

**UNIVERSIDADE DE SÃO PAULO  
ESCOLA DE ENGENHARIA DE SÃO CARLOS  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**PEDRO IVO DE CASTRO OYAMA**

**Método para classificação de café em grãos por imagens  
digitais pelo uso de atributos selecionados de morfologia, cor e  
textura**

**São Carlos**

**2014**



PEDRO IVO DE CASTRO OYAMA

**Método para classificação de café em grãos por imagens digitais pelo uso de atributos selecionados de morfologia, cor e textura<sup>1</sup>**

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

Área de concentração: Processamento de Sinais e Instrumentação

Orientador: Prof. Dr. Evandro Luis Linhari Rodrigues

**São Carlos**

**2014**

---

<sup>1</sup> 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 DESTA TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Oyama, Pedro Ivo de Castro

0985m

Método para classificação de café em grãos por imagens digitais pelo uso de atributos selecionados de morfologia, cor e textura / Pedro Ivo de Castro Oyama; orientador Evandro Luís Linhari Rodrigues. São Carlos, 2014.

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, 2014.

1. Classificação de grãos de café.
2. Redes neurais.
3. Visão computacional.
4. Reconhecimento de Padrões.
5. Textura. I. Título.

## FOLHA DE JULGAMENTO

Candidato: Engenheiro **PEDRO IVO DE CASTRO OYAMA.**

Título da dissertação: Método para classificação de café em grãos por imagens digitais pelo uso de atributos selecionados de morfologia, cor e textura".

Data da defesa: 31/07/2014

### Comissão Julgadora:

### Resultado:

Prof. Associado **Evandro Luis Linhari Rodrigues**  
**(Orientador)**  
(Escola de Engenharia de São Carlos/EESC)

Aprovado

Dr. **Lúcio André de Castro Jorge**  
(Empresa Brasileira de Pesquisa Agropecuária/EMBRAPA)

Aprovado

Dr. **Ednaldo José Ferreira**  
(Empresa Brasileira de Pesquisa Agropecuária/EMBRAPA)

Aprovado

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

Presidente da Comissão de Pós-Graduação:  
Prof. Associado **Paulo César Lima Segantine**

Folha 10/10  
31/07/2014



# AGRADECIMENTOS

Ao Prof. Dr. Evandro, pela orientação e por todo seu apoio.

Ao Dr. Lúcio, pelas oportunidades concedidas e pela coorientação.

À Escola de Engenharia de São Carlos, por toda estrutura oferecida para o desenvolvimento do mestrado.

À Cooxupé, pelo apoio financeiro concedido por intermédio da Fundação para o Incremento da Pesquisa e do Aperfeiçoamento Industrial.

À Embrapa Instrumentação, pela disponibilização de recursos, de pessoal e do laboratório.

À minha família e aos meus amigos, pelo apoio constante em toda minha vida.





# RESUMO

OYAMA, P.I.C. **Método para classificação de café em grãos por imagens digitais pelo uso de atributos selecionados de morfologia, cor e textura**. 2014. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade São Paulo, São Carlos, 2014.

A análise da qualidade de grãos é um dos gargalos encontrados na cadeia produtiva do setor cafeeiro, tendo em vista que atualmente é feita de forma manual. Buscando uma solução para o problema, este trabalho apresenta um método baseado em visão computacional e redes neurais artificiais para identificar vinte e uma classes de grãos de café em amostras. No total, 421 atributos de três diferentes naturezas – morfologia, cor e textura – foram reunidos para compor o conjunto de características utilizado pela rede neural. Os atributos morfológicos são: Descritores de Fourier, Descritores Genéricos de Fourier, Momentos de Zernike, elementos do Modelo Autorregressivo e um conjunto de atributos diversos. Após avaliar duas abordagens para os atributos de cor – histogramas de frequências de cor e atributos estatísticos desses histogramas – a segunda foi escolhida e, assim, os atributos de cor adotados foram: média, variância, obliquidade, energia, curtose, entropia e suavidade de histogramas globais de cor, calculados para os espaços de cor RGB, HSV,  $I_1I_2I_3$  e CIELAB. Visando um melhor desempenho, os descritores de Haralick foram modificados para que dois pixels de referência fossem utilizados no cálculo da matriz de coocorrência. A versão modificada dos descritores superou as originais, e assim, seus valores calculados com o espaço de cor  $I_1I_2I_3$  (aquele que apresentou melhor eficácia em testes) foram utilizados como atributos de textura. O conjunto de atributos foi arranjado em cinco subconjuntos, cada um contendo diferentes combinações das distintas naturezas de atributos e sendo associado a uma análise. Para cada subconjunto selecionaram-se os melhores elementos pelas técnicas chi-quadrado, ganho de informação e PCA (Principal Component Analysis). O resultado dessa seleção determinou as entradas para três processos classificatórios, que foram avaliados a fim de se determinar o mais efetivo. Após as avaliações, e sendo determinada a melhor configuração, o processo classificatório escolhido proporcionou a acurácia de 85,08%, superando trabalhos correlatos.

palavras-chave: classificação de grãos de café, redes neurais, visão computacional, reconhecimento de padrões, textura



# ABSTRACT

OYAMA, P.I.C. **Method for coffee beans classification through digital images using selected morphological, colour and textural attributes**. 2014. Dissertation (Master) – Escola de Engenharia de São Carlos, Universidade São Paulo, São Carlos, 2014.

The quality assessment of beans is one of the bottlenecks found in the production chain of the coffee industry, as nowadays it is done manually. Seeking a solution for the problem, this work presents a method based on computer vision with neural networks to identify twenty-one classes of coffee beans in samples. In total, 421 features of three different types – morphological, colour and textural – were gathered to compose the feature set used by the neural network. The morphological features were Fourier Descriptors, Generic Fourier Descriptors, Zernike Moments, elements from Autoregressive Model and a miscellaneous set. After evaluating two approaches of colour features – colour frequency histograms and statistics from those histograms – the latter was chosen and the colour features comprised the mean, variance, skewness, kurtosis, energy, entropy and smoothness of global histograms calculated for the channels of the RGB, HSV,  $I_1I_2I_3$  and CIELAB colour spaces. Seeking better performance the Haralick features were modified, so two pixels were used as reference in the computation of the Grey Level Co-occurrence Matrix. The modified versions of the features outperformed the original ones and their computations with the  $I_1I_2I_3$  colour space (the one that provided the best results in tests) were used as textural features. The feature set was then rearranged in five intersecting subsets, each one containing different combinations of the feature types and being associated with an analysis. For each subset the best elements were selected using the techniques PCA (Principal Component Analysis), chi-squared and information gain. The resulting selections were used to determine the inputs to three classification processes, which were evaluated in order to select the most effective. After all evaluations, and having determined the best configuration, the selected classification process yielded an overall accuracy of 85.08%, outperforming related works.

Keywords: coffee bean classification, neural networks, computer vision, pattern recognition, texture



# LISTA DE FIGURAS

Figura 1 – Representação do Perceptron .....	36
Figura 2 – Topologia de uma PMC .....	37
Figura 3 – Cubo RGB .....	40
Figura 4 – Espaço de cor YUV .....	41
Figura 5 – Espaço de cor YIQ .....	42
Figura 6 – Espaço de cor YDbDr .....	43
Figura 7 – Espaço de cor YPbPr .....	44
Figura 8 – Espaço de cor YCbCr .....	45
Figura 9 – Espaço de cor YCgCr .....	46
Figura 10 – Espaço de cor XYZ .....	47
Figura 11 – Espaço de cor CIELAB .....	48
Figura 12 – Espaço de cor HSV .....	49
Figura 13 – Espaço de cor $I_1I_2I_3$ .....	50
Figura 14 – Espaço de cor rgb por duas perspectivas.....	51
Figura 15 – Mapeamento de coordenadas utilizado pelo DGF. ....	53
Figura 16 – Orientação do objeto e sistema alternativo de coordenadas.....	58
Figura 17 – Relação entre o pixel de referência (PR) e o pixel vizinho ( $PV_i$ ) para $d = 1$ ..	60
Figura 18 – Formato de uma GLCM para uma imagem com 3 níveis de cinza.....	61
Figura 19 – Função de densidade da distribuição $\chi^2$ , para vários graus de liberdade k.....	68
Figura 20 – Função distribuição acumulada da distribuição $\chi^2$ , para vários graus de liberdade k.....	69
Figura 21 – Classes de grãos e impurezas. ....	72
Figura 22 – Fluxograma do método .....	77
Figura 23 – Estrutura interna do aparato de captura de imagens.....	80
Figura 24 – Grãos identificados e rotulados .....	82
Figura 25 – Utilização de dois pixels de referência para o cálculo da GLCM.....	90
Figura 26 – GLCM para 2 níveis de cinza utilizando a abordagem de dois pixels de referência. ....	91
Figura 27 – Comparação de simetrias no cálculo das GLCM. ....	92
Figura 28 – As três configurações de simetria para a GLCM utilizando dois pixels de referência. ....	92

Figura 29 – Simetria diagonal para os pixels PV_8, PV_0, PV_3 e PV_5.....	93
Figura 30 – Processo classificatório envolvendo análises paralelas de cor, morfologia e textura.....	108
Figura 31 – Treinamento e avaliação do processo classificatório $P_{M+C+T}$ .....	109
Figura 32 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_{MCT}$ .....	122

## LISTA DE GRÁFICOS

Gráfico 1 – Distribuição do número de amostras por classe .....	74
Gráfico 2 – Distribuição do número de amostras de grãos perfeitos por peneira .....	75
Gráfico 3 – Distribuição das amostras por classe, para o banco de atributos morfológicos .....	101
Gráfico 4 – Distribuição das amostras da classe Ovalado por classe original, para o banco de atributos morfológicos .....	101
Gráfico 5 – Distribuição das amostras da classe Perfeito por peneira, para o banco de atributos morfológicos .....	101
Gráfico 6 – Distribuição das amostras da classe Irregular por classe original, para o banco de atributos morfológicos .....	102
Gráfico 7 – Distribuição das amostras por classe, para os bancos de cor e textura .....	102
Gráfico 8 – Distribuição das amostras da classe fundida <b>Perfeito</b> por classe original e peneira, para os bancos de cor e textura .....	103
Gráfico 9 – Distribuição das amostras das classes fundidas <b>Marinheiro</b> e <b>Casca</b> por classe original, para os bancos de cor e textura .....	103
Gráfico 10 – Distribuição das amostras por classe, para o banco de atributos morfológicos, de cor e de textura.....	104
Gráfico 11 – Distribuição das amostras da classe Perfeito por peneira, para o banco de atributos morfológicos, de cor e de textura .....	104
Gráfico 12 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_M$ .....	116
Gráfico 13 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_C$ .....	118
Gráfico 14 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_T$ .....	119
Gráfico 15 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_{CT}$ .....	121





## LISTA DE TABELAS

Tabela 1 – Distribuição do número de amostras por classe .....	73
Tabela 2 – Distribuição do número de amostras de grãos perfeitos por peneira.....	75
Tabela 3 – Acurácias para cada espaço de cor, das classificações utilizando histogramas de frequências normalizadas das cores do grão como vetor de características .....	86
Tabela 4 – Acurácias (em %), para cada vetor de características avaliado, das classificações utilizando descritores de Haralick .....	89
Tabela 5 – Atualização da GLCM para cada posição do pixel vizinho .....	93
Tabela 6 – Acurácias (em %), para cada vetor de características avaliado, das classificações utilizando descritores de Haralick com 2 pixels de referência. Comparadas com as respectivas acurácias dos descritores calculados com 1 pixel de referência .....	98
Tabela 7 – Relação das classes discrimináveis em cada análise .....	99
Tabela 8 – Classes fundidas para cada análise .....	100
Tabela 9 – Classes de cada análise .....	100
Tabela 10 – Número de amostras disponíveis para cada análise.....	104
Tabela 11 – Acurácias para cada espaço de cor, das classificações utilizando histogramas de frequências normalizadas das cores do grão como vetor de características .....	111
Tabela 12 – Comparação das acurácias obtidas pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência .....	113
Tabela 13 – Comparação das precisões médias obtidas pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência.....	113
Tabela 14 – Comparação dos recalls médios obtidos pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência .....	113
Tabela 15 – Comparação das F-Measures médias obtidas pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência.....	113
Tabela 16 – Quinze primeiros atributos das ordenações por chi-quadrado e por ganho de informação (G.I.) para cada análise.....	114
Tabela 17 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_M$ .....	115
Tabela 18 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_C$ . .....	117

Tabela 19 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_T$ .....	119
Tabela 20 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_{CT}$ .....	120
Tabela 21 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise $A_{MCT}$ .....	122
Tabela 22 – Resumo do processo de seleção de atributos .....	123
Tabela 23 – Recalls das classes dos Processos Classificatórios .....	124
Tabela 24 – Matriz de confusão do processo classificatório proposto. ....	126
Tabela 25 - Recalls do processo classificatório proposto. ....	126
Tabela 26 – Dez maiores confusões entre classes.....	127
Tabela 27 - Notação dos atributos utilizada nas tabelas de ordenações.....	137
Tabela 28 – Ordenação dos atributos da análise $A_M$ pelos algoritmos Ganho de Informação e chi-quadrado.....	138
Tabela 29 – Ordenação dos atributos da análise $A_C$ pelos algoritmos Ganho de Informação e chi-quadrado.....	140
Tabela 30 – Ordenação dos atributos da análise $A_T$ pelos algoritmos Ganho de Informação e chi-quadrado.....	141
Tabela 31 – Ordenação dos atributos da análise $A_{CT}$ pelos algoritmos Ganho de Informação e chi-quadrado.....	143
Tabela 32 – Ordenação dos atributos da análise $A_{MCT}$ pelos algoritmos Ganho de Informação e chi-quadrado .....	145

# LISTA DE SIGLAS

CIE XYZ	Espaço de cor cujos canais são X, Y e Z
CIELAB	Espaço de cor cujos canais são L, a* e b*
DGFs	Descritores Genéricos de Fourier
GLCM	Matriz de co-ocorrência de níveis de cinza, do inglês Grey Level Co-occurrence Matrix
HSV	Espaço de cor cujos canais são H, S e V
I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	Espaço de cor cujos canais são I <sub>1</sub> , I <sub>2</sub> e I <sub>3</sub>
PCA	Análise de Componentes Principais, do inglês Principal Component Analysis
PMC	Perceptron Multicamadas
RGB	Espaço de cor cujos canais são R, G e B
rgb	Espaço de cor RGB normalizado cujos canais são r, g e b
TPFM	Transformada Polar de Fourier Modificada
YCbCr	Espaço de cor cujos canais são Y, Cb e Cr
YCgCr	Espaço de cor cujos canais são Y, Cg e Cr
YDbDr	Espaço de cor cujos canais são Y, Db e Dr
YIQ	Espaço de cor cujos canais são Y, I e Q
YPbPr	Espaço de cor cujos canais são Y, Pb e Pr
YUV	Espaço de cor cujos canais são Y, U e V



# SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	25
1.1. Objetivos.....	26
1.2. Estado da Arte .....	26
1.3. Organização do Trabalho.....	34
<b>2. FUNDAMENTAÇÃO TEÓRICA</b> .....	35
2.1. Redes Neurais Artificiais.....	35
2.2. Espaços de Cor .....	39
2.2.1. RGB.....	39
2.2.2. YUV .....	40
2.2.3. YIQ.....	41
2.2.4. YDbDr.....	42
2.2.5. YPbPr .....	43
2.2.6. YCbCr .....	44
2.2.7. YCgCr .....	45
2.2.8. CIE XYZ .....	46
2.2.9. CIELAB .....	47
2.2.10. HSV .....	48
2.2.11. $I_1I_2I_3$ .....	50
2.2.12. RGB normalizado (rgb).....	51
2.3. Atributos Morfológicos .....	51
2.3.1. Assinaturas .....	52
2.3.2. Descritores de Fourier .....	52
2.3.3. Descritores Genéricos de Fourier (DGFs).....	53
2.3.4. Modelo Autorregressivo.....	54
2.3.5. Momentos de Zernike.....	56

2.3.6.	Atributos Unitários .....	57
2.4.	Descritores de Haralick .....	59
2.5.	Análise de Componentes Principais (PCA) .....	64
2.6.	Seleção de Atributos .....	65
2.6.1.	Ganho de Informação .....	65
2.6.2.	Chi-quadrado .....	67
<b>3.</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>71</b>
3.1.	Especificação do Software .....	71
3.2.	Amostras .....	72
3.3.	Visão geral do método .....	75
3.4.	Crítérios de Avaliação.....	77
3.5.	Topologia das Redes Neurais.....	79
3.6.	Hardware e Aquisição de Imagens .....	79
3.7.	Segmentação e Individualização .....	80
3.8.	Criação de um Banco de Dados de Amostras .....	82
3.9.	Caracterização dos Atributos .....	83
3.9.1.	Atributos Morfológicos .....	83
3.9.2.	Atributos de Cor .....	84
3.9.3.	Atributos de Textura .....	88
3.10.	Definição das Classes.....	98
3.11.	Seleção de Atributos .....	105
3.12.	Definição do Processo Classificatório .....	106
<b>4.</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	<b>111</b>
4.1.	Classificação por Histogramas de Frequências Normalizadas de Cores .....	111
4.2.	Modificação dos Descritores de Haralick .....	112
4.3.	Seleção de Atributos .....	114
4.4.	Definição do Processo Classificatório .....	124

<b>5. CONCLUSÕES</b> .....	129
<b>6. TRABALHOS PUBLICADOS</b> .....	131
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	133
<b>APÊNDICE</b> .....	137





# 1. INTRODUÇÃO

Desde o século XIX o Brasil tem se destacado na produção e exportação do café, e atualmente ocupa a primeira posição mundial tanto na produção como na exportação do produto, contando com cerca de 30% do total das exportações mundiais do café (INTERNATIONAL COFFEE ORGANIZATION, 2014a; b). Devido à alta exigência do mercado internacional por produtos de qualidade, o café brasileiro exportado necessita passar por um rígido controle de qualidade, o qual deve ser preciso e rápido, dado o grande volume do produto que deve ser avaliado. Esse controle diz respeito tanto ao café em pó quanto ao grão antes da torrefação e da moagem.

