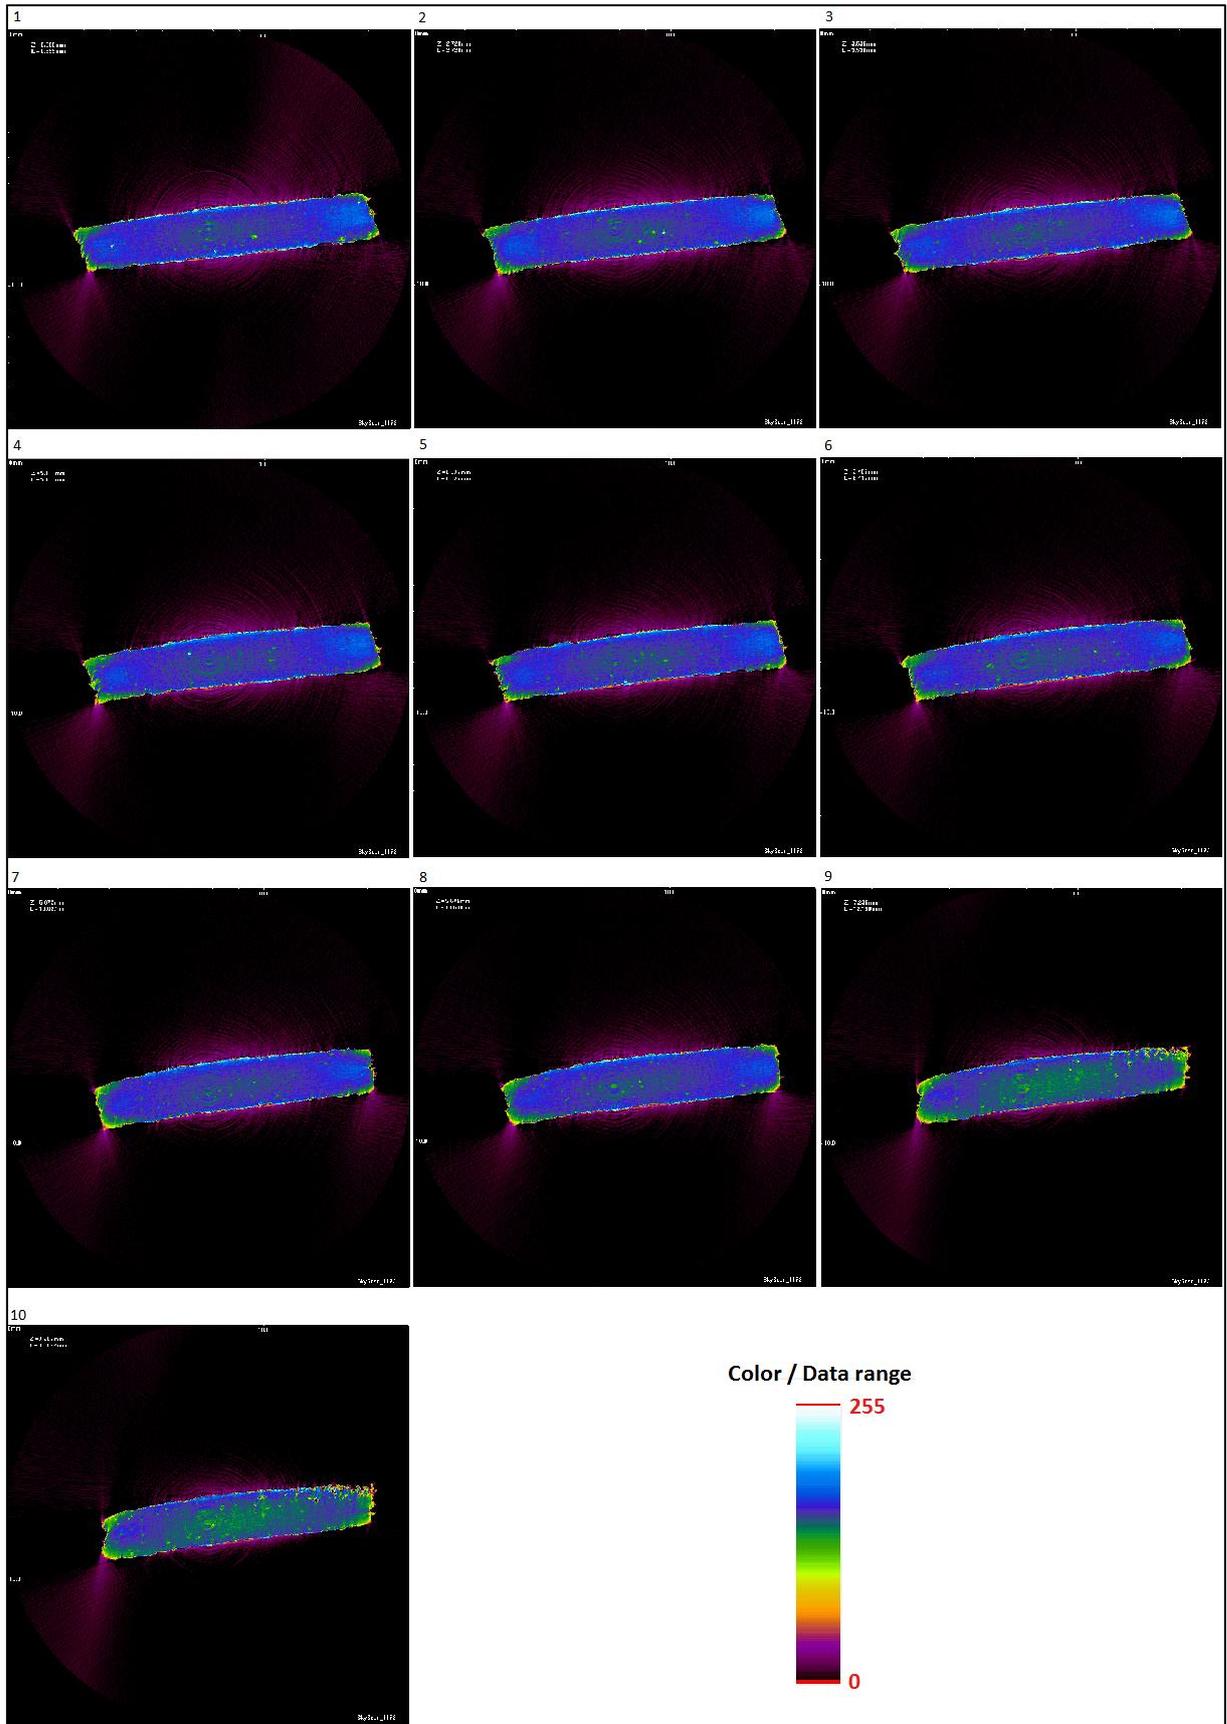


Figura 40 - Imagens tomográficas da amostra de Carandá 15% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 15% de Carandá, na janela selecionada a homogeneidade média obtida foi de 38,31% pelo cálculo do CVP e um grau de rugosidade de 0,144 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 17).

