

RAQUEL APARECIDA ABRAHÃO E COSTA

MATERIALOGRAFIA QUANTITATIVA DE MICROESTRUTURAS
COMPLEXAS BASEADA NA SEGMENTAÇÃO POR TEXTURAS

Dissertação apresentada à Faculdade
de Engenharia do Campus de
Guaratinguetá, Universidade
Estadual Paulista, para a obtenção
do título de Mestre em Engenharia
Mecânica na área de Materiais

Orientador: Prof. Dr. Luis Rogério de Oliveira Hein

Guaratinguetá
2006

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

C837m Costa, Raquel Aparecida Abrahão
Materialografia Quantitativa De Microestruturas
Complexas Baseada Na Segmentação Por Texturas /
Raquel Aparecida Abrahão e Costa. – Guaratinguetá :
[s.n.], 2006

Bibliografia: f.96-99
Dissertação (mestrado) – Universidade Estadual
Paulista, Faculdade de Engenharia do Campus de
Guaratinguetá, 2006.

Orientador: Prof. Dr. Luis Rogerio de Oliveira Hein
1. Característica de textura, Widmanstätten I. Título

CDU 620.1



UNESP  UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia do Campus de
Guaratinguetá

**MATERIALOGRAFIA QUANTITATIVA DE
MICROESTRUTURAS COMPLEXAS BASEADA NA SEGMENTAÇÃO
POR TEXTURAS**

RAQUEL APARECIDA ABRAHÃO E COSTA

ESTA TESE FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
“MESTRE EM ENGENHARIA MECÂNICA”

ESPECIALIDADE: ENGENHARIA MECÂNICA
ÁREA DE CONCENTRAÇÃO: MATERIAIS

APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-
GRADUAÇÃO

Prof. Dr. João Andrade de Carvalho Jr.
Coordenador

BANCA EXAMINADORA:

Prof. Dr. LUIS ROGERIO DE OLIVEIRA HEIN
Orientador/UNESP-FEG

Prof. Dr. Carlos Frederico de Angelis
INPE-CPTEC

Prof. Dr. Fernando de Azevedo Silva
UNESP-FEG

Fevereiro de 2006

DADOS CURRICULARES

RAQUEL APARECIDA ABRAHÃO E COSTA

NASCIMENTO	24.09.1978 – SÃO PAULO / SP
FILIAÇÃO	Marco Aurélio de Miranda Costa Maria Sara Abrahão e Costa
1997/2003	Curso de Licenciatura em Física Faculdade de Engenharia de Guaratinguetá - UNESP
2004/2006	Curso de Pós-Graduação em Engenharia Mecânica, nível de Mestrado, na Universidade Estadual Paulista – FEG - UNESP.

Dedico esse trabalho

À Deus .

Aos meus pais Marco e Sara,
pelo amor e apoio que sempre me dedicaram.

À minha Tia Ruth e Tio Damaso,
pelo abrigo e carinho por esses anos todos.

Às minhas primas Maysie, Kátia e Tunica,
pelo impulso inicial.

Ao meu noivo Paulo,
que sempre me incentivou nas horas mais difíceis.

Ao meu Tio Carlinhos, por todo o
material, carinho e incentivo.

À Meg, Pan e Tatá.

AGRADECIMENTOS

Em primeiro lugar ao Orientador Professor Doutor Rogério Hein, pela paciência, dedicação, incentivo e oportunidade de realizar este trabalho e fazer parte do seu grupo de pesquisa.

Ao Professor Aníbal pelas aulas de C++, por sua orientação e ajuda na estrutura do algoritmo e da dissertação. E todo pessoal do INPE-DSA pela ajuda e incentivo.

As minhas amigas Tessie e Midori, pelo companheirismo, amizade e incentivo nas melhores e mais difíceis horas durante esses anos.

A minha amiga Marize, obrigado pelo empréstimo de sua apostila de C++.

À Professora Doutora Ana Paula Rosifini por suas contribuições relacionadas a liga de titânio.

Aos técnicos do Departamento de Materiais e Tecnologia, pela ajuda nas sessões de metalografia.

Á Nara, Paula e Marcos pela preparação metalografica das amostras, e auxilio na execução do trabalho.

“Deus não joga Dados”

Albert Einstein

COSTA, R. A. A. **Materialografia Quantitativa de Microestruturas Complexas Baseadas Na Segmentação Por Texturas**. 2006. XXXf. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2006.

RESUMO

A pesquisa desenvolvida para reconhecimento de padrões estatísticos com base nas informações de textura, ainda possui muitos desafios a serem superados. Um deles é a extração de características a partir de imagens que apresentam pouca variação de contraste.

Este trabalho propõe um algoritmo de seleção de características de textura baseado nas características de Haralick como a correlação e a entropia. A proposta dessa abordagem é tornar possível classificar os dados, linearmente separáveis ou não, em duas ou mais classes levando em conta um pequeno subespaço de características. Foram estudadas técnicas estatísticas para obtenção da textura, para análise e quantificação de colônias α e a fração volumétrica de Widmanstätten, presentes na liga Ti-6Al-4V.

A pesquisa culminou no desenvolvimento de um algoritmo e na realização de testes de caracterização baseadas na textura das imagens. No primeiro teste utilizou-se a correlação entre duas áreas, de dimensões diferentes, de uma mesma imagem para a identificação de pontos homólogos entre essas imagens onde foi possível a obtenção da fração volumétrica das fases α e β , onde a variação tonal é evidente. Para o segundo teste utilizou-se a correlação entre os mapas de entropia, seguindo o mesmo procedimento anterior para obter os pontos homólogos entre as imagens.

A metodologia proposta pode ser aplicada a outros tipos de materiais. A partir dos resultados da fração de área α e a fração de área das colônias α , poderão ser feito ensaios nos quais será possível relacionar as porcentagens citadas com as propriedades mecânicas da liga.

PALAVRAS-CHAVE: Característica de textura, Widmanstätten

COSTA, R. A. A. **Quantitative Materialographic of Complex Microstructures by Texture Segmentation.** 2006. XXXf. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2006.

ABSTRACT

The research developed for recognition of statistical patterns based on texture information has still many challenges to be overcome. One of them is characteristics extraction from images which display little contrast variation.

This work proposes an algorithm of texture characteristics selection based on Haralick characteristics as correlation and entropy. This initiation proposal is to make possible to classify data, linearly separable or not, in two or more ranges taking in account a little area of characteristics. It has been studied statistical techniques to obtain texture, for analysis and amount of α colony and Widmanstätten volumeter fraction, present in Ti-6Al-4V alloy.

This research has culminated in an algorithm development and in characterization tests accomplishment based on image texture. In the first test there has been used correlation between two areas of different dimensions, from the same picture for similar points identification between these images where it has been possible to obtain volumetric fraction of phases α and β where the tonal variation is evident. For the second test it has been used correlation between entropy maps, following the previous procedure in order to obtain similar points between the images.

The proposed methodology can be applied to other material types. From results of area fraction and α colonies area fraction it can be made tests in which it will be possible to relate the percentages cited with the alloy mechanical properties.

KEYWORDS: Characteristics of texture, Widmanstätten

SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

CAPÍTULO 1	18
1. INTRODUÇÃO	18
1.2 OBJETIVOS DO TRABALHO:	19
1.3 ORGANIZAÇÃO DO TRABALHO:	20
CAPÍTULO 2	22
2.JUSTIFICATIVA	22
CAPÍTULO 3	25
3.PROCESSAMENTO DIGITAL DE IMAGENS	25
3.1 IMAGEM.....	25
3.2 DIGITALIZAÇÃO: AMOSTRAGEM E QUANTIZAÇÃO.....	25
3.3 TEXTURA.....	27
3.4 ABORDAGENS PARA A DESCRIÇÃO DE TEXTURAS	29
3.5 ABORDAGEM ESTATÍSTICA	30
3.6 ABORDAGEM ESTATÍSTICA DE PRIMEIRA ORDEM	31
3.7 ABORDAGEM ESTATÍSTICA DE SEGUNDA ORDEM	32
3.8 MATRIZ CO-OCORRÊNCIA DE TEXTURA	33
3.9 CARACTERÍSTICAS DE HARALICK.....	36
3.10.1 Segundo momento angular	36
3.10.2. Entropia.....	37
3.10.3. Contraste	37
3.10.4. Correlação.....	37
3.10.5. Variância.....	38
3.10.6. Homogeneidade	38
3.11 CORRELAÇÃO DIGITAL.....	38
3.12 ENTROPIA.....	40
3.12.1 Teoria da Informação.....	40

3.12.2 Limiarização por Entropia	41
CAPÍTULO 4	42
4.MÉTODOS	42
4.1 INTRODUÇÃO	42
4.2 SISTEMA DE AQUISIÇÃO E PROCESSAMENTO DE IMAGENS	42
4.2.1 Equipamentos	42
4.2.2 Programas	43
4.2.3 Descrição dos programas utilizados	45
4.2.3.1 Bloodshed Dev-C++	45
4.2.3.2 NIH Image J.....	47
4.3 DESCRIÇÃO DO ALGORITMO	48
4.3.1 Algoritmos para detecção de parâmetros estatísticos.....	48
4.3.2 Amostragem.....	49
4.3.2.1 Amostragem da Classe inicial – imagem de referência	50
4.3.2.2 Correlação Imagem Referência e Imagem Busca	51
4.3.2.3 Saída das classes relevantes.....	52
4.4 CORRELAÇÃO DA ENTROPIA.....	52
4.4.2 Algoritmo para a detecção de parâmetros estatísticos.....	54
4.5 ANÁLISE NO PROGRAMA IMAGE J	55
4.5.1 LIMIARIZAÇÃO	55
CAPÍTULO 5	57
5.MATERIAIS	57
5.1 MATERIALOGRAFIA	57
5.1.1 Tratamento térmico.....	57
5.1.2 Resfriamento.....	58
5.2 PREPARAÇÃO MATERIALOGRÁFICA.....	58
5.2.1 Lixamento	58
5.2.2 Polimento.....	59
5.2.3 Ataque Químico.....	59
5.2.4 Microscópio	60
CAPÍTULO 6	61

6.1 RESULTADOS E DISCUSSÃO OBTIDOS NA PRIMEIRA FASE DO PROCESSO - TRATAMENTO TÉRMICO	61
CAPÍTULO 7	64
7. RESULTADOS E DISCUSSÃO OBTIDOS NA SEGUNDA FASE DO PROCESSO - PROCESSAMENTO DIGITAL.	64
7.1 Descrição do algoritmo.....	64
7.2 Diferenciação entre fase α inserida na matriz β	65
7.3 Análise dos Dados da Correlação dos Mapas de Entropia.	70
CAPÍTULO 8	94
8. CONCLUSÃO	94
CAPITULO 9	97
9. REFERÊNCIAS.....	97
ANEXO A	101
1. TITÂNIO E SUAS LIGAS.....	101
1.1 PRODUÇÃO	101
1.2 METALURGIA FÍSICA	103
1.3 O TITÂNIO E SUAS LIGAS.....	104
1.4 LIGA α	107
1.5 A LIGA $\alpha + \beta$	108
1.6 LIGAS β	110
1.7 Ti-6Al-4V	110
Composição	111
Propriedades Físicas	111
Propriedades Mecânicas	112
1.8 MORFOLOGIA MARTENSÍTICA.....	112
1.9 ESTRUTURA DE WIDMANSTÄTTEN	113
ANEXO B	116

LISTA DE FIGURAS

Figura 2.1 - Secção de uma cabeça humana, incluindo cerebelo, córtex, cérebro e as fossas nasais - 545x700 24-bit color jpeg.	23
Figura 2.2 - Aparelho de tomografia - CT Scanner Picker PQ 5000 Model	23
Figura 2.3 - Cordão umbilical.....	24
Figura 3.4 - Câmera do Hubble retrata Estufa de Estrelas em Formação	24
Figura 3.1 – Imagem digital formada por um único bit.....	26
Figura 3.2 – Imagem digital formada por oito bits.....	27
Figura 3.3: Principais aplicações da análise de texturas. (a) imagem monocromática original; (b) mapa de classes resultante da classificação da imagem, indicando as texturas presentes; (c) bordas identificadas pelo processo de segmentação	28
Figura 3.4. (a) Imagem Máscara.gif e (b) Histograma da respectiva imagem	30
Figura 3.5 (a) Figura preto e branco com um posicionamento e seu histograma.(b) Figura preto e branco com um posicionamento diferente do primeiro e seu histograma.....	32
Figura 3.6: Composição da matriz de coocorrência. Cada elemento é composto pelo numero de transições específicas entre os níveis de cinza.....	34
Figura 3.7– Cálculo de matrizes de co-ocorrência.(a) Imagem de 3x3 pixels com 4 valores de Níveis de Cinza (0,1,2,3) (b) Matriz de co-ocorrência com direção de 0° (c) Matriz de co-ocorrência com direção de 90°	35
Figura 3.8 - exemplo de matriz referencia e de matriz busca.....	39
Figura 4.1. Sistema de processamento e análise de imagens.....	43
Figura 4.2: descrição do processo de compilação	45
Figura 4.3 Ambiente de trabalho <i>Bloodshed Dev-C++</i>	46
Figura 4.5. Ambiente do <i>Bloodshed Dev-C++</i> apresentando um erro	47
Figura 4.6 Ambiente de trabalho <i>Image J</i>	48
Figura 4.7 representação das fases necessárias para representação das classes presentes na imagem.....	50
Figura 4.8 Escolha da imagem referência.....	51

Figura 4.9 método de sobreposição das imagens de busca e referência para determinação do coeficiente de correlação	51
Figura 4.10 método da escolha da escala de tons de cinza da imagem saída	52
Figura 4.11 representação das fases necessárias para representação das classes presentes na imagem	54
Figura 4.12. Imagem de saída após a correlação com imagem referencia 10x10 pixels em uma matriz de busca 300x300 pixels.	56
Figura 4.13 .A parte preta da imagem representa a matriz β e o branco as agulhas α nas estruturas de Widmanstätten	56
Figura 5.1 Forno utilizado para realização do tratamento térmico	58
Figura 5.2 Amostras após todo processo metalográfico.....	60
Figura 5.3 Microscópio óptico digital NIKON EPIHOT 200	60
Figura 6.1 CDP1.1 resfriado no ar	61
Figura 6.2 CDP1.2 resfriado no ar	62
Figura 6.3 CDP2.1 resfriado em água	62
Figura 6.4 CDP2.2 resfriado em água	63
Figura 6.5 CDP3.1 resfriado no interior do forno	63
Figura 6.6 . CDP3.2 resfriado no interior do forno	63
Figura 7.1 Fluxograma programa Correlação.....	65
Figura 7.2 (a) Máscara busca (b) Histograma da máscara busca	66
Figura 7.3 (a) Matriz de correlação – Matriz de saída - calculada a partir da máscara de busca 1000x1000 e da máscara de referência 10x10 (b) Histograma Bimodal da Matriz de saída.	67
Figura 7.4 (a) Matriz de saída aplicada o threshold (b) Sobreposição da máscara de busca com a Matriz de saída aplicada o threshold.....	68
Figura 7.5 – Identificação das fases α e β com o uso do algoritmo proposto.	69
Figura 7.6. Imagem da liga Ti-6Al-4V, tratada termicamente, evidenciando a estrutura de Widmantätten dimensão 1600x1200 pixels.	71
Figura 7.7(a) máscara de busca e localização da máscara de referência. (b) histograma da máscara de busca. A máscara de busca foi retirada da linha 300 e coluna 300, e a máscara de referência da linha 350 e da coluna 350.	72

Figura 7.8(a) Imagem de saída gerada pela correlação dos mapas de entropia referentes a figura 7.7. (b) histograma tri-modal da Matriz de saída.	72
Figura 7.9(a) Imagem de saída gerada apenas pela correlação entre a máscara de busca e o de referência., referente a figura 7.7 (b) Histograma da Imagem de saída.	73
Figura 7.10(a) máscara de busca e localização da máscara de referência. (b) histograma da máscara de busca.....	73
Figura 7.11(a) Imagem de saída gerada pela correlação dos mapas de entropia referentes a figura 7.10. (b) histograma multimodal da Matriz de saída.....	74
Figura 7.12(a) máscara de busca e localização da máscara de referência. (b) histograma da máscara de busca.....	74
Figura 7.13(a) Imagem de saída gerada pela correlação dos mapas de entropia referentes a figura 7.12. (b) histograma tri-modal da Matriz de saída.	74
Figura 7.14 (a) Operação ADD entre a máscara de busca e a matriz saída da correlação da entropia. (b) operação AND entre a máscara de busca e a matriz saída da correlação da entropia.....	76
Figura 7.15(a) Análise da primeira parte do histograma da matriz de saída da correlação da entropia (b) representação gráfica do histograma.	76
Figura 7.17 Máscara de busca usado para gerar as imagens presentes nas figuras 7.18(a,b,c,d,e,f e g)	78
Figura 7.18 Imagens e histogramas gerados a partir da variação da Máscara de referência, na mesma Máscara de busca.....	81
Figura 7.19 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.	83
Figura 7.20 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.	84
Figura 7.21 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.	85
Figura 7.22 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.	86

Figura 7.23 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.	87
Figura 7.25 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.	89
Figura 7.26. Segmentos da figura 7.21 usados para cálculo da fração de área	91
Figura 7.27. Segmentos da figura 7.22 usados para cálculo da fração de área	91
Figura 7.28. Segmentos da figura 7.23 usados para cálculo da fração de área	92
Figura 7.29. Segmentos da figura 7.24 usados para cálculo da fração de área	93
Figura 7.30. Segmentos da figura 7.25 usados para cálculo da fração de área	93

LISTA DE TABELAS

Tabela 7.1 – Valores dos desvios padrões σ e das médias μ das máscaras de busca e referência.....	68
Tabela 7.2 – área total da imagem, Média, desvio padrão, mínimo, máximo, % de área da fase α e β	68
Tabela 7.3. Valores obtidos a partir da figura 7.21	90
Tabela 7.4. Valores obtidos a partir da figura 7.22	91
Tabela 7.5. Valores obtidos a partir da figura 7.23	92
Tabela 7.6. Valores obtidos a partir da figura 7.24	92
Tabela 7.7. Valores obtidos a partir da figura 7.25	93

1. INTRODUÇÃO

O Processamento digital de imagens, sem dúvida, é uma área em constante crescimento. O interesse em suas aplicações vem principalmente de duas áreas: melhoria na informação (imagem) para interpretação humana, e o processamento de imagens em computador, pois a análise quantitativa e a interpretação de imagens representam um recurso indispensável em diferentes ramos da ciência como, por exemplo, na ciência dos materiais, no Programa Espacial, na medicina, na física, na engenharia, e outros.

Para realizar a análise de uma imagem é preciso ter-se um sistema de classificação, que usa obter informações suficientes para diferenciar regiões de interesse e/ou definir um conjunto de características capazes de descrever de maneira efetiva cada região contida em uma imagem. Este processo de classificação está fundamentado nos níveis de cinza ou cores, características de forma e textura. A característica de textura é uma importante informação para o processo de análise e interpretação de imagens, no qual é possível determinar as variações locais dos valores dos pixels que se repetem de maneira regular ou aleatória ao longo da imagem.

Uma das aplicações do uso das características de textura é a avaliação de microestruturas em ligas metálicas, ou não, para quantificação das mesmas. No caso do decorrente trabalho é adotado a liga de titânio – Ti-6Al-4V após tratamento térmico, onde fica evidenciado a estrutura de Widmstätten.

O titânio e suas ligas têm sido utilizados em várias aplicações, por exemplo, em peças de uso aeroespacial em substituição ao aço e ao alumínio e na área medica como implantes e próteses. Possuem uma excelente relação resistência mecânica/peso, boa resistência à corrosão e bio-compatibilidade.

O titânio puro em temperatura ambiente apresenta estrutura hexagonal compacta (fase α). Quando aquecido a $882,5^{\circ}\text{C}$, ocorre uma transformação alotrópica alterando a estrutura para a estrutura cúbica de corpo centrado (fase β).

Essa temperatura de transformação é sensivelmente afetada quando incluídos elementos de liga ou impurezas na estrutura primitiva. Para que ocorra a adição dos elementos de liga, surge a necessidade de se manter uma ou outra fase em equilíbrio termodinâmico. Alterações das propriedades mecânicas decorrentes das variações na microestrutura podem ser produzidas por meio do processamento termomecânico e posteriores tratamentos térmicos. As ligas $\alpha + \beta$ têm melhores propriedades mecânicas do que o titânio comercialmente puro, e com tratamentos térmicos os limites de resistência ainda podem ser aumentados significativamente (BLOOR et al,1994). O controle da microestrutura depende, essencialmente, da composição química, da temperatura dos tratamentos térmicos e da taxa de resfriamento (FLOWER ,1990). Diferentes padrões baseados em imagens foram desenvolvidos para caracterizar as microestruturas da liga Ti-6Al-4V mas a quantificação das características microestruturais em ligas α/β do Ti é muito difícil, devido a duas razões: a microestrutura é complexa e envolve as características que vão de uma ampla variação do tamanho da escala das estruturas presentes como: as larguras das agulhas de Widmanstätten, o tamanho da colônia, e o tamanho do grão que pode variar de micron a milímetros. (Russ 1994). A segunda, a informação disponível é de uma seção bidimensional da microestrutura, usando a imagem padrão do microscópio eletrônico de varredura (MEV) e técnicas de microscopia óptica, são limitadas para observar e compreender o aspecto tridimensional.

1.2 OBJETIVOS DO TRABALHO:

O foco fundamental desse trabalho é a utilização de técnicas de processamento e análise digital de imagens para a estimativa da fração volumétrica de estruturas de Widmanstätten, a partir das características microestruturais. É proposto um método para classificação de imagens através da análise de textura utilizando matrizes de co-ocorrência com ênfase no parâmetro da correlação. Para utilizar a informação contida nas matrizes de co-ocorrência

de níveis de cinza, será empregado o descritor estatístico da correlação para medir essas características texturais.

Os objetivos deste trabalho são:

- Desenvolvimento e implementação de uma rotina para análise de textura em Ti-6Al-4V, para quantificação:
 1. Tamanho e fração volumétrica das colônias α Widmanstätten;
 2. Fração volumétrica do α e β , em estruturas entrelaçadas.

Para a obtenção dos dados citados acima, uma possível classificação de imagens com base nas características de texturas o algoritmo foi desenvolvido, a princípio na linguagem C++ para, posteriormente, ser implementado no software de domínio público *NIH Image J*.

1.3 ORGANIZAÇÃO DO TRABALHO:

Este primeiro capítulo apresentou as considerações iniciais e o contexto no qual se insere este trabalho, a motivação para seu desenvolvimento e os objetivos a serem alcançados.

O Capítulo 2 apresenta a justificativa deste trabalho.

O Capítulo 3 mostra uma visão da extração de características expondo as principais técnicas que são usadas atualmente, com especial ênfase nas características de textura.

O Capítulo 4 abrange a parte relacionada a materiais, descrevendo de modo quantitativo e qualitativo, a aparelhagem usada como também programas e rotinas.

O Capítulo 5 abrange todo o processo metalográfico assim como a aquisição das imagens das microestruturas reveladas após o tratamento térmico.

O Capítulo 6 são apresentadas as imagens obtidas a partir do tratamento térmico com também a sua interpretação.