Um dos desafios que as cooperativas de café enfrentam atualmente é avaliar a qualidade das safras de seus associados no ritmo imposto pelo processo produtivo, de modo que eles saibam prontamente o valor do seu produto. Essa informação deve ser obtida rapidamente, já que o preço pelo qual essas commodities são negociadas podem ser muito voláteis. A qualidade de uma safra geralmente é avaliada pela análise de pequenas amostras, visando identificar e quantificar grãos defeituosos e impurezas, os quais podem depreciar sobremaneira o sabor e o aroma da bebida produzida, e conseqüentemente seu valor. Grãos defeituosos são aqueles que apresentam alterações físicas e químicas comprometedoras, e podem ser provenientes de diversos fatores ocorridos durante o ciclo de vida do café, do cultivo e da colheita, ao beneficiamento e armazenamento. Impurezas são qualquer corpo estranho que não é café encontrado junto dos grãos. A qualidade da amostra é dada de maneira quantitativa ao se computar o número de ocorrências dos diversos tipos de defeitos e impurezas, os quais geralmente têm pesos diferentes na contagem, já que podem depreciar a bebida em proporções distintas.

Atualmente, a avaliação de qualidade é feita visualmente por especialistas e apresenta as seguintes desvantagens: a análise é dependente da interpretação subjetiva do avaliador, de modo que diferentes avaliadores podem dar diferentes diagnósticos para a mesma amostra; é um processo lento, já que cada grão deve ser avaliado individualmente; e a qualidade da análise se deprecia ao decorrer do turno de trabalho, por fatores envolvendo, principalmente, a fadiga.

Essas questões fazem dessa análise um processo caro e não totalmente confiável, dadas as subjetividades envolvidas.

Em geral, os métodos automáticos de classificação aparecem em máquinas e sistemas para aplicação no processo de produção de beneficiadoras de sementes. No laboratório, a análise de amostras continua sendo feita de forma subjetiva e manual.

Neste contexto, o presente trabalho propõe um método para análise de amostras de café em grãos pela análise de imagens digitais, a fim de se aumentar a velocidade e reduzir as subjetividades envolvidas no atual processo manual de classificação.

### **1.1.Objetivos**

O objetivo deste trabalho foi desenvolver um método para a classificação de grãos de café em uma amostra por meio de processamento de imagem digital.

Dada a imagem de uma amostra, com grãos que não se tocam, cada um dos objetos deve receber uma classificação, de acordo com as regras de análise comumente adotadas pela indústria de café, com a maior acurácia possível.

### **1.2.Estado da Arte**

Apesar de o problema já ter sido explorado por grupos que desenvolveram produtos e patentes relacionados, não há muitos trabalhos acadêmicos tratando a classificação de café por processamento digital de imagens na literatura. Por outro lado, muitos trabalhos abordando problemas correlatos de classificação de grãos e sementes têm sido desenvolvidos dentro e fora do país. Problemas desse tipo têm sido alvo de estudos há pelo menos quatro décadas e, a fim de se traçar um panorama geral sobre o que tem sido desenvolvido, um breve resumo englobando alguns trabalhos publicados ao decorrer desse período será apresentado nesta seção.

Brogan e Edison (1974) apresentaram um dos trabalhos pioneiros no uso de visão computacional na classificação de grãos. Eles utilizaram os atributos morfológicos comprimento, largura e espessura, e algumas de suas combinações, como por exemplo largura/comprimento, para determinar a composição de amostras de grãos. As amostras podiam

conter grãos de milho, trigo, soja, cevada, aveia e centeio. Mesmo sendo um dos trabalhos precursores da área, seu método obteve bons resultados, com a acurácia de cerca de 98%.

Neuman et al. (1989a) analisaram amostras de 10 diferentes variedades de sementes de trigo, arranjadas em 6 categorias mais abrangentes. Com um lote de sementes, calcularam os valores médios dos canais R, G e B para cada variedade, assim como as respectivas variâncias. Com os resultados, constatou-se a possibilidade de se discriminar as sementes de diferentes categorias por meio dos valores médios dos elementos do sistema RGB. Na continuação do trabalho (NEUMAN et al., 1989b), os valores obtidos no primeiro estudo foram utilizados para gerar funções discriminantes. Um segundo lote de sementes foi utilizado para validar o método. Aplicando-se o método para diferenciar grãos em uma amostra contendo apenas sementes de duas categorias distintas (realizando um experimento para cada uma das 30 combinações possíveis) obteve-se uma acurácia média de 88% em relação a todos os experimentos. Classificando-se uma amostra contendo sementes de todas as seis categorias a acurácia foi de 66,6%.

Chtioui et al. (1996) classificaram sementes em amostras contendo quatro espécies diferentes: rumex, aveia selvagem, alfafa e vicia. A classificação foi realizada analisando atributos morfológicos, como Descritores de Fourier e momentos invariantes, totalizando 25 atributos. Também foram utilizados atributos de textura calculados a partir de histogramas locais (média, variância, energia, entropia, curtose e obliquidade) e cinco dos descritores de Haralick (HARALICK; SHANMUGA.K; DINSTEIN, 1973) (energia, contraste, correlação, entropia e momento inverso de diferenças). Os atributos de textura foram calculados para os três canais do modelo RGB e para o modelo em tons de cinza, totalizando, portanto, 44 atributos. Esse conjunto de atributos foi então utilizado em dois métodos de classificação: análise discriminante stepwise (MCLACHLAN, 2004) e redes neurais perceptron multicamadas (PMC). Em classificações-teste o primeiro método obteve 98,4% de acurácia e o segundo 100%.

Ahmad et al. (1999) utilizaram um sistema de visão computacional para discriminar grãos de soja sintomáticos (dentre oito doenças) e não sintomáticos. De cada semente foi extraída uma janela amostral (de 15x15 pixels), com as quais foram calculadas seis características de cor – valores máximo e mínimo, média, variância, mediana e desvio padrão – para cada um dos componentes RGB. Com o uso da correlação de Pearson, o conjunto de características foi reduzido pela metade, eliminando-se variáveis com alta correlação. Os atributos mantidos

foram os mínimos, médias e variâncias. Com eles foram gerados classificadores pela análise discriminante stepwise. Os testes revelaram, no melhor caso, uma acurácia de 67,16%.

No trabalho de Majumdar e Jayas (2000a) foram utilizadas características de forma para diferenciar sementes em amostras contendo duas variedades de trigo, uma de cevada, uma de aveia e uma de centeio. De um lote de sementes, foram calculadas 23 características para cada grão, das quais foram selecionadas as 10 mais significativas pela análise discriminante stepwise. Dentre as selecionadas estavam: maior e menor raios, os primeiros momentos invariantes e o primeiro Descritor de Fourier. A classificação foi realizada utilizando-se análise discriminante com o conjunto de características selecionadas. A acurácia do método foi de 96%.

O trabalho anterior foi estendido por Majumdar e Jayas (2000b), tratando o mesmo problema com métodos análogos, porém com o uso de características de cores. De 18 atributos de cor extraídos das sementes (média, variância e intervalo de variação das componentes RGB e HSI), foram determinadas as 10 mais significativas, as quais foram utilizadas na classificação pela análise discriminante. O resultado foi uma acurácia de 94,88%.

Majumdar e Jayas (2000c) deram continuidade aos métodos descritos anteriormente, realizando a classificação por atributos de textura. Alguns parâmetros definidos para análise de textura foram variados para encontrar sua melhor combinação. Foi avaliado o uso de diferentes números máximos de tons de cinza: 32, 16, 8 e 4. Além disso, diferentes canais de cor pelas quais são calculados os descritores foram testados: os canais do modelo RGB e algumas combinações entre elas, por exemplo,  $(R + G + B) / 3$ . Um total de 25 atributos de textura foram utilizados, dentre eles atributos derivados de matrizes de coocorrência de níveis de cinza, apresentados por Haralick, Shanmuga e Dinstein (1973) e atributos derivados de matrizes de comprimento de primitiva a nível de cinza, desenvolvidos por Galloway (1975). O número de atributos foi reduzido para 15 aplicando a análise discriminante stepwise, e estes atributos foram utilizados no classificador baseado em análise discriminante. Uma bateria de classificações foi conduzida contemplando todas as combinações de parâmetros. O melhor resultado foi obtido fazendo a análise no canal G com um máximo de 8 tons, gerando a acurácia de 91,94%.

Um estudo avaliando combinações das três abordagens anteriores foi conduzido por Majumdar e Jayas (2000d). Foram realizados testes de classificação utilizando todas as possíveis combinações de dois conjuntos de atributos: morfologia e textura (combinação A); morfologia e cor (combinação B); e textura e cor (combinação C). Também foi testada a combinação de todos os conjuntos – morfologia, cor e textura (combinação D). No caso de combinações de dois conjuntos, as classificações foram realizadas pelo uso dos 15 atributos

mais discriminantes, enquanto que quando todos os conjuntos foram considerados os 20 atributos mais discriminantes foram adotados. As acurácias obtidas com as combinações A, B, C e D foram, respectivamente, 98,6%, 99,4%, 98,4 e 99,7%. Assim, para o problema apresentado, a classificação mostrou-se mais acurada para a combinação D, ou seja, utilizando a combinação de todos os tipos de atributos.

Carter, Yan e Tomlins (2006) publicaram um trabalho de análise de amostras de grãos de arroz por imagens digitais. Nele é apresentado um procedimento de visão computacional para determinar em uma amostra o número de grãos de arroz de cada um dos três possíveis tipos (em porcentagem). De um conjunto de amostras de sementes foram extraídas diversas características morfológicas de cada grão, incluindo razão de aspecto, e maior e menor eixos. Com esses dados foram calculados seus respectivos histogramas (com cinco intervalos) e seus valores médios para cada classe, gerando uma base de dados. Depois da aplicação da PCA (Principal Component Analysis) (JOLLIFFE, 2005) foram selecionadas as seis componentes principais mais discriminantes dentre as resultantes. Essas componentes principais foram definidas como as variáveis de entrada de um sistema fuzzy (COX et al., 1998), e para cada uma delas foi desenvolvida uma função de pertinência. O software desenvolvido utilizou as funções para classificar individualmente os grãos de uma amostra. Várias classificações de amostras contendo combinação de dois tipos de sementes em proporções típicas foram realizadas para avaliar a eficácia do método, e foram obtidos resultados com erros situados entre 5% e 10%.

Khatchatourian e Padilha (2008) utilizaram redes neurais artificiais do tipo PMC para classificação de 8 variedades de soja por imagens digitais. Aplicando um método de detecção de bordas pelo filtro de Prewitt e operações morfológicas para eliminação de ruídos, amostras de grãos de soja foram segmentadas de uma imagem de fundo preto. Os grãos foram então individualizados e identificados. Cada um deles foi transcrito em uma matriz 130x130, dimensões previamente avaliadas para comportar qualquer grão, de modo que um elemento de valor 1 representa um pixel do grão e um elemento de valor 0 representa um pixel do fundo. Estas matrizes foram então transformadas em vetores de dimensão 16.900 para servirem como vetores de características. Uma rede neural que contava com três camadas escondidas com 90, 70 e 60 neurônios, foi treinada com 280 amostras. Utilizando a rede neural na classificação de um conjunto de amostras diferentes das utilizadas no treinamento, os autores obtiveram a acurácia de 57,5%.

Choudhary, Paliwal e Jayas (2008) utilizaram técnicas de visão computacional para diferenciar sementes em amostras contendo duas variedades de trigo, uma de cevada, uma de aveia e uma de centeio. O método utilizou 51 características morfológicas, 93 de cor, 56 de textura e 135 relacionadas a wavelets. Wavelets são uma ferramenta de análise de sinais que, dentre outras possibilidades, permite caracterizar texturas em múltiplas resoluções por meio de sucessivas decomposições (GONZALEZ; WOODS, 2008a). Os pixels das sementes foram passados para os distintos canais de três espaços de cor – RGB, HSI, e CIELAB. Em cada um dos canais foi aplicada uma transformada wavelet discreta, decompondo a imagem original em três outras de resoluções diferentes. Para cada uma das decomposições foram calculadas 3 características de energia e 3 de correlação. Assim, foram obtidos os 135 atributos de wavelet. As características morfológicas, de cor e de textura foram obtidas de maneira semelhante aos calculados em outros artigos citados anteriormente. Com classificadores baseados em análise discriminante foram comparadas combinações diferentes de conjuntos de características de naturezas distintas. O melhor resultado foi obtido quando todos os conjuntos foram utilizados ao mesmo tempo, proporcionando uma acurácia de 97,0%. Apesar de a classificação utilizando somente os atributos wavelet ter gerado o pior resultado – acurácia de 75,1% – dois de seus elementos foram listados entre as 20 características mais discriminantes pela análise discriminante stepwise.

No trabalho de Carrillo e Peñaloza (2009) foram utilizados classificadores baseados na distância de Mahalanobis (MAHALANOBIS, 1936) para identificar seis classes de café em grão em uma amostra. A distância de Mahalanobis permite calcular a distância entre um grupo de valores e outro, ou entre um valor e um grupo de valores. Essa distância é calculada utilizando a covariância entre os grupos de valores e suas médias. Com um conjunto de amostras, foram extraídos os valores RGB de todos os pixels dos grãos presentes e estes foram agrupados por classes. A classificação foi então testada calculando-se a distância de Mahalanobis de cada pixel de um grão com cada um dos agrupamentos de pixels representativos das classes. O pixel recebeu a classificação do agrupamento que proporcionou a menor distância e, após a classificação de todos os pixels, ao grão foi atribuída a classe que possuía maior número de pixels. O recall médio desse método foi de 67,7%.

Chen et al. (2010) desenvolveram um método para classificação de grãos de milho de cinco variedades diferentes com imagens capturadas com um digitalizador de mesa. Inicialmente foram extraídas características geométricas, de cor e de forma, totalizando 58 atributos. Os atributos geométricos incluem área, perímetro, comprimento e larguras dos grãos em diferentes

pontos. Os de forma abrangem, entre outros, momentos invariantes e os primeiros coeficientes de Fourier. A cor foi tratada transformando-se o espaço RGB em outros quatro: RGB normalizado, YCbCr,  $I_1I_2I_3$  e HSV. As características de cor utilizadas foram desvios padrões e médias de componentes desses espaços de cor. Com o objetivo de melhorar a eficiência e a eficácia do método, o número de atributos foi reduzido utilizando a análise discriminante stepwise. O processo de classificação foi dividido em duas etapas, sendo que na primeira foram separadas três classes de grãos por intermédio de um classificador baseado no cálculo de distâncias Mahalanobis. A segunda etapa utilizou uma rede neural do tipo PMC para separar uma das classes determinadas no processo anterior em três outras. A acurácia obtida com o método foi de 94,8%.

