UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
Departamento de Engenharia Elétrica

Raissa Tavares Vieira

Análise de micropadrões em imagens digitais baseada
em números *fuzzy*

São Carlos
2013

Raissa Tavares Vieira

Análise de micropadrões em imagens digitais baseada em números *fuzzy*

Dissertação apresentada à Escola de
Engenharia de São Carlos da Universidade de
São Paulo para obtenção do título de Mestre em
Ciências, Programa de Engenharia Elétrica.

Área de Concentração: Processamento de sinais
e instrumentação

Orientador: Prof. Dr. Adilson Gonzaga

São Carlos
2013

Trata-se da versão corrigida da dissertação. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

T231a   Tavares Vieira, Raissa
            Análise de micropadrões em imagens digitais baseada
            em números fuzzy / Raissa Tavares Vieira; orientador
            Adilson Gonzaga. São Carlos, 2013.

            Dissertação (Mestrado) - Programa de Pós-Graduação
            em Engenharia Elétrica e Área de Concentração em
            Processamento de Sinais e Instrumentação -- Escola de
            Engenharia de São Carlos da Universidade de São Paulo,
            2013.

            1. Análise de textura. 2. Números fuzzy. 3. Análise
            de micropadrões. I. Título.

FOLHA DE JULGAMENTO

Candidata: Engenheira **RAISSA TAVARES VIEIRA**.

Título da dissertação: "Análise de micropadrões em imagens digitais baseada em números *fuzzy*".

Data da defesa: 25/03/2013

Comissão Julgadora:

Resultado:

Prof. Associado **Adilson Gonzaga (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

APROVADA

Prof^a. Dr^a. **Inês Aparecida Gasparotto Boaventura**
(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP-São José do Rio Preto)

Aprovado

Prof. Dr. **Aparecido Nilceu Marana**
(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP-Bauru)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica e Presidente da
Comissão de Pós-Graduação:
Prof. Titular **Denis Vinicius Coury**

Dedico este trabalho aos meus pais, os grandes amores da minha vida.

Agradecimentos

Primeiramente agradeço a confiança, o acolhimento, a paciência e as observações valorosas do meu orientador Adilson Gonzaga.

Aos colegas do LAVI - Laboratório de Visão Computacional pelas discussões e apoio no desenvolvimento deste trabalho.

Aos meus pais pelo esforço constante para promover uma boa estrutura emocional e educacional durante toda minha vida.

Aos meus irmãos, Paula e Rafael e ao meu namorado Ailton.

A todos os meus amigos, que direta e indiretamente me incentivaram no decorrer deste trabalho.

A Universidade de São Paulo.

"O insucesso é apenas uma oportunidade para recomeçar com mais inteligência."

Henry Ford

RESUMO

VIEIRA, R. T. **Análise de micropadrões em imagens digitais baseada em números *fuzzy***. 2013. 151f. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.

As imagens digitais são frequentemente corrompidas por ruídos ou distorcidas pelo processo de aquisição. A teoria dos conjuntos *fuzzy* e a lógica *fuzzy* constituem uma alternativa mais adequada para lidar com tais incertezas, em comparação com os sistemas convencionais, baseados na lógica tradicional (*crisp*). Este trabalho propõe uma nova metodologia para análise de micropadrões de imagens digitais baseada em números *fuzzy*. Um micropadrão é uma estrutura de níveis de cinza dos pixels de uma vizinhança e pode descrever o contexto espacial da imagem, como borda, textura, linha, canto e padrões mais complexos. Na literatura de visão computacional, algumas abordagens foram desenvolvidas para extrair estas características, tais como *Texture Unit* (TU), *Local Binary Pattern* (LBP) e *Fuzzy Number Edge Detector* (FUNED). O trabalho apresenta um novo método que modela a distribuição dos níveis de cinza de um micropadrão como um conjunto *fuzzy*, e com base nas funções de pertinência usadas gera códigos-*fuzzy* que representam o grau de pertinência de cada pixel vizinho com nível de cinza *próximo* do pixel central. A metodologia proposta é chamada de *Local Fuzzy Pattern* (LFP) e é aplicada na análise de textura usando a função sigmoide (LFP-s), a função triangular e simétrica (LFP-t) e a função gaussiana (LFP-g) para calcular o grau de pertinência do pixel central em relação à sua vizinhança. Para avaliar o desempenho da técnica proposta foram usados bases de texturas, cujas imagens foram amostradas aleatoriamente. Após processá-las pelas abordagens LFP-s, LFP-t, LFP-g e LBP, foram comparadas as taxas de acertos alcançadas usando a distância Chi-quadrado. Nos experimentos realizados também é avaliado o esforço computacional do LFP, comparando-o com o descritor LBP. Os resultados mostram que o LFP é eficaz na descrição de textura e que supera o LBP nos diferentes testes realizados. Neste trabalho também é demonstrado que a formulação do LFP é uma generalização de técnicas previamente publicadas, como *Texture Unit*, *Local Binary Pattern* e FUNED.

Palavras-chave: Análise de textura. Números *fuzzy*. Análise de micropadrões.

ABSTRACT

VIEIRA, R. T. **Analysis of micro-patterns in digital images based on fuzzy numbers.** 2013. 151f. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.

Digital images are often corrupted by noise and distorted by the acquisition process. The fuzzy set theory and fuzzy logic are an alternative more appropriate to deal with these uncertainties, in comparison with conventional treatment based on traditional logic (crisp). This work proposes a new methodology for the analysis of micro-patterns of digital images based on fuzzy numbers. A micro-pattern is the structure of the gray-level pixels within a neighborhood and can describe the spatial context of the image, such as edge, texture, line, corner and more complex patterns. In the literature of computer vision, some approaches have been developed to extract these features, such as Texture Unit (TU), Local Binary Pattern (LBP) and Fuzzy Number Edge Detector (FUNED). This work presents a new method that models the distribution of the gray levels of a micro-pattern as a fuzzy set, and based on the membership functions used generates fuzzy-codes that represent the membership degree of each neighbor pixel neighbor with gray-levels near of the central pixel. The proposed methodology is called Local Fuzzy Pattern (LFP) and is applied in the texture analysis by using a sigmoid (LFP-s), a symmetrical triangular (LFP-t) function and Gaussian function (LFP-g) for calculating the membership degree of a central pixel of a neighborhood. To evaluate the performance of the proposed technique were used two database, whose images were randomly sampled. After processing these images by the LFP-s, LFP-t, LFP-g and LBP approaches, it was compared the hit-rate reached by using the Chi-square distance. In the experiments also evaluated the computational effort of the LFP and surpasses the LBP that the different tests. The results show that the LFP-s is efficient to describe texture and that it surpasses the LBP in different tests. This work also demonstrates that the proposed formulation for the LFP is a generalization of previously published techniques such as Texture Unit, LBP and FUNED.

Keywords: Texture analysis. Fuzzy numbers. Analysis of micro-patterns.

LISTA DE ILUSTRAÇÕES

Figura 2.1 - Cálculo do <i>Texture Unit</i>	39
Figura 2.2 - Cálculo do <i>Local Binary Pattern</i>	40
Figura 2.3 - Vizinhança circular de um pixel em multirresolução LBP	41
Figura 3.1 - (a) Conjunto fuzzy normalizado (b) Conjunto fuzzy não normalizado	45
Figura 3.2 - Conjunto <i>fuzzy</i>	45
Figura 3.3 - Representação de um número <i>fuzzy</i> triangular	48
Figura 3.4 - Representação de um número <i>fuzzy</i> trapezoidal	49
Figura 3.5 - Representação de um número <i>fuzzy</i> gaussiano	49
Figura 3.6 - Representação de um número <i>fuzzy</i> sigmoidal	50
Figura 4.1 - Funções de pertinências dos conjuntos <i>fuzzy</i> {N, P}	54
Figura 4.2 - Cálculo do Local <i>Fuzzy Pattern</i>	55
Figura 4.3 - Funções de pertinência $m_0()$ e $m_1()$	56
Figura 4.4 - Exemplo de cálculo do FLBP em uma vizinhança 3×3 para $T = 10$ (a) vizinhança 3×3 (b) Valores limiarizados fuzzy com graus de pertinência (c) matriz de pesos (d) Códigos LBP e os valores de contribuição <i>CLBP</i> . Fonte: Iakovidis, Keramidas, Maroulis (2008)	57
Figura 4.5 - Funções de pertinência $\mu_0()$, $\mu_1()$ e $\mu_9()$	58
Figura 5.1 - Cálculo do grau de pertinência do pixel central. (a) Micropadrão ($W \times W$) (b) função de pertinência (c) Matriz das pertinências em relação ao pixel central (d) Matriz de pesos	60
Figura 5.2 Cálculo do código LFP	61
Figura 5.3 - Função de pertinência sigmoide	62
Figura 5.4. Texturas do álbum de Brodatz	64
Figura 5.5 Texturas da base de imagens do minério vermiculita	65
Figura 5.6 Câmera fotográfica Sony DSC-W350.....	66
Figura 5.7 Tripé e mesa de apoio	66
Figura 5.8 Caixa de madeira.....	67
Figura 5.9 Ilustração da distância entre a lente da câmera e o minério	67
Figura 5.10 Experimento na iluminação tipo 1.	67
Figura 5.11 Experimento sob iluminação tipo 2.	68
Figura 5.12 Iluminação LED	68

Figura 5.13 Imagens do minério vermiculita	69
Figura 5.14 Processo de formatação das imagens.....	69
Figura 5.15 Padronização na nomenclatura das amostras extraídas	70
Figura 5.16 - Processo de classificação	71
Figura 6.1 Esforço computacional no processo de classificação do conjunto de amostras	81
Figura 6.2 Esforço computacional no processo de classificação de uma amostra.....	81
Figura 6.3 Textura com todas as amostras classificadas corretamente	82
Figura 6.4 Texturas que o LBP apresentou o pior desempenho	82
Figura 6.5 - Textura em que o LBP apresentou melhor desempenho na classificação das amostras	83
Figura 6.6 Texturas em que o LFP-g apresentou melhor desempenho na classificação das amostras	83
Figura 6.7 Texturas em que o LFP-s apresentou melhor desempenho na classificação das amostras	83
Figura 6.8 Avaliação qualitativa para o Tipo 1 de iluminação para o descritor LFP-s.	84
Figura 6.9 Avaliação qualitativa para o Tipo 1 de iluminação para o descritor LBP	84
Figura 6.10 Avaliação qualitativa para o Tipo 2 de iluminação para o descritor LFP-s.	85
Figura 6.11 Avaliação qualitativa para o Tipo 2 de iluminação para o descritor LBP	86
Figura 6.12 Avaliação qualitativa para o Tipo 3 de iluminação para o descritor LFP-s.	86
Figura 6.13 Avaliação qualitativa para o Tipo 3 de iluminação para o descritor LBP	87

LISTA DE TABELAS

Tabela 6.1 Sensibilidade obtida para diferentes tamanhos de amostras e vizinhança 3x3 – álbum de Brodatz.....	73
Tabela 6.2 Parâmetros otimizados para diferentes tamanhos de amostras e vizinhança 3x3 - álbum de Brodatz.....	74
Tabela 6.3 Sensibilidade obtida para diferentes tamanhos de amostras e vizinhança 5x5 – álbum de Brodatz.....	75
Tabela 6.4 Parâmetros otimizados para diferentes tamanhos de amostras e vizinhança 5x5 - álbum de Brodatz.....	75
Tabela 6.5 Ganho de sensibilidade em relação ao tamanho da vizinhança.....	75
Tabela 6.6 Sensibilidade obtida para diferentes tamanhos de amostras – banco de imagens de vermiculita TC1	76
Tabela 6.7 Parâmetros otimizados para diferentes tamanhos de amostras - banco de imagens de vermiculita TC1	76
Tabela 6.8 Sensibilidade obtida para diferentes tamanhos de amostras – banco de imagens de vermiculita TC2.....	77
Tabela 6.9 Parâmetros otimizados para diferentes tamanhos de amostras - banco de imagens de vermiculita TC2	77
Tabela 6.10 Sensibilidade obtida para diferentes tamanhos de amostras – banco de imagens de vermiculita TC3.....	78
Tabela 6.11 Parâmetros otimizados para diferentes tamanhos de amostras - banco de imagens de vermiculita TC3	78
Tabela 6.12 Matriz de confusão LFP-s.....	79
Tabela 6.13 Matriz de confusão LBP	80

LISTA DE SIGLAS

FLTP	<i>Fuzzy Local Texture Patterns</i>
FUNED	<i>Fuzzy Number Edge Detector</i>
LBP	<i>Local Binary Pattern</i>
LFBP	<i>Local Fuzzy Binary Pattern</i>
LFP	<i>Local Fuzzy Pattern</i>
LFP-s	<i>Local Fuzzy Pattern-sigmoid</i>
LFP-t	<i>Local Fuzzy Pattern-triangular</i>
LFP-g	<i>Local Fuzzy Pattern-gaussian</i>
LTP	<i>Local Texture Patterns</i>
TS	<i>Texture Spectrum</i>
TU	<i>Texture Unit</i>

LISTA DE SÍMBOLOS

V_i	Pixel da vizinhança
E_i	Valor binário ou ternário assumido pelo pixel da vizinhança
V_0	Pixel central
N_{TU}	Código TU
N_{LBP}	Código LBP
P	Quantidade de pixels da vizinhança
R	Escala do perímetro circular
$\mu_A(x)$	Grau de pertinência do elemento x
X	Universo de discurso
F	Conjunto <i>fuzzy</i> F
$\mu_F(x)$	Grau de pertinência do elemento x em relação ao conjunto F
$altura(F)$	Altura de um conjunto <i>fuzzy</i> F
max	Operador máximo
$suporte(F)$	Suporte de um conjunto <i>fuzzy</i> F
α	Corte em um conjunto <i>fuzzy</i>
F_α	Conjunto de α -cortes do conjunto <i>fuzzy</i> F
$cardinalidade(F)$	Cardinalidade de um conjunto <i>fuzzy</i> F
F_1	Conjunto <i>fuzzy</i> F_1
F_2	Conjunto <i>fuzzy</i> F_2
$\mu_{F_1}(x)$	Grau de pertinência do elemento x em relação ao conjunto F_1
$\mu_{F_2}(x)$	Grau de pertinência do elemento x em relação ao conjunto F_2
$\cup$	União
min	Operador mínimo
$\cap$	Interseção
$\mu_{\bar{A}}(x)$	Complemento de uma conjunto <i>fuzzy</i> A
A_α	Conjunto de α -cortes do conjunto <i>fuzzy</i> A
$a_1^{(\alpha)}$	α -corte 1 do conjunto A_α
$a_2^{(\alpha)}$	α -corte 2 do conjunto A_α
$b_1^{(\alpha)}$	α -cortes 1 do conjunto B_α
$b_2^{(\alpha)}$	α -cortes 2 do conjunto B_α
δ	Espalhamento de número <i>fuzzy</i>
σ	Desvio padrão
β	Inclinação da curva sigmoide

d_i	Diferença de nível de cinza
x_c	Pixel central
x_i	Pixel da vizinhança
N	Conjunto <i>fuzzy</i> que representa diferenças negativas
P	Conjunto <i>fuzzy</i> que representa diferenças positivas
e	Parâmetro que determina a imprecisão do modelo
n_i	Grau de pertinência no conjunto <i>fuzzy</i> N
p_i	Grau de pertinência no conjunto <i>fuzzy</i> P
M	Quantidade de pixels vizinhos
FP_k	k -ésimo padrão <i>fuzzy</i>
F_k	Grau de pertinência do k -ésimo padrão <i>fuzzy</i>
p_i	Pixel da vizinhança
p_c	Pixel central
$m_0()$	Função de pertinência
T	Parâmetro que controla o grau de incerteza
W	Tamanho da vizinhança
$g(i, j)$	Pixel central
$\hat{\mu}_{g(i, j)}$	Grau de pertinência do pixel central $g(i, j)$
$f_{g(i, j)}$	Função de pertinência
$P(k, l)$	Matriz de pesos
$A(k, l)$	Pixels da vizinhança
χ^2	Chi-quadrado
Q_i	Frequência do nível de cinza da amostra que está sendo avaliada
P_i	Frequência do nível de cinza da amostra do conjunto que está sendo comparada com a amostra avaliada
S	Sensibilidade
VP	Verdadeiros positivos
FN	Falsos negativos

SUMÁRIO

RESUMO	13
ABSTRACT	15
LISTA DE ILUSTRAÇÕES	17
LISTA DE TABELAS	19
LISTA DE SIGLAS	21
LISTA DE SÍMBOLOS	23
1. Introdução	29
1.1 Considerações iniciais.....	29
1.2 Motivação	29
1.3 Objetivos.....	30
1.4 Estrutura do trabalho.....	30
2. Textura.....	33
2.1 Considerações iniciais.....	33
2.2 O que é textura?	34
2.3 Abordagens para descrição de textura	35
2.3.1 Abordagem estatística	35
2.3.2 Abordagem estrutural	37
2.3.3 Abordagem espectral	38
2.3.4 Abordagem por micropadrões locais	38
2.4 Considerações Finais	42
3. Conjuntos <i>fuzzy</i> e números <i>fuzzy</i>	43
3.1 Considerações iniciais.....	43
3.2 Conjuntos <i>Fuzzy</i>	43
3.3 Operações com conjuntos <i>fuzzy</i>	46
3.4 Números <i>fuzzy</i>	47
3.5 Operações com números <i>fuzzy</i>	50

3.6	Considerações finais.....	51
4.	Textura <i>Fuzzy</i>	53
4.1	Considerações iniciais	53
4.2	<i>Local Fuzzy Pattern</i>	53
4.3	<i>Fuzzy Local Binary Pattern</i>	55
4.4	<i>Fuzzy Local Texture Pattern</i>	57
5.	Método proposto	59
5.1	Considerações iniciais	59
5.2	Abordagem proposta	59
5.3	Análise de textura.....	64
5.4	Considerações finais.....	71
6.	Resultados experimentais.....	73
6.1	Considerações iniciais	73
6.2	Análise quantitativa.....	73
6.3	Análise qualitativa.....	82
6.4	Considerações finais.....	87
7.	Conclusões	89
7.1	Considerações finais.....	89
7.2	Sugestões para trabalhos futuros	90
7.3	Publicações oriundas do trabalho	90
	Referências Bibliográficas	91
	APÊNDICE A – Distribuição das referências bibliográficas	99
	APÊNDICE B – Rotina para geração de amostras aleatórias	101
	APÊNDICE C – Rotina da função do descritor LFP-s	103
	APÊNDICE D – Rotina da função do descritor LFP-t	105
	APÊNDICE E – Rotina da função do descritor LFP-g.....	107
	APÊNDICE F – Programa de classificação das amostras	109

APÊNDICE G – Sensibilidade obtida para diferentes valores de parâmetro (Álbum de Brodatz – vizinhança 3 x 3).....	115
APÊNDICE H – Sensibilidade obtida para diferentes valores de parâmetro (Álbum de Brodatz – vizinhança 5 x 5).....	121
APÊNDICE I – Sensibilidade obtida para diferentes valores de parâmetro (Imagens de vermiculita – Iluminação Tipo 1)	127
APÊNDICE J – Sensibilidade obtida para diferentes valores de parâmetro (Imagens de vermiculita – Iluminação Tipo 2)	133
APÊNDICE K – Sensibilidade obtida para diferentes valores de parâmetro (Imagens de vermiculita – Iluminação Tipo 3)	139
APÊNDICE L – Esforço computacional	145
ANEXO A- 111 imagens do Álbum de Brodatz	147
ANEXO B - 240 imagens do minério vermiculita	151

Capítulo 1

Introdução

1.1 Considerações iniciais

A textura fornece informações importantes sobre a constituição de cenas em geral. É um aspecto importante para análise de imagens na solução de problemas de segmentação (ZULIANG; LIMIN; JIANTING, 2012; KHANNA; SHRIVASTAVA, 2012), reconhecimento (AHONEN; HADID; PIETIKAINEN, 2006; ZHAO; PIETIKAINEN, 2007) e síntese (XIN; HUAWEI; FEI, 2010; XU; MA, 2010), mas também pelo fato de possibilitar a compreensão dos mecanismos básicos que fundamentam a percepção visual humana (TAMURA; MORI; YAMAWAKI, 1978).

Em visão computacional o campo de pesquisa em textura tem concentrado esforços para desenvolver métodos computacionais automáticos que recuperem a informação visual e interpretem o conteúdo da imagem a partir das suas propriedades texturais. Devido à subjetividade inerente à textura, várias técnicas de descrição foram desenvolvidas e introduzidas ao longo dos anos e dependendo da perspectiva, há problemas para os quais alguns métodos funcionam adequadamente e outros não.

Dentre as diferentes técnicas para descrição de textura que estão atualmente em uso, encontram-se as técnicas *fuzzy*¹. São técnicas capazes de representar apropriadamente a incerteza e imprecisões provenientes do processo de aquisição de imagens (KNOPF; GUPTA, 1994). Esta característica ambígua das imagens foi considerada no direcionamento deste trabalho que propõe um novo descritor de textura baseado em conjuntos de números *fuzzy*.

1.2 Motivação

A análise de textura é uma importante área da pesquisa em visão computacional. Enormes esforços têm sido feitos em busca de uma descrição de textura eficiente. No entanto, a análise de textura é geralmente um problema difícil devido à diversidade e complexidade de texturas naturais.

---

¹ Apesar da existência da tradução do termo *fuzzy* para o português como “nebuloso”, é usado neste trabalho o termo em inglês.

Algumas técnicas caracterizam a descrição de textura como um problema de raciocínio *fuzzy* (IAKOVIDIS; KERAMIDAS; MAROULIS, 2008; SRINIVASAN; RAMAR; SURULIANDI, 2011; KERAMIDAS; IAKOVIDIS; MAROULIS, 2011). Porém, estas técnicas baseiam-se em regras *fuzzy*, o que torna o sistema complexo e com alto custo computacional. Assim, a principal motivação para este trabalho é propor uma solução mais paramétrica para o problema de descrição de texturas baseando-se não em lógica, mas sim em conjuntos *fuzzy*.

1.3 Objetivos

Objetivos gerais:

O presente trabalho tem como objetivo principal propor um novo método para descrição de texturas baseado na teoria de conjuntos *fuzzy*. Esta nova aplicação da teoria *fuzzy* opera diretamente no domínio espacial da imagem, tratando seus pixels como números *fuzzy*.

Objetivos Específicos:

Validar a metodologia proposta avaliando seu desempenho na análise de imagens contidas em bases de texturas.

1.4 Estrutura do trabalho

Estruturalmente, este trabalho está dividido da seguinte maneira:

No capítulo 1 é apresentada uma introdução ao assunto abordado neste trabalho, motivação, objetivos e organização desta dissertação.

No capítulo 2 é apresentado o conceito de textura e as principais abordagens utilizadas para descrevê-la, bem como, uma revisão bibliográfica dos principais métodos de análise de textura.

No capítulo 3 são apresentados os conceitos de conjuntos *fuzzy* e números *fuzzy*.

Aplicações da teoria *fuzzy* na descrição de texturas são discutidas no capítulo 4, com vistas à nova abordagem proposta.

A metodologia empregada neste trabalho para descrição de texturas está detalhada no capítulo 5.

No capítulo 6 são apresentados e discutidos os resultados obtidos.

E finalmente, no capítulo 7, são apresentadas as conclusões finais e são também identificados os possíveis pontos a serem explorados pela nova abordagem em trabalhos futuros.

Capítulo 2

Textura

2.1 Considerações iniciais

Textura é uma das características mais importantes para classificar e reconhecer objetos e cenas e tem grande relevância na área de visão computacional com várias aplicações, como por exemplo, diagnóstico em imagens médicas (CHANG; ZHANG; LIU, 2011; KHADEMI; KRISHNAN, 2008; LIU et al., 2010; SINDHU, 2010; THANGAM et al., 2009), sensoriamento remoto (HARALICK; SHANMUGAM; DINSTEIN, 1973; RIGNOT; KWOK, 1990), inspeção (DEWAELE; VAN GOOL; OOSTERLINCK, 1988; JAIN; FARROKHNI; ALMAN, 1990), ou até mesmo no processamento de documentos (JAIN; BHATTACHARJEE; CHEN, 1992; TAXT; FLYNN; JAIN, 1989). A textura além de ser um componente importante na análise de imagem para resolver vários problemas que envolvem aplicações de segmentação, reconhecimento e síntese, também fornece uma chave para compreender os mecanismos básicos que fundamentam a percepção visual humana.

Por meio da análise de texturas é possível distinguir regiões que apresentam as mesmas características de refletância e, portanto, mesmas cores em determinada combinação de bandas. Isso torna a textura um excelente descritor regional capaz de contribuir na melhoria da exatidão do processo de reconhecimento, descrição e classificação de imagens (CHOI et al., 2002). A análise de textura estabelece o relacionamento de vizinhança dos elementos de textura e seu posicionamento em relação aos demais (conectividade), o número de elementos por unidade espacial (densidade) e a sua regularidade (homogeneidade) (THEODORIDIS; KOUTROUMBAS, 2008).

Este capítulo tem como objetivo fornecer uma visão geral acerca das características de textura e das abordagens que vem sendo utilizadas para sua análise. Por ser uma área extensa a intenção não é esgotá-la neste capítulo. Assim, é feita uma revisão das definições de textura e em seguida é feita uma categorização das técnicas existentes para descrição de textura baseada nas características extraídas em cada uma delas.

2.2 O que é textura?

A textura é um termo intuitivo e largamente empregado, mas apesar de ter sua importância e ubiquidade em dados de imagem, não possui uma definição precisa nem uma aproximação matemática adequada para quantificá-la. Na literatura encontram-se diversas definições de textura propostas ao longo dos anos.

Tamura, Mori e Yamawaki (1978) consideram que a textura constitui uma região macroscópica. A sua estrutura é simplesmente atribuída aos padrões repetitivos nos quais os elementos ou primitivas são dispostos de acordo com uma regra de posicionamento.

Para Coggins (1982) uma textura é compreendida como uma primitiva que é repetida sobre uma região que é maior em comparação ao tamanho da primitiva.

Bimbo (1999) afirma que a textura pode ser descrita por propriedades espaciais, propriedades de frequência ou propriedades perceptuais.

Para Sklansky (1978), uma região em uma imagem apresenta uma textura única se um conjunto de características estatísticas ou outras propriedades locais da imagem forem constantes, com pouca variação ou aproximadamente periódicas.

Haralick, Shanmugan e Dinstein (1973), relacionam a definição de textura com o uso de coeficientes de uniformidade, densidade, aspereza, regularidade, intensidade, dentre outras características da imagem.

Este conjunto de definições demonstra que a definição de textura é formulada por pessoas diferentes e não há um consenso geral. Neste caso, a análise tende a ser mais orientada pela aplicação desejada.

As texturas podem ser descritas e classificadas de acordo com algumas propriedades. Pratt (1991) classifica as texturas como artificiais, quando consistem em arranjos de símbolos dispostos sobre um fundo neutro e como naturais quando são compostas por cenários encontrados na natureza, contendo arranjos de pixels do tipo semi-repetitivos. Haralick (1979) classifica as texturas como fortes ou fracas, sendo mais fortes quanto maior a sua regularidade, ou seja, a interdependência das primitivas de textura. Sonka, Hlava e Boyle (1993) asseveram que a descrição da textura é dependente de escala. Castleman (1996) afirma que as texturas são quantificadas avaliando-se aspectos relativos à variação de tons de cinza em seções contidas na imagem.

2.3 Abordagens para descrição de textura

As variadas definições de textura conduzem a diferentes maneiras de análise, assim, várias abordagens foram desenvolvidas buscando utilizar a textura como base na descrição de uma imagem. Gonzalez e Woods (2008) citaram a existência de três abordagens principais usadas em processamento de imagens para a descrição de textura, que são divididas em estatísticas, estruturais e, espectrais. Lembrando que esta categorização não é única, pois existem técnicas que geram novas características a partir da aplicação de duas ou mais abordagens como, por exemplo, Latif-Amet, Ertuzun e Ercil (2000) combinaram os conceitos da teoria *wavelet* e matrizes de co-ocorrência para detecção de defeitos em imagens têxteis. Neste trabalho é inserida mais uma abordagem denominada de abordagem por micropadrões locais. Entende-se que esta nomenclatura é mais adequada para tratar de técnicas que analisam uma vizinhança local da imagem e extraem a partir da sua análise, características para descrição da textura.

Independentemente da abordagem utilizada, o desafio para escolha de um modelo para definir uma textura está na capacidade que o modelo tem para capturar todas as características visuais significativas da textura. Para classificar um número de texturas, a ideia é aumentar (ou diminuir) heurísticamente a complexidade do modelo, até que as texturas do conjunto de treinamento possam ser classificadas com sucesso (XIE; MIRMEHDI, 2008).

As próximas seções fornecerão um detalhamento maior sobre as principais técnicas utilizadas para descrição de texturas para cada tipo de abordagem, com ênfase na abordagem por micropadrões locais, a qual contextualiza o método desenvolvido neste trabalho.

2.3.1 Abordagem estatística

Na abordagem estatística um vetor de características, que representa um ponto em um espaço multidimensional de características, é usado para representar a textura. Este tipo de abordagem é utilizada normalmente para fins de classificação visando encontrar uma regra de decisão probabilística para associar a textura a alguma classe específica (SONKA; HLAVAC; BOYLE, 1998). Geralmente não é possível reconstruir a textura a partir destas características, visto que as abordagens estatísticas não tentam compreender explicitamente a estrutura hierárquica da textura. É feita uma representação indireta por meio de propriedades não determinísticas que governam a distribuição e a relação entre os níveis de cinza de uma imagem.

Um grande número de características tem sido proposto e podem ser classificadas em dois tipos mais importantes:

- *Características baseadas em estatística de primeira ordem*: avalia a distribuição de níveis de cinza na imagem utilizando o histograma de primeira ordem como base para a extração de características. Essa abordagem é computacionalmente simples e não leva em consideração a relação do pixel com a sua vizinhança, tornando-a invariante à rotação e translação.
- *Características baseadas em estatística de segunda ordem*: esta abordagem leva em consideração o posicionamento espacial de cada pixel da imagem em relação a sua vizinhança, e assim, esta abordagem permite uma diferenciação espacial da distribuição de níveis de cinza em uma imagem ou uma textura.

A extração de características texturais a partir da matriz de co-ocorrência proposta por Haralick, Shanmugan e Dinstein (1973) é um método da abordagem estatística bastante utilizado para análise de texturas (MOCOFAN; VASIU, 2012; JIAN, 2010; ALMEIDA; SOUZA; CANDEIAS, 2010; GOTLIEB; KREYSZIG, 1990). Seu uso principal é na caracterização de texturas em uma imagem através de um conjunto de estatísticas para as ocorrências de cada nível de cinza em pixels diferentes ao longo de diferentes direções. Essa matriz é utilizada para diversos cálculos estatísticos de segunda ordem, como no caso da extração de características de Haralick, Shanmugan e Dinstein (1973) que definiram 14 medidas texturais: variância, segundo momento angular, energia, contraste, correlação, homogeneidade, momento inverso da diferença, soma da média, soma da variância, soma da entropia, diferença da variância, diferença da entropia, medida de informação da correlação e coeficiente de correlação máxima.

Outra maneira estatística para quantificar a textura de uma imagem proposta por Haralick, Shanmugan e Dinstein (1973) é a função de autocorrelação obtida a partir da observação de que algumas texturas são de natureza repetitiva. Esta função mede a correlação entre a própria imagem e a imagem traduzida como um vetor de deslocamento.

O comprimento da série de um nível de cinza (*Gray Tone Run Lengths*) foi introduzido por Galloway (1974). Cada série, medida em uma das direções: horizontal, vertical ou diagonal, é um conjunto de pontos de uma imagem consecutivos, colineares e com o mesmo valor de nível de cinza. É gerada uma matriz que armazena as probabilidades de

encontrar repetições destas séries em um dado comprimento e ao longo de uma direção, ou seja, em uma dada direção, a matriz de *run-length* calcula, para cada valor de cinza, quantas vezes ele aparece em grupos de 2, 3, 4, etc. pixels.

2.3.2 Abordagem estrutural

Algumas texturas podem ser interpretadas como padrões bidimensionais constituídos por um conjunto de primitivas ou subpadrões, que são dispostos de acordo com certas regras de posicionamento para sua geração. É difícil identificar corretamente estas primitivas. No entanto, se for possível extrair de uma imagem um conjunto razoável de primitivas de textura, a descrição da textura pode ser feita a partir de estatísticas de propriedades dessas primitivas.

Os principais objetivos das abordagens estruturais são extrair primitivas da textura e modelar ou generalizar as regras de posicionamento espacial. A textura primitiva pode ser tão simples como pixels individuais ou uma região com níveis de cinza uniforme.

As abordagens estruturais são consideradas apropriadas quando a primitiva de textura é grande o suficiente para ser individualmente segmentada e descrita. A primitiva de textura é a estrutura geométrica básica que forma a textura. Em texturas muito finas de imagens digitais, pode ser o próprio pixel. A vantagem da abordagem estrutural é que ela provê uma boa descrição simbólica da imagem. Entretanto, essa característica é mais útil em tarefas de síntese do que em análise de textura.

Julesz (1962) realizou os primeiros estudos em análise computacional de textura. Uma das principais contribuições resultantes dos seus estudos foi a Teoria *Texton* que levou a uma abordagem estrutural a qual extrai primitivas da textura que a caracterizam localmente no processo de descrição. Nesta teoria, a textura é caracterizada pela repetição de *textons* sobre uma região, cujos tamanhos, formatos, cores e orientações podem variar. Estas variações encontradas na forma como os *textons* se relacionam é suficiente para diferenciar duas texturas.

Xie e Mirmehdi (2007) apresentaram outro modelo estrutural para representar imagens de textura chamado *Textem*. Cada *textem*, caracterizado por uma média e uma matriz de covariância, representa uma classe de *patches* extraídos das imagens originais. A imagem original é então descrita por um conjunto destes *textems*, cada um dos quais são uma representação implícita da primitiva da textura.

A geometria fractal introduzida por Mandelbrot (1983) também vem sendo aplicada como uma abordagem estrutural na análise de textura (BACKES; CASANOVA; BRUNO,

2012) assim como abordagens baseadas em redes complexas (BACKES; CASANOVA; BRUNO, 2009; BACKES; CASANOVA; BRUNO, 2010).

Em Haralick (1979) é feito um levantamento das abordagens estruturais para análise de textura e em Haindl (1991) são abordados também alguns modelos utilizados para análise de textura estrutural.