Tabela 17 - Resultado da análise da amostra com 15% de Carandá

<i>Carandá 15%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I° pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
1	570x1030	0,0181	0,134	70,490
2	570x1030	0,0197	0,140	33,553
3	570x1030	0,0224	0,149	34,875
4	570x1030	0,0167	0,129	31,984
5	570x1030	0,0282	0,168	39,707
6	570x1030	0,0161	0,126	53,691
7	570x1030	0,0272	0,165	44,843
8	570x1030	0,0247	0,157	43,834
9	570x1030	0,0229	0,151	91,349
10	570x1030	0,0147	0,121	172,520
	<i>Média</i>	0,0211	0,144	61,685

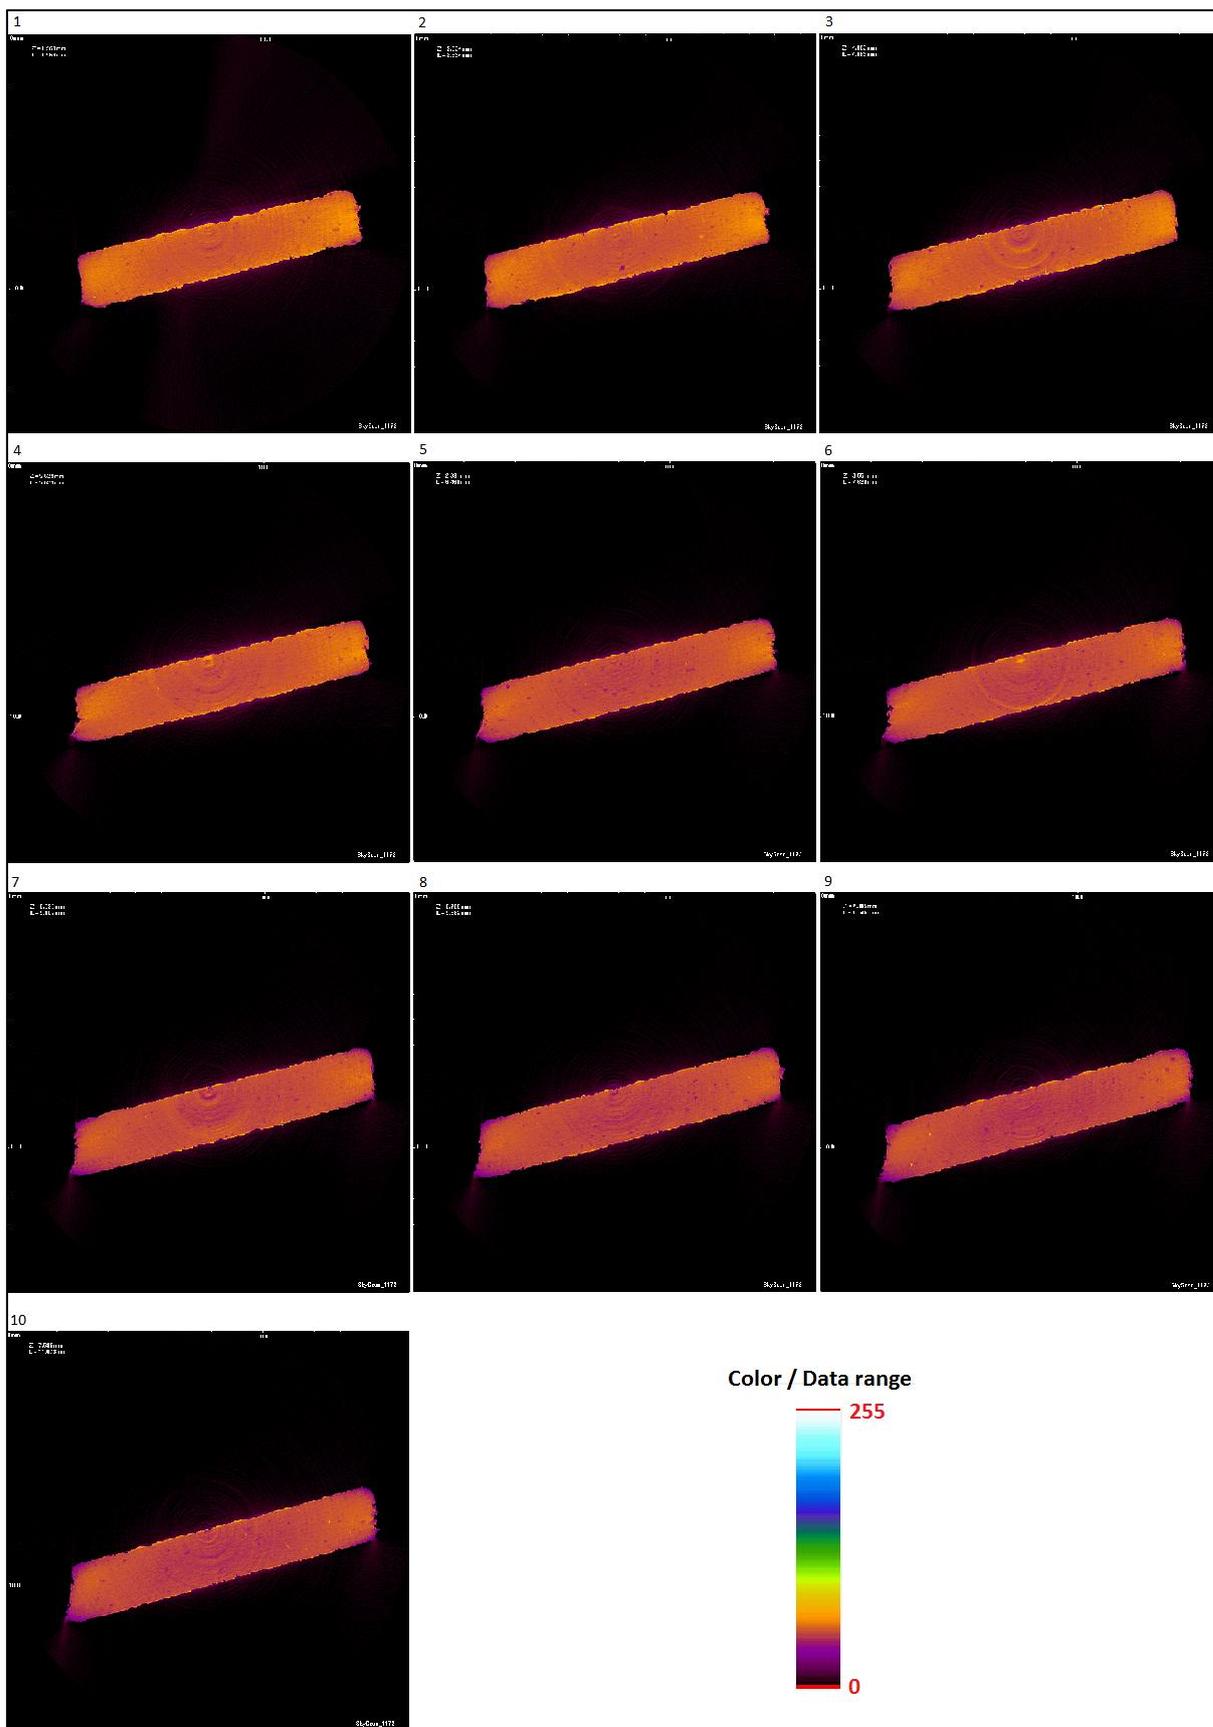


Figura 41 - Imagens tomográficas da amostra de Carandá 20% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 20% de Carandá, na janela selecionada a homogeneidade média obtida foi de 67,08% pelo cálculo do CVP e um grau de rugosidade de 0,131 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 18).