No Capítulo 7 são apresentados os resultados e discussões das imagens geradas pelo algoritmo, a descrição deste, a diferenciação entre a fase α e β e a análise dos dados da correlação dos mapas de entropia

O Capítulo 8 apresenta a conclusão.

No capítulo 9 é apresentada a bibliografia utilizada.

JUSTIFICATIVA

O processamento digital de imagens possibilita um melhor realce das imagens trabalhadas, logo, o processamento digital de imagens visa a manipulação e análise da informação pixel a pixel pelo computador, além disso, também permite auxiliar na busca por informações que não estão explícitas durante a análise pelo olho humano.

Através deste é possível fazer a reconstrução de imagens a partir de suas projeções, usado em construção de dados 3D a partir de projeções 2D, com por exemplo em tomografia computadorizada, microestruturas, ou ainda representar imagens usando suas características:

- a) representações de baixo nível: cor, textura, forma, movimento
- b) características de alto nível para reconhecimento: características da face, e por fim o reconhecimento e a classificação.

Pode ser utilizado na:

A - Biologia

- análise automática de amostras biológicas (análise de espécimes);
- análise de ossos, tecidos e células (contagem e classificação);
- análise, classificação e casamento de material DNA.

B - Defesa/Inteligência

- interpretação automática de imagens de satélite da terra;
- reconhecimento e rastreamento de alvos em tempo real.

C - Processamento de documentos

- varredura (scanning), arquivamento e transmissão de documentos;
- detecção e reconhecimento automático de caracteres impressos.

D - Automação de Fábricas

- inspeção visual de produtos e montagem.

E - Apoio da Lei

- Identificação de Pessoas;

- processamento automático de impressões digitais figura;
- reconhecimento facial;
- casamento de DNA;
- proteção e identificação de copyright;
- Segurança de Dados;
- Comunicação secreta (Steganography).

F - Diagnóstico Médico conforme demonstrado nas figuras 2.1 e 2.2.

- Imagens de Raios X;
- Tomografia Computadorizada;
- Ultra sonografia, como no exemplo da identificação das veias e artérias de um feto figura 2.3;




Figura 2.1 - Secção de uma cabeça humana, incluindo cerebelo, córtex, cérebro e as fossas nasais - 545x700 24-bit color jpeg. (www.parenthood.com)




Figura 2.2 - Aparelho de tomografia - CT Scanner Picker PQ 5000 Model




Figura 2.3 - Cordão umbilical, as cores representam as duas artérias e uma veia. (<http://www.parenthood.com/us.html?N=573>)

G - Astronomia

- separação de estrelas de galáxias;
- classificação de galáxias como na imagem enviada pela câmera do telescópio do Hubble, figura 2.4.




Figura 3.4 - Câmera do Hubble retrata Estufa de Estrelas em Formação (http://www.jpl.nasa.gov/stars_galaxies/)

H - Na Ciência dos Materiais

- descrição de micro-estruturas;
- densidade numérica por área ou volume;
- aglomeração e quantidade de colônias;
- caminho livre médio;
- distância ao vizinho mais próximo.

PROCESSAMENTO DIGITAL DE IMAGENS

3.1 IMAGEM

Uma imagem pode ser considerada um conjunto de pontos em um espaço vetorial gerado pela base canônica - função bidimensional - $F(x,y)$, onde x e y são coordenadas espaciais (plana). A amplitude de f em qualquer par de coordenadas (x,y) é chamada de *intensidade* ou *níveis de cinza*, de uma imagem em qualquer ponto. Quando x e y e os valores de amplitude de f são todos finitos, são chamados de quantidades discretas.

A representação de uma imagem capturada para um meio digital, é uma matriz linha x coluna – $F(x,y)$. Cada elemento da matriz chama-se pixel e representa a cor de um ponto da imagem, podendo ser, 0 e 1(para uma imagem binária) 0 a 255 (para tons de cinza) ou três números de 0 a 255 (representando uma cor distinta). A intensidade de cada pixel corresponde à informação local do brilho que será resposta a luz gerada ou refletida por ela.

3.2 DIGITALIZAÇÃO: AMOSTRAGEM E QUANTIZAÇÃO

Na representação de imagens digitais, leva-se em conta dois aspectos importantes a frequência da amostragem e a quantização.

A frequência de amostragem espacial ou resolução espacial determina o número de amostras que é obtido por unidade de comprimento, vertical ou horizontal, do sensor (por exemplo, 100 pontos por polegada), e, portanto é um parâmetro que determina o número de pontos por linha ou coluna do sensor. Se o sensor tiver 1 polegada quadrada, a imagem do exemplo dado teria 100x100 pontos (10000 pontos) no total.

O segundo aspecto a ser considerado é a representação da intensidade de cinza ou cor: quantização ou resolução radiométrica. Como os computadores funcionam em sistemas binários, a representação de resolução em profundidade de cor é realizada da seguinte maneira:

Imagem em preto em branco $2^1 - [0\ 1]$ (1 bit)

Imagem com 4 níveis de cor: $2^2 - [01\ 10\ 00\ 11]$ (2 bits), e assim sucessivamente.

A resolução freqüentemente adotada em níveis de cinza é 256 (2^8), representando uma resolução, portanto de 8 bits (1 byte). Na Figura 3.1, um único bit foi usado para representar a intensidade de cada posição: quando é zero, significa preto, e um, branco. Na Figura 3.2, a intensidade de 1 foi para 8 bits, ampliando os valores de intensidade de 1 para 256.




Figura 3.1 – Imagem digital formada por um único bit.




Figura 3.2 – Imagem digital formada por oito bits

3.3 TEXTURA

As características de uma imagem podem ser descritas a partir de sua efetiva classificação, possibilitando o reconhecimento de diferentes parâmetros, os quais destacam as regiões de interesse. Normalmente, o processo de classificação é baseado nos níveis de cinza ou cores, características de forma e textura. Neste sistema encontram-se as características empregadas pelo sistema visual humano, contendo informações sobre a distribuição espacial e variação de luminosidade, além de descrever o arranjo estrutural das superfícies e relações entre regiões vizinhas (SCHWARTZ,2005).

A textura é uma das mais importantes características que são usadas para classificar e reconhecer objetos e cenas. Alguns pesquisadores, também usam a definição de textura para encontrar a similaridade entre imagens contidas em um mesmo banco de dados. Mas esta definição não apresenta uma padronização, ocorrendo variações de acordo com a utilização do processo. Agora serão citadas algumas definições de textura de acordo com as diferentes áreas que a utilizam.

A textura é definida como uma combinação entre magnitude e frequência da variação tonal numa imagem, produzida pelo efeito conjunto de todas as pequenas feições que compõem uma área em particular na imagem. Embora possam ser consideradas como propriedades independentes, tonalidade e textura,

na realidade, possuem relações íntimas: sem variações em tonalidade, nenhuma mudança na textura poderia ser recebida (CROSTA,1993). Para Zhong e Jain(1999) uma região da imagem é texturizada se esta contiver algumas repetições do padrão do níveis de intensidade. A textura é caracterizada geralmente pela variação espacial, direcionada. Segundo Aksoy e Haralick(1999) textura é definida como sendo a distribuição estatística das propriedades da dependência espacial dos níveis de cinza. Em imagens monocromáticas as variações de matrizes da co-ocorrência do nível cinza são usadas para extrair esta informação. As imagens texturizadas fornecem uma informação rica sobre o conteúdo da imagem.

Para o desenvolvimento desta dissertação foi utilizada a ultima definição citada, pois a matriz de co-ocorrência é uma abordagem utilizada para extrair informações sobre a transição dos níveis de cinza entre dois pixels, baseada na repetição e variação desses.

A análise de texturas pode ser utilizada na *classificação*, que objetiva a criação de um mapa (ou uma nova imagem) onde cada região homogênea é identificada como pertencente a uma determinada classe; na *segmentação*, visando à determinação das bordas entre as diferentes regiões texturizadas contidas em uma imagem e; finalmente, na *síntese de texturas*, responsável pela determinação de um modelo capaz de identificar uma dada textura. A figura 03 abaixo exemplifica as aplicações da análise de texturas

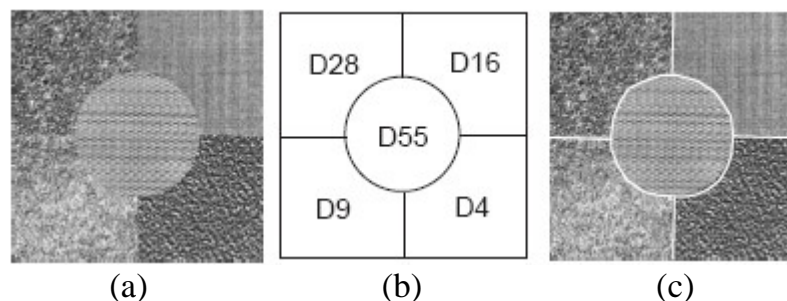


Figura 3.3: Principais aplicações da análise de texturas. (a) imagem monocromática original; (b) mapa de classes resultante da classificação da imagem, indicando as texturas presentes; (c) bordas identificadas pelo processo de segmentação;Adaptado de Schwartz(2005).

3.4 ABORDAGENS PARA A DESCRIÇÃO DE TEXTURAS

Gonzalez e Woods(1993) citam a existência de três principais abordagens que podem ser utilizadas na descrição de texturas:

- espectral
- estrutural
- estatística

A abordagem espectral diz respeito as propriedades baseadas no espectro de Fourier, onde pode ser detectada a existência de padrões periódicos ou semiperiódicos (KULLARNI,1994). A abordagem estrutural visualiza cada textura como sendo formada pela repetição de primitivas ou padrões, estes obedecendo a alguma regra de posicionamento para a sua geração (BALLARD;BROWN,1982). Na abordagem estatística, são utilizadas medidas estatísticas para descrever as texturas. Essas medidas podem ser aplicadas às texturas que não apresentam boa regularidade (BALLARD;BROWN,1982).

3.5 ESTATÍSTICA DESCRITIVA PARA IMAGENS - HISTOGRAMA

As características mais básicas de toda imagem são as medidas que definem a amplitude da imagem em termos da luminância¹, valor espectral e outras unidades. A forma com que é apresentada a distribuição do níveis de cinza em um histograma, fornece a informação sobre a natureza da imagem. Por exemplo, um histograma com uma distribuição estreita indicaria que se trata de uma imagem de contraste² baixo.

¹ Luminância: Unidade de medida da intensidade de uma fonte de luz. Também utilizada como sinônimo de brilho.

Um histograma bi-modal às vezes indica que a imagem contém um objeto que tem uma amplitude mais estreita em relação ao fundo da imagem. Essas medidas podem ser quantizadas conforme apresentado na equação 3.1:

$$P(I) = \frac{\text{número.pixels.com.nível.de.cinza.I}}{\text{número.total.de.pixels.na.região}} \quad (3.1)$$

onde $P(I)$ é a fração de pixels com nível de cinza I . Por exemplo, histograma da figura máscara.gif Figura 3.4(a) e 3.4(b), onde $P(I)$ representa o eixo da porcentagem e I para $I=0,1,\dots,N_g-1$ representa o eixo da intensidade, provê uma percepção da distribuição de cinza.

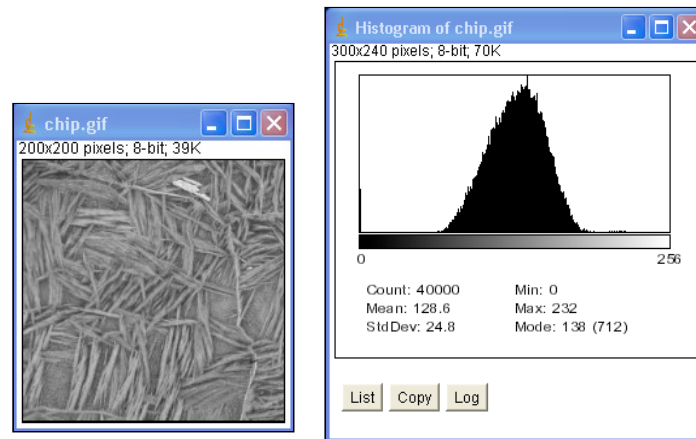


Figura 3.4. (a) Imagem Máscara.gif e (b) Histograma da respectiva imagem

3.5 ABORDAGEM ESTATÍSTICA

Segundo Russ (1994), uma das abordagens mais simples para descrever a textura é o momento, calculado a partir do histograma em níveis de cinza de uma imagem ou de uma região.

²Contraste: variação entre os tons mais claros e os mais escuros em uma imagem. Em imagens de alto contraste, as sombras ficam nos extremos da variação entre o branco e o preto. Em imagens de pouco contraste, os tons são mais próximos

Sendo z uma variável aleatória que denota a intensidade discreta da imagem e $p(z_i)$, $i=1,2,\dots,L$ o histograma correspondente, onde L é o número de níveis distintos da intensidade. O momento* de z sobre o meio é:

$$\mu_n(z) = \sum_{i=1}^L (z_i - m)^n p(z_i) \quad (3.2)$$

Onde m é o valor médio de z (intensidade média):

$$m = \sum_{i=1}^L z_i p(z_i). \quad (3.3)$$

O segundo momento é de grande importância na descrição da textura. É a medida do contraste do nível de cinza, que possa ser usado para estabelecer descritores da homogeneidade relativa. O terceiro momento é uma medida da inclinação do histograma, o quarto momento é a de seu nivelamento relativo. O quinto e o maior momento não são facilmente relacionados à forma do histograma, mas fornecem uma descrição quantitativa adicional ao índice de textura. A medida das características de textura, usando somente histogramas, sofre a limitação por não carregarem nenhuma informação a respeito da posição relativa dos pixels. Uma maneira para obter essa informação da textura é na análise do processo, onde não se deve considerar somente a distribuição da intensidade, mas também a posição dos pixels com igual ou valores quase iguais da intensidade. Com base nessa limitação, é proposta a classificação da abordagem estatística em Primeira e Segunda Ordem com segue.

3.6 ABORDAGEM ESTATÍSTICA DE PRIMEIRA ORDEM


O Histograma de uma imagem pode ser definido por uma função discreta:

$$p(z_i) = \frac{n_i}{n} \quad (3.4)$$

onde z_i é o i -ésimo nível de cinza, n_i é o número de pixels da imagem com este nível de cinza e n é o número total de pixels da imagem. Nesta abordagem o histograma (equação 3.4) da imagem fornece a possibilidade de ocorrências dos níveis de cinza i , sem a preocupação de localização espacial.

3.7 ABORDAGEM ESTATÍSTICA DE SEGUNDA ORDEM

Esta segunda abordagem analisa o processo com base no posicionamento espacial relativo da ocorrência dos níveis de cinza em uma imagem. Deste modo, uma imagem que contenha uma mesma quantidade de diferentes níveis de cinza que a outra, diferenciando-se somente em termos do posicionamento dos mesmos, irá apresentar, conforme a primeira abordagem, um mesmo histograma, como ilustrado nas figuras 3.5(a) e 3.5(b). Seguindo a abordagem de segunda ordem, as duas imagens podem ser diferenciadas mesmo tendo histogramas de primeira ordem iguais. Nesse segundo método, como proposto por Haralick et al(1973), é levado em conta o posicionamento relativo dos pixels.



(b)

Figura 3.5 (a) Figura preto e branco com um posicionamento e seu histograma.(b) Figura preto e branco com um posicionamento diferente do primeiro e seu histograma

3.8 MATRIZ CO-OCORRÊNCIA DE TEXTURA

A matriz da co-ocorrência do nível de cinza (*Grey level co-occurrence matrix – GLCM*) contém as informações sobre as posições dos pixels que têm valores de nível de cinza similares, ou seja, a matriz de co-ocorrência é uma tabulação de quantas combinações diferentes de valores de intensidade dos pixels (níveis de cinza) ocorrem em uma imagem (SCHWARTZ;PEDRINI2003).

A intenção é fazer uma varredura na imagem e manter-se a par de como se comporta a periodicidade dos pixels que diferem na intensidade e são separados por uma distância d fixa. Normalmente, a direção entre dois pixels também é importante para uma classificação a partir da textura, e esta é implementada por matrizes múltiplas, uma para cada direção de interesse. Geralmente trabalhamos em quatro sentidos: horizontal, vertical, e as duas diagonais. Para cada valor de d temos quatro imagens, cada uma na dimensão de 256×256 , para uma imagem original com 256 níveis do cinza. Ao analisar estas matrizes devemos computar alguns valores numéricos simples, encapsulando a informação. Estes valores são chamados freqüentemente descritores. Esta informação pode ser apresentada em forma da matriz de freqüências relativas $P(i,j;d,\theta)$ com a qual dois pixels vizinhos separados pela distância d e com orientação θ ocorrem na imagem, um com o nível de cinza representado por i e o outro com nível de cinza representado por j . As matrizes resultantes são simétricas e podem ser normalizadas dividindo-se cada termo entrada na matriz pelo número dos pixels vizinhos usados para computar essa matriz (AKSOY;HARALICK(1999)).

Regiões da imagem são amostradas de forma a permitir que seus pixels possam pertencer simultaneamente a múltiplas regiões, melhorando assim a determinação da classe à qual cada pixel pertence. Para cada região, um vetor de características é determinado através do cálculo dos descritores estatísticos sobre a matriz de co-ocorrência, com dependência espacial em 0° , 45° , 90° e 135° graus (HARALICK et al,1973).

A matriz de co-ocorrência de textura considera a relação entre dois pixels por vez, um chamado de pixel referência e o outro de pixel vizinho. O número de

linhas e colunas dessa matriz é proporcional à quantidade de níveis de cinza contidos na textura. Adicionalmente, o elemento $P(m,n)$ da matriz de co-ocorrência representa o numero de transições entre os níveis de cinza m e n que ocorrem na textura (SCHWARTZ,2005).

Antes que a matriz seja formada, determinam-se quais pixels e quais relacionamentos espaciais serão considerados. Conforme Schwartz(2005), constrói-se o conjunto S , no qual cada elemento é composto de dois pares ordenados denotando cada pixel envolvido na relação espacial. Após, é utilizada a relação descrita pela equação 5 para determinar o numero de transições que ocorrem entre cada par de tons de cinza contidos na textura, onde $f(x,y)$ indica o tom de cinza do pixel localizado na coordenada (x,y) .

$$P(m,n) = \#\{(i,j),(k,l) \in S \mid f(i,j) = m \text{ e } f(k,l) = n\} \quad (3.5)$$

onde (k,l) e (m,n) são as coordenadas dos pixels em questão.

O pixel vizinho escolhido pode, por exemplo, estar a leste (direita) de cada pixel referência. Isto pode ser expresso como uma relação $(1,0)$: 1 pixel na direção i , 0 pixels na direção j . Cada pixel dentro da imagem torna-se o pixel referência, iniciando no canto superior esquerdo e procedendo até o inferior direito. Os pixels situados na margem direita não têm vizinhos a sua direita, então eles não são utilizados para esta contagem (SCHWARTZ;PEDRINI,2003). A figura 3.6 abaixo exemplifica a composição da matriz para quatro níveis de cinza.

	0	1	2	3
0	P(0,0)	P(0,1)	P(0,2)	P(0,3)
1	P(1,0)	P(1,1)	P(1,2)	P(1,3)
2	P(2,0)	P(2,1)	P(2,2)	P(2,3)
3	P(3,0)	P(3,1)	P(2,3)	P(3,3)

Figura 3.6: Composição da matriz de coocorrência. Cada elemento é composto pelo numero de transições específicas entre os níveis de cinza.

O valor $P(m,n)$ é armazenado em uma linha i e em uma coluna j consiste no número de vezes em que o pixel de valor i possuem vizinho de valor j à esquerda ou à direita, no caso de $\theta = 0^\circ$, em uma distância d pré-estabelecida.

A Figura 3.7 mostra exemplos de matrizes de co-ocorrência de uma imagem de 3x3 pixels, com 4 níveis de cinza, nas direções 0° e 90° , com $|d| \leq 1$.

0	1	2
3	3	0
2	2	1

(a)

$$\begin{bmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 2 & 0 \\ 0 & 2 & 2 & 0 \\ 1 & 0 & 0 & 2 \end{bmatrix}$$

(b)

$$\begin{bmatrix} 0 & 1 & 1 & 1 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 2 \\ 1 & 1 & 2 & 0 \end{bmatrix}$$

(c)

Figura 3.7– Cálculo de matrizes de co-ocorrência.(a) Imagem de 3x3 pixels com 4 valores de Níveis de Cinza (0,1,2,3) (b) Matriz de co-ocorrência com direção de 0° (c) Matriz de co-ocorrência com direção de 90° FONTE: Adaptada de Haralick et al. (1973).

Como foi descrito por Schwartz(2005), as características de textura são extraídas a partir de outra representação da matriz de co-ocorrência, denominada de representação normalizada, mostrada pela equação 6, onde cada elemento da matriz original é dividido pela soma de seus componentes, onde H_g denota o maior nível de cinza presente na textura.

$$P_{m,n} = \frac{P(m,n)}{\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} P(i,j)} \quad m,n = 0, \dots, H_g \quad (3.6)$$

De acordo com Haralick et al(1973) é proposta a inclusão dos θ e d , já citados, para exercer o controle sobre o ângulo e a distância entre os pixels,

respectivamente. Desta maneira, diversas matrizes podem ser criadas com pequenas alterações nos parâmetros, proporcionando um maior número de características de textura.

Com o objetivo de utilizar a informação contida nas matrizes de co-ocorrência de níveis de cinza, foi utilizado o descritor estatístico - correlação - para medir características texturais. O classificador proposto atua a partir de um número N de classes presentes em uma imagem, a fim de determinarem as regiões pertencentes a cada classe.

3.9 CARACTERÍSTICAS DE HARALICK

Haralick et al (1973) apresentam um procedimento geral para extrair propriedades da textura de uma imagem. Estas características são calculadas no domínio espacial, e na abordagem estatística de segunda ordem, baseada na suposição que a informação da textura na imagem I está contida total ou parcialmente na relação espacial entre os tons de cinza na imagem. É obtido um conjunto de matrizes de co-ocorrência que apresentam dependência-espacial e probabilidade de distribuição, e é proposto um conjunto de 14 características de textura que podem ser extraídas dessas matrizes. Essas características contêm informação sobre semelhança textural da imagem, embora apenas seis dessas (segundo momento angular, entropia, contraste, variância, correlação e a homogeneidade) serão abordados.

3.10.1 Segundo momento angular

O Segundo Momento Angular (SMA) f_1 expressa a homogeneidade da imagem e é caracterizado pela soma do quadrado dos elementos de P . Conforme SCHWARTZ(2005) em uma textura áspera, poucos elementos da matriz de co-ocorrência normalizada apresentam valores diferentes de zero, e quando ocorrem, são próximos de um.

$$f_1 = \sum_i \sum_j \{p(i, j, d, \theta)\}^2 \quad (3.7)$$

3.10.2. Entropia

A entropia f_2 mede o grau de dispersão de níveis de cinza e pode também, junto com o SMA, ser utilizada como medida da homogeneidade. Este valor é alto quando os valores das matrizes de co-ocorrência são iguais e é baixo quando a concentração de valores na diagonal é alta ou quando as entradas da matriz de co-ocorrência possuem valores baixos.

$$f_2 = - \sum_{i=0}^{H_g} \sum_{j=0}^{H_g} p(i, j, d, \theta) \log p(i, j, d, \theta) \quad (3.8)$$

3.10.3. Contraste

O contraste representado por f_3 é caracterizado pela diferença do momento da matriz P, ou seja, pela diferença dos tons de cinza. Em termos da matriz de co-ocorrência, valores baixos para medida f_3 , como mostrado na equação 3.9, ocorrem quando há grande concentração de elementos significativos em torno da diagonal principal.

$$f_3 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j, d, \theta) \right\}, |i-j|=n \quad (3.9)$$

3.10.4. Correlação

A correlação f_4 é uma medida da dependência linear dos tons de cinza. Para valores de f_3 próximos a um, indica a existência de relação linear entre os pares de níveis de cinza SCHWARTZ(2005).

$$f_4 = \frac{\sum_i \sum_j (i, j) p(i, j, d, \theta) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3.10)$$

Onde μ_x , μ_y , σ_x e σ_y indicam respectivamente as médias e os desvios padrões.