Ahmad et al. (2010) apresentaram uma máquina para realizar a separação automática de grãos de café por visão computacional. O problema consistia em diferenciar entre quatro tipos de grãos, sendo três deles caracterizados pelo tamanho e o quarto (grão defeituoso), podendo ser definido por tamanho ou cor. Foram utilizados três atributos morfológicos (área, comprimento e perímetro), dois atributos de cor (citados pelos autores como índices de vermelho e verde) e mais um atributo definido como área defeituosa. 2000 amostras, uniformemente distribuídas entre as classes, foram utilizadas para treinar uma PMC, e 500 outras amostras, também uniformemente distribuídas, constituíram o conjunto de testes para avaliação do método. O resultado foi uma acurácia de 78,32%.

No trabalho de Arefi, Motlagh e Teimourlou (2011) foi realizada a identificação de quatro variedades de trigo iraniano em amostras. Para tanto foram utilizados atributos morfológicos e de cor, calculados a partir das representações das sementes em cinco espaços de cor distintos: RGB, HSI, RGB normalizado, YCrCgCb,  $I_1I_2I_3$  e CIELAB. Para cada grão de um conjunto de treinamento foram calculados os valores de média, desvio padrão, variância, obliquidade e curtose de cada um dos canais dos espaços de cores e foram escolhidos seis atributos para serem utilizados como entrada para uma rede neural, a saber: média(CIE-a\*), curtose(CIE-a\*), média(R-B), média(R-G), obliquidade(G) e variância(R-G). Dentre 10 atributos morfológicos foram escolhidos 6 para comporem o conjunto de entrada da rede neural: área, área/eixo maior, área/perímetro,  $\frac{4\pi \text{ área}}{\text{perímetro}^2}$ , eixo maior/ eixo menor e diâmetro do círculo de mesma área / eixo maior. Treinando uma rede neural artificial do tipo PMC com 280 amostras e classificando amostras-teste foi obtida a acurácia de 95,86%.

Faridah, Parikesit e Ferdiansjah (2013) apresentam um método para classificar amostras de café como um todo, ao invés de classificar seus grãos componentes individualmente. As

amostras deviam ser classificadas como pertencentes a uma dentre as sete possíveis categorias, de acordo com sua aparência. Foram utilizadas as médias dos canais R, G e B, juntamente com quatro descritores de Haralick (energia, entropia, contraste e homogeneidade) como entrada para redes neurais PMC. Os recalls obtidos para cada uma das categorias foram 100%, 80%, 60%, 40%, 100%, 40% e 100%, resultando no recall médio de 74,29%.

No trabalho de Delwiche, Yang e Graybosch (2013) é proposto um método para avaliação de grãos de trigo por meio de imagens tomadas de ângulos distintos. O objetivo do estudo foi discriminar os grãos entre duas classes: bons e defeituosos, sendo os possíveis defeitos a presença de bolor, ponta preta ou brotos. Com o uso de um jogo de espelhos, três imagens de perspectivas diferentes eram capturadas de grãos em queda-livre. De cada uma das imagens de um grão foram calculados os oito atributos morfológicos seguintes: área, perímetro, maior e menor eixos, excentricidade, solidez (área dividida pela área do menor polígono convexo a envolver o grão) e a razão maior eixo/ menor eixo e sua inversa. Também foram calculados cinco dos descritores de Haralick: contraste, correlação, energia, homogeneidade e entropia. Para cada um desses atributos foram calculados os valores máximo, mínimo e médio entre as três imagens para compor o conjunto de atributos. Os descritores de Fourier elípticos (KUHL; GIARDINA, 1982) foram calculados para apenas uma das imagens, e os coeficientes dos seus 10 primeiros harmônicos, e os valores das suas 5 primeiras componentes principais dos coeficientes simétricos foram adicionados ao conjunto, juntamente com o volume da revolução da elipse dada pelas médias dos eixos menores e maiores das três imagens. Utilizando a análise discriminante stepwise foram selecionados os atributos mais discriminantes – dois morfológicos e quatro de textura – e eles foram avaliados por dois métodos, análise discriminante stepwise e K-nearest neighbours. Os resultados proporcionaram acurácias entre 91% e 94%.

Valiente-Gonzalez et al. (2014) apresentaram um equipamento para a avaliação automática da qualidade de grãos de milho por imagem. O método proposto visava classificar grãos individualizados como “aceito” ou “rejeitado”. A análise foi realizada em duas etapas: na primeira pixels eram avaliados entre “bons” e “defeituosos”, e na segunda avaliava-se a proporção de pixels ruins no grão para determinar sua classificação. O vetor de características utilizado para classificar um pixel era composto pelas coordenadas do espaço de cor adotado de cada um dos pixels que compreendem uma janela 3x3. Com um conjunto de amostras de treinamento (somente de grãos “aceitos”) calcularam-se os valores médios de cada um dos elementos do vetor de características e os vetores de características foram então transformados



para que ficassem centrados na média de seus valores. Aplicou-se então a PCA nos vetores de características transformados, de modo que o resultado seria o modelo de pixels “bons”. A distribuição de Hotelling ( $T^2$ ), que determina a variação do pixel para o modelo, foi calculada para cada um dos pixels do conjunto de treinamento. Um threshold foi definido para  $T^2$  para que  $\tau\%$  dos pixels de treinamento tivessem seus  $T^2$  menores que o threshold, e os pixels com valores maiores seriam considerados defeituosos. A segmentação dos grãos foi feita de modo semelhante à determinação dos pixels defeituosos, pelo método conhecido como eigenbackgrounds (OLIVER; ROSARIO; PENTLAND, 2000). A porcentagem de pixels defeituosos ( $\varepsilon$ ) em cada um dos grãos do conjunto de treinamento foi calculada, e então calculou-se a média  $\bar{\varepsilon}$  dessas porcentagens. Definiu-se, então, um parâmetro  $\alpha$ , de modo que se um grão apresentasse  $\varepsilon > \alpha\bar{\varepsilon}$  ele seria considerado “rejeitado”. A partir desse método, utilizaram-se amostras de testes (200 grãos “aceitos” e 200 grãos “rejeitados”) para determinar os melhores valores para os parâmetros, o espaço de cor mais eficaz (entre RGB, HSV e CIELAB), e conseqüentemente a capacidade do método. O melhor resultado obtido foi 92% de acurácia, 92% de precisão e 91% de recall com o espaço de cor HSV,  $\tau = 95\%$  e  $\alpha = 1,2$ .

A abordagem adotada neste trabalho para tratar o problema de classificação de grãos de café foi extrair um conjunto de atributos morfológicos, de cor e de textura, e então agrupá-los em subconjuntos ( $\{\text{morfológicos}\}$ ,  $\{\text{cor}\}$ ,  $\{\text{textura}\}$ ,  $\{\text{cor e textura}\}$  e  $\{\text{morfológicos, cor e textura}\}$ ), associando cada um deles a uma análise baseada em redes neurais. Os atributos morfológicos eram: Descritores de Fourier, Descritores Genéricos de Fourier, Momentos de Zernike, elementos do Modelo Autorregressivo e um conjunto de atributos diversos. Os atributos de cor eram estatísticas extraídas de histogramas de cor de quatro espaços de cor. Os atributos de textura eram descritores de Haralick modificados para utilizar dois pixels de referência no cálculo das matrizes de co-ocorrência. Para cada subconjunto aplicaram-se técnicas de seleção, a fim de se definir os melhores atributos de cada análise. As análises foram combinadas em três diferentes configurações e avaliadas, determinando o método de classificação proposto.

### **1.3.Organização do Trabalho**

No Capítulo 2 são detalhados os fundamentos teóricos envolvidos nas técnicas e ferramentas utilizadas neste trabalho, abordando redes neurais artificiais, espaços de cores, os atributos utilizados e conceitos utilizados para seleção de atributos.

O método desenvolvido é apresentado no Capítulo 3, sendo definidos o material utilizado, os processos de captura de imagens, segmentação e individualização dos grãos. Também são definidos os atributos utilizados e como foram selecionados e o processo para definir o procedimento de classificação.

Os resultados dos experimentos realizados para avaliar o método são apresentados e discutidos no Capítulo 4.

O Capítulo 5 traz as conclusões obtidas do trabalho realizado e comentários gerais.

E, finalmente, o Capítulo 6 apresenta os trabalhos publicados em decorrência deste trabalho.

## **2.FUNDAMENTAÇÃO TEÓRICA**

Neste capítulo serão expostos brevemente os conceitos que contextualizam o problema abordado e o método proposto. Será apresentada a rede neural do tipo PMC, o classificador utilizado como base para as classificações. Também serão apresentados os espaços de cor utilizados para derivar os atributos de cor: RGB, YUV, YIQ, YDbDr, YPbPr, YCbCr, YCgCr, CIE XYZ, CIELAB, HSV,  $I_1I_2I_3$  e RGB normalizado. Também os atributos morfológicos utilizados no método: assinaturas, Descritores de Fourier, Modelo Autorregressivo, Momentos de Zernike, Descritores Genéricos de Fourier (DGF) e um conjunto de descritores compostos por somente um elemento. Serão apresentados os 14 descritores de Haralick, desenhados para representação de textura e modificados no método proposto visando se avaliar macro-texturas. Por fins, serão apresentados os conceitos utilizados para promover seleção de atributos: PCA (Principal Component Analysis), Ganho de Informação e Chi-quadrado.

### **2.1.Redes Neurais Artificiais**

Redes neurais artificiais do tipo Perceptron Multicamadas são modelos computacionais inspirados no modelo biológico de interligação entre neurônios, e visam promover o aprendizado de máquina. Dentre outras aplicações, elas são amplamente utilizadas na classificação de padrões, ou seja, indicar a que classe pertencem os dados de entrada. As PMCs são redes neurais cujo aprendizado é supervisionado, e, portanto, antes de realizar qualquer classificação é necessário um processo de treinamento no qual vários exemplos de dados pré-classificados são apresentados. As PMCs são constituídas de várias camadas de neurônios artificiais, os Perceptrons, os quais são ilustrados na Figura 1. (SILVA; SPATTI; FLAUZINO, 2010)

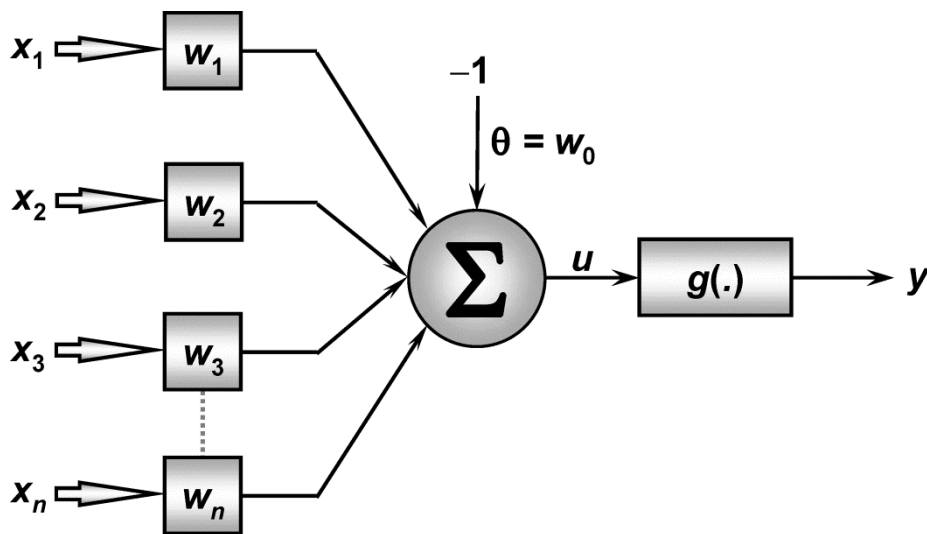


Figura 1 – Representação do Perceptron  
(SILVA; SPATTI; FLAUZINO, 2010)

O Perceptron recebe um conjunto de sinais de entrada ( $x_1, x_2, \dots, x_n$ ) e os transforma em um único sinal de saída  $y$ . Cada um dos sinais de entrada é multiplicado por seu respectivo peso sináptico ( $w_1, w_2, \dots, w_n$ ), e os resultados dessas operações são somados junto com o produto do limiar de ativação ( $\theta$ ) e seu peso sináptico ( $w_0$ ), cujo valor é  $-1$ , como determinado pela Equação (2.1). O resultado do somatório, chamado de potencial de ativação ( $u$ ), é passado como argumento para a função de ativação ( $g(\cdot)$ ), a qual definirá a saída  $y$  (Equação (2.2)). Os pesos sinápticos são ajustados automaticamente pelo processo de treinamento e, assim, o Perceptron é capaz de associar uma saída a um conjunto de valores de entrada, conforme o comportamento entrada-saída apresentado no treinamento.

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (2.1)$$

$$y = g(u) \quad (2.2)$$

As camadas de neurônios de uma PMC, e como elas são interligadas, são ilustrados na Figura 2. Há uma camada de entrada, por onde dados são fornecidos, uma de saída, por onde os resultados são apresentados, e pelo menos uma camada escondida (intermediária). As saídas de neurônios de uma camada são utilizadas como entrada para os neurônios da camada posterior, de forma sucessiva até o sinal chegar à camada de saída. O número de camadas

escondidas e o número de neurônios em cada uma devem ser definidos de acordo com a aplicação, e influenciam na taxa de sucesso da classificação (SILVA; SPATTI; FLAUZINO, 2010).




Figura 2 – Topologia de uma PMC  
(SILVA; SPATTI; FLAUZINO, 2010)

O algoritmo de treinamento de uma PMC mais comumente utilizado é o backpropagation (RUMELHART; HINTON; WILLIAMS, 1985). Ele exige um conjunto de amostras, as quais contêm valores de entrada e as respectivas saídas desejadas. Para cada amostra o conjunto de sinais de entrada é passado à rede neural e o conjunto de valores de saída é produzido como normalmente seria no modo de operação. As saídas são comparadas aos valores esperados e o erro obtido é retropropagado sucessivamente, camada a camada, ajustando-se os pesos sinápticos no processo a fim de se minimizar o erro. Uma execução desse processo para todo o conjunto de amostras é chamada de época. O algoritmo repete sucessivamente a execução de épocas até que um determinado critério de parada seja atingindo, o qual pode ser a obtenção de um erro satisfatoriamente pequeno ou a conclusão da execução de certo número de épocas.

Os principais parâmetros que devem ser especificados no treinamento pelo backpropagation são o critério de parada, a taxa de aprendizado ( $\eta$ ) e o momentum ( $\alpha$ ). Os dois últimos parâmetros podem ser melhor entendidos pelas Equações (2.3) e (2.4), adaptadas de Haykin (1999).

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (2.3)$$

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) - \eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (2.4)$$

Onde  $w_{ji}(n)$  é o peso sináptico na iteração  $n$  do neurônio  $j$  que está conectado ao neurônio  $i$  da camada anterior.  $\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}$  é o gradiente do erro na iteração  $n$ , que indica a direção de maior variação do erro. Uma iteração do treinamento é caracterizada como processamento de uma única amostra, e não deve ser confundida com o conceito de época.

Analisando as equações, primeiramente sem o uso do momentum ( $\alpha = 0$ ), constata-se que a taxa de aprendizado determina a magnitude com a qual o gradiente do erro é utilizado na atualização. Taxas de aprendizagem altas garantem que a cada atualização os pesos sinápticos sofram maiores alterações em direção ao erro mínimo, aumentando a velocidade do aprendizado, mas podem causar instabilidade e impossibilitar que um erro menor que um certo limite seja alcançado, uma vez que um grande incremento pode fazer com que o valor resultante vá além do valor que proporciona o erro mínimo. Por outro lado, taxas de aprendizagem baixas diminuem a possibilidade de instabilidade, mas exigem a execução de um número de épocas muito maior e torna o aprendizado mais suscetível a mínimos locais.

O momentum é um parâmetro responsável por tornar a aprendizagem mais eficiente. Quando ele é adotado, o algoritmo de aprendizagem passa a utilizar tanto a taxa de aprendizagem quanto o momentum para atualizar os pesos sinápticos. Para uma melhor compreensão de seu mecanismo, a Equação (2.4) pode ser reescrita em forma de série para  $\alpha \neq 0$ , conforme a Equação (2.5).

$$\Delta w_{ji}(n) = -\eta \sum_{t=0}^n \alpha^{n-t} \frac{\partial \varepsilon(t)}{\partial w_{ji}(t)} \quad (2.5)$$

Nota-se que quando o momentum é utilizado, a atualização do peso sináptico não é influenciada somente pelo valor do gradiente na iteração corrente, mas também por todos os seus valores em iterações anteriores. Como  $0 \leq |\alpha| < 1$ , os valores do gradiente têm seus pesos diminuídos exponencialmente conforme a distância entre suas correspondentes iterações e a iteração corrente aumenta. Como constatado por Jacobs (1988), pela Equação (2.5) pode-se

perceber que quando o gradiente mantém o mesmo sinal em atualizações consecutivas, o resultado do somatório aumenta em módulo, e conseqüentemente o ajuste do peso torna-se mais significativo, enquanto que quando os sinais do gradiente se opõem em atualizações consecutivas, o ajuste do peso é menos significativo.