Tabela 18 - Resultado da análise da amostra com 20% de Carandá

<i>Carandá 20%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I* pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
1	470x1140	0,0110	0,105	15,779
2	470x1140	0,0203	0,142	35,393
3	470x1160	0,0104	0,102	54,324
4	470x1160	0,0207	0,144	29,623
5	470x1180	0,0210	0,145	27,142
6	470x1180	0,0201	0,142	31,938
7	470x1180	0,0189	0,137	33,392
8	470x1180	0,0267	0,163	40,697
9	470x1200	0,0109	0,104	28,040
10	470x1200	0,0210	0,145	36,192
	<i>Média</i>	0,0178	0,131	32,925

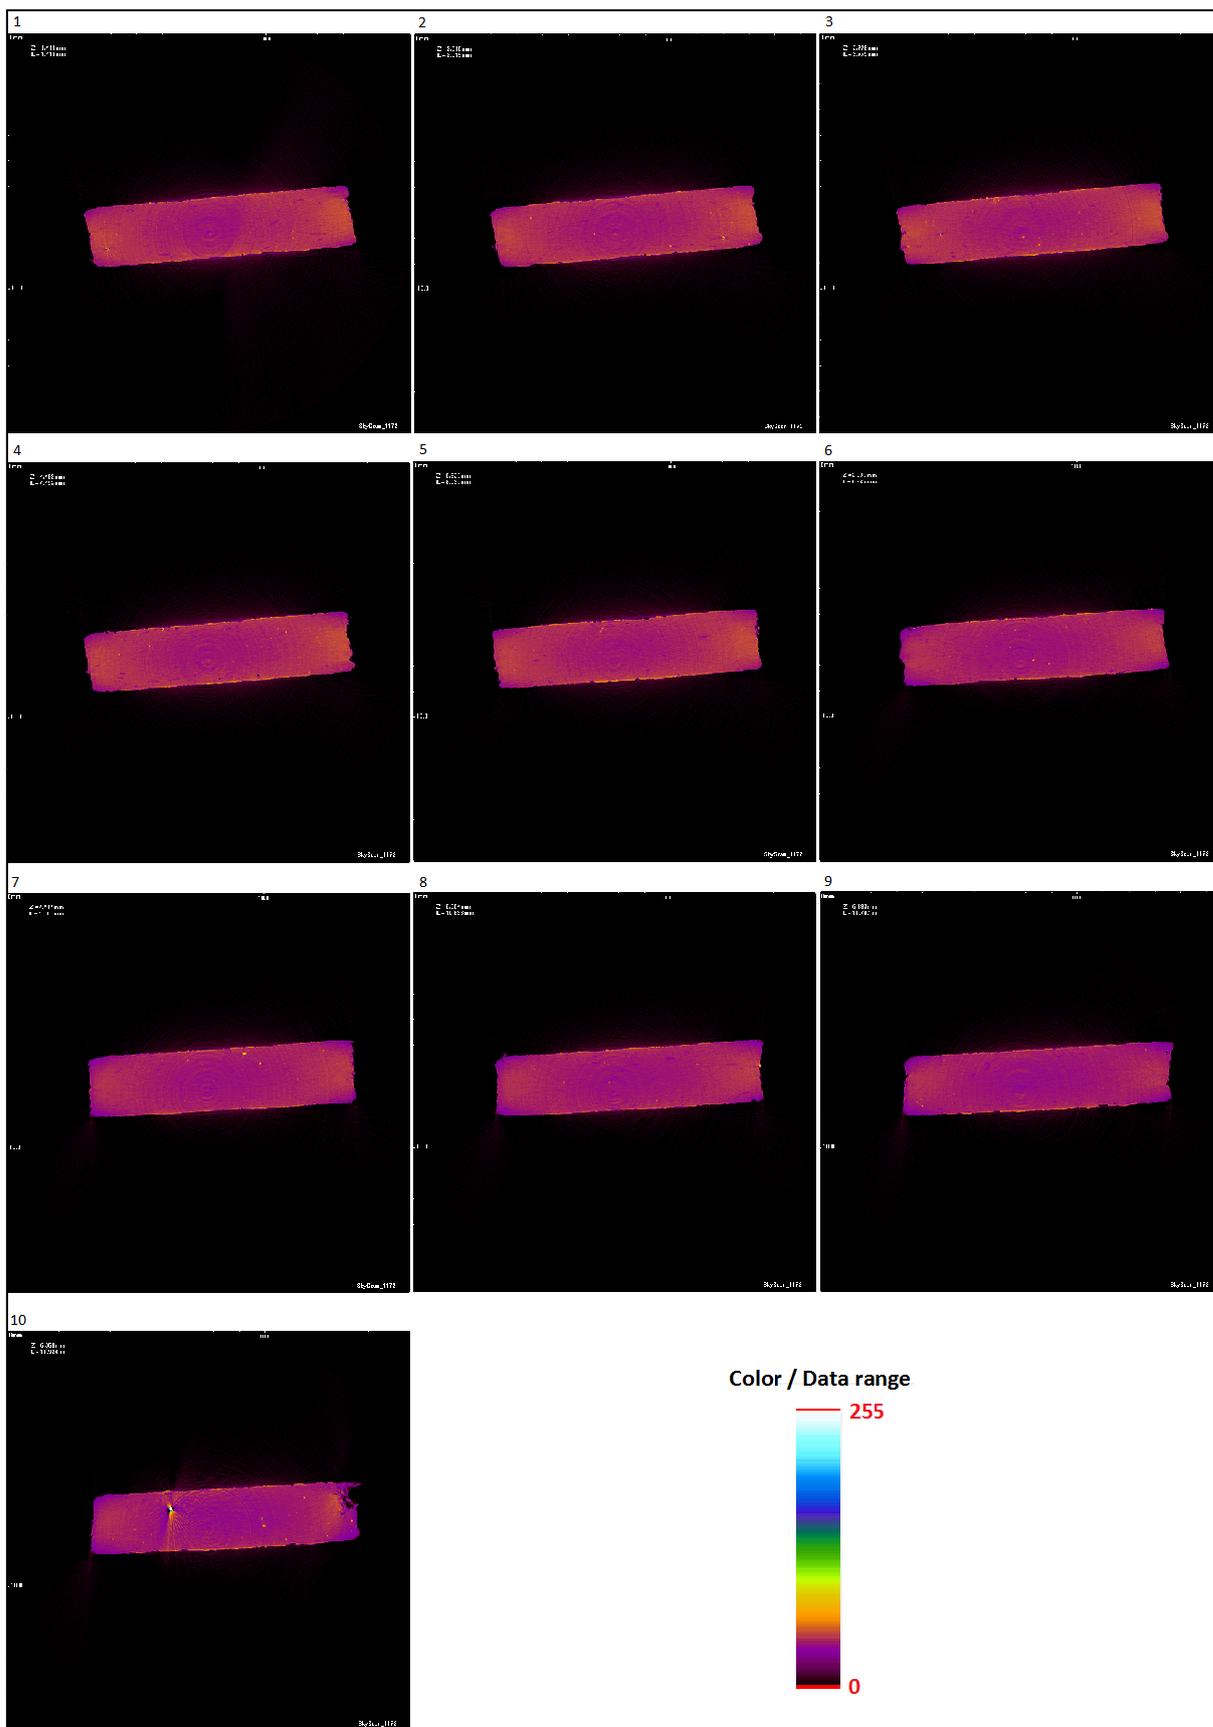


Figura 42 - Imagens tomográficas da amostra de Gravatá 5% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 5% de Gravata, na janela selecionada a homogeneidade média obtida foi de 74,33% pelo cálculo do CVP e um grau de rugosidade de 0,134 pelo cálculo do desvio padrão do momento invariante Φ_1 (Tabela 19).