3.10.5. Variância

A variância f_5 indica a variação da intensidade luminosa diretamente relacionada com a média. Dá a idéia de contraste na imagem.

$$f_5 = \sum_i \sum_j (i - \mu)^2 p(i, j, d, \theta) \quad (3.11)$$

3.10.6. Homogeneidade

A homogeneidade, mostrada na equação 3.12, assume valores altos quando a textura apresenta uma variação pequena entre os níveis de cinza da imagem.

$$f_6 = \sum_{i=0}^{H_g} \sum_{j=0}^{H_g} \frac{1}{1 + (i - j)^2} p(i, j, d, \theta) \quad (3.12)$$

3.11 CORRELAÇÃO DIGITAL

A correlação analisa o grau de relação entre duas variáveis quantitativas, isto é, analisam as duas variáveis simultâneas. A estatística **correlação** mede a força, ou o grau de relacionamento entre duas variáveis.

Segundo Filho e Ceteno(2004), o princípio da correlação digital é identificar regiões parecidas ou similares em duas imagens digitais, por meio da análise da correlação entre as mesmas. Quando duas regiões em um par de imagens são altamente similares, a correlação entre elas cresce. Regiões diferentes são caracterizadas por baixos coeficientes de correlação. Este princípio pode ser aplicado na localização de pontos homólogos em um par de imagens da mesma área.

Para a identificação dos pontos homólogos, deve-se ter uma matriz de referência, obtida em uma das imagens, que será deslocada ao longo da outra imagem para localizar o ponto mais parecido com ela. Como, na prática, é possível restringir a área de busca a uma região menor na imagem, adota-se uma matriz de busca na segunda imagem, uma região menor onde se sabe que o ponto ocorre (figura 3.8). O processo então consiste em deslocar a matriz de referência ao longo da matriz de busca procurando identificar os locais onde ambos sejam mais parecidos, medindo sua similaridade através de parâmetros como a diferença ou a correlação entre as mesmas.




Figura 3.8 - exemplo de matriz referencia e de matriz busca

Filho e Centeno (2004) afirmam que existe a possibilidade de estimativas, a partir das imagens de referência, locais onde o ponto procurado provavelmente se localiza, e é possível restringir a matriz de busca, onde o mais aconselhável seria a escolha de uma área da imagem razoavelmente grande, devido à incerteza da localização do ponto na segunda imagem. Logo, a imagem de referência, ou matriz de amostra, é representada em geral por uma pequena matriz. A matriz de busca, ao contrário, deve ser uma matriz de maior dimensão. A matriz de referencia, deve ser de ordem ímpar de tal modo que seja possível identificar a célula central. Como a matriz de amostra é deslocada ao longo da matriz de busca, para cada posição da matriz de amostra será definida uma sub-região distinta dentro da matriz de busca, a qual é chamada de matriz candidata. A

matriz candidata é aquela situada na matriz de busca, que no momento corresponde a posição da matriz de amostra (FILHO;CENTENO, 2004). Os deslocamentos da matriz de amostra sobre a matriz de busca geram diversas matrizes candidatas. O elemento central da matriz de amostra representa o ponto de referência. O resultado da análise de correlação será atribuído ao correspondente ponto na matriz candidata. O processo consiste então em posicionar a matriz de amostra em todas as possíveis posições dentro da matriz de busca e calcular, a partir dos correspondentes tons de cinza de ambas as matrizes, os valores das correlações (FILHO;CENTENO, 2004).

3.12 ENTROPIA

O conceito de entropia no campo de processamento digital de imagens é baseado na teoria da informação, Shannon(1948) achou uma única quantidade da medida da incerteza de uma fonte de informação, ele mostra que processos aleatórios tais como a fala ou a música tem uma complexidade abaixo da qual o sinal não pode ser comprimido, a esta complexidade chamou de Entropia. O termo acima mencionado tanto pode ser usado no processamento de imagens com em termodinâmica, mas com significados evidentemente distintos. Em forma a distinguir a duas aplicações do termo usamos para processamento de imagens a teoria da informação entrópica ou *Shannon's Entropy*.

3.12.1 Teoria da Informação

A premissa fundamental da teoria de informação é que a geração de informações pode ser modelada como um processo probabilístico, que pode ser medido de maneira que concorde com nossa intuição. De acordo com essa suposição, diz-se que um evento aleatório $E(mensagem)$ que ocorra com probabilidade $P(E)$ contém unidades de informação. A quantidade $I(E)$ é freqüentemente denominada de auto-informação de E. (Gonzalez, Woods , 1992)

$$I(E) = \log \frac{1}{P(E)} = -\log P(E) \quad (3.13)$$

Visto que $0 \leq P \leq 1$, $I(E)$ é sempre um número positivo. A base do logaritmo na Equação (3.13) determina a unidade utilizada para se medir essa informação. Se o logaritmo da base 2 for utilizado, a unidade resultante é chamada bit. Note que $P(E)=1/2$, $I(E) = -\log_2 1/2$, ou seja 1 bit. (Gonzalez, Woods, 1992)

A Média da auto-informação das E mensagens do conjunto $\Omega_x = \{E_0, E_1, \dots, E_{M-1}\}$ é denominada Entropia da variável aleatória X (\equiv entropia do conjunto Ω_x de mensagens). Assim, a entropia $H(X)$ da variável aleatória X é dada por:

$$H(X) = I(E) = -\sum_{k=0}^{E-1} P(E) \log_2 P(E) [bits] \quad (3.14)$$

onde E é o operador estatístico que retorna o valor do argumento.

3.12.2 Limiarização por Entropia

Na Limiarização por entropia a separação entre o primeiro e o segundo planos é alcançada localizando o máximo de um critério de entropia bidimensional. O nível de cinza de cada pixel e o nível médio de cinza de seus vizinhos são usados para gerar uma superfície de entropia. O pico desta superfície determina o nível de cinza e o nível médio de cinza ao redor do limiar. Além disso, um pixel pertence a um segmento se seu valor de nível de cinza satisfaz duas condições: a distribuição espacial do nível de cinza e a distribuição do nível de cinza. A frequência da ocorrência de cada par de níveis de cinza é calculada (ou seja, um histograma modificado). Isto irá desenhar uma superfície que deverá ter dois picos e um vale. Os picos correspondem ao primeiro e segundo planos. Eles podem ser separados pela escolha de um limiar que maximize a entropia nos dois grupos. (Abutaleb, 1989)

MÉTODOS

4.1 INTRODUÇÃO

Neste capítulo é descrito o sistema de processamento e análise de imagem, conforme objetivos proposto no capítulo 2.1, utilizado na realização deste trabalho, como também linguagem, algoritmos e tipos de imagens utilizadas.

Sequencialmente é introduzido à linguagem estruturada **C** e seu compilador, *Free Integrated Development Environment for the C/C++ Bloodshed Dev-C++*, que foi utilizada para montagem do algoritmo base de tratamento inicial da imagem.

No processamento final, ou seja a imagem de saída, é processada no programa de domínio público *NIH Image J*.

4.2 SISTEMA DE AQUISIÇÃO E PROCESSAMENTO DE IMAGENS

4.2.1 Equipamentos

Para a concepção e implementação do algoritmo foi usado diversos equipamentos que são mostrados esquematicamente na figura 4.1.

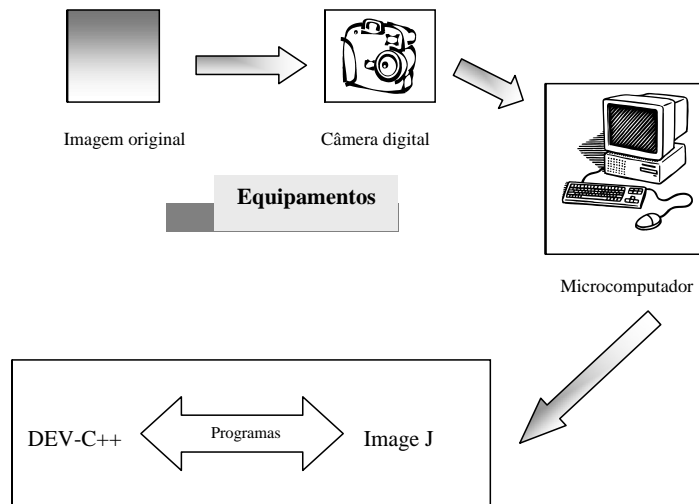


Figura 4.1. Sistema de processamento e análise de imagens

As imagens capturadas pelo microscópio óptico NIKON EPIPHOT 200 com objetivas planas cromáticas e plana procromáticas, são digitalizadas e transmitidas por uma câmera digital; **Diagnostic Instruments Spot Insight Color QE** com resolução máxima de 1600x1200 pixels com 16 bits em escala monocromática ou 48 bits em cores, ainda apresenta uma razão de aspecto unitária dos pixels, acoplada ao microscópio e a partir dessa, as imagens são enviadas para serem armazenadas e processadas no microcomputador **Dell Dimension 4700** com 1,5 Gb de RAM, processador Pentium 4HT de 3,0 GHz, um HD de 80 Gb, outro de 250 Gb e gravador de DVD.

4.2.2 Programas

A análise morfológica das imagens apresentadas exigiu uma série de procedimentos complexos e que exigiam um tempo relativamente curto para seu processamento. Salientando principalmente a rapidez que as conexões matemáticas precisam ser feitas foi escolhida a linguagem de programação C++ compilado e rodado no *Bloodshed Dev-C++*. E a posterior facilidade de ser

implementado como um plugin no programa de análise digital de imagens, de domínio público, Image-J, pela semelhança no código principal.

A linguagem de programação C foi criada e primeiramente implantada por Dennis Ritchie num Dec PDP-11, utilizando o sistema operacional UNIX. O C é o resultado do processo de desenvolvimento que começou com uma antiga linguagem chamada BCPL, desenvolvida por Martin Richards, que influenciou a linguagem chamada B, que foi criada por Ken Thompson e que levou ao desenvolvimento de C.

Embora C tenha sete diferentes tipos de cada dado interno, não é uma linguagem com digitação pesada como Pascal ou Ada. O C permite conversões de quase todos os tipos. Elementos tipo caractere e inteiro podem ser livremente misturados na maioria das expressões. Não possui nenhuma checagem de erro em tempo de processamento - tais como checagem de vetor limite ou checagem de compatibilidade tipo argumento. Isto é de responsabilidade do programador. Na figura 5.2 ilustra como é estruturado o compilador C desde a inserção do código principal até a saída dos dados.

O C é especial porque permite a direta manipulação de bits, bytes, palavras e ponteiros. Outra vantagem de ter apenas 28 palavras chaves, que são os comandos que compõem a linguagem. Para uma comparação, considere o Basic da IBM que apresenta 159 palavras chaves (SCHILDT,1989)

A linguagem C oferece uma biblioteca padrão (*C Standard Library*) que é um conjunto de funções que cobrem um conjunto de tarefas: entrada/saída, manipulação de conjunto de caracteres (*strings*), funções matemáticas e outras.

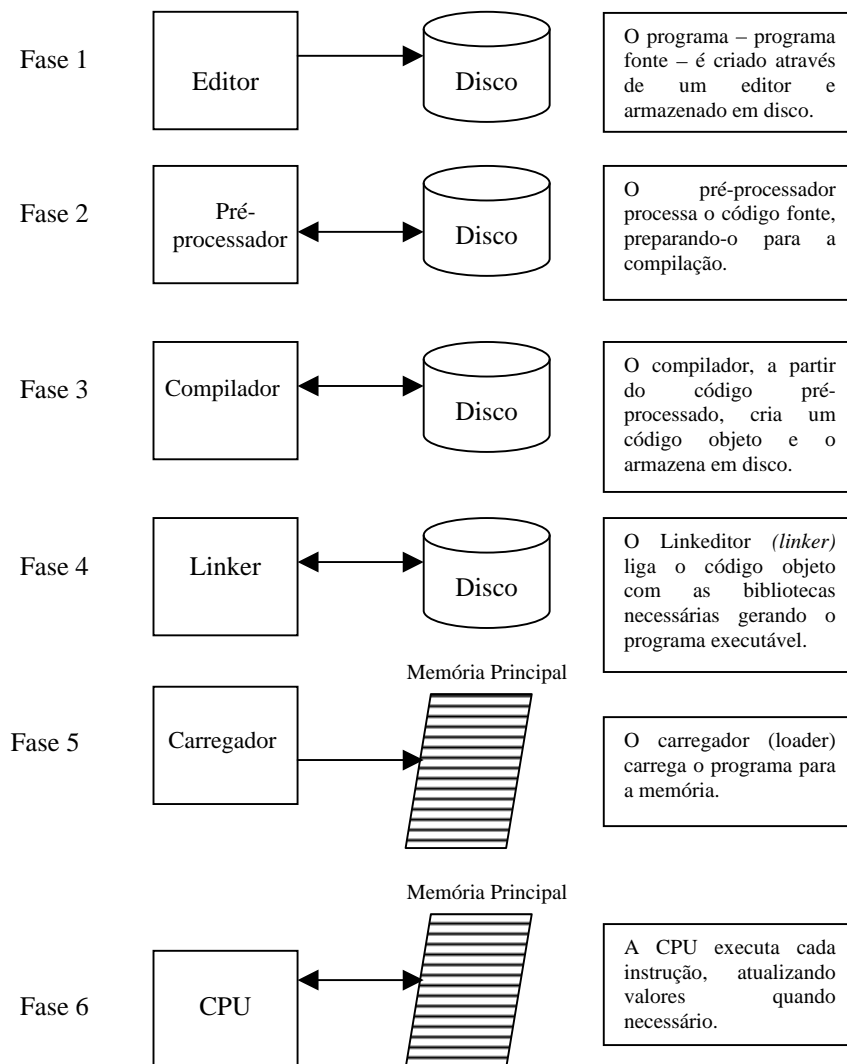


Figura 4.2: descrição do processo de compilação

4.2.3 Descrição dos programas utilizados

4.2.3.1 Bloodshed Dev-C++

Bloodshed Dev-C++ é um ambiente integrado de desenvolvimento para as linguagens *C* e *C++*. A figura 4.3 expõe o ambiente de trabalho do compilador, na figura 4.5 é mostrado um exemplo de um erro de formatação do código. Ele usa a implementação *Mingw* (ambiente integrado de desenvolvimento) do *GCC* (*GNU Compiler Collection*) como seu compilador. Ele é desenvolvido por Colin Laplace, Mike Berg e Hongli Lai e é “Free Software”.

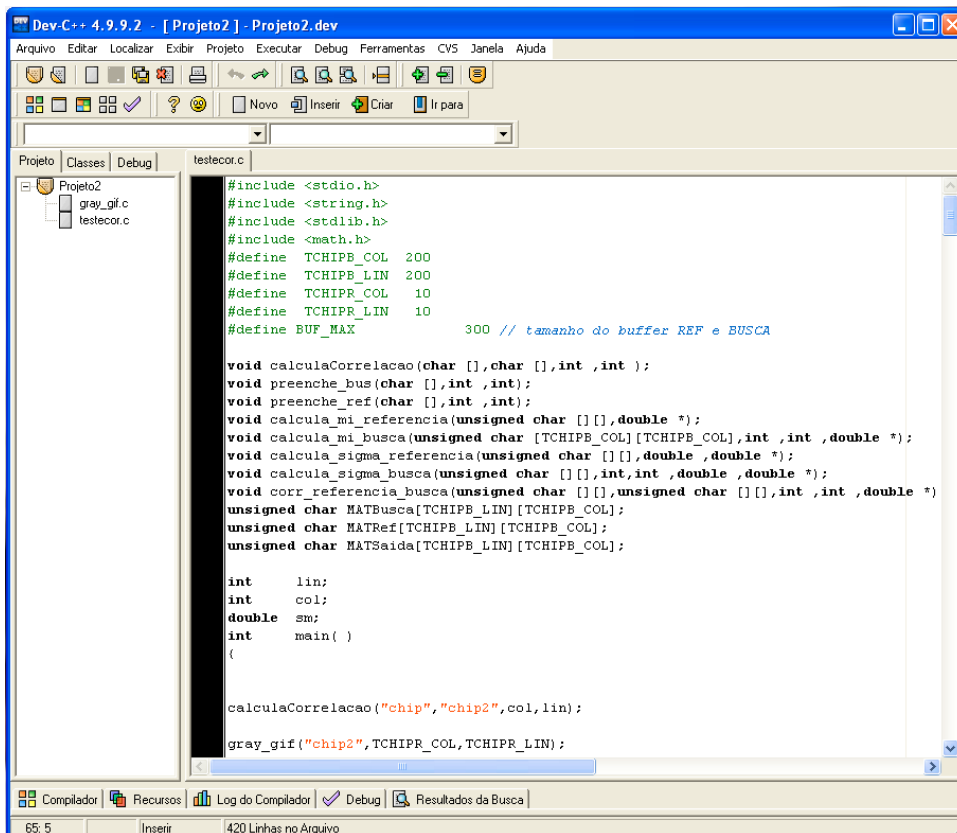


Figura 4.3 Ambiente de trabalho *Bloodshed Dev-C++*

Suas características são:

- eliminar erros integrados (que usa GDB⁷);
- gerente de projeto;
- suporte para inúmeras linguagens;
- conclusão do código;
- lista de função;
- perfil de sustentação;
- criação rápida no ambiente Windows, console, bibliotecas estática e DLLs ;
- sustentação para criar os moldes e seus próprios projetos;
- criação de arquivos;
- edita e compila;

- gerente de ferramenta.

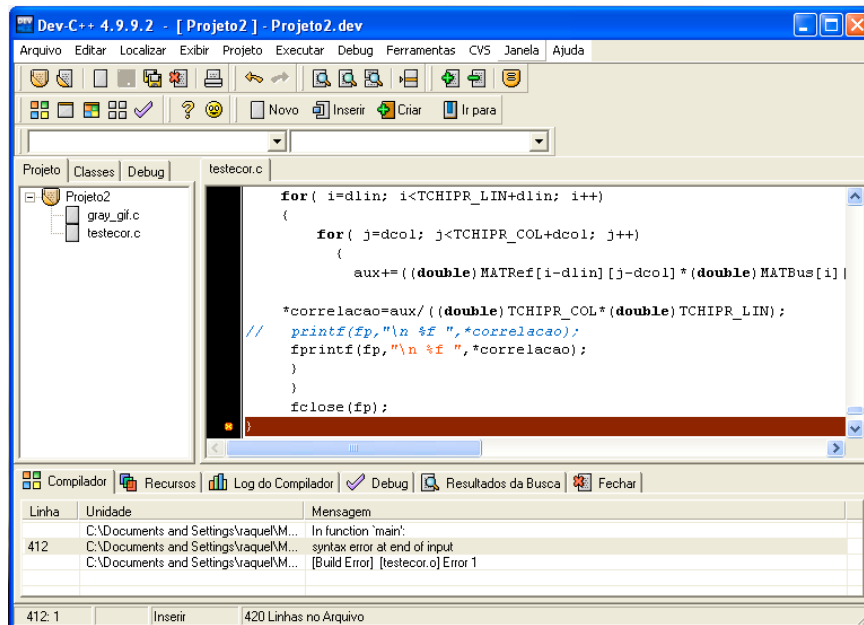


Figura 4.5. Ambiente do Bloodshed Dev-C++ apresentando um erro de sintaxe.

4.2.3.2 NIH Image J

O NIH Image J é um programa de processamento de imagem de domínio público e distribuição gratuita, inspirado pelo NIH Image para Macintosh, desenvolvido pelo *National Institute of Health*, em Bethesda, liberado por Wayne Rasband. Ele roda como um applet⁸ ou como um aplicativo em qualquer computador que possua Java 1.1 . É suportado em Windows, Mac OS, Mac OS X e Linux. Pode ler imagens TIFF, GIF, JPEG, BMP, DICOM, FITS e "RAW". Suporta pilhas ou series de imagens a serem processadas. É “multithreaded”, isto é, pode efetuar diferentes funções ao mesmo tempo, a leitura de uma pode ser executada em paralelo com outras operações.

⁷ GDB, é um projeto que permite a eliminação de erros, e permite que você veja o que está indo no interior de um outro programa quando executar -- ou o que um outro programa fazia neste momento deixou de funcionar. Este pode fazer quatro coisas principais para ajudar identificar erros no ato: Começa o seu programa, especificando qualquer coisa que pôde afetar seu comportamento; faz o seu programa para em circunstâncias especificadas; examina o que aconteceu, quando seu programa parou; muda coisas em seu programa, assim que você pode experimentar como corrigir o erro e diferentes maneiras.

⁸ pequeno programa escrito em linguagem Java para ser inserido no programa principal.

É mostrado na figura 4.6 o ambiente de trabalho do Image J.




Figura 4.6 Ambiente de trabalho Image J

4.3 DESCRIÇÃO DO ALGORITMO

Este capítulo tem como objetivo descrever e apresentar de uma maneira detalhada os dois conceitos, correlação - abordagem estatística e a limiarização – abordagem morfológica, usados na análise deste trabalho.

Assim como o desenvolvimento da metodologia aplicada para quantização: da espessura das agulhas α de Widmanstätten, tamanho das colônias, fração volumétrica do α de Widmanstätten.

4.3.1 Algoritmos para detecção de parâmetros estatísticos.

O classificador desenvolvido neste trabalho baseia-se no cálculo da distancia entre os vetores das características de uma região. Esses componentes são obtidos através do cálculo das medidas estatísticas para determinar as características texturais Haralick et al(1973), nesse caso o *coeficiente de correlação* é definido conforme equação 4.1.

$$correlacao = \frac{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} ijP(i, j, d, \theta) - \mu_x \mu_y}{\sigma_x \sigma_y}, \text{ sendo} \quad (4.1)$$

$$\mu_x = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} iP(i, j, d, \theta) \quad , \quad \mu_y = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} jP(i, j, d, \theta)$$

$$\sigma_x = \sqrt{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} i^2 P(i, j, d, \theta) - \mu_i^2} \quad , \quad \sigma_y = \sqrt{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} j^2 P(i, j, d, \theta) - \mu_j^2}$$

onde μ_x e μ_y representam as medidas das direções x e y, respectivamente e σ_x e σ_y representam os desvios padrões.

Apesar da matriz de co-ocorrência ter sido definida como sendo composta pelo numero de transições que ocorrem entre determinados níveis de cinza, como já citado anteriormente a características de textura são obtidas a partir da sua forma normalizada equação (4.2), assim temos o coeficiente de correlação

$$Cor = \frac{\frac{1}{N} \sum_{i=1}^N (X_i - M_x)(Y_i - M_y)}{\sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - M_x)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - M_y)^2}} \quad (4.2)$$

onde M_x é a média de X e M_y a média de Y. Geralmente o valor 0,81 é considerado de grande correlação (SCHILDT,1989).