2.3.3 Abordagem espectral

A abordagem espectral diz respeito às propriedades baseadas no espectro de Fourier, onde pode ser detectada a existência de padrões periódicos ou semi-periódicos. O espectro é útil para este propósito por possuir três características: (a) picos proeminentes no espectro fornecem a direção dos padrões de textura; (b) a posição dos picos no plano da frequência fornece o período espacial fundamental dos padrões e (c) quando os elementos periódicos são eliminados através do processo de filtragem deixa os elementos não periódicos na imagem, que podem ser descritos por técnicas estatísticas. O espectro de Fourier é idealmente adaptado para a descrição da orientação de padrões periódicos ou quase periódicos em uma imagem. Os padrões globais de textura, embora facilmente distinguíveis como concentrações de agrupamentos de alta energia no espectro, são geralmente difíceis de detectar em métodos espaciais devido à natureza local dessas técnicas (GONZALEZ; WOODS, 2008).

Gabor (1946) desenvolveu outra técnica eficiente para a extração de características na abordagem espectral, os filtros de Gabor, que consiste em uma variante local da transformada de Fourier bastante eficiente no processo de análise de textura a partir de frequências espaciais. Devido a sua capacidade de caracterizar um sinal simultaneamente nos domínios temporal e da frequência, que são limitados pela relação de incerteza conjunta, é possível simular algumas das características do sistema visual humano.

Transformadas *wavelets* (DE WOUWER; SCHEUNDERS; VAN DYCK, 1999; ARIVAZHAGAN; GANESAN, 2003) também se apresentam como técnicas eficientes para descrever textura, especialmente em análise multirresolução de imagens.

2.3.4 Abordagem por micropadrões locais

Os descritores de textura modelam algoritmos que tem a capacidade de analisar as propriedades da superfície de um objeto. Os descritores de textura local realizam esta atividade analisando uma vizinhança e codificando cada uma delas, computando assim, as

relações das intensidades relativas entre os pixels em uma pequena vizinhança e não sobre os seus valores de intensidade absolutos.

He e Wang (1990) deram os primeiros passos para análise local de imagens ao introduzir o *Texture Unit* (TU). Neste modelo a informação de textura é coletada de uma vizinhança 3 x 3 (Figura 2.1a), que representa a menor unidade da imagem, no sentido de se ter oito direções em torno dos pixels. Os valores deste micropadrão² são divididos em três níveis de acordo com o valor do pixel central. Cada pixel da vizinhança (V_i) assume o valor (E_i) 0, 1 ou 2 dependendo se está abaixo, igual ou acima do valor do pixel central (V_0), respectivamente (Figura 2.1b). Uma unidade de textura para um vizinhança é produzida multiplicando-se os valores limiarizados (Figura 2.1c) pelos pesos dados aos pixels correspondentes (Figura 2.1d) e, posteriormente, somando-se o resultado (Figura 2.1e), obtendo-se assim, o código TU (Equação 2.1) que caracteriza um determinado micropadrão da imagem.

$$N_{TU} = \sum_{i=1}^8 E_i \cdot 3^{i-1}. \quad (2.1)$$

A partir desta metodologia é possível se obter até $3^8 = 6561$ códigos de unidades de textura.

Figura 2.1 - Cálculo do *Texture Unit*

A descrição global da imagem é obtida a partir do histograma destas unidades de textura chamado *Texture Spectrum* (TS). Uma das vantagens deste método é que

² Estrutura que descreve um contexto espacial da imagem

os aspectos da textura de uma imagem são caracterizados pelo seu TS correspondente em vez de um conjunto de medidas. Assim, o espectro de textura pode ser usado diretamente para sua análise. A abordagem TS foi aplicada na caracterização (WANG; HE, 1990a; HE; WANG, 1991a), como filtro (HE; FABBRI, 1990; HE; WANG, 1991b), na classificação (WANG; HE, 1990b; HE; WANG, 1992a) e na detecção de bordas em imagens de texturas (HE; WANG, 1992b).

Baseados na metodologia do *Texture Unit*, Ojala, Pietikainen, e Harwood (1996) propuseram o *Local Binary Pattern* (LBP). Neste método uma vizinhança 3 x 3 (Figura 2.2a) é limiarizada pelo valor do pixel central gerando uma matriz com valores binários (Figura 2.2b) resultante da comparação: valor binário ‘1’ nos vizinhos que tem valor superior ou igual ao pixel central e ‘0’, caso contrário (Figura 2.2b). Os valores dos pixels na vizinhança limiarizada são multiplicados pelos pesos (Figura 2.2d) dados aos pixels correspondentes. Concluída esta etapa, realiza-se a soma destes valores, resultando no valor do código LBP (Equação 2.2) (Figura 2.2e).

$$N_{LBP} = \sum_{i=1}^8 E_i \cdot 2^{i-1}. \quad (2.2)$$

Em seguida, um histograma é criado para computar as ocorrências dos diferentes códigos LBP de todos os pixels da imagem. Este histograma forma o vetor de características LBP, que caracteriza a imagem de textura. É possível observar que esta abordagem difere do TU no sentido de que há apenas dois níveis para limiarização da vizinhança o que reduz a quantidade de códigos gerados de 6561 para 256.

Figura 2.2 - Cálculo do *Local Binary Pattern*

Ojala, Pietikäinen e Mäenpää (2002) estenderam a definição do LBP para vizinhanças circulares do pixel com o objetivo de torná-lo invariante a rotação e adequado para análise multi-escalar. É considerada uma vizinhança circular (Figura 2.3) e a quantidade de vizinhos P pode ser escolhida a partir de um perímetro circular em qualquer escala R . A vizinhança é interpolada com espaçamento igual no círculo.

Figura 2.3 - Vizinhança circular de um pixel em multirresolução LBP
Fonte: Ojala, Pietikäinen, Mäenpää (2002)

O número possível de padrões locais cresce rapidamente se o número de vizinhos cresce, e dependendo da quantidade adotada, torna-se inviável para aplicações reais. Mäenpää et al. (2000) sugeriram considerar apenas os padrões “uniformes” em que o número máximo de transições de *bits* do valor um para zero ou vice-versa é limitado. Observou-se que certos padrões locais parecem representar a grande maioria, às vezes mais de 90% de todos os padrões locais da imagem. Com esta abordagem o número de códigos binários diferentes é reduzido, mantendo um bom desempenho. Por exemplo, o número das *bins* do histograma com um LBP 8-bit é reduzido para 59 *bins*, em que os 58 *bins* são os padrões uniformes e o último *bin* contém a frequência de ocorrência de todos os outros.

Segundo Suruliandi e Ramar (2008) a quantidade de códigos gerados pelo TU revela mais informações da textura, porém aumenta o tempo computacional. Já no caso do LBP uniforme, há uma redução da quantidade de códigos, tornando-o computacionalmente mais eficiente, porém inadequado para representar uma região local. Diante disto, propuseram o *Local Texture Patterns* (LTP), que aplica um padrão ternário assim como o TU para obter mais informação textural aliado à medida de uniformidade do LBP para redução do número de *bins*. O método proposto permite a detecção do número de transição ou descontinuidades na disposição circular dos padrões. Quando tais transições são encontradas seguindo um padrão, estes são registrados como padrões de texturas locais (*Local Texture Pattern*) uniformes e são atribuídos a eles códigos únicos. Todos os outros padrões não uniformes são

agrupados em uma única categoria. Os LTP uniformes correspondem às primitivas de uma imagem de textura e, portanto, podem descrevê-la.

Ao longo dos anos o LBP conquistou grande popularidade, inúmeros trabalhos têm referenciado e desenvolvido novas variações e aplicações do LBP para classificação de textura (MÄENPÄÄ; PIETIKÄINEN; OJALA, 2000; LIAO; LAW; CHUNG, 2009; GUO; ZHANG; ZHANG, 2010); segmentação de textura (ZHANG et al., 2011); reconhecimento facial (PETPON; SRISUK, 2009; MEENA; SURULIANDI, 2011); recuperação de imagens (SADAT et al., 2011; XIANCHUAN; QI, 2009); reconhecimento racial (MUHAMMAD et al., 2012). Em Pietikäinen et al. (2011) é possível encontrar uma compilação de vários trabalhos que foram desenvolvidos a partir da abordagem LBP.

2.4 Considerações Finais

Neste capítulo discorreu-se sobre textura e as diferentes finalidades da análise de textura, tendo sido resumidas diversas técnicas pertencentes a cada uma das grandes vertentes: estatística, estrutural, espectral e micropadrões locais. Como a literatura sobre análise e síntese de textura é extensa, contemplou-se um conjunto dos métodos mais usados. Deu-se especial destaque às técnicas de micropadrões locais (TU e LBP) devido ao fato deste trabalho objetivar o desenvolvimento de uma técnica que se enquadra dentro desta metodologia de análise de texturas.

Capítulo 3

Conjuntos *fuzzy* e números *fuzzy*

3.1 Considerações iniciais

A teoria de conjuntos *fuzzy* foi introduzida por Zadeh (1965) com o objetivo de conciliar modelagem matemática e conhecimento humano. Desde então, várias pesquisas e trabalhos vêm sendo realizados baseados no conceito de conjuntos *fuzzy* e as aplicações são encontradas em muitos contextos, desde a medicina a aplicações no mercado financeiro.

A lógica *fuzzy* permite a definição de valores intermediários entre avaliações tradicionais, como verdadeiro/falso, sim/não, alto/baixo, etc. Estes valores intermediários podem ser matematicamente formulados e processados por computadores. A modelagem *fuzzy* considera o modo como a falta de exatidão e a incerteza são descritas e, fazendo isso, torna-se suficientemente adequada para manipular de maneira conveniente o conhecimento.

Neste capítulo é evidenciado somente o necessário para o entendimento da teoria básica de conjuntos e lógica *fuzzy* visando sua aplicação em processamento de imagem. A teoria dos conjuntos *fuzzy* e números *fuzzy* é apresentada, e são mostradas as extensões das operações algébricas usuais sobre os números reais para operar com quantidades incertas, sob o ponto de vista da teoria de conjuntos *fuzzy*.

3.2 Conjuntos *Fuzzy*

Na teoria dos conjuntos clássicos verifica-se que a função de inclusão indica se um determinado elemento pertence ou não a um dado conjunto, ou seja, de maneira bem definida (*crisp*). Já na teoria dos conjuntos *fuzzy*, a ideia da função de inclusão é flexibilizada, a qual indica que um determinado elemento pertence mais ao conjunto do que outros elementos pertencentes ao mesmo conjunto, ou seja, os elementos podem então pertencer parcialmente ao conjunto. Um conjunto *fuzzy*, então, é um conjunto que contém elementos que têm diferentes graus de pertinência ao conjunto.

Para a formalização dos conceitos da teoria dos conjuntos *fuzzy* serão consideradas as seguintes definições (BARROS; BASSANEZI, 2006):

Definição 1: Conjunto fuzzy. Seja X o conjunto universo³. Um conjunto *fuzzy* F é um subconjunto de X , definido como um conjunto de pares ordenados, tal que:

$$F = \{(x, \mu_F(x)) | x \in X\}, \quad (3.1)$$

em que $\mu_F(x)$ é chamada de função de pertinência ou função característica do conjunto F . Formalmente tem-se:

$$\mu_F(x): X \rightarrow [0; 1]; x \in X, \quad (3.2)$$

$\mu_F(x)$ retorna o grau de pertinência (que varia entre 0 e 1) do elemento x , pertencente ao universo de discurso X , em relação ao conjunto *fuzzy* F .

O conjunto universo X pode ser composto por elementos discretos ou ser um espaço contínuo. Como consequência, a notação convencional para um subconjunto *fuzzy* F também pode ser discreto ou finito, definido por:

$$F = \left\{ \frac{\mu_F(x_1)}{x_1} + \frac{\mu_F(x_2)}{x_2} + \dots + \frac{\mu_F(x_n)}{x_n} \right\} = \left\{ \sum_{i=1}^N \frac{\mu_F(x_i)}{x_i} \right\}. \quad (3.3)$$

Quando o universo de discurso, X , é contínuo e infinito, o subconjunto *fuzzy* F é denotado por:

$$F = \left\{ \int \frac{\mu_F(x)}{x} \right\}. \quad (3.4)$$

Em ambas as notações, a barra horizontal não indica um quociente, mas sim um delimitador. O numerador em cada termo é o valor de pertinência no conjunto F associado com o elemento do universo indicado no denominador. Na primeira notação de conjunto *fuzzy*, Equação (3.3), o símbolo "+" não denota soma algébrica, indica a composição ou agregação dos elementos do conjunto.

Definição 2: Conjunto fuzzy normalizado. É o conjunto em que pelo menos um de seus elementos possui grau de pertinência igual a 1. A Figura 3.1 ilustra um conjunto *fuzzy* normalizado (Figura 3.1a) e um conjunto *fuzzy* não normalizado (Figura 3.1b).

---

³ Refere-se ao domínio ou espaço onde estão definidos os elementos do conjunto

Figura 3.1 - (a) Conjunto fuzzy normalizado (b) Conjunto fuzzy não normalizado

Definição 3: Altura de um conjunto fuzzy. Corresponde ao maior grau de pertinência assumido por um dos elementos do conjunto *fuzzy*, ou seja:

$$altura(F) = \max_{x_i \in X} \mu_F(x_i). \quad (3.5)$$

Definição 4: Suporte de um conjunto fuzzy. O suporte de um conjunto *fuzzy* é um subconjunto de F que possui elementos com graus de pertinência não nulos, ou seja:

$$suporte(F) = \{x \in X | \mu_F(x) > 0\}. \quad (3.6)$$

Para o conjunto *fuzzy* apresentado na Figura 3.2, tem-se:

Figura 3.2 - Conjunto fuzzy

$$suporte(F) = \{x \in X | 2 < x < 7\}. \quad (3.7)$$

Definição 5: α -corte em um conjunto fuzzy. Um α -corte em um conjunto *fuzzy* F é especificado por um conjunto *crisp* que contém todos os elementos de F , pertencentes ao universo de discurso X , que possuem grau de pertinência maior ou igual a α , ou seja:

$$F_\alpha = \{x \in X | \mu_F(x) \geq \alpha\}. \quad (3.8)$$

Definição 6: Cardinalidade de um conjunto *fuzzy*. É a soma dos graus de pertinência de todos os elementos de F , os quais pertencem ao universo de discurso X , ou seja:

$$cardinalidade(F) = \sum_{x \in X} \mu_F(x). \quad (3.9)$$

3.3 Operações com conjuntos *fuzzy*

O processamento de informações *fuzzy* em sistemas que usam a lógica *fuzzy* consiste normalmente em operações realizadas sobre as suas respectivas funções de pertinência.

As operações básicas união, intersecção e complemento são definidas em função de operadores *max* e *min*, os quais são análogos aos operadores produto e soma da álgebra elementar.

Utilizando as funções *max* e *min* em dois conjuntos *fuzzy* F_1 e F_2 , ambos definidos em um mesmo universo de discurso X , tem-se as definições seguintes:

Definição 7: Conjunto União. O conjunto união é formado por todos os valores máximos entre $\mu_{F_1}(x)$ e $\mu_{F_2}(x)$, ou seja:

$$\mu_{F_1}(x) \cup \mu_{F_2}(x) = \max\{\mu_{F_1}(x), \mu_{F_2}(x)\}. \quad (3.10)$$

Definição 8: Conjunto Intersecção. O conjunto intersecção é formado por todos os valores mínimos entre $\mu_{F_1}(x)$ e $\mu_{F_2}(x)$, ou seja:

$$\mu_{F_1}(x) \cap \mu_{F_2}(x) = \min\{\mu_{F_1}(x), \mu_{F_2}(x)\}. \quad (3.11)$$

Definição 9: Conjunto Complemento. O complemento de um conjunto *fuzzy* F é formado pela subtração de $\mu_F(x)$ do valor unitário, isto é:

$$\mu_{\bar{F}}(x) = 1 - \mu_F. \quad (3.12)$$

3.4 Números *fuzzy*

Os conjuntos *fuzzy* são constituídos por números *fuzzy*, definidos em universos discretos ou contínuos, que permitem a quantificação da incerteza associada a uma dada informação. Assim, a representação de grandezas associadas às declarações do tipo “perto de 20”, “aproximadamente 15”, “em torno de 47” podem ser mapeadas por meio de números *fuzzy*.

Definição 10: Um subconjunto *fuzzy* A é chamado de número *fuzzy* quando o conjunto universo no qual μ_A está definido, é um conjunto dos números reais $\mathbb{R}$ e satisfazem às seguintes condições (BARROS; BASSANEZI, 2006):

- i. todos os α -cortes de A são não-vazios, com $0 \leq \alpha \leq 1$;
- ii. todos os α -cortes de A são intervalos fechados de $\mathbb{R}$;
- iii. $\text{suporte}(A) = \{x \in \mathbb{R}; \mu_A > 0\}$ é limitado.

A descrição de números *fuzzy* pode ser efetuada mediante aplicação do teorema da representação que diz que qualquer conjunto *fuzzy* pode ser especificado por meio de uma coleção e seus α -cortes. Assim, para um número *fuzzy* A , tem-se:

$$A = \bigcup_{0 \leq \alpha \leq 1} (\alpha A_\alpha), \quad (3.13)$$

sendo A_α o intervalo do universo de discurso em que $\mu_A(x) \geq \alpha$.

Para um número *fuzzy* A , um α -corte em A pode ser representado por um par de valores $a_1^{(\alpha)}$ e $a_2^{(\alpha)}$ que representam o domínio de um α -corte em A , assim, um α -corte de A produz o conjunto $A_\alpha = [a_1^{(\alpha)}, a_2^{(\alpha)}]$.

Em muitos casos práticos os números *fuzzy* podem ser representados por funções parametrizadas. A seguir são dadas as definições para as mais comuns (SUMATHI; SUREKHA, 2010).

Definição 11: Um número *fuzzy* A é dito triangular se a sua função de pertinência é da forma:

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{x-a}{m-a}, & \text{se } x \in [a, m] \\ \frac{b-x}{b-m}, & \text{se } x \in [m, b] \\ 0, & \text{se } x \geq b \end{cases}. \quad (3.14)$$

O gráfico da função de pertinência de um número *fuzzy* triangular (Figura 3.3) tem a forma de um triângulo, que tem como base o intervalo $[a, b]$ e, como único vértice fora desta base, o ponto $(m, 1)$.

Figura 3.3 - Representação de um número *fuzzy* triangular

Quando $m - a = b - m = \delta$, tem-se um número *fuzzy* triangular simétrico. Para este caso, tem-se:

$$\mu_A(x) = \begin{cases} 1 - \frac{|x-m|}{\delta}, & \text{se } m - \delta < x \leq m + \delta, \\ 0, & \text{c. c.} \end{cases} \quad (3.15)$$

o parâmetro δ controla a base do triângulo que representa o número *fuzzy* e é chamado de espalhamento do número *fuzzy*.

Definição 12: Um número *fuzzy* A é dito trapezoidal se a sua função de pertinência tem a forma de um trapézio, dada por:

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{x-a}{m-a}, & \text{se } x \in [a, m] \\ 1, & \text{se } x \in [m, n] \\ \frac{b-x}{b-n}, & \text{se } x \in [n, b] \\ 0, & \text{se } x \geq b \end{cases}. \quad (3.16)$$

O gráfico da função de pertinência de um número *fuzzy* trapezoidal (Figura 3.4) tem a forma de um trapézio, que tem como base menor o intervalo $[m, n]$ e, base maior o intervalo $[a, b]$.

Figura 3.4 - Representação de um número *fuzzy* trapezoidal

Definição 13: Um número *fuzzy* A é dito gaussiano ou em forma de sino se a sua função de pertinência é dada pela Equação (3.17).

$$\mu_A(x) = e^{-\frac{(x-m)^2}{\sigma}}, \quad (3.17)$$

sendo σ o desvio padrão. A Figura 3.5 ilustra a representação de um número *fuzzy* gaussiano.

Figura 3.5 - Representação de um número *fuzzy* gaussiano

Definição 14: Um número *fuzzy* A é dito sigmoidal se a sua função de pertinência é dada pela Equação (3.18).

$$\mu_A(x) = \frac{1}{1 + e^{\frac{-(x-m)}{\beta}}}, \quad (3.18)$$

em que β é a inclinação da curva sigmoide. Um número *fuzzy* sigmoidal pode ser representado conforme Figura 3.6.

Figura 3.6 - Representação de um número *fuzzy* sigmoidal

3.5 Operações com números *fuzzy*

Sejam dois números *fuzzy* A e B , definidos em um mesmo universo de discurso X , representados pelas funções de pertinência $\mu_A(x)$ e $\mu_B(x)$. As operações entre A e B podem ser definidas em função dos seus α -cortes.

Adição entre números *fuzzy*. A adição entre os números *fuzzy* A e B pode ser definida em função dos seus α -cortes, ou seja:

$$A + B = [a_1^{(\alpha)}, a_2^{(\alpha)}] + [b_1^{(\alpha)}, b_2^{(\alpha)}] = [a_1^{(\alpha)} + b_1^{(\alpha)}, a_2^{(\alpha)} + b_2^{(\alpha)}]. \quad (3.19)$$

O resultado desta operação produz outro conjunto *fuzzy*, que pode ser reconstruído a partir de seus α -cortes.

Subtração entre números *fuzzy*. A subtração de $\{A - B\}$ é expressada por:

$$A - B = [a_1^{(\alpha)}, a_2^{(\alpha)}] - [b_1^{(\alpha)}, b_2^{(\alpha)}] = [a_1^{(\alpha)} - b_2^{(\alpha)}, a_2^{(\alpha)} - b_1^{(\alpha)}]. \quad (3.20)$$

Multiplicação entre números *fuzzy*. A multiplicação entre os números *fuzzy* A e B , seria então dado por:

$$A * B = [a_1^{(\alpha)} * b_1^{(\alpha)}, a_2^{(\alpha)} * b_2^{(\alpha)}]. \quad (3.21)$$

Divisão entre números *fuzzy*. Finalmente, a divisão é dado por:

$$A \div B = \left[a_1^{(\alpha)} \div b_2^{(\alpha)}, a_2^{(\alpha)} \div b_1^{(\alpha)} \right]. \quad (3.22)$$

Mínimo entre números *fuzzy*. Dados dois números *fuzzy* A e B , definidos em um mesmo universo de discurso X , o resultado da aplicação do operador *min* é obtido por:

$$\min(A, B) = \left[\min(a_1^{(\alpha)}, b_1^{(\alpha)}), \min(a_2^{(\alpha)}, b_2^{(\alpha)}) \right]. \quad (3.23)$$

Máximo entre números *fuzzy*. O resultado da aplicação do operador *max* é dado por:

$$\max(A, B) = \left[\max(a_1^{(\alpha)}, b_1^{(\alpha)}), \max(a_2^{(\alpha)}, b_2^{(\alpha)}) \right]. \quad (3.24)$$

3.6 Considerações finais

Este capítulo apresentou os conceitos básicos relacionados à teoria dos conjuntos *fuzzy* e números *fuzzy*, com enfoque nos conceitos utilizados neste trabalho. É necessário levar em consideração que, no contexto que está inserido a abordagem proposta neste trabalho, não são utilizados sistemas de tomadas de decisão com base em regras *fuzzy*. O enfoque principal da metodologia proposta é a interpretação dos pixels da imagem como números *fuzzy*. As metodologias de análise de textura tradicionalmente encontradas na literatura utilizam a lógica *fuzzy*, isto é, aplicam regras e processos de decisão. O próximo capítulo apresenta estas aplicações em descritores locais de textura.

Capítulo 4

Textura *Fuzzy*

4.1 Considerações iniciais

He e Wang (1990) introduziram o *Texture Unit* (TU) que relaciona a intensidade dos níveis de cinza de uma vizinhança, abordagem utilizada para caracterização e classificação de textura. A desvantagem deste descritor é a quantidade elevada de códigos gerados, há 6561 TU possíveis, cujos valores não são correlacionados. Como consequência, as regiões devem ter um tamanho relativamente grande para se obter as distribuições e que permita calcular medidas de dissimilaridade confiáveis e estáveis.

Ojala, Pietiknen e Harwood (1996) propuseram uma versão simplificada do descritor TU chamado *Local Binary Pattern* (LBP). O LBP reduz a quantidade de códigos gerados para 256. No entanto, com esta simplificação há perda de poder discriminatório e o aumento da sensibilidade a ruído, visto que é feita uma comparação *crisp* entre os pixels, perdendo assim, a informação relacionada com a quantidade real da diferença entre os valores dos pixels.

Uma possível solução para os problemas anteriormente mencionados é o uso da lógica *fuzzy* que é capaz de gerenciar adequadamente informações vagas e ambíguas e pode ser aplicada no processamento de imagem (GEORGE; MADAN, 1994). Como em imagens reais dois pixels vizinhos raramente têm exatamente o mesmo valor de intensidade, devido à presença de ruído e aos diferentes processos de aquisição e digitalização de imagens, fazendo uso da lógica *fuzzy* é possível gerenciar adequadamente informações vagas e ambíguas proporcionando classificações mais flexíveis. Neste capítulo serão apresentadas algumas das abordagens encontradas na literatura que utilizam lógica *fuzzy* na sua formulação para descrever micropadrões.

4.2 *Local Fuzzy Pattern*

Caponetti et al. (2006) introduziram um novo operador para discriminação de textura que consiste em uma versão *fuzzificada* do *Local Binary Pattern*. A diferença de nível de cinza d_i entre o pixel central x_c e o pixel da vizinhança x_i é caracterizada por meio de dois conjuntos *fuzzy* $\{N, P\}$ que representam as diferenças negativas e positivas, respectivamente.

As funções de pertinência dos conjuntos *fuzzy* são simétricas e trapezoidais e a quantidade de imprecisão é determinada pela variação do parâmetro e . As funções são ilustradas na Figura 4.1, em que n_i e p_i são os valores dos graus de pertinência para uma dada diferença d_i , cada pixel x_i é representado como um par (n_i, p_i) .

Figura 4.1 - Funções de pertinências dos conjuntos *fuzzy* $\{N, P\}$

Dados M vizinhos de x_c , há 2^M *Local Fuzzy Patterns* possíveis. Cada um deles é descrito como uma sequência $(s_1, \dots, s_M)$ dos símbolos $\{N, P\}$ indicando se d_i for negativo ($s_i = N$) ou positivo ($s_i = P$). Por exemplo, para x_c com dois vizinhos, tem-se quatro padrões *fuzzy* possíveis: (NN) , (NP) , (PN) , (PP) .

Considerando o k -ésimo padrão *fuzzy* $FP_k = (s_1, \dots, s_M)$, o grau de pertinência do padrão é calculado pela Equação (4.1).

$$F_k = \prod_{i \in I^k} p_i \prod_{j \in J^k} n_j, \quad k = 1, \dots, 2^M, \quad (4.1)$$

em que $I^k = \{i = 1, \dots, M | s_i^k = P\}$ e $J^k = \{j = 1, \dots, M | s_j^k = N\}$.

Finalmente, cada F_k calculado é acumulado no k -ésimo *bin* do histograma para obter a distribuição dos padrões locais *fuzzy* da textura. Como exemplo, a Figura 4.2 apresenta o valor da função de pertinência para os conjuntos *fuzzy* P e N , com e igual a 2, avaliado para uma determinada vizinhança que descreve um micropadrão da imagem.

Figura 4.2 - Cálculo do Local *Fuzzy* Pattern

Tomando como base o pixel x_1 cujo valor de nível de cinza é 6. A diferença entre este valor e o valor do pixel central é igual a 0, logo tem-se um valor positivo e é calculado o seu grau de pertinência na função P. Já a diferença entre o pixel x_2 e o pixel central é igual a -1, então calcula-se o seu grau de pertinência na função N. Este processo é realizado em toda a vizinhança e todos os graus de pertinência são multiplicados e seu valor final armazenado no k -ésimo *bin* do histograma.

Esta abordagem foi aplicada na segmentação de texturas coloridas (GÓRECKI; CAPONETTI, 2007) e também foi aplicado na classificação de glóbulos brancos no sangue (FATICHAH et al., 2011).

4.3 *Fuzzy Local Binary Pattern*

Iakovidis, Keramidas e Maroulis (2008) propuseram o *Fuzzy Local Binary Pattern* (FLBP), mais uma extensão *fuzzificada* do LBP, que foi proposto inicialmente para a caracterização de textura em imagens de ultrassonografia. A fuzzificação da abordagem LBP se dá pela transformação das variáveis de entrada em variáveis *fuzzy*, de acordo com um conjunto de regras *fuzzy*. Assim, são apresentadas duas regras *fuzzy* para descrever a relação entre os valores de intensidade dos pixels da vizinhança p_i ($0 \leq i \leq 7$) e o pixel central p_c de uma vizinhança 3×3 :

Regra R_0 : quanto menor for o p_i em relação ao pixel central p_c , maior é a certeza que o valor binário d_i é 0.

Regra R_1 : quanto maior for o p_i em relação ao pixel central p_c , maior é a certeza que o valor binário d_i é 1.

De acordo com as regras R_0 e R_1 é possível determinar duas funções de pertinência, $m_0()$ (Figura 4.3) que define o grau de pertinência para o qual p_i tem valor de nível de cinza menor que o de p_c e, assim, define o grau de pertinência em que d_i é zero. A função de pertinência $m_0()$ é definida Equação (4.2).

$$m_0(i) = \begin{cases} 0, & \text{se } p_i \geq p_c + T \\ \frac{T - p_i + p_c}{2 \cdot T}, & \text{se } p_c - T < p_i < p_c + T \\ 1, & \text{se } p_i \leq p_c - T \end{cases} \quad (4.2)$$

Por outro lado, a função de pertinência $m_1()$, define o grau de pertinência para o qual p_i tem um valor de nível de cinza maior do que p_c e, assim, o grau de pertinência em que d_i é 1. A função de pertinência $m_1()$ é definida pela Equação (4.3).

$$m_1(i) = 1 - m_0(i). \quad (4.3)$$

Para ambas as funções de pertinência $m_0()$ e $m_1()$, $T \in [0,255]$ é um parâmetro que controla o grau de incerteza.

Figura 4.3 - Funções de pertinência $m_0()$ e $m_1()$

No LBP básico é gerado um código único que caracteriza uma vizinhança 3 x 3, já na abordagem FLBP proposta, uma vizinhança pode ser caracterizada por mais de um código LBP. A Figura 4.4 apresenta um exemplo da abordagem FLBP, em que dois códigos LBP

caracterizam uma mesma vizinhança 3×3 . O grau em que cada código de LBP caracteriza uma vizinhança, depende dos valores das funções de pertinência $m_0()$ e $m_1()$.

Figura 4.4 - Exemplo de cálculo do FLBP em uma vizinhança 3×3 para $T = 10$ (a) vizinhança 3×3 (b) Valores limiarizados fuzzy com graus de pertinência (c) matriz de pesos (d) Códigos LBP e os valores de contribuição C_{LBP} . Fonte: Iakovidis, Keramidas, Maroulis (2008)

Para uma vizinhança 3×3 , a contribuição C_{LBP} de cada código de LBP em um *bin* do histograma FLBP é definida pela Equação (4.4).

$$C_{LBP} = \prod_{i=0}^8 m_{d_i}(i), \quad (4.4)$$

em que $d_i \in \{0,1\}$ e o código LBP pode ser obtido pela Equação (2.2). Para cada pixel da vizinhança, d_i pode ser tanto 0 quanto 1, com um grau de $m_0()$ ou $m_1()$, respectivamente, formando diferentes códigos LBP com diferentes contribuições (Equação 4.4). Assim, cada vizinhança 3×3 contribui para mais de um *bin* do histograma FLBP. A contribuição total de uma vizinhança 3×3 nos *bins* de um histograma FLBP é dada pela Equação (4.5).

$$\sum_{LBP=0}^{255} C_{LBP} = 1. \quad (4.5)$$

4.4 Fuzzy Local Texture Pattern

Srinivasan, Ramar e Suruliandi (2011) propuseram o *Fuzzy Local Texture Pattern* (FLTP) uma *fuzzificação* do método LTP (*Local Texture Pattern*) que usa uma padrão ternário (0, 1 ou 9) que representa a relação entre o pixel central e uma vizinhança 3×3 . A metodologia proposta utiliza três funções de pertinência $\mu_0()$, $\mu_1()$ e $\mu_9()$ (Figura 4.5) para representar de maneira mais flexível o padrão ternário do LTP.

Figura 4.5 - Funções de pertinência $\mu_0()$, $\mu_1()$ e $\mu_9()$

Assim, para cada pixel da vizinhança é atribuído um grau de pertinência $\mu_0()$, $\mu_1()$ e $\mu_9()$ dependendo se está abaixo, igual ou acima do valor do pixel central, respectivamente.

Em (SURULIANDI; RAMAR; SURULIANDI, 2012) foi demonstrado que esta metodologia é também invariante à rotação, com acurácia de 98,11% alcançada na classificação de imagens rotacionadas.

4.5 Considerações finais

Neste capítulo foram apresentados os descritores de micropadrões locais, baseados em lógica *fuzzy*, desenvolvidos mais recentemente. Os mesmos se apresentam como abordagens mais tolerantes à incerteza e presença de ruídos inerente de imagens digitais em comparação com as abordagens *crisp* presentes na literatura. Porém, deve-se levar em consideração que todos eles utilizam regras *fuzzy* para determinar qual valor binário ou ternário é assumido para codificação de um micropadrão e isto de certa forma contribui com aumento do custo computacional. No capítulo seguinte é apresentada uma nova abordagem para descrição de micropadrões também baseada na teoria *fuzzy*, mas diferentemente das abordagens descritas neste capítulo, não há o uso de regras *fuzzy*. Os pixels são simplesmente interpretados como números *fuzzy* e a vizinhança como um conjunto *fuzzy*, apresentando-se como um método mais compacto.

Capítulo 5

Método proposto

5.1 Considerações iniciais

Neste capítulo é apresentada a abordagem proposta para análise de micropadrões em imagens digitais baseada em números *fuzzy*. Considera-se um micropadrão como sendo uma estrutura de pixels em níveis de cinza que pode descrever um contexto espacial de uma imagem, como bordas, cantos, textura e até mesmo padrões mais complexos. Diferentemente das abordagens expostas no capítulo anterior, não são usadas regras *fuzzy* para se obter um código final que descreva um determinado padrão da imagem. Na abordagem proposta, uma vizinhança de pixels é simplesmente tratada como um conjunto *fuzzy* e o nível de cinza de cada pixel como um número *fuzzy*. A interpretação direta de uma imagem por números *fuzzy* é bastante adequada, uma vez que os números *fuzzy* refletem bem as incertezas dos níveis de cinza em uma imagem.