Tabela 19 - Resultado da análise da amostra com 5% de Gravata

<i>Gravata 5%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I* pixel</i>	<i>HuI</i>	<i>HuI</i>	<i>HuI</i>
1	520x945	0,0222	0,149	30,654
2	520x945	0,0143	0,119	22,745
3	520x945	0,0184	0,135	23,696
4	520x945	0,0163	0,127	22,198
5	520x915	0,0180	0,134	24,337
6	520x915	0,0175	0,132	26,344
7	520x915	0,0176	0,132	27,030
8	520x915	0,0156	0,124	29,544
9	520x915	0,0204	0,142	22,510
10	520x915	0,0209	0,144	27,592
	<i>Média</i>	0,0181	0,134	25,665

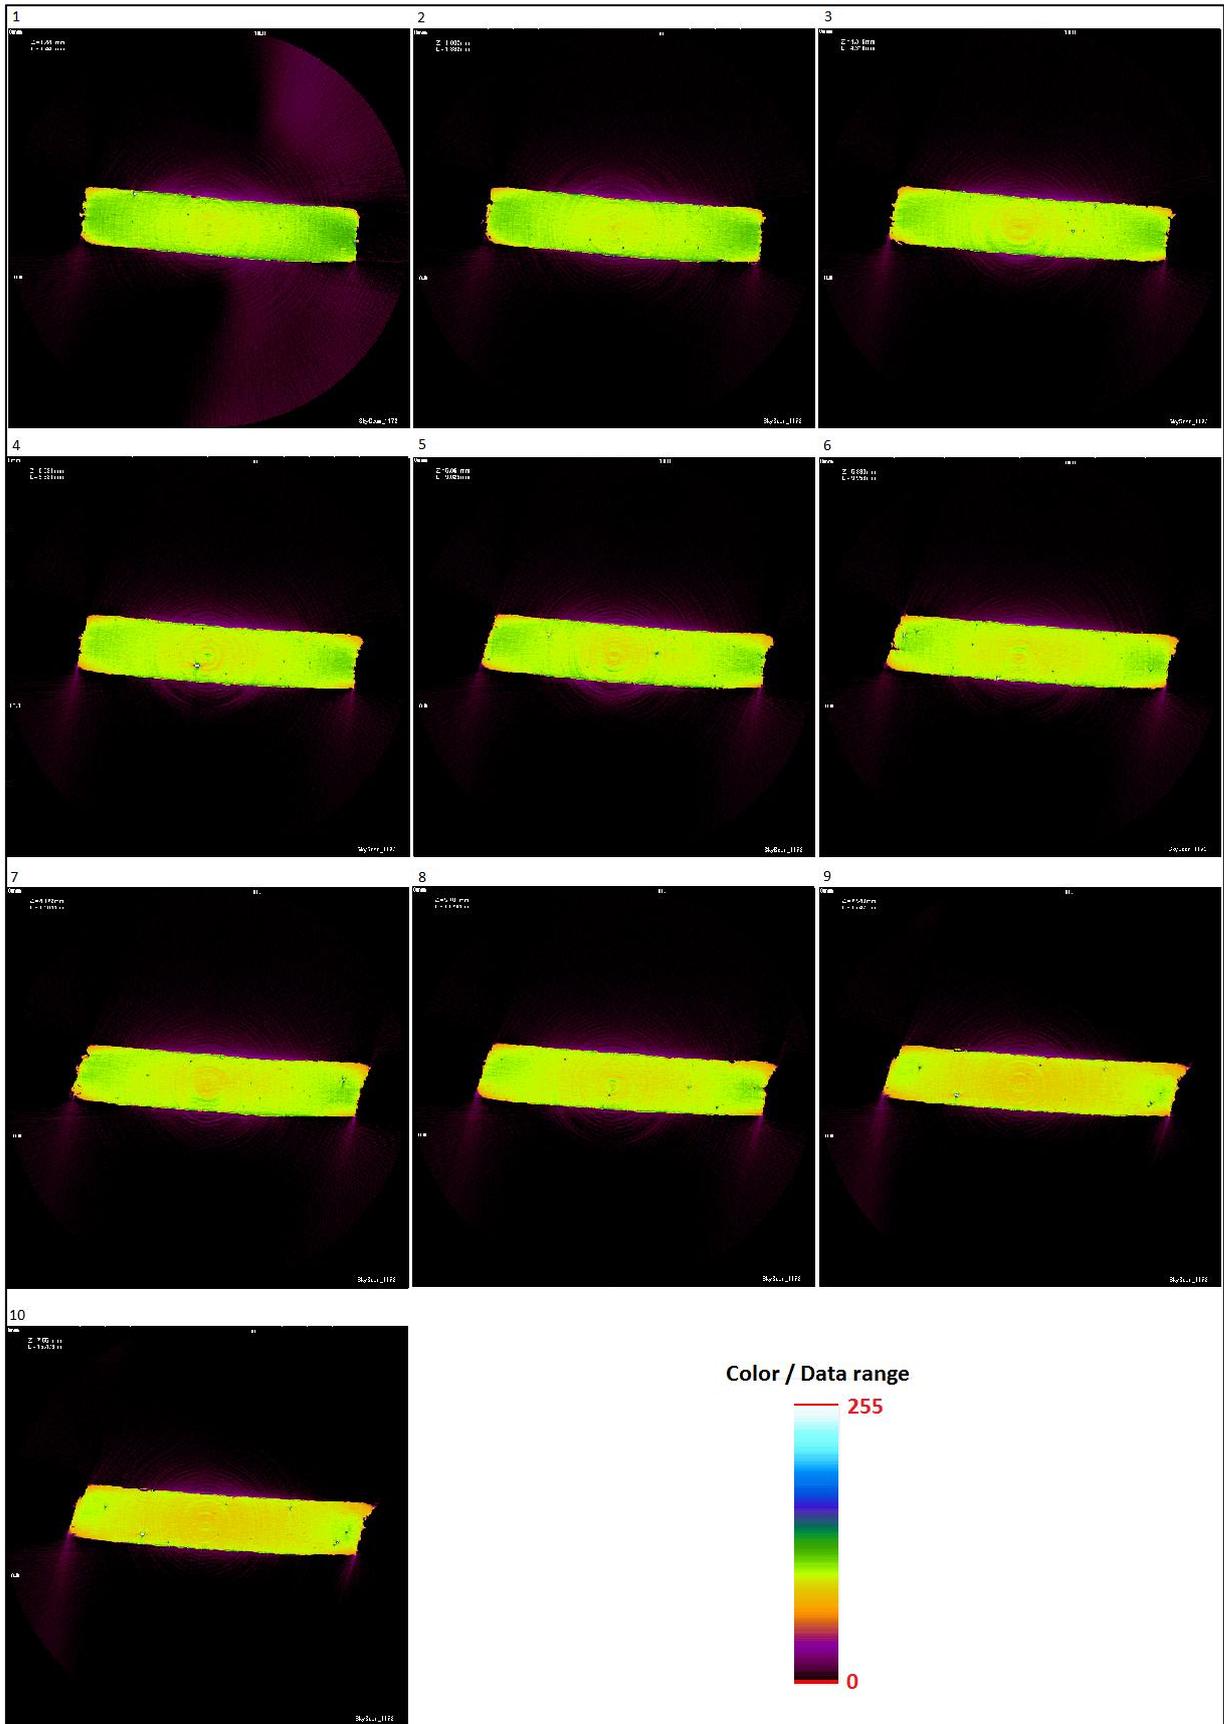


Figura 43 - Imagens tomográficas da amostra de Gravata 10% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 10% de Gravatá, na janela selecionada a homogeneidade média obtida foi de 63,8% pelo cálculo do CVP e um grau de rugosidade de 0,140 pelo cálculo do desvio padrão do momento invariante Φ_1 (Tabela 20).