4.3.2 Amostragem

A correlação digital identifica regiões parecidas ou similares em duas imagens digitais, através da análise da correlação entre as mesmas, ou seja, localiza pontos homólogos em um par de imagens.

Segundo Schwartz(2005) as classes a serem encontradas são amostradas a partir da imagem em que está sendo realizada a classificação. Sem levar em conta a ocorrência desta na imagem.

São definidas três fases para identificação das classes relevantes presentes nas imagens de entrada. A amostragem das classes iniciais – imagem referência, classificação das regiões da imagem de entrada – imagem busca e saída das classes relevantes conforme figura 4.7 abaixo.

É importante que todas as imagens se apresentem no formato “raw”. No formato RAW os dados são brutos, ou seja, apresentam-se não processados e

geralmente sem formatos, não apresentando informações de "header". Eles são de fácil leitura e escrita e são armazenados em 8 bits por pixel, variando de 0 a 255 níveis de cinza.

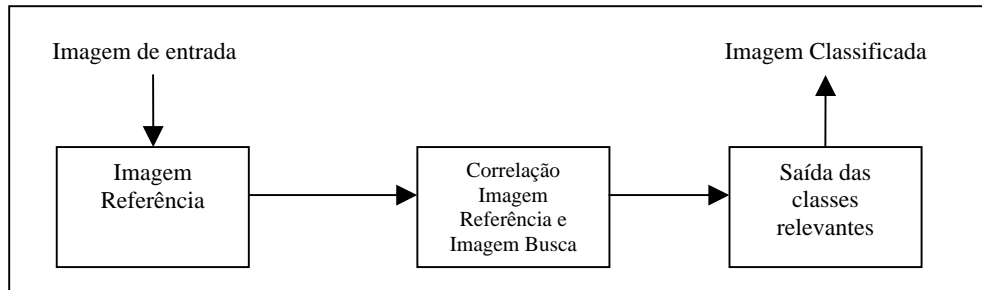


Figura 4.7 representação das fases necessárias para representação das classes presentes na imagem

4.3.2.1 Amostragem da Classe inicial – imagem de referência

Em intervalos regulares, são amostradas regiões da imagem que são chamadas de classes iniciais. Todas as amostras são quadradas e possuem o mesmo tamanho, definido pelo usuário como apresentado na figura 4.8. É escolhida uma dessas amostras e é definida como *imagem de referência*. Para essa amostra é calculada a matriz de co-ocorrência, que compõe o vetor de características (SCHWARTZ,2005).

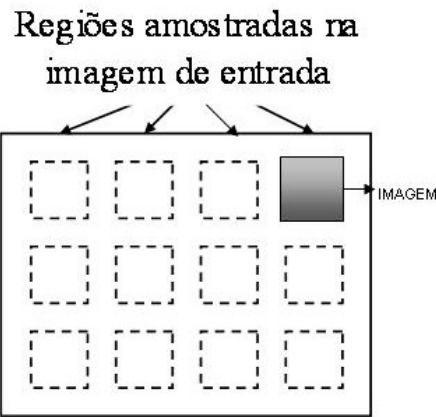


Figura 4.8 Escolha da imagem referência. Adaptado SCHWARTZ(2005).

4.3.2.2 Correlação Imagem Referência e Imagem Busca

Após a determinação da região inicial, ou seja, a imagem de referência. É deslocada a janela da Imagem de referência sobre a imagem de entrada, que é denominada – *Imagem de Busca*. Através da sobreposição, figura 4.9, dessas duas regiões é possível o cálculo do vetor característica, ou seja, é possível calcular o coeficiente de correlação entre a imagem referência e imagem busca, para possível classificação das classes dos pixels.

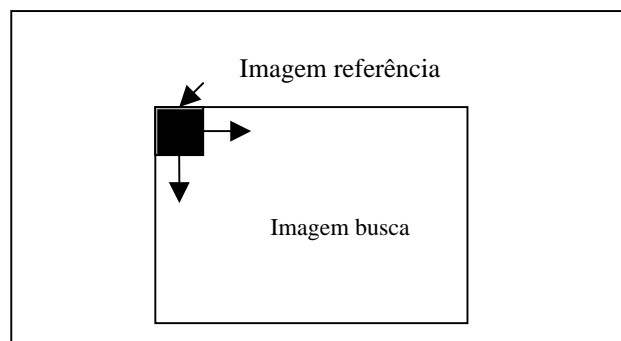


Figura 4.9 método de sobreposição das imagens de busca e referência para determinação do coeficiente de correlação

4.3.2.3 Saída das classes relevantes

Após realização do processo anterior, é gerada uma imagem com o valor do coeficiente de correlação pixel a pixel, e para cada valor é associado um tom de cinza, para gerar uma saída com a extensão gif, conforme a relação abaixo




Figura 4.10 método da escolha da escala de tons de cinza da imagem saída

O valor de correlação menor é relacionado com a cor preta e o maior valor de correlação com a cor branca. A partir a associação a cima pode chegar à seguinte relação:

$$y = \frac{255 \cdot x}{1} \quad (4.3)$$

Com x sendo o valor da correlação e o y o seu tom de cinza correspondente.

4.4 CORRELAÇÃO DA ENTROPIA

Semelhante a proposta de Schwartz(2005), para essa nova etapa foi utilizado a correlação dos mapas de entropia, das máscaras de busca e a de referência.

A correlação digital, como já foi citada, identifica regiões homólogas a partir da variação tonal entre as máscaras. Este método é eficiente para separar o fundo da imagem (segmento da imagem que apresenta maior contraste),

possibilitando assim a quantificação das fases, sendo a fase β o fundo da imagem.

Para localização das orientações das colônias α da liga Ti-6Al-4V termicamente tratada, esse método se torna ineficiente, por isso, é associada ao algoritmo outras características de Haralick, que possam gerar um histograma com uma melhor distribuição dos níveis de cinza, um número maior de picos e vales, onde cada um representa uma colônia com base nas informações da máscara de referência.

A Entropia, como característica de Haralick, faz com que o valor do nível de cinza de cada pixel, pertencente a um segmento, apresente duas condições: a distribuição espacial do nível de cinza e a distribuição do nível de cinza. A frequência da ocorrência de cada par de níveis de cinza se torna possível de ser calculada, ou seja, através de um histograma modificado. Esta é a medida da incerteza associada a uma determinada distribuição, cujas propriedades matemáticas possibilitam a sua aplicabilidade para o efeito.

Considere-se um conjunto de acontecimentos possíveis cujas probabilidades de ocorrência são dadas por p_1, p_2, \dots, p_n . A entropia $H=H(p_1, \dots, p_n)$ surge como uma medida de incerteza, assumindo as seguintes propriedades (Shannon 1948, Shannon et al 1963 e Fieldman 1998):

- 1 – A entropia é contínua em $p_i, i=1, \dots, n$;
- 2 – Se $p_i = 1/n$, então a entropia é uma função monótona crescente em n , pois quanto maior for o número de acontecimentos possíveis, maior é a incerteza e a possibilidade de escolha;
- 3 – A entropia é maximizada numa distribuição uniforme (incerteza completa);
- 4 – A entropia de um conjunto é aditiva, i. e., é igual à soma da entropia dos vários subconjuntos que o compõem e,
- 5 – A entropia é função da distribuição em si e não depende da forma como são agrupados os eventos, isto é, a entropia é uma função de estado. (Dionisio et al 2003)

4.4.2 Algoritmo para a detecção de parâmetros estatísticos

Como foi explicitado no item 4.3.1 na equação 4.2, é feita a correlação entre duas imagens, nesse caso específico, vai correlatar duas imagens onde anteriormente foi calculada a entropia para cada termo da imagem.

$$Cor_{entropia} = \frac{\frac{1}{N} \sum_{i=1}^N (Xe_i - Me_x)(Ye_i - Me_y)}{\sqrt{\frac{1}{N} \sum_{i=1}^N (Xe_i - Me_x)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (Ye_i - Me_y)^2}} \quad (4.4)$$

onde Xe , é o mapa de entropia da matriz de busca, Me_x é a média de Xe , e Ye , é o mapa de entropia da matriz de referência, Me_y é a média de Ye .

A amostragem segue igual ao item 4.3.2, ocorrendo uma mudança apenas na figura 4.7, onde a imagem de referência e de busca, são mapas de entropia, como na figura (4.11)

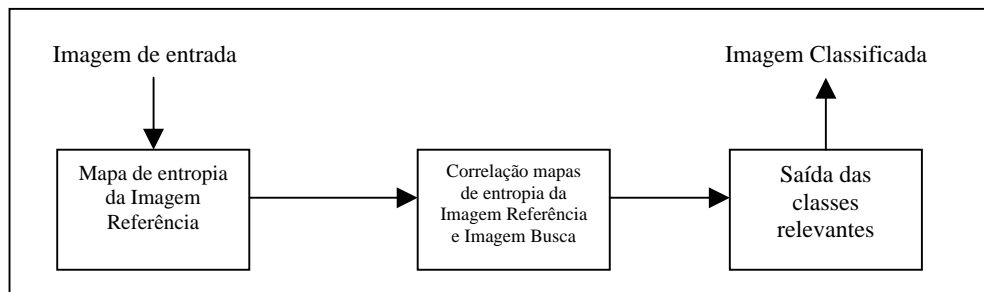


Figura 4.11 representação das fases necessárias para representação das classes presentes na imagem

A amostragem das classes iniciais segue igual ao item 4.3.2.1, a correlação máscara de referência e máscara de busca seguem igual ao item 4.3.2.2, a saída das classes relevantes igual ao item 4.3.2.3.

4.5 ANÁLISE NO PROGRAMA IMAGE J

Neste item serão mostradas algumas operações usadas para possibilitar as medições citadas no capítulo 1.

4.5.1 LIMIAZIZAÇÃO

A Limiarização(thresholding) é definida como um valor mínimo de alguma quantidade. É o método de segmentação mais simples que é utilizado mais como passo inicial. Dada uma imagem $f(x,y)$ em tons de cinza, a limiarização tem como saída uma imagem binária $g(x, y)$ onde:

$$\begin{aligned}g(x, y) &= 0, \text{ se } f(x, y) < T; \\g(x, y) &= 1, \text{ se } f(x, y) \geq T.\end{aligned}\tag{4.5}$$

onde T é o limiar (*threshold*), $g(x, y) = 1$ para os pontos dos objetos da imagem e $g(x, y) = 0$ para pontos que pertençam ao fundo da imagem.

A escolha de T é fundamental para o processo. Entretanto é muito raro uma imagem ser segmentada corretamente com apenas um valor para o limiar. Para solucionar este problema é possível utilizar a limiarização(threshold) adaptativa (segmentação utilizando limiares variáveis), onde o limiar varia em função das características locais da imagem (Grupo de Base de Dados e Imagens)⁸.

A limiarização nos permite separar as regiões de uma imagem quando esta apresenta duas classes (o fundo e o objeto) figura 4.11. A forma mais simples de limiarização consiste na bipartição do histograma, convertendo os pixels cujo tom de cinza é maior ou igual a certo valor de limiar (T) em brancos e os demais em pretos, como mostra a figura 4.12.




Figura 4.12. Imagem de saída após a correlação com imagem referencia 10x10 pixels em uma matriz de busca 300x300 pixels.

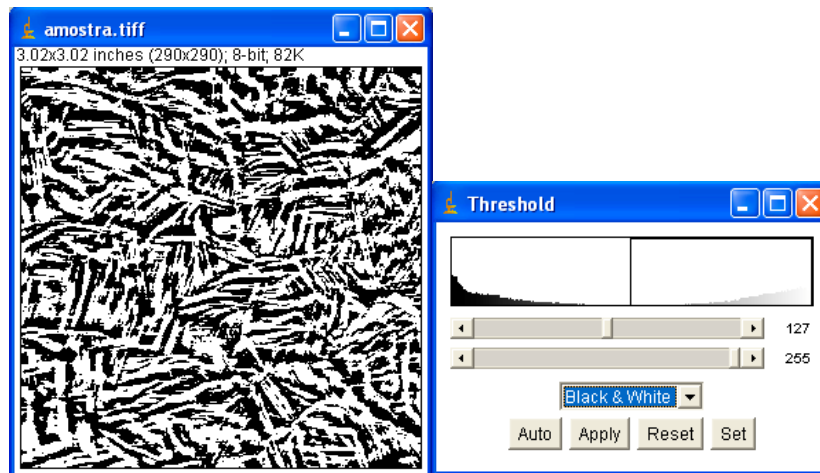


Figura 4.13 .A parte preta da imagem representa a matriz β e o branco as agulhas α nas estruturas de Widmanstätten

MATERIAIS

O material utilizado neste estudo foi uma liga metálica Ti-6Al-4V, doada pela Empresa Brasileira de Aeronáutica S.A (Embraer), utilizada em aplicações estruturais de aeronaves. Durante essa primeira etapa foram utilizadas três amostras da liga Ti-6Al-4V, visando a obtenção da microestrutura de Widamanstätten. Toda parte experimental foi realizada nos laboratórios do Departamento de Materiais e Tecnologia - DMT FEG/UNESP.

5.1 MATERIALOGRAFIA

5.1.1 Tratamento térmico

As amostras foram aquecidas em um forno elétrico tipo mufla modelo EDG figura 5.1, no laboratório de Cerâmica do DMT - hermeticamente fechado e revestido de cerâmica refratária, submetidas a uma taxa de 20°C por minuto até atingir o patamar de 1050°C, este patamar foi assegurado durante 20 minutos.

Durante o aquecimento foram seguidas algumas normas, a saber: o aquecimento deve ser gradual, a peça deve aquecer-se uniformemente por todos os lados, não deve permitir um contato direto das peças com a resistência. Condições ambientes iniciais: temperatura externa de 27°C, umidade atmosférica de 60% e pressão de 750 mmHg.



Figura 5.1 Forno utilizado para realização do tratamento térmico

5.1.2 Resfriamento

- 1) dentro do forno - resfriamento lento;
- 2) a temperatura ambiente (27°C) resfriamento moderado;
- 3) na água resfriamento rápido.

As amostras ao serem aquecidas sofrem quebras de suas ligações atômicas. As diferentes formas de resfriamento utilizadas acarretam diferentes rearranjos microestruturais, dependentes das diferentes perdas de energia que cada meio refrigerante proporciona.

5.2 PREPARAÇÃO MATERIALOGRÁFICA

5.2.1 Lixamento

O lixamento foi feito utilizando-se papel lixa de carbeto de silício (SiC), com sete diferentes granulometrias (220, 320, 400, 600, 1000, 1200 e 2000). Nas etapas finais de lixamento, as lixas com granulometria 2000 foram empregadas na etapa final de lixamento assim como, a lubrificação aquosa junto com parafina, assegurando a baixa deformação na superfície da amostra evitando deformar e aquecer demasiadamente a microestrutura.

Após o lixamento mecânico, as amostras foram imersas em éter contido em um béquer e deixados durante 20 minutos em ultra-som, possibilitando a remoção de partículas de abrasivos que possam ficar retidas na superfície da amostra.

5.2.2 Polimento

Nesta etapa foram utilizados panos para polimento Struers OP-CHEN e solução coloidal de sílica (OPS, *Struers*), diluída em um terço em água destilada. Para ajudar na lubrificação e reduzir a agressão à superfície do metal, adicionaram-se algumas gotas de sabão líquido no tecido da politriz automática que o laboratório do DMT FEG/UNESP possui. Essa politriz garante 45 minutos de polimento contínuo, o que assegura uniformidade e qualidade para a superfície.

5.2.3 Ataque Químico

Para visualizar a microestrutura foi necessário realizar um ataque químico. Essa etapa tem como objetivo tornar evidente as diferentes microestruturas obtidas com o tratamento térmico. Submergiram-se as amostras em uma solução de 3% de ácido fluorídrico (HF) por dez segundos, por se tratar de um ácido forte e extremamente prejudicial às lentes do microscópio óptico, foi necessário deixar as amostras em água corrente após o ataque por cinco minutos.

A amostra número um foi resfriada no ar, a amostra dois foi resfriada na água e a terceira foi resfriada dentro do forno mufla.



Figura 5.2 Amostras após todo processo metalográfico.

5.2.4 Microscópio

Após o ataque químico, essas microestruturas foram analisadas no microscópio óptico **NIKON EPIPHOT 200** figura 5.3, com objetivas de 50x e 100x.

As imagens das microestruturas reveladas foram capturadas e salvas para posterior quantificação.

As imagens obtidas das três amostras com duas ampliações diferentes 50x estão expostas no Capítulo 6.



Figura 5.3 Microscópio óptico digital NIKON EPIPHOT 200

6.1 RESULTADOS E DISCUSSÃO OBTIDOS NA PRIMEIRA FASE DO PROCESSO - TRATAMENTO TÉRMICO

Após o tratamento térmico descrito no ítem 5.1.1 e 5.1.2, foi obtido os seguintes resultados.

No corpo de prova um, que foi retirada do forno após o tempo previsto e deixada resfriar em temperatura ambiente obtivemos a seguinte imagem – figura 6.1 e 6.2 - de sua microestrutura. É tido que os átomos constituintes do material possuem maior tempo; comparado com um resfriamento brusco; para restabelecerem suas ligações, estando longe de suas ligações anteriores ao tratamento. Observa-se o crescimento da fase alfa (conglomerados de coloração branca junto das agulhas) tendo como um fator precursor às ligações entre os átomos mais similares às iniciais. Ou seja, é notada a nucleação da fase na matriz β retida, já com a formação de colônias α .




Figura 6.1 CDP1.1 resfriado no ar




Figura 6.2 CDP1.2 resfriado no ar

O corpo de prova dois foi exposto a um resfriamento brusco, em água, saindo de um ambiente a 1050°C para um de 25°C. Nas figuras 6.3 e 6.4 é possível observar a formação das estruturas de Widmanstätten, nas quais a fase α precipitada praticamente encobre a matriz β retida. Esta estrutura não representa a condição estável do material, pois apresenta a energia retida nestas agulhas de Widmanstätten, entretanto tal energia tende a se dissipar com o tempo elevando a entropia do sistema e atingindo uma condição de maior estabilidade, sendo esta a de disseminação das agulhas. Esta estrutura é mais importante em relação a proposta deste trabalho.

O corpo de prova três foi resfriado no interior do forno, este que melhor reestruturou suas ligações atômicas formando apenas as fases α e β . Nas figuras 6.5 e 6.6 é observado que ocorre um total crescimento da fase α na matriz β . Esta estrutura é a mais estável dentre todas, podendo sofrer transformações ao longo do tempo, mas com pouca variação organizacional.




Figura 6.3 CDP2.1 resfriado em água




Figura 6.4 CDP2.2 resfriado em água

A variação das tonalidades deve-se ao tratamento térmico, e a polarização: a fase β apresenta célula unitária cúbica de corpo centrado com todas as arestas do mesmo tamanho, quando incidida luz sobre qualquer face esta não apresentará mudança na coloração em razão da simetria presente; todavia, a fase α é hexagonal, apresentando valores das faces e de suas arestas diferentes entre si, devido a esta configuração quando a luz é incidida dependendo da fase receptora refletirá uma coloração diferente.




Figura 6.5 CDP3.1 resfriado no interior do forno




Figura 6.6 . CDP3.2 resfriado no interior do forno

7. RESULTADOS E DISCUSSÃO OBTIDOS NA SEGUNDA FASE DO PROCESSO - PROCESSAMENTO DIGITAL.

Como foi visto no capítulo 3, a textura é definida como sendo a distribuição estatística das propriedades da dependência espacial dos níveis de cinza, ou seja, é usada para classificar e reconhecer objetos e cenas. A principal dificuldade para classificação de imagens de Ti-6Al-4V tratada termicamente, com base nas características de textura, está na identificação de áreas com mesma orientação de agulhas α de Widmanstätten.

O algoritmo desenvolvido consiste em uma rotina para cálculo entre os vetores característicos de uma região e de reconhecimento de parâmetros semelhantes entre essas regiões em um par de imagens. Como explicitado anteriormente, o parâmetro da correlação foi o selecionado, pois expressa uma idéia de linearidade de dependências de tons de cinza em uma imagem, e a partir de uma comparação é possível classificar a área de interesse.

7.1 Descrição do algoritmo

Nesta segunda etapa, após a aquisição das imagens, foi compilado e executado um programa na linguagem C++, o qual correlata diferentes imagens para prover uma imagem que apresenta um mapa da textura do corpo de prova dois, que apresentou a estrutura de Widmanstätten.

Segue um fluxograma – figura 7.1- da modelagem do programa - *correlação* - utilizado.

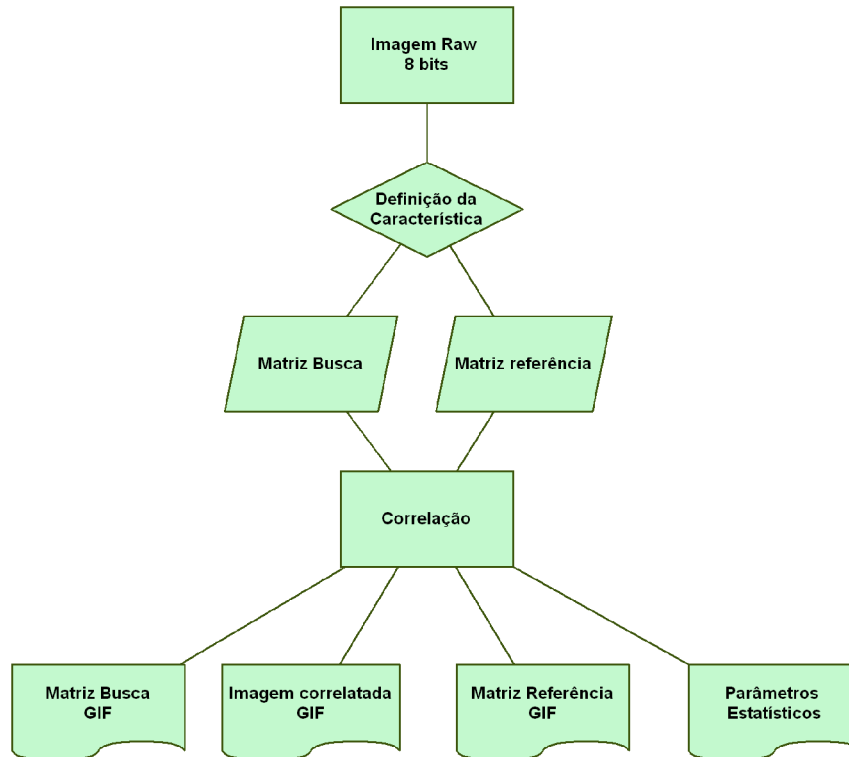


Figura 7.1 Fluxograma programa Correlação

7.2 Diferenciação entre fase α inserida na matriz β

De acordo com a expressão 4.2, é dito que a correlação – normalizada - é o grau de similaridade normalizado entre as duas imagens. Como as imagens comparadas são da mesma cena (região), só que capturadas em dimensões diferentes, as possíveis variações detectadas (baixo grau de correlação) terão relação direta com a variação de tonalidade da cena. Desta forma, interpretam-se as regiões que possuem um valor baixo no Mapa de correlação (regiões escuras) como sendo regiões onde houve grande variação entre as imagens. Por outro lado, regiões com altos valores de correlação (regiões claras) são interpretadas como sendo regiões em que houve pouca variação entre as imagens.