## **2.2.Espaços de Cor**

Os seres humanos percebem cores por meio de células sensíveis a luz presentes na retina do olho. Essas células são denominadas cones e bastonetes, sendo os primeiros muito mais eficazes em proporcionar distinção de cores que os últimos, que são mais relacionados à visão noturna por serem mais sensíveis a baixos níveis de iluminação. Existem três tipos de cones, diferenciados pelo comprimento de onda que são capazes de estimulá-los. Os cones do tipo L são sensíveis a comprimentos de onda longos, referentes ao espectro de cores avermelhadas; os de tipo M são sensíveis a médios comprimentos de onda, referentes ao espectro de cores esverdeadas; e finalmente os de tipo S são sensíveis a comprimentos de onda curtos, referentes ao espectro de cores azuladas. Assim, as cores que percebemos estão relacionadas ao número de cones sensibilizados de cada tipo. Por exemplo, quando há muitos cones S sensibilizados, e poucos dos outros tipos, vemos uma cor de tonalidade azul.

Esta é a forma como o olho humano capta as cores. Para lidarmos matematicamente ou computacionalmente com elas, algum sistema semelhante deve ser utilizado, e esses sistemas são chamados de espaços de cor. Existem diversos deles na literatura, sendo que suas eficácias são dependentes da aplicação em que estão sendo empregadas. A seguir são apresentados os espaços de cor utilizados neste trabalho.

### **2.2.1. RGB**

O modelo RGB trata as cores da mesma forma como o olho humano as capta. As cores são representadas pelos canais R, G e B, que definem respectivamente intensidade com a qual as cores primárias vermelho, verde e azul estão presentes. Desta forma, ele é um modelo aditivo, já que a cor é representada pela soma dos valores de seus canais. Este espaço de cor pode ser representado por um cubo (conforme o apresentado na Figura 3), já que cada um dos canais variam de 0 a 255 (ou 0 a 1 em algumas representações). O RGB é importante porque é um dos principais espaços de cor utilizados no processo de captura de imagens das câmeras digitais, e assim sendo a grande maioria das imagens são armazenadas utilizando-o.




Figura 3 – Cubo RGB

(extraído de [http://en.wikipedia.org/wiki/HSL\\_and\\_HSV](http://en.wikipedia.org/wiki/HSL_and_HSV) )

Os espaços de cor definidos abaixo – YUV, YIQ, YDbDr, YPbPr, YCbCr e YCgCr – foram desenvolvidos para serem utilizados em sistemas eletrônicos de display, como televisores e telas de computadores. Eles separam a informação de cor em três canais – um de luminância e dois de crominância. Com o intuito de minimizar gastos nas transmissões, e dado que a visão humana é mais sensível a variações de luminância que de crominância, os canais destinados a esta última contam com menor resolução.

### 2.2.2. YUV

Este modelo é o adotado pelo padrão PAL de transmissão de sinais analógicos televisivos, os quais são utilizados pela maioria dos países. Seu primeiro canal de crominância (U) determina a diferença entre o azul e a luminância ( $B - Y$ ) enquanto o segundo canal (V) determina a diferença entre o vermelho e a luminância ( $R - Y$ ). Seus canais podem ser calculados a partir dos valores RGB pelas Equações (2.6)-(2.8) (JACK, 2007). O espaço YUV está representado na Figura 4.



$$Y = 0,299R + 0,587G + 0,114B \quad (2.6)$$

$$U = -0,147R - 0,289G + 0,436B \quad (2.7)$$

$$V = 0,615R - 0,515G - 0,1B \quad (2.8)$$

Em que:  $R, G, B, Y \in [0,1]$  ,  $U \in [-0,436, +0,436]$  ,  $V \in [-0,615, +0,615]$




Figura 4 – Espaço de cor YUV

### 2.2.3. YIQ

O padrão NTSC de transmissão analógica de TV foi inicialmente proposto com o modelo YUV, mas foi substituído pelo YIQ, pois este exige uma menor largura de banda na transmissão (PRATT, 2007). Os canais de crominância I e Q são um remapeamento do sistema YUV, com os eixos U e V rotacionados de  $33^\circ$  (FORD; ROBERTS, 1998). A transformação do espaço RGB para o YIQ é dada pelas Equações (2.9)-(2.11) (JACK, 2007). O espaço é mostrado na Figura 5.

$$Y = 0,299R + 0,587G + 0,114B \quad (2.9)$$

$$I = 0,596R - 0,275G - 0,321B \quad (2.10)$$

$$Q = 0,212R - 0,523G + 0,311B \quad (2.11)$$

Em que:  $R, G, B, Y \in [0,1]$  ,  $I \in [-0,5957, +0,5957]$  ,  $Q \in [-0,5226, +0,5226]$




Figura 5 – Espaço de cor YIQ

#### 2.2.4. YDbDr

É o modelo empregado pelo padrão SECAM de transmissão de TV, adotado basicamente pela França, Rússia e alguns países do leste europeu. Seus canais de cromaticidade também definem a diferença entre o azul e a luminância e a diferença entre o vermelho e a luminância. Os canais podem ser calculados pelas Equações (2.12) - (2.14) (SHI; SUN, 2008) e o espaço de cor é ilustrado na Figura 6.

$$Y = 0,299R + 0,587G + 0,114B \quad (2.12)$$

$$Db = -0,450R - 0,883G + 1,333B \quad (2.13)$$

$$Dr = -1,333R + 1,116G - 0,217B \quad (2.14)$$

Em que:  $R, G, B, Y \in [0,1]$  ,  $Db, DPr \in [-1333, +1333]$




Figura 6 – Espaço de cor YDbDr

### 2.2.5. YPbPr

Este é um espaço de cor utilizado na transmissão analógica de vídeo. Ele é derivado dos sinais de vídeo composto (NTSC, PAL), que utilizam os espaços de cor YUV e YIQ, e foi desenvolvido para requerer menor largura de banda sem prejudicar a qualidade da imagem. Por isso é capaz de transmitir vídeos em alta definição (JACK, 2007). Assim como no YUV, os canais de cromaticidade Pb e Pr determinam a diferença entre o azul e a luminância e a diferença entre o vermelho e a luminância, respectivamente. O cálculo de Y, Pb e Pr é dado pelas Equações (2.15)-(2.17) (JACK, 2007). O espaço de cor é representado na Figura 7.

$$Y = 0,299R + 0,587G + 0,114B \quad (2.15)$$

$$Pb = -0,169R - 0,331G + 0,5B \quad (2.16)$$

$$Pr = 0,5R - 0,419G - 0,081B \quad (2.17)$$

Em que:  $R, G, B, Y \in [0,1]$  ,  $Pb, Pr \in [-0,5, +0,5]$




Figura 7 – Espaço de cor YPbPr

### 2.2.6. YCbCr

YCbCr é a versão digital do modelo YPbPr, com resolução de 8 bits para cada canal. Por se tratar de um espaço de cor para aplicações digitais, ele teve que ser redimensionado e deslocado em relação ao YPbPr para garantir uma escala com valores inteiros e não-negativos. Assim sendo, a obtenção dos canais YCbCr a partir do espaço YPbPr é dada pelo conjunto de Equações (2.18)-(2.20) (JACK, 2007). O espaço de cor é ilustrado na Figura 8.

$$Y = \text{ARREDONDA}(219Y + 16) \quad (2.18)$$

$$Cb = \text{ARREDONDA}(224Pb + 128) \quad (2.19)$$

$$Cr = \text{ARREDONDA}(224Pr + 128) \quad (2.20)$$

Em que:  $Y \in [16, 235]$ ,  $Cb, Cr \in [16, 240]$

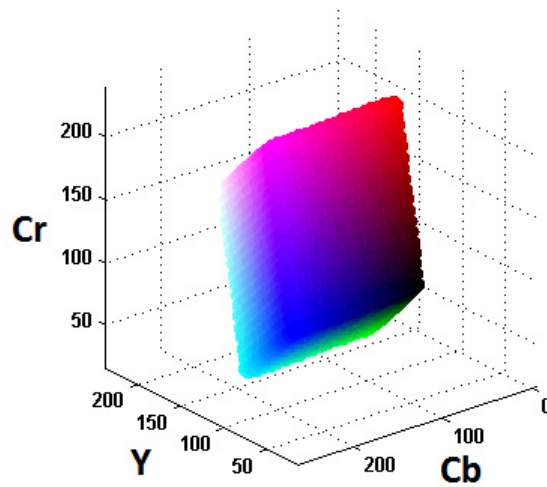


Figura 8 – Espaço de cor YCbCr

### 2.2.7. YCgCr

Este espaço é uma variação do YCbCr e foi apresentado por De Dios e García (2003) na segmentação de faces. Ao invés de utilizar um canal de cromaticidade para a diferença entre o azul e a luminância (Cb), o YCgCr utiliza um canal para a diferença entre o verde e a luminância (Cg). Os canais são calculados pelas Equações (2.21)-(2.23). O espaço YCgCr é representado na Figura 9.

$$Y = 16 + 65,481R + 128,553G + 24,966B \quad (2.21)$$

$$Cg = 128 - 81,085R + 112G - 30,915B \quad (2.22)$$

$$Cr = 128 + 112R - 93,768G - 18,214B \quad (2.23)$$

Em que:  $R, G, B \in [0,1]$  ,  $Y \in [16, 235]$ ,  $Cg, Cr \in [16, 240]$




Figura 9 – Espaço de cor YCgCr

### 2.2.8. CIE XYZ

A CIE (Commission internationale de l'éclairage), órgão internacional de padronização de cor e luz, desenvolveu em 1931 o sistema de cor XYZ baseando-se em um experimento para analisar como os seres humanos percebem a cor. Neste experimento um observador deveria formar uma dada cor por meio da projeção de três fontes de luz de cores diferentes – vermelho, verde e azul – em uma tela. Cores diferentes eram formadas variando-se a intensidade das fontes. Porém algumas cores não podiam ser formadas desta maneira, a menos que se utilizassem intensidades negativas das fontes. O espaço de cor XYZ foi desenvolvido como um esforço de se criar um sistema que utilizasse apenas combinações de valores positivos de cores primárias para a representação de qualquer cor. Essas cores primárias são X, Y e Z. Os canais do espaço de cor são obtidos a partir das Equações (2.24)-(2.26) (PRATT, 2007) e o espaço é representado na Figura 10.

$$X = 0,49018626R + 0,30987954G + 0,19993420B \quad (2.24)$$

$$Y = 0,17701522R + 0,81232418G + 0,01066060B \quad (2.25)$$

$$Z = 0,01007720G + 0,98992280B \quad (2.26)$$

Em que: R, G, B, X, Y, Z  $\in$  [0,1]




Figura 10 – Espaço de cor XYZ

### 2.2.9. CIELAB

O CIELAB, também conhecido como CIE  $L^* a^* b^*$ , é um espaço de cor definido pela CIE como um esforço de se criar um modelo de cor perceptualmente uniforme, já que o CIE XYZ não o é (BILLMEYER; SALTZMAN, 1981). Ser perceptualmente uniforme garante que uma mudança nos valores das componentes gere uma mudança proporcional na percepção humana das cores resultantes. Este modelo de cor é amplamente utilizado no tratamento de cores de frutos e hortaliças (JORGE et al., 2011). O CIELAB é especificado por três canais –  $L$ ,  $a^*$  e  $b^*$ .  $L$  representa o brilho da cor,  $a^*$  representa uma escala de matiz que varia de verde (valores negativos) a magenta (valores positivos), e  $b^*$  representa uma escala de matiz que varia de azul (valores negativos) a amarelo (valores positivos).

Os valores dos canais deste modelo são calculados a partir de valores do espaço de cor CIE XYZ, como apresentado pelas Equações (2.27)-(2.30). O espaço de cor é ilustrado na Figura 11.

$$L = 116f(Y/Y_n) - 16 \quad (2.27)$$


$$a^* = 500 [f(X/X_n) - f(Y/Y_n)] \quad (2.28)$$

$$b^* = 200 [f(Y/Y) - f(Z/Z_n)] \quad (2.29)$$

Sendo:

$$f(k) = \begin{cases} k^{\frac{1}{3}} & , \text{se } k > \left(\frac{6}{29}\right)^3 \\ \frac{1}{3}\left(\frac{29}{6}\right)^2 k + \frac{4}{29} & , \text{caso contrário} \end{cases} \quad (2.30)$$

$X_n$ ,  $Y_n$  e  $Z_n$  são os valores CIE XYZ para o iluminante referência, que neste trabalho foi o D65, caracterizado por  $X_n = 95,047$ ,  $Y_n = 100,000$  e  $Z_n = 108,883$ .



**Figura 11 – Espaço de cor CIELAB**  
(extraído de [www.flexoglobal.com](http://www.flexoglobal.com))

### 2.2.10. HSV

O modelo HSV decompõe uma cor em três canais: matiz (hue - H), saturação (saturation - S) e valor (value - V). O matiz traz a informação da cor em si, definindo se ela é vermelha, verde, amarela, etc.. Seus valores variam de  $0^\circ$  a  $360^\circ$ . A saturação indica a pureza da cor, de modo que quanto menor seu valor, menos se percebe a presença do matiz na cor, de tal forma que as cores que apresentam saturação 0 constituem o conjunto de cores da escala de cinza. O valor determina o brilho, sendo que cores claras possuem altos valores de V, ao passo que cores escuras possuem baixos valores. Tanto a saturação quanto o brilho variam de 0 a 100%. Os valores de H, S e V podem ser obtidos pelas Equações (2.31)-(2.33) (CHAVES-GONZALEZ et al., 2010). O espaço HSV é apresentado na Figura 12.



$$H = \begin{cases} \text{Indefinido} & , \text{se } MAX = MIN \\ 60 \cdot \frac{G - B}{MAX - MIN} & , \text{se } MAX = R \text{ e } G \geq B \\ 60 \cdot \frac{G - B}{MAX - MIN} + 360 & , \text{se } MAX = R \text{ e } G < B \\ 60 \cdot \frac{B - R}{MAX - MIN} + 120 & , \text{se } MAX = G \\ 60 \cdot \frac{R - G}{MAX - MIN} + 240 & , \text{se } MAX = B \end{cases} \quad (2.31)$$

$$S = \begin{cases} 0, & , \text{se } MAX = 0 \\ 1 - \frac{MIN}{MAX} & , \text{se } MAX \neq 0 \end{cases} \quad (2.32)$$

$$V = MAX \quad (2.33)$$

Em que:  $R, G, B, S, V \in [0,1]$  ,  $H \in [0,360]$  ,  $MAX = M\acute{A}XIMO(R,G,B)$  e  
 $MIN = M\acute{I}NIMO(R,G,B)$




Figura 12 – Espaço de cor HSV  
(extraído de [http://en.wikipedia.org/wiki/HSL\\_and\\_HSV](http://en.wikipedia.org/wiki/HSL_and_HSV))

### 2.2.11. $I_1I_2I_3$

O espaço  $I_1I_2I_3$  foi proposto por Ohta, Kanade e Sakai (1980) com o intuito de se determinar um espaço de cor eficiente na segmentação de imagens. Para cada uma das imagens selecionadas foi calculada a transformada de Karhunen–Loève (RAO; YIP, 2001) dos canais RGB dos pixels da região a ser segmentada. Desta forma, para cada imagem foi obtido um espaço de cor cujos canais são descorrelacionados, e apresentam variâncias máximas. Ao analisarem os resultados obtidos em cada uma das imagens, os autores perceberam um padrão nas transformações que levavam do espaço RGB aos novos espaços de cor. Esse padrão se aproximava ao que então propuseram como o  $I_1I_2I_3$ , e que é apresentado pelas Equações (2.34)-(2.36). O espaço de cor é ilustrado na Figura 13. No trabalho citado o  $I_1I_2I_3$  foi comparado com vários outros espaços de cor na segmentação por thresholding recursivo e obteve bons resultados.

$$I_1 = \frac{1}{3}(R + G + B) \quad (2.34)$$

$$I_2 = \frac{1}{2}(R - B) \quad (2.35)$$

$$I_3 = \frac{1}{4}(-R + 2G - B) \quad (2.36)$$

Em que:  $R, G, B, I_1 \in [0,1]$  ,  $I_2, I_3 \in [-0,5,0,5]$




Figura 13 – Espaço de cor  $I_1I_2I_3$

### 2.2.12. RGB normalizado (rgb)

Visando reduzir a sensibilidade a variações de iluminação, o espaço RGB pode ser normalizado conforme as Equações (2.37)-(2.39) (BROWN; CRAW; LEWTHWAITE, 2001). Deve-se notar que a normalização, exatamente por remover informações de luminosidade, reduz significativamente o volume do espaço de cor, como pode ser observado na representação do espaço de cor na Figura 14.

$$r = R / (R + G + B) \quad (2.37)$$

$$g = G / (R + G + B) \quad (2.38)$$

$$b = B / (R + G + B) \quad (2.39)$$

Em que:  $R, G, B, r, g, b \in [0,1]$




Figura 14 – Espaço de cor rgb por duas perspectivas

### 2.3. Atributos Morfológicos

Um dos desafios da visão computacional é conseguir definir formas de objetos por meio de representações matemáticas de maneira concisa, mas que ainda assim consigam expor informações intrínsecas da forma. Essas representações podem ser denominadas de atributos morfológicos. Inúmeras técnicas já foram apresentadas e suas eficiências dependem da aplicação e de que características da forma se deseja exaltar. Outro critério muito relevante

envolvendo os atributos é o custo computacional exigido nos cálculos, que sendo muito alto, pode comprometer algumas aplicações. A seguir são apresentados os atributos utilizados neste trabalho.