Tabela 20 - Resultado da análise da amostra com 10% de Gravatá

<i>Gravatá 10%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição 1° pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
<i>1</i>	500x865	0,0186	0,136	30,612
<i>2</i>	500x865	0,0182	0,135	30,946
<i>3</i>	500x865	0,0197	0,140	27,489
<i>4</i>	500x865	0,0140	0,118	33,138
<i>5</i>	500x865	0,0243	0,156	29,218
<i>6</i>	500x865	0,0226	0,150	24,653
<i>7</i>	500x865	0,0280	0,167	27,809
<i>8</i>	500x865	0,0196	0,140	48,316
<i>9</i>	500x865	0,0164	0,128	57,511
<i>10</i>	500x865	0,0178	0,133	52,354
	<i>Média</i>	0,0199	0,140	36,205

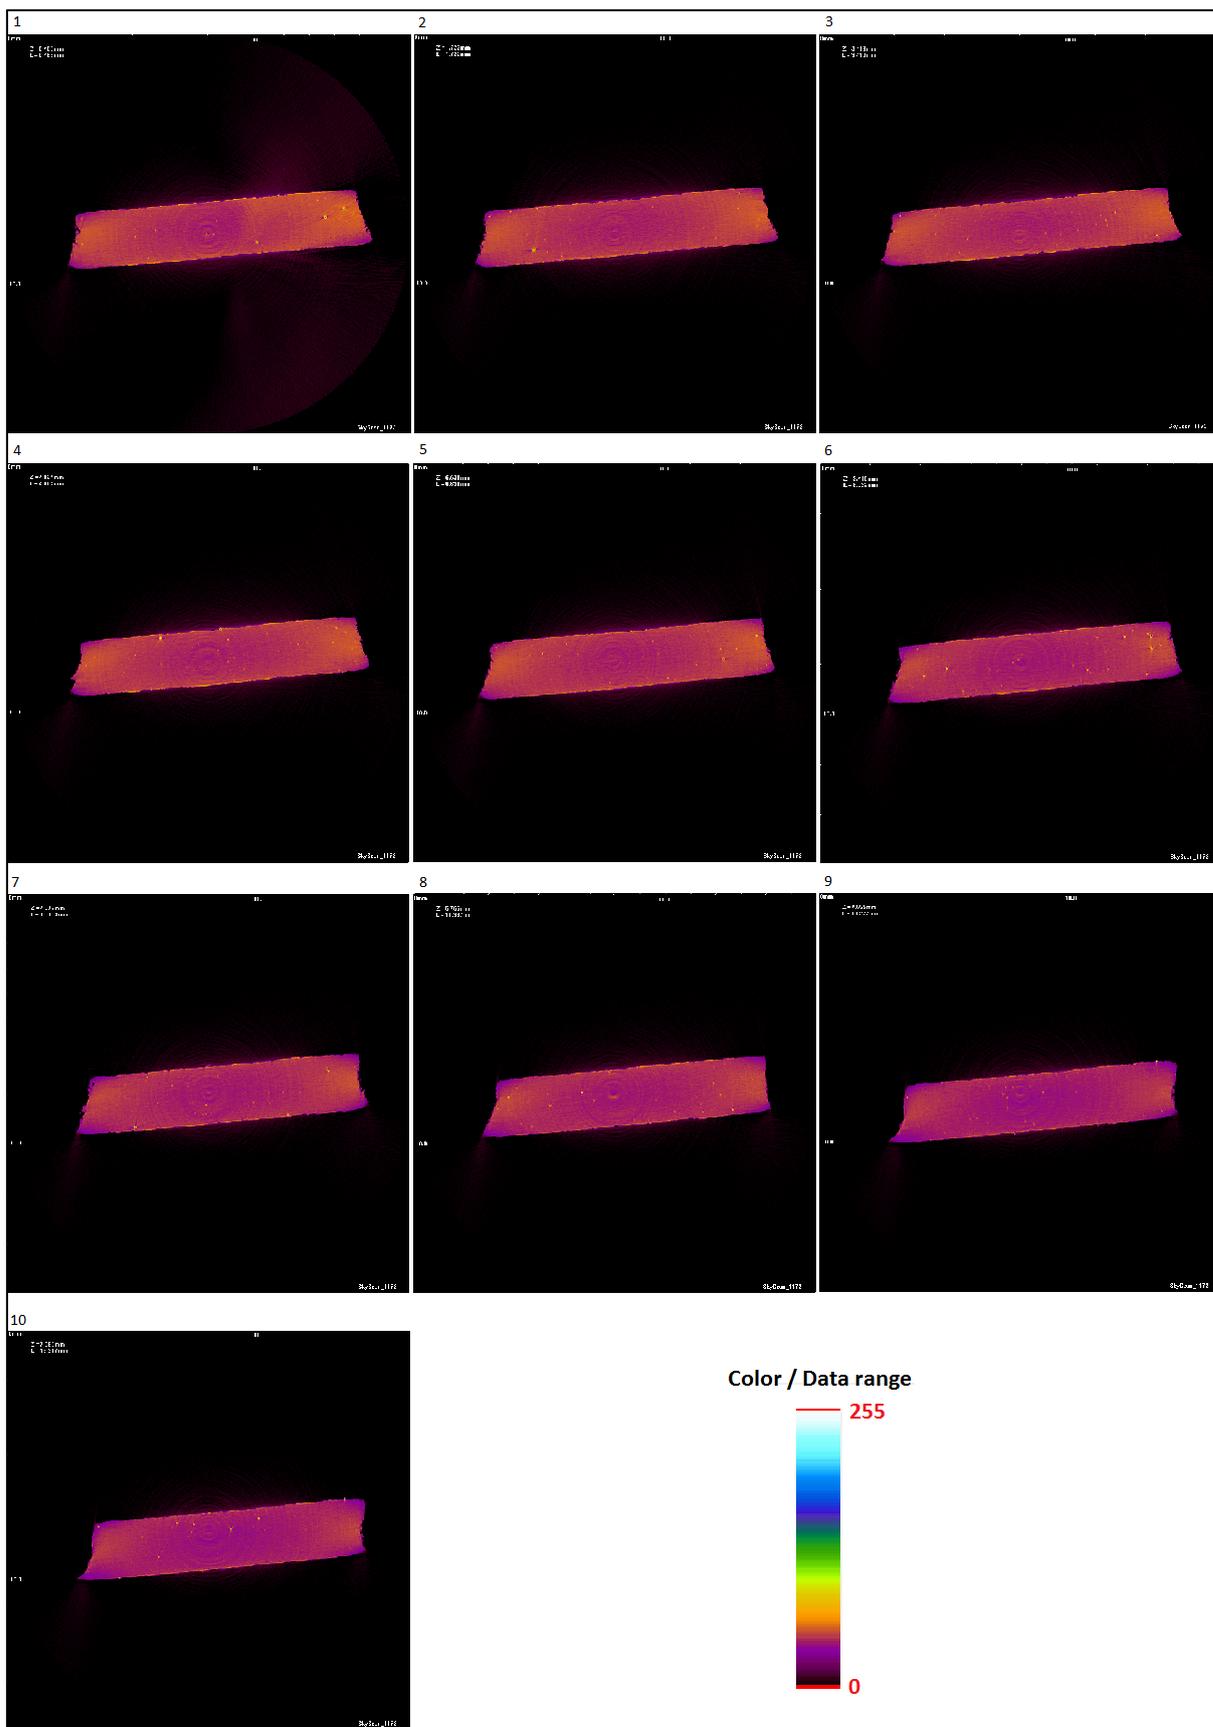


Figura 44 - Imagens tomográficas da amostra de Gravata 15% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 15% de Carandá, na janela selecionada a homogeneidade média obtida foi de 57,19% pelo cálculo do CVP e um grau de rugosidade de 0,124 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 21).