A figura 7.2(a) mostra a imagem de uma área de um corpo de prova da liga Ti-6Al-4V obtidas pelo microscópio óptico e na figura 7.2(a) – *matriz busca*. Depois de aplicado o algoritmo, é gerada a figura 7.3(a), onde é mostrada a matriz correlação calculada por 4.2 utilizando-se uma máscara de referência (10x10) e a máscara de busca figura 7.3(a) (1000x1000) e seu respectivo

histograma em 7.3(b). O trecho escuro (de baixa co-ocorrência) ao longo da imagem é a de menor correlação e representa a fase β , analogamente, o contraste branco representa a parte com maior correlação a fase α .

Segue a tabela 7.1 na qual estão presentes os valores das médias ($\mu_{\text{referência}}$ e μ_{busca}) e desvios padrões ($\sigma_{\text{referência}}$ e σ_{busca}) indicando a variabilidade e a dispersão dos dados em torno da média, na imagem de busca e de referência.

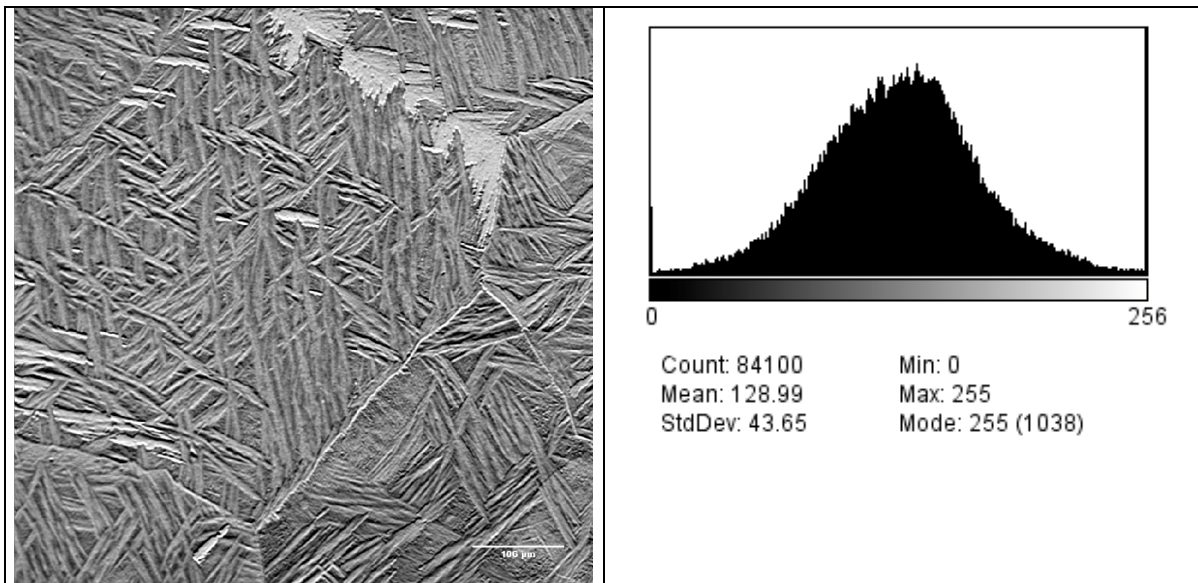


Figura 7.2 (a) Máscara busca (b) Histograma da máscara busca




Figura 7.3 (a) Matriz de correlação – Matriz de saída - calculada a partir da máscara de busca 1000x1000 e da máscara de referência 10x10 (b) Histograma Bimodal da Matriz de saída.

Depois da limiarização da Matriz de saída, figura 7.4(a) ficou mais evidente a separação entre as fases α e β , onde o preto representa a fase β e o branco a fase α e foi possível a quantificação dessas fases.

Para ser obtida a porcentagem da fração de área de cada fase, foi usado o programa de domínio público *Image J*, na imagem limiarizada, o qual gerou a tabela 7.2 com os valores da área total em pixel, média, desvio padrão, mínimo, máximo, porcentagem da fase α e β .




Figura 7.4 (a) Matriz de saída aplicada o threshold (b) Sobreposição da máscara de busca com a Matriz de saída aplicada o threshold

Tabela 7.1 – Valores dos desvios padrões σ e das médias μ das máscaras de busca e referência

σ_{busca}	25.526
$\sigma_{\text{referência}}$	49.136
μ_{busca}	132.410
$\mu_{\text{referência}}$	16.080

Tabela 7.2 – área total da imagem, Média, desvio padrão, mínimo, máximo, % de área da fase α e β .

Área(pixel)	Média	Desvio Padrão	Min	Max	%Area α (pixel/ μm)	%Area β (pixel/ μm)
439966.890	129.255	127.488	0	255	49.312	50.688

Feito uma ampliação na imagem 7.4(b), é observado que as fases foram separadas com certa eficiência como mostrado na figura 7.5. A área da imagem de busca evidenciada nos mostra uma lamela da fase α em uma tonalidade mais clara, comparando-a com a imagem que foi gerada a partir da sobreposição da máscara de busca com a Matriz de saída aplicada o *threshold* onde apresenta em branco o valor da fase α e em tonalidades de cinza a fase β .




Figura 7.5 – Identificação das fases α e β com o uso do algoritmo proposto.

Em uma análise com base nos histogramas apresentados nas figuras 7.2(b) e 7.3(b), é observado como é a distribuição estatística do pixels (“luminância”) na máscara de busca e na matriz saída. Na figura 7.2 é apresentado a imagem da máscara de busca e seu respectivo histograma imagem, com as informações do histograma é dito de uma imagem de baixo contraste, onde não apresenta uma distribuição tonal de pixel de uma maneira uniforme, mostrando a similaridade dos tons de cinza na imagem . Após a aplicação da rotina, um histograma bimodal é obtido, representado pela figura 7.4(b). É classificado desta forma devido a presença de dois picos, ou duas regiões de luminância com maior incidência de pixels da imagem. Este é o caso típico de imagens que apresentam objetos e fundo de maneira bem definida, como a imagem 7.4(a). Ou seja, ocorreram duas distribuições com diferentes valores das médias.

7.3 Análise dos Dados da Correlação dos Mapas de Entropia.

No item 7.2, foi realizada a correlação entre a máscara de referência e a máscara de busca sem processamento anterior, no método descrito neste item, foram correlatadas imagens compostas pelos mapas de entropia, como resultado foi gerada uma imagem com base nesses valores, obedecendo a escala citada na figura 4.10.

Os mapas de entropia, em geral, apresentam a indicação de quão uniforme estão distribuídos os elementos da imagem. A frequência da ocorrência de cada par de níveis de cinza se torna possível de ser calculada, ou seja, através de um histograma modificado. Esta é a medida da incerteza associada a uma determinada distribuição, cujas propriedades matemáticas possibilitam a sua aplicabilidade para o efeito.

O conceito de entropia (entropia de Shannon) é o de uma medida de informação calculada pelas probabilidades de ocorrência de eventos individuais ou combinados. Sejam X e Y variáveis aleatórias e P a função probabilidade. Formalmente, a entropia de X e Y é definida como (Martins Junior, 2004):

$$H(X,Y) = -\sum \sum P(x,y) \log P(x,y) \quad (7.1)$$

A entropia como função critério para seleção de características surge da capacidade que esse conceito estatístico possui de medir o grau de aleatoriedade (ou de incerteza) de variáveis individuais ou combinadas. Dada à distribuição de X , quanto menor o grau de aleatoriedade de Y condicionado aos valores de X , mais informação teremos sobre o comportamento de Y quando tomamos como referência os valores de X . Um caso extremo é quando Y for totalmente determinado por X , tendo grau de aleatoriedade nula, ou seja, a entropia é nula. (Martins Junior, 2004)

Para distinguir regiões de características similares, nos mapas de entropia, foi medida a correlação entre X e Y . Sendo X Máscara de Busca e Y Máscara de referência.

A correlação dos mapas de entropia é dada pela relação:

$$Cor_{entropia} = \frac{\frac{1}{N} \sum_{i=1}^N (Xe_i - Me_x)(Ye_i - Me_y)}{\sqrt{\frac{1}{N} \sum_{i=1}^N (Xe_i - Me_x)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (Ye_i - Me_y)^2}} \quad (7.2)$$

onde Xe , é o mapa de entropia da matriz de busca, Me_x é a média de Xe , e Ye , é o mapa de entropia da matriz de referência, Me_y é a média de Ye .

Os valores da média indicam o valor médio de luminosidade nas imagens, e o desvio padrão indica a variação da intensidade com relação à média, dando idéia do contraste da imagem.

Esta primeira análise será em torno dos histogramas, que é dito como a descrição global da distribuição dos níveis de cinza, gerados pela imagem de busca e pela imagem gerada pelo algoritmo da correlação da entropia.

Foram fixados as dimensões das Máscaras de referência 40x40 pixels e Máscaras de busca 140x140 pixels, variando apenas a sua posição na imagem original figura 7.6.




Figura 7.6. Imagem da liga Ti-6Al-4V, tratada termicamente, evidenciando a estrutura de Widmantätten dimensão 1600x1200 pixels.

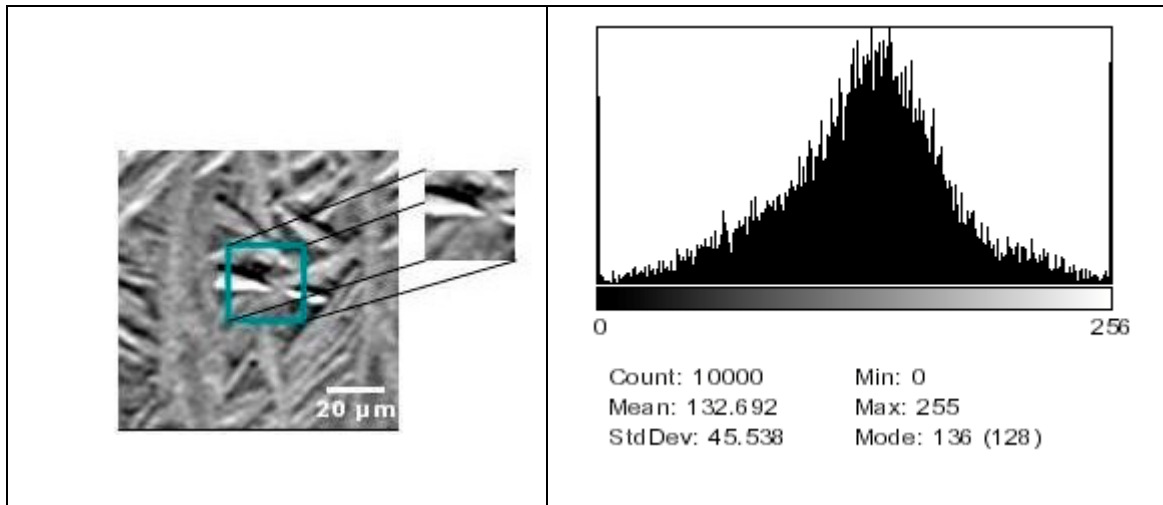


Figura 7.7(a) máscara de busca e localização da máscara de referência. (b) histograma da máscara de busca. A máscara de busca foi retirada da linha 300 e coluna 300, e a máscara de referência da linha 350 e da coluna 350.

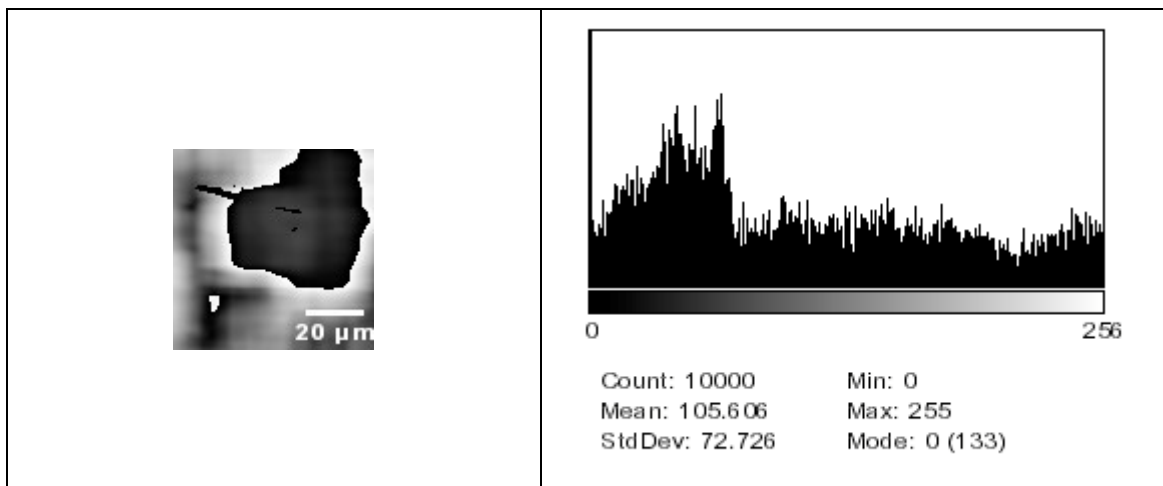


Figura 7.8(a) Imagem de saída gerada pela correlação dos mapas de entropia referentes a figura 7.7. (b) histograma tri-modal da Matriz de saída.

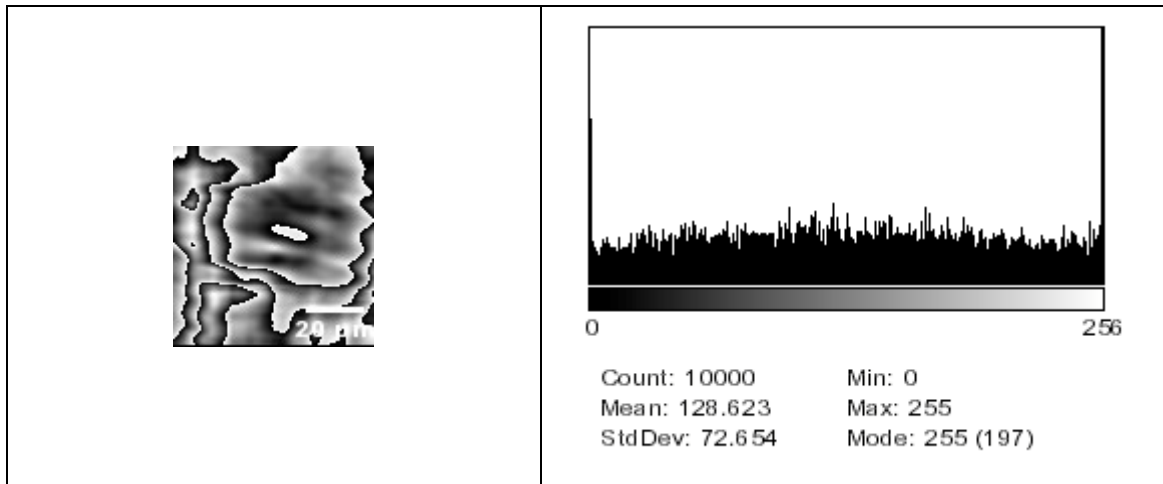


Figura 7.9(a) Imagem de saída gerada apenas pela correlação entre a máscara de busca e o de referência., referente a figura 7.7 (b) Histograma da Imagem de saída.

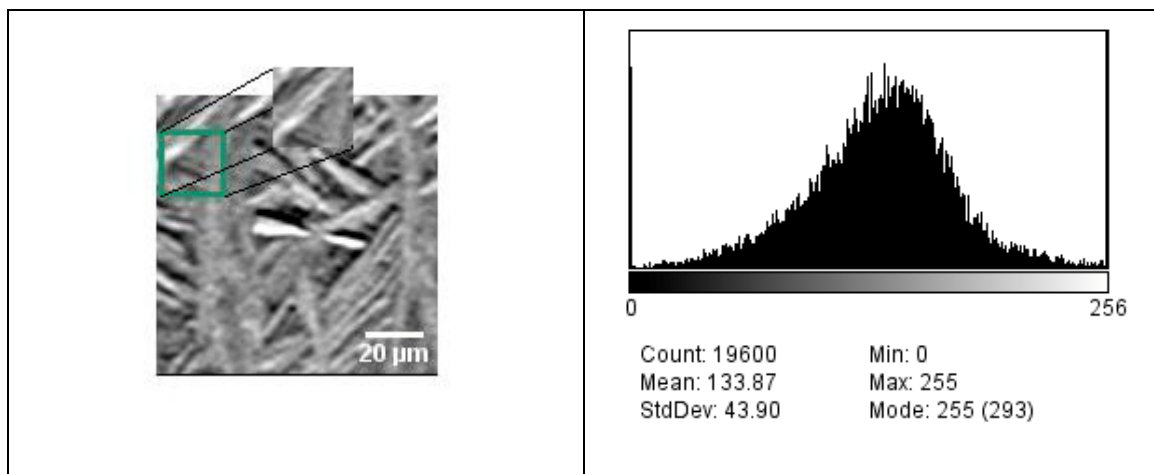


Figura 7.10(a) máscara de busca e localização da máscara de referência.
(b) histograma da máscara de busca




Figura 7.11(a) Imagem de saída gerada pela correlação dos mapas de entropia referentes a figura 7.10. (b) histograma multimodal da Matriz de saída.




Figura 7.12(a) máscara de busca e localização da máscara de referência. (b) histograma da máscara de busca.




Figura 7.13(a) Imagem de saída gerada pela correlação dos mapas de entropia referentes a figura 7.12. (b) histograma tri-modal da Matriz de saída.

Segundo Martins Junior (2004), para dar uma idéia sobre o potencial da entropia como critério para seleção de características, deve-se considerar um gráfico onde os padrões Y são representados pela abscissa e a probabilidade desse padrão se repetir na área analisada é representada pela ordenada X . Se o gráfico apresentar um pico saliente (massa de probabilidades bem concentrada), significa que a entropia $H(Y,X)$ é pequena, isto é, X prediz os padrões de Y com boa confiança. Por outro lado, se o gráfico apresenta-se achatado (massa de probabilidades bem distribuída), a entropia $H(Y,X)$ é alta, significando que X não prediz Y . Portanto, a entropia pode ser usada como um critério bastante apropriado para realizar seleção de características.

O histograma 7.7(b) indica como está a distribuição dos pixels da máscara de busca em relação aos tons de cinza. É observada uma concentração em torno do ponto 128, ou seja, a sua moda - histograma mono-modal.

O histograma 7.8(b) é composto pelas informações da entropia, e apresenta três partes distintas – histograma tri-modal, sendo cada uma dessas partes responsável pelo reconhecimento de um padrão que se repete na imagem, de acordo com Martins Junior (2004).

A figura 7.9(a) representa a matriz de saída gerada pelo algoritmo. Para essa imagem foi usada somente a correlação entre a máscara de busca e a de referência. É notado a partir do seu histograma figura 7.9(b), que nessas condições é impossível separar as texturas, pois foi gerada uma imagem homogênea com base nos seus tons de cinza dos pixels não associando a sua posição relativa.

Para qualificar as texturas relacionadas com a Máscara de referência, foi usada operação matemática ADD (adição), do programa *NIH Image J*, entre a Máscara de busca e a matriz saída (correlação das entropias), como resultado é obtida uma imagem onde a textura reconhecida pelo algoritmo fica em branco e o restante permanece similar a Máscara de busca figura 7.14(a). Depois foi usada a operação AND para delimitar essas estruturas como mostrado na figura 7.14(b). Nota-se que o algoritmo delimitou uma região da Máscara de busca onde estão presentes áreas com predomínio de alto contraste.




Figura 7.14 (a) Operação ADD entre a máscara de busca e a matriz saída da correlação da entropia. (b) operação AND entre a máscara de busca e a matriz saída da correlação da entropia.

A variação das regiões do histograma da matriz de saída (correlação da entropia) resulta em imagens salientando diferentes regiões de textura. A região mais a esquerda do histograma figura 7.15(a), produz um mapa de textura evidenciando regiões de alto contraste na imagem figura 7.15(b), a região central já salienta regiões de predomínio de baixo contraste, figura 7.16 (a) e (b).




Figura 7.15(a) Análise da primeira parte do histograma da matriz de saída da correlação da entropia (b) representação gráfica do histograma.

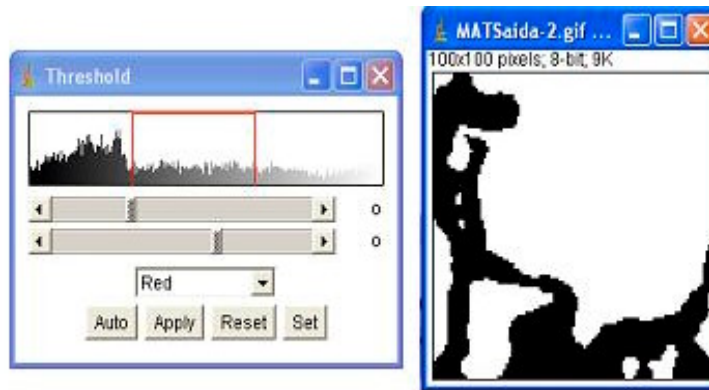


Figura 7.16 (a) Análise da parte central do histograma da matriz de saída da correlação da entropia (b) representação gráfica do histograma.

A Segunda análise consiste também na correlação da entropia entre as Máscaras busca, e referência, com variação da Máscara referência de 10x10 pixels até a dimensão 70x70 pixel, variando de 10 em 10 pixels, compondo uma matriz saída de 700x700. Assim é possível ter uma visão global da eficiência do algoritmo para quantificação da colônia presente na Máscara de referência.

Quando é escolhida uma Máscara de referência de dimensões pequenas em relação à Máscara de busca, por volta de 2% , essa Máscara não possui um número de informações suficientes para determinar as características de uma colônia, além disso, as informações contidas nela têm maior possibilidade de estarem presentes em diversos segmentos da imagem. A imagem resultante, não apresenta características possíveis de serem mensuradas, conforme figura 7.18(a).

Conforme aumentamos a Máscara de referencia, mais informações ele possui, e as imagens gradativamente, conseguem carregar um maior número de informações figuras 7.18 (b,c,d,e,f e g).

Uma Máscara de referência com a dimensão de aproximadamente 10% do tamanho da Máscara de busca, carrega informações suficientes para que seja possível quantificar o numero de repetições do Máscara de referencia na Máscara de busca como demonstrado na figura 7.18(g).