### 2.3.1. Assinaturas

Assinaturas são funções 1D calculadas a partir dos pontos do contorno de uma forma. Geralmente elas são normalizadas para se obter invariância a escala. Existem várias abordagens para calculá-las, como, por exemplo, a tangente do ângulo, a área, comprimento da corda e a distância do centroide (ZHANG; LU, 2004). Esta última foi a utilizada neste trabalho.

As coordenadas  $(\bar{x}, \bar{y})$  do centroide de uma figura representada por uma região contendo  $N_p$  pixels de coordenadas  $(x_i, y_i)$  (com  $i = 1, \dots, N_p$ ) são dadas por (2.40) e (2.41) (JAIN, 1989).

$$\bar{x} = \frac{1}{N_p} \sum_{i=1}^{N_p} x_i \quad (2.40)$$

$$\bar{y} = \frac{1}{N_p} \sum_{i=1}^{N_p} y_i \quad (2.41)$$

Portanto, para uma forma contendo  $N_{pb}$  pixels de borda, cujas coordenadas são  $(x_k, y_k)$  (com  $k = 1, \dots, N_{pb}$ ), tem-se o  $k$ -ésimo elemento da sua assinatura dado pela Equação (2.42).

$$z(k) = \sqrt{(x_k - \bar{x})^2 + (y_k - \bar{y})^2} \quad (2.42)$$

### 2.3.2. Descritores de Fourier

Utilizando-se a transformada de Fourier é possível representar qualquer sinal como uma soma de senoides multiplicadas por diferentes coeficientes, tendo cada senoide uma frequência distinta. Essa transformada é amplamente utilizada na área de análise de sinais por permitir uma visualização do sinal no domínio da frequência, fornecendo possibilidades não alcançadas no domínio do tempo (GONZALEZ; WOODS, 2008b).

A transformada de Fourier também pode ser utilizada na representação de forma, bastando tratar um conjunto de assinaturas como sendo um sinal e aplicar sobre ele a transformada. Os coeficientes das senoides obtidas passam então a ser chamados de Descritores de Fourier. Características típicas dos Descritores de Fourier são que geralmente a forma geral da figura é relativamente bem definida a partir de alguns dos termos de menor ordem da expansão, e as magnitudes dos termos são invariantes a rotação.

Os descritores de Fourier  $F(u)$  de um conjunto de  $N_a$  assinaturas  $z(k)$  são obtidos pela equação (2.43) (GONZALEZ; WOODS, 2008b):

$$F(u) = \frac{1}{N_a} \sum_{k=0}^{N_a-1} z(k) e^{-j2\pi uk/N_a} \quad (2.43)$$

Para  $u = 0, 1, \dots, N_a - 1$ .

### 2.3.3. Descritores Genéricos de Fourier (DGFs)

Uma das desvantagens da transformada de Fourier 2D é que ela não é invariante a rotação, pois girar uma imagem em  $\theta$  acarreta a mesma rotação  $\theta$  no espectro da frequência. Os Descritores Genéricos de Fourier (DGFs) (ZHANG; LU, 2002) foram propostos para contornar esse problema, utilizando-se de coordenadas polares ao invés de retangulares.

Desta forma, para se calcular os DGFs, primeiramente é aplicada uma Transformada Polar de Fourier Modificada (TPFM) sobre a forma. Essa transformada trata uma forma descrita em coordenadas polares como se fosse uma forma em coordenadas retangulares, como ilustrado na Figura 15. Então aplica-se a transformada de Fourier 2D discreta sobre ela.




Figura 15 – Mapeamento de coordenadas utilizado pelo DGF.

Retirada de (ZHANG E LU, 2002) (a) Uma imagem em coordenadas polares (b) a mesma imagem em coordenadas polares tratada como coordenadas retangulares.

Dessa forma, a TPFM é dada pela Equação (2.44):

$$TPFM(\rho, \varphi) = \sum_r \sum_i f(r, \theta_i) e^{-j2\pi(\frac{r}{R}\rho + \frac{2\pi i}{T}\varphi)} \quad (2.44)$$

Onde  $\rho$  e  $\varphi$  são, respectivamente, as frequências radial e angular. Sendo  $0 \leq r < R$ ,  $\theta_i = \frac{i2\pi}{T}$  ( $0 \leq i < T$ ) e  $f(r, \theta_i)$  é a representação da imagem em coordenadas polares.  $0 \leq \rho < R$  e  $0 \leq \varphi < T$ . R e T são, respectivamente, as resoluções radiais e angulares.

Para se obter invariância a translação a imagem deve ser transladada de modo a fazer o centroide  $(\bar{x}, \bar{y})$  da forma ser a origem da imagem. Tem-se então:

$$r = \sqrt{(x - \bar{x})^2 + (y - \bar{y})^2} \quad (2.45)$$

$$\theta = \arctg\left(\frac{y - \bar{y}}{x - \bar{x}}\right) \quad (2.46)$$

Para se obter invariância quanto a rotação e escala, uma normalização se faz necessária. Assim, os DGFs são definidos como segue:

$$DGF(\rho, \varphi) = \begin{cases} \frac{TPFM(\rho, \varphi)}{\text{Área}} & , \text{se } \rho = 0 \text{ e } \varphi = 0 \\ \frac{TPFM(\rho, \varphi)}{TPFM(0,0)} & , \text{caso contrário} \end{cases} \quad (2.47)$$

Para  $\rho = 0, \dots, m$  e  $\varphi = 0, \dots, n$ . Sendo Área a área do círculo que circunscreve a forma e m e n, respectivamente, os números máximos de frequências radiais e angulares escolhidos para compor o conjunto de descritores.

#### 2.3.4. Modelo Autorregressivo

O Modelo Autorregressivo (DUBOIS; GLANZ, 1986) é uma técnica de representação de forma invariante a translação, rotação e escala. Ele representa as distâncias dos pontos da borda ao centroide da forma (que são chamadas de raio) como uma série temporal, de modo que cada

raio é definido como uma combinação linear dos raios anteriores. Primeiramente é definido o número de raios ( $N_R$ ) a serem utilizados. Os  $N_R$  raios são então coletados de forma que duas amostras vizinhas sejam separadas por um mesmo ângulo  $\Delta\varphi = 2\pi/N_R$ .

O modelo determina que o conjunto de amostras de raios ( $r_t$ ) pode ser dado pela seguinte combinação linear:

$$r_t = \alpha + \sum_{j=1}^{m_{AR}} \gamma_j r_{t-j} + \sqrt{\beta} w_t \quad t = 1, \dots, N_R \quad (2.48)$$

Sendo,

$m_{AR}$ : Ordem do modelo

$r_t$ : Amostra do raio corrente

$r_{t-j}$ : Raio situado  $j$  posições anteriores ao raio corrente

$\gamma_1, \dots, \gamma_{m_{AR}}$ : Coeficientes da autorregressão a serem estimados

$\sqrt{\beta}$ : Constante a ser estimada

$\alpha$ : Constante a ser estimada

$\{w_t\}$ : Uma sequência aleatória de amostras independentes com média 0 e variância 1

Considera-se  $r_t$  uma função periódica, de modo que  $r_t = r_{t+N_R}$ .

Os parâmetros do modelo são determinados segundo as Equações (2.49) e (2.50).

$$\beta = \frac{1}{N_R} \sum_{t=1}^{N_R} \left( r_t - \alpha - \sum_{j=1}^{m_{AR}} \gamma_j r_{t-j} \right)^2 \quad (2.49)$$

$$\begin{bmatrix} \gamma_1 \\ \vdots \\ \gamma_{m_{AR}} \\ \alpha \end{bmatrix} = \begin{bmatrix} \sum_{t=1}^{N_R} r_{t-1}^2 & \cdots & \sum_{t=1}^{N_R} r_{t-1} r_{t-m_{AR}} & \sum_{t=1}^{N_R} r_{t-1} \\ \vdots & \ddots & \vdots & \vdots \\ \sum_{t=1}^{N_R} r_{t-m_{AR}} r_{t-1} & & \sum_{t=1}^{N_R} r_{t-m_{AR}} & \sum_{t=1}^{N_R} r_{t-m_{AR}} r_t \\ \sum_{t=1}^{N_R} r_{t-1} & \cdots & \sum_{t=1}^{N_R} r_{t-m_{AR}} & N_R \end{bmatrix}^{-1} \begin{bmatrix} \sum_{t=1}^{N_R} r_{t-1} r_t \\ \vdots \\ \sum_{t=1}^{N_R} r_{t-m_{AR}} r_t \\ \sum_{t=1}^N r_t \end{bmatrix} \quad (2.50)$$

A razão  $\alpha/\sqrt{\beta}$  pode ser interpretada como a relação sinal-ruído da forma, e os parâmetros  $\{\gamma_1, \dots, \gamma_m\}$  estabelecem a função que determina o seu contorno. Assim sendo, o conjunto  $\{\frac{\alpha}{\sqrt{\beta}}, \gamma_1, \dots, \gamma_m\}$  pode ser utilizado como um vetor de características para descrever o contorno de uma forma.

### 2.3.5. Momentos de Zernike

Os Momentos de Zernike (TEAGUE, 1979) são um conjunto de momentos complexos formados pela projeção de uma função  $f(x, y)$ , mapeada no círculo unitário  $x^2 + y^2 \leq 1$ , em uma família de polinômios complexos - os polinômios de Zernike.

As principais características dos Momentos de Zernike são que eles são invariantes a rotação, e por se tratarem de momentos ortogonais, contam com um mínimo de redundância de informação. O cálculo dos Momentos de Zernike para uma imagem digital  $f(x, y)$  quadrada de lado  $L$ , é definido pela Equação (2.51):

$$Z_{n_Z, m_Z} = \frac{n_Z + 1}{\pi(L - 1)} \sum_{x=1}^L \sum_{y=1}^L f(x, y) V_{n_Z, m_Z}(\rho, \theta) \quad (2.51)$$

Com  $\rho = \frac{\sqrt{x^2 + y^2}}{L}$  e  $\theta = \tan^{-1}(y/x)$ .  $n_Z$  é um número natural chamado de ordem do momento e  $m_Z$  é denominado repetição, sendo que  $n_Z - |m_Z|$  é par e  $|m_Z| < n_Z$ .

$V_{n_Z, m_Z}$  é a família de polinômios de Zernike, definida por (2.52).

$$V_{n_Z, m_Z}(\rho, \theta) = R_{n_Z, m_Z}(\rho) e^{-jm_Z\theta} \quad (2.52)$$

Com

$$R_{n_Z, m_Z}(\rho) = \sum_{s=0}^{n_Z - \frac{|m_Z|}{2}} (-1)^s \frac{\rho^{n_Z - 2s} (n_Z - s)!}{s! \left[ \frac{n_Z + |m_Z|}{2} - s \right]! \left[ \frac{n_Z - |m_Z|}{2} - s \right]!} \quad (2.53)$$



Para seu uso como atributos morfológicos, são utilizadas as magnitudes dos momentos de até certa ordem pré-definida. O número de momentos da ordem 0 até a ordem  $n_z$  é dada por  $(\frac{n_z}{2} + 1)(n_z + 1)$ .

### 2.3.6. Atributos Unitários

Os atributos morfológicos desta seção foram chamados de unitários por não serem constituídos de um conjunto de valores como os atributos morfológicos apresentados anteriormente. Cada um dos atributos unitários é definido por apenas um valor.

Os atributos unitários utilizados neste estudo são: área, perímetro, eixo maior, eixo menor, excentricidade, spread, slenderness e mais outros cinco atributos derivados dos anteriores ( $A_1$ ,  $A_2$ ,  $A_3$ ,  $A_4$  e  $A_5$ ). Os dois primeiros são diretamente obtidos pelo contorno da forma, enquanto o cálculo dos outros são apresentados a seguir.

Para o cálculo dos atributos citados deve-se determinar primeiramente certos momentos centrais. Temos que os momentos centrais de ordem  $(p,q)$  de uma forma representada pelos pixels de coordenadas  $(x_i, y_i)$  (com  $i = 1, \dots, N_p$ ) são calculados pela Equação (2.54).


$$\mu_{p,q} = \sum_{i=1}^{N_p} (x_i - \bar{x})^p (y_i - \bar{y})^q \quad (2.54)$$

Sendo  $\bar{x}$  e  $\bar{y}$  as coordenadas do centroide.

Conforme descrito por Jain (1989), para o cálculo dos eixos maior e menor de uma forma deve-se calcular sua orientação, ou seja, o ângulo  $\theta$  (Figura 16) com o qual ele possui o menor momento de inércia.  $\theta$  é dado pela Equação (2.55).

$$\theta = \arctan\left(\frac{\mu_{1,1}}{\mu_{2,0} - \mu_{0,2}}\right) \quad (2.55)$$

Pode-se adotar um sistema alternativo de coordenadas, eixos  $\alpha$  e  $\beta$ , que sejam respectivamente paralelo e perpendicular à orientação do objeto, como ilustrado na Figura 16.



**Figura 16 – Orientação do objeto e sistema alternativo de coordenadas**  
 Imagem adaptada de (JAIN, 1989)

Assim, as coordenadas  $\alpha$  e  $\beta$  podem ser calculadas a partir das coordenadas  $x$  e  $y$  aplicando-se uma operação de rotação de  $\theta$ :

$$\begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (2.56)$$

Transformando todos os pixels da forma para o sistema de coordenadas  $(\alpha, \beta)$ , e determinando o menor e maior valores de  $\alpha$  ( $\alpha_{min}$  e  $\alpha_{max}$  respectivamente) e o menor e maior valores de  $\beta$  ( $\beta_{min}$  e  $\beta_{max}$  respectivamente) pode-se definir os eixos maior e menor:

$$\text{Eixo menor} = \text{MIN}(\alpha_{max} - \alpha_{min}, \beta_{max} - \beta_{min}) \quad (2.57)$$

$$\text{Eixo maior} = \text{MAX}(\alpha_{max} - \alpha_{min}, \beta_{max} - \beta_{min}) \quad (2.58)$$

A excentricidade de uma forma é calculada pela Equação (2.59) (JAIN, 1989). Os outros atributos derivados são apresentados por Symons e Fulcher (1988) e Shouche et al. (2001) na classificação de grãos de trigo e são dados pelas Equações (2.60)-(2.66).

$$\text{excentricidade} = \frac{(\mu_{2,0} - \mu_{0,2})^2 + 4\mu_{1,1}}{\text{Área}} \quad (2.59)$$

$$\text{spread} = \mu_{2,0} + \mu_{0,2} \quad (2.60)$$

$$slenderness = \sqrt{(\mu_{2,0} - \mu_{0,2})^2 + 4\mu_{1,1}^2} \quad (2.61)$$

$$A_1 = \frac{4\pi\text{Área}}{\text{Perímetro}^2} \quad (2.62)$$

$$A_2 = \frac{\text{Eixo maior}}{\text{Área}} \quad (2.63)$$

$$A_3 = \frac{\text{Área}}{(\text{Eixo maior})^3} \quad (2.64)$$

$$A_4 = \frac{\text{Área}}{\pi(\text{Eixo maior}/2)^2} \quad (2.65)$$

$$A_5 = \frac{\text{Área}}{\pi(\text{Eixo maior}/2)(\text{Eixo menor}/2)} \quad (2.66)$$

## 2.4. Descritores de Haralick

Em 1973 Robert Haralick e seus colaboradores publicaram um artigo (HARALICK; SHANMUGA.K; DINSTEIN, 1973) descrevendo métodos matemáticos para descrever texturas de imagens digitais. Esse artigo apresenta 14 características que podem ser extraídas de uma imagem para representar texturas. Elas ficaram conhecidas como descritores de Haralick, os quais são uma das principais referências para aplicações que envolvem análise de texturas por imagens digitais. O estudo de Haralick baseia-se na utilização de matrizes de co-ocorrência de níveis de cinza (GLCM, do inglês Grey Level Co-occurrence Matrix).