Tabela 21 - Resultado da análise da amostra com 15% de Gravatá

<i>Gravatá 15%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição 1° pixel</i>	<i>Hu1</i>	<i>Hu1</i>	<i>Hu1</i>
<i>1</i>	445x945	0,0103	0,101	86,697
<i>2</i>	445x945	0,0150	0,122	25,806
<i>3</i>	445x945	0,0168	0,129	23,944
<i>4</i>	445x945	0,0122	0,110	27,974
<i>5</i>	445x945	0,0159	0,126	22,771
<i>6</i>	445x945	0,0195	0,139	32,108
<i>7</i>	445x965	0,0144	0,120	29,577
<i>8</i>	445x965	0,0208	0,144	34,715
<i>9</i>	445x995	0,0164	0,128	29,922
<i>10</i>	445x995	0,0144	0,120	114,596
	<i>Média</i>	0,0156	0,124	42,811

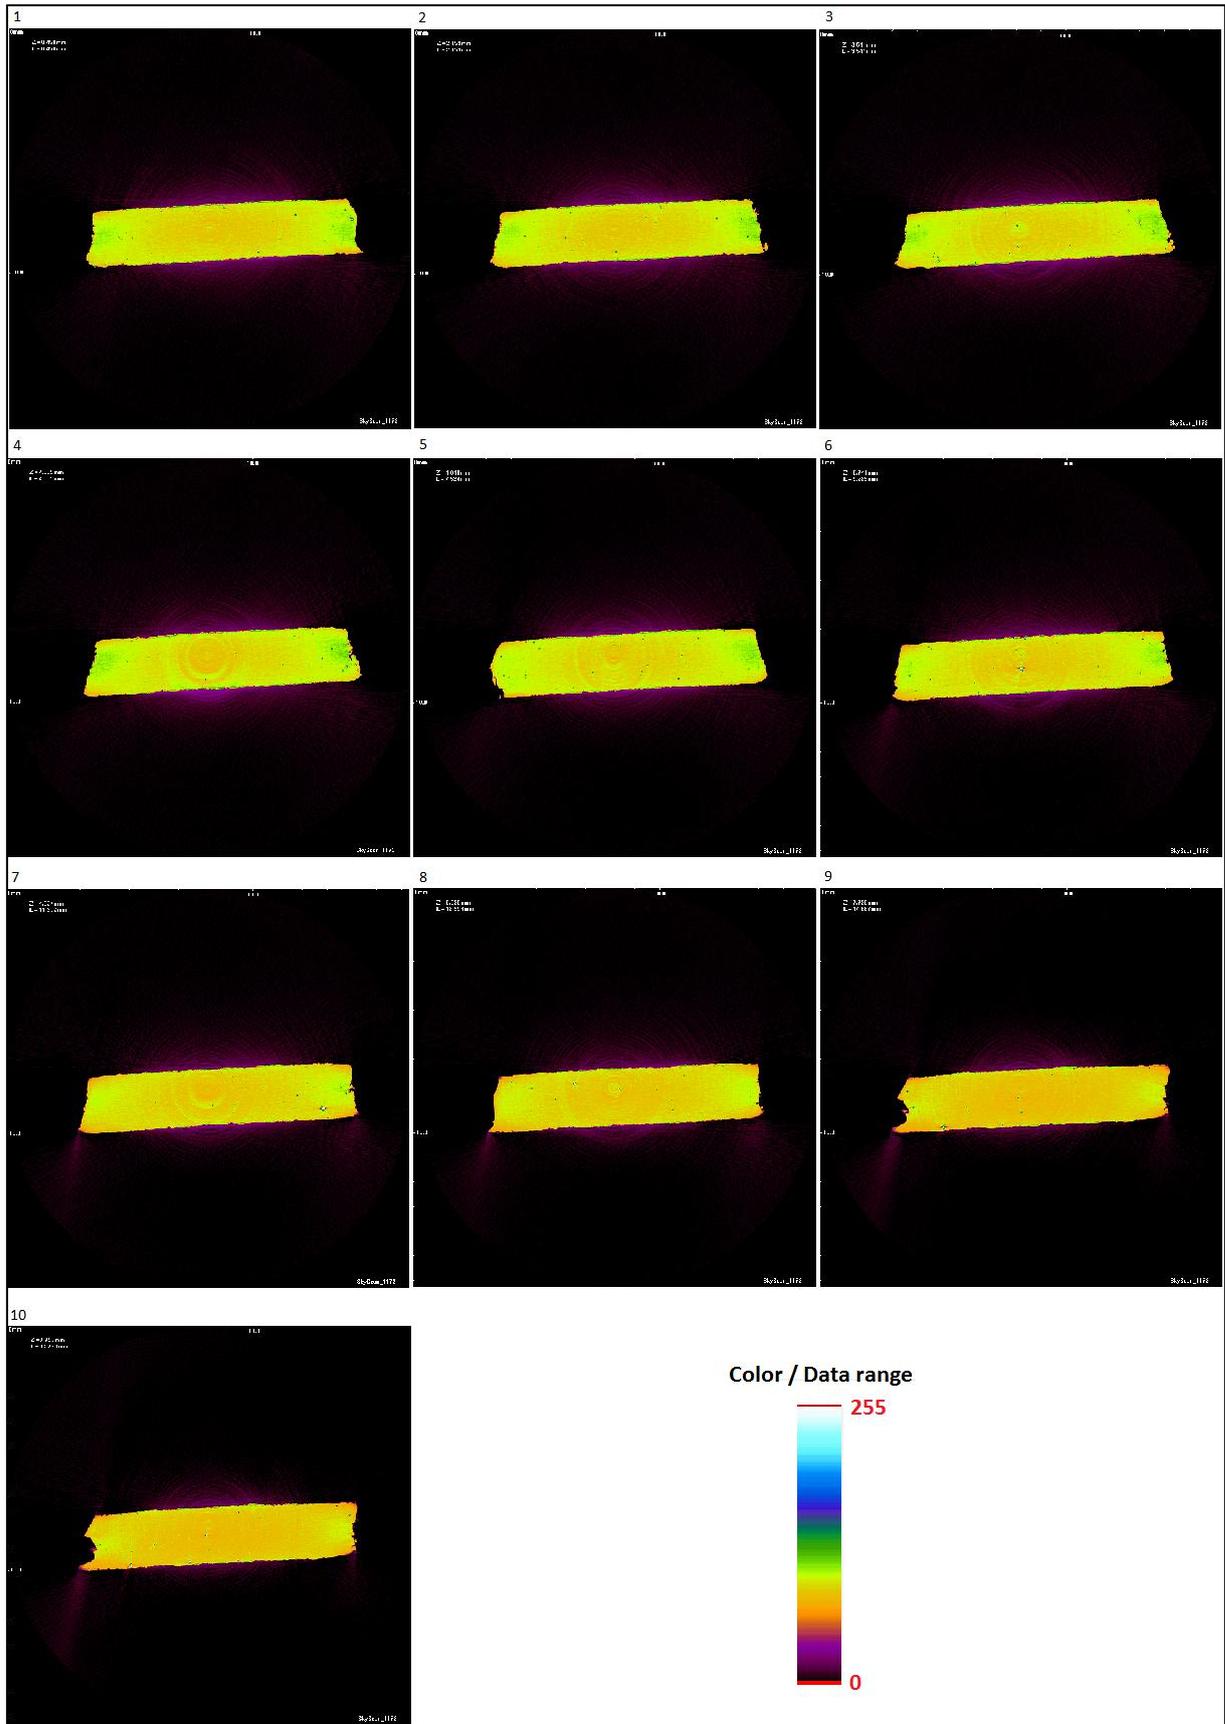


Figura 45 - Imagens tomográficas da amostra de Gravatá 20% utilizadas para análise