5.2 Abordagem proposta

Considerando os níveis de cinza dos pixels como números *fuzzy*, é possível incorporar sua variabilidade inerente, provendo uma metodologia mais apropriada para o tratamento de imagens digitais quando comparada às metodologias tradicionais baseadas na formulação analítica. Outra característica importante é que a abordagem proposta não é baseada em regras *fuzzy*, o que diminui o seu custo computacional.

É importante notar que a representação por números *fuzzy* é paramétrica e que a definição de uma função de pertinência apropriada é heurística e não única. Assim, a definição de diferentes funções de pertinência é baseada nas propriedades da vizinhança do micropadrão $W \times W$ do pixel central $g(i, j)$ em uma imagem digital. A metodologia proposta assume que cada distribuição de níveis de cinza dentro desta vizinhança é um conjunto *fuzzy* devido ao grau de incerteza gerado pelo processo de aquisição da imagem e devido também ao ruído imprevisível produzido por diversas fontes.

Esta nova abordagem é chamada de *Local Fuzzy Pattern* (LFP). Apesar de o nome proposto ser igual ao dado por Caponetti et al. (2006) as duas metodologias diferem

substancialmente, pois, naquela, regras fuzzy definem o código gerado para o micropadrão, enquanto que, na metodologia proposta neste trabalho, uma função de pertinência é responsável diretamente pelo código LFP. Propõe-se que o grau de pertinência do pixel central $g(i,j)$ para o micropadrão definido pela vizinhança $W \times W$ (Figura 5.1a) seja determinado pela Equação (5.1):

$$\hat{\mu}_{g(i,j)} = \frac{\sum_{k=1}^W \sum_{l=1}^W [f_{g(i,j)} P(k,l)]}{\sum_{k=1}^W \sum_{l=1}^W P(k,l)}, \quad (5.1)$$

na qual $f_{g(i,j)}$ é a função de pertinência (Figura 5.1b) que irá gerar os valores das pertinências em relação ao pixel central (Figura 5.1c) e $P(k,l)$ é uma matriz de pesos (Figura 5.1d) para a vizinhança $A(k,l)$ com a mesma dimensão $W \times W$.

Figura 5.1 - Cálculo do grau de pertinência do pixel central. (a) Micropadrão ($W \times W$) (b) função de pertinência (c) Matriz das pertinências em relação ao pixel central (d) Matriz de pesos

O grau de pertinência ($\hat{\mu}_{g(i,j)}$) do pixel central à região definida pela janela $W \times W$ é então dado pela média ponderada dos valores de pertinências individuais de cada pixel. Este grau de pertinência define o código LFP proposto que reflete a estrutura do micropadrão

dentro da vizinhança considerada. A Figura 5.2 exemplifica o cálculo do código LFP para um determinado micropadrão de uma imagem de textura.

Figura 5.2 Cálculo do código LFP

Usando a equação (5.1) é possível derivar algumas abordagens tradicionais previamente publicadas para análise de micropadrões ao aplicar diferentes funções de pertinência e matrizes de pesos.

O *Texture Unit* (HE; WANG, 1990) pode ser derivado da Equação (5.1) aplicando a função de pertinência dada pela equação (5.2):

$$f_{g(i,j)} = 1 + sgn[A(k,l) - g(i,j)], \quad (5.2)$$

em que,

$$sgn[A(k,l) - g(i,j)] = \begin{cases} -1, & se \ [A(k,l) - g(i,j)] < 0, \\ 0, & se \ [A(k,l) - g(i,j)] = 0, \\ 1, & se \ [A(k,l) - g(i,j)] > 0. \end{cases}$$

e

$$P(k,l) = \begin{bmatrix} 1 & 3 & 9 \\ 2187 & 0 & 27 \\ 729 & 243 & 81 \end{bmatrix}$$

O *Local Binary Pattern* (OJALA; PIETIKAINEN; HARWOOD, 1996) também pode ser derivado da equação (5.1) usando-se uma função *crisp* como a função degrau de Heaviside, Equação (5.3):

$$f_{g(i,j)} = H[A(k,l) - g(i,j)], \quad (5.3)$$

em que,

$$H[A(k,l) - g(i,j)] = \begin{cases} 0, & \text{se } [A(k,l) - g(i,j)] < 0, \\ 1, & \text{se } [A(k,l) - g(i,j)] \geq 0. \end{cases}$$

Levando-se em consideração o LBP básico com uma vizinhança de pixels de 3 x 3, a matriz de pesos é:

$$P(k,l) = \begin{bmatrix} 1 & 2 & 4 \\ 128 & 0 & 8 \\ 64 & 32 & 16 \end{bmatrix}$$

O N_{LBP} (valores entre 0 e 255) pode ser obtido pela equação (5.4):

$$N_{LBP} = \hat{\mu}_{g(i,j)} \sum_{k=1}^W \sum_{l=1}^W P(k,l). \quad (5.4)$$

O *LBP*, então, é um caso particular da abordagem LFP.

Para que se possa avaliar o desempenho da abordagem proposta (LFP) comparativamente à tradicional técnica LBP, é utilizada como função de pertinência a função sigmoide (Figura 5.3), para análise local de textura.

Figura 5.3 - Função de pertinência sigmoide

Como na abordagem LBP é feita uma comparação *crisp* (0 ou 1) entre os pixels, há uma perda de informação relacionada com a quantidade real da diferença entre os valores dos pixels. Assim, pretende-se com o uso da função sigmoide, dada pela Equação (5.7), captar nuances que abordagens com formulação analítica não são capazes. Este descritor é então chamado de *Local Fuzzy Pattern-sigmoid* (LFP-s).

$$f_{g(i,j)} = \frac{1}{1 + e^{\frac{-[A(k,l)-g(i,j)]}{\beta}}}. \quad (5.7)$$

Para este descritor é adotada a matriz de pesos:

$$P(k,l) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Boaventura (2010) propôs uma nova abordagem para detecção de bordas em imagens digitais baseada no conceito de números *fuzzy*, chamada *Fuzzy Number Edge Detector* (FUNED). Analisando este método, observou-se também seu potencial para descrever regiões. Propõe-se também no presente trabalho, uma adaptação deste modelo como um descritor de textura local e que é denominado de *Local Fuzzy Pattern-triangular* (LFP-t). Pode-se derivá-lo da Equação (5.1) usando uma função de pertinência triangular e simétrica, descrita pela Equação (5.8):

$$f_{g(i,j)} = \max\left(0, 1 - \frac{|g(i,j) - A(k,l)|}{\delta}\right), \quad (5.8)$$

em que, $A(k,l)$ são os pixels na vizinhança $W \times W$, δ é o espalhamento de número *fuzzy* e a matriz de pesos é da forma:

$$P(k,l) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

O valor zero do pixel central desta matriz de pesos deve-se ao fato de que em (BOAVENTURA, 2010) o pixel central da região analisada é excluído do cálculo de sua pertinência.

Outra função de pertinência que também é avaliada neste trabalho é a função gaussiana dada pela Equação (5.9). Ao descritor de textura local que utilizará esta função de pertinência é dado o nome de *Local Fuzzy Pattern-gaussian* (LFP-g).

$$f_{g(i,j)} = e^{-\frac{[A(k,l)-g(i,j)]^2}{\sigma}}, \quad (5.9)$$

em que, σ é o desvio padrão.

Como o LFP-s, o LFP-t e LFP-g geram valores no intervalo $[0,1]$, é necessário convertê-los para um esquema de nível de cinza de 8-bit, cada valor do grau de pertinência é multiplicado por 255 e é arredondado o resultado final. Assim, os histogramas LFP-s, LFP-t e LFP-g têm 256 *bins* (valores inteiros entre 0 e 255), da mesma forma que o LBP básico. Neste trabalho é realizada uma comparação dos três descritores LFP-s, LFP-t e LFP-g com o descritor LBP.

5.3 Análise de textura

Para avaliação de desempenho dos descritores propostos foram realizados testes com imagens de duas bases diferentes: o álbum de Brodatz e o banco de imagens do minério vermiculita. A primeira base é composta por imagens digitalizadas a partir do álbum de Brodatz (1966), amplamente utilizada em pesquisas na área de visão computacional. A segunda base foi gerada no Laboratório de Visão Computacional e seu processo de desenvolvimento é descrito na sub-seção 5.3.2. Alguns exemplos de imagens do álbum de Brodatz e da base de dados de imagem do minério vermiculita são apresentados nas Figuras 5.4 e 5.5, respectivamente.

Figura 5.4. Texturas do álbum de Brodatz

Figura 5.5 Texturas da base de imagens do minério vermiculita

5.3.1 Álbum de Brodatz

O primeiro experimento utiliza 111 imagens de texturas sintéticas e naturais (Anexo A) do álbum de Brodatz. Cada imagem de textura é considerada como uma classe com dimensão de 640 x 640 pixels. Para cada classe são extraídas dez amostras aleatórias⁴, assim, totalizam-se para o experimento 1110 imagens. Com o objetivo de avaliar a influência do tamanho da amostra no processo de classificação foram realizados testes com diferentes tamanhos de amostras extraídas: 45 x 45 pixels, 50 x 50 pixels, 55 x 55 pixels, 60 x 60 pixels, 65 x 65 pixels, 70 x 70 pixels, 75 x 75 pixels, 80 x 80 pixels, 85 x 85 pixels e 90 x 90 pixels.

Para avaliar também a influência do tamanho da vizinhança utilizada pelo descritor LFP na classificação das amostras são utilizados dois tamanhos de vizinhança 3x3 e 5x5, usando respectivamente as seguintes matrizes de pesos para cada descritor:

- LFP-s

$$\begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}_{3 \times 3} \quad \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}_{5 \times 5}$$

- LFP-t e LFP-g

$$\begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix}_{3 \times 3} \quad \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}_{5 \times 5}$$

⁴ O programa referente ao algoritmo deste processo de extração de amostras encontra-se no Apêndice 1.

5.3.2 Banco de imagens do minério vermiculita

O segundo experimento foi realizado com imagens do minério vermiculita. Este banco de imagens foi desenvolvido pelo Laboratório de Visão Computacional⁵ (Anexo B). Para o processo de captura e digitalização das imagens foram utilizados os seguintes dispositivos e equipamentos:

- Câmera fotográfica Sony DSC-W350, 14.1 Megapixels, Sensor super HAD CCD tipo 1/2.3 (7.76mm), Lentes Carl Zeiss Vario-Tessar (Figura 5.6).

Figura 5.6 Câmera fotográfica Sony DSC-W350

- Tripé universal Sony e mesa de apoio (Figura 5.7).

Figura 5.7 Tripé e mesa de apoio

---

⁵ <http://iris.sel.eesc.usp.br/lavi/>

- Caixa de madeira para armazenamento do minério com dimensões 11 cm x 11 cm x 4 cm (Figura 5.8).

Figura 5.8 Caixa de madeira

A distância estabelecida entre a lente da câmera fotográfica e o minério foi de 11 cm (Figura 5.9). As imagens foram capturadas com uma resolução de 5 megapixels.

Figura 5.9 Ilustração da distância entre a lente da câmera e o minério

O processo de captura foi realizado em três condições de iluminação:

- Iluminação Tipo 1 (Test Case 1): lâmpada fluorescente (Figura 5.10)

Figura 5.10 Experimento na iluminação tipo 1.

- Iluminação Tipo 2 (Test Case 2): iluminação natural (Figura 5.11).

Figura 5.11 Experimento sob iluminação tipo 2.

- Iluminação Tipo 3 (Test Case 3): iluminação com lâmpadas de LED, neste tipo de iluminação além dos equipamentos previamente mencionados também foram utilizadas duas lâmpadas de LED 9W Luz Branca Bivolt VisionLED Philips como únicas fontes de iluminação em uma sala fechada (Figura 5.12).

Figura 5.12 Iluminação LED

O minério vermiculita foi separado por um especialista em mineração em 8 classes de acordo com a granulometria e a concentração de fibras:

- Classe 1: Concentrado de Vermiculita – Tipo: Média com alta concentração de fibras
- Classe 2: Concentrado de Vermiculita – Tipo: Média com baixa concentração de fibras
- Classe 3: Concentrado de Vermiculita – Tipo: Fina com alta concentração de fibras
- Classe 4: Concentrado de Vermiculita – Tipo: Fina com baixa concentração de fibras
- Classe 5: Concentrado de Vermiculita – Tipo: Superfina com alta concentração de fibras

- Classe 6: Concentrado de Vermiculita – Tipo: Superfina com baixa concentração de fibras
- Classe 7: Concentrado de Vermiculita – Tipo: Micron com alta concentração de fibras
- Classe 8: Concentrado de Vermiculita – Tipo: Micron com baixa concentração de fibras

A Figura 5.13 exibe um exemplo de imagem para cada classe.

Figura 5.13 Imagens do minério vermiculita

Para cada classe em cada tipo de iluminação foi realizada a captura de 10 imagens com tamanho 2592 x 1944 pixels. Após o processo de captura, as imagens foram transformadas em nível de cinza através da função no matlab `rgb2gray` e só então foram recortadas, eliminando as bordas indesejadas, e passaram a ter o tamanho 1600 x 1600 pixels (Figura 5.14).

Figura 5.14 Processo de formatação das imagens

Após o processo de formatação das imagens foram extraídas 20 amostras aleatórias de cada imagem e, assim como no primeiro experimento, foram extraídas amostras com diversos

tamanhos: 100 x 100 pixels, 160 x 160 pixels, 170 x 170 pixels, 175 x 175 pixels, 180 x 180 pixels, 185 x 185 pixels, 190 x 190 pixels, 195 x 195 pixels, 200 x 200 pixels, 220 x 220 pixels, 250 x 250 pixels, 300 x 300 pixels.

A nomenclatura utilizada para nomear as amostras extraídas segue o padrão ilustrado na Figura 5.15.

Figura 5.15 Padronização na nomenclatura das amostras extraídas

De maneira resumida cada tipo de iluminação é dividido em 8 classes de acordo com o tipo de minério, para cada classe foram capturadas 10 imagens das quais foram extraídas 20 amostras aleatórias. No total, cada tipo de iluminação possui 1600 amostras.

5.3.3 Processo de avaliação e classificação

O mesmo processo de avaliação foi aplicado nos dois experimentos. Para cada banco de imagem foram aplicados os descritores LBP básico e LFP com as funções de pertinência: sigmoidal (APÊNDICE C), triangular (APÊNDICE D) e gaussiana (APÊNDICE E) gerando seus histogramas correspondentes a partir da distribuição das probabilidades dos códigos provenientes de cada descritor.

O processo de classificação é então executado usando-se a distância Chi-quadrado (PELE; WERMAN, 2010) dada pela Equação (5.9):

$$\chi^2(P_i, Q_i) = \frac{1}{2} \sum_{i=0}^{255} \frac{(P_i - Q_i)^2}{(P_i + Q_i)}, \quad (5.9)$$

sendo, Q_i a frequência do nível de cinza da amostra que está sendo avaliada e P_i a frequência do nível de cinza da amostra do conjunto que está sendo comparada com a amostra avaliada.

Utilizando-se validação cruzada *leave-one-out*, foram comparados os histogramas gerados de cada amostra (programa de comparação dos histogramas no APÊNDICE F) com o

restante das amostras do conjunto (1109 amostras – álbum de brodatz e 1599 - vermiculita) conforme ilustrado na Figura 5.16.

Figura 5.16 - Processo de classificação

Uma amostra é considerada corretamente classificada se pertencer à mesma classe da amostra de teste para qual obteve a menor distância, ou seja, se o menor valor de distância Chi-quadrado for encontrado quando a amostra avaliada for comparada com as demais amostras da mesma classe.

Os resultados das classificações são armazenados em uma matriz de confusão e é feito o cálculo da sensibilidade (S), Equação (5.10), alcançada para cada descritor.

$$S = \frac{VP}{VP + FN}, \quad (5.10)$$

em que VP são os verdadeiros positivos e FN os falsos negativos.

5.4 Considerações finais

Neste capítulo apresentou-se um novo método para descrição de micropadrões em imagens de textura. O método proposto aplica a teoria de números fuzzy para descrição de imagens digitais, considerando-se as incertezas em relação aos níveis de cinza. A este novo método foi dado o nome de LFP (*Local Fuzzy Pattern*) do qual são derivados três descritores,

o LFP-s (*Local Fuzzy Pattern-sigmoid*), o LFP-t (*Local Fuzzy Pattern-triangular*) e o LFP-g (*Local Fuzzy Pattern-gaussian*). Mostrou-se que usando a abordagem proposta neste trabalho é possível derivar algumas abordagens tradicionais de análise de textura local, previamente publicadas. Assim, usando a função de pertinência adequada, a metodologia proposta pode extrair características específicas da imagem, baseada no processamento de micropadrões. E finalmente, foi apresentada a metodologia aplicada para avaliação dos descritores propostos. No próximo capítulo são exibidos e discutidos os resultados obtidos que validam as metodologias apresentadas neste capítulo.

Capítulo 6

Resultados experimentais

6.1 Considerações iniciais

Neste capítulo são apresentados os resultados experimentais obtidos pela aplicação dos descritores de micropadrões LFP-s, LFP-t e LFP-g nas imagens de textura, com análise de seus desempenhos. Para avaliação dos descritores propostos, foram realizados testes computacionais em imagens do álbum de Brodatz e da base de imagens do minério vermiculita e os resultados são comparados com o descritor de micropadrão LBP.

6.2 Análise quantitativa

O descritor LFP apresentado neste trabalho é paramétrico por natureza, assim, se faz necessário a definição dos parâmetros para cada descritor: a inclinação da curva (β) para o LFP-s, o espalhamento de número fuzzy (δ) para o LFP-t e o desvio padrão (σ) para o LFP-g a fim de se alcançar o melhor desempenho. Para cada experimento serão exibidos os melhores valores de sensibilidade encontrados para os parâmetros otimizados, os valores de sensibilidade obtidos para os demais parâmetros podem ser verificados nos Apêndices F e G para o álbum de Brodatz e nos Apêndices H, I e J para o banco de imagens do minério vermiculita.

6.2.1 Resultados para o álbum de Brodatz

A Tabela 6.1 exibe os valores de sensibilidade obtidos pelos descritores aplicando-se uma vizinhança de tamanho 3x3 e usando diferentes tamanhos de amostra. A Tabela 6.2 exibe os valores dos parâmetros otimizados.

Tabela 6.1 Sensibilidade obtida para diferentes tamanhos de amostras e vizinhança 3x3 – álbum de Brodatz
Tamanho da amostra (pixels)

	45x45	50x50	55x55	60x60	65x65	70x70	75x75	80x80	85x85	90x90
LBP	75,9%	82,9%	84,2%	85,9%	87,1%	89,7%	91,4%	92,7%	94,6%	94,6%
LFP-s	81,6%	87,2%	89,2%	91,9%	93,0%	94,8%	96,2%	96,5%	98,1%	97,9%
LFP-t	72,0%	78,2%	80,5%	84,4%	85,4%	88,6%	89,6%	91,9%	93,2%	94,1%
LFP-g	75,5%	81,1%	84,3%	87,7%	88,2%	90,6%	93,0%	94,7%	95,9%	95,9%

Tabela 6.2 Parâmetros otimizados para diferentes tamanhos de amostras e vizinhança 3x3 - álbum de Brodatz
Tamanho da amostra (pixels)

	45x45	50x50	55x55	60x60	65x65	70x70	75x75	80x80	85x85	90x90
Beta	1,001	0,950	0,750	1,003	1,001	0,900	1,007	1,001	0,950	0,900
Delta	5,700	5,800	5,700	5,800	5,800	5,720	5,600	5,600	5,600	5,800
Sigma	1,700	1,750	1,750	1,600	1,600	1,700	1,800	1,700	1,600	1,800

Observa-se que o aumento do tamanho das amostras extraídas proporciona a melhora da classificação das mesmas. O melhor valor de sensibilidade é obtido pelo descritor LFP-s com 98,1% superando os demais descritores, inclusive para todos os tamanhos de amostras.

Verifica-se também que o descritor LFP-g só apresentou desempenho inferior ao LBP em apenas dois dos casos analisados: 45 x 45 pixels e 50 x 50 pixels. Nos casos em que supera há um ganho de até 2%, é o caso das amostras de tamanho 80 x 80 pixels. O descritor LFP-t apresentou desempenho inferior aos demais descritores em todos os casos de teste, necessita de amostras com tamanhos maiores para poder classificá-las de maneira mais adequada.

Outro ponto a ser observado é que o descritor LBP necessita de uma amostra de tamanho 90 x 90 pixels para alcançar um valor de sensibilidade que o LFP-s já alcança com uma amostra menor com 70 x 70 pixels de tamanho. Isto mostra que a metodologia proposta neste trabalho possibilita melhor descrição com menos informação que o LBP necessita.

Com o objetivo de verificar a influência do tamanho da vizinhança utilizada no processo de classificação foi realizado um teste aumentando o tamanho da vizinhança de 3 x 3 para 5 x 5 nos descritores LFP. A Tabela 6.3 exibe os valores de sensibilidade ao aumentar o tamanho da vizinhança e a Tabela 6.4 exibe os respectivos parâmetros otimizados.

Tabela 6.3 Sensibilidade obtida para diferentes tamanhos de amostras e vizinhança 5x5 – álbum de Brodatz

	Tamanho da amostra (pixels)									
	45x45	50x50	55x55	60x60	65x65	70x70	75x75	80x80	85x85	90x90
LFP-s	65,5%	75,0%	79,0%	82,9%	85,1%	87,6%	90,6%	92,0%	95,7%	95,8%
LFP-t	60,5%	67,9%	71,9%	76,8%	79,1%	80,4%	85,1%	86,9%	89,7%	90,6%
LFP-g	67,1%	74,1%	77,7%	80,8%	81,9%	83,9%	86,3%	90,4%	91,2%	92,3%

Tabela 6.4 Parâmetros otimizados para diferentes tamanhos de amostras e vizinhança 5x5 - álbum de Brodatz

	Tamanho da amostra (pixels)									
	45x45	50x50	55x55	60x60	65x65	70x70	75x75	80x80	85x85	90x90
Beta	0,950	0,630	0,910	0,950	0,700	0,650	0,700	0,910	0,910	0,600
Delta	5,800	5,800	5,900	5,900	5,600	5,720	5,800	5,800	5,800	5,600
Sigma	1,100	1,100	1,100	1,210	1,660	1,500	1,750	1,680	1,680	1,700

Houve piora de desempenho em relação aos valores de sensibilidade obtidos com o uso da vizinhança menor. Este fato pode ser melhor visualizado na Tabela 6.5 que exibe o ganho no valor de sensibilidade do tamanho da vizinhança menor em relação à vizinhança maior.

Tabela 6.5 Ganho de sensibilidade em relação ao tamanho da vizinhança

	Tamanho da amostra (pixels)									
	45x45	50x50	55x55	60x60	65x65	70x70	75x75	80x80	85x85	90x90
LFP-s	16,1%	12,2%	10,2%	9,0%	7,9%	7,2%	5,6%	4,5%	2,4%	2,1%
LFP-t	11,5%	10,3%	8,6%	7,6%	6,3%	8,2%	4,5%	5,0%	3,5%	3,5%
LFP-g	8,4%	7,0%	6,6%	6,9%	6,3%	6,7%	6,7%	4,3%	4,7%	3,6%

Devido ao fato de o aumento da vizinhança não proporcionar um ganho na sensibilidade, no experimento seguinte foram realizados testes aplicando apenas a vizinhança 3 x 3.

6.2.2 Resultados para imagens do minério vermiculita

Os resultados exibidos nesta sub-seção serão divididos por tipos de iluminação.

- Iluminação TIPO 1: iluminação fluorescente (Tabelas 6.6 e 6.7)
- Iluminação TIPO 2: iluminação natural (Tabelas 6.8 e 6.9)
- Iluminação TIPO 3: iluminação com lâmpadas de LED (Tabelas 6.10 e 6.11)

Tabela 6.6 Sensibilidade obtida para diferentes tamanhos de amostras – banco de imagens de vermiculita TC1

Tamanho da amostra (pixels)												
	100x100	160x160	170x170	175x175	180x180	185x185	190x190	195x195	200x200	220x220	250x250	300x300
LBP	58,7%	79,3%	84,1%	85,4%	86,4%	85,7%	87,6%	89,1%	90,9%	92,3%	94,6%	96,8%
LFP-s	60,4%	80,8%	83,9%	85,8%	87,2%	87,2%	89,7%	89,7%	90,4%	92,5%	94,9%	98,3%
LFP-t	52,4%	73,0%	76,9%	77,3%	78,6%	77,7%	81,7%	81,4%	83,3%	86,1%	88,9%	93,2%
LFP-g	53,4%	73,3%	77,8%	78,9%	77,8%	79,8%	81,5%	82,1%	83,6%	86,6%	89,3%	93,3%

Tabela 6.7 Parâmetros otimizados para diferentes tamanhos de amostras - banco de imagens de vermiculita TC1

Tamanho da amostra (pixels)												
	100x100	160x160	170x170	175x175	180x180	185x185	190x190	195x195	200x200	220x220	250x250	300x300
Beta	0,710	0,500	0,500	0,700	0,800	0,500	0,600	0,500	0,580	0,500	0,500	0,820
Delta	35,000	53,200	52,600	55,000	40,200	41,000	39,500	52,900	30,000	54,500	41,000	30,000
Sigma	9,800	9,800	10,000	12,000	5,800	10,000	15,000	10,000	5,800	1,650	10,000	9,800

Tabela 6.8 Sensibilidade obtida para diferentes tamanhos de amostras – banco de imagens de vermiculita TC2

	Tamanho da amostra (pixels)											
	100x100	160x160	170x170	175x175	180x180	185x185	190x190	195x195	200x200	220x220	250x250	300x300
LBP	56,8%	82,3%	86,5%	86,9%	86,0%	89,3%	89,4%	90,2%	91,4%	93,6%	95,9%	97,4%
LFP-s	59,4%	84,8%	87,1%	87,7%	88,9%	90,8%	91,3%	91,3%	91,8%	94,9%	96,2%	98,7%
LFP-t	50,6%	72,3%	77,3%	75,1%	76,1%	78,9%	78,9%	80,4%	82,8%	85,7%	89,1%	92,6%
LFP-g	52,7%	72,0%	76,4%	76,3%	76,3%	76,8%	79,7%	81,2%	83,3%	85,4%	89,3%	92,7%

Tabela 6.9 Parâmetros otimizados para diferentes tamanhos de amostras - banco de imagens de vermiculita TC2

	Tamanho da amostra (pixels)											
	100x100	160x160	170x170	175x175	180x180	185x185	190x190	195x195	200x200	220x220	250x250	300x300
Beta	0,620	0,722	0,580	0,710	0,750	1,005	0,600	0,722	0,727/0,73	0,740	0,700	0,745
Delta	39,800	40,000	38,000	30,000	40,200	55,000	51,000	41,000	54,500	38,000	51,8/52/35	50,000
Sigma	15,000	16,000	10,200	14,950	10,000	1,800	15,100	15,500	15,100	10,200	18,000	10,000

Tabela 6.10 Sensibilidade obtida para diferentes tamanhos de amostras – banco de imagens de vermiculita TC3

Tamanho da amostra (pixels)												
	100x100	160X160	170x170	175x175	180x180	185x185	190x190	195x195	200x200	220x220	250x250	300x300
LBP	58,7%	82,8%	85,6%	85,2%	85,8%	87,0%	88,8%	88,6%	92,4%	92,6%	95,3%	96,8%
LFP-s	62,9%	84,1%	87,6%	86,6%	89,9%	88,6%	90,0%	91,0%	92,9%	94,5%	96,7%	98,3%
LFP-t	55,1%	73,9%	78,9%	76,9%	81,9%	79,9%	80,9%	83,6%	86,3%	87,6%	90,8%	93,2%
LFP-g	54,80%	74,4%	79,1%	77,2%	80,6%	79,6%	81,1%	84,1%	83,6%	86,9%	91,4%	93,3%

Tabela 6.11 Parâmetros otimizados para diferentes tamanhos de amostras - banco de imagens de vermiculita TC3

Tamanho da amostra (pixels)												
	100x100	160X160	170x170	175x175	180x180	185x185	190x190	195x195	200x200	220x220	250x250	300x300
Beta	0,727	0,800	0,700	1,000	0,700	0,740	0,996	0,800	0,714	0,700	0,700	0,820
Delta	40,000	30,000	38,000	54,500	40,000	30,000	41,000	40,000	60,000	51,000	54,500	30,000
Sigma	9,800	19,800	15,150	12,000	19,500	18,000	12,000	10,000	15,100	9,800	15,100	1,150

Analisando as tabelas para cada tipo de iluminação observa-se que o descritor LFP-s supera o LBP na maioria dos testes. Isto ocorre devido ao fato de que o LBP é uma versão *crisp* do LFP-s, e assim, a textura pôde ser melhor representada pela abordagem proposta neste trabalho.

Os descritores LFP-t e LFP-g apresentaram desempenho inferior aos dos outros descritores. Conclui-se assim, que ao usar a função de pertinência sigmóide, o LFP tem maior capacidade de capturar as características visuais significativas da textura do que ao utilizar as funções triangular e gaussiana.

O experimento realizado sob iluminação natural apresentou de maneira geral o melhor desempenho no processo de classificação em relação às demais iluminações. Assim, para análise das imagens deste banco de imagens não é necessário um controle rígido de iluminação, pois ao submeter o minério a iluminação controlada com lâmpadas de LED não houve ganhos significativos em relação a iluminação natural sem nenhum tipo de controle.

O melhor desempenho foi apresentado na iluminação natural com amostras de tamanho 300 x 300 pixels, com 98,7% de sensibilidade para o descritor LFP-s com parâmetro beta igual a 0,745. A Tabela 6.12 exibe a matriz de confusão gerada para este caso.

Tabela 6.12 Matriz de confusão LFP-s

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8
Classe 1	196	2	2	0	0	0	0	0
Classe 2	4	197	0	0	0	0	0	0
Classe 3	0	0	194	1	0	0	0	0
Classe 4	0	1	4	199	1	0	0	0
Classe 5	0	0	0	0	198	1	0	0
Classe 6	0	0	0	0	1	199	0	0
Classe 7	0	0	0	0	0	0	198	2
Classe 8	0	0	0	0	0	0	2	198

Na diagonal principal tem-se os verdadeiros positivos, ou seja, das 200 amostras de cada classe quantas foram classificadas corretamente como pertencentes daquela classe. É importante resaltar que a Classe 1 e a Classe 2 contém imagens de minério com mesmas granulometrias, neste caso tipo ‘médio’, assim como Classe 3 e 4, Classe 5 e 6 e Classe 7 e 8 também representam minérios com mesma granulometria e o que as diferencia é a apenas a concentração de fibras. Isto explica o fato de a maioria das

amostras que foram classificadas erroneamente estarem na classe do mesmo tipo da sua classe de origem. Por exemplo, para a Classe 1 algumas amostras são confundidas, 4 delas são classificadas como pertencentes a Classe 2 (com o mesmo tipo de minério). Mas há também o caso em que a mostra é classificada como pertencente a uma classe de tipo diferente da sua classe de origem, isto ocorre na Classe 3 que classifica 2 amostras como sendo da Classe 1.

Observando a matriz de confusão para o mesmo tipo de iluminação e tamanho de amostra agora analisando o descritor LBP (Tabela 6.13), mais amostras são confundidas em outras classes e inclusive classes com o minério de granulometrias diferentes. Na Classe 1 por exemplo, 3 de suas amostras são classificadas como Classe 2, 3 como classe 3 e 2 como classe 4.

Tabela 6.13 Matriz de confusão LBP

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8
Classe 1	192	3	0	0	0	0	0	0
Classe 2	3	193	1	1	0	0	0	0
Classe 3	3	4	193	3	0	0	0	0
Classe 4	2	0	3	194	0	0	0	0
Classe 5	0	0	2	2	195	2	1	0
Classe 6	0	0	1	0	3	198	1	0
Classe 7	0	0	0	0	0	0	196	3
Classe 8	0	0	0	0	2	0	2	197

Outro teste realizado foi a medição do esforço computacional requerido pelos descritores analisados. Executou-se uma tomada de tempo para o processo de classificação de uma amostra e do conjunto de amostras, como também, a sua relação com os valores de sensibilidade com o aumento dos tamanhos das amostras extraídas. Os testes foram conduzidos em um computador 3.40 GHz Intel i7-2600 com 16GB de memória RAM.

Os gráficos da Figura 6.1 exibem o tempo obtido em segundos no processo de classificação do conjunto de amostras e os gráficos da Figura 6.2 o tempo gasto em segundos no processo de classificação de uma amostra ao variar o tamanho da mesma. Estes gráficos ilustram resultados para o caso de iluminação com lâmpadas de LED, no Apêndice L é possível verificar o tempo de processamento para os demais tipos de iluminação e descritores.

Figura 6.17 Esforço computacional no processo de classificação do conjunto de amostras

Figura 6.18 Esforço computacional no processo de classificação de uma amostra

Verifica-se que o aumento do tamanho da amostra proporciona melhores valores de sensibilidade, porém, há um aumento do esforço computacional. O LBP apresenta desempenho superior justificado pela simplicidade da sua função de cálculo – uma função *crisp*. O LFP, por fazer uso da função sigmoide, chega a levar cerca de 27% a mais do tempo apresentado pelo LBP para a classificação do conjunto de amostra de tamanho 300 x 300 pixels, mas em contrapartida obtém melhor valor de sensibilidade.

6.3 Análise qualitativa

6.3.1 Resultados para o álbum de Brodatz

Conforme exibido da Tabela 6.1 o desempenho do LFP-s supera o LBP em até 5,9%, até 9,6% o LFP-t e até 6,1% o LFP-g. Porém, há texturas para as quais todas as quatro abordagens as descrevem bem, como por exemplo, a textura apresentada na Figura 6.3 em que as 10 amostras processadas por todos os três descritores foram corretamente classificadas.

Figura 6.19 Textura com todas as amostras classificadas corretamente

Há texturas também que o LBP classifica 50% ou menos amostras e é superado pelos três descritores fuzzy com bom desempenho, o que pode ser observado nas texturas da Figura 6.4.

Textura D30					Textura D97				
LBP	LFPs	LFPt	LFPg		LBP	LFPs	LFPt	LFPg	
Acertos	4	10	9	8	5	10	8	10	

Figura 6.20 Texturas que o LBP apresentou o pior desempenho

Para o caso analisado, em apenas uma imagem o LBP supera os demais descritores (Figura 6.5), mas ainda assim, o LFP-s e o LFP-g classificam corretamente 80% das amostras.