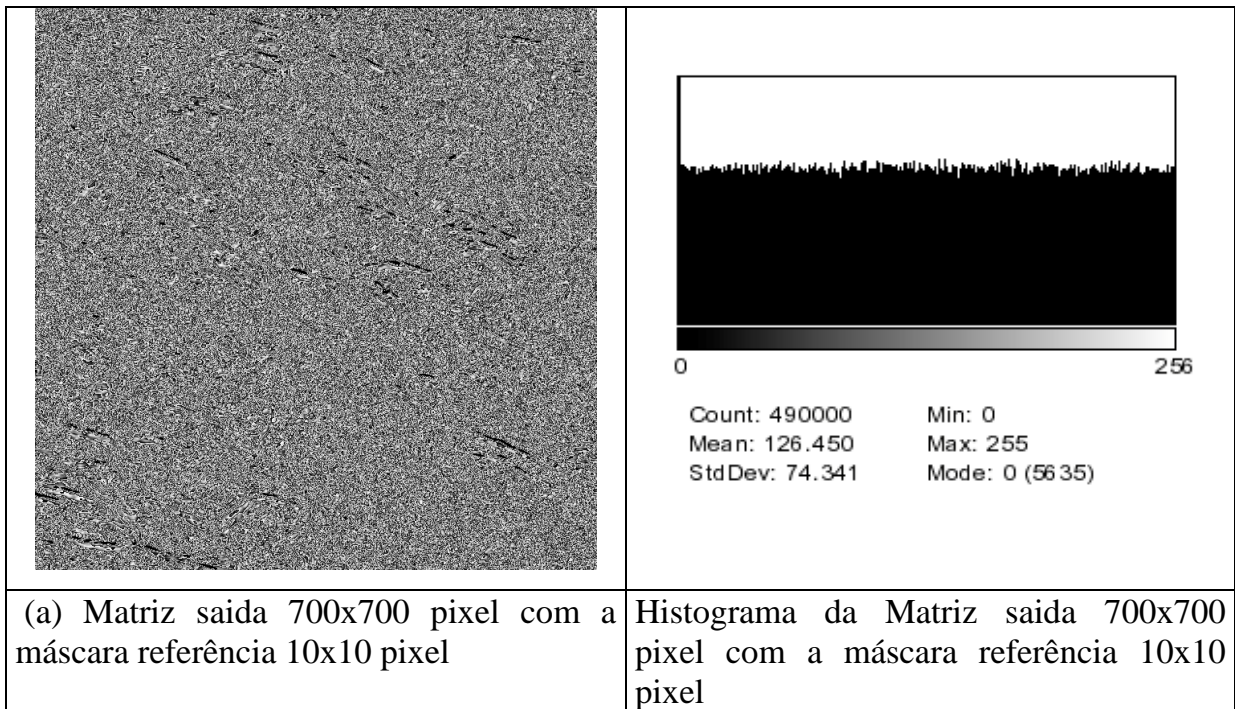




Figura 7.17 Máscara de busca usado para gerar as imagens presentes nas figuras 7.18(a,b,c,d,e,f e g)







0 256

Count: 490000 Min: 0
Mean: 121.562 Max: 252
StdDev: 60.716 Mode: 74 (2948)

(b) Matriz saída 700x700 pixel com a máscara referência 20x20 pixel

Histograma da matriz saída 700x700 pixel com a máscara referência 20x20 pixel





0 256

Count: 490000 Min: 0
Mean: 106.240 Max: 254
StdDev: 63.508 Mode: 102 (3410)

(c) Matriz saída 700x700 pixel com a máscara referência 30x30 pixel

Histograma matriz saída 700x700 pixel com a máscara referência 30x30 pixel





0 256

Count: 490000 Min: 0
Mean: 101.438 Max: 255
StdDev: 68.887 Mode: 0 (5715)

(d) Matriz saída 700x700 pixel com a máscara referência 40x40 pixel

Histograma da matriz saída 700x700 pixel com a máscara referência 40x40 pixel



0 256

Count: 490000 Min: 0
Mean: 95.336 Max: 254
StdDev: 55.151 Mode: 97 (4929)

(e) Matriz saída 700x700 pixel com a máscara referência 50x50 pixel

Histograma da matriz saída 700x700 pixel com a máscara referência 50x50 pixel


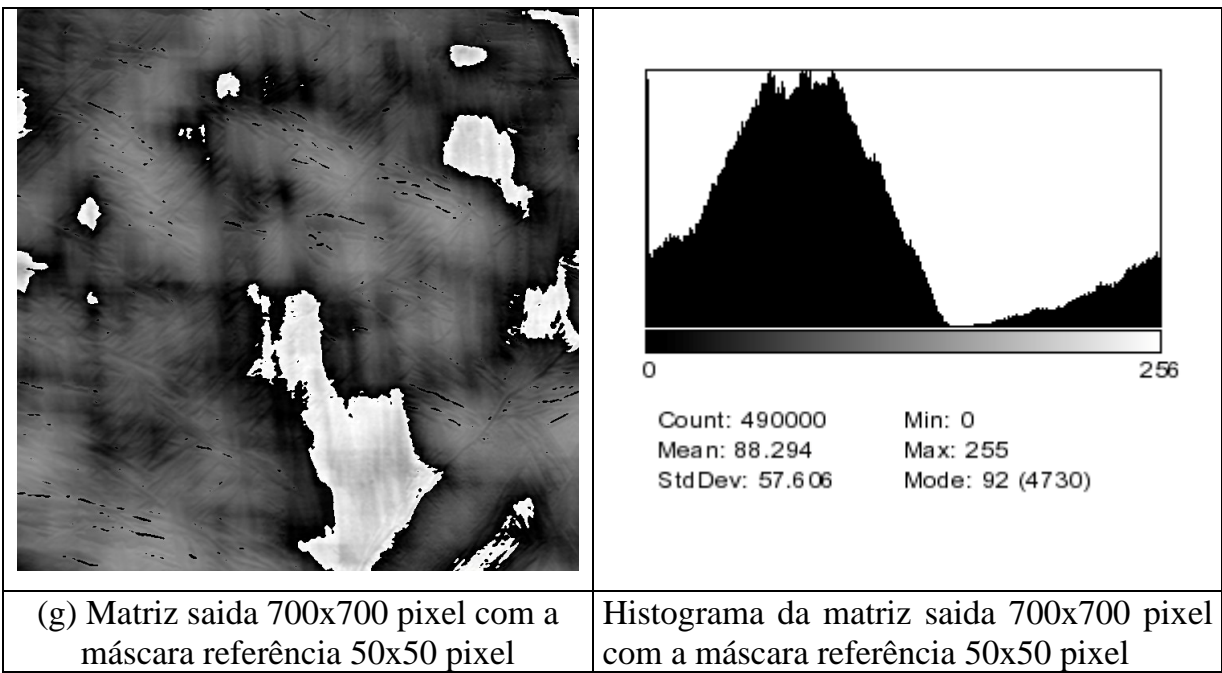
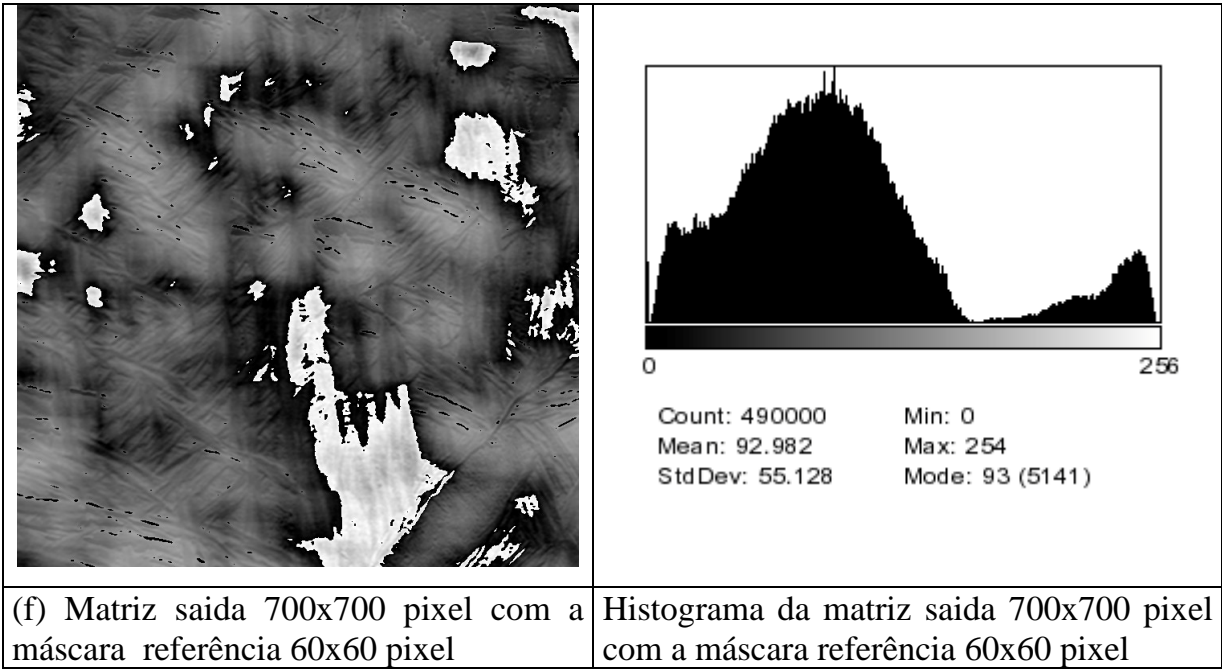



Figura 7.18 Imagens e histogramas gerados a partir da variação da Máscara de referência, na mesma Máscara de busca.


Na figura 7.18 (a), é demonstrado um exemplo da correlação da entropia com uma máscara de referência pequena (10x10pixel), a partir do histograma é notado que os tons de cinza apresentam um distribuição uniforme ao longo da imagem, impossibilitando a possível diferenciação entre as colônias. A partir da imagem 7.18 (c), o histograma está na forma bimodal ou trimodal, são três regiões distintas na imagem. Para identificação desses segmentos - colônias -na imagem, são sobrepostas as imagens da Máscara de busca e a de referência (operação ADD), podendo observar as colônias que estão evidenciadas. Os gráficos em 3D das matrizes de saídas mostradas abaixo, servem como um modelo da representação da imagem sem os segmento em que a correlação é muito baixa.

A seqüência abaixo demonstra bem esse processo.




(a) Imagem resultado da operação ADD entre a máscara de busca e Matriz saída (fig.7.18(a)).

(b) Imagem resultado da operação AND entre a máscara de busca e Matriz saída (fig.7.18(a)).




(c) Gráfico 3D da superfície da figura 7.19(a)

Figura 7.19 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.




(a) Imagem resultado da operação add entre a máscara de busca e Matriz saída (fig.7.18(b)).

(b) Imagem resultado da operação and entre a máscara de busca e Matriz saída (fig.7.18(b)).




(c) Gráfico 3D da superfície da figura 7.20(a)


Figura 7.20 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.



(a) Imagem resultado da operação add entre a máscara de busca e Matriz saída (fig.7.18(c)).




(b) Imagem resultado da operação and entre a máscara de busca e Matriz saída (fig.7.18(c)).




(c) Gráfico 3D da superfície da figura 7.21(a)


Figura 7.21 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.



(a) Imagem resultado da operação add entre a máscara de busca e Matriz saída (fig.7.18(d)).




(b) Imagem resultado da operação and entre a máscara de busca e Matriz saída (fig.7.18(d)).




(c) Gráfico 3D da superfície da figura 7.22(a)


Figura 7.22 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.



(a) Imagem resultado da operação add entre a máscara de busca e Matriz saída (fig.7.18(e)).




(b) Imagem resultado da operação and entre a máscara de busca e Matriz saída (fig.7.18(e)).




(c) Gráfico 3D da superfície da figura 7.23(a)


Figura 7.23 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.



(a) Imagem resultado da operação add entre a máscara de busca e Matriz saída (fig.7.18(f)).




(b) Imagem resultado da operação and entre a máscara de busca e Matriz saída (fig.7.18(f)).




(c) Gráfico 3D da superfície da figura 7.24(a)

Figura 7.24 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.



(a) Imagem resultado da operação add entre a máscara de busca e Matriz saída (fig.7.18(g)).

(b) Imagem resultado da operação and entre a máscara de busca e Matriz saída (fig.7.18(g)).



(c) Gráfico 3D da superfície da figura 7.25(a)

Figura 7.25 Método para identificação das colônias evidenciadas pelo algoritmo, e seu respectivo mapa de elevação.

Conforme a sequência de figuras (figura 7.19 até figura 7.25), é observado a relação entre o tamanho da máscara de referência e sua influencia na separação

das colônias α de Widmanstätten. Com esses resultados pode-se determinar a fração volumétrica das colônias com relação direta com a máscara de referência.

Note que o algoritmo não apresenta 100% de certeza nas medições, caso contrário ele só identificaria a máscara de referência na imagem de busca e o resto da imagem ficaria preto perdendo as outras informações.

Por exemplo na figura 7.21 o algoritmo identificou dois tipos de colônias, uma que apresentou baixo contraste e outra com orientação em torno de 45° . Na figura 7.23 refinou-se mais esse resultado, notando a presença de uma maior quantidade de colônias com baixo contraste, na figura 7.24 só são apresentadas colônias de baixo contraste.

A fração volumétrica de uma determinada partícula pode ser calculada através das técnicas de esteriologia. KURZYDLOWSKI e RALPH, 1995) demonstram que a fração volumétrica pode ser extraída através do cálculo da fração de área, como demonstrado na equação 7.3.

$$V_v = A_A = \frac{A_I}{A_T} \quad (7.3)$$

Onde A_i é área da partícula selecionada e A_T é a área total dos campos.

Segue a quantificação das colônias α de Widmanstätten.

É mostrado os dados obtidos a partir da figura 7.18 com as variações já descritas anteriormente, e através do programa *NIH Image J* é calculado o número de colônias identificadas, área total, média e fração de área .

Tabela 7.3. Valores obtidos a partir da figura 7.21

Count:	202
Total Area:	173448.000 pixel ²
Average Size:	858.653 pixel ²
Area Fraction:	35.4%




Figura 7.26. Segmentos da figura 7.21 usados para cálculo da fração de área

Tabela 7.4. Valores obtidos a partir da figura 7.22

Count:	120
Total Area:	121687.000 pixel ²
Average Size:	1014.058 pixel ²
Area Fraction:	24.8%



Figura 7.27. Segmentos da figura 7.22 usados para cálculo da fração de área

Tabela 7.5. Valores obtidos a partir da figura 7.23

Count:	41
Total Area:	45501.000 pixel ²
Average Size:	1109.780 pixel ²
Area Fraction:	9.3%



Figura 7.28. Segmentos da figura 7.23 usados para cálculo da fração de área

Tabela 7.6. Valores obtidos a partir da figura 7.24

Count:	39
Total Area:	45742.000 pixel ²
Average Size:	1172.872 pixel ²
Area Fraction:	9.3%



Figura 7.29. Segmentos da figura 7.24 usados para cálculo da fração de área

Tabela 7.7. Valores obtidos a partir da figura 7.25

Count:	24
Total Area:	50401.000 pixel ²
Average Size:	2100.042 pixel ²
Area Fraction:	10.3%




Figura 7.30. Segmentos da figura 7.25 usados para cálculo da fração de área

8. CONCLUSÃO

O reconhecimento de padrões estatísticos baseado nas informações de textura de imagens digitais permitiu avaliar e quantificar microestruturas em ligas metálicas.

Este trabalho pesquisou técnicas estatísticas para obtenção da textura, análise e quantificação de colônias α e a fração volumétrica de Widmanstätten, presentes na liga Ti-6Al-4V. A aplicação de diferentes taxas de resfriamento nas amostras utilizadas resultou em microestruturas com características particulares. Os valores obtidos, a partir da observação da imagem original e após da aplicação do algoritmo, apresentaram coerência com alto grau de confiabilidade, o que justifica o desenvolvimento e implementação deste trabalho.

O desenvolvimento do algoritmo e a realização de testes de caracterização baseadas na textura de imagens foram divididos em dois métodos: o primeiro para diferenciar as fases α e β da imagem e o segundo para determinar as colônias α de Widmanstätten. O primeiro método utilizou a correlação entre duas áreas de dimensões diferentes em uma mesma imagem para a identificação de pontos homólogos entre ambas. Foi possível obter a fração volumétrica das fases α e β , em que a variação de tonalidade é bem evidente conforme apresentado na metodologia (capítulo 7). O segundo método utilizou a correlação entre os mapas de entropia para obtenção de pontos homólogos entre as imagens, apresentando a indicação de quão uniforme estão distribuídos os elementos da imagem, e a frequência da ocorrência de cada colônia torna-se possível de ser calculada, através de um histograma modificado conforme apresentado na metodologia (capítulo 7).

O primeiro método forneceu o melhor resultado com uma máscara de referência pequena (cerca de 1% do tamanho da máscara de busca). As informações presentes na matriz de saída mostram-se relacionadas com os tons

de cinza presente na imagem, desprezando a posição dos pixels e sua ligação com os pixels vizinhos. Observou-se que o histograma dessa matriz de saída é bimodal, onde cada pico indica uma fase presente na imagem. Concluiu-se que é possível separar o fundo (fase β) da imagem dos demais elementos (fase α). Ao utilizar uma máscara de referência maior (cerca de 30% da máscara de busca), nota-se que a imagem de saída não apresenta regiões distintas e o seu histograma é bem uniforme, sem picos ou vales, impossibilitando a separação das fases, ou seja, das características de textura.

O segundo método, no qual a entropia foi utilizada como parâmetro, é dividido em dois tipos de análises **A** e **B**. Em **A** fixou-se a dimensão da máscara de referência e variou-se sua posição na máscara de busca, dessa maneira solucionou-se a ineficiência que foi notada ao utilizar uma máscara de referência maior no primeiro método. O resultado obtido pela aplicação da análise **A** foi uma imagem de saída com regiões delimitadas de acordo com as informações da máscara de referência e um histograma trimodal. Esse resultado mostra que através da abordagem **A** é possível delimitar três regiões distintas de textura, o que é bem superior a condição alcançada com método um.

Na abordagem **B**, fixamos a posição da máscara de referência dentro da máscara de busca e variamos suas dimensões. Observamos que quando escolhida uma Máscara de referência de dimensões pequenas em relação à Máscara de busca, por volta de 2%, essa Máscara não possui um número de informações suficientes para determinar as características de uma colônia. Além disso, as informações presentes na Máscara de busca têm maior possibilidade de estarem presentes em diversos segmentos da imagem. Assim, a imagem resultante não apresenta características possíveis de serem mensuradas. Com o aumento da dimensão da máscara de referência obtivemos uma expressiva melhora na distinção das colônias α de Widmanstätten.

A metodologia proposta permitiu a obtenção de resultados acima do esperado para a liga estudada, devendo agora ser aplicada a outros tipos de materiais para evidenciar os resultados obtidos e a sua viabilidade comercial. Isso porque a partir dos resultados da fração de área entre as fases, em diferentes

materiais e ligas, poderemos obter razões entre as frações de área que apresentam os melhores valores de propriedades mecânicas para o material estudado.

A utilização da metodologia proposta possibilita conhecer as propriedades mecânicas de determinado material sem a necessidade de realizar ensaios destrutivos, que geralmente são caros e demorados.

A continuidade deste estudo, através de trabalhos de iniciação científica, dissertações de mestrado e possivelmente tese de doutorado, irá contribuir para o desenvolvimento da matemática aplicada computacional em apoio à seleção de materiais de uso em engenharia.

Em trabalhos futuro visualizamos a implementação desse algoritmo aplicado a outros tipos de materiais em geral tais como cerâmicas e ligas metálicas.

9. REFERÊNCIAS

ABUTALEB, A. S.; “Automatic Thresholding of Gray-Level Pictures Using Two Dimensional Entropy”; Computer Graphics & Image Processing, 47(1) - pp22-32, july 1989.

AMERICAN SOCIETY FOR TESTING AND MATERIALS, ASTM E 112-96, Standard Test Methods for Determining Average Grain Size, 1998, Annual Book of ASTM Standards, v. 03.01, 2004;

AMERICAN SOCIETY FOR TESTING AND MATERIALS, ASTM E 1382-97, Standard Test Methods for Determining Average Grain Size Using Semiautomatic and Automatic Image Analysis, 2004, Annual Book of ASTM Standards, v. 03.01, 2004;

BALLARD, D.H.; BROWN, C.M. **Computer Vision**. Prentice Hall ,1982.

BLOOR, D., BROOK R., FLEMINGS, M.; MAHAJAN, S. **The Encyclopedia of Advanced Materials**, v. 1, 4, Elsevier Science Inc., New York, 1994, págs. 66 e 2868.

BRESCIANI E, F°. **Seleção de Metais Não Ferrosos**, Editora da Unicamp, Brasil, 1992, págs. 25 e 111.

CALLISTER, W.D. **Ciência e Engenharia de Materiais: Uma introdução – 5ªEdição**. LTC,2000.

CHRAPONSKI, J; SZKLINIARZ, W. **Quantitative metallography of two-phase titanium alloys - Materials Characterization**. USA. Vol. 46, no. 2-3, Feb.-Mar. 2001, pag. 149-154

COLLINGS,E.W. **The physical Metallurgy of Titanium Alloys**. 1984

CROSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**.Campinas: IG/UNICAMP, 1993.

DIONÍSIO, A.; MENEZES, R.; MENDES, D., **A Entropia Como Medida De Informação Na Modelação Económica, Temas em Métodos Quantitativos 3**,

ed. Elizabeth Reis e Manuela Magalhães Hill; Edições Sílabo, Lisboa, Fevereiro de 2003.

EFFORD, N., **Digital Image Processing - a Practical Introduction Using Java**, Addison-Wesley, 2000;

FIELDMAN, D., **The Brief Introduction to: Information Theory, Excess Entropy and Computational Mechanics**; University of California, 1998.

FILHO, C. A. Z.; CENTENO, J. A. S. **Análise Da Qualidade De Informações Altimétricas Geradas Pelo Sistema Aster** – 2004

FLOWER, H.M. Microstructural Development in Relation to Hot Working of Titanium Alloys. **Materials Science and Technology**, v.6, 1990, pags 1082-92.

FRASER, H L.; **Quantification of microstructural features in α/β titanium alloys**. Materials Science and Engineering A. Vol. 372, no. 1-2, pp. 191-193. 15 May 2004.

GONZALEZ, R.C., WOODS, R.E. Digital Image Processing Reprinted With Corrections. **Person Education Asian**. September, 1993.

GONZALEZ, R.C ; WOODS, R.E.; **Digital Image Processing** – pg 231-237 – 1992

HARALICK, R. M., SHANMUGAM, K., DINSTEN, I. Textural features for image classification. **IEEE Transaction on Systems, Man and Cybernetics**, v.3, n. 6, p. 610-621. Nov. 1973.

HULL, D., **Fractography Observing, Measuring and Interpreting Fracture Surface Topography**, Cambridge University Press, 1999;

KELLY S. M. **Thermal and Microstructure Modeling of Metal Deposition Processes with Application to Ti-6Al-4V**. Dissertation submitted to the Faculty of the Virginia Polytechnic Institute and State University in partial fulfillment of the requirements for the degree of doctor of philosophy in Materials Science and Engineering, 2004

KELLY; S. M. **Characterization and Thermal Modeling of Laser Formed Ti-6Al-4V** - Thesis submitted to the Faculty of the Virginia Polytechnic Institute and State University in partial fulfillment of the requirements for the degree of Master of Science - Blacksburg, Virginia - Maio 2002.