De acordo com a análise realizada nas imagens tomográficas da amostra com 20% de Carandá, na janela selecionada a homogeneidade média obtida foi de 59,02% pelo cálculo do CVP e um grau de rugosidade de 0,131 pelo cálculo do desvio padrão do momento invariante ϕ_1 (Tabela 22).

Tabela 22 - Resultado da análise da amostra com 20% de Gravatá

<i>Gravatá 20%</i>		<i>Var.</i>	<i>D.P.</i>	<i>C.V.P.</i>
<i>Imagem</i>	<i>Posição I° pixel</i>	<i>HuI</i>	<i>HuI</i>	<i>HuI</i>
<i>1</i>	530x970	0,0142	0,119	26,924
<i>2</i>	530x970	0,0199	0,141	28,379
<i>3</i>	530x970	0,0148	0,121	24,842
<i>4</i>	530x970	0,0219	0,148	29,985
<i>5</i>	530x970	0,0207	0,144	22,351
<i>6</i>	530x970	0,0157	0,125	29,461
<i>7</i>	530x980	0,0235	0,153	27,881
<i>8</i>	530x980	0,0169	0,130	39,896
<i>9</i>	530x980	0,0114	0,106	87,662
<i>10</i>	530x980	0,0165	0,128	92,509
	<i>Média</i>	0,0176	0,131	40,989

As análises realizadas não têm relação direta com a distribuição do material fibroso em TPS, mas sim, com a distribuição dos níveis de cinza dos pixels que constituem a imagem. Porém pode-se dizer que o material fibroso e os tons de cinza possuem uma relação direta, pois é possível afirmar que o material fibroso encontrado nas amostras possui uma tonalidade de cinza distinta do TPS puro.

A partir dos resultados obtidos pode-se inferir a homogeneidade das amostras com a análise das médias dos cálculos estatísticos realizados nas imagens tomográficas, sendo que quanto menor os valores obtidos maior é a homogeneidade da distribuição dos tons de cinza dentro da janela que fora selecionada para análise.

Uma maior homogeneidade significa uma melhor distribuição das fibras vegetais em TPS e conseqüentemente uma amostra com maior resistência mecânica e uma menor absorção de água.

Pôde-se perceber também que em alguns casos os momentos invariantes se mostram sensíveis e reagem retornando um valor diferente do esperado. Essa sensibilidade pode ser devida a ocorrência de artefatos e ruídos que não raramente são encontrados nas imagens, assim como foi observado na análise da amostra da mistura de 5% de Carandá em TPS, onde a média do CVP de Φ_1 ultrapassa o valor esperado.

Em alguns casos a sensibilidade do momento foi alta e houve a necessidade de se escolher outra imagem, pois o TeAS não foi capaz de calcular os momentos invariantes nas janelas selecionadas. Ocorreu principalmente nas imagens das secções mais próximas ao limite superior e inferior das amostras.

Alem dos artefatos pôde-se observar em, alguns casos, manchas brancas em meio às amostras, porém foi percebido que as manchas são pequenas bolhas de ar provenientes da produção da amostra, as manchas brancas não afetaram a análise de forma negativa.

4.3 Conclusão do Capítulo

Neste capítulo foram apresentados experimentos para validar o método de análise de homogeneidade. A análise mostrou que nem todos os momentos invariantes puderam ser utilizados.

Foi possível identificar que mesmo os momentos invariantes que fornecem dados com relação à homogeneidade são sensíveis a ruídos e artefatos originados na própria reconstrução tomográfica das amostras.

Capítulo 5

CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS

Neste capítulo são apresentadas conclusões e propostas de trabalhos futuros, considerando a linha de pesquisa em processamento digital de imagens.

5.1 Conclusões

Foi apresentado neste trabalho o desenvolvimento de um método de processamento digital de imagens para inferência da qualidade de materiais preparados com fibras vegetais, com o objetivo de auxiliar no processo de verificação da qualidade da produção e extração de características de amostras de compósitos biodegradáveis.

Como resultados principais encontraram destaque:

1. Um estudo detalhado sobre diversas abordagens existentes na atualidade para a realização da extração de dados sobre texturas com base no processamento digital de imagens.
2. Uma quantidade significativa de dados analisados, com a qual é possível afirmar que, apesar das adversidades enfrentadas, pela complexidade dos estudos efetuados o método contribui para a correta determinação dos índices pretendidos, auxiliando a verificação da qualidade do processo de fabricação de novos materiais biodegradáveis produzidos a partir de fibras vegetais de plantas nativas brasileiras e amido termoplástico.

3. Um método de análise, de homogeneidade de textura, para inferência da qualidade da mistura de TPS e fibras vegetais, com base no uso de momentos invariantes.
4. Um estudo sobre a linguagem de programação Python e suas capacidades de uso na área de processamento de imagens digitais.

Tendo em vista os objetivos propostos por esse trabalho, de acordo com os resultados apresentados, pôde-se concluir que o método apresentado neste trabalho auxilia na verificação da qualidade da produção de amostras de materiais biodegradáveis compostas de TPS e fibras vegetais.

5.2 Proposta de trabalho futuro

1. Desenvolvimento de um processo de análise que vise uma melhor automação e rapidez como por exemplo, um algoritmo que verifique a diferença de posicionamento de um pixel entre imagens para a viabilização do carregamento de múltiplas imagens de uma só vez;
2. Desenvolvimento de um filtro de imagens, dedicado, para amenizar os ruídos e artefatos normalmente encontrados em uma imagem tomográfica obtida de materiais biodegradáveis compostos de TPS e fibras vegetais.

REFERÊNCIAS BIBLIOGRÁFICAS

ASTM - "Specification for compostable plastics". American Society for Testing and Materials, 1999.

AVÉROUS, L. - "Biodegradable multiphase systems based on plasticized starch: A review". Journal of Macromolecular Science-Polymer, Volume C4, N°3, Pg. 231-274, 2004.

BALLARD, D. H., BROWN C. M. – "Computer Vision". Prentice-Hall, Englewood Cliffs, Cap. 11, Pg. 352–382, 1982.

CARMONA, V. B. – "Desenvolvimento de compósitos biodegradáveis a partir de amido termoplástico e fibras de Acuri, Carandá e Gravatá". Dissertação de mestrado, Programa de pós - graduação em engenharia de materiais, Universidade Federal de São Carlos, 2011.