Textura D43				
	LBP	LFPs	LFPt	LFPg
Acertos	10	8	7	8

Figura 6.21 - Textura em que o LBP apresentou melhor desempenho na classificação das amostras

O LFP-t foi o descritor que apresentou o pior desempenho, em nenhuma das imagens superou a classificação obtida pelos outros descritores. Já o LFP-g apresenta casos em que supera os demais descritores, inclusive o LFP-s (Figura 6.6).

Textura D109				
	LBP	LFPs	LFPt	LFPg
Acertos	6	8	7	10

Textura D33				
	LBP	LFPs	LFPt	LFPg
Acertos	9	9	9	10

Figura 6.22 Texturas em que o LFP-g apresentou melhor desempenho na classificação das amostras

De maneira geral o desempenho do LFP-s é superior, considerando os outros três métodos comparados. Em várias imagens mostrou o melhor desempenho, como pode se observar na Figura 6.7. Na textura D53, por exemplo, o LFP-s classifica corretamente as 10 amostras da classe, enquanto que o LBP classifica corretamente 6 amostras, o LFP-t 7 amostras e o LFP-g 9 amostras. Com isto, pode-se afirmar que a melhor função de pertinência para análise da textura em geral é a curva sigmóide.

Textura D53				
	LBP	LFPs	LFPt	LFPg
Acertos	6	10	7	9

Textura D49				
	LBP	LFPs	LFPt	LFPg
Acertos	7	9	7	8

Textura D111				
	LBP	LFPs	LFPt	LFPg
Acertos	8	10	8	8

Figura 6.23 Texturas em que o LFP-s apresentou melhor desempenho na classificação das amostras

6.3.2 Resultados para imagens do minério vermiculita

Para cada iluminação foi selecionada aleatoriamente uma amostra para realização de uma análise qualitativa do processo de classificação com tamanho 250 x 250 pixels. A Figura 6.8 exibe a avaliação ao aplicar o LFP-s ($\beta = 0,95$) na oitava amostra extraída da imagem 1 da classe 1 sob a iluminação do Tipo 1. Já a Figura 6.9 exibe a avaliação ao aplicar o descritor LBP na mesma amostra sob o mesmo tipo de iluminação. Ao lado da amostra escolhida para a análise estão dispostas as 10 amostras que apresentaram menor distância em relação à amostra em análise no processo classificatório.

Amostra teste TC1C1_I1S8	Amostra 1 TC1C1_I1S20	Amostra 2 TC1C1_I1S1	Amostra 3 TC1C1_I1S10	Amostra 4 TC1C1_I1S7	Amostra 5 TC1C2_I1S4
Distância	0,0321	0,0364	0,0433	0,0444	0,0464
Classe	1	1	1	1	2
Imagem	1	1	1	1	1

Amostra 6 TC1C2_I1S17	Amostra 7 TC1C2_I4S8	Amostra 7 TC1C1_I8S20	Amostra 9 TC1C1_I3S19	Amostra 10 TC1C2_I6S8	
Distância	0,0483	0,0485	0,0497	0,0499	0,0501
Classe	2	2	1	1	2
Imagem	1	4	8	3	6

Figura 6.24 Avaliação qualitativa para o Tipo 1 de iluminação para o descritor LFP-s.

Amostra teste TC1C1_I1S8	Amostra 1 TC1C1_I5S9	Amostra 2 TC1C1_I1S20	Amostra 3 TC1C3_I7S3	Amostra 4 TC1C2_I8S9	Amostra 5 TC1C2_I4S9
Distância	0,0918	0,1023	0,1035	0,1036	0,1050
Classe	1	1	3	2	2
Imagem	5	1	7	8	4

Amostra 6 TC1C4_I5S13	Amostra 7 TC1C3_I3S15	Amostra 7 TC1C3_I7S9	Amostra 9 TC1C4_I2S14	Amostra 10 TC1C2_I3S7	
Distância	0,1127	0,1173	0,1186	0,1193	0,1203
Classe	4	3	3	4	2
Imagem	5	3	7	2	3

Figura 6.25 Avaliação qualitativa para o Tipo 1 de iluminação para o descritor LBP.

Ao aplicar o LFP-s nas amostras 5, 6, 7 e 10 da Classe 2 as mesmas foram classificadas como semelhantes a amostra em análise, visualmente estas amostras apresentam grande semelhança com a amostra teste, visto que representam o mesmo tipo de minério, no caso, tipo “médio”. Mas já no caso do LBP além de retornar amostras da Classe 2 também retorna amostras de classes de tipos diferentes como é o caso das amostras 3, 6 e 9 todas do tipo “fina”, isto pode ser comprovado visualmente ao observar os minérios de tamanhos diferentes da amostra original.

Dentre as 10 amostras com menor distância retornadas pelo LBP apenas 2 pertencem a mesma classe da amostra analisada, já o LFP-s é capaz de retornar 6 amostras da mesma classe. As distâncias calculadas para o LBP apresentam valores maiores em todas as amostras que os valores calculados para o LFP-s. Isto explica o fato do LBP ter retornado tantas amostras de imagens diferentes do que a imagem a qual foi extraída a amostra em análise, como por exemplo, a amostra 4 foi extraída da imagem 8.

A mesma análise foi realizada para os demais tipos de iluminação. A Figura 6.10 exibe a avaliação ao aplicar o LFP-s ($\beta = 0,7$) na décima amostra extraída da imagem 1 da Classe 5 sob a iluminação do Tipo 2 e a Figura 6.11 exibe a avaliação ao aplicar o descritor LBP na mesma amostra sob o mesmo tipo de iluminação.

Amostra teste TC2C5_I1S10						
		Amostra 1 TC2C5_I1S7	Amostra 2 TC2C5_I1S15	Amostra 3 TC2C5_I1S16	Amostra 4 TC2C5_I2S1	Amostra 5 TC2C5_I6S2
Distância		0,0160	0,0419	0,0486	0,0491	0,0503
Classe		5	5	5	5	5
Imagem		1	1	1	2	6

		Amostra 6 TC2C5_I3S15	Amostra 7 TC2C5_I5S11	Amostra 7 TC2C5_I1S3	Amostra 9 TC2C6_I2S19	Amostra 10 TC2C5_I2S17
Distância		0,0520	0,0522	0,0529	0,0534	0,0538
Classe		5	5	5	6	5
Imagem		3	5	1	2	2

Figura 6.26 Avaliação qualitativa para o Tipo 2 de iluminação para o descritor LFP-s.

Amostra teste TC2C5_I1S10	Amostra 1 TC2C5_I1S7	Amostra 2 TC2C5_I1S15	Amostra 3 TC2C5_I1S16	Amostra 4 TC2C3_I1S14	Amostra 5 TC2C5_I9S10
Distância	0,0323	0,0459	0,0757	0,0758	0,0765
Classe	5	5	5	3	5
Imagem	1	1	1	1	9

Amostra 6 TC2C5_I1S2	Amostra 7 TC2C4_I10S12	Amostra 7 TC2C5_I9S12	Amostra 9 TC2C4_I10S10	Amostra 10 TC2C5_I5S12	
Distância	0,0775	0,0783	0,0786	0,0816	0,0816
Classe	5	4	5	4	5
Imagem	1	10	9	10	5

Figura 6.27 Avaliação qualitativa para o Tipo 2 de iluminação para o descritor LBP.

A Figura 6.12 exibe a avaliação ao aplicar o LFP-s ($\beta = 0,7$) na oitava amostra extraída da imagem 9 da Classe 4 sob a iluminação do Tipo 3 e a Figura 6.13 exibe a avaliação ao aplicar o descritor LBP na mesma amostra sob o mesmo tipo de iluminação.

Amostra teste TC3C4_I9S8	Amostra 1 TC3C4_I9S18	Amostra 2 TC3C4_I9S2	Amostra 3 TC3C3_I3S9	Amostra 4 TC3C4_I9S4	Amostra 5 TC3C4_I10S15
Distância	0,0205	0,0390	0,0408	0,0421	0,0435
Classe	4	4	3	4	4
Imagem	9	9	3	9	10

Amostra 6 TC3C4_I10S20	Amostra 7 TC3C3_I7S11	Amostra 7 TC3C4_I9S15	Amostra 9 TC3C4_I8S1	Amostra 10 TC3C4_I10S17	
Distância	0,0442	0,0444	0,0455	0,0464	0,0464
Classe	4	3	4	4	4
Imagem	10	7	9	8	10

Figura 6.28 Avaliação qualitativa para o Tipo 3 de iluminação para o descritor LFP-s.

Amostra teste TC3C4_I9S8	Amostra 1 TC3C4_I9S18	Amostra 2 TC3C4_I9S2	Amostra 3 TC3C4_I9S17	Amostra 4 TC3C3_I7S1	Amostra 5 TC3C3_I1S9	
	Distância	0,0350	0,0465	0,0578	0,0674	0,0688
	Classe	4	4	4	3	3
	Imagem	9	9	9	7	1

Amostra 6 TC3C3_I1S19	Amostra 7 TC3C3_I10S5	Amostra 7 TC3C4_I9S3	Amostra 9 TC3C3_I6S1	Amostra 10 TC3C3_I4S3		
	Distância	0,0695	0,0706	0,0707	0,0709	0,0712
	Classe	3	3	4	3	3
	Imagem	1	10	9	6	4

Figura 6.29 Avaliação qualitativa para o Tipo 3 de iluminação para o descritor LBP.

É possível observar que através do uso do descritor LFP-s as amostras são classificadas mais corretamente e que, quando são classificadas como pertencentes à outra classe, retornam imagens do mesmo tipo de minério. Outro ponto importante é o fato das distâncias entre a amostra teste e as amostra retornadas para o LFP-s são sempre menores que as calculadas para o LBP, aumentando assim a confiabilidade do descritor.

6.4 Considerações finais

Neste capítulo foram apresentados os resultados obtidos para avaliação do novo método proposto para descrição de texturas. O descritor proposto foi comparado com o LBP, descritor amplamente difundido na literatura e obteve desempenho superior para os testes realizados com os dois bancos de imagens. Foi avaliado o melhor desempenho para três funções de pertinência, e a função sigmoide se mostrou mais robusta para descrição das imagens tornando assim, o LFP-s o descritor mais geral dos três avaliados. O próximo capítulo contém as conclusões.

Capítulo 7

Conclusões

7.1 Considerações finais

Este trabalho propõe uma nova metodologia em processamento digital de imagens para análise local de micropadrões. Para isto é proposta uma nova equação baseada em funções de pertinência de números *fuzzy*. Assume-se que a vizinhança de um pixel em imagens digitais deve ser modelada como um conjunto *fuzzy*, levando-se em consideração os níveis de cinza dos pixels, para que, as incertezas geradas possam ser modeladas adequadamente. A este novo método foi dado o nome de LFP (*Local Fuzzy Pattern*) e foi provado que é uma generalização de alguns métodos publicados anteriormente. Utilizando-se uma função sigmoide (LFP-s), uma função simétrica triangular (LFP-t) e uma função gaussiana (LFP-g) para o cálculo do grau de pertinência de um pixel central em relação a sua vizinhança, a abordagem proposta foi aplicada para análise de textura.

As 111 imagens de textura do álbum de Brodatz foram amostradas aleatoriamente, gerando 10 amostras para cada classe e das 240 imagens de textura do banco de imagens do minério vermiculita foram extraídas 20 amostras aleatórias. Após o processamento dessas imagens pelos descritores LFP-s, LFP-t, LFP-g e LBP, foram comparadas as taxas de acertos por meio da distância Chi-quadrado. Os resultados da avaliação de desempenho mostraram que o LFP-s supera o LBP em até 5,9% em termos de classificações corretas para o álbum de Brodatz e em até 4,2 % para a base do minério vermiculita. Este resultado se justifica pelo fato do LBP ser um caso particular do LFP, isto é, se for adotada uma função de pertinência *crisp* para a formulação LFP, obtêm-se a abordagem LBP.

A metodologia proposta é um método geral e robusto para análise de micropadrões em imagens de textura que permite ao usuário o ajuste de parâmetros que proporcionam a melhora do desempenho no processo de descrição. Outro benefício da metodologia proposta é a possibilidade de utilizar diferentes funções de pertinência, o uso da função adequada, possibilita a codificação e a captura das características

representativas de uma vizinhança de um pixel analisado. Portanto, micropadrões, tais como textura, borda e cantos poderão ser melhor representados pela metodologia LFP.

7.2 Sugestões para trabalhos futuros

A partir da investigação realizada, novas propostas surgem para continuidade do trabalho:

- Avaliar outras funções de pertinência, como por exemplo, a função trapezoidal.
- Comparar a metodologia proposta com outros descritores de micropadrões locais que também utilizam uma abordagem baseada em lógica *fuzzy*.
- Avaliar o desempenho dos descritores considerando a variação da rotação das imagens.
- Como definir os parâmetros de forma automática.

7.3 Publicações oriundas do trabalho

Trabalhos completos publicados em anais de congressos

VIEIRA, R. T.; CHIERICI, C. E. O.; FERRAZ, C. T.; GONZAGA, A. Image micro-pattern analysis using *Fuzzy Numbers*. In: *Proceedings of SIBGRAPI 2012 - Conference on Graphics, Patterns and Images*, Ouro Preto, 2012.

VIEIRA, R. T.; FERRAZ, C. T.; LANGONI, V. M.; GONZAGA, A. Uma nova proposta para análise de textura local por conjuntos *fuzzy*. In: *Anais do VIII Workshop de Visão Computacional*, Goiânia, 2012.

FERRAZ, C. T.; VIEIRA, R. T.; LANGONI, V. M.; GONZAGA, A. Avaliação de desempenho de detectores de bordas em imagens ruidosas. In: *Anais do VIII Workshop de Visão Computacional*, Goiânia, 2012.

Capítulos de livros publicados

Vieira, Raissa Tavares; Oliveira Chierici, Carlos Eduardo; Ferraz, Carolina Toledo; Gonzaga, Adilson. Local *Fuzzy Pattern*: A New Way for Micro-pattern Analysis. *Lecture Notes in Computer Science*. 1ed.: Springer Berlin Heidelberg, p. 602-611, 2012

Prêmio de melhor artigo

Vieira, Raissa Tavares; Oliveira Chierici, Carlos Eduardo; Ferraz, Carolina Toledo; Gonzaga, Adilson. Local *Fuzzy Pattern*: A New Way for Micro-pattern Analysis. In: *13th International Conference on Intelligent Data Engineering and Automated Learning*. Natal, 2012.

Referências Bibliográficas^{6 7}

AHONEN, T.; HADID, A.; PIETIKAINEN, M. Face Description with Local Binary Patterns: Application to Face Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 26, n. 12, p. 2037-2041, 2006.

ARIVAZHAGAN, S.; GANESAN, L. Texture Classification Using Wavelet Transform. *Pattern Recognition Letters*, v.24, n.9-10, p. 1513-1521, 2003.

BACKES, A. R.; CASANOVA, D; BRUNO, O. M. A complex network-based approach for boundary shape analysis. *Pattern Recognition*, v.42, n.1, p.54-67, 2009.

_____. A complex network-based approach for texture analysis. In: Isabelle, B.; Roberto, M. C. (Ed.). *Lecture Notes in Computer Science*. Springer-Verlag Berlin Heidelberg, 2010, v.6419, p.354-361.

_____.Color texture analysis based on fractal descriptors. *Pattern Recognition*, v. 45, n. 5, 2012.

BARROS, L; BASSANEZI, R. C. *Tópicos de Lógica Fuzzy e Biomatemática*. Coleção IMECC Textos Didáticos, v. 5, 2006.

BIMBO, A. D. *Visual information retrieval*. Morgan Kaufmann Publishers Inc. San Francisco, California, 1999.

BRODATZ, P. Textures: A photographic album for artists and designers. New York: Dover Publications, 1966.

CAPONETTI, L, et al. Texture Segmentation with Local Fuzzy Patterns and Neuro-fuzzy Decision Support In: Gabrys, B.; Howlett, R. J.; Jain, L. C. (Ed.), *KES 2006*, Springer-Verlag, Berlin, Heidelberg, 2006, v. Part II, p. 340-347.

CASTLEMAN, K.R. *Digital Image Processing*. New Jersey: Prentice hall Inc., 1996.

CHANG, Q.; ZHANG, B.; LIU, R. Texture analysis method for shape-based segmentation in medical image. In: *4th International Congress on Image and Signal Processing*, 2011, v. 3, p. 1146 – 1149.

---

⁶ De acordo com a Associação Brasileira de Normas Técnicas. NBR 6023.

⁷ O apêndice A exibe a distribuição das referências bibliográficas utilizadas neste trabalho em relação ao ano de publicação das mesmas.

CHOI, Y. et al. Texture Descriptors. In: Manjunath, B. S.; Salembier, P.; Sikora T. (Ed.). *Introduction to MPEG-7: Multimedia Content Description Interface*, John Wiley & Sons, New York, 2002.

COGGINS, J. M. A Framework for Texture Analysis Based on Spatial Filtering. 1982 Ph.D. Thesis - Computer Science Department, Michigan State University, East Lansing, Michigan, 1982.

de ALMEIDA, C. W. D.; de SOUZA, R. M. C. R.; CANDEIAS, A. L. B.; Texture classification based on co-occurrence matrix and self-organizing map. In: *IEEE International Conference on Systems Man and Cybernetics (SMC)*, 2010, p. 2487-2491.

DEWAELE, P.; VAN GOOL, P.; OOSTERLINCK, A. Texture Inspection with Self-Adaptive Convolution Filters, In: *Proceedings of the 9th International Conference on Pattern Recognition*, 1988, p. 56-60.

de WOUWER, G. V.; SCHEUNDERS, P.; VAN DYCK, D. Statistical Texture Characterization from Discrete Wavelet Representations. *IEEE Transactions on Image Processing*. v. 8, n. 4, p. 592–598, 1999.

FATICHAH, C. et al. Parameter Optimization of Local Fuzzy Patterns based on Fuzzy Contrast Measures for White Blood Cell Feature Extraction. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, v.16, n.3, 2012.

GABOR, D. Theory of Communication. *Journal of the Institute of Electrical Engineers*, v. 93, p.429-457, 1946.

GALLOWAY, R. Texture analysis using gray level Run lengths, *Computer Graphics and Image Processing*. n. 4, p. 172–179, 1974.

GEORGE, K.K; MADAN, M. G. Fuzzy uncertainty measures in image processing. *Journal of Electronic Imaging*. v.3, n.2, p.142-153, 1994.

GOTLIEB, C. C.; KREYSZIG, H. E. Texture descriptors based on co-occurrence matrices. *Computer Vision, Graphics, and Image Processing*. v. 51, n. 1, p. 70-86, 1990.

GONZALEZ, R. C.; WOODS, R. E. *Digital image processing*. Prentice Hall, 2008.

GÓRECKI, O.; CAPONETTI, L. Color Texture Segmentation with Local Fuzzy Patterns and Spatially Constrained Fuzzy C-Means. In: *Proceedings of the 7th international workshop on Fuzzy Logic and Applications: Applications of Fuzzy Sets Theory*, 2007, p. 362-369.

GUO, Z. H.; ZHANG, L.; ZHANG, D. Rotation invariant texture classification using LBP variance (LBPV) with global matching. *Pattern Recognition*. v.43, n.3, p.706–719, 2010.

HAINDL, M. *Texture Synthesis*. CWI Quarterly, 1991, v. 4, no. 4, p. 305-331.

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

HARALICK, R. M. Statistical and Structural Approaches to texture. In: *Proceedings of the IEEE*, 1979, v. 67, n. 5, p. 786-80.

HE, D.C.; FABBRI, A. Textural Filtering for SAR Image Processing. *IEEE Trans. on Geoscience and Remote Sensing*, v.28, n.4, p. 735-737, 1990.

HE, D.C.; WANG, L. Texture Unit, Texture Spectrum, and Texture Analysis. *IEEE Transactions On Geoscience And Remote Sensing*. v. 28, p. 509-512, 1990.

_____. Texture Features Based on Texture Spectrum. *Pattern Recognition*, v.24, n.3, p. 391-399, 1991a.

_____. Textural Filtering Based on the Texture Spectrum. *Pattern Recognition*, v.24, p. 1187-1195, 1991b.

_____. Unsupervised Textural Classification of Images Using the Texture Spectrum. *Pattern Recognition*, v.25, n.3, p.247-255, 1992a.

_____. Detecting Texture Edges from Images. *Pattern Recognition*, v.25, p.595-600, 1992b.

IAKOVIDIS, D. K.; KERAMIDAS, E. G.; MAROULIS, D. Fuzzy Local Binary Patterns for Ultrasound Texture Characterization. In Campilho, A.; Kamel, M. (Ed.). *Lecture Notes in Computer Science*. Springer-Verlag Berlin Heidelberg, 2008, v. 5112, p. 750-759.

JAIN, A. K.; FARROKHNI, F.; ALMAN, D. H. Texture Analysis of Automotive Finishes, In: *Proceedings of SME Machine Vision Applications Conference*, 1990, p. 1-16.

JAIN, A. K.; BHATTACHARJEE, S. K.; CHEN, Y. On Texture in Document Images. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1992, p. 677 – 680.

JIAN, Y. Texture Image Segmentation Based on Gaussian Mixture Models and Gray Level Co-occurrence Matrix. In: *International Symposium on Information Science and Engineering*. 2010, p.149-152.

JULESZ, B. Textons, the elements of texture perception, and their interactions. *Nature*. v. 290, p.91 – 97, 1981

KHADEMI, A.; KRISHNAN, S. Medical image texture analysis: A case study with small bowel, retinal and mammogram images. In: *Canadian Conference on Electrical and Computer Engineering*, 2008, p. 1949 – 1954.

KHANNA, A.; SHRIVASTAVA, M. Unsupervised techniques of segmentation on texture images: A comparison. In: *2012 IEEE International Conference on Signal Processing, Computing and Control*, 2012, p.1-6.

KNOPE, G. K.; GUPTA, M. M. Fuzzy uncertainty measures in image processing. *Journal of Electronic Imaging*, v.3, n. 2, p. 142-153, 1994.

LATIF-AMET, A. E.; ERCIL, A. An efficient method for texture defect detection: Subband domain co-occurrence matrices. *Image and Vision Computing*. v.18, n. 6-7, p. 543-553, 2000.

LIAO, S.; LAW, M.; CHUNG, C.S. Dominant local binary patterns for texture classification. *IEEE Transactions on Image Processing*. v.18, n.5, p. 1107–1118, 2009.

LIU, S. et al. Texture characteristic extraction of medical images based on pyramid structure wavelet transform. In: *2010 International Conference on Computer Design and Applications*, 2010, v.1, p. 342 – 345.

MÄENPÄÄ, T.; OJALA, T.; PIETIKÄINEN, M.; SORIANO, M. Robust texture classification by subsets of local binary patterns. In: *Proc. 15th International Conference on Pattern Recognition*. 2000, v.3, p.947–950.

MANDELBROT, B. B., *The Fractal Geometry of Nature*. W.H. Freeman, 1983.

MEENA, K.; SURULIANDI, A. Local binary patterns and its variants for face recognition. In: *2011 International Conference on Recent Trends in Information Technology*, 2011, p.782-786.

MOCOFAN, M.; VASIU, R. Dynamic textures indexing using the co-occurrence matrix features. In: *7th IEEE International Symposium on Applied Computational Intelligence and Informatic*, 2012, p.327-330.

MUHAMMAD, G. et al. Race recognition using local descriptors. In: *IEEE International Conference on Acoustics, Speech and Signal Processing*, 2012, p.1525-1528.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*. v.29, n.1, p.51-59, 1996.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 27, p. 971–987, 2002

PELE, O.; WERMAN, M. The quadratic-chi histogram distance family. In: *Proceedings of the 11th European conference on Computer vision*, 2010, p. 749-762.

PETPON, A.; SRISUK, S. Face recognition with local line binary pattern. In: *Proc. International Conference on Image and Graphics*, 2009, p. 533–539.

PIETIKÄINEN, M. et al. *Computer Vision Using Local Binary Patterns*. London: Springer-Verlag, 2011.

PRATT, W. K. *Digital Image Processing*, John Wiley & Sons, 1991.

RIGNOT, E.; KWOK, R. Extraction of Textural Features in SAR Images: Statistical Model and Sensitivity, In: *Proceedings of International Geoscience and Remote Sensing Symposium*, 1990, p. 1979-1982.

SADAT, R. M .N. et al. Efficient design of Local Binary Pattern for image retrieval. In: *2011 IEEE Symposium on Computers & Informatics (ISCI)*, 2011, p.510-514.

SINDHU, R. Intelligent compression of medical images with texture information. In: *2nd International Conference on Computer and Automation Engineering*, 2010, v.2, p. 734 – 737.

SKLANSKY, J. Image Segmentation and Feature Extraction. *IEEE Transactions on Systems, Man and Cybernetics*. v. 13, n. 5, p. 907-916, 1978.

SONKA, M.; HLAVA, V.; BOYLE, R. *Image Processing, Analysis and Machine Vision*. London: Chapman & Hall, 1993.

SRINIVASAN, E.M.; RAMAR, K.; SURULIANDI, A. Texture Analysis Using Local Texture Patterns: a Fuzzy Logic Approach. *International Journal of Pattern Recognition and Artificial Intelligence*. v. 25, n. 5, p.741-762, 2011.

SUMATHI, S.; SUREKHA, P. *Computational intelligence paradigms : theory & applications using MATLAB*. New York: Taylor and Francis Group, 2010.

SURULIANDI, A.; RAMAR, K. Local Texture Patterns - A Univariate Texture Model for Classification of Images. In: *16th International Conference on Advanced Computing and Communications*, 2008, p.32-39.

SURULIANDI, A.; RAMAR, K.; SURULIANDI, A. Rotation Invariant Texture Classification using Fuzzy Local Texture Patterns. *International Journal of Computer Science And Technology*. V.3, n. 1, p. 653-657, 2012.

TAXT, T.; FLYNN, P. J.; JAIN, A. K. Segmentation of Document Images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. PAMI-11, n. 12, p. 1322-1329, 1989.

TAMURA, H.; MORI, S.; YAMAWAKI, T. Textural Features Corresponding to Visual Perception. *IEEE Transactions on Systems, Man and Cybernetics*, v. 8, n. 6, p. 460-473, 1978.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. Orlando: Academic Press, 2008.

THANGAM, S. V. et al. An Effective Edge Detection Methodology for Medical Images Based on Texture Discrimination. In: *Seventh International Conference on Advances in Pattern Recognition*, 2009, p. 227 – 231.

XIE, X.; MIRMEHDI, M. TEXEM: Texture exemplars for defect detection on random textured surfaces, *IEEE Transactions on Pattern Analysis and Machine Intelligence*. v. 29, n. 8, p. 1454-1464, 2007.

WANG, L.; HE, D. C. A New Statistical Approach for Texture Analysis. *Photogram. Engg. and Remote Sensing*, v.56, n.1, p. 61-66, 1990a.

_____. Texture classification using texture spectrum. *Pattern Recognition*, v.23, p.905-910, 1990b.

XIE, X.; MIRMEHDI, M. A Galaxy of Texture Features. Chapter In: *Handbook of Texture Analysis*, p. 375-406. Imperial College Press, 2008.

XIN, W.; HUAWEL, J.; FEI, Y. T. Study on constraint-based texture synthesis. In: *2010 2nd International Conference on Education Technology and Computer*, 2010, v.1, p. 172-175.

XU, G.; MA, S. Robust tile-based texture synthesis using texture element. In: *2010 International Conference on Electronics and Information Engineering*, 2010, v. 2, p.V2-179-V2-183.

XIANCHUAN, X.; QI, Z. Medical Image Retrieval Using Local Binary Patterns with Image Euclidean Distance. In; *International Conference on Information Engineering and Computer Science*, 2009, p.1-4.

ZADEH, L.A. Fuzzy sets. *Information and Control*. v.8, p.338–53, 1965.

ZHANG, B. et al. A new algorithm of incomplete fingerprint segmentation based on LBP. In; *2011 IEEE International Conference on Cloud Computing and Intelligence Systems*, 2011, p.610-613.

ZHAO, G.; PIETIKAINEN, M. Dynamic Texture Recognition Using Local Binary Patterns with an Application to Facial Expressions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 29, n. 6, p. 915-928, 2007.

ZULIANG, A.; LIMIN, Z.; JIANTING, Z. A practical method of texture segmentation and transformation for radar image simulation. In: *2012 IEEE International Conference on Computer Science and Automation Engineering*, 2012, p. 311-317.

APÊNDICE A – Distribuição das referências bibliográficas

O gráfico da figura abaixo ilustra a distribuição dos 76 trabalhos referenciados nesta dissertação em relação aos seus respectivos anos de publicação. Observa-se que há uma maior concentração nos últimos setes anos, enfatizando assim, a busca por trabalhos atuais que melhor contextualizam a abordagem proposta nesta dissertação.

Observa-se também um pico no ano de 1990, isto se deve ao fato de que este ano foi o marco inicial nas pesquisas de abordagens de micropadrões locais iniciada com o *Texture Unit* proposto por We e Wang, mas apenas em 1996 em diante que se popularizou este tipo de análise de textura com a introdução do *Local Binary Pattern* por Ojala, Pietikainen e Harrwood e desde então, várias abordagens foram propostas para este mesmo fim.

APÊNDICE B – Rotina para geração de amostras aleatórias

```

%% Rotina para extração de amostras aleatórias %%

clear all, close all, clc

dirData = dir('*.jpg');      %carrega os nomes dos arquivo .jpg no diretório
corrente
texto = {dirData.name};

% Dados de entrada
tam_imagem=1600;    %tamanho da imagem que as amostras serão extraídas (1600 x
1600)
qnt_amostra=20;     %quantidade de amostras que serão extraídas de cada imagem
tam_amostra=52;     %tamanho da amostra (52x52 pixels)
                    %lembrando que ao aplicar os descritores, a imagem final
                    %terá uma linha e uma coluna a menos. Assim, para se
                    %trabalhar com amostras de 50x50 é necessário gerar aqui
                    %amostras com tamanho 52x52

% Alocação de memória
amostra=zeros(tam_amostra,tam_amostra);
ind=zeros(1,qnt_amostra);

% Gera as amostras e transforma em imagem (.gif .jpg ...)
for r=1:length(texto)
    str=char(texto(r));
    im=imread(str); %imagem de referência

    % Gera pontos aleatórios que serão os pontos de origem das amostras
    l_rand = fix(((tam_imagem-tam_amostra-2)/2)*(rand(qnt_amostra,1)+1));
    c_rand = fix(((tam_imagem-tam_amostra-2)/2)*(rand(qnt_amostra,1)+1));

    % Gera amostras aleatórias
    contLinha = 1;
    for i=1:qnt_amostra
        l1=0;
        for l2=1:tam_amostra
            c1=0;
            for c2=1:tam_amostra
                amostra(l2,c2)=im(l_rand(i)+l1,c_rand(i)+c1);
                c1=c1+1;
            end
            l1=l1+1;
        end

        % Estrutura para trabalhar com os blocos de pixels (cada amostra)
        matriz(contLinha).amostra = amostra;
        contLinha = contLinha + 1;
    end

    % Conversão das amostras em imagens
    for j = 1:qnt_amostra
        t=char(texto(r));
        t2=t(1:size(t,2)-4); %elimina o '.jpg'
        novoNome = sprintf('%sS%d.gif',t2,j);
        imwrite(matriz(j).amostra,novoNome);
    end
end

```


APÊNDICE C – Rotina da função do descritor LFP-s

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% LFP - Local Fuzzy Pattern
%
% Input arguments:
% img - Gray scale image.
% neighborSize - number of sample point in an square window.
% beta - pertinence function argument.
%
function result = LFP(img, neighborSize, beta)

if neighborSize < 3 || floor(neighborSize/2) == 0
    error('A vizinhança deve ser um número ímpar maior ou igual a 3!');
end;

img = double(img);

% Tamanho da imagem original
[ysize xsize] = size(img);

if(xsize < neighborSize || ysize < neighborSize)
    error('Imagem muito pequena. Deve ter pelo menos o tamanho da janela.');
```

end

```

% weightMatrix = [1 1 1 1 1; 1 1 1 1 1; 1 1 1 1 1; 1 1 1 1 1; 1 1 1 1 1];
weightMatrix = [1 1 1; 1 1 1; 1 1 1]; %matriz de pesos 1
%weightMatrix = [1 1 1; 1 0 1; 1 1 1]; %matriz de pesos 2

border = fix(neighborSize/2);
dataMatrix = img(2*border : ysize - border, 2*border : xsize - border);

[matrixSizeY matrixSizeX] = size(dataMatrix);
pertinenceSum = zeros(matrixSizeY, matrixSizeX);
weightSum = 0;

for i = 1 : neighborSize
    for j = 1 : neighborSize
        weight = weightMatrix(i, j);

        windowData = img(i : (i+matrixSizeY) - 1, j : (j+matrixSizeX) - 1);

        expData = windowData - dataMatrix;
        pert = 1./(1 + exp(-expData/beta));

        pertinenceSum = pertinenceSum + (pert * weight);
        weightSum = weightSum + weight;
    end;
end;

result = pertinenceSum / weightSum;
```


APÊNDICE D – Rotina da função do descritor LFP-t

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% LFP triangular - Local Fuzzy Pattern
%
% Input arguments:
% img - Gray scale image.
% neighborSize - number of sample point in an square window.
% delta - fuzzy number span.
%
function result = LFP-t(img, neighborSize, delta)

if neighborSize < 3 || floor(neighborSize/2) == 0
    error('A vizinhança deve ser um número ímpar maior ou igual a 3!');
end;

img = double(img);

% Tamanho da imagem original
[ysize xsize] = size(img);

if(xsize < neighborSize || ysize < neighborSize)
    error('Imagem muito pequena. De ter pelo menos o tamanho da janela.');
```

end

```

%weightMatrix = [1 1 1; 1 1 1; 1 1 1]; %matriz de pesos 1
weightMatrix = [1 1 1; 1 0 1; 1 1 1]; %matriz de pesos 2
% weightMatrix = [1 1 1 1 1; 1 1 1 1 1; 1 1 0 1 1; 1 1 1 1 1; 1 1 1 1 1];

border = fix(neighborSize/2);
dataMatrix = img(2*border : ysize - border, 2*border : xsize - border);

[matrixSizeY matrixSizeX] = size(dataMatrix);
pertinenceSum = zeros(matrixSizeY, matrixSizeX);
weightSum = 0;

for i = 1 : neighborSize
    for j = 1 : neighborSize
        weight = weightMatrix(i, j);

        windowData = img(i : (i+matrixSizeY) - 1, j : (j+matrixSizeX) - 1);

        val1 = (windowData - (dataMatrix-delta))/delta;
        val2 = ((dataMatrix+delta) - windowData)/delta;
        pert = max(min(val1, val2), 0);

        pertinenceSum = pertinenceSum + (pert * weight);
        weightSum = weightSum + weight;
    end;
end;

result = pertinenceSum / weightSum;
```