- KULKARNI A.D. **Artificial Neural Networks For Image Understanding**. New York, Van Nostrand Reinhold, 1994.
- KURZYLOWSKI, K. J., RALPH, B., **The quantitative description of the microstructure of materials: 1ª**, Boca Raton: CRC Press, 1995,418p.
- LATALA, Z., WOJNAR, L., **Computer-aided Versus Manual Grain Size Assessment in a Single Phase Material**, Materials Characterization, v. 46, 2001, p. 227-233;
- MALING, D.H.. **Measuring from maps: Principles and methods of cartometry**. Oxford: Pergamon Press, 1989, pag 577.
- MARTINS Jr, D. C., **Redução de dimensionalidade utilizando entropia condicional média aplicada a problemas de bioinformática e de processamento de imagens**. São Paulo, 2004 . Dissertação (Mestrado em Ciências da Computação) Instituto de Matemática e Estatística da Universidade de São Paulo
- OUCHI, C. et al. Effects of ultra-high purification and addition of interstitial elements on properties of pure titanium and titanium alloy. **Materials Science and Engineering**. A243, p. 186-195, 1998.
- PETZOW, G., **Metallographic Etching**, ASM International, Second Edition, 1999;
- PHILIPS, R., Crystals, **Defects and Microstructures – Modeling Across Scales**, Cambrydge University Press, 2001;
- RIBEIRO, R., B., **Estudo da Influência das Condições do Ataque Químico para a Revelação Metalográfica Sobre a Investigação Quantitativa por Sistemas de Processamento Digital e Análise de Imagens**, Guaratinguetá, Dissertação de Mestrado – UNESP, 1999;
- RUSS,J.C. **The Image Processing Handbook**. 2ª Edição, CRC Press, 1994.
- RUSS, J., C., **Practical Stereology**, Plenum Press, 1986;
- SCHLDT, H. **C avançado: guia do usuário**. Tradução Cláudio Gaiger Silveira. 2ª Edição, McGraw-Hill , 1989, pg 166.

SCHWARTZ, W. R.; PEDRINI, H. **Método Para Classificação De Imagens Baseada Em Matrizes De Co-ocorrência Utilizando Características De Textura** – Anais Do III Colóquio Brasileiro De Ciências Geodésicas. 2003 .

SCHWARTZ W.B; **Segmentação de Imagens Baseada em Dependência Espacial Utilizando Campo Aleatório de Markov Associado com Características de Texturas** - Dissertação Apresentada como Requisito Parcial à Obtenção do Grau de Mestre. Programa de Pós-Graduação Em Informática, Setor de Ciências Exatas, Universidade Federal do Paraná, CURITIBA , 2005.

SHANNON. C.E.; **A mathematical theory of communication**. The Bell System Technical Journal, 27:279-423, 1948.

SHANNON, C. E., WEAVER, W., **The mathematical theory of communication**. Univ. of Illinois Press, 1963.

SILVEIRA, E. Comportamento da resistência à fadiga da liga Ti-10V-2Fe-3Al soldada pelo processo TIG. Dissertação (Mestrado em Engenharia de Materiais) – Faculdade de Engenharia química de Lorena, Lorena, 2002.

SMITH, C. S., **A History of Metallography**, The MIT Press, 1988;

TILEY, J; SEARLES, T; LEE, E; KAR, S; BANERJEE, R; RUSS, J C;

VANDER VOORT, G. F., **Metallography – Principles and Practice**, New York: McGraw-Hill, 1984;

VIEIRA, P., M., R., PACIORNICK, S., **Uncertainty Evaluation of Metallographic Measurements by Image Analysis and Thermodynamic Modeling**, Materials Characterization, v. 47, 2001, p. 219-226.

ZHONG Y., A.K. JAIN; **Object localization using color, texture and shape - Pattern Recognition**. Department of Computer Science, Michigan State University, E. Lansing, MI 48824, USA - Received 15 March 1999

1. TITÂNIO E SUAS LIGAS

Em 1790, o elemento titânio foi descoberto no minério ilmenita (FeTiO_3), na Inglaterra pelo Geólogo William Gregor. Desde a sua descoberta até 1795, pouco interesse foi mostrado por essa areia magnética preta conhecida como o **menaccanite**. Em 1795, o alemão M.H.Klaproth, detectou o mesmo metal no minério rutilo (TiO_2), e nomeou provisoriamente o novo elemento por "titânio", "Por esta razão nenhum nome posso estabelecer para este novo elemento, que indica peculiar propriedade e característica, na minha atual posição eu acho, que é melhor a escolha de uma denominação sem significado e assim não pode não dar nenhuma ascensão às idéias errôneas. E pedirei um nome vindo da mitologia para esta substância metálica, e em particular “Titans”, primeiros filhos da terra. Conseqüentemente eu chamo este gênero metálico, de titanium1."

O titânio é o nono elemento mais abundante da crosta terrestre, em torno de 0,63% do total, sendo superado pelo oxigênio, silício, alumínio, ferro, magnésio, cálcio, sódio e potássio, e é encontrado em maior abundância do que o zinco, o cobre. Durante as próximas seções e subseções serão tratados: a produção de titânio, a metalurgia física, a classificação da liga, propriedades gerais da liga, e os constituintes e as morfologias microestruturais observadas.

1.1 PRODUÇÃO

Embora haja diversos minerais em que o elemento titânio é encontrado, o rutilo e o ilmenita são os pontos de partida para começar a produção do titânio. Primeiramente, o dióxido titânio (TiO_2) encontrado no minério rutilo, é misturado e aquecido com o coque (88% de Carbono fixo, 10% de Cinzas, 2,0% de Umidade, 0,8% de Voláteis, 0,7% de Enxofre)(www.demec.ufmg.br) e cloro, produzindo o gás tetracloreto de titânio, TiCl_4 , nesse primeiro método é utilizado

o sódio como agente redutor. A partir do minério rutilo, a energia requerida para produzir uma tonelada de titânio é 16 vezes maior do que o necessário para produzir uma tonelada do aço, 3,7 vezes que o ferro-cromo, 1,7 vezes maior que o alumínio, e ligeiramente maior do que se precisa para produzir o magnésio. No processo Kroll*, $TiCl_4$ reage com o magnésio em atmosfera inerte como agente redutor produzindo o titânio puro e o $MgCl_2$. O titânio produzido pelo processo Kroll é chamado de metal esponja, e este método ainda é o mais utilizado e aceito no mercado.

A figura 1.1 apresenta de forma esquematizada a forma de obtenção do Ti e suas principais etapas.

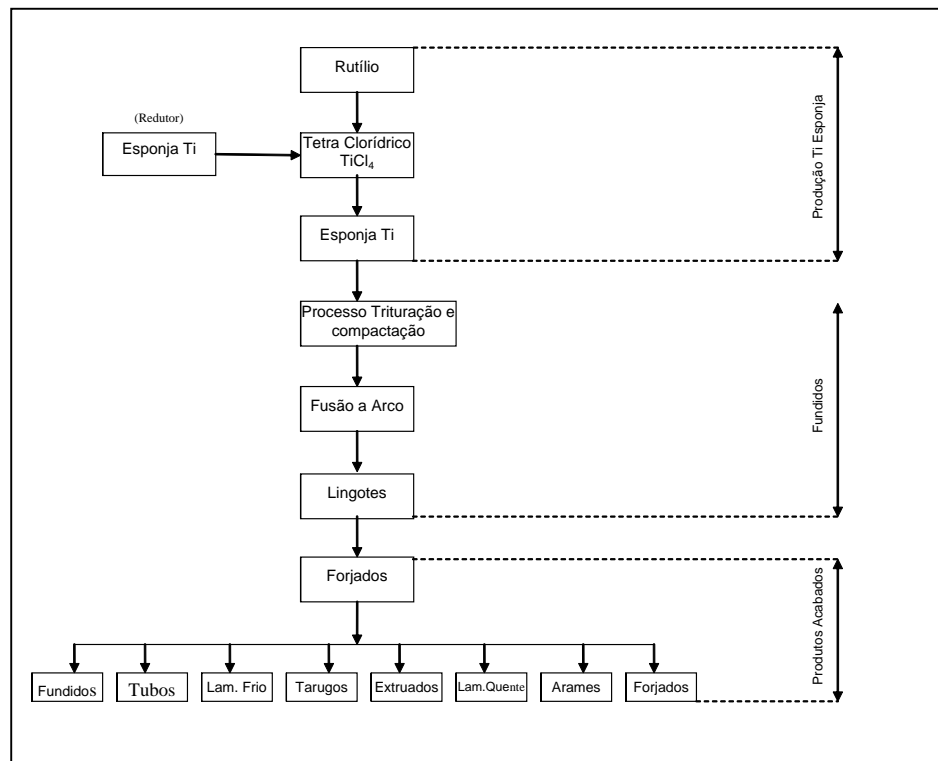


Figura 1.1: principais formas de obtenção do Ti - Kroll

Os primeiros produtos comerciais de titânio foram produzidos pelo “*Titanium Metals Company of America*” (TMCA) por volta de 1950. O titânio foi introduzido à indústria aeroespacial nos anos 50 em resposta à necessidade de novos materiais, que apresentassem uma melhor relação resistência/peso (módulo de elasticidade: 102GPa; limite de resistência: 240MPa; limite de escoamento: 170MPa; dureza Brinell: 70HB e densidade: $4,5g/cm^3$ (CALLISTER,2002).

Além disso, as ligas de titânio têm excelente resistência quando expostas as altas temperaturas são resistentes á corrosão e a oxidação, inclusive por água do mar. Assim o titânio pode ser encontrado em larga escala tanto em aplicações aeronáuticas como também em implantes, quadros de bicicleta, armazenamento hidrogênio, supercondutores, tubulação do condensador para a geração nuclear, polpa e papel industrial, indústrias químicas e petroquímicas. Esta diversidade da indústria de base tem ajudado a indústria do titânio aumentar firmemente a sua produção permitida em uma taxa de 8% por o ano.

1.2 METALURGIA FÍSICA

A metalurgia física das ligas titânio que será tratada nessa seção, destaca os aspectos importantes das ligas titânio incluindo, as características de diferentes classes das ligas de titânio, transformações da fase e suas respectivas morfologias, e a relação entre as estruturas e as propriedades existentes nas ligas de titânio. Ao ser aquecido, o titânio puro é submetido a uma transformação de fase alotrópica, da estrutura hexagonal compacta (HCP) fase α , para a estrutura cúbica de corpo centrado(CCC) fase β , em 882.5°C (β *transus*), conforme ilustrado na figura 1.2 e é fundo a 1668°C (FLOWER,1990).

A temperatura *transus* é definida como a menor temperatura de equilíbrio na qual uma liga de titânio apresenta 100% da fase β . Essa temperatura é importante nos processos de conformação mecânica e no tratamento térmico do titânio e suas ligas.

Abaixo da temperatura *transus*, a liga de titânio é uma mistura das fases α e β , ou somente fase β se o metal contém estabilizadores β ; de outro modo ela, é totalmente constituída por fase α .




Figura 1.2: Formas alotrópicas do Ti Puro

1.3 O TITÂNIO E SUAS LIGAS

As ligas de titânio apresentam uma ampla escala de propriedades mecânicas em consequência da modificação química da liga e do tratamento termomecânico. Por esta razão Flower(1990) indica que há mais de vinte ligas diferentes de titânio são empregadas sozinhas nas aplicações aeroespaciais, dentre outras. As ligas de titânio são compostas geralmente das mistura de fases α e β , esta combinação que pode produzir o α , o $\alpha + \beta$ e β em equilíbrio de fases em temperatura ambiente. Assim, as designações das ligas titânio podem cair em uma de três categorias: α , $\alpha + \beta$ e β . Em alguns casos a composição da liga pode encontrar-se perto do transus de $\alpha \geq \alpha + \beta$ ou de $\beta \geq \alpha + \beta$ em temperatura ambiente, conduzindo à uma sub-classificação ligas “pseudo- α ” e “pseudo- β ”.

Na figura 1.3 é possível observar um esquema de classificação das ligas de titânio proposto por Flower(1990). A classificação técnica de algumas ligas de titânio baseadas em seu índice β -estabilizador é mostrada esquematicamente no diagrama de fase β -isomorfa na figura 1.4, onde um diagrama de fases similar a figura 1.3 com uma curva mais realística do início da formação martensítica (M_s/M_f) e largura do campo da fase de $\alpha + \beta$. A transformação martensítica será

discutida em uma seção posterior. A tabela 1.1 lista diversas ligas do titânio e sua classe específica.

Os elementos que estabilizam a fase α são denominados de estabilizadores alfa-gênicos, e são classificados como intersticiais e substitucionais. O Al, Ga, Ge, e Sn são classificados como elementos substitucionais e resultam no aumento da ductibilidade, favorece a redução do peso e é utilizado com teores variando de 2 a 6%p, e O, C, N como intersticiais (OUCHI et al,1998). O limite de resistência e a dureza são diretamente proporcionais à porcentagem de O. Os metais de transição, os refratários e os nobres são estabilizadores de β , denominado por estabilizadores beta-gênicos. Estes apresentam-se divididos em dois grupos: os isomorfos – representados pelo vanádio, molibdênio, tântalo e nióbio e os eutetóides – representados pelo cromo, manganês, ferro, cobalto, níquel, e cobre.

Nas ligas de titânio, a temperatura de β *transus* será maior ou menor, dependendo do elemento de liga. É notada também, a formação da fase $\alpha+\beta$. Os elementos de liga produzem uma pequena mudança ou o aumento do β *transus*, e estabilizam a fase.

O sistema binário α e β pode ser dividido em subcategorias: α -peritético, α -peritetóide, β -isomorfo e β -eutetóide, por seus diagramas de fase como mostrado na figura 1.3. A figura 1.3 serve também resumir elementos estabilizadores de α ou β .

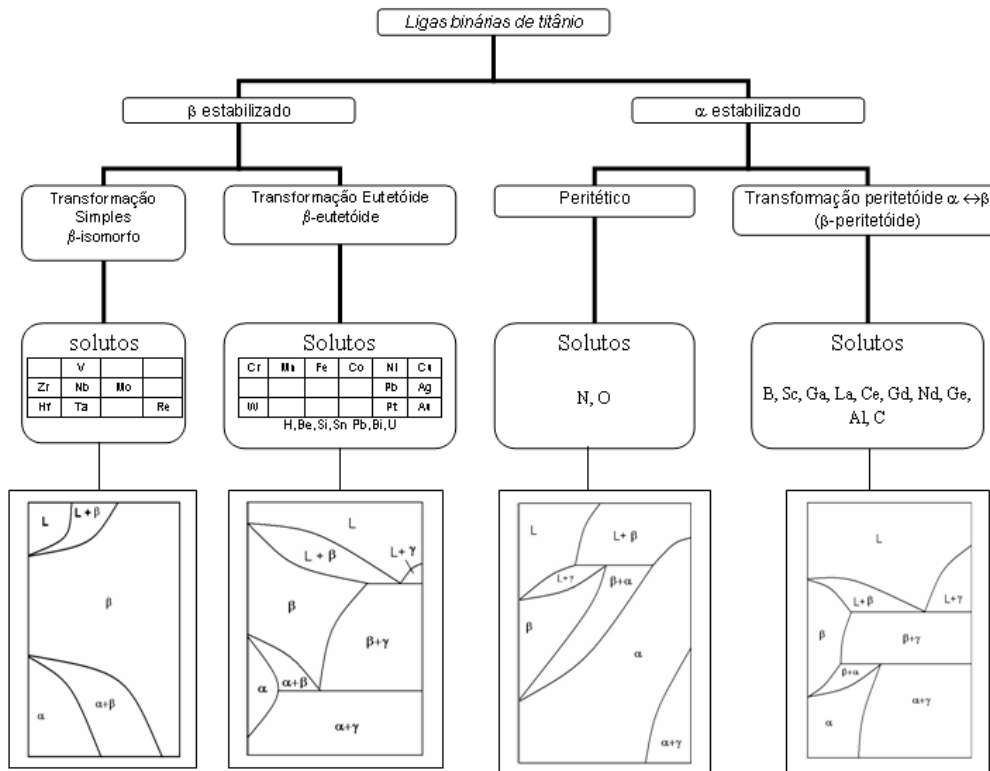


Figura 1.3: Esquema de classificação do diagrama de fases das ligas de titânio. α e β são (HCP) e (CCC) respectivamente e γ representa o composto intermetálico, adaptado de Collings (1984)




Figura 1.4 Diagrama de fase isomorfo pseudobinário mostrando a curva de transformação martensítica desde seu início até o seu fim e o campo da fase $\alpha + \beta$. Adaptado de Collings(1984)

Tabela 1.1 – Classificação estrutural de ligas de titânio de uso comercial. Adaptada Collings(1984)

Liga			Classificação
Ti-5Al-2.5Sn			α
Ti-8Al-1Mo-1V	}	pseudo α	}
Ti-6Al-2Sn-4Zr-2Mo			
Ti-6Al-4V			
Ti-6Al-2Sn-6V			}
Ti-3Al-2.5V			
Ti-6Al-2Sn-4Zr-6Mo	}	pseudo β	}
Ti-5Al-2Sn-2Zr-4Cr-4Mo			
Ti-3Al-10V-2Fe			
Ti-13V-11Cr-3Al			}
Ti-15V-3Cr-3Al-3Sn			
Ti-4Mo-8V-6Cr-4Zr-3Al			
Ti-11.5Mo-6Zr-4.5Sn			

As próximas seções tratam das ligas α , β e $\alpha+\beta$, pois estão intimamente relacionadas com o desenvolvimento do trabalho.

1.4 LIGA α

As ligas α apresentam em sua composição após resfriamento a partir do campo β , $\beta \rightarrow \alpha+\beta$ à temperatura ambiente, obtendo somente a fase α de HCP. As características das ligas α de titânio, tais como Ti-5Al-2.5Sn são: elevado limite de resistência, dureza, resistência à fadiga em altas temperaturas e soldabilidade (KELLY,2002). A liga α não sofre tratamento térmico e não exibe ductilidade, sendo apropriadas para aplicações criogênicas³. O alumínio é o mais importante estabilizador da liga α , é uma solução sólida que fortalece o titânio e reduz a densidade da liga. O titânio comercialmente puro (CP) é considerado uma liga α se associado com as impurezas intersticiais O, C, N, e H e a impureza substitucional Fe como explicitado na tabela 1.2.

Pequenas adições dos elementos intersticiais como O, N, e C aumentam o limite de resistência, porém diminuem a ductibilidade e a dureza do Ti. COLLINGS(1984) .

Tabela 1.2– Classificação das ligas de Ti comercialmente puro (adaptado Smith, 1993).

%p Ti	Grau	%p C	%p Fe	%p N	%p O	%p H
99,50	1,00	0,08	0,25	0,03	0,18	0,02
99,20	2,00	0,08	0,25	0,03	0,20	0,02
99,10	3,00	0,08	0,25	0,05	0,30	0,02
99,00	4,00	0,08	0,50	0,05	0,40	0,02

1.5 A LIGA $\alpha + \beta$

As ligas de titânio bifásicas $\alpha + \beta$ são caracterizadas por uma microestrutura granular, constituídas por grãos que se formaram no contorno de grão da fase β (Figura 1.5). Dentro dos grãos são observadas colônias lamelares da fase α , nucleadas no processo da transformação da fase, principalmente nos limites de grão. As lamelas α dentro das colônias são dispostas paralelamente, dando forma à textura dentro dos grãos. Uma descrição quantitativa completa deste tipo de microestrutura deve incluir dados sobre todos os três elementos: grãos, colônias e lamelas (CHRAPONSKI;SZKLINIARZ,2001).

³ **cri.o.gê.ni.co** *adj* (*crio*²+ *geno*+ *ico*²) **1** Relativo ou pertencente à criogenia. **2** Que produz baixa temperatura; criógeno. **cri.o.ge.ni.a** *sf Fís* (*crio*²+ *geno*+ *ia*¹) Ramo da Física que trata da produção e feitos de temperaturas muito baixas

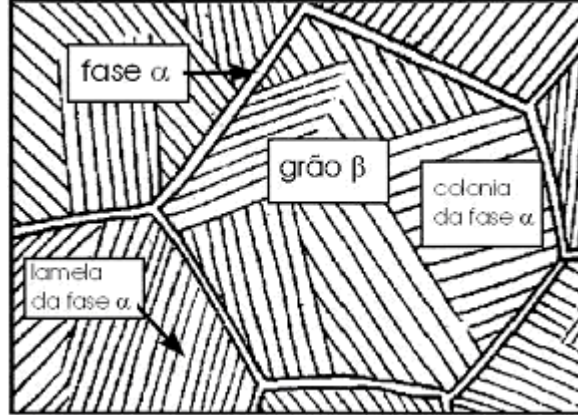


Figura 1.5: Diagrama da microestrutura da liga de Ti $\alpha + \beta$. Adaptada CHRAPONSKI e SZKLINIARZ(2001)

A microestrutura dessas ligas é função da composição química, da história de processamento e tratamento térmico. Quando essas ligas são solubilizadas e resfriadas em água (velocidade de resfriamento superior a 525°C/s) conforme tabela 1.2, a microestrutura obtida é a martensita hexagonal (α'), sendo composta de longas placas de martensita orientadas ortogonalmente, possuindo uma morfologia acicular. O envelhecimento da martensita produz aumento na resistência mecânica devido a precipitação da fase β a partir da martensita instável (α'). Quando uma amostra dessa liga é solubilizada e resfriada ao ar, é produzida uma microestrutura acicular de α , que é revelada a partir da fase β por nucleação e crescimento. Uma mesma amostra solubilizada e resfriada lentamente, condição próxima às condições de equilíbrio, observa-se a ocorrência de plaquetas grosseiras de α que também são formadas por nucleação e crescimento. Devido a baixa velocidade de resfriamento é observada a ocorrência de uma pequena quantidade de fase β nos contornos de grão. As ligas de titânio $\alpha + \beta$ são caracterizadas microestruturalmente pela presença da fase α em contorno de grão da fase β original (CHARPONSKI;SZKLINIARD,2001).

Tabela 1.3: Produto da transformação X taxa de resfriamento. Adaptada SHAWN(2002)

Produto da transformação	Taxa de resfriamento K/s	Temperatura inicial
Widamanstätten(α)	TR<20	~1173K
Maciço(α_m)	20<TR<410	1243-1273K
Martensítica(α')	TR>410	848K

1.6 LIGAS β

As ligas β possuem estabilizadores betagênicos com teores elevados. Estes estabilizadores são conhecidos com isomorfos e eutetóides. A fase β é usualmente metaestável e possui a tendência de transformar-se em $\alpha + \beta$ na condição de equilíbrio. Após tratamento de solubilização⁴, a fase β metaestável é envelhecida⁵ a temperaturas de 450 a 650°C para transformar-se parcialmente em fase α e β . A fase α apresenta-se dispersa na fase β retida, obtendo-se valores de resistência mecânica comparáveis ou superiores às ligas $\alpha + \beta$ envelhecidas. As ligas β apresentam maior densidade se comparadas com as ligas $\alpha + \beta$.

1.7 Ti-6Al-4V

Esta liga Ti-6Al-4V está classificada como uma liga $\alpha + \beta$ é a principal da indústria das ligas de titânio sendo, aproximadamente 70% de todas as ligas formadas são subclasses da Ti-6Al-4V. Esta liga é tratável termicamente e pode ser usada acima de 400°C.

⁴ Solubilização: consiste em um tratamento térmico no qual todos os átomos do soluto são dissolvidos para formar uma solução sólida monofásica

As ligas como o Ti-Al, apresentam duas fases $\alpha + \beta$ que se estreitam em uma mesma região. A introdução do V para uma concentração constante do Al, apresenta uma influência comparativamente pequena na posição $\beta/(\alpha + \beta)$ transus, produzindo uma diminuição rápida de $(\alpha + \beta)/\alpha$ transus. A presença constante de 10 %p Al, e de 8%pV é suficiente para permitir a retenção do componente β à temperatura quanto 600°C.

Composição

Tabela 1.4. Composição Ti6Al4V

ELEMENTO	CONTEÚDO
C	<0.08%
Fe	<0.25%
N ₂	<0.05%
O ₂	<0.2%
Al	5.5-6.76%
V	3.5-4.5%
H ₂ (sheet)	<0.015%
H ₂ (bar)	<0.0125%
H ₂ (billet)	<0.01%

Propriedades Físicas

Tabela 1.5. Propriedades Físicas da liga Ti6Al4V.