A GLCM é uma representação matricial da frequência com que diferentes combinações de brilho (níveis de cinza) ocorrem em uma imagem. A relação entre combinações de brilho é determinada comparando-se um pixel de referência a um pixel vizinho. O pixel vizinho é determinado por dois parâmetros: a distância  $d$  e o ângulo  $\theta$  em relação ao pixel de referência.

Devido a simetria, considera-se apenas quatro valores de  $\theta$ :  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ . A relação entre o pixel de referência e o pixel vizinho é ilustrada na Figura 17, para  $d = 1$ .

Desta forma, se, por exemplo, o pixel vizinho for escolhido com  $d = 1$  e  $\theta = 0^\circ$ , as combinações de brilho serão determinadas comparando-se o pixel de referência ao pixel à sua direita e ao pixel à sua esquerda. A contagem das diferentes combinações é feita percorrendo-se todos os pixels da imagem, com cada um deles sendo o pixel de referência da vez.

<b>PV<sub>3</sub></b> ( $d = 1, \theta = 135^\circ$ )	<b>PV<sub>2</sub></b> ( $d = 1, \theta = 90^\circ$ )	<b>PV<sub>1</sub></b> ( $d = 1, \theta = 45^\circ$ )
<b>PV<sub>4</sub></b> ( $d = 1, \theta = 0^\circ$ )	<b>PR</b>	<b>PV<sub>0</sub></b> ( $d = 1, \theta = 0^\circ$ )
<b>PV<sub>5</sub></b> ( $d = 1, \theta = 45^\circ$ )	<b>PV<sub>6</sub></b> ( $d = 1, \theta = 90^\circ$ )	<b>PV<sub>7</sub></b> ( $d = 1, \theta = 135^\circ$ )

Figura 17 – Relação entre o pixel de referência (PR) e o pixel vizinho (PV<sub>i</sub>) para  $d = 1$

Todas as possíveis combinações de níveis de cinza são contadas e formatadas em uma matriz, a GLCM. Supondo uma imagem com apenas três níveis de cinza (0, 1 ou 2), a GLCM referente a ela teria o formato apresentado na Figura 18. Sendo que  $V_{i,j}$  indica quantas ocorrências de pixels de referência com nível de cinza  $i$  cujo pixel vizinho apresenta nível de cinza  $j$  há na imagem.

		Valor do pixel vizinho		
		0	1	2
Valor do pixel de referência	0	$V_{(0,0)}$	$V_{(0,1)}$	$V_{(0,2)}$
	1	$V_{(1,0)}$	$V_{(1,1)}$	$V_{(1,2)}$
	2	$V_{(2,0)}$	$V_{(2,1)}$	$V_{(2,2)}$

Figura 18 – Formato de uma GLCM para uma imagem com 3 níveis de cinza

É necessário que a GLCM seja normalizada, apresentando probabilidades de ocorrência de combinações, ao invés de números absolutos de ocorrências. Essas probabilidades  $P_{i,j}$  são calculadas segundo a Equação (2.67), para  $N_{NC}$  níveis de cinza.

$$P_{i,j} = \frac{V_{i,j}}{\sum_{p=0}^{N_{NC}-1} \sum_{q=0}^{N_{NC}-1} V_{p,q}} \quad (2.67)$$

Cada um dos 14 descritores de Haralick é calculado utilizando-se os valores da GLCM de uma forma diferente. Antes de se calcular os descritores é preciso determinar alguns valores auxiliares, os quais são definidos pelas Equações (2.68)-(2.74). Os 14 descritores são dados pelas Equações (2.75)-(2.88). Nos cálculos envolvendo logaritmos soma-se  $\varepsilon$ , um valor arbitrário positivo muito pequeno, ao argumento do log, a fim de se evitar a indefinição  $\log(0)$ .

$$P_x(i) = \sum_{j=0}^{N_{NC}-1} P_{i,j} \quad (2.68)$$

$$P_y(j) = \sum_{i=0}^{N_{NC}-1} P_{i,j} \quad (2.69)$$

$$P_{x+y}(k) = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j} \quad (2.70)$$

Com  $i + j = k$  e  $k = 0, 1, \dots, 2 N_{NC} - 2$ .

$$P_{x-y}(k) = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j} \quad (2.71)$$

Com  $|i - j| = k$  e  $k = 0, 1, \dots, N_{NC} - 1$ .

$$HXY1 = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j} \log(P_x(i)P_y(j) + \varepsilon) \quad (2.72)$$

$$HXY2 = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_x(i)P_y(j) \log(P_x(i)P_y(j) + \varepsilon) \quad (2.73)$$

$$Q(i,j) = \sum_{k=0}^{N_{NC}-1} \frac{P_{i,k}P_{j,k}}{P_x(i)P_y(j)} \quad (2.74)$$

$$\text{Segundo Momento Angular} = f_1 = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j}^2 \quad (2.75)$$

$$\text{Contraste} = f_2 = \sum_{n=0}^{N_{NC}-1} n^2 \left( \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j} \right) \quad (2.76)$$

$$\text{Correlação} = f_3 = \frac{\sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.77)$$

Onde  $\mu_x$ ,  $\sigma_x$ ,  $\mu_y$ , e  $\sigma_y$  são, respectivamente, a média e o desvio padrão de  $P_x$  e a média e o desvio padrão de  $P_y$ .

$$\text{Variância} = f_4 = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} (i - \mu)^2 P_{i,j} \quad (2.78)$$

Sendo  $\mu$  a média dos níveis de cinza presentes na imagem.

$$\text{Momento Inverso da Diferença} = f_5 = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (2.79)$$

$$\text{Média da Soma} = f_6 = \sum_{i=2}^{2N_{NC}} iP_{x+y}(i - 2) \quad (2.80)$$

$$\text{Variância da Soma} = f_7 = \sum_{i=2}^{2N_{NC}} (i - f_6)^2 P_{x+y}(i - 2) \quad (2.81)$$

$$\text{Entropia da Soma} = f_8 = - \sum_{i=0}^{2N_{NC}-2} P_{x+y}(i) \log(P_{x+y}(i) + \varepsilon) \quad (2.82)$$

$$\text{Entropia} = f_9 = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j} \log(P_{i,j} + \varepsilon) \quad (2.83)$$

$$\text{Variância da Diferença} = f_{10} = \text{Variância de } (P_{x-y}) \quad (2.84)$$

$$\text{Entropia da Diferença} = f_{11} = - \sum_{i=0}^{N_{NC}-1} P_{x-y}(i) \log(P_{x-y}(i) + \varepsilon) \quad (2.85)$$

$$\text{Medida de Correlação 1} = f_{12} = \frac{f_9 - HXY1}{MAX(HX, HY)} \quad (2.86)$$

Sendo HX e HY as entropias de  $P_x$  e  $P_y$ .

$$\text{Medida de Correção 2} = f_{13} = (1 - e^{-2(HXY2 - f_9)})^{1/2} \quad (2.87)$$

$$\text{Máximo Coeficiente de Correlação} = f_{14} = (\text{Segundo maior autovalor de } Q)^{1/2} \quad (2.88)$$

## 2.5. Análise de Componentes Principais (PCA)

Muitas vezes, ao se trabalhar com um conjunto de características, percebe-se que ele apresenta grande redundância de informações, ou seja, as características têm altos coeficientes de correlação. Em geral, essa redundância é indesejável, pois limita o poder discriminatório das características. A Análise de Componentes Principais (PCA, do inglês Principal Component Analysis) é uma técnica que de um conjunto de características gera outras novas, cujas covariâncias são mínimas, e, portanto, têm máximas variâncias, de modo que essas novas características são perfeitamente descorrelacionadas (COSTA; CESAR, 2000). O conjunto de novas características, chamadas de componentes principais, é obtido por uma transformação linear aplicada nas características originais.

Dado um conjunto de  $m$  amostras expressas em  $n$  características, ele pode ser representado por uma matriz  $\mathbf{F}_{m \times n}$ . Sendo  $\mathbf{K} = \mathbf{F}^T \mathbf{F}$ , então  $\mathbf{K}$  é a matriz de covariância de  $\mathbf{F}$  multiplicada por um escalar arbitrário e  $\mathbf{K}$  é positiva definida, tendo, portanto, todos os seus autovalores positivos. Define-se os autovalores de  $\mathbf{K}$  como  $\lambda_i$  ( $i = 1, \dots, n$ ), de modo que  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$ . Associado a cada autovalor  $\lambda_i$  há um autovetor  $\mathbf{v}_i$ . Como os autovalores  $\lambda_i$  foram ordenados de forma decrescente, tem-se que os autovetores  $\mathbf{v}_i$  estão sequenciados em ordem decrescente da variância apresentada pelos dados através dos eixos que eles representam. Além disso, dado que os autovetores são ortogonais por definição, os  $\mathbf{v}_i$  podem ser, então, definidos como as componentes principais propostas pelo método.

Define-se, assim,  $\mathbf{L}$  como sendo a matriz que transforma o conjunto de dados expressos pelas características originais no mesmo conjunto expresso pelas componentes principais.  $\mathbf{L}$  é uma matriz cujas colunas são os autovetores  $\mathbf{v}_i$ :

$$\mathbf{L} = [\mathbf{v}_1 \quad \dots \quad \mathbf{v}_n] \quad (2.89)$$

Então o conjunto de dados transformados pela PCA ( $\tilde{\mathbf{F}}$ ) é dado por

$$\tilde{\mathbf{F}} = \mathbf{F}\mathbf{L} \quad (2.90)$$

A PCA pode ser utilizada para a compressão de dados. Para tanto, basta eliminar as componentes principais relacionadas a autovalores muito pequenos, já que elas apresentam



variâncias muito baixas e, portanto, não proporcionam uma perda muito grande de informações quando omitidas.

## **2.6. Seleção de Atributos**

Ao se definir um conjunto de atributos para realizar classificações, é possível que nem todos eles contribuam no processo discriminatório ou que contribuam muito pouco, de forma a aumentar injustificadamente o custo computacional envolvido. É possível, também, que certos atributos possam até prejudicar o resultado da classificação. Existem na literatura muitas técnicas que propõem contornar esse problema, fazendo uma filtragem, de modo a determinar um subconjunto dos atributos, o qual contém apenas aqueles com maior poder discriminante. Uma técnica de redução de dimensionalidade, que pode ser utilizada de modo similar a um seletor de atributos, é utilizar a PCA, descrita na Seção 2.5, para transformar os atributos, e então eliminar as componentes principais com baixas variâncias, ou seja, aquelas relacionadas aos menores autovalores.

Outra técnica é avaliar individualmente cada um dos atributos, e então ordená-los segundo um determinado critério de avaliação. Este critério deve ser um procedimento que calcula o poder discriminante de um atributo, mesurado por um valor, ao analisar sua relação com todo conjunto de amostras. A seleção pode ser feita, então, determinando um valor de corte para os valores relacionados aos poderes discriminantes, de forma a manter somente atributos com valores acima dele. Outra possibilidade é manter um determinado número de atributos, os quais são selecionados entre os mais bem posicionados. Dois critérios de avaliação de atributos foram utilizados neste trabalho, e serão escritos abaixo: ganho de informação e chi-quadrado.

### **2.6.1. Ganho de Informação**

Em teoria da informação, o termo entropia representa a incerteza associada a uma variável aleatória, de forma que quanto maior a entropia, maior a quantidade de informação necessária para se prever o valor dessa variável. A entropia é máxima quando a variável apresenta uma distribuição uniforme (MACKAY, 2003).

O conceito de entropia pode ser usado na área de classificação de padrões para se determinar o ganho de informação que um atributo proporciona à classificação, conforme descrito por

Setiono e Liu (1996). Dado um conjunto  $\mathbf{S}$  contendo  $N_{am}$  amostras, as quais são categorizadas em classes, definidas pela variável  $C \in \{c_1, \dots, c_n\}$ , e sendo  $N(c_i)$  o número de amostras da classe  $c_i$ , então a entropia da classificação do conjunto  $\mathbf{S}$  é dada por:

$$H(\mathbf{S}) = - \sum_{i=1}^n \frac{N(c_i)}{N_{am}} \log_2 \frac{N(c_i)}{N_{am}} \quad (2.91)$$

Tendo as amostras de  $\mathbf{S}$  um atributo  $A \in \{a_1, \dots, a_m\}$ , então  $\mathbf{S}$  pode ser dividido de modo que cada subconjunto  $\mathbf{S}_j$  resultante tenha apenas amostras com  $A = a_j$  ( $j = 1, \dots, m$ ). Sendo  $N(a_j)$  o número de amostras com  $A = a_j$  e  $N(c_i, a_j)$  o número de amostras com  $C = c_i$  e  $A = a_j$ , então a entropia da classificação do conjunto  $\mathbf{S}_j$  é calculada pela Equação (2.92).

$$H(\mathbf{S}_j) = - \sum_{i=1}^n \frac{N(c_i, a_j)}{N(a_j)} \log_2 \frac{N(c_i, a_j)}{N(a_j)} \quad (2.92)$$

A entropia de  $\mathbf{S}$  quando suas amostras são arranjadas pelos valores de  $A$  pode ser calculada pela soma das entropias dos subconjuntos  $\mathbf{S}_j$ , ponderada pelo número de elementos nos subconjuntos, conforme a Equação (2.93).

$$H(\mathbf{S}, A) = \sum_{j=1}^m \frac{N(a_j)}{N_{am}} H(\mathbf{S}_j) \quad (2.93)$$

O ganho de informação que o atributo  $A$  oferece na classificação do conjunto de amostras  $\mathbf{S}$  é dado pela redução observada na entropia ao se arranjar as amostras de  $\mathbf{S}$  pelos valores de  $A$ . O ganho de informação é dado pela equação abaixo.

$$G(\mathbf{S}, A) = H(\mathbf{S}) - H(\mathbf{S}, A) \quad (2.94)$$

Como o valor de  $G(\mathbf{S}, A)$  é sensível ao número de diferentes valores que  $A$  pode assumir, uma normalização se faz necessária para que os ganhos de informação de diferentes atributos possam ser comparados de modo consistente. A normalização pode ser feita pela entropia do

atributo em relação a seus valores ( $\tilde{H}(\mathbf{S}, A)$ ). Dessa forma, calculamos o ganho de informação normalizado segundo a Equação (2.95).

$$G_N(\mathbf{S}, A) = \frac{G(\mathbf{S}, A)}{\tilde{H}(\mathbf{S}, A)} \quad (2.95)$$

Com

$$\tilde{H}(\mathbf{S}, A) = \sum_{j=1}^m \frac{N(a_j)}{N_{am}} \log_2 \frac{N(a_j)}{N_{am}} \quad (2.96)$$

Os cálculos descritos acima pressupõem que o atributo A seja uma variável discreta. Caso ele seja definido por uma variável contínua, algum método de discretização deve ser previamente aplicado.

### 2.6.2. Chi-quadrado

Este critério avalia um atributo baseando-se na estatística  $\chi^2$ . O  $\chi^2$  é amplamente utilizado para se verificar ou refutar uma hipótese de dependência entre duas variáveis, atribuindo ao resultado um grau de confiabilidade estatístico.