APÊNDICE E – Rotina da função do descritor LFP-g

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% LFP - Local Fuzzy Pattern
% Gaussian function.
%
% Input arguments:
% img - Gray scale image.
% neighborSize - number of sample point in an square window.
% bellWidth - controls the width of the gaussian "bell" curve.
%
function result = LFP-g(img, neighborSize, bellWidth)

if neighborSize < 3 || floor(neighborSize/2) == 0
    error('A vizinhança deve ser um número ímpar maior ou igual a 3!');
end;

img = double(img);

% Tamanho da imagem original
[ysize xsize] = size(img);

if(xsize < neighborSize || ysize < neighborSize)
    error('Imagem muito pequena. De ter pelo menos o tamanho da janela.');
```

end

```

% weightMatrix = [1 1 1 1 1; 1 1 1 1 1; 1 1 0 1 1; 1 1 1 1 1; 1 1 1 1 1];
% weightMatrix = [1 1 1; 1 1 1; 1 1 1]; %matriz de pesos 1
weightMatrix = [1 1 1; 1 0 1; 1 1 1]; %matriz de pesos 2

border = fix(neighborSize/2);
dataMatrix = img(2*border : ysize - border, 2*border : xsize - border);

[matrixSizeY matrixSizeX] = size(dataMatrix);
pertinenceSum = zeros(matrixSizeY, matrixSizeX);
weightSum = 0;

for i = 1 : neighborSize
    for j = 1 : neighborSize
        weight = weightMatrix(i, j);
        windowData = img(i : (i+matrixSizeY) - 1, j : (j+matrixSizeX) - 1);

        % Gaussian function arguments:
        %
        % peakHeight - height of the curve's peak.
        % centrePos - position of the centre of the peak.
        % bellWidth - controls the width of the "bell".
        %
        % Gaussian function:
        % result = peakHeight*(exp( -( (x-centrePos).^2)/(2*(bellWidth^2)) )
    ));

    %
    pert = exp( -( ((windowData-dataMatrix).^2)/(2*(bellWidth^2)) ) );

    pertinenceSum = pertinenceSum + (pert * weight);
    weightSum = weightSum + weight;
    end;
end;

result = pertinenceSum / weightSum;
```


APÊNDICE F – Programa de classificação das amostras

```

%%% Rotina para classificação das amostras %%%

clc, clear all, close all;

%%%% DADOS DE ENTRADA %%%%

% Escolha do descritor que será aplicado
operador = input('Selecione uma das opções: \n\n1 - LBP \n2 - LFP-s \n3 - LFP-t \n4 - LFP-g\n\n');

% Tamanho da amostra
tamanhoAmostra = input('\nDigite o tamanho da amostra: ');

% Quantidade de classes
qntClasse = input('\nDigite a quantidade de classes de imagens: ');

% Quantidade de imagens por classe
qntImgClasse = input('\nDigite a quantidade de imagens que cada classe possui: ');

% Quantidade de amostras extraídas de cada imagem
qntAmostraImg = input('\nDigite a quantidade de amostras extraídas de cada imagem: ');

if operador ~= 1
    % Tamanho da vizinhança
    lfpNumVizinhos = input('\nDigite o tamanho da vizinhança: ');

    % Leitura dos parâmetros dos descritores de textura
    disp('Lendo lista de parâmetros...');

    if operador == 2
        parametro =
xlsread(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),'parametros','C5:C64');
        qtdParametro=length(parametro);
    elseif operador == 3
        parametro =
xlsread(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),'parametros','H5:H64');
        qtdParametro=length(parametro);
    elseif operador == 4
        parametro =
xlsread(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),'parametros','K5:K64');
        qtdParametro=length(parametro);
    end
end

%%%% Leitura das amostras %%%%
disp('Carregando amostras...');
dirData = dir('*.gif'); %carrega os nomes dos arquivo .gif no diretório corrente
texto = {dirData.name};
numImgs = length(texto);
imgList = cell(numImgs, 1);
imgHistList = cell(numImgs, 1);
bins = 256;

for i = 1 : numImgs
    str = char(texto(i));
    imgList{i} = imread(str);
end;

```

```

##### Opção de salvar matriz de confusão #####
salvarMatrizConfusao = input('\nDeseja salvar a matriz de confusão? \n\n1 - sim
\n2 - não\n\n');

if salvarMatrizConfusao == 1
    salvarMatrizConfusao = 1;
else
    salvarMatrizConfusao = 2;
end

##### Aplicação do descritor de textura escolhido #####
disp('Aplicando descritor de texturas...');
i1 = 1;
i3 = 1;

if operador == 1 % aplicar LBP
    for r = 1 : numImgs
        amostra = imgList{r};

        % Aplica o descritor LBP básico
        SP = [-1 -1; -1 0; -1 1; 0 -1; -0 1; 1 -1; 1 0; 1 1];
        amostra_NiveldeCinza = lbp(amostra,SP,0,'i');
        imgHist = imhist(amostra_NiveldeCinza);

        % Normalização da frequência dos níveis de cinza da imagem de referência
        ma_ref = max(imgHist);
        mi_ref = min(imgHist);
        imgHist = (imgHist - mi_ref) / (ma_ref - mi_ref);
        imgHistList{r} = imgHist;

        if i1 < qntAmostraImg
            i1 = i1 + 1;
        else
            i1 = 1;
            i3 = i3 + 1;
        end
    end

    ##### Classificação das amostras #####
    disp('Classificando amostras...');

    h_comp = zeros(1, bins);
    h_ref = zeros(1, bins);
    chi_quadrado = zeros(1, numImgs);
    matriz_chi = zeros(length(texto), numImgs);

    for r = 1 : numImgs
        h_ref = imgHistList{r};

        % Comparação da amostra de referência com as demais amostras da base de
dados
        for p = 1 : numImgs
            h_comp = imgHistList{p};

            subMatrix = h_comp - h_ref;
            subMatrix2 = subMatrix.^2;
            addMatrix = h_comp + h_ref;

            idxZero = find(addMatrix == 0);
            addMatrix(idxZero) = 1;

            DistMat = subMatrix2./addMatrix;
            DV = sum(DistMat,1);

            chi_quadrado(p) = DV; %armazena os valores chi-quadrado
        end
    end
end

```

```

        matriz_chi(:, r) = chi_quadrado';
    end

    %%%% Gera matriz de confusão %%%%
    disp('Gerando matriz de confusão...');

    numerico = matriz_chi';
    tam = size(numerico);

    for i = 1 : tam(1)
        for j = 1 : tam(2)
            if i == j
                numerico(i,j) = 1000; %substitui os '0' da diagonal principal
                % por um valor grande para não entrar no cálculo do mínimo
            end
        end
    end

    matriz_confusao = zeros((tam(1) / qntAmostraImg), (tam(2) / qntAmostraImg));
    % aloca memória

    for r = 1 : tam(2)
        [minimo, posicao] = min(numerico(1 : tam(1), r));
        classe = fix((posicao - 1) / qntAmostraImg) + 1;
        matriz_confusao(classe, (fix((r - 1) / qntAmostraImg) + 1)) =
matriz_confusao(classe, (fix((r - 1) / qntAmostraImg)+1)) + 1;
    end

    matrizConfusaoNova=zeros(qntClasse,qntClasse);
    i2=1;
    s2=qntImgClasse;

    for j=1:qntClasse
        i1=1;
        s=qntImgClasse;
        for i=1:qntClasse
            matrizConfusaoNova(i,j)=sum(sum(matriz_confusao(i1:s,i2:s2)));
            i1=i1+qntImgClasse;
            s=s+qntImgClasse;
        end
        i2=i2+qntImgClasse;
        s2=s2+qntImgClasse;
    end

    % Cálculo da sensibilidade
    tam2 = size(matrizConfusaoNova);
    soma = 0;
    for i2 = 1 : tam2(1)
        for j2 = 1 : tam2(2)
            if i2 == j2
                soma = soma + matrizConfusaoNova(i2,j2);
            end
        end
    end

    sensibilidade = (soma / numImgs) * 100;
    message = sprintf('Sensibilidade: %02f', sensibilidade);
    disp(message);

    if salvarMatrizConfusao == 1
        disp('Salvando matriz de confusão...');
        % Matriz de confusão LBP

    xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),sensibilid
ade,'matriz_de_confusao_LBP','D2');

```

```

xlswrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),matrizConf
usaoNova,'matriz_de_confusao_LBP','B5:I12');
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% FIM LBP
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
else
    for b = 1: qtdParametro
        for r = 1 : numImgs
            amostra = imgList{r};

            if operador == 2
                % Aplicar o descritor LFP-s
                lfpMatrix = LFP(amostra, lfpNumVizinhos, parametro(b));
                % converte a matriz com os códigos LFP p/ níveis de cinza (0-
255) amostra_NiveldeCinza = uint8(lfpMatrix * 255);
            elseif operador == 3
                % Aplicar o descritor LFP-t
                lfpMatrix = LFP-t(amostra, lfpNumVizinhos, parametro(b));
                % converte a matriz com os códigos LFP-t p/ níveis de cinza (0-
255) amostra_NiveldeCinza = uint8(lfpMatrix * 255);
            elseif operador == 4
                % Aplicar o descritor LFP-g
                lfpMatrix = LFP-g(amostra, lfpNumVizinhos, parametro(b));
                % converte a matriz com os códigos LFP-g p/ níveis de cinza (0-
255) amostra_NiveldeCinza = uint8(lfpMatrix * 255);
            end

            imgHist = imhist(amostra_NiveldeCinza);

            % Normalização da frequência dos níveis de cinza da imagem de
referência
            ma_ref = max(imgHist);
            mi_ref = min(imgHist);

            imgHist = (imgHist - mi_ref) / (ma_ref - mi_ref);
            imgHistList{r} = imgHist;

            if i1 < qntAmostraImg
                i1 = i1 + 1;
            else
                i1 = 1;
                i3 = i3 + 1;
            end
        end

        %%%% Classificação das amostras %%%%
        disp('Classificando amostras...');

        h_comp = zeros(1, bins);
        h_ref = zeros(1, bins);
        chi_quadrado = zeros(1, numImgs);
        matriz_chi = zeros(length(texto), numImgs);

        for r = 1 : numImgs
            h_ref = imgHistList{r};

            % Comparação da amostra de referência com as demais amostras da base
de dados
            for p = 1 : numImgs
                h_comp = imgHistList{p};

                subMatrix = h_comp - h_ref;
                subMatrix2 = subMatrix.^2;
                addMatrix = h_comp + h_ref;
            end
        end
    end
end

```

```

        idxZero = find(addMatrix == 0);
        addMatrix(idxZero) = 1;

        DistMat = subMatrix2./addMatrix;
        DV = sum(DistMat,1);

        chi_quadrado(p) = DV; %armazena os valores chi-quadrado
    end

    matriz_chi(:, r) = chi_quadrado';
end

%%%% Gera matriz de confusao %%%%%
disp('Gerando matriz de confusão...');

numerico = matriz_chi';
tam = size(numerico);

for i = 1 : tam(1)
    for j = 1 : tam(2)
        if i == j
            numerico(i,j) = 1000; %substitui os '0' da diagonal
principal por um valor grande para não entrar no cálculo do mínimo
        end
    end
end

matriz_confusao = zeros((tam(1) / qntAmostraImg), (tam(2) /
qntAmostraImg)); % aloca memória

for r = 1 : tam(2)
    [minimo,posicao] = min(numerico(1 : tam(1),r));
    classe = fix((posicao - 1) / qntAmostraImg) + 1;
    matriz_confusao(classe, (fix((r - 1) / qntAmostraImg) + 1)) =
matriz_confusao(classe, (fix((r - 1) / qntAmostraImg)+1)) + 1;
end

matrizConfusaoNova=zeros(qntClasse,qntClasse);
i2=1;
s2=qntImgClasse;

for j=1:qntClasse
    i1=1;
    s=qntImgClasse;
    for i=1:qntClasse
        matrizConfusaoNova(i,j)=sum(sum(matriz_confusao(i1:s,i2:s2)));
        i1=i1+qntImgClasse;
        s=s+qntImgClasse;
    end
    i2=i2+qntImgClasse;
    s2=s2+qntImgClasse;
end

% Cálculo da sensibilidade
tam2 = size(matrizConfusaoNova);
soma = 0;
for i2 = 1 : tam2(1)
    for j2 = 1 : tam2(2)
        if i2 == j2
            soma = soma + matrizConfusaoNova(i2,j2);
        end
    end
end

sensibilidade = (soma / numImgs) * 100;
message = sprintf('Sensibilidade: %02f', sensibilidade);
disp(message);

```

```

    if salvarMatrizConfusao == 1
        disp('Salvando matriz de confusão...');

        if operador == 2
            % Matriz de confusão LFP-s

            xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),sensibilid
            ade,cat(2,'matriz_de_confusao_LFP-s_',num2str(parametro(b))), 'D2');

            xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),sensibilid
            ade,'parametros',cat(2,'D',num2str(b+4)));

            xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),matrizConf
            usaoNova,cat(2,'matriz_de_confusao_LFP-s_',num2str(parametro(b))), 'B5:I12');
            elseif operador == 3
                % Matriz de confusão LFP-t

                xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),sensibilid
                ade,cat(2,'matriz_de_confusao_LFP-t_',num2str(parametro(b))), 'D2');

                xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),sensibilid
                ade,'parametros',cat(2,'I',num2str(b+4)));

                xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),matriz_con
                fusao,cat(2,'matriz_de_confusao_LFP-t_',num2str(parametro(b))), 'B5:I12');
                elseif operador == 4
                    % Matriz de confusão LFP-g

                    xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),sensibilid
                    ade,cat(2,'matriz_de_confusao_LFP-g_',num2str(parametro(b))), 'D2');

                    xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),sensibilid
                    ade,'parametros',cat(2,'L',num2str(b+4)));