Propriedades	Valores típicos
Densidade g/cm ³ (lb/ cu in)	4.42 (0.159)
Calor específico J/kg.°C (BTU/lb/°F)	560 (0.134)
Resistividade Elétrica ohm.cm (ohm.in)	170 (67)
Condutividade térmica W/m.K (BTU/ft.h.°F)	7.2 (67)
Coefficiente médio de expansão térmica 0-100°C /°C (0-212°F /°F)	8.6x10 ⁻⁶ (4.8)
Coefficiente médio de expansão térmica 0-300°C /°C (0-572°F /°F)	9.2x10 ⁻⁶ (5.1)
β Transus °C±15°C (°F)	999 (1830)

⁵ Envelhecimento: consiste no aquecimento de uma solução sólida α supersaturada até uma temperatura intermediária, localizada dentro de uma região bifásica $\alpha + \beta$, a fase β precipitada começa a se formar na forma de partículas finamente dispersas com composição C_{β} . CALLISTER(2000).

Propriedades Mecânicas

Tabela 1.6. Propriedades Mecânicas da liga Ti6Al4V.

Propriedades	Mínima	Valores Típicos
Tensão máxima MPa (ksi)	897 (130)	1000 (145)
0.2% Tensão de escoamento MPa (ksi)	828 (120)	910 (132)
Elongação acima de 2 %	10	18
Redução de área %	20	
Módulo de Elasticidade GPa (Msi)		114 (17)
Dureza Rockwell C		36
Soldabilidade x Espessura	6	
Impacto Charpy (ft.lbf)		24 (18)

1.8 MORFOLOGIA MARTENSÍTICA

Nas ligas de titânio, o equilíbrio entre as zonas α e β são separadas por duas fases, a região $\alpha + \beta$, e a transformação de temperatura $\beta \rightarrow \alpha^m$ ⁶, M_s , e a composição dependente, figura 1.4. Nas ligas α -estabilizadas, representadas por Ti-Al, M_s pode ser encontrada um pouco abaixo da temperatura transus ($\alpha + \beta$)/ α , já nas ligas β -estabilizado está sempre presente dentro da zona $\alpha + \beta$.

Em condições favoráveis, a transformação do β para α^m ocorre completamente, com considerável coerência estrutural. O resultado é chamado de "martensita densa" (conhecido também, como ripas, ou somente martensita), no qual consistem em grandes zonas irregulares mensuradas de 50 a 100 μ m, subdividido em plaquetas paralelas, finas com menos de 1 μ m na transversal, fig (martensita densa). Na martensita densa, a falta da fase- β retida, indica a determinação de um plano uniforme. Com o aumento da concentração do soluto – estabilizadores betagênicos - a coerência entre as plaquetas, que poderiam compor uma colônia densa, é perdida. O resultado disto é uma disposição parcialmente desordenada individual das plaquetas denominada como "martensita acicular - α' (em forma de agulha)", (COLLINGS,1984).

⁶ o símbolo α^m é usado como notação do produto da transformação martensítica se for α' ou α'' . M_s indica o início da transformação durante o resfriamento; M_f o final.

1.9 ESTRUTURA DE WIDMANSTÄTTEN

A nucleação e o crescimento da fase α com o seu plano basal , $\{ 0001 \}_\alpha$, é paralelo ao plano $\{ 110 \}_\beta$ da fase β e o $\langle 111 \rangle_\beta \parallel \langle 1120 \rangle_\alpha$. como resultado a fase α assume as morfologias: agulha, ripa, lamela ou plaquetas muitas vezes chamadas como α *acicular*. Se a liga contiver uma quantidade suficiente de estabilizadores- β , as plaquetas- α estarão separadas pela fase β retida. A fase β retida ou "matriz β " contorna as plaquetas e é enriquecida em elementos estabilizadores β , como consequência da difusão rápida destes elementos antes de migrar para a interface.

As plaquetas α formam-se de modo que o eixo c (direcionado $\langle 0001 \rangle$) é paralelo à interface α/β e a interface α/β está próxima ao plano prismático $\{ 1010 \}_\alpha$. O primeiro grão β (PBG) tem seis combinações não paralelas no plano $\{ 110 \}_\beta$ e cada plano tem 2 direções $\langle 111 \rangle$, as plaquetas α estão relacionadas ao PBG por 1 das 12 orientações variantes (KELLY,2004). Quando a fase nucleada apresenta a forma de agulhas ou placas, e exibe uma relação cristalográfica com a matriz, o resultado é a morfologia de Widmanstätten, como no esquema apresentado na figura 1.6. A formação do Widmanstätten na liga Ti-4Al-6V de $\alpha+\beta$ é ilustrada na figura 1.8. Esta estrutura consiste em grupos de agulhas ou plaquetas da fase- α entrelaçados, onde se encontram com seus eixos longos paralelos no plano $\{ 110 \}$ da matriz β retida, como ilustra a figura 1.5, onde é mostrado o mecanismo de crescimento desta.

As estruturas de Widmanstätten podem ser arranjadas em pacotes de mesma similaridade alinhado com as plaquetas- α ou colônias (figura 1.7) ou estrutura tipo *basketweave* . A estrutura basketweave é o indicativo de uma taxa de resfriamento rápido acima do β -transus ou aumento no índice do estabilizador- β , conforme tabela 1.3. A quantidade da estrutura de Widmanstätten que aparecem em cada colônia aumentará com o controle da temperatura da solução β e do tempo e diminuirá de acordo com a quantidade do elementos estabilizadores- β , quantidade de β trabalhado, e taxa de refrigeração.

A estrutura de Widmanstätten é característica das ligas Ti-MT como no caso das ligas pseudo- α de $\alpha + \beta$ (tais como Ti-6Al-4V) apropriadamente resfriadas, é geralmente tratada como sendo um produto da nucleação e do crescimento da fase- α como ilustra a figura 1.6.




Figura 1.6: Esquema da seqüência da transformação de fase e os eventos ocorridos durante o resfriamento contínuo da liga Ti-6Al-4V através β -transus. Curva do início da transformação alotrópica ou contorno de grão α . (a) Grão β primário é mostrado em cinza . (b) O começo da transformação α para formação alotrópica da estrutura de Widmanstätten dentro do contorno de grão β . (c) continuação do crescimento de α e alongamento do contorno de grão β . (d) Crescimento das colônias α . (e) formação da morfologia basketweave.. adaptado de KELLY(2002)




Figura 1.7: A imagem mostra a micrografia BSE com (α_{CG}) contorno de grão α e colônia α e estrutura de basketweave, morfologia formada através da difusão durante a refrigeração a partir de β transus. O contraste branco indica β e o contraste escuro α . Adaptado de KELLY(2002)




Figura 1.8 Estrutura de Widamanstätten da liga Ti-6Al-4V, obtida no DMT – UNESP- Guaratinguetá.

Algoritmo Correlação

```
#include <stdio.h>
#include <string.h>
#include <stdlib.h>
#include <math.h>
#define TMÁSCARAB_COL 760
#define TMÁSCARAB_LIN 760
#define TMÁSCARAR_COL 60
#define TMÁSCARAR_LIN 60
#define BUF_MAX 1600 // tamanho do buffer REF e BUSCA
void calculaCorrelacao(char [],char [],int ,int ,int,int);
void preenche_bus(char [],int ,int);
void preenche_ref(char [],int ,int);
void calcula_mi_referencia(unsigned char [],double *);
void calcula_mi_busca(unsigned char [],int ,int ,double *);
void calcula_sigma_referencia(unsigned char [],double ,double *);
void calcula_sigma_busca(unsigned char [],int,int ,double ,double *);
void corr_referencia_busca(unsigned char [],unsigned char [],unsigned char [],int
,int ,double, double,double,double *);
void entropia_busca(unsigned char [],int ,int , double *);
void entropia_ref(unsigned char [],int ,int , double *);
unsigned char MATBusca[TMÁSCARAB_LIN][TMÁSCARAB_COL];
unsigned char MATRef[TMÁSCARAB_LIN][TMÁSCARAB_COL];
unsigned char MATSaida[TMÁSCARAB_LIN][TMÁSCARAB_COL];
unsigned char MATEnt[TMÁSCARAB_LIN][TMÁSCARAB_COL];
unsigned char MATEntref[TMÁSCARAR_LIN][TMÁSCARAR_COL];

int lin;
int col;
int linn;
int coll;
int linha;
```

```

int coluna;
double sm;
int main()
{
lin=23;
col=23;
linn=579;
coll=75;
calculaCorrelacao("máscara","máscara2",col,lin,coll,linn);
gray_gif("máscara2",TMÁSCARAR_COL,TMÁSCARAR_LIN);
gray_gif("máscara",TMÁSCARAB_COL,TMÁSCARAB_LIN);
gray_gif("saidasimi",TMÁSCARAB_COL,TMÁSCARAB_LIN);
gray_gif("saida",TMÁSCARAB_COL,TMÁSCARAB_LIN);
return 0;
}
void calculaCorrelacao(char ima_bus[],char ima_ref[],int col,int lin,int coll,int linn)
{
int          janref[4],          /* coordenadas do cursor com ref `a referencia*/
             janbus[4],         /* coordenadas do cursor no disco */
             i,
             j,
             n_dcol,
             n_dlin,
             dcol,
             dlin;              /* variaveis auxiliares */

double  mi_referencia,          /* coeficiente mi da referencia */
        sigma_referencia,      /* " sigma da referencia */
        mi_busca,              /* " do disco */
        sigma_busca,          /* " do disco */
        covariancia,          /* " de covariancia */
        similaridade,         /* " de similaridade */
        correlacao,           /* " de correlacao */

```

```

saida,
simi_maior,          /* maior similaridade encontrada */
entropia,
entropiaf,
entr,
ent;
unsigned
char  ncsaida,
buff_ref[TMÁSCARAR_COL][TMÁSCARAR_LIN], /* buffer da janela de
referencia */ buff_bus[TMÁSCARAB_COL][TMÁSCARAB_LIN],/* buffer da
janela de busca */ entsaida;
unsigned
//char bufRaq[20][20];
char buff[TMÁSCARAB_COL];
FILE *fp;
FILE *fm;
FILE *fimg;
FILE *fent;
FILE *fb;

if ((fm=fopen("saidasimi.txt","wt")) == NULL)
{
printf("\nErro ao abrir arquivo saida");
system("pause");
}
printf("\n etapa1");
// preencher buffer da janela de busca
preenche_bus("raquel12.raw",lin,col);
// preenche_bus("tessie.raw",lin,col);
if( (fp=fopen("máscara","wb")) == NULL)
{
printf("\nErro ao abrir imagem ");
system("pause");
}

```

```

        exit(1);
    }
for(lin=0; lin<TMÁSCARAB_LIN; lin++)
{
    for(col=0; col<TMÁSCARAB_COL; col++)
    {
        buff[col]=MATBusca[lin][col];
    }
    fwrite((char *)buff,1,TMÁSCARAB_COL,fp);
}
fclose(fp);
// preencher buffer da janela de referencia
preenche_ref("raquel12.raw",linn,coll);
// preenche_ref("tessie.raw",lin,col);
if( (fp=fopen("máscara2", "wb")) == NULL)
{
    printf("\Erro ao abrir imagem ");
    system("pause");
    exit(1);
}
for(linn=0; linn<TMÁSCARAR_LIN; linn++)
{
    for(coll=0; coll<TMÁSCARAR_COL; coll++)
    {
        buff[coll]=MATRef[linn][coll];
    }
    fwrite((char *)buff,1,TMÁSCARAR_COL,fp);
}
fclose(fp);

// seta valor de similaridade
simi_maior=-1.0;
// calculo do valor de mi da referencia
calcula_mi_referencia(MATRef,&mi_referencia);

```



```

/* calcula valor da esperançã da imagem na referencia */
calcula_sigma_referencia(MATRef,mi_referencia,&sigma_referencia);
/* calcula entropia referencia*/
// entropia_ref(MATRef,dlin,dcol,&entr);
/* # de deslocamentos em linhas e em colunas na imagem de busca */
/* ( M-N+1) x ( M-N+1)    M: janela busca, N: janela referencia*/
/* # de deslocamento em linhas e em colunas */
n_dcol=n_dlin =(TMÁSCARAB_COL-TMÁSCARAR_COL+1);
/* define as posicoes de deslocamento na imagem de busca */
for( dlin=0; dlin < n_dlin; dlin++)
{
printf("\n %d ",dlin);

for( dcol=0; dcol < n_dcol; dcol++)
{
/* calcula valor de "mi" da imagem de busca */
calcula_mi_busca(MATBusca,dlin,dcol,&mi_busca);

/* calcula valor da esperançã da imagem no disco */

calcula_sigma_busca(MATBusca,dlin,dcol,mi_busca,&sigma_busca);
/* entropia busca */
// entropia_busca(MATBusca,dlin,dcol,&ent);
/* calculo da correlacao referencia - busca */

corr_referencia_busca(MATBusca,MATRef,MATEnt,dlin,dcol,sigma_referenci
a,ent,entr,&correlacao);
/* calculo da covariancia cov(x.y)=E[x.y]-mix*miy; */
covariancia = (correlacao - (mi_referencia * mi_busca));
if( sigma_referencia==0.0 || sigma_busca==0.0)
continue;
/* similaridade sim = cov(x.y)/(sigmax*sigmay) */
similaridade=covariancia/(sigma_referencia*sigma_busca);

```

```

    ncsaida= (unsigned char)(similaridade*175.5+0.5);
    entsaida= (unsigned char)(ent*300);
//    ncsaida= (unsigned char)((similaridade*255.0 +255)/2);

    fprintf(fm,"%3d ",ncsaida);
    MATSaida[dlin][dcol]=ncsaida;

//        printf("\n %d %d %f",dcol,dlin,entropia);
//    getch();
    }
}
fclose(fm);

// gerar a imagem gif da correlação
if( (fp=fopen("MATSaida","wb")) == NULL)
{
    printf("\Erro ao abrir imagem MATSaida");
    system("pause");
    exit(1);
}

for(lin=0; lin<700; lin++)
{
    for(col=0; col<700; col++)
    {
        buff[col]=MATSaida[lin][col];
    }
    fwrite((char *)buff,1,700,fp);
}
fclose(fp);
gray_gif("MATSaida",700,700);
}

```

```

// preencher vetor imagem de busca
void preenche_bus(char arqBusca[],int llb,int ccb)
{
    FILE *fp;
    unsigned char buff[1600];
    //unsigned char buff[561];
    int k,lin,col;
    long nof;
    //lin=700;
    //col=300;
    //lin=1;
    //col=1;

    // abre arquivo original
    if( (fp=fopen(arqBusca,"rb")) == NULL)
    {
        printf("\Erro ao abrir imagem %s",arqBusca);
        system("pause");
        exit(1);
    }

    // posiona o ponteiro na imagem
    nof=(long)llb * (long)1600;
    fseek(fp,nof,SEEK_SET);

    for(lin=0; lin<TMÁSCARAB_LIN; lin++)
    {
        fread(buff,1,1600,fp);
        // fread(buff,1,561,fp);
        for(col=ccb,k=0; col<ccb+TMÁSCARAB_COL; col++,k++)
        {
            MATBusca[lin][k]=buff[col];
        }
    }
}

```

```

    }
    fclose(fp);
}

// preencher vetor de referencia com valores de cinza
void preenche_ref(char arqRef[],int llr,int ccr)
{
FILE *fp;
unsigned char buff[1600];
//unsigned char buff[561];
int k,lin,col;
long nof;
//lin=300;
//col=300;
    // abre arquivo original
    if( (fp=fopen(arqRef,"rb")) == NULL)
    {
        printf("\Erro ao abrir imagem %s",arqRef);
        system("pause");
        exit(1);
    }

    // posiona o ponteiro na imagem
    nof=(long)llr * (long)1600;
    fseek(fp,nof,SEEK_SET);

    for(lin=0; lin<TMÁSCARAR_LIN; lin++)
    {
        fread(buff,1,1600,fp);
        for(col=ccr,k=0; col<ccr+TMÁSCARAR_COL; col++,k++)
        {
            MATRef[lin][k]=buff[col];
        }
    }
}

```

```

    }
    fclose(fp);
}

/* calculo do valor de mi da referencia */
void calcula_mi_referencia(unsigned char
MATRef[TMÁSCARAR_COL][TMÁSCARAR_LIN],double *mi_referencia)
{
FILE *fr;
int i,j;
double aux;
if ((fr=fopen("mi_ref.txt","wt")) == NULL)
{
printf("\nErro ao abrir arquivo mi_ref.txt");
system("pause");
}
aux=0.0;

for(i=0; i<TMÁSCARAR_LIN; i++)
{
for(j=0; j<TMÁSCARAR_COL; j++)
aux+=(double)MATRef[i][j];
}

*mi_referencia=aux/((double)TMÁSCARAR_COL*(double)TMÁSCARAR_LI
N);
fprintf(fr,"\n *mi_referencia=%f ",*mi_referencia);
fclose(fr);
}

void calcula_mi_busca(unsigned char
MATBusca[TMÁSCARAB_COL][TMÁSCARAB_LIN],int dlin,int dcol,double
*mi_busca)
{

```

```

FILE *fr;
    int    i,j;
    double aux;
    if ((fr=fopen("mi_busca.txt","wt")) == NULL)
    {
        printf("\nErro ao abrir arquivo mi_busca.txt");
        system("pause");
    }
aux = 0.0;

    /* dlin e dcol deslocamento da linha e coluna na imagem busca */
    /* o tamanho do máscara da imagem busca e' definido por T_REF */
    for(i=dlin; i<(TMÁSCARAR_LIN+dlin); i++)
    {
        for(j=dcol; j<(TMÁSCARAR_COL+dcol); j++)
            aux+=(double)MATBusca[i][j];
    }

    *mi_busca = aux/((double)TMÁSCARAR_LIN*(double)TMÁSCARAR_COL);
    fprintf(fr,"\n *mi_busca=%f ",*mi_busca);
fclose(fr);
}
/*****

    sigma2 = E[(x-mix)2] = E[x2]-E2[x] ou
    sigma2 = (1/N2)*somatoria(xi-mix)2 = (1/N)*somatoria(x2) - mix
*****/
void          calcula_sigma_referencia(unsigned          char
MATRef[TMÁSCARAR_COL][TMÁSCARAR_LIN],double          mi_referencia,double
*sigma_referencia)
{
FILE *fr;
int    i,j;
double res,
        aux;

```

```

        aux=0.0;
if ((fr=fopen("sigmar.txt","wt")) == NULL)
    {
        printf("\nErro ao abrir arquivo sigmar.txt");
        system("pause");
    }
    for(i=0; i<TMÁSCARAR_LIN; i++)
    {
        for(j=0; j<TMÁSCARAR_COL; j++)
        {
            res = ((double)MATRef[i][j])-mi_referencia;
            aux += (res * res);
        }
    }

    *sigma_referencia=aux/(((double)TMÁSCARAR_COL*(double)TMÁSCARAR
_LIN);
    *sigma_referencia = sqrt(*sigma_referencia);
    fprintf(fr, "\n sigmar=%f ", *sigma_referencia);
    fclose(fr);
}

/* calcula valor da esperança da imagem de busca */
void          calcula_sigma_busca(unsigned          char
MATBusca[TMÁSCARAB_COL][TMÁSCARAB_LIN],int    dlin,int    dcol,double
mi_busca,double *sigma_busca)
{
int    i,j;
double res,
        aux;
FILE *fr;
    if ((fr=fopen("sigma.txt","wt")) == NULL)
    {
        printf("\nErro ao abrir arquivo sigma.txt");

```

```

    system("pause");
}
    aux=0.0;

    for(i=dlin; i<TMÁSCARAR_LIN+dlin; i++)
    {
        for(j=dcol; j<TMÁSCARAR_COL+dcol; j++)
        {
            res = ((double)MATBusca[i][j])-mi_busca;
            aux += (res * res);
        }
    }

    *sigma_busca=aux/((double)TMÁSCARAR_COL*(double)TMÁSCARAR_LI
N);

    *sigma_busca = sqrt (*sigma_busca);
    fprintf(fr, "\n sigma=%f ", *sigma_busca);
    fclose(fr);
}

```

```

void corr_referencia_busca (unsigned char
MATBusca[TMÁSCARAB_COL][TMÁSCARAB_LIN], unsigned char
MATRef[TMÁSCARAB_COL][TMÁSCARAB_LIN], unsigned char
MATEnt[TMÁSCARAR_COL][TMÁSCARAR_LIN], int dlin, int dcol, double
sigma_referencia,double ent,double entr,double *correlacao)
{
    int    i,j;
    double aux,
    aux2,
    aux3;
    FILE *fp;
    if ((fp=fopen("correlacao.txt","wt")) == NULL)
    {
        printf("\nErro ao abrir arquivo correlacao.txt");
    }
}

```



```

system("pause");
}
aux=0.0;

for( i=dlin; i<TMÁSCARAR_LIN+dlin; i++)
{
for( j=dcol; j<TMÁSCARAR_COL+dcol; j++)
{
aux3=(((double)MATBusca[i][j])*log((double)MATBusca[i][j]));
aux2=(((double)MATRef[i][j])*log((double)MATRef[i][j]));
aux=aux2*aux3;
*correlacao=- aux/((double)TMÁSCARAR_COL*(double)TMÁSCARAR_LIN);
// *correlacao=aux/((double)TMÁSCARAB_COL*(double)TMÁSCARAB_LIN);
// *correlacao=aux/sigma_referencia;
// printf("\n %f ",*correlacao);
fprintf(fp,"\n %f ",*correlacao);
}
}
fclose(fp);
}

void entropia_busca(unsigned char
MATBusca[TMÁSCARAB_COL][TMÁSCARAB_LIN],int dlin,int dcol, double *ent)
{
int i,j;
double aux;

FILE *fp;
if ((fp=fopen("entropia.txt","wt")) == NULL)
{
printf("\nErro ao abrir arquivo entropia.txt");
system("pause");
}
aux=0.0;
for( i=0; i<TMÁSCARAB_LIN; i++)

```

```

    {
        for( j=0; j<TMÁSCARAB_COL; j++)
            {
                aux=((double)MATBusca[i][j])*log((double)MATBusca[i][j]);
                *ent=-aux/((double)TMÁSCARAB_COL*(double)TMÁSCARAB_LIN);
                fprintf(fp,"\n %f ",*ent);
            }
        }
        fclose(fp);
}

void entropia_ref(unsigned char
MATRef[TMÁSCARAR_COL][TMÁSCARAR_LIN],int dlin,int dcol, double *entr)
{
int i,j;
double aux;
FILE *fp;
if ((fp=fopen("entropiaref.txt","wt")) == NULL)
{
printf("\nErro ao abrir arquivo entropia.txt");
system("pause");
}
aux=0.0;
for( i=0; i<TMÁSCARAR_LIN; i++)
{
for( j=0; j<TMÁSCARAR_COL; j++)
{
aux=((double)MATRef[i][j])*log((double)MATRef[i][j]);
*entr=-aux/((double)TMÁSCARAR_COL*(double)TMÁSCARAR_LIN);
fprintf(fp,"\n %f ",*entr);
}
}
fclose(fp);
}

```

This document was created with Win2PDF available at <http://www.win2pdf.com>.
The unregistered version of Win2PDF is for evaluation or non-commercial use only.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)