Primeiramente deve-se compreender o conceito da distribuição  $\chi^2$  (WALCK, 2007). Dado um conjunto de variáveis aleatórias independentes  $Z_p$  ( $p = 1, \dots, k$ ) com distribuição normal com média zero e variância 1 ( $Z_p \sim N(0,1)$ ), e definindo uma variável aleatória  $Q = \sum_{r=1}^k Z_r^2$ , então Q apresenta uma distribuição chi-quadrado com k graus de liberdade ( $Q \sim \chi_k^2$ ). A função de densidade de  $\chi_k^2$  é dada pela Equação (2.97) e sua curva está traçada na Figura 19 para alguns graus de liberdade.

$$f_k(x) = \begin{cases} \frac{x^{\frac{k}{2}-1} e^{-\frac{x}{2}}}{2^{\frac{k}{2}} \Gamma(\frac{k}{2})} & , \quad x \geq 0 \\ 0 & , \quad x < 0 \end{cases} \quad (2.97)$$

Onde  $\Gamma(\cdot)$  é a função gama definida pela Equação (2.98).

$$\Gamma(z) = \int_0^{\infty} t^{z-1} e^{-t} dt \quad (2.98)$$

A função distribuição acumulada de  $\chi_k^2$  é dada pela Equação (2.99) e sua curva está traçada na Figura 20 para alguns graus de liberdade.

$$F_k(x) = \frac{\gamma(\frac{k}{2}, \frac{x}{2})}{\Gamma(\frac{k}{2})} \quad (2.99)$$

Sendo  $\gamma(\cdot)$  a função gama incompleta definida pela Equação (2.100)

$$\gamma(s, x) = \int_0^x t^{s-1} e^{-t} dt \quad (2.100)$$




Figura 19 – Função de densidade da distribuição  $\chi^2$ , para vários graus de liberdade  $k$

Figura retirada de [http://en.wikipedia.org/wiki/Chi-squared\\_distribution](http://en.wikipedia.org/wiki/Chi-squared_distribution)




Figura 20 – Função distribuição acumulada da distribuição  $\chi^2$ , para vários graus de liberdade  $k$   
 Figura retirada de [http://en.wikipedia.org/wiki/Chi-squared\\_distribution](http://en.wikipedia.org/wiki/Chi-squared_distribution)

Em problemas de classificação de padrões, pode-se avaliar a dependência entre a classe de uma amostra, definida pela variável  $C \in \{c_1, \dots, c_n\}$  e um atributo da amostra, definido pela variável discreta  $A \in \{a_1, \dots, a_m\}$ . Primeiramente são definidas duas hipóteses: a hipótese nula ( $H_0$ ), a qual será avaliada pelo teste, e a hipótese alternativa ( $H_a$ ), que será estatisticamente comprovada caso a hipótese nula não seja sustentada. Então são definidos dois conjuntos de valores:

$O_{ij}$  : Número de amostras observadas com  $C = c_i$  e  $A = a_j$ .

$E_{ij}$ : Número de amostras esperadas com  $C = c_i$  e  $A = a_j$ , se a hipótese  $H_0$  for verdadeira.

Com  $i = 1, \dots, n$  e  $j = 1, \dots, m$ .

O atributo estatístico  $X^2$  é então dado pela Equação (2.101) (MENDENHALL; BEAVER; BEAVER, 2013).

$$X^2 = \sum_{i=1}^n \sum_{j=1}^m \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \quad (2.101)$$

Se  $H_0$  for verdadeira,  $X^2$  terá um valor próximo de zero. Se  $X^2$  apresentar um valor elevado é provável que  $H_0$  não seja verdadeira e, conseqüentemente, a hipótese  $H_a$  seja mais plausível. É possível se atribuir um nível de confiabilidade estatístico no descarte ou na permanência da

hipótese  $H_0$ . Como para um número suficientemente grande de amostras, em repetidos experimentos  $X^2$  apresenta uma distribuição próxima de  $\chi_k^2$  com  $k = (m-1)(n-1)$  (MENDENHALL; BEAVER; BEAVER, 2013), é possível calcular a probabilidade de  $H_0$  ser verdadeira a partir da função distribuição acumulada da Equação (2.99). Sendo  $x$  o valor calculado de  $X^2$ , a probabilidade de se obter  $X^2 \geq x$  ( $P(X^2 \geq x)$ ), sendo  $H_0$  verdadeira é  $1 - F_k(x)$  e, portanto, essa é a probabilidade de  $H_0$  ser verdadeira.

No problema de classificação de padrões, para se avaliar a importância de um atributo, pode-se assumir a hipótese nula  $H_0$  como sendo a total independência entre a classe e o atributo. A partir dessa hipótese pode-se estimar os valores esperados para as amostras  $\hat{E}_{ij}$ . Sendo  $\hat{p}_{ci}$  a probabilidade estimada de uma amostra pertencer à classe  $c_i$ , e  $\hat{p}_{aj}$  a probabilidade estimada de o atributo da amostra ter valor  $a_j$ , então:

$$\hat{p}_{ci} = \frac{\text{Número de amostras da classe } c_i}{\text{Número total de amostras}} = \frac{\sum_{r=1}^m O_{ir}}{N_{am}} \quad (2.102)$$

$$\hat{p}_{aj} = \frac{\text{Número de amostras com atributo } a_j}{\text{Número total de amostras}} = \frac{\sum_{r=1}^n O_{rj}}{N_{am}} \quad (2.103)$$

$$\hat{E}_{ij} = \hat{p}_{ci}\hat{p}_{aj} = \frac{(\sum_{r=1}^m O_{ik})(\sum_{r=1}^n O_{kj})}{N_{am}} \quad (2.104)$$

Faz-se, então,  $E_{ij} = \hat{E}_{ij}$  e calcula-se  $X^2$  pela Equação (2.101). Quanto maior for  $X^2$ , maior a importância do atributo. É necessário se salientar, que para calcular  $X^2$ , o atributo deve ser uma variável discreta. Se esse não for o caso, um método de discretização deve ser aplicado.

## 3. MATERIAIS E MÉTODOS

Este capítulo apresentará o método desenvolvido para a classificação de amostras de café em grãos, assim como todo material utilizado no processo. Na Seção 3.1 serão apresentados o software utilizado no auxílio do desenvolvimento das rotinas envolvidas no método e o ambiente de desenvolvimento. A Seção 3.2 caracterizará o conjunto de amostras e impurezas no qual foi baseado o desenvolvimento do método, e a forma como foi construído um banco de dados para armazenar suas informações é descrita na Seção 3.8. O método é apresentado de maneira sucinta na Seção 3.3 e detalhado nas seções seguintes. Os critérios adotados para se avaliar o método são apresentados na Seção 3.4. A configuração das redes neurais utilizadas e os parâmetros dos processos de avaliação são dados na Seção 3.5. O hardware adotado para realizar a captura de imagens de amostras é descrito na Seção 3.6 e a segmentação e individualização dos grãos das imagens na Seção 3.7. A Seção 3.9 caracteriza os atributos que compuseram os diferentes vetores de características avaliados, sendo que na Seção 3.9.3.2 será explanado como os descritores de Haralick foram modificados para serem utilizados como atributos de textura dos vetores de características. A Seção 3.10 definirá as classes a serem identificadas em cada etapa dos processos classificatórios avaliados. O processo de seleção de atributos utilizado para reduzir o número de características empregadas é descrito na Seção 3.11. E finalmente, a Seção 3.12 detalha como foi definido o processo classificatório.

### 3.1. Especificação do *Software*

O desenvolvimento do software que realiza todos os passos englobados no método proposto foi realizado em linguagem Java, utilizando a IDE NetBeans<sup>1</sup> na versão 7.2 e com o auxílio de bibliotecas de manipulação de imagens, como JAI<sup>2</sup> (Java Advanced Imaging) e ImageJ<sup>3</sup>. Para o manuseio das redes neurais e aplicação da PCA foi utilizado um pacote de ferramentas de mineração de dados chamado WEKA<sup>4</sup> (WITTEN; FRANK; HALL, 2011), contendo

---

<sup>1</sup> Disponível em <http://www.netbeans.org/downloads/>. Acessado em 16/05/2014.

<sup>2</sup> Disponível em <http://www.oracle.com/technetwork/java/download-1-0-2-140451.html>. Acessado em 16/05/2014.

<sup>3</sup> Disponível em <http://rsbweb.nih.gov/ij/download.html>. Acessado em 16/05/2014.

<sup>4</sup> Disponível em <http://www.cs.waikato.ac.nz/ml/weka/>. Acessado em 16/05/2014.

implementações de algoritmos relacionados à PMC e a outras redes neurais. Também foram utilizadas as implementações dos algoritmos de seleção de atributos fornecidas pelo WEKA.

### 3.2. Amostras

As categorias de classificação de café adotadas neste trabalho foram as utilizadas pela Cooperativa Regional de Cafeicultores de Guaxupé Ltda. (Cooxupé), que forneceu amostras de grãos contendo grãos perfeitos, com defeitos e impurezas já separados e classificados por especialistas da cooperativa. Essas amostras foram utilizadas como referências para o desenvolvimento do método e sua validação. As diferentes classes de grãos e impurezas a serem identificadas neste trabalho são apresentadas Figura 21.




Figura 21 – Classes de grãos e impurezas.

(a) ardido, (b) barrento, (c) branco, (d) brocado, (e) cabeça, (f) casca, (g) casca de marinheiro, (h) perfeito, (i) chocho, (j) coco, (k) concha, (l) marinheiro, (m) melado, (n) pau, (o) pedra, (p) preto, (q) preto-verde, (r) quebrado, (s) triângulo, (t) velho, (u) verde

Os defeitos são: ardido, barrento, branco, brocado, cabeça, chocho, concha, marinheiro, melado, preto, preto-verde, quebrado, triângulo, velho e verde. As impurezas são: casca, casca



de marinho, coco, pau e pedra. Portanto, com a classe de grãos perfeito, tem-se um total de 21 classes.

No total foram utilizadas 15.773 amostras, distribuídas por classe de acordo com a Tabela 1, que está ilustrada no Gráfico 1.

**Tabela 1 – Distribuição do número de amostras por classe**

<b>Classe</b>	<b>Quantidade</b>
Perfeito	2585
Ardido	518
Barrento	788
Branco	667
Brocado	710
Cabeça	698
Casca	496
Casca de marinho	499
Chocho	798
Coco	544
Concha	588
Marinho	547
Melado	502
Pau	637
Pedra	710
Preto	577
Preto Verde	746
Quebrado	920
Triângulo	820
Velho	633
Verde	790




Gráfico 1 – Distribuição do número de amostras por classe

Percebe-se que há uma distribuição razoavelmente uniforme entre as classes, com exceção da classe perfeito, que apresenta um número muito maior de amostras. Isso se deve ao fato de que esta classe é subdividida em nove outras – as peneiras – uma classificação adicional utilizada pelas cooperativas que agrupa grãos de acordo com seus tamanhos. Essa classificação remete ao processo de separação dos grãos por tamanho, onde são utilizadas peneiras com crivos de medidas distintas. As medidas dos crivos das peneiras são dadas em frações de 1/64 de polegada e o número da peneira corresponde ao numerador da fração. Por exemplo: a peneira 19 está associada ao crivo de 19/64 de polegada. Como grãos perfeitos devem ser identificados independentemente de sua peneira, uma quantidade significativa de cada peneira deve ser utilizada.

As 2585 amostras de grãos perfeitos estão distribuídas entre as nove peneiras de acordo conforme a Tabela 2 e o Gráfico 2.

Tabela 2 – Distribuição do número de amostras de grãos perfeitos por peneira

Peneira	Quantidade
MK11	278
MK12	257
PN13	295
PN14	293
PN15	309
PN16	319
PN17	300
PN18	270
PN19	264




Gráfico 2 – Distribuição do número de amostras de grãos perfeitos por peneira

### 3.3. Visão geral do método

O método adotado neste trabalho é apresentado resumidamente nesta seção. Primeiramente, imagens das amostras foram adquiridas, então definiu-se uma técnica de segmentação dos grãos, possibilitando a separação dos objetos de interesse do fundo das imagens. Com isso foi possível criar um banco de dados de amostras pré-classificadas, e então extrair diversos atributos de cor, morfológicos e de textura.

Posteriormente foram avaliados métodos para se realizar a classificação em si. Para tanto, foram definidas cinco análises: utilizando somente atributos morfológicos ( $A_M$ ); utilizando somente atributos de cor ( $A_C$ ); utilizando somente atributos de textura ( $A_T$ ); utilizando somente

atributos de cor e textura ( $A_{CT}$ ); e utilizando todos os atributos juntos ( $A_{MCT}$ ). Cada uma dessas análises consiste na classificação do grão por uma rede neural previamente treinada com os atributos associados a ela. A determinação de quais atributos foram utilizados para as redes neurais foi feita por meio de um processo de seleção de atributos. Para cada análise são definidas diferentes classes a serem identificadas, as quais são a fusão das classes originais do problema (impurezas e defeitos).

Finalmente, foram avaliados três processos de classificação, os quais se utilizam das análises descritas:

**$P_{MCT}$** : Classificar diretamente a partir da análise  $A_{MCT}$ .

**$P_{M+C+T}$** : Realizar as análises  $A_M$ ,  $A_C$  e  $A_T$  paralelamente e cruzar os resultados para definir a classificação final.

**$P_{M+CT}$** : Realizar as análises  $A_M$  e  $A_{CT}$  paralelamente e cruzar os resultados para definir a classificação final.

A Figura 22 apresenta o método em linhas gerais, por meio de um fluxograma. O processo representado pelo bloco A é detalhado na Seção 3.6. O processo do bloco B é apresentado na Seção 3.7. O processo do bloco C é discutido na Seção 3.8. Os atributos extraídos no processo do bloco D são descritos na Seção 3.9. O processo definido pelo conjunto de blocos E é detalhado na Seção 3.11. Finalmente, os processos dos blocos F e G são descritos na Seção 3.12.

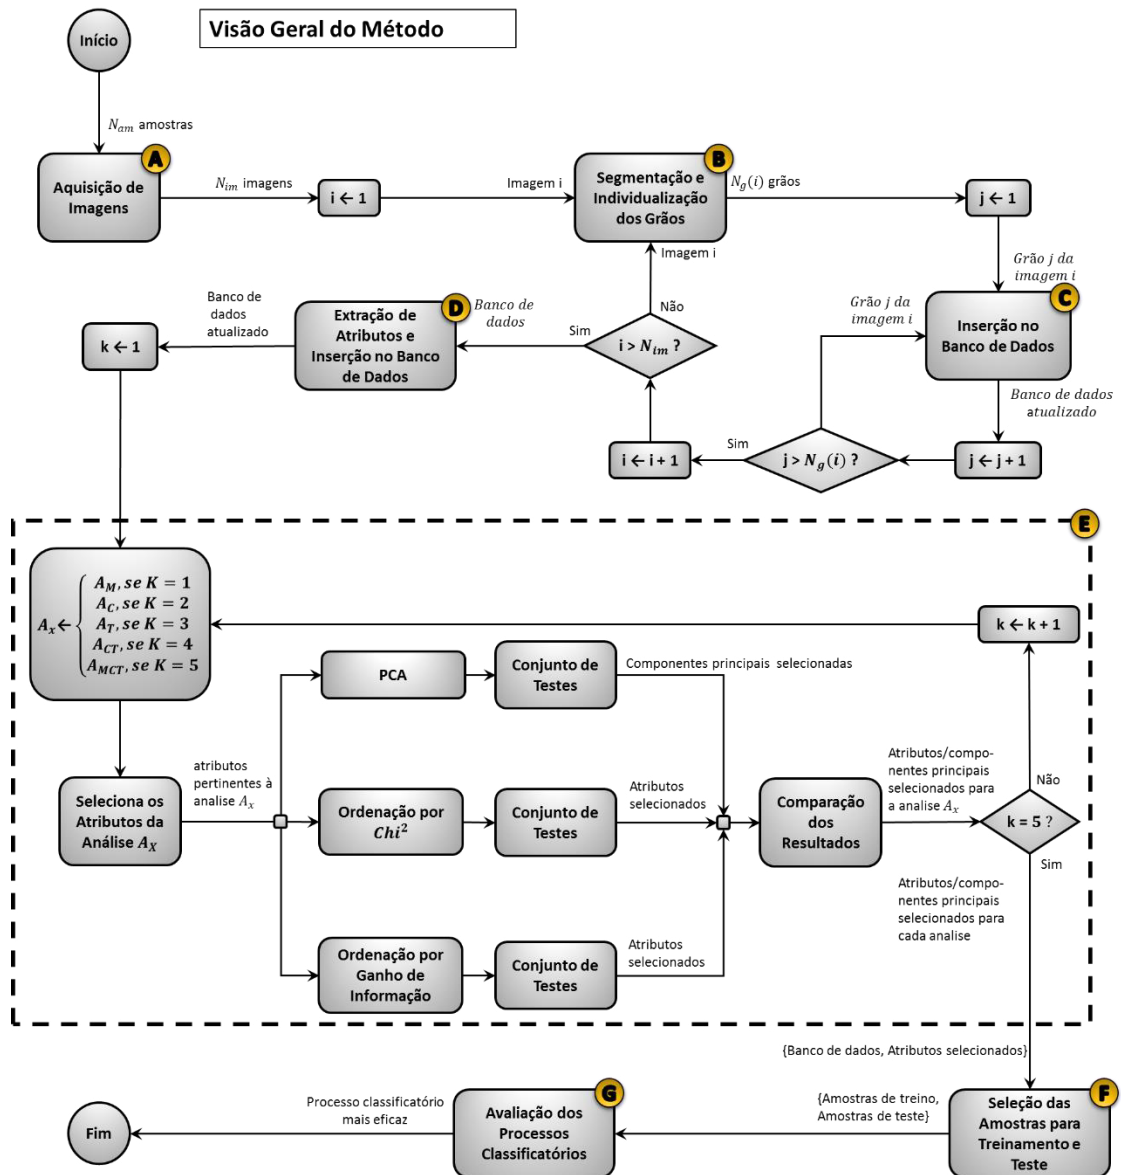


Figura 22 – Fluxograma do método

### 3.4. Critérios de Avaliação

O principal critério de comparação de resultados foi a acurácia (Equação (3.1)), critério esse adotado pela maioria dos trabalhos apresentados na Introdução.

$$\text{Acurácia} = \frac{\text{Número de instâncias corretamente classificadas}}{\text{Total de instâncias classificadas}} \quad (3.1)$$

Outros critérios também foram utilizados: precisão, recall e F-Measure. O conceito de precisão define a proporção de acertos ao se atribuir uma certa classe aos objetos sendo classificados. O conceito de recall define a proporção de acerto ao se classificar objetos de uma certa classe. A F-Measure é uma forma de avaliar tanto a precisão quanto o recall utilizando uma só medida. Para tanto, é realizada a média harmônica entre os dois critérios.