                    xlsxwrite(cat(2,'matriz_de_confusao_',num2str(tamanhoAmostra),'.xlsx'),matriz_con
                    fusao,cat(2,'matriz_de_confusao_LFP-g_',num2str(parametro(b))), 'B5:I12');
                    end
                end
            end
        end
    end
end

```

APÊNDICE G – Sensibilidade obtida para diferentes valores de parâmetro
(Álbum de Brodatz – vizinhança 3 x 3)

LFP-s 45x45		LFP-t 45x45		LFP-g 45x45		LFP-s 50x50		LFP-t 50x50		LFP-g 50x50	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	59,1	2,000	43,3	1,500	73,0	0,100	68,4	2,000	51,1	1,500	79,6
0,200	67,4	4,000	54,4	1,550	74,3	0,200	74,4	4,000	62,6	1,550	80,4
0,300	67,9	5,000	57,5	1,600	73,6	0,300	78,2	5,000	62,8	1,600	80,4
0,400	75,3	5,500	66,8	1,650	74,4	0,400	81,8	5,500	74,6	1,650	81,1
0,500	78,3	5,600	71,7	1,700	75,5	0,500	82,4	5,600	77,7	1,700	80,1
0,600	78,5	5,650	71,4	1,750	74,7	0,600	83,9	5,650	76,4	1,750	81,1
0,700	80,5	5,700	72,0	1,800	74,1	0,700	85,7	5,700	77,8	1,800	80,8
0,710	80,4	5,720	71,7	1,900	75,0	0,710	86,5	5,720	78,1	1,900	80,0
0,720	81,3	5,800	71,9	2,000	74,2	0,720	85,8	5,800	78,2	2,000	80,3
0,725	80,6	6,000	61,1	4,000	62,9	0,725	86,3	6,000	69,6	4,000	69,6
0,750	80,1	10,000	55,5	5,000	58,8	0,750	86,0	10,000	61,5	5,000	67,1
0,800	79,7	15,000	56,1	5,700	58,2	0,800	85,7	15,000	62,3	5,700	65,0
0,900	80,7	20,000	53,8	6,000	57,4	0,900	87,2	20,000	62,3	6,000	66,6
0,950	80,9	25,000	55,6	10,000	57,5	0,950	87,2	25,000	61,7	10,000	62,3
1,000	81,3	30,000	54,9	15,000	53,8	1,000	85,9	30,000	61,6	15,000	59,8
1,001	81,6	35,000	54,5	20,000	51,4	1,001	85,9	35,000	60,8	20,000	60,2
1,003	80,7	40,000	54,3	25,000	54,1	1,003	85,7	40,000	58,8	25,000	57,9
1,005	81,2	45,000	52,6	30,000	52,3	1,005	85,4	45,000	59,0	30,000	58,2
1,007	80,8	48,000	53,5	35,000	54,0	1,007	85,5	48,000	59,1	35,000	56,9
1,050	79,8	49,000	53,1	40,000	53,7	1,050	86,5	49,000	59,9	40,000	56,8
1,100	78,8	50,000	54,7	45,000	52,9	1,100	86,2	50,000	58,8	45,000	57,7
1,200	78,6	51,000	54,6	48,000	53,3	1,200	84,8	51,000	57,6	48,000	57,2
1,400	77,7	51,800	55,4	50,000	53,4	1,400	83,2	51,800	60,0	50,000	58,0
1,500	75,9	52,000	56,0	52,000	54,0	1,500	83,1	52,000	58,1	52,000	57,7
1,600	76,1	52,200	55,1	55,000	51,9	1,600	79,5	52,200	59,1	55,000	57,3
1,700	72,6	52,500	54,9	60,000	52,0	1,700	78,5	52,500	59,1	60,000	58,9
1,800	73,7	53,000	54,8	65,000	51,7	1,800	78,1	53,000	59,8	65,000	59,1
2,000	71,9	55,000	53,0	70,000	53,7	2,000	77,6	55,000	59,2	70,000	56,8
5,000	59,9	60,000	53,4	75,000	52,3	5,000	68,2	60,000	58,6	75,000	59,0
7,000	54,0	65,000	52,7	80,000	52,3	7,000	64,0	65,000	57,5	80,000	59,5

LFP-s 55x55		LFP-t 55x55		LFP-g 55x55		LFP-s 60x60		LFP-t 60x60		LFP-g 60x60	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	69,8	2,000	52,0	1,500	82,8	0,100	75,6	2,000	56,8	1,500	85,3
0,200	76,7	4,000	64,1	1,550	82,9	0,200	81,3	4,000	71,2	1,550	86,7
0,300	78,0	5,000	65,0	1,600	84,1	0,300	83,4	5,000	72,4	1,600	87,7
0,400	84,0	5,500	74,8	1,650	83,4	0,400	87,2	5,500	80,4	1,650	87,1
0,500	87,0	5,600	80,1	1,700	82,8	0,500	90,1	5,600	84,1	1,700	86,8
0,600	87,7	5,650	78,5	1,750	84,3	0,600	89,8	5,650	83,8	1,750	87,0
0,700	87,8	5,700	80,5	1,800	83,7	0,700	91,9	5,700	84,0	1,800	85,8
0,710	87,9	5,720	79,5	1,900	83,2	0,710	91,4	5,720	84,3	1,900	86,4
0,720	88,6	5,800	80,3	2,000	84,0	0,720	90,9	5,800	84,4	2,000	85,3
0,725	89,1	6,000	68,9	4,000	73,2	0,725	91,3	6,000	75,6	4,000	77,0
0,750	89,2	10,000	65,3	5,000	70,4	0,750	91,2	10,000	72,1	5,000	74,1
0,800	88,7	15,000	65,5	5,700	69,5	0,800	90,6	15,000	69,5	5,700	73,6
0,900	88,1	20,000	65,9	6,000	70,5	0,900	91,3	20,000	69,5	6,000	74,4
0,950	88,1	25,000	66,7	10,000	64,4	0,950	92,7	25,000	70,4	10,000	67,9
1,000	88,6	30,000	66,1	15,000	64,4	1,000	91,6	30,000	69,5	15,000	68,0
1,001	88,6	35,000	64,5	20,000	63,4	1,001	91,7	35,000	67,7	20,000	66,2
1,003	88,8	40,000	65,7	25,000	62,5	1,003	91,9	40,000	66,5	25,000	66,5
1,005	88,8	45,000	63,3	30,000	62,8	1,005	91,6	45,000	68,2	30,000	66,5
1,007	88,7	48,000	64,5	35,000	62,9	1,007	90,0	48,000	67,7	35,000	64,3
1,050	88,4	49,000	65,1	40,000	64,0	1,050	91,2	49,000	67,1	40,000	64,3
1,100	86,9	50,000	64,5	45,000	61,3	1,100	90,8	50,000	68,3	45,000	63,5
1,200	88,0	51,000	63,9	48,000	60,5	1,200	90,8	51,000	67,9	48,000	63,6
1,400	87,1	51,800	65,9	50,000	60,4	1,400	90,1	51,800	68,9	50,000	65,0
1,500	86,1	52,000	66,7	52,000	61,9	1,500	88,6	52,000	69,0	52,000	63,8
1,600	83,9	52,200	66,8	55,000	63,1	1,600	87,8	52,200	69,3	55,000	62,6
1,700	83,7	52,500	66,5	60,000	61,1	1,700	87,1	52,500	70,5	60,000	63,3
1,800	82,8	53,000	65,5	65,000	61,7	1,800	87,9	53,000	67,6	65,000	63,6
2,000	79,8	55,000	63,9	70,000	61,4	2,000	85,9	55,000	68,6	70,000	60,2
5,000	73,0	60,000	66,6	75,000	62,3	5,000	76,8	60,000	68,9	75,000	62,2
7,000	68,6	65,000	62,3	80,000	61,8	7,000	74,3	65,000	68,6	80,000	62,4

LFP-s 65x65		LFP-t 65x65		LFP-g 65x65		LFP-s 70x70		LFP-t 70x70		LFP-g 70x70	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	77,3	2,000	61,2	1,500	86,8	0,100	81,2	2,000	65,3	1,500	89,9
0,200	84,7	4,000	74,1	1,550	87,7	0,200	86,0	4,000	78,0	1,550	90,2
0,300	87,0	5,000	72,3	1,600	88,2	0,300	89,1	5,000	78,1	1,600	90,0
0,400	89,8	5,500	82,7	1,650	88,1	0,400	91,7	5,500	85,2	1,650	90,4
0,500	90,8	5,600	85,4	1,700	88,2	0,500	92,3	5,600	88,2	1,700	90,6
0,600	91,3	5,650	84,7	1,750	87,6	0,600	93,0	5,650	87,7	1,750	90,5
0,700	92,2	5,700	85,4	1,800	87,4	0,700	94,0	5,700	88,1	1,800	90,2
0,710	92,3	5,720	85,3	1,900	87,4	0,710	94,4	5,720	88,6	1,900	90,0
0,720	92,0	5,800	85,4	2,000	87,8	0,720	93,4	5,800	88,4	2,000	90,5
0,725	92,6	6,000	77,7	4,000	78,8	0,725	93,8	6,000	80,8	4,000	83,7
0,750	93,0	10,000	71,8	5,000	77,5	0,750	94,1	10,000	76,6	5,000	81,2
0,800	91,8	15,000	72,3	5,700	74,9	0,800	93,1	15,000	76,9	5,700	78,7
0,900	91,5	20,000	72,9	6,000	75,9	0,900	94,8	20,000	76,3	6,000	80,9
0,950	93,5	25,000	72,3	10,000	72,3	0,950	93,5	25,000	77,4	10,000	78,2
1,000	92,6	30,000	72,9	15,000	71,6	1,000	93,8	30,000	77,5	15,000	77,5
1,001	93,0	35,000	71,2	20,000	70,8	1,001	93,7	35,000	77,4	20,000	75,8
1,003	92,7	40,000	72,2	25,000	68,7	1,003	93,9	40,000	75,5	25,000	73,4
1,005	93,1	45,000	72,4	30,000	69,0	1,005	93,6	45,000	76,8	30,000	74,1
1,007	92,6	48,000	70,2	35,000	68,8	1,007	93,9	48,000	76,7	35,000	74,0
1,050	92,3	49,000	70,3	40,000	69,5	1,050	93,4	49,000	77,3	40,000	73,8
1,100	92,3	50,000	71,5	45,000	69,1	1,100	93,2	50,000	76,7	45,000	73,3
1,200	91,2	51,000	72,0	48,000	67,2	1,200	92,9	51,000	76,7	48,000	73,2
1,400	91,3	51,800	70,5	50,000	67,5	1,400	93,1	51,800	75,6	50,000	73,3
1,500	90,0	52,000	71,4	52,000	69,7	1,500	92,6	52,000	76,5	52,000	73,0
1,600	90,0	52,200	72,1	55,000	69,0	1,600	91,4	52,200	77,5	55,000	71,1
1,700	89,1	52,500	71,9	60,000	68,6	1,700	91,4	52,500	76,5	60,000	71,2
1,800	90,1	53,000	70,7	65,000	68,8	1,800	90,7	53,000	76,3	65,000	70,2
2,000	88,1	55,000	71,0	70,000	68,4	2,000	90,0	55,000	74,4	70,000	71,9
5,000	79,9	60,000	68,8	75,000	69,1	5,000	83,4	60,000	75,1	75,000	71,8
7,000	77,4	65,000	70,0	80,000	68,8	7,000	80,9	65,000	74,4	80,000	72,2

LFP-s 75x75		LFP-t 75x75		LFP-g 75x75		LFP-s 80x80		LFP-t 80x80		LFP-g 80x80	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	85,0	2,000	68,2	1,500	91,6	0,100	87,7	2,000	72,5	1,600	93,2
0,200	87,9	4,000	80,6	1,550	92,1	0,200	91,0	4,000	83,1	1,650	94,2
0,300	91,5	5,000	80,9	1,600	92,5	0,300	91,2	5,000	82,3	1,700	94,7
0,400	93,7	5,500	86,8	1,650	92,4	0,400	94,4	5,500	90,5	1,750	94,1
0,500	93,7	5,600	89,6	1,700	92,0	0,500	95,3	5,600	91,9	1,800	93,7
0,600	94,7	5,650	89,3	1,750	92,0	0,600	96,0	5,650	91,6	1,900	92,8
0,700	95,3	5,700	89,5	1,800	93,0	0,700	96,2	5,700	91,4	2,000	93,1
0,710	95,0	5,720	89,4	1,900	91,9	0,710	95,9	5,720	91,8	4,000	87,4
0,720	95,1	5,800	89,5	2,000	91,4	0,720	96,0	5,800	91,6	5,000	85,7
0,725	95,6	6,000	83,9	4,000	81,6	0,725	95,7	6,000	85,5	5,700	85,9
0,750	95,2	10,000	79,1	5,000	81,2	0,750	95,9	10,000	82,5	5,800	85,9
0,800	95,2	15,000	79,4	5,700	80,7	0,800	95,7	15,000	81,4	6,000	85,8
0,900	95,0	20,000	77,8	6,000	80,4	0,900	95,9	20,000	83,5	10,000	84,0
0,950	95,7	25,000	77,8	10,000	79,5	0,950	96,0	25,000	82,5	15,000	82,0
1,000	95,9	30,000	79,8	15,000	77,9	1,000	96,5	30,000	84,2	20,000	81,5
1,001	95,6	35,000	78,6	20,000	78,1	1,001	96,5	35,000	83,2	25,000	81,2
1,003	95,9	40,000	80,5	25,000	77,1	1,003	96,3	40,000	83,3	30,000	80,6
1,005	95,7	45,000	79,7	30,000	76,6	1,005	96,3	45,000	84,0	35,000	79,8
1,007	96,2	48,000	79,4	35,000	76,8	1,007	96,4	48,000	83,5	40,000	79,1
1,050	95,2	49,000	78,9	40,000	76,9	1,050	95,9	49,000	84,4	45,000	79,3
1,100	96,0	50,000	78,9	45,000	75,2	1,100	95,7	50,000	83,4	48,000	79,3
1,200	95,2	51,000	78,3	48,000	75,4	1,200	95,7	51,000	83,8	50,000	78,7
1,400	94,0	51,800	79,4	50,000	74,9	1,400	95,0	51,800	83,4	51,000	79,5
1,500	93,7	52,000	78,9	52,000	76,8	1,500	94,5	52,000	83,1	52,500	79,6
1,600	93,6	52,200	79,6	55,000	75,4	1,600	94,6	52,200	84,1	53,000	78,8
1,700	92,9	52,500	78,7	60,000	76,4	1,700	94,0	52,500	83,9	55,000	80,2
1,800	93,0	53,000	79,0	65,000	75,4	1,800	93,3	53,000	82,2	60,000	78,6
2,000	90,6	55,000	78,9	70,000	76,7	2,000	92,6	55,000	83,8	65,000	77,1
5,000	84,4	60,000	77,7	75,000	77,1	5,000	87,5	60,000	83,2	70,000	78,0
7,000	84,3	65,000	78,7	80,000	76,8	7,000	86,8	65,000	82,7	75,000	78,9

LFP-s 85x85		LFP-t 85x85		LFP-g 85x85		LFP-s 90x90		LFP-t 90x90		LFP-g 90x90	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	90,7	2,000	74,1	1,600	95,9	0,100	88,9	2,000	77,0	1,600	95,9
0,200	93,0	4,000	86,6	1,650	95,7	0,200	93,0	4,000	85,5	1,650	95,6
0,300	95,3	5,000	85,7	1,700	95,4	0,300	94,4	5,000	87,7	1,700	95,6
0,400	96,8	5,500	92,2	1,750	95,3	0,400	96,1	5,500	91,4	1,750	95,4
0,500	96,8	5,600	93,2	1,800	95,3	0,500	97,0	5,600	94,0	1,800	95,9
0,600	97,1	5,650	92,6	1,900	95,5	0,600	97,5	5,650	92,7	1,900	95,3
0,700	97,7	5,700	93,1	2,000	95,3	0,700	97,2	5,700	93,6	2,000	95,2
0,710	97,8	5,720	93,2	4,000	89,0	0,710	97,7	5,720	94,0	4,000	89,8
0,720	97,8	5,800	93,2	5,000	88,6	0,720	97,7	5,800	94,1	5,000	89,1
0,725	98,0	6,000	88,9	5,700	88,6	0,725	97,8	6,000	88,8	5,700	89,7
0,750	98,0	10,000	85,0	5,800	88,4	0,750	97,4	10,000	85,8	5,800	88,8
0,800	97,7	15,000	84,1	6,000	88,8	0,800	97,5	15,000	86,2	6,000	89,8
0,900	97,4	20,000	84,2	10,000	85,5	0,900	97,9	20,000	85,8	10,000	87,3
0,950	98,1	25,000	84,8	15,000	83,2	0,950	97,7	25,000	85,5	15,000	85,9
1,000	97,5	30,000	84,8	20,000	83,2	1,000	97,5	30,000	86,7	20,000	84,1
1,001	97,5	35,000	84,9	25,000	82,2	1,001	97,5	35,000	86,3	25,000	82,9
1,003	97,7	40,000	86,2	30,000	82,8	1,003	97,5	40,000	86,7	30,000	84,5
1,005	97,5	45,000	84,0	35,000	81,3	1,005	97,6	45,000	85,9	35,000	83,6
1,007	97,6	48,000	85,9	40,000	81,0	1,007	97,5	48,000	86,5	40,000	83,0
1,050	97,7	49,000	84,9	45,000	81,4	1,050	97,7	49,000	85,9	45,000	82,3
1,100	97,6	50,000	84,5	48,000	81,4	1,100	97,3	50,000	86,8	48,000	83,1
1,200	97,5	51,000	84,7	50,000	80,7	1,200	96,6	51,000	85,9	50,000	82,8
1,400	96,8	51,800	84,8	51,000	80,6	1,400	96,2	51,800	85,9	51,000	82,6
1,500	96,7	52,000	85,7	52,500	80,1	1,500	96,2	52,000	85,7	52,500	81,4
1,600	96,6	52,200	84,3	53,000	80,5	1,600	95,8	52,200	87,1	53,000	81,3
1,700	96,1	52,500	84,9	55,000	80,6	1,700	95,9	52,500	85,5	55,000	82,1
1,800	96,7	53,000	84,2	60,000	80,0	1,800	95,3	53,000	85,6	60,000	82,3
2,000	95,8	55,000	83,8	65,000	80,3	2,000	94,5	55,000	86,1	65,000	81,8
5,000	92,3	60,000	85,0	70,000	80,5	5,000	91,7	60,000	86,1	70,000	81,6
7,000	88,9	65,000	83,4	75,000	81,5	7,000	90,6	65,000	84,8	75,000	81,1

APÊNDICE H – Sensibilidade obtida para diferentes valores de parâmetro
(Álbum de Brodatz – vizinhança 5 x 5)

LFP-s 45x45		LFP-t 45x45		LFP-g 45x45		LFP-s 50x50		LFP-t 50x50		LFP-g 50x50	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	49,1	2,000	46,5	0,800	62,2	0,100	57,5	2,000	51,8	0,850	68,4
0,200	57,5	4,000	51,8	0,900	62,5	0,200	64,8	4,000	58,4	0,900	68,7
0,300	62,3	5,000	49,5	1,000	64,4	0,300	68,3	5,000	55,1	0,950	69,3
0,400	60,3	5,500	55,8	1,100	67,1	0,400	69,4	5,500	64,8	0,980	71,3
0,500	62,9	5,600	58,3	1,150	65,7	0,500	71,3	5,600	66,3	1,100	74,1
0,600	63,6	5,650	58,6	1,200	65,7	0,550	73,0	5,650	66,3	1,120	74,0
0,700	62,9	5,700	59,0	1,250	64,1	0,580	72,7	5,700	65,9	1,150	73,5
0,710	63,6	5,720	58,7	1,280	64,4	0,600	75,0	5,720	66,0	1,200	71,8
0,720	61,6	5,800	60,5	1,300	65,3	0,630	75,0	5,800	67,9	1,240	71,4
0,725	61,4	6,000	53,9	1,450	62,1	0,680	71,4	6,000	60,2	1,280	71,6
0,750	61,9	10,000	45,7	1,480	61,6	0,700	73,2	10,000	53,8	1,300	71,7
0,800	63,1	15,000	43,9	1,500	64,5	0,710	72,1	15,000	51,8	1,320	72,8
0,900	64,4	20,000	43,8	1,550	64,1	0,720	69,4	20,000	52,0	1,350	72,0
0,950	65,5	25,000	43,2	1,600	62,6	0,725	69,8	25,000	53,0	1,400	70,2
1,000	61,9	30,000	45,0	1,650	65,0	0,750	70,2	30,000	51,7	1,450	69,0
1,001	61,8	35,000	44,9	1,700	64,0	0,800	72,2	35,000	52,3	1,480	69,5
1,003	62,0	40,000	46,0	1,750	61,4	0,900	71,7	40,000	52,1	1,500	70,5
1,005	62,5	45,000	45,9	1,800	59,7	0,950	71,5	45,000	51,8	1,550	69,5
1,007	62,3	48,000	47,4	1,900	57,7	1,000	70,5	48,000	52,8	1,600	69,0
1,050	60,4	49,000	45,9	2,000	58,6	1,001	71,1	49,000	52,1	1,650	70,5
1,100	59,5	50,000	46,1	4,000	47,7	1,003	71,4	50,000	53,0	1,700	69,7
1,200	59,5	51,000	46,5	5,000	41,0	1,005	70,9	51,000	53,3	1,750	67,5
1,400	58,5	51,800	46,5	5,700	44,6	1,007	71,2	51,800	51,6	1,800	67,3
1,500	56,0	52,000	45,4	6,000	43,6	1,050	68,6	52,000	52,5	1,900	66,1
1,600	53,8	52,200	46,8	10,000	45,0	1,100	68,2	52,200	53,0	2,000	66,2
1,700	53,9	52,500	45,9	15,000	44,8	1,200	64,9	52,500	53,2	4,000	51,8
1,800	53,2	53,000	44,5	20,000	44,7	1,400	64,4	53,000	51,9	5,000	51,9
2,000	52,7	55,000	46,0	25,000	46,3	1,500	63,7	55,000	51,9	5,700	50,5
5,000	45,7	60,000	47,0	30,000	47,6	1,600	61,7	60,000	52,6	6,000	51,4
7,000	45,7	65,000	46,4	35,000	45,1	1,700	62,8	65,000	51,6	10,000	53,3
10,000	46,6	70,000	46,9	40,000	46,6	1,800	61,1	70,000	52,3	15,000	49,9

LFP-s 55x55		LFP-t 55x55		LFP-g 55x55		LFP-s 60x60		LFP-t 60x60		LFP-g 60x60	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	61,2	2,000	53,6	0,900	71,8	0,100	67,2	2,000	59,2	0,900	76,8
0,200	68,8	4,000	62,5	1,100	77,7	0,200	72,4	4,000	67,3	1,150	80,1
0,300	73,1	5,000	59,3	1,200	76,3	0,300	77,7	5,000	65,0	1,180	79,4
0,400	76,9	5,500	66,8	1,300	76,2	0,400	77,8	5,500	71,7	1,200	80,5
0,500	75,7	5,600	68,9	1,400	72,0	0,500	79,4	5,600	72,1	1,210	80,8
0,550	75,9	5,650	69,8	1,450	73,9	0,600	80,5	5,650	71,7	1,250	79,5
0,570	75,4	5,700	69,3	1,480	75,0	0,700	80,0	5,700	73,0	1,300	77,7
0,590	77,6	5,720	69,3	1,500	75,1	0,710	79,2	5,720	73,2	1,350	80,5
0,600	78,1	5,780	70,6	1,510	74,5	0,720	78,7	5,750	74,3	1,400	78,2
0,620	78,6	5,800	70,5	1,520	74,6	0,725	79,0	5,780	75,8	1,450	77,9
0,650	77,6	5,900	71,9	1,550	73,6	0,750	79,8	5,800	74,4	1,480	80,1
0,700	74,6	6,000	64,5	1,600	71,1	0,800	79,4	5,850	76,6	1,500	79,5
0,710	76,2	10,000	59,5	1,650	72,1	0,900	81,8	5,900	76,8	1,550	78,1
0,720	75,7	15,000	57,1	1,700	72,3	0,930	82,8	6,000	69,2	1,600	77,6
0,725	74,5	20,000	57,2	1,750	70,5	0,950	82,9	10,000	63,9	1,620	78,0
0,750	76,3	25,000	57,0	1,800	71,4	0,960	81,8	15,000	60,4	1,640	79,3
0,800	77,1	30,000	55,4	1,900	69,6	0,970	82,0	20,000	59,5	1,650	79,9
0,850	76,3	35,000	57,2	2,000	70,0	1,000	81,6	25,000	59,0	1,660	79,7
0,880	77,8	40,000	58,1	4,000	57,4	1,001	82,1	30,000	60,5	1,680	79,5
0,900	78,3	45,000	57,0	5,000	56,4	1,003	82,2	35,000	61,4	1,700	79,4
0,910	79,0	48,000	55,6	5,700	57,0	1,005	81,4	40,000	59,1	1,750	76,6
0,930	78,8	49,000	57,6	6,000	56,7	1,007	81,1	45,000	61,4	1,800	76,2
0,950	76,9	50,000	57,7	10,000	56,2	1,050	78,2	48,000	61,9	1,900	73,7
1,000	75,8	51,000	58,3	15,000	57,7	1,100	78,5	49,000	61,6	2,000	74,1
1,001	76,1	51,800	57,7	20,000	58,4	1,200	75,4	50,000	60,8	4,000	61,6
1,003	75,6	52,000	59,1	25,000	59,0	1,400	75,1	51,000	60,0	5,000	61,2
1,005	75,9	52,200	57,2	30,000	58,8	1,500	75,0	51,800	60,5	5,700	60,5
1,007	75,8	52,500	57,8	35,000	57,0	1,600	73,0	52,000	60,1	6,000	60,4
1,050	74,1	53,000	57,9	40,000	56,1	1,700	70,3	52,200	59,6	10,000	59,5
1,100	73,2	55,000	58,6	45,000	57,2	1,800	73,7	52,500	62,1	15,000	59,6
1,200	71,6	60,000	59,5	48,000	56,2	2,000	70,9	53,000	62,1	20,000	61,3

LFP-s 65x65		LFP-t 65x65		LFP-g 65x65		LFP-s 70x70		LFP-t 70x70		LFP-g 70x70	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	72,8	2,000	64,6	1,350	81,2	0,100	74,9	2,000	67,8	1,400	83,2
0,200	78,2	4,000	69,6	1,400	79,7	0,200	79,0	4,000	73,1	1,480	83,9
0,300	80,5	5,000	70,4	1,450	81,0	0,300	85,1	5,000	71,5	1,490	83,3
0,400	81,2	5,500	75,1	1,480	80,9	0,400	84,9	5,500	77,0	1,500	83,9
0,500	82,4	5,600	79,2	1,500	81,1	0,500	86,6	5,600	78,3	1,550	82,9
0,600	84,1	5,650	77,7	1,550	80,8	0,520	86,4	5,650	79,5	1,600	82,0
0,700	85,1	5,700	78,6	1,600	79,5	0,550	86,8	5,700	80,0	1,650	83,1
0,710	84,8	5,720	78,5	1,640	80,6	0,580	87,4	5,720	80,4	1,700	83,3
0,720	83,8	5,800	78,0	1,650	81,3	0,600	87,6	5,800	80,7	1,750	82,1
0,725	83,7	6,000	72,2	1,660	81,9	0,620	87,6	5,820	81,2	1,800	80,6
0,750	84,2	10,000	65,2	1,700	79,7	0,650	87,6	5,900	80,6	1,900	81,5
0,800	84,3	15,000	62,1	1,750	79,0	0,700	86,3	6,000	74,1	2,000	79,8
0,900	84,9	20,000	64,1	1,800	78,8	0,710	87,3	10,000	72,1	4,000	70,1
0,950	84,1	25,000	64,4	1,900	76,1	0,720	86,4	15,000	69,8	5,000	68,6
1,000	83,9	30,000	65,9	2,000	76,8	0,725	86,1	20,000	69,3	5,700	67,8
1,001	84,1	35,000	63,2	4,000	66,0	0,750	87,2	25,000	68,6	6,000	67,4
1,003	84,0	40,000	65,3	5,000	62,3	0,800	87,1	30,000	69,7	10,000	67,2
1,005	84,1	45,000	65,3	5,700	62,6	0,900	87,3	35,000	68,6	15,000	68,5
1,007	84,5	48,000	64,0	6,000	62,1	0,950	87,4	40,000	71,1	20,000	69,8
1,050	82,0	49,000	65,8	10,000	63,4	1,000	86,3	45,000	69,3	25,000	70,2
1,100	81,9	50,000	65,6	15,000	64,5	1,001	86,2	48,000	69,8	30,000	69,8
1,200	81,8	51,000	63,9	20,000	64,0	1,003	86,2	49,000	69,8	35,000	69,4
1,400	80,5	51,800	65,0	25,000	65,1	1,005	85,7	50,000	70,6	40,000	69,5
1,500	78,2	52,000	65,0	30,000	64,7	1,007	85,7	51,000	70,6	45,000	67,9
1,600	78,1	52,200	64,1	35,000	65,4	1,050	84,1	51,800	69,5	48,000	69,5
1,700	77,5	52,500	64,4	40,000	64,2	1,100	84,1	52,000	69,5	50,000	68,3
1,800	76,8	53,000	65,8	45,000	64,4	1,200	82,2	52,200	69,3	52,000	67,5
2,000	76,1	55,000	65,3	48,000	63,7	1,400	83,0	52,500	69,3	55,000	68,6
5,000	68,8	60,000	65,2	50,000	64,3	1,500	82,6	53,000	70,4	60,000	68,8
7,000	66,6	65,000	65,8	52,000	62,3	1,600	81,2	55,000	70,1	65,000	69,1
10,000	67,5	70,000	65,9	55,000	62,0	1,700	80,8	60,000	69,4	70,000	68,0

LFP-s 75x75		LFP-t 75x75		LFP-g 75x75		LFP-s 80x80		LFP-t 80x80		LFP-g 80x80	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	79,7	2,000	70,5	1,350	86,3	0,100	81,5	2,000	75,8	1,100	90,4
0,200	85,7	4,000	77,1	1,400	86,3	0,200	85,8	4,000	81,6	1,200	89,8
0,300	88,9	5,000	74,9	1,450	85,8	0,300	89,3	5,000	78,8	1,300	89,6
0,400	88,3	5,500	82,2	1,480	86,0	0,400	89,3	5,500	83,9	1,400	87,7
0,500	89,9	5,600	83,2	1,500	87,2	0,500	89,1	5,600	85,0	1,500	89,5
0,600	89,8	5,650	82,9	1,550	86,2	0,600	89,3	5,650	85,8	1,600	87,4
0,650	89,6	5,700	84,1	1,600	84,9	0,700	88,8	5,700	86,8	1,650	89,7
0,680	90,0	5,720	84,7	1,650	86,0	0,710	89,4	5,720	86,9	1,660	89,2
0,700	90,6	5,800	85,1	1,700	85,9	0,720	88,7	5,800	86,9	1,680	90,4
0,710	89,5	6,000	78,8	1,750	86,3	0,725	89,0	6,000	82,9	1,700	89,8
0,720	89,4	10,000	74,5	1,800	84,9	0,750	88,8	10,000	78,1	1,720	88,3
0,725	89,5	15,000	74,8	1,900	84,0	0,800	88,1	15,000	76,5	1,740	87,7
0,750	89,8	20,000	72,0	2,000	83,0	0,850	90,6	20,000	75,4	1,750	87,9
0,800	89,6	25,000	72,3	4,000	75,2	0,880	91,4	25,000	76,0	1,800	88,5
0,900	90,3	30,000	73,4	5,000	73,3	0,900	91,8	30,000	77,1	1,900	86,4
0,950	89,7	35,000	72,7	5,700	72,7	0,910	92,0	35,000	75,9	2,000	86,5
1,000	90,2	40,000	72,5	6,000	74,2	0,930	91,8	40,000	76,0	4,000	76,6
1,001	90,2	45,000	73,0	10,000	73,0	0,950	91,1	45,000	76,3	5,000	75,1
1,003	89,5	48,000	72,3	15,000	73,2	1,000	91,3	48,000	74,6	5,700	74,4
1,005	89,9	49,000	73,4	20,000	73,2	1,001	90,7	49,000	75,9	5,800	75,2
1,007	89,5	50,000	73,7	25,000	73,4	1,003	90,7	50,000	76,1	6,000	75,6
1,050	88,9	51,000	74,8	30,000	73,4	1,005	90,9	51,000	76,8	10,000	75,2
1,100	88,2	51,800	72,2	35,000	71,7	1,007	90,6	51,800	77,1	15,000	75,5
1,200	87,3	52,000	74,1	40,000	72,1	1,050	90,5	52,000	77,3	20,000	74,8
1,400	87,2	52,200	74,7	45,000	71,5	1,100	89,5	52,200	76,5	25,000	74,8
1,500	86,6	52,500	74,8	48,000	71,8	1,200	87,5	52,500	76,5	30,000	74,1
1,600	85,0	53,000	74,3	50,000	71,4	1,400	87,2	53,000	76,4	35,000	74,0
1,700	83,8	55,000	72,4	52,000	72,2	1,500	87,8	55,000	77,1	40,000	74,1
1,800	84,1	60,000	74,5	55,000	70,6	1,600	88,6	60,000	76,8	45,000	73,2
2,000	84,5	65,000	75,4	60,000	70,8	1,700	86,6	65,000	76,7	48,000	74,3
5,000	78,4	70,000	73,7	65,000	72,4	1,800	86,8	70,000	77,2	50,000	75,0

LFP-s 85x85		LFP-t 85x85		LFP-g 85x85		LFP-s 90 x90		LFP-t 90x90		LFP-g 90x90	
Beta	S (%)	Delta	S (%)	Sigma	S (%)	Beta	S (%)	Delta	S (%)	Sigma	S (%)
0,100	86,2	2,000	78,3	1,100	93,7	0,100	88,8	2,000	79,5	1,600	91,7
0,200	90,5	4,000	83,2	1,200	92,0	0,200	92,3	4,000	85,8	1,650	92,8
0,300	92,5	5,000	81,9	1,300	91,7	0,300	93,4	5,000	84,7	1,700	92,3
0,400	93,2	5,500	87,7	1,400	90,9	0,400	93,6	5,500	89,8	1,750	91,8
0,500	93,9	5,600	87,9	1,500	91,5	0,500	94,6	5,600	90,6	1,800	91,6
0,600	94,5	5,650	88,6	1,600	90,8	0,600	95,8	5,650	90,8	1,900	90,8
0,700	94,6	5,700	88,6	1,650	90,5	0,700	95,2	5,700	91,5	2,000	90,7
0,710	94,6	5,720	89,2	1,660	90,7	0,710	94,8	5,720	91,4	4,000	83,5
0,720	93,9	5,800	89,7	1,680	91,2	0,720	94,4	5,800	91,9	5,000	80,9
0,725	94,2	6,000	85,0	1,700	91,0	0,725	94,8	6,000	87,4	5,700	82,2
0,750	94,0	10,000	81,1	1,720	90,4	0,750	94,6	10,000	85,0	5,800	83,2
0,800	95,4	15,000	80,2	1,740	90,2	0,800	94,1	15,000	83,2	6,000	82,4
0,850	95,3	20,000	81,7	1,750	89,8	0,900	95,0	20,000	82,8	10,000	82,1
0,880	95,6	25,000	80,0	1,800	90,2	0,950	95,0	25,000	80,8	15,000	80,2
0,900	95,6	30,000	80,1	1,900	87,6	1,000	95,1	30,000	81,2	20,000	80,3
0,910	95,7	35,000	78,6	2,000	87,6	1,001	95,2	35,000	83,3	25,000	81,3
0,930	95,7	40,000	80,5	4,000	81,4	1,003	95,1	40,000	82,9	30,000	79,8
0,950	95,1	45,000	80,1	5,000	80,3	1,005	95,6	45,000	82,5	35,000	80,8
1,000	94,6	48,000	79,2	5,700	78,6	1,007	95,4	48,000	82,8	40,000	79,8
1,001	94,5	49,000	79,8	5,800	78,6	1,050	94,9	49,000	82,2	45,000	79,1
1,003	94,9	50,000	80,2	6,000	79,2	1,100	93,9	50,000	81,4	48,000	79,2
1,005	95,0	51,000	80,4	10,000	80,5	1,200	93,7	51,000	81,8	50,000	79,9
1,007	95,0	51,800	79,7	15,000	78,7	1,400	93,0	51,800	81,9	51,000	79,3
1,050	93,6	52,000	80,8	20,000	79,9	1,500	93,2	52,000	81,7	52,500	80,3
1,100	92,9	52,200	79,5	25,000	78,7	1,600	92,4	52,200	81,8	53,000	79,5
1,200	92,2	52,500	80,0	30,000	79,3	1,700	91,9	52,500	81,5	55,000	79,1
1,400	92,1	53,000	80,6	35,000	77,9	1,800	91,0	53,000	81,8	60,000	77,7
1,500	91,7	55,000	80,2	40,000	78,6	2,000	91,4	55,000	82,5	65,000	78,7
1,600	91,8	60,000	79,6	45,000	77,7	5,000	87,7	60,000	82,3	70,000	79,5
1,700	90,8	65,000	80,7	48,000	76,8	7,000	86,4	65,000	82,0	75,000	78,5
1,800	90,6	70,000	81,3	50,000	77,1	10,000	84,3	70,000	82,5	80,000	78,8

APÊNDICE I – Sensibilidade obtida para diferentes valores de parâmetro
(Imagens de vermiculita – Iluminação Tipo 1)

LFP-s 100x100		LFP-t 100x100		LFP-g 100x100		LFP-s 160x160		LFP-t 160x160		LFP-g 160x160	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,200	47,7	5,600	48,9	1,150	49,4	0,200	64,4	5,720	66,8	1,150	71,9
0,300	55,3	5,650	46,7	1,200	48,6	0,300	74,9	5,800	66,1	1,200	69,8
0,400	58,8	5,700	47,6	1,300	46,7	0,400	80,6	6,000	54,6	1,300	71,4
0,500	56,4	5,720	47,6	1,400	48,8	0,500	80,8	10,000	55,3	1,400	69,1
0,580	60,1	5,800	48,1	1,500	47,5	0,580	81,1	15,000	65,6	1,500	67,8
0,595	60,2	6,000	38,0	1,550	48,6	0,595	80,3	20,000	66,5	1,550	71,6
0,600	59,7	10,000	40,6	1,580	49,6	0,600	80,1	25,000	72,6	1,580	70,3
0,620	59,3	15,000	45,7	1,600	50,3	0,620	80,4	30,000	73,1	1,600	70,7
0,680	59,4	20,000	48,8	1,620	51,2	0,680	79,4	35,000	71,7	1,620	70,6
0,690	60,5	25,000	50,1	1,630	48,5	0,690	79,1	38,000	72,4	1,630	69,2
0,698	59,7	30,000	48,8	1,650	49,3	0,698	79,5	39,500	72,1	1,650	70,6
0,700	59,7	35,000	52,4	1,660	49,6	0,700	79,6	39,800	71,4	1,660	70,8
0,710	60,4	38,000	48,4	1,680	49,2	0,710	80,6	40,000	72,3	1,680	71,2
0,713	59,9	39,500	50,6	1,700	49,8	0,713	79,7	40,200	72,1	1,700	71,6
0,713	59,8	39,800	50,5	1,720	48,1	0,713	79,1	41,000	72,6	1,720	70,9
0,712	59,7	40,000	50,6	1,740	50,2	0,712	80,6	43,000	70,9	1,740	69,8
0,713	59,3	40,200	50,4	1,750	49,9	0,713	79,2	45,000	69,5	1,750	69,1
0,714	60,1	41,000	50,6	1,800	49,8	0,714	79,3	48,000	71,9	1,800	68,9
0,718	58,5	43,000	50,3	1,900	49,1	0,718	79,0	49,000	71,2	1,900	69,8
0,720	59,1	45,000	50,6	2,000	49,3	0,720	78,8	50,000	71,4	2,000	67,6
0,721	58,0	48,000	48,1	4,000	47,1	0,721	79,1	51,000	71,4	4,000	66,9
0,722	59,6	49,000	49,3	5,000	50,4	0,722	78,7	51,800	71,4	5,000	67,6
0,722	59,1	50,000	49,0	5,700	53,9	0,722	78,3	52,000	70,3	5,700	71,8
0,723	60,2	51,000	48,8	5,800	51,9	0,723	79,6	52,200	71,3	5,800	72,6
0,724	59,3	51,800	47,7	6,000	52,0	0,724	79,4	52,500	70,7	6,000	70,3
0,725	60,3	52,000	48,6	9,800	53,4	0,725	79,0	52,600	70,5	9,800	73,3
0,726	60,9	52,200	50,3	10,000	52,1	0,726	78,9	52,800	70,2	10,000	72,6
0,727	59,4	52,500	48,4	10,200	49,1	0,727	79,9	52,900	70,4	10,200	72,6
0,730	59,3	52,600	49,8	12,000	52,9	0,730	79,2	53,000	70,2	12,000	72,7
0,735	60,3	52,800	49,5	13,000	53,6	0,735	79,5	53,200	73,0	13,000	73,1