CASTELLANO, G. – "Caracterização dos parâmetros de textura em imagens de RM cerebrais de indivíduos sadios", Projeto de iniciação científica, Grupo de Neurofísica, Departamento de Raios Cósmicos e Cronologia, Instituto de Física Gleb Wataghin da UNICAMP, Campinas, 2012.

CASTLEMAN, K. R. – "Digital Image Processing", 1ª Edição, Prentice-Hall, Englewood Cliffs, NJ, 1996.

CHANDRA, R., RUSTGI, R., – "Biodegradable polymer". Progress in Polymer Science, Oxford, Volume 23, N° 7, PG.1273-1335, 1998.

CONNERS, R. W., HARLOW C. A. – "Toward a structural textural analyzer based on statistical methods". Computer-Graphics and Image Processing, Volume 12, N°3, Pg. 224-256, 1980.

CORMACK, A. M. – “Reconstruction of Densities from their Projections, with Applications in Radiological Physics”, *Phys. Med. Biol.*, Volume 18, N° 2, 1973.

CORRADINI, E., TEIXEIRA E. M., AGNELI J. A. M., MATTOSO L. H. C. - “Amido Termoplástico”. EMBRAPA instrumentação agropecuária – CNPDIA , São Carlos, Documentos 30, ID 11042 – 1, ISSN 1518-7179, 2007.

CRUVINEL, P. E. – “X and γ -rays computerized minitomography scanner for multidisciplinary use”, Tese Apresentada na Universidade de Campinas, Unicamp, Campinas, 1987.

CRUVINEL, P.E., CESAREO, R., CRESTANA, S., MASCARENHAS, S. – “X and Gamma-rays computerized minitomograph scanner for soil science”, *IEEE Transactions on Instrumentation and Measurement*, Volume 39, N° 5, 1990.

CRUVINEL, P. E., CRESTANA, S., ARTAXO, P. E., MARTINS, J. V., ARMELIN, M.J.A. – “Studying the spatial variability of Cr in agricultural field using both particle induced X-ray emission (PIXE) and instrumental neutron activation analysis (INAA) technique”. *Nuclear Instruments and Methods in Physics Research*, Volume 109-10, Pg. 247-251, Amsterdam, 1996.

CURVELO, A. A., CARVALHO, A.J.F., AGNELLI, J.A.M. – “Thermoplastic starch-cellulosic fibers composites: preliminary results”. *Carbohydrate Polymers*, Birmingham, Volume 45, Pg. 183-188, 2001.

DAVIS, L. S., MITICHE A. – “Edge detection in textures”. *Computer Graphics and Image Processing*, Volume 12, N° 1, Pg. 25-39, 1980.

FU, K. S. – “Syntactic Methods in Pattern Recognition”. 1ª Edição, Academic Press, New York, 1974.

GONZALEZ, R. C., WOODS R. E. – “Processamento Digital de Imagens” 3ª Edição, Pearson, 2010.

HARALICK, R. M. – “Statistical and structural approaches to texture”. Proceedings IEEE, Volume 67, N° 5, 1979.

HARALICK, R. M., SHANMUGAM K., DINSTEIN I. – “Textural features for image classification”. Transactions on Systems, Man and Cybernetics, U.S.A., Volume SMC-3, N° 6, 1973.

HOUNSFIELD, G.N. – “Computerized Transverse Axial Scanning (Tomography): Part I. Description of System”, British Journal of Radiology, N° 46, 1973

HU, M. K. – “Visual Pattern Recognition by Moment Invariants”, IRE Transactions on Information Theory, Volume 8, N°2, 1962.

JULESZ, B. – “Textons, the elements of texture perception and their Interactions”. Nature - International Journal of Science, N°290 (5802): 91–97, 1981.

LUNDH, F., ELLIS M. – “The Python Imaging Library”, Secret Labs AB, Pythonware, 2002.

MANI, R., BHATTACHARYA, M. – “Properties of injection molded starch/synthetic polymer blends IV. Thermal and morphology properties”. European Polymer Journal, Volume 34, N° 10, Elsevier, 1998.

MINATEL, E.R. CRUVINEL, P.E. – “Three-dimensional reconstruction and visualization of tomography images system using frequential techniques and wavelets”. International Symposium on Computer Graphic, Image Processing and vision, EMBRAPA, São Carlos, 1998.

RÖPER, H., KOCH, H. – “The role of starch in biodegradable thermoplastic materials”. Starch, Volume 42, N° 4, Belgium, 1990.

ROSENFELD, A., DWYER, S. J. – “Digital Picture Analysis – Topics in Applied Physics”. Springer Verlag, Berlin, Heidelberg, New York, Volume 11, 1976.

SANTOS, A. P. O. – “Desenvolvimento de Descritores de Imagens para Reconhecimento de Padrões de Plantas Invasoras (Folhas Largas e Folhas Estreitas)”. Dissertação de mestrado, Programa de Pós Graduação em Ciência da Computação, Universidade Federal de São Carlos, 2009.

SANTOS, A. P. O., CRUVINEL, P. E. – “Desenvolvimento de um Modelo de Descritores de Imagens para Reconhecimento de Padrões de Plantas Invasoras (Folhas Largas e Folhas Estreitas)”. XI Encontro de Modelagem Computacional, 2008, Volta Redonda, 2008.

SHOGREN, R. L., FANTA, G. F., DOANE, W. M. – “Development of starch based plastic - A reexamination of selected polymer system in historical perspective”. International journal for the investigation, processing and user of carbohydrates and their derivatives, Weinheim, Volume 45, N° 8, Pg. 276–280, 1993.

SHULMAN, A. R. – “Optical Data Processing (Pure & Applied Optics)”. John Wiley & Sons Inc, New York, 1970.

SONKA, M., HLAVAC, V., BOYLE, R. – “Image Processing, Analysis, and Machine Vision”. 3ª Edição. Thomson Learning. United States of America, 1998.

TEIXEIRA, E. M. – “Utilização de amido de mandioca na preparação de novos materiais termoplásticos”. Tese de doutorado, Instituto de Química de São Carlos, Universidade de São Carlos, São Carlos, 2007.

THAKORE, I. M., DESAI, S., SARAWADE, D. B., DEVI, S. – “Studies on biodegradability, morphology and thermo mechanical properties of LDPE/modified starch blends”. European Polymer Journal, Volume 37, N° 1, Pg. 151-160, 2001.

VIEIRA, R. T. – “Análise de micro padrões em imagens digitais baseada em números *fuzzy*”, Dissertação de mestrado, Universidade de São Paulo, Departamento de engenharia elétrica, São Carlos, 2013.

WANG, S., ROSENFELD A. – “A relative effectiveness of selected texture primitive”. IEEE Transactions on Systems, Man and Cybernetics, Volume SMC-11, N°5, Pg. 360-370, 1981.

WANG, X. L., YANG, K. K., WANG, Y .Z. – “Properties of starch blends with biodegradable polymers”. Journal of Macromolecular Science-Polymer Reviews, Volume C43, Pg. 385-409, 2003.

WILLET, J., MILLARD, M. M., JASBERG, B. K. – “Extrusion of waxy maize starch: melt rheology and molecular weight degradation of amylopectin”. American Institute of Chemical Engineers Annual Meeting, Volume 38, Pg. 5983-5989, 1997.

Referências on-line:

Python – <http://www.python.org.br/>, Ultimo acesso realizado 28/04/2013.

Numpy and SciPy Documentation – <http://docs.scipy.org/doc/>, Ultimo acesso realizado 28/04/2013.