0,740	59,8	52,900	49,1	14,800	51,3	0,740	79,6	54,000	70,1	14,800	71,3
0,745	60,8	53,000	48,9	14,950	51,6	0,745	79,7	54,500	70,8	14,950	71,6
0,750	58,7	53,200	51,3	15,000	49,9	0,750	79,3	55,000	69,0	15,000	72,1
0,800	58,8	54,000	49,9	15,100	50,8	0,800	80,3	60,000	69,3	15,100	72,1
0,810	58,4	54,500	50,9	15,200	50,8	0,810	79,6	65,000	71,6	15,200	72,7

LFP-s 170x170		LFP-t 170x170		LFP-g 170x170		LFP-s 175x175		LFP-t 175x175		LFP-g 175x175	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,200	68,4	5,600	70,3	1,150	73,3	0,200	71,1	15,000	69,7	1,550	74,5
0,300	78,4	5,650	69,4	1,200	74,4	0,300	80,3	20,000	73,9	1,580	74,1
0,400	82,8	5,700	69,7	1,300	74,4	0,400	84,3	25,000	74,5	1,600	74,8
0,500	83,9	5,720	70,2	1,400	73,4	0,500	85,2	30,000	76,9	1,620	74,1
0,580	83,4	5,800	70,1	1,500	75,4	0,600	85,3	35,000	77,4	1,630	74,7
0,595	83,8	6,000	57,8	1,550	73,9	0,700	85,8	38,000	75,3	1,650	75,7
0,600	82,4	10,000	61,9	1,580	75,9	0,710	84,4	39,500	75,5	1,660	75,6
0,620	83,0	15,000	70,3	1,600	74,6	0,720	85,3	39,800	76,2	1,680	75,3
0,680	81,9	20,000	70,4	1,620	74,6	0,721	84,7	40,000	74,7	1,700	75,6
0,690	80,4	25,000	74,1	1,630	74,0	0,722	84,8	40,200	75,4	1,720	74,4
0,698	82,1	30,000	75,1	1,650	74,8	0,723	85,4	41,000	76,2	1,740	75,0
0,700	82,8	35,000	75,1	1,660	74,8	0,724	85,5	43,000	77,6	1,750	75,3
0,710	81,9	38,000	75,7	1,680	74,9	0,725	85,3	45,000	75,2	1,800	76,0
0,713	81,6	39,500	75,4	1,700	74,1	0,726	84,9	48,000	75,1	1,900	74,9
0,713	81,8	39,800	74,8	1,720	74,1	0,727	85,1	49,000	77,1	2,000	76,0
0,712	82,3	40,000	74,8	1,740	73,8	0,730	84,6	50,000	75,0	4,000	70,5
0,713	81,7	40,200	75,9	1,750	73,5	0,735	84,2	51,000	75,7	5,000	72,8
0,714	82,9	41,000	75,4	1,800	73,7	0,740	84,1	51,800	76,5	5,700	77,2
0,718	82,9	43,000	73,9	1,900	73,4	0,745	84,3	52,000	74,9	5,800	76,1
0,720	82,1	45,000	75,4	2,000	73,0	0,750	84,3	52,200	75,9	6,000	77,3
0,721	81,9	48,000	74,8	4,000	69,5	0,800	84,3	52,500	76,3	10,000	78,3
0,722	83,3	49,000	73,6	5,000	72,4	0,850	84,3	52,600	76,0	12,000	78,9
0,722	83,3	50,000	74,6	5,700	76,1	0,880	84,9	52,800	76,1	13,000	76,8
0,723	83,2	51,000	74,6	5,800	74,9	0,900	84,3	52,900	76,6	14,800	76,6
0,724	83,0	51,800	73,6	6,000	77,6	0,910	84,4	53,000	75,8	14,950	76,7
0,725	83,1	52,000	75,3	9,800	76,3	0,930	84,2	53,200	76,4	15,000	77,8
0,726	82,7	52,200	75,1	10,000	77,8	0,950	83,2	54,000	76,8	15,100	75,3
0,727	83,0	52,500	74,7	10,200	77,2	0,980	83,9	54,500	76,9	15,500	76,4
0,730	83,0	52,600	76,9	12,000	75,2	0,990	84,5	55,000	77,3	16,000	76,4
0,735	83,8	52,800	73,6	13,000	75,4	0,995	83,6	60,000	75,5	17,000	74,7
0,740	83,3	52,900	73,6	14,800	75,4	1,000	83,2	65,000	72,6	18,000	75,4
0,745	82,7	53,000	75,3	14,950	75,0	1,001	84,7	70,000	75,4	19,500	75,1
0,750	82,8	53,200	75,1	15,000	75,9	1,003	84,6	75,000	74,2	19,800	75,2
0,800	83,3	54,000	73,9	15,100	75,9	1,005	84,6	77,000	73,7	20,000	75,1
0,810	82,4	54,500	73,8	15,200	76,6	1,007	84,6	78,000	75,2	20,200	74,6

LFP-s 180x180		LFP-t 180x180		LFP-g 180x180		LFP-s 185x185		LFP-t 185x185		LFP-g 185x185	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,200	73,0	5,600	70,6	1,000	75,6	0,200	70,6	5,600	70,3	1,100	75,8
0,300	81,6	5,650	68,3	1,100	75,1	0,300	81,4	5,650	68,9	1,150	75,9
0,400	84,0	5,700	70,6	1,150	76,4	0,400	85,7	5,700	69,7	1,200	75,7
0,500	86,6	5,720	70,6	1,200	75,8	0,500	87,2	5,720	71,9	1,300	76,4
0,600	86,8	5,800	70,3	1,300	76,7	0,600	86,0	5,800	70,3	1,400	75,9
0,700	85,9	6,000	56,6	1,400	75,9	0,700	85,8	6,000	56,6	1,500	74,4
0,710	86,2	10,000	63,0	1,500	76,4	0,710	85,6	10,000	59,7	1,550	74,5
0,720	86,4	15,000	72,9	1,550	75,8	0,720	86,0	15,000	68,0	1,580	75,1
0,721	86,6	20,000	72,9	1,580	77,1	0,721	85,3	20,000	73,3	1,600	76,3
0,722	86,1	25,000	74,5	1,600	75,1	0,722	85,4	25,000	74,4	1,620	75,7
0,723	85,7	30,000	76,6	1,620	77,6	0,723	85,6	30,000	76,8	1,630	74,7
0,724	86,0	35,000	76,6	1,630	77,1	0,724	85,9	35,000	77,7	1,650	74,1
0,725	86,3	38,000	76,2	1,650	75,7	0,725	85,8	38,000	75,9	1,660	74,7
0,726	86,8	39,500	77,6	1,660	75,9	0,726	86,1	39,500	76,3	1,680	75,9
0,727	86,0	39,800	77,1	1,680	75,6	0,727	86,3	39,800	75,4	1,700	76,3
0,730	85,4	40,000	77,9	1,700	75,4	0,730	85,8	40,000	76,1	1,720	74,9
0,735	86,1	40,200	78,6	1,720	74,6	0,735	85,8	40,200	76,4	1,740	74,7
0,740	86,8	41,000	77,9	1,740	76,2	0,740	84,9	41,000	77,7	1,750	74,1
0,745	86,9	43,000	77,2	1,750	75,9	0,745	85,6	43,000	77,7	1,800	74,6
0,750	87,1	45,000	76,9	1,800	75,3	0,750	85,4	45,000	76,9	1,900	76,1
0,800	87,2	48,000	77,1	1,900	76,1	0,800	84,4	48,000	75,8	2,000	73,6
0,850	87,0	49,000	75,4	2,000	74,6	0,850	84,5	49,000	76,7	4,000	71,9
0,880	85,7	50,000	75,3	4,000	69,9	0,880	84,8	50,000	75,5	5,000	72,9
0,900	85,8	51,000	74,2	5,000	73,2	0,900	83,8	51,000	75,6	5,700	76,4
0,910	85,4	51,800	75,3	5,700	77,4	0,910	85,2	51,800	75,2	5,800	77,8
0,930	86,1	52,000	74,8	5,800	77,8	0,930	83,4	52,000	75,6	6,000	77,5
0,950	85,0	52,200	75,6	6,000	76,1	0,950	84,9	52,200	76,9	10,000	79,8
1,000	84,6	52,500	76,1	10,000	78,3	1,000	85,2	52,500	76,3	15,000	77,9
1,001	84,8	52,600	75,5	15,000	77,3	1,001	85,5	52,600	75,6	18,000	74,6
1,003	83,9	52,800	74,6	18,000	76,1	1,003	84,9	52,800	76,7	19,500	76,5
1,005	84,0	52,900	74,9	19,500	75,4	1,005	85,6	52,900	76,7	19,800	74,9
1,007	84,6	53,000	76,4	19,800	76,3	1,007	84,8	53,000	76,6	20,000	76,1
1,050	83,9	53,200	75,9	20,000	73,7	1,050	84,4	53,200	77,1	20,200	75,3
1,100	83,9	54,000	73,6	20,200	74,8	1,100	84,1	54,000	74,8	20,500	74,8
1,200	84,1	54,500	75,4	20,500	75,5	1,200	83,5	54,500	75,3	22,000	72,8

LFP-s 190x190		LFP-t 190x190		LFP-g 190x190		LFP-s 195x195		LFP-t 195x195		LFP-g 195x195	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,200	73,1	5,600	75,4	1,500	78,6	0,200	74,9	6,000	60,8	1,200	79,4
0,300	82,7	5,650	72,2	1,550	78,7	0,300	85,3	10,000	61,6	1,300	79,3
0,400	86,6	5,700	73,6	1,580	79,5	0,400	87,4	15,000	74,6	1,400	77,6
0,500	87,8	5,720	74,3	1,600	78,1	0,500	89,7	20,000	76,9	1,500	77,3
0,580	87,6	5,800	75,7	1,620	77,6	0,580	89,1	25,000	79,9	1,550	77,5
0,595	88,6	6,000	59,3	1,630	78,0	0,595	88,6	30,000	80,6	1,580	78,5
0,600	89,7	10,000	63,6	1,650	77,9	0,600	88,3	35,000	79,7	1,600	77,9
0,620	88,4	15,000	71,3	1,660	78,1	0,620	88,9	38,000	80,4	1,620	77,9
0,680	87,8	20,000	75,3	1,680	79,0	0,680	87,2	39,500	81,1	1,630	79,9
0,690	87,6	25,000	79,0	1,700	78,1	0,690	88,1	39,800	80,1	1,650	79,0
0,698	87,6	30,000	81,2	1,720	77,4	0,698	87,7	40,000	80,9	1,660	79,6
0,700	87,1	35,000	80,4	1,740	79,5	0,700	87,6	40,200	80,3	1,680	79,2
0,710	86,7	38,000	81,4	1,750	79,2	0,710	87,9	41,000	80,5	1,700	78,4
0,712	86,8	39,500	81,7	1,800	78,6	0,712	88,4	43,000	80,2	1,720	77,3
0,718	87,3	39,800	80,3	1,900	78,3	0,718	87,3	45,000	79,8	1,740	78,0
0,720	87,6	40,000	80,6	2,000	80,8	0,720	88,0	48,000	80,8	1,750	77,4
0,721	86,8	40,200	80,9	4,000	74,4	0,721	88,1	49,000	80,0	1,800	77,5
0,722	86,7	41,000	81,1	5,000	75,1	0,722	88,1	50,000	79,8	1,900	78,1
0,722	86,4	43,000	80,6	5,700	79,8	0,722	88,0	51,000	80,3	2,000	78,2
0,723	86,8	45,000	81,3	5,800	79,6	0,723	87,7	51,800	80,9	4,000	74,5
0,724	86,8	48,000	79,8	6,000	81,3	0,724	88,1	52,000	79,8	5,000	77,1
0,725	86,7	49,000	80,4	10,000	79,3	0,725	88,5	52,200	79,4	5,700	78,6
0,726	86,5	50,000	80,7	12,000	80,6	0,726	87,7	52,500	80,1	5,800	80,3
0,727	86,7	51,000	80,5	13,000	82,7	0,727	88,3	52,600	80,1	6,000	80,8
0,730	87,1	51,800	79,3	14,800	81,1	0,730	87,8	52,800	80,4	10,000	82,1
0,735	86,4	52,000	79,6	14,950	81,0	0,735	88,0	52,900	81,4	12,000	81,6
0,740	86,5	52,200	79,5	15,000	81,5	0,740	87,1	53,000	80,8	13,000	81,6
0,745	86,4	52,500	80,8	15,100	81,5	0,745	87,8	53,200	81,1	14,800	81,4
0,750	86,8	52,600	80,3	15,500	80,5	0,750	88,1	54,000	78,8	14,950	80,7
0,800	87,2	52,800	80,2	16,000	78,9	0,800	88,4	54,500	80,1	15,000	80,8
0,850	86,5	52,900	80,4	17,000	80,8	0,850	88,4	55,000	80,6	15,100	80,9
0,880	87,2	53,000	79,9	18,000	79,3	0,880	88,5	60,000	79,3	15,500	80,8
0,900	85,9	53,200	79,2	19,500	79,6	0,900	89,0	65,000	78,0	16,000	79,6
0,910	85,4	54,000	79,9	19,800	80,2	0,910	88,2	70,000	77,4	17,000	80,6
0,930	86,4	54,500	80,6	20,000	79,3	0,930	88,4	75,000	77,7	18,000	81,4

LFP-s 200x200		LFP-t 200x200		LFP-g 200x200		LFP-s 220x220		LFP-t 220x220		LFP-g 220x220	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,200	75,1	5,600	77,9	1,150	81,9	0,200	80,1	20,000	80,7	1,150	85,2
0,300	85,9	5,650	75,1	1,200	81,3	0,300	88,1	25,000	84,3	1,200	85,3
0,400	89,9	5,700	76,3	1,300	81,8	0,400	91,9	30,000	87,2	1,300	85,5
0,500	90,4	5,720	77,6	1,400	82,6	0,500	92,5	35,000	85,7	1,400	85,6
0,550	89,6	5,800	78,3	1,500	80,7	0,580	91,8	38,000	86,1	1,500	85,4
0,578	90,3	6,000	64,1	1,550	81,7	0,595	91,6	39,500	85,1	1,550	84,3
0,580	90,4	10,000	67,4	1,580	82,4	0,600	92,4	39,800	85,5	1,580	85,9
0,582	90,1	15,000	77,9	1,600	81,4	0,620	92,0	40,000	85,3	1,600	85,7
0,585	89,8	20,000	79,6	1,620	82,3	0,680	91,1	40,200	85,4	1,620	85,3
0,595	90,3	25,000	80,9	1,630	81,8	0,690	91,4	41,000	85,3	1,630	84,9
0,600	88,9	30,000	83,3	1,650	82,1	0,698	91,2	43,000	85,1	1,650	86,6
0,620	89,8	35,000	82,8	1,660	81,9	0,700	91,1	45,000	85,3	1,660	85,5
0,680	88,4	38,000	82,1	1,680	83,1	0,710	90,7	48,000	84,4	1,680	85,6
0,690	89,3	39,500	82,1	1,700	82,4	0,713	90,9	49,000	85,3	1,700	85,4
0,698	89,0	39,800	81,1	1,720	83,4	0,713	91,4	50,000	84,8	1,720	86,0
0,700	88,6	40,000	81,8	1,740	80,7	0,712	91,4	51,000	84,8	1,740	85,8
0,710	89,2	40,200	83,2	1,750	81,0	0,713	91,3	51,800	84,2	1,750	85,5
0,713	88,6	41,000	83,1	1,800	80,9	0,714	90,9	52,000	85,3	1,800	85,1
0,713	88,9	43,000	80,9	1,900	81,5	0,718	91,3	52,200	86,1	1,900	83,3
0,712	88,6	45,000	81,3	2,000	81,5	0,720	91,7	52,500	85,4	2,000	84,7
0,800	89,1	48,000	81,4	4,000	77,4	0,721	91,8	52,600	85,2	4,000	80,1
0,810	90,4	49,000	82,4	5,000	79,2	0,722	91,6	52,800	84,8	5,000	83,6
0,820	89,8	50,000	81,6	5,700	82,4	0,722	91,9	52,900	84,9	5,700	85,8
0,850	89,5	51,000	80,3	5,800	83,6	0,723	92,6	53,000	84,5	5,800	84,9
0,880	88,8	51,800	81,3	6,000	82,3	0,724	92,1	53,200	85,4	6,000	84,0
0,900	88,8	52,000	80,6	9,800	82,1	0,725	91,9	54,000	85,3	9,800	86,0
0,910	88,8	52,200	82,1	10,000	83,3	0,726	91,4	54,500	86,1	10,000	85,2
0,930	88,3	52,500	81,3	10,200	83,1	0,727	91,3	55,000	83,3	10,200	85,6
0,950	87,9	52,600	81,4	12,000	82,6	0,730	91,8	60,000	83,2	12,000	86,2
0,960	87,4	52,800	82,0	13,000	82,3	0,735	91,6	65,000	84,3	13,000	85,8
0,970	87,8	52,900	81,4	14,800	81,2	0,740	92,0	70,000	84,6	14,800	86,5
0,975	88,8	53,000	82,0	14,950	81,2	0,745	91,9	75,000	84,3	14,950	84,2
0,980	88,4	53,200	80,6	15,000	80,6	0,750	91,7	77,000	83,0	15,000	85,4
0,983	88,7	54,000	81,2	15,100	81,8	0,800	91,6	78,000	82,3	15,100	85,3
0,986	89,4	54,500	82,2	15,200	80,8	0,810	92,2	79,500	82,5	15,200	85,2

LFP-s 250x250		LFP-t 250x250		LFP-g 250x250		LFP-s 300x300		LFP-t 300x300		LFP-g 300x300	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,200	84,3	5,600	83,3	1,150	87,3	0,712	97,9	5,600	89,8	1,150	93,3
0,300	91,2	5,650	81,4	1,200	88,6	0,713	98,0	5,650	88,3	1,200	92,4
0,400	94,6	5,700	81,9	1,300	87,8	0,714	97,9	5,700	89,3	1,300	92,4
0,500	94,9	5,720	83,4	1,400	88,1	0,718	97,6	5,720	89,8	1,400	92,7
0,580	94,1	5,800	83,8	1,500	87,8	0,720	97,8	5,800	90,2	1,500	91,5
0,595	94,1	6,000	70,9	1,550	87,5	0,721	97,9	6,000	77,5	1,550	92,8
0,600	94,3	10,000	71,9	1,580	87,6	0,722	97,9	10,000	80,9	1,580	91,8
0,620	94,3	15,000	83,5	1,600	87,6	0,722	98,1	15,000	82,8	1,600	92,4
0,680	93,6	20,000	87,1	1,620	87,6	0,723	98,1	20,000	86,6	1,620	91,8
0,690	94,3	25,000	85,6	1,630	87,8	0,724	97,9	25,000	91,0	1,630	92,3
0,698	94,8	30,000	87,6	1,650	87,4	0,725	97,9	30,000	93,2	1,650	92,1
0,700	94,2	35,000	87,6	1,660	88,2	0,726	97,4	35,000	93,1	1,660	92,3
0,710	94,0	38,000	86,9	1,680	86,8	0,727	97,8	38,000	92,4	1,680	92,3
0,713	94,4	39,500	87,5	1,700	86,6	0,730	97,9	39,500	92,1	1,700	92,3
0,713	94,4	39,800	88,4	1,720	86,3	0,735	97,7	39,800	92,0	1,720	92,3
0,712	94,2	40,000	87,4	1,740	87,3	0,740	97,4	40,000	92,6	1,740	92,2
0,713	94,3	40,200	87,9	1,750	85,9	0,745	97,6	40,200	91,7	1,750	92,3
0,714	94,6	41,000	88,9	1,800	86,6	0,750	97,8	41,000	93,0	1,800	91,0
0,718	94,3	43,000	86,9	1,900	87,4	0,800	97,8	43,000	92,9	1,900	91,7
0,720	94,1	45,000	86,6	2,000	86,9	0,810	97,9	45,000	92,1	2,000	91,6
0,721	94,1	48,000	86,8	4,000	82,1	0,820	98,3	48,000	92,3	4,000	90,4
0,722	94,3	49,000	86,7	5,000	83,1	0,850	98,0	49,000	92,4	5,000	89,3
0,722	94,2	50,000	87,2	5,700	87,6	0,880	97,4	50,000	92,6	5,700	88,4
0,723	93,8	51,000	87,5	5,800	88,3	0,900	97,6	51,000	91,9	5,800	87,9
0,724	93,4	51,800	86,6	6,000	88,8	0,910	97,8	51,800	92,1	6,000	89,1
0,725	93,7	52,000	86,4	9,800	88,8	0,930	97,8	52,000	91,9	9,800	93,6
0,726	93,9	52,200	86,9	10,000	89,3	0,950	97,5	52,200	91,7	10,000	92,1
0,727	93,3	52,500	88,3	10,200	88,8	0,960	97,7	52,500	92,1	10,200	93,0
0,730	93,8	52,600	86,9	12,000	89,0	0,970	97,5	52,600	91,8	12,000	92,7
0,735	93,9	52,800	87,6	13,000	88,1	0,975	97,6	52,800	92,1	13,000	92,4
0,740	93,3	52,900	87,1	14,800	88,8	0,980	97,6	52,900	91,8	14,800	92,1
0,745	93,8	53,000	86,9	14,950	86,8	0,983	97,6	53,000	91,8	14,950	91,9
0,750	93,8	53,200	86,9	15,000	86,9	0,986	97,6	53,200	91,6	15,000	93,1
0,800	94,1	54,000	86,7	15,100	87,1	0,988	97,6	54,000	91,5	15,100	92,4
0,810	94,6	54,500	87,4	15,200	85,7	0,989	97,6	54,500	91,1	15,200	92,4

APÊNDICE J – Sensibilidade obtida para diferentes valores de parâmetro
(Imagens de vermiculita – Iluminação Tipo 2)

LFP-s 100x100		LFP-t 100x100		LFP-g 100x100		LFP-s 160x160		LFP-t 160x160		LFP-g 160x160	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	42,8	5,500	40,7	1,680	47,1	0,100	61,8	5,500	58,3	1,740	68,8
0,200	46,4	5,600	43,9	1,700	48,0	0,200	69,6	5,600	66,1	1,750	68,1
0,300	53,0	5,650	42,4	1,720	46,8	0,300	79,3	5,650	63,6	1,800	68,6
0,400	55,6	5,700	44,3	1,740	46,7	0,400	82,0	5,700	63,8	1,900	69,5
0,500	56,5	5,720	42,7	1,750	46,4	0,500	84,5	5,720	64,9	2,000	68,8
0,580	56,6	5,800	43,4	1,800	46,0	0,580	83,4	5,800	66,6	4,000	67,6
0,595	57,3	6,000	35,2	1,900	48,0	0,595	82,7	6,000	51,3	5,000	64,7
0,600	58,2	10,000	38,8	2,000	47,4	0,600	83,0	10,000	54,9	5,700	64,4
0,620	59,4	15,000	40,7	4,000	45,5	0,620	84,2	15,000	58,5	5,800	64,5
0,680	57,9	20,000	45,9	5,000	45,5	0,680	83,3	20,000	65,3	6,000	65,6
0,690	57,4	25,000	47,8	5,700	47,6	0,690	83,3	25,000	69,9	9,800	70,9
0,698	57,6	30,000	49,7	5,800	48,9	0,698	83,8	30,000	70,6	10,000	71,2
0,700	58,5	35,000	48,1	6,000	48,0	0,700	83,6	35,000	71,9	10,200	71,9
0,710	57,8	38,000	49,1	9,800	50,3	0,710	83,8	38,000	70,9	12,000	72,7
0,713	57,4	39,500	47,8	10,000	51,8	0,713	83,4	39,500	70,1	13,000	71,5
0,713	57,3	39,800	50,6	10,200	50,9	0,713	83,5	39,800	69,6	14,800	71,3
0,712	58,0	40,000	50,5	12,000	50,5	0,712	83,4	40,000	72,3	14,950	70,7
0,713	57,9	40,200	48,8	13,000	49,9	0,713	83,0	40,200	71,3	15,000	70,7
0,714	58,2	41,000	48,6	14,800	50,7	0,714	82,9	41,000	70,9	15,100	71,1
0,718	58,3	43,000	50,1	14,950	49,8	0,718	83,9	43,000	71,8	15,200	71,9
0,720	57,2	45,000	48,3	15,000	52,7	0,720	84,2	45,000	71,8	15,300	71,7
0,721	57,1	48,000	51,4	15,100	50,6	0,721	84,4	48,000	70,8	15,500	71,3
0,722	57,4	49,000	50,1	15,200	52,4	0,722	84,7	49,000	70,3	16,000	72,0
0,722	57,8	50,000	50,4	15,300	50,5	0,722	84,8	50,000	70,7	17,000	71,9
0,723	58,5	51,000	49,8	15,500	49,6	0,723	84,1	51,000	68,7	17,200	70,3
0,724	58,3	51,800	48,4	16,000	50,5	0,724	84,6	51,800	69,9	18,000	71,7
0,725	59,5	52,000	48,1	17,000	51,1	0,725	84,5	52,000	69,8	19,500	70,7
0,726	59,2	52,200	47,9	17,200	49,5	0,726	84,2	52,200	70,6	19,800	71,4
0,727	59,2	52,500	48,2	18,000	50,4	0,727	84,6	52,500	71,0	20,000	70,9
0,730	58,4	52,600	48,7	19,500	49,6	0,730	84,2	52,600	71,3	20,200	71,1
0,735	58,8	52,800	48,4	19,800	48,6	0,735	83,5	52,800	71,0	20,500	71,5
0,740	58,0	52,900	49,6	20,000	50,9	0,740	82,8	52,900	69,5	22,000	71,1
0,745	57,5	53,000	50,6	20,200	48,8	0,745	83,4	53,000	70,3	25,000	69,1
0,750	58,5	53,200	47,3	20,500	48,6	0,750	83,3	53,200	69,7	30,000	69,5
0,800	58,8	54,000	47,6	22,000	47,4	0,800	83,0	54,000	70,9	35,000	67,8

LFP-s 170x170		LFP-t 170x170		LFP-g 170x170		LFP-s 175x175		LFP-t 175x175		LFP-g 175x175	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	66,1	5,500	60,3	1,100	71,7	0,100	68,2	5,500	60,1	1,550	72,9
0,200	73,1	5,600	67,8	1,150	72,5	0,200	75,3	5,600	68,5	1,580	74,3
0,300	82,1	5,650	65,8	1,200	70,9	0,300	83,3	5,650	67,1	1,600	74,8
0,400	84,8	5,700	67,8	1,300	73,5	0,400	85,8	5,700	68,6	1,620	72,2
0,500	86,5	5,720	67,6	1,400	72,0	0,500	87,3	5,720	69,3	1,630	72,8
0,580	87,1	5,800	68,0	1,500	72,4	0,600	86,9	5,800	69,2	1,650	72,6
0,595	86,4	6,000	54,4	1,550	73,7	0,700	87,1	6,000	54,1	1,660	72,0
0,600	86,9	10,000	60,8	1,580	74,1	0,710	87,7	10,000	57,8	1,680	73,5
0,620	86,2	15,000	63,1	1,600	74,3	0,720	87,2	15,000	60,6	1,700	72,4
0,680	86,9	20,000	68,6	1,620	72,6	0,721	87,6	20,000	67,0	1,720	73,2
0,690	85,6	25,000	73,1	1,630	73,2	0,722	86,4	25,000	70,6	1,740	72,8
0,698	85,8	30,000	75,5	1,650	73,6	0,723	85,6	30,000	75,1	1,750	71,9
0,700	86,3	35,000	73,8	1,660	74,0	0,724	86,1	35,000	74,1	1,800	72,9
0,710	86,9	38,000	77,3	1,680	73,1	0,725	86,8	38,000	74,1	1,900	72,3
0,713	86,4	39,500	75,1	1,700	73,2	0,726	86,9	39,500	73,4	2,000	73,2
0,713	86,3	39,800	74,3	1,720	72,3	0,727	86,3	39,800	74,6	4,000	69,6
0,712	86,3	40,000	75,7	1,740	73,8	0,730	86,9	40,000	74,0	5,000	66,3
0,713	86,1	40,200	75,4	1,750	74,1	0,735	86,8	40,200	72,9	5,700	66,1
0,714	85,9	41,000	76,4	1,800	73,2	0,740	86,4	41,000	73,9	5,800	66,8
0,718	86,3	43,000	75,4	1,900	73,6	0,745	86,8	43,000	74,1	6,000	68,1
0,720	85,6	45,000	73,9	2,000	73,4	0,750	86,0	45,000	73,3	10,000	75,6
0,721	86,1	48,000	75,3	4,000	71,6	0,800	86,3	48,000	74,4	12,000	75,0
0,722	85,8	49,000	74,4	5,000	69,6	0,850	85,3	49,000	74,0	13,000	74,9
0,722	86,2	50,000	74,9	5,700	68,6	0,880	86,6	50,000	73,6	14,800	74,4
0,723	86,1	51,000	74,0	5,800	67,6	0,900	86,5	51,000	74,7	14,950	76,3
0,724	86,1	51,800	74,4	6,000	69,1	0,910	87,1	51,800	74,7	15,000	74,1
0,725	86,2	52,000	75,2	9,800	75,9	0,930	86,1	52,000	74,8	15,100	73,8
0,726	85,8	52,200	74,3	10,000	75,1	0,950	86,3	52,200	74,7	15,500	73,8
0,727	86,4	52,500	74,1	10,200	76,4	0,980	86,9	52,500	73,6	16,000	74,9
0,730	86,6	52,600	73,9	12,000	75,4	0,990	86,5	52,600	74,6	17,000	74,6
0,735	86,9	52,800	75,2	13,000	75,9	0,995	86,7	52,800	74,3	18,000	74,8
0,740	86,2	52,900	75,0	14,800	74,3	1,000	86,4	52,900	73,9	19,500	74,9
0,745	86,8	53,000	75,3	14,950	74,9	1,001	86,5	53,000	72,9	19,800	73,9
0,750	86,1	53,200	73,0	15,000	76,0	1,003	85,8	53,200	74,1	20,000	74,3
0,800	86,8	54,000	73,6	15,100	75,4	1,005	86,5	54,000	74,9	20,200	74,9

LFP-s 180x180		LFP-t 180x180		LFP-g 180x180		LFP-s 185x185		LFP-t 185x185		LFP-g 185x185	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	67,5	5,500	60,1	1,550	73,1	0,722	88,4	38,000	76,9	1,150	75,8
0,200	77,0	5,600	68,6	1,580	72,0	0,723	89,3	39,500	77,3	1,200	74,7
0,300	83,1	5,650	64,4	1,600	72,8	0,724	88,6	39,800	75,5	1,300	75,6
0,400	87,4	5,700	66,5	1,620	72,3	0,725	88,4	40,000	76,8	1,400	74,9
0,500	87,5	5,720	67,4	1,630	72,2	0,726	88,5	40,200	77,1	1,500	75,2
0,600	87,5	5,800	68,9	1,650	73,9	0,727	88,2	41,000	76,7	1,550	77,4
0,700	87,3	6,000	51,4	1,660	72,3	0,730	89,1	43,000	77,4	1,580	75,1
0,710	87,6	10,000	56,2	1,680	72,3	0,735	89,1	45,000	76,3	1,600	75,1
0,720	88,1	15,000	61,6	1,700	73,6	0,740	88,4	48,000	76,7	1,620	75,9
0,721	88,4	20,000	68,1	1,720	73,5	0,745	89,3	49,000	78,4	1,630	75,4
0,722	87,6	25,000	73,3	1,740	72,8	0,750	89,9	50,000	78,6	1,650	75,5
0,723	87,6	30,000	75,1	1,750	73,6	0,800	89,1	51,000	77,4	1,660	74,9
0,724	87,4	35,000	74,6	1,800	72,9	0,850	90,3	51,800	77,5	1,680	76,2
0,725	87,1	38,000	74,9	1,900	72,7	0,880	89,1	52,000	77,7	1,700	76,4
0,726	87,6	39,500	74,8	2,000	72,9	0,900	89,9	52,200	77,6	1,720	75,4
0,727	87,8	39,800	74,1	4,000	70,5	0,910	89,8	52,500	77,4	1,740	75,2
0,730	87,8	40,000	74,4	5,000	68,8	0,930	89,9	52,600	77,4	1,750	75,5
0,735	87,8	40,200	76,1	5,700	67,6	0,950	89,9	52,800	77,0	1,800	76,8
0,740	88,1	41,000	75,1	5,800	67,2	1,000	90,3	52,900	77,7	1,900	76,3
0,745	88,0	43,000	74,8	6,000	69,9	1,001	90,1	53,000	77,8	2,000	76,6
0,750	88,9	45,000	75,6	10,000	76,3	1,003	90,1	53,200	76,9	4,000	72,7
0,800	88,4	48,000	76,1	15,000	75,1	1,005	90,8	54,000	77,3	5,000	70,9
0,850	88,0	49,000	75,6	18,000	74,9	1,007	90,1	54,500	76,8	5,700	70,3
0,880	87,7	50,000	74,1	19,500	74,7	1,050	90,1	55,000	78,9	5,800	70,9
0,900	85,9	51,000	73,9	19,800	75,1	1,100	89,1	60,000	76,8	6,000	71,2
0,910	86,6	51,800	75,0	20,000	74,2	1,200	87,0	65,000	75,3	10,000	79,0
0,930	86,3	52,000	73,8	20,200	75,4	1,400	88,2	70,000	77,1	15,000	78,3
0,950	86,6	52,200	74,1	20,500	75,2	1,500	86,6	75,000	76,0	18,000	77,6
1,000	88,1	52,500	74,5	22,000	74,6	1,600	86,8	77,000	75,4	19,500	79,1
1,001	87,9	52,600	73,5	25,000	73,8	1,700	86,8	78,000	77,1	19,800	77,6
1,003	88,2	52,800	75,6	30,000	73,0	1,800	86,6	79,500	75,4	20,000	78,0
1,005	87,9	52,900	75,8	35,000	71,0	2,000	86,3	79,800	75,5	20,200	78,5
1,007	88,1	53,000	74,4	40,000	70,1	5,000	81,7	80,000	76,0	20,500	77,3
1,050	87,0	53,200	73,8	45,000	70,3	7,000	81,1	80,200	77,0	22,000	75,3
1,100	86,3	54,000	75,4	48,000	69,4	10,000	81,9	80,500	75,7	25,000	77,3

LFP-s 190x190		LFP-t 190x190		LFP-g 190x190		LFP-s 195x195		LFP-t 195x195		LFP-g 195x195	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	72,3	5,500	64,6	1,550	78,3	0,100	72,2	5,500	65,8	1,550	78,1
0,200	76,0	5,600	74,9	1,580	79,1	0,200	77,3	5,600	73,5	1,580	78,3
0,300	85,7	5,650	70,9	1,600	76,9	0,300	86,1	5,650	70,8	1,600	78,6
0,400	88,8	5,700	72,9	1,620	77,0	0,400	89,3	5,700	71,9	1,620	77,4
0,500	89,4	5,720	73,8	1,630	79,4	0,500	90,6	5,720	73,2	1,630	77,8
0,580	90,2	5,800	74,5	1,650	78,8	0,580	90,6	5,800	73,6	1,650	77,9
0,595	91,1	6,000	57,4	1,660	79,1	0,595	91,1	6,000	57,6	1,660	77,3
0,600	91,3	10,000	64,4	1,680	79,0	0,600	90,8	10,000	63,5	1,680	77,0
0,620	89,9	15,000	66,8	1,700	79,1	0,620	90,4	15,000	67,2	1,700	78,3
0,680	91,0	20,000	70,6	1,720	78,4	0,680	90,1	20,000	71,7	1,720	77,4
0,690	89,9	25,000	77,6	1,740	77,5	0,690	90,1	25,000	79,6	1,740	76,8
0,698	90,9	30,000	77,8	1,750	77,5	0,698	90,1	30,000	80,1	1,750	78,1
0,700	91,0	35,000	78,3	1,800	77,7	0,700	90,2	35,000	78,9	1,800	77,7
0,710	90,0	38,000	79,8	1,900	76,7	0,710	90,6	38,000	79,6	1,900	77,3
0,712	90,6	39,500	76,5	2,000	77,9	0,712	91,1	39,500	78,4	2,000	78,1
0,718	90,9	39,800	76,8	4,000	76,1	0,718	90,1	39,800	77,0	4,000	74,7
0,720	91,1	40,000	78,0	5,000	72,8	0,720	90,5	40,000	79,9	5,000	72,5
0,721	91,2	40,200	78,0	5,700	72,3	0,721	90,7	40,200	78,2	5,700	74,6
0,722	91,2	41,000	77,9	5,800	72,5	0,722	91,3	41,000	80,4	5,800	72,6
0,722	90,7	43,000	78,4	6,000	73,6	0,722	90,5	43,000	79,1	6,000	73,1
0,723	90,8	45,000	78,4	10,000	79,2	0,723	91,0	45,000	79,4	10,000	80,9
0,724	90,7	48,000	79,4	12,000	79,3	0,724	91,1	48,000	79,2	12,000	79,6
0,725	90,8	49,000	78,3	13,000	79,0	0,725	91,0	49,000	79,6	13,000	80,2
0,726	90,9	50,000	76,8	14,800	80,6	0,726	90,7	50,000	79,6	14,800	80,8
0,727	90,8	51,000	78,9	14,950	78,1	0,727	90,4	51,000	78,0	14,950	80,4
0,730	90,3	51,800	78,3	15,000	78,5	0,730	90,8	51,800	78,6	15,000	79,3
0,735	89,4	52,000	77,4	15,100	79,7	0,735	91,1	52,000	79,4	15,100	80,2
0,740	89,9	52,200	77,9	15,500	79,2	0,740	90,5	52,200	79,2	15,500	81,2
0,745	89,4	52,500	78,1	16,000	79,4	0,745	90,3	52,500	77,8	16,000	80,2
0,750	90,7	52,600	78,8	17,000	79,1	0,750	90,2	52,600	77,6	17,000	79,8
0,800	89,5	52,800	77,4	18,000	79,9	0,800	90,1	52,800	78,6	18,000	79,3
0,850	89,6	52,900	77,8	19,500	78,0	0,850	89,5	52,900	78,6	19,500	78,3
0,880	89,3	53,000	78,1	19,800	79,4	0,880	89,0	53,000	79,5	19,800	79,1
0,900	90,0	53,200	77,8	20,000	77,3	0,900	90,3	53,200	78,8	20,000	78,0
0,910	90,4	54,000	77,4	20,200	79,1	0,910	90,1	54,000	80,1	20,200	78,2

LFP-s 200x200		LFP-t 200x200		LFP-g 200x200		LFP-s 220x220		LFP-t 220x220		LFP-g 220x220	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,690	91,3	25,000	80,6	1,630	79,6	0,500	94,7	5,720	79,8	1,400	83,2
0,698	91,2	30,000	81,8	1,650	79,8	0,580	94,4	5,800	79,8	1,500	83,9
0,700	91,1	35,000	81,3	1,660	80,2	0,595	94,1	6,000	65,6	1,550	84,9
0,710	91,0	38,000	82,3	1,680	80,4	0,600	94,0	10,000	67,3	1,580	84,3
0,713	90,6	39,500	81,7	1,700	78,9	0,620	93,9	15,000	72,5	1,600	85,0
0,713	91,0	39,800	79,3	1,720	79,5	0,680	93,9	20,000	77,0	1,620	84,5
0,712	91,0	40,000	81,1	1,740	80,4	0,690	93,9	25,000	82,6	1,630	84,6
0,713	90,8	40,200	79,7	1,750	80,1	0,698	93,3	30,000	83,8	1,650	85,1
0,714	91,1	41,000	83,1	1,800	79,8	0,700	93,6	35,000	84,5	1,660	83,7
0,718	91,4	43,000	82,1	1,900	80,0	0,710	94,1	38,000	85,7	1,680	84,3
0,720	91,4	45,000	82,0	2,000	80,2	0,713	94,3	39,500	83,2	1,700	83,9
0,721	91,3	48,000	82,6	4,000	76,7	0,713	94,1	39,800	83,8	1,720	83,8
0,722	91,6	49,000	81,4	5,000	75,3	0,712	94,4	40,000	84,4	1,740	83,4
0,722	91,7	50,000	81,9	5,700	73,9	0,713	94,1	40,200	83,1	1,750	83,6
0,723	91,6	51,000	82,4	5,800	73,6	0,714	93,9	41,000	84,1	1,800	83,4
0,724	91,6	51,800	83,6	6,000	75,9	0,718	93,9	43,000	84,8	1,900	83,9
0,725	91,7	52,000	83,3	9,800	82,9	0,720	94,0	45,000	84,3	2,000	84,6
0,726	91,7	52,200	81,1	10,000	83,9	0,721	94,4	48,000	84,9	4,000	80,0
0,727	91,8	52,500	82,3	10,200	82,3	0,722	94,6	49,000	84,6	5,000	77,6
0,730	91,8	52,600	82,4	12,000	81,9	0,722	94,3	50,000	84,6	5,700	77,2
0,735	91,3	52,800	82,3	13,000	83,2	0,723	94,6	51,000	84,8	5,800	75,8
0,740	91,3	52,900	82,3	14,800	82,6	0,724	94,4	51,800	83,7	6,000	78,3
0,745	91,4	53,000	82,4	14,950	81,2	0,725	94,3	52,000	84,4	9,800	85,3
0,750	91,3	53,200	82,5	15,000	82,1	0,726	94,2	52,200	84,2	10,000	84,9
0,800	91,3	54,000	82,4	15,100	83,3	0,727	94,2	52,500	83,8	10,200	85,4
0,810	90,8	54,500	82,8	15,200	80,8	0,730	94,2	52,600	83,4	12,000	84,8
0,820	90,2	55,000	82,1	15,300	82,0	0,735	94,0	52,800	85,0	13,000	85,1
0,850	90,6	60,000	80,9	15,500	81,6	0,740	94,9	52,900	85,4	14,800	84,5
0,880	90,4	65,000	78,9	16,000	81,2	0,745	94,8	53,000	84,7	14,950	84,1
0,900	90,1	70,000	80,1	17,000	81,0	0,750	95,0	53,200	83,6	15,000	83,4
0,910	90,8	75,000	80,7	17,200	82,1	0,800	93,9	54,000	85,4	15,100	84,1
0,930	90,6	77,000	79,8	18,000	81,3	0,810	93,8	54,500	85,3	15,200	84,9
0,950	90,5	78,000	80,6	19,500	81,3	0,820	93,9	55,000	84,8	15,300	85,0
0,960	90,3	79,500	79,6	19,800	82,6	0,850	94,3	60,000	84,1	15,500	84,2
0,970	90,7	79,800	80,5	20,000	82,4	0,880	93,9	65,000	82,8	16,000	83,4

LFP-s 250x250		LFP-t 250x250		LFP-g 250x250		LFP-s 300x300		LFP-t 300x300		LFP-g 300x300	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	83,5	5,500	77,7	1,900	87,5	0,595	98,4	6,000	73,2	1,550	90,8
0,200	88,3	5,600	84,3	2,000	87,6	0,600	98,3	10,000	76,4	1,580	91,3
0,300	93,4	5,650	82,8	4,000	83,6	0,620	98,1	15,000	80,4	1,600	91,6
0,400	95,3	5,700	84,2	5,000	84,8	0,680	98,1	20,000	85,9	1,620	90,8
0,500	96,1	5,720	84,3	5,700	82,6	0,690	98,0	25,000	91,3	1,630	90,9
0,580	95,9	5,800	84,8	5,800	83,3	0,698	98,3	30,000	90,8	1,650	91,1
0,595	95,8	6,000	71,3	6,000	83,5	0,700	98,2	35,000	91,8	1,660	90,7
0,600	96,1	10,000	73,2	9,800	89,4	0,710	98,1	38,000	91,4	1,680	91,3
0,620	95,9	15,000	77,1	10,000	88,6	0,713	97,9	39,500	90,3	1,700	91,7
0,680	95,6	20,000	80,9	10,200	89,4	0,713	98,0	39,800	91,4	1,720	90,4
0,690	95,4	25,000	86,8	12,000	89,3	0,712	98,0	40,000	91,5	1,740	90,4
0,698	96,0	30,000	88,1	13,000	88,7	0,713	97,9	40,200	92,3	1,750	90,8
0,700	96,2	35,000	89,1	14,800	87,6	0,714	97,9	41,000	90,8	1,800	90,1
0,710	95,8	38,000	88,3	14,950	87,9	0,718	98,3	43,000	91,5	1,900	90,5
0,713	95,7	39,500	87,1	15,000	88,0	0,720	98,3	45,000	91,6	2,000	91,4
0,713	95,9	39,800	87,5	15,100	87,2	0,721	98,4	48,000	92,0	4,000	87,7
0,712	95,8	40,000	87,2	15,200	88,6	0,722	98,5	49,000	91,8	5,000	85,6
0,713	95,8	40,200	87,3	15,300	88,9	0,722	98,4	50,000	92,6	5,700	85,9
0,714	95,8	41,000	88,6	15,500	88,4	0,723	98,3	51,000	91,8	5,800	84,8
0,718	95,9	43,000	87,3	16,000	88,6	0,724	98,3	51,800	92,2	6,000	84,6
0,720	95,9	45,000	88,6	17,000	88,5	0,725	98,2	52,000	91,1	9,800	92,1
0,721	95,6	48,000	88,9	17,200	88,1	0,726	98,2	52,200	91,7	10,000	92,7
0,722	95,7	49,000	88,7	18,000	89,3	0,727	98,2	52,500	91,5	10,200	92,6
0,722	95,6	50,000	88,4	19,500	87,3	0,730	98,3	52,600	91,1	12,000	92,5
0,723	95,3	51,000	88,8	19,800	87,7	0,735	98,4	52,800	91,9	13,000	92,4
0,724	95,5	51,800	89,1	20,000	87,8	0,740	98,6	52,900	91,8	14,800	90,9
0,725	95,8	52,000	89,1	20,200	86,8	0,745	98,7	53,000	91,8	14,950	91,6
0,726	95,6	52,200	87,7	20,500	89,1	0,750	98,4	53,200	91,4	15,000	92,3
0,727	95,6	52,500	88,8	22,000	88,1	0,800	98,1	54,000	92,2	15,100	92,2
0,730	95,9	52,600	88,4	25,000	87,4	0,810	98,4	54,500	91,8	15,200	91,6
0,735	95,6	52,800	88,3	30,000	87,3	0,820	98,2	55,000	91,4	15,300	92,0
0,740	96,0	52,900	88,0	35,000	85,6	0,850	98,2	60,000	91,0	15,500	91,9
0,745	95,6	53,000	88,2	40,000	84,8	0,880	98,1	65,000	91,4	16,000	91,1
0,750	96,1	53,200	87,5	45,000	83,6	0,900	97,9	70,000	90,4	17,000	91,3
0,800	95,3	54,000	87,5	48,000	83,8	0,910	97,8	75,000	91,6	17,200	92,5

APÊNDICE K – Sensibilidade obtida para diferentes valores de parâmetro
(Imagens de vermiculita – Iluminação Tipo 3)

LFP-s 100x100		LFP-t 100x100		LFP-g 100x100		LFP-s 160x160		LFP-t 160x160		LFP-g 160x160	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	45,9	5,500	41,6	1,100	47,4	0,690	80,7	5,500	57,4	5,000	65,8
0,200	51,2	5,600	48,1	1,150	48,1	0,698	82,3	5,600	66,3	5,700	67,6
0,300	54,9	5,650	44,9	1,200	49,3	0,700	82,2	5,650	63,4	5,800	67,4
0,400	59,1	5,700	46,0	1,300	48,7	0,710	82,8	5,700	66,3	6,000	65,6
0,500	59,8	5,720	48,2	1,400	49,1	0,713	83,4	5,720	66,4	9,800	72,0
0,580	61,3	5,800	48,1	1,500	48,9	0,713	83,6	5,800	66,3	10,000	73,5
0,595	59,8	6,000	38,0	1,550	48,9	0,712	83,1	6,000	53,9	10,200	72,6
0,600	62,0	10,000	42,5	1,580	49,4	0,713	83,3	10,000	58,9	12,000	72,7
0,620	61,9	15,000	43,2	1,600	50,1	0,714	83,5	15,000	61,3	13,000	73,6
0,680	61,1	20,000	48,7	1,620	49,4	0,718	83,3	20,000	65,6	14,800	71,4
0,690	60,5	25,000	53,1	1,630	49,1	0,720	83,4	25,000	71,1	14,950	72,6
0,698	60,3	30,000	52,1	1,650	50,7	0,721	83,5	30,000	73,9	15,000	71,8
0,700	60,2	35,000	53,6	1,660	50,4	0,722	83,9	35,000	71,6	15,100	74,4
0,710	60,3	38,000	52,5	1,680	49,8	0,722	83,6	38,000	73,1	15,200	72,2
0,713	61,5	39,500	51,4	1,700	48,9	0,723	82,9	39,500	72,4	15,300	72,2
0,713	60,9	39,800	52,6	1,720	49,6	0,724	82,6	39,800	72,6	15,500	72,1
0,712	60,4	40,000	55,1	1,740	50,9	0,725	82,7	40,000	73,2	16,000	71,3
0,713	60,6	40,200	52,3	1,750	50,1	0,726	82,4	40,200	72,7	17,000	71,9
0,714	60,4	41,000	53,5	1,800	48,5	0,727	82,8	41,000	72,9	17,200	71,4
0,718	60,6	43,000	52,1	1,900	49,3	0,730	82,4	43,000	71,9	18,000	71,7
0,720	61,1	45,000	53,6	2,000	50,6	0,735	82,3	45,000	72,3	19,500	72,2
0,721	61,6	48,000	53,4	4,000	50,4	0,740	82,8	48,000	73,1	19,800	74,4
0,722	61,4	49,000	54,7	5,000	47,3	0,745	83,6	49,000	72,3	20,000	73,6
0,722	61,9	50,000	53,5	5,700	50,6	0,750	83,7	50,000	73,1	20,200	73,4
0,723	61,8	51,000	52,9	5,800	48,4	0,800	84,1	51,000	72,6	20,500	72,8
0,724	61,8	51,800	54,0	6,000	51,6	0,810	82,6	51,800	70,4	22,000	72,2
0,725	62,4	52,000	54,2	9,800	54,8	0,820	82,6	52,000	71,6	25,000	70,3
0,726	63,4	52,200	53,1	10,000	51,7	0,850	83,1	52,200	73,4	30,000	69,6
0,727	62,9	52,500	54,8	10,200	52,9	0,880	82,3	52,500	73,3	35,000	67,5
0,730	61,1	52,600	53,3	12,000	54,1	0,900	83,1	52,600	70,5	40,000	67,2
0,735	61,1	52,800	53,6	13,000	53,8	0,910	82,5	52,800	72,6	45,000	66,4
0,740	62,4	52,900	53,4	14,800	54,0	0,930	83,3	52,900	71,7	48,000	67,2
0,745	61,2	53,000	55,6	14,950	53,6	0,950	83,4	53,000	72,3	50,000	65,3
0,750	61,2	53,200	53,3	15,000	54,6	0,960	84,0	53,200	73,1	51,000	67,0
0,800	60,6	54,000	52,8	15,100	53,8	0,970	83,2	54,000	73,1	52,500	64,4

LFP-s 170x170		LFP-t 170x170		LFP-g 170x170		LFP-s 175x175		LFP-t 175x175		LFP-g 175x175	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	65,0	5,500	66,3	1,800	75,6	0,725	84,6	39,500	74,8	1,620	75,1
0,200	73,6	5,600	71,3	1,900	76,3	0,726	84,3	39,800	74,9	1,630	74,7
0,300	81,1	5,650	69,8	2,000	75,7	0,727	84,6	40,000	76,1	1,650	74,6
0,400	85,1	5,700	71,6	4,000	73,8	0,730	85,4	40,200	73,8	1,660	74,8
0,500	86,5	5,720	70,8	5,000	72,4	0,735	85,3	41,000	75,9	1,680	75,8
0,580	85,9	5,800	71,2	5,700	71,1	0,740	85,9	43,000	76,1	1,700	73,3
0,595	86,2	6,000	58,8	5,800	72,1	0,745	85,9	45,000	76,6	1,720	74,6
0,600	86,5	10,000	62,3	6,000	72,0	0,750	84,9	48,000	75,9	1,740	74,9
0,620	86,8	15,000	65,9	9,800	78,3	0,800	85,5	49,000	75,2	1,750	74,1
0,680	87,1	20,000	69,1	10,000	77,4	0,850	85,7	50,000	75,3	1,800	73,6
0,690	87,2	25,000	75,9	10,200	77,4	0,880	85,4	51,000	75,0	1,900	74,7
0,698	87,2	30,000	77,5	12,000	77,3	0,900	85,0	51,800	75,7	2,000	75,6
0,700	87,6	35,000	77,4	13,000	76,2	0,910	85,9	52,000	76,8	4,000	72,9
0,710	87,4	38,000	78,9	14,800	77,1	0,930	85,9	52,200	75,1	5,000	70,9
0,713	87,2	39,500	75,8	14,950	77,7	0,950	84,2	52,500	74,7	5,700	70,4
0,713	87,2	39,800	77,6	15,000	78,0	0,980	85,4	52,600	75,2	5,800	69,5
0,712	87,5	40,000	77,8	15,100	77,6	0,990	85,8	52,800	76,4	6,000	70,4
0,713	86,9	40,200	75,6	15,200	78,8	0,995	85,3	52,900	76,2	10,000	75,9
0,714	86,6	41,000	78,1	15,300	78,1	1,000	86,6	53,000	76,6	12,000	77,2
0,718	87,2	43,000	77,8	15,500	79,1	1,001	86,1	53,200	75,3	13,000	75,0
0,720	86,7	45,000	78,0	16,000	77,7	1,003	85,8	54,000	75,8	14,800	75,1
0,721	86,9	48,000	77,7	17,000	77,4	1,005	85,3	54,500	76,9	14,950	74,9
0,722	87,3	49,000	77,8	17,200	78,6	1,007	85,3	55,000	75,5	15,000	76,9
0,722	86,9	50,000	77,1	18,000	78,2	1,050	84,4	60,000	75,2	15,100	75,1
0,723	86,9	51,000	76,3	19,500	77,7	1,100	85,7	65,000	74,2	15,500	75,7
0,724	87,0	51,800	78,2	19,800	77,6	1,200	84,2	70,000	74,9	16,000	74,4
0,725	86,8	52,000	77,2	20,000	77,9	1,400	84,1	75,000	75,5	17,000	74,9
0,726	86,3	52,200	78,0	20,200	77,8	1,500	83,9	77,000	74,8	18,000	75,8
0,727	86,3	52,500	76,4	20,500	77,3	1,600	84,5	78,000	74,5	19,500	75,6
0,730	86,4	52,600	77,3	22,000	76,6	1,700	84,4	79,500	74,2	19,800	75,8
0,735	86,6	52,800	76,9	25,000	74,3	1,800	84,7	79,800	75,1	20,000	76,6
0,740	86,8	52,900	78,3	30,000	74,7	2,000	82,1	80,000	75,6	20,200	76,4
0,745	87,0	53,000	77,4	35,000	74,6	5,000	74,4	80,200	74,1	20,500	75,6
0,750	87,1	53,200	77,4	40,000	74,8	7,000	73,9	80,500	75,2	22,000	76,1
0,800	85,4	54,000	78,3	45,000	72,4	10,000	77,6	82,000	74,8	25,000	74,4

LFP-s 180x180		LFP-t 180x180		LFP-g 180x180		LFP-s 185x185		LFP-t 185x185		LFP-g 185x185	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	67,9	5,500	67,8	1,550	77,4	0,100	66,3	5,500	64,3	1,400	74,6
0,200	74,3	5,600	74,9	1,580	78,4	0,200	73,3	5,600	73,9	1,500	74,4
0,300	83,4	5,650	71,4	1,600	78,4	0,300	82,4	5,650	71,6	1,550	76,3
0,400	87,1	5,700	72,2	1,620	78,6	0,400	86,3	5,700	72,5	1,580	76,3
0,500	88,3	5,720	73,7	1,630	76,9	0,500	88,2	5,720	73,8	1,600	76,6
0,600	89,1	5,800	75,3	1,650	77,6	0,600	87,9	5,800	73,9	1,620	75,5
0,700	89,9	6,000	61,6	1,660	78,2	0,700	88,3	6,000	57,5	1,630	75,4
0,710	89,3	10,000	65,4	1,680	77,0	0,710	87,9	10,000	62,9	1,650	76,4
0,720	89,6	15,000	69,6	1,700	77,3	0,720	88,1	15,000	65,4	1,660	75,4
0,721	88,9	20,000	74,7	1,720	77,6	0,721	87,9	20,000	70,0	1,680	76,6
0,722	88,5	25,000	78,3	1,740	77,8	0,722	87,6	25,000	77,1	1,700	76,4
0,723	89,3	30,000	79,4	1,750	78,6	0,723	87,3	30,000	79,9	1,720	76,5
0,724	89,0	35,000	78,3	1,800	78,1	0,724	87,1	35,000	77,6	1,740	76,4
0,725	89,2	38,000	79,7	1,900	77,3	0,725	86,9	38,000	78,5	1,750	75,4
0,726	88,9	39,500	80,3	2,000	76,4	0,726	87,4	39,500	77,8	1,800	77,1
0,727	88,9	39,800	79,4	4,000	76,2	0,727	87,1	39,800	77,2	1,900	76,3
0,730	88,9	40,000	81,9	5,000	75,8	0,730	87,6	40,000	79,4	2,000	75,8
0,735	88,5	40,200	79,1	5,700	74,9	0,735	87,8	40,200	77,9	4,000	76,6
0,740	88,8	41,000	78,8	5,800	73,5	0,740	88,6	41,000	79,4	5,000	73,1
0,745	88,9	43,000	79,5	6,000	74,5	0,745	88,0	43,000	78,5	5,700	72,1
0,750	87,9	45,000	78,4	10,000	78,1	0,750	88,0	45,000	79,1	5,800	72,9
0,800	89,1	48,000	79,9	15,000	80,5	0,800	87,3	48,000	78,9	6,000	70,3
0,850	88,3	49,000	80,4	18,000	79,0	0,850	87,6	49,000	78,2	10,000	79,2
0,880	87,8	50,000	78,2	19,500	80,6	0,880	87,9	50,000	79,5	15,000	78,6
0,900	86,8	51,000	80,4	19,800	79,9	0,900	88,1	51,000	78,1	18,000	79,6
0,910	86,3	51,800	78,9	20,000	79,8	0,910	88,6	51,800	77,6	19,500	76,5
0,930	87,3	52,000	79,1	20,200	78,8	0,930	87,0	52,000	77,6	19,800	78,2
0,950	87,8	52,200	79,5	20,500	78,5	0,950	86,5	52,200	77,6	20,000	78,2
1,000	88,3	52,500	77,9	22,000	77,8	1,000	87,8	52,500	78,2	20,200	78,3
1,001	87,6	52,600	78,1	25,000	78,4	1,001	88,5	52,600	77,8	20,500	78,9
1,003	87,6	52,800	79,8	30,000	76,6	1,003	88,3	52,800	78,8	22,000	78,3
1,005	87,4	52,900	79,1	35,000	75,1	1,005	87,8	52,900	79,4	25,000	77,3
1,007	86,8	53,000	78,7	40,000	74,8	1,007	87,8	53,000	78,4	30,000	75,5
1,050	88,6	53,200	78,2	45,000	75,3	1,050	86,9	53,200	77,7	35,000	75,0
1,100	87,3	54,000	78,3	48,000	73,5	1,100	86,1	54,000	77,4	40,000	73,9

LFP-s 190x190		LFP-t 190x190		LFP-g 190x190		LFP-s 195x195		LFP-t 195x195		LFP-g 195x195	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,740	89,2	5,500	66,9	1,550	77,4	0,100	69,3	5,500	68,1	1,550	79,4
0,745	88,1	5,600	74,1	1,580	79,3	0,200	75,3	5,600	75,9	1,580	80,4
0,750	89,0	5,650	72,1	1,600	79,9	0,300	85,4	5,650	72,5	1,600	80,5
0,800	89,3	5,700	72,9	1,620	79,6	0,400	88,8	5,700	75,8	1,620	81,5
0,850	88,6	5,720	74,8	1,630	79,6	0,500	89,9	5,720	75,4	1,630	81,1
0,880	89,0	5,800	74,5	1,650	78,3	0,580	90,1	5,800	76,2	1,650	79,3
0,900	88,3	6,000	60,9	1,660	79,4	0,595	90,6	6,000	61,2	1,660	80,1
0,910	88,9	10,000	63,6	1,680	80,3	0,600	90,9	10,000	66,6	1,680	79,4
0,930	89,1	15,000	65,6	1,700	78,8	0,620	89,9	15,000	69,5	1,700	78,8
0,950	88,4	20,000	72,3	1,720	80,7	0,680	91,0	20,000	73,2	1,720	79,1
0,960	88,7	25,000	79,0	1,740	79,0	0,690	89,8	25,000	80,6	1,740	80,3
0,970	89,0	30,000	80,6	1,750	77,6	0,698	90,1	30,000	80,9	1,750	80,9
0,975	89,6	35,000	79,3	1,800	78,4	0,700	90,4	35,000	81,0	1,800	79,1
0,980	89,6	38,000	80,1	1,900	79,4	0,710	90,2	38,000	80,9	1,900	80,2
0,983	89,4	39,500	80,3	2,000	78,2	0,712	90,3	39,500	81,1	2,000	80,5
0,986	89,5	39,800	79,4	4,000	77,4	0,718	89,6	39,800	80,4	4,000	77,8
0,988	88,8	40,000	80,8	5,000	75,1	0,720	89,6	40,000	83,6	5,000	75,6
0,989	89,3	40,200	78,9	5,700	74,0	0,721	90,4	40,200	81,3	5,700	76,1
0,990	88,9	41,000	80,9	5,800	75,9	0,722	90,6	41,000	81,1	5,800	75,5
0,991	89,2	43,000	79,4	6,000	74,1	0,722	90,9	43,000	80,9	6,000	74,6
0,992	89,5	45,000	81,3	10,000	79,6	0,723	90,2	45,000	82,8	10,000	84,1
0,993	89,4	48,000	81,5	12,000	81,1	0,724	89,9	48,000	81,1	12,000	83,1
0,994	89,6	49,000	80,5	13,000	80,1	0,725	89,9	49,000	80,3	13,000	81,4
0,995	89,8	50,000	79,6	14,800	81,0	0,726	89,9	50,000	81,3	14,800	82,3
0,996	90,0	51,000	80,7	14,950	80,9	0,727	89,6	51,000	80,4	14,950	81,1
0,997	89,6	51,800	78,9	15,000	80,4	0,730	90,3	51,800	79,3	15,000	82,0
1,000	89,4	52,000	80,1	15,100	80,2	0,735	89,8	52,000	79,8	15,100	80,8
1,001	89,1	52,200	80,4	15,500	81,0	0,740	90,3	52,200	81,3	15,500	83,1
1,002	89,4	52,500	79,1	16,000	80,3	0,745	90,3	52,500	80,1	16,000	82,6
1,003	89,6	52,600	79,0	17,000	79,8	0,750	90,4	52,600	81,1	17,000	83,2
1,003	89,8	52,800	80,4	18,000	80,0	0,800	91,0	52,800	81,6	18,000	82,4
1,004	89,3	52,900	80,4	19,500	79,1	0,850	90,4	52,900	81,8	19,500	80,9
1,004	89,1	53,000	81,3	19,800	79,0	0,880	90,1	53,000	81,2	19,800	82,7
1,005	89,2	53,200	81,3	20,000	79,6	0,900	90,1	53,200	81,4	20,000	81,4
1,007	88,6	54,000	79,9	20,200	77,9	0,910	90,6	54,000	81,1	20,200	80,4

LFP-s 200x200		LFP-t 200x200		LFP-g 200x200		LFP-s 220x220		LFP-t 220x220		LFP-g 220x220	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,100	72,0	40,000	84,5	1,740	82,9	0,100	73,9	5,500	74,6	1,100	84,4
0,200	79,4	40,200	82,9	1,750	83,5	0,200	83,1	5,600	82,6	1,150	85,9
0,300	86,3	41,000	83,5	1,800	82,6	0,300	89,0	5,650	79,6	1,200	84,9
0,400	91,0	43,000	83,9	1,900	81,8	0,400	92,5	5,700	81,3	1,300	85,6
0,500	91,8	45,000	84,6	2,000	82,8	0,500	93,7	5,720	82,2	1,400	85,3
0,580	91,4	48,000	84,1	4,000	79,9	0,580	94,2	5,800	82,7	1,500	85,8
0,595	91,3	49,000	84,3	5,000	80,5	0,595	93,4	6,000	67,4	1,550	86,0
0,600	91,6	50,000	85,4	5,700	79,1	0,600	93,2	10,000	71,7	1,580	86,8
0,620	92,3	51,000	84,0	5,800	78,8	0,620	93,1	15,000	74,5	1,600	86,6
0,680	92,4	51,800	84,4	6,000	79,3	0,680	94,4	20,000	79,9	1,620	85,2
0,690	92,3	52,000	84,0	9,800	84,8	0,690	93,8	25,000	84,3	1,630	86,0
0,698	92,3	52,200	83,6	10,000	83,3	0,698	94,4	30,000	87,1	1,650	86,5
0,700	92,0	52,500	83,3	10,200	84,9	0,700	94,5	35,000	87,5	1,660	86,3
0,710	92,5	52,600	84,3	12,000	82,7	0,710	93,2	38,000	86,6	1,680	85,4
0,713	92,7	52,800	84,2	13,000	83,1	0,713	93,3	39,500	85,7	1,700	85,4
0,713	92,4	52,900	84,3	14,800	83,3	0,713	93,5	39,800	84,6	1,720	85,4
0,712	92,7	53,000	84,0	14,950	83,1	0,712	93,1	40,000	87,1	1,740	84,3
0,713	92,6	53,200	84,1	15,000	84,1	0,713	93,5	40,200	85,6	1,750	85,1
0,714	92,9	54,000	83,8	15,100	83,6	0,714	93,4	41,000	86,6	1,800	85,9
0,718	91,8	54,500	84,8	15,200	84,3	0,718	93,5	43,000	86,3	1,900	84,9
0,720	92,0	55,000	83,7	15,300	82,9	0,720	94,0	45,000	86,1	2,000	85,4
0,721	92,1	60,000	86,3	15,500	83,4	0,721	93,6	48,000	86,3	4,000	82,6
0,722	91,9	65,000	82,1	16,000	83,4	0,722	93,6	49,000	85,9	5,000	81,8
0,722	91,3	70,000	83,8	17,000	83,6	0,722	93,8	50,000	85,6	5,700	79,1
0,723	91,7	75,000	82,3	17,200	82,5	0,723	94,0	51,000	87,6	5,800	80,4
0,724	91,9	77,000	83,1	18,000	82,5	0,724	94,4	51,800	85,4	6,000	79,3
0,725	92,3	78,000	84,8	19,500	82,8	0,725	94,1	52,000	86,7	9,800	86,9
0,726	91,8	79,500	83,4	19,800	83,2	0,726	93,7	52,200	85,4	10,000	85,4
0,727	92,1	79,800	82,7	20,000	84,0	0,727	93,6	52,500	86,0	10,200	86,8
0,730	92,3	80,000	82,3	20,200	83,6	0,730	93,9	52,600	87,3	12,000	85,7
0,735	92,6	80,200	83,1	20,500	84,1	0,735	92,8	52,800	86,1	13,000	86,5
0,740	92,2	80,500	84,6	22,000	82,4	0,740	93,4	52,900	85,9	14,800	85,8
0,745	92,4	82,000	83,4	25,000	83,3	0,745	93,6	53,000	85,3	14,950	86,1
0,750	91,9	85,000	81,5	30,000	81,9	0,750	93,4	53,200	85,4	15,000	86,6
0,800	92,6	87,000	83,0	35,000	81,0	0,800	93,4	54,000	86,3	15,100	86,9

LFP-s 250x250		LFP-t 250x250		LFP-g 250x250		LFP-s 300x300		LFP-t 300x300		LFP-g 300x300	
Beta	S (%)	Delta	S (%)	Delta	S (%)	Beta	S (%)	Delta	S (%)	Delta	S (%)
0,595	96,0	6,000	73,3	1,550	90,9	0,698	97,7	5,500	83,9	1,100	91,7
0,600	96,1	10,000	75,9	1,580	90,2	0,700	97,7	5,600	89,8	1,150	93,3
0,620	96,5	15,000	79,1	1,600	89,6	0,710	97,8	5,650	88,3	1,200	92,4
0,680	96,1	20,000	84,1	1,620	89,8	0,713	98,0	5,700	89,3	1,300	92,4
0,690	96,2	25,000	88,3	1,630	90,4	0,713	97,9	5,720	89,8	1,400	92,7
0,698	96,6	30,000	90,8	1,650	89,1	0,712	97,9	5,800	90,2	1,500	91,5
0,700	96,7	35,000	89,9	1,660	89,2	0,713	98,0	6,000	77,5	1,550	92,8
0,710	96,4	38,000	90,9	1,680	89,3	0,714	97,9	10,000	80,9	1,580	91,8
0,713	96,7	39,500	89,9	1,700	89,5	0,718	97,6	15,000	82,8	1,600	92,4
0,713	96,6	39,800	90,4	1,720	89,9	0,720	97,8	20,000	86,6	1,620	91,8
0,712	96,5	40,000	90,8	1,740	89,1	0,721	97,9	25,000	91,0	1,630	92,3
0,713	96,6	40,200	89,6	1,750	89,3	0,722	97,9	30,000	93,2	1,650	92,1
0,714	96,4	41,000	90,7	1,800	88,9	0,722	98,1	35,000	93,1	1,660	92,3
0,718	96,3	43,000	91,1	1,900	89,6	0,723	98,1	38,000	92,4	1,680	92,3
0,720	96,5	45,000	89,4	2,000	89,9	0,724	97,9	39,500	92,1	1,700	92,3
0,721	96,3	48,000	90,4	4,000	86,8	0,725	97,9	39,800	92,0	1,720	92,3
0,722	95,4	49,000	89,7	5,000	86,2	0,726	97,4	40,000	92,6	1,740	92,2
0,722	95,7	50,000	89,8	5,700	85,6	0,727	97,8	40,200	91,7	1,750	92,3
0,723	95,9	51,000	90,3	5,800	84,5	0,730	97,9	41,000	93,0	1,800	91,0
0,724	95,8	51,800	90,1	6,000	85,5	0,735	97,7	43,000	92,9	1,900	91,7
0,725	95,7	52,000	90,1	9,800	90,5	0,740	97,4	45,000	92,1	2,000	91,6
0,726	95,6	52,200	90,4	10,000	90,6	0,745	97,6	48,000	92,3	4,000	90,4
0,727	95,6	52,500	90,0	10,200	90,2	0,750	97,8	49,000	92,4	5,000	89,3
0,730	95,8	52,600	89,9	12,000	90,8	0,800	97,8	50,000	92,6	5,700	88,4
0,735	95,3	52,800	89,4	13,000	90,7	0,810	97,9	51,000	91,9	5,800	87,9
0,740	95,6	52,900	89,8	14,800	90,4	0,820	98,3	51,800	92,1	6,000	89,1
0,745	95,9	53,000	89,3	14,950	90,8	0,850	98,0	52,000	91,9	9,800	93,6
0,750	96,6	53,200	90,2	15,000	90,2	0,880	97,4	52,200	91,7	10,000	92,1
0,800	95,9	54,000	89,5	15,100	91,4	0,900	97,6	52,500	92,1	10,200	93,0
0,810	96,0	54,500	90,8	15,200	88,6	0,910	97,8	52,600	91,8	12,000	92,7
0,820	96,1	55,000	89,5	15,300	88,8	0,930	97,8	52,800	92,1	13,000	92,4
0,850	95,8	60,000	89,4	15,500	88,9	0,950	97,5	52,900	91,8	14,800	92,1
0,880	96,1	65,000	88,9	16,000	90,3	0,960	97,7	53,000	91,8	14,950	91,9
0,900	95,8	70,000	88,9	17,000	89,7	0,970	97,5	53,200	91,6	15,000	93,1
0,910	95,6	75,000	89,3	17,200	89,8	0,975	97,6	54,000	91,5	15,100	92,4

APÊNDICE L – Esforço computacional

Duração do processo de classificação de um conjunto de amostras (segundos)

	Iluminação Tipo 1				Iluminação Tipo 2				Iluminação Tipo 3			
	LBP	LFP-s	LFP-t	LFP-g	LBP	LFP-s	LFP-t	LFP-g	LBP	LFP-s	LFP-t	LFP-g
Tamanho da amostra (pixels)												
100x100	18,46	21,83	20,87	20,61	17,60	22,19	20,14	19,49	19,30	24,05	20,09	19,63
160x160	18,99	22,63	23,42	20,51	18,32	22,84	21,70	19,72	20,47	25,55	22,64	19,79
170x170	18,21	22,40	23,27	20,20	18,13	23,33	23,19	20,14	20,78	24,57	22,37	19,98
175x175	18,50	23,76	23,57	20,83	19,02	23,41	23,78	20,37	20,81	25,43	24,44	20,42
180x180	18,61	23,84	23,88	21,40	18,66	23,85	24,48	22,94	21,37	26,24	24,22	21,06
185x185	18,68	25,60	24,23	21,73	20,37	24,09	24,13	24,97	21,51	24,02	24,63	20,93
190x190	19,21	25,67	23,87	21,26	19,14	24,48	25,35	21,42	21,14	24,36	23,97	21,65
195x195	18,68	24,23	24,41	21,79	19,45	24,40	24,43	23,61	21,47	24,50	24,27	21,61
200x200	19,66	26,01	25,60	22,75	20,04	25,11	24,79	23,58	22,32	24,73	25,17	22,06
220x220	20,01	26,68	26,94	25,40	21,66	26,42	27,49	23,74	22,02	26,23	26,35	23,54
250x250	20,57	27,41	28,02	24,43	21,23	29,32	30,25	25,55	23,63	27,88	28,99	24,20
300x300	23,51	33,91	35,69	28,45	20,87	30,71	29,01	23,39	25,91	35,46	37,01	32,44

Duração do processo de classificação de uma amostra (segundos)

	Iluminação Tipo 1				Iluminação Tipo 2				Iluminação Tipo 3			
	LBP	LFP-s	LFP-t	LFP-g	LBP	LFP-s	LFP-t	LFP-g	LBP	LFP-s	LFP-t	LFP-g
Tamanho da amostra (pixels)												
100x100	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01
160x160	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,01	0,01
170x170	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01
175x175	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01
180x180	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,02	0,02	0,01
185x185	0,02	0,02	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,02	0,01	0,01
190x190	0,01	0,01	0,01	0,01	0,01	0,02	0,02	0,02	0,01	0,01	0,01	0,01
195x195	0,01	0,02	0,02	0,01	0,01	0,02	0,02	0,01	0,02	0,02	0,01	0,01
200x200	0,01	0,02	0,02	0,01	0,01	0,02	0,02	0,01	0,01	0,02	0,02	0,01
220x220	0,02	0,02	0,02	0,02	0,01	0,02	0,02	0,01	0,01	0,02	0,02	0,02
250x250	0,01	0,02	0,02	0,02	0,01	0,02	0,02	0,02	0,01	0,02	0,02	0,01
300x300	0,02	0,02	0,02	0,02	0,02	0,02	0,03	0,02	0,02	0,03	0,03	0,02

ANEXO A- 111 imagens do Álbum de Brodatz

Textura D1	Textura D2	Textura D3	Textura D4	Textura D5	Textura D6
Textura D7	Textura D8	Textura D9	Textura D10	Textura D11	Textura D12
Textura D13	Textura D14	Textura D15	Textura D16	Textura D17	Textura D18
Textura D19	Textura D20	Textura D21	Textura D22	Textura D23	Textura D24
Textura D25	Textura D26	Textura D27	Textura D28	Textura D29	Textura D30
Textura D31	Textura D32	Textura D33	Textura D34	Textura D35	Textura D36
Textura D37	Textura D38	Textura D39	Textura D40	Textura D41	Textura D42
Textura D43	Textura D44	Textura D45	Textura D46	Textura D47	Textura D48

Textura D49	Textura D50	Textura D51	Textura D52	Textura D53	Textura D54
Textura D55	Textura D56	Textura D57	Textura D58	Textura D59	Textura D60
Textura D61	Textura D62	Textura D63	Textura D64	Textura D65	Textura D66
Textura D67	Textura D68	Textura D69	Textura D70	Textura D71	Textura D72
Textura D73	Textura D74	Textura D75	Textura D76	Textura D77	Textura D78
Textura D79	Textura D80	Textura D81	Textura D82	Textura D83	Textura D84
Textura D85	Textura D86	Textura D87	Textura D88	Textura D89	Textura D90
Textura D91	Textura D92	Textura D93	Textura D94	Textura D95	Textura D96

Textura D97	Textura D98	Textura D99	Textura D100	Textura D101	Textura D102
Textura D103	Textura D104	Textura D105	Textura D106	Textura D107	Textura D108
Textura D109	Textura D110	Textura D111			

ANEXO B - 240 imagens do minério vermiculita

TC1C1_I1	TC1C1_I2	TC1C1_I3	TC1C1_I4	TC1C1_I5	TC1C1_I6
TC1C1_I7	TC1C1_I8	TC1C1_I9	TC1C1_I10	TC1C2_I1	TC1C2_I2
TC1C2_I3	TC1C2_I4	TC1C2_I5	TC1C2_I6	TC1C2_I7	TC1C2_I8
TC1C2_I9	TC1C2_I10	TC1C3_I1	TC1C3_I2	TC1C3_I3	TC1C3_I4
TC1C3_I5	TC1C3_I6	TC1C3_I7	TC1C3_I8	TC1C3_I9	TC1C3_I10
TC1C4_I1	TC1C4_I2	TC1C4_I3	TC1C4_I4	TC1C4_I5	TC1C4_I6
TC1C4_I7	TC1C4_I8	TC1C4_I9	TC1C4_I10	TC1C5_I1	TC1C5_I2
TC1C5_I3	TC1C5_I4	TC1C5_I5	TC1C5_I6	TC1C5_I7	TC1C5_I8

TC1C5_I9	TC1C5_I10	TC1C6_I1	TC1C6_I2	TC1C6_I3	TC1C6_I4
TC1C6_I5	TC1C6_I6	TC1C6_I7	TC1C6_I8	TC1C6_I9	TC1C6_I10
TC1C7_I1	TC1C7_I2	TC1C7_I3	TC1C7_I4	TC1C7_I5	TC1C7_I6
TC1C7_I7	TC1C7_I8	TC1C7_I9	TC1C7_I10	TC1C8_I1	TC1C8_I2
TC1C8_I3	TC1C8_I4	TC1C8_I5	TC1C8_I6	TC1C8_I7	TC1C8_I8
TC1C8_I9	TC1C8_I10	TC2C1_I1	TC2C1_I2	TC2C1_I3	TC2C1_I4
TC2C1_I5	TC2C1_I6	TC2C1_I7	TC2C1_I8	TC2C1_I9	TC2C1_I10
TC2C2_I1	TC2C2_I2	TC2C2_I3	TC2C2_I4	TC2C2_I5	TC2C2_I6

TC2C2_I7	TC2C2_I8	TC2C2_I9	TC2C2_I10	TC2C3_I1	TC2C3_I2
TC2C3_I3	TC2C3_I4	TC2C3_I5	TC2C3_I6	TC2C3_I7	TC2C3_I8
TC2C3_I9	TC2C3_I10	TC2C4_I1	TC2C4_I2	TC2C4_I3	TC2C4_I4
TC2C4_I5	TC2C4_I6	TC2C4_I7	TC2C4_I8	TC2C4_I9	TC2C4_I10
TC2C5_I1	TC2C5_I2	TC2C5_I3	TC2C5_I4	TC2C5_I5	TC2C5_I6
TC2C5_I7	TC2C5_I8	TC2C5_I9	TC2C5_I10	TC2C6_I1	TC2C6_I2
TC2C6_I3	TC2C6_I4	TC2C6_I5	TC2C6_I6	TC2C6_I7	TC2C6_I8
TC2C6_I9	TC2C6_I10	TC2C7_I1	TC2C7_I2	TC2C7_I3	TC2C7_I4

TC2C7_I5	TC2C7_I6	TC2C7_I7	TC2C7_I8	TC2C7_I9	TC2C7_I10
TC2C8_I1	TC2C8_I2	TC2C8_I3	TC2C8_I4	TC2C8_I5	TC2C8_I6
TC2C8_I7	TC2C8_I8	TC2C8_I9	TC2C8_I10	TC3C1_I1	TC3C1_I2
TC3C1_I3	TC3C1_I4	TC3C1_I5	TC3C1_I6	TC3C1_I7	TC3C1_I8
TC3C1_I9	TC3C1_I10	TC3C2_I1	TC3C2_I2	TC3C2_I3	TC3C2_I4
TC3C2_I5	TC3C2_I6	TC3C2_I7	TC3C2_I8	TC3C2_I9	TC3C2_I10
TC3C3_I1	TC3C3_I2	TC3C3_I3	TC3C3_I4	TC3C3_I5	TC3C3_I6
TC3C3_I7	TC3C3_I8	TC3C3_I9	TC3C3_I10	TC3C4_I1	TC3C4_I2

TC3C4_I3	TC3C4_I4	TC3C4_I5	TC3C4_I6	TC3C4_I7	TC3C4_I8
TC3C4_I9	TC3C4_I10	TC3C5_I1	TC3C5_I2	TC3C5_I3	TC3C5_I4
TC3C5_I5	TC3C5_I6	TC3C5_I7	TC3C5_I8	TC3C5_I9	TC3C5_I10
TC3C6_I1	TC3C6_I2	TC3C6_I3	TC3C6_I4	TC3C6_I5	TC3C6_I6
TC3C6_I7	TC3C6_I8	TC3C6_I9	TC3C6_I10	TC3C7_I1	TC3C7_I2
TC3C7_I3	TC3C7_I4	TC3C7_I5	TC3C7_I6	TC3C7_I7	TC3C7_I8
TC3C7_I9	TC3C7_I10	TC3C8_I1	TC3C8_I2	TC3C8_I3	TC3C8_I4
TC3C8_I5	TC3C8_I6	TC3C8_I7	TC3C8_I8	TC3C8_I9	TC3C8_I10