Para calcular esses critérios deve-se definir os seguintes conceitos:

Número de verdadeiros positivos da classe C:  $VP(C)$  = Número de vezes que a classe C foi corretamente atribuída a um objeto

Número de falsos positivos da classe C:  $FP(C)$  = Número de vezes que a classe C foi erroneamente atribuída a um objeto

Número de falsos negativos da classe C:  $FN(C)$  = Número de vezes que a um objeto foi erroneamente atribuída a classe C

Então a precisão, o recall e a F-Measure para uma classe C são dados pelas equações abaixo:

$$precisão(C) = \frac{VP(C)}{VP(C) + FP(C)} \quad (3.2)$$

$$recall(C) = \frac{VP(C)}{VP(C) + FN(C)} \quad (3.3)$$

$$F - Measure(C) = \frac{2 \text{ precisão}(C) \text{ recall}(C)}{\text{ precisão}(C) + \text{ recall}(C)} \quad (3.4)$$

O recall médio das classes pode ser utilizado para verificar se o valor da acurácia é consistente, não sendo fruto de um classificador viciado, que tende a indicar a classe mais recorrente, por exemplo, no caso de não uniformidade de distribuição de instâncias entre as classes. Valores de acurácia e de recall médio muito diferentes podem ser um indício dessa condição.

### 3.5. Topologia das Redes Neurais

Redes neurais do tipo PCM, treinadas com o algoritmo backpropagation, foram os classificadores adotados neste trabalho. Os parâmetros de treinamentos utilizados foram: taxa de aprendizagem  $\eta = 0,1$ , momentum  $\alpha = 0,5$  e como critério de parada a execução de 5.000 épocas. As topologias são a mesma para todas as redes, com três camadas: uma de entrada (com um neurônio para cada elemento do vetor de características), uma de saída (um neurônio para cada uma das classes a serem identificadas), e uma escondida. Como o trabalho exigiu a comparação de resultados de classificações com números diferentes de dados de entrada e de saída, padronizou-se o número de neurônios da camada escondida em função do número de entradas e saídas. Dessa forma, o número de neurônios da camada escondida  $N_{ce}$  é calculado para cada rede, segundo a Equação (3.5), arredondando para baixo.

$$N_{ce} = (N_e + N_s)/2 \quad (3.5)$$

Onde:

$N_e$ : Número de neurônios na camada de entrada.

$N_s$ : Número de neurônios na camada de saída.

A maioria das classificações das redes neurais foi avaliada utilizando-se a validação cruzada pelo método k-folds (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Por esse método o conjunto de amostras é dividido em k subconjuntos mutualmente exclusivos de tamanhos iguais (quando possível). Então são realizadas k iterações de um processo que consiste no treinamento de uma rede neural seguido da sua utilização na classificação de um conjunto de amostras de validação. Em cada iteração um subconjunto diferente é utilizado para realizar a validação e os (k-1) subconjuntos restantes são utilizados para o treinamento. É feita a média dos resultados da classificação do conjunto de validação de cada iteração para definir um resultado final.

### 3.6. Hardware e Aquisição de Imagens

Para se poder capturar imagens das amostras de café por um método sistemático, com o qual todas as condições que afetam a foto pudessem ser reproduzidas exatamente da mesma forma a cada processo de aquisição, uma câmara foi desenvolvida (representação esquemática

na Figura 23). Ela é composta por uma bandeja horizontal revestida com a cor azul, onde os grãos são depositados, sob condições controladas de luz. A bandeja é iluminada por um conjunto de lâmpadas de LED e uma câmera de vídeo é posicionada cerca de 60cm acima dela. A câmera é do modelo GC1020C<sup>1</sup>, da marca AVT. Ela é do tipo IP acessível por uma interface Gigabit Ethernet. As imagens são capturadas e armazenadas no formato bitmap com resolução de 1024x768 pixels.




Figura 23 – Estrutura interna do aparato de captura de imagens

### 3.7.Segmentação e Individualização

A primeira etapa do método é a identificação de grãos e impurezas presentes na amostra. O fundo de cor azul foi escolhido devido ao fato de nenhuma das classes apresentarem tonalidades próximas a essa cor, como pode ser observado na Figura 21, de forma a facilitar a segmentação

---

<sup>1</sup> Manual com especificações completas está disponível em: [http://www.alliedvisiontec.com/fileadmin/content/PDF/Products/Technical\\_Manual/Prosilica\\_GC/70-0064\\_GC\\_TechMan\\_V2.0.pdf](http://www.alliedvisiontec.com/fileadmin/content/PDF/Products/Technical_Manual/Prosilica_GC/70-0064_GC_TechMan_V2.0.pdf). Acessado em 16/05/14.



da imagem. Analisando-se o espaço de cor RGB, percebe-se que as tonalidades de azul apresentam valores de B significativamente maiores que de R e G. Definiu-se então a seguinte função de segmentação:

<p>SE <math>B \geq X * R</math> e <math>B \geq X * G</math>  ENTÃO é um pixel de fundo.  SENÃO é um pixel de objeto.</p>
--

Sendo que R, G e B são as componentes de cor do pixel a ser avaliado e X é um parâmetro a ser encontrado empiricamente.

A função de segmentação foi testada para diversos valores de X, avaliando-se visualmente o resultado obtido. Os testes foram realizados utilizando-se amostras que apresentassem objetos de diferentes colorações, desde grãos muito escuros a grãos mais claros e com tonalidades diversificadas (pedras, paus, grãos marinheiro, etc.). O valor de X que apresentou os melhores resultados foi 3,3.

Tendo os objetos sido separados do fundo, a imagem é binarizada para que os outros algoritmos possam ser aplicados. A partir da imagem binarizada é finalmente executado um algoritmo para rotular as diferentes formas. A rotulação é feita pelo método das componentes conexas, o qual agrupa os pixels de acordo com as suas conectividades. Existem duas variantes que definem a conectividade dos pixels: a vizinhança-de-4 e a vizinhança-de-8. A primeira considera que dois pixels são vizinhos somente se estiverem conectados pelos eixos vertical ou horizontal, enquanto a segunda, adotada neste trabalho, também considera os diagonais. Uma componente conexa é um grupo de pixels que compartilham da propriedade de que existe um caminho de ligação (uma sucessão de vizinhos) entre quaisquer dois deles (Costa e Cesar, 2000). Uma vez definidas as componentes conexas, cada uma delas e seus respectivos pixels são rotulados, representando um objeto diferente. Depois de rotuladas todas as formas presentes na imagem, é trivial se extrair os pixels de seus contornos.

Finalmente, são descartados os objetos compostos por menos que 40 pixels, por eles serem muito pequenos para representar um objeto de interesse, provavelmente sendo resultado de ruído da imagem ou uma falha no algoritmo de identificação.

Na Figura 24 pode ser visualizada uma imagem de saída do processo de identificação de grãos. Nesta imagem, os contornos dos grãos foram pintados de verde e numerados sequencialmente.




Figura 24 – Grãos identificados e rotulados

### 3.8.Criação de um Banco de Dados de Amostras

As amostras descritas na Seção 3.2 foram digitalizadas e individualizadas pelo método descrito na Seção 3.7. Cada um dos objetos de interesse (grãos ou impurezas) foi armazenado em um banco de dados JAVA DB<sup>1</sup>, o qual oferece suporte a consultas SQL. Para cada objeto foram armazenadas as seguintes informações: sua classe, a escala da imagem (pixels/mm) e informações sobre cada um de seus pixels componentes. Cada um desses pixels apresentam as seguintes informações: suas coordenadas X e Y em relação a sua imagem de origem, seus valores R, G e B e também a informação se este pixel pertence ou não à borda do objeto. Essa última informação é necessária para se recuperar os contornos dos objetos.

---

<sup>1</sup> Mais informações em: <http://www.oracle.com/technetwork/java/javadb/overview/index.html> (Acessado em 16/05/2014)

### 3.9. Caracterização dos Atributos

Esta seção apresentará os atributos adotados neste estudo, juntamente com os parâmetros utilizados para calculá-los. Os atributos são divididos em três naturezas: atributos morfológicos, atributos de cor e atributos de textura. Os atributos descritos nas próximas subseções foram calculados para cada uma das amostras presentes no banco de dados descrito na Seção 3.8. Foram definidos cinco banco de dados para comportarem os atributos calculados:

$\text{Banco}_M$ : banco de dados contendo os atributos morfológicos das amostras do banco de amostras.

$\text{Banco}_C$ : banco de dados contendo os atributos de cor das amostras do banco de amostras.

$\text{Banco}_T$ : banco de dados contendo os atributos de textura das amostras do banco de amostras.

$\text{Banco}_{CT}$ :  $\text{Banco}_C \bowtie \text{Banco}_T$ .

$\text{Banco}_{MCT}$ :  $\text{Banco}_M \bowtie \text{Banco}_C \bowtie \text{Banco}_T$ .

Onde  $\bowtie$  representa a operação JOIN da álgebra relacional aplicada sobre o número identificador da amostra.

Cada um desses bancos está associado a uma das análises apresentadas na Seção 3.3. De forma que os atributos contidos no  $\text{Banco}_M$  foram utilizados pela análise  $A_M$  (após o processo de seleção de atributos descrito na Seção 3.11), e assim por diante.

#### 3.9.1. Atributos Morfológicos

Os conceitos e o cálculo dos atributos morfológicos foram apresentados na Seção 2.3. Neste trabalho foram utilizados os atributos a seguir: 39 Descritores de Fourier de menor ordem, calculados a partir da assinatura dada pelas distâncias da borda ao centroide; 28 DGFs, referentes a 4 diferentes frequências radiais ( $R=m=4$ ) e 7 diferentes frequências angulares ( $T=N=7$ ), parâmetros esses determinados por avaliações conduzidas por Oyama, Rodrigues e Jorge (2012); elementos do Modelo Autorregressivo até ordem 10 ( $N_R=10$ ), calculados utilizando 60 raios ( $N_{AR} = 60$ ), resultando em 11 atributos; Momentos de Zernike até ordem 20 ( $n_Z = 20$ ), com todas as suas repetições, resultando em 121 valores; e os 12 atributos unitários

( área, perímetro, eixo maior, eixo menor, excentricidade, spread, slenderness,  $A_1$ ,  $A_2$ ,  $A_3$ ,  $A_4$  e  $A_5$ ). Portanto, contou-se com um total de 211 atributos morfológicos.

Esses 211 atributos foram calculados para cada uma das amostras do banco de amostras e os valores foram inseridos no  $Bancom$ .

### 3.9.2. Atributos de Cor

Dois conjuntos de atributos foram comparados na definição dos atributos de cor: histogramas de frequências normalizadas de cores, e atributos estatísticos extraídos desses histogramas. Os atributos e sua avaliação são apresentadas a seguir.

#### 3.9.2.1. Histograma de Frequências Normalizadas de Cores

Nas etapas iniciais do trabalho avaliou-se o uso de histogramas de frequências normalizadas das cores dos pixels dos grãos como atributos de cor. As frequências dos histogramas de um dado espaço de cor foram utilizadas como atributos da amostra no processo de classificação. Histogramas de vários espaços de cor foram avaliados.

Como o número de cores possíveis de serem representadas pelos espaços de cor adotados é muito elevado, da ordem de dezenas de milhões, os espaços de cor precisaram ser quantizados para tornar viável o cálculo dos histogramas e sua utilização como um conjunto de atributos. A quantização foi feita linearmente, de modo que cada um dos novos valores quantizados acomodasse o mesmo número de cores do modelo original. A quantização de um canal de um espaço de cor feita segundo a Equação (3.6):

$$Q(V_C) = \begin{cases} N_{val} - 1 & , \quad se \ V_C = V_{max,C} \\ ARREDONDA \left( N_{val} \frac{V_C - V_{min,C}}{V_{max,C} - V_{min,C}} \right) & , \quad caso \ contrário \end{cases} \quad (3.6)$$

Sendo que  $Q(V_C)$  é o valor quantizado,  $V_C$  é o valor do modelo de cor original, cujo domínio é limitado por  $V_{min,C}$  e  $V_{max,C}$ . O índice  $C$  determina o canal do espaço de cor que está sendo quantizado. A função  $ARREDONDA(x)$  arredonda  $x$  para o inteiro de menor valor. O canal quantizado apresentará  $N_{val}$  possíveis valores, situados no intervalo discreto  $[0, N_{val} - 1]$ .

Como no banco de amostra estão armazenados os valores R, G e B de cada pixel de uma amostra, o cálculo dos histogramas para cada canal do espaço RGB é facilmente feito. Além dos histogramas do espaço RGB, foram avaliados os histogramas dos seguintes espaços de cor: YUV, YIQ, YDbDr, YPbPr, YCbCr, CIE XYZ, CIELAB, HSV, RGB normalizado (rgb) e  $I_1I_2I_3$ . A conversão do espaço RGB para outros espaços de cor é dada pelas equações apresentadas na Seção 2.2.

Todos os histogramas foram calculados quantizando cada canal dos espaços de cor em 10 valores ( $N_{val} = 10$ ). As 30 frequências provenientes dos histogramas dos canais de um mesmo espaço de cor foram utilizadas como vetor de característica para classificar os grãos. Ou seja, 12 conjuntos de atributos foram avaliados, um para cada espaço de cor. A avaliação de cada conjunto de atributos se deu pelo método da validação cruzada com 10 folds, utilizando as instâncias do banco de amostras para derivar os atributos e adotando redes neurais PMC como classificadores, conforme a configuração apresentada na Seção 3.5.

Nesta avaliação preliminar dos atributos foram utilizadas somente classes caracterizadas por sua cor. Das classes apresentadas na Figura 21 foram selecionadas 17 com essa característica: perfeito, pedra, melado, branco, concha, casca, preto-verde, barrento, coco, preto, pau, ardido, marinho, brocado, velho, verde e casca de marinho. E visto que o par de classes coco e casca representam essencialmente a mesma classe no que diz respeito à cor, já que ambos têm a mesma composição externa, porém com interiores diferentes, sendo diferenciáveis somente por forma, essas duas classes foram condensadas em uma só. A mesma situação é observada com as classes marinho e casca de marinho, as quais também foram englobadas em uma classe só. Portanto, apenas as classes ‘cabeça’, ‘triângulo’, ‘chocho’ e ‘quebrado’ foram excluídas e 15 classes foram utilizadas na avaliação, que foi promovida com 12.537 amostras.

Os resultados das avaliações são apresentados na Tabela 3, com o melhor desempenho destacado. Esses resultados serão melhor discutidos na Seção 4.1.

**Tabela 3 – Acurácias para cada espaço de cor, das classificações utilizando histogramas de frequências normalizadas das cores do grão como vetor de características**

<b>Espaço de Cor</b>	<b>Acurácia (%)</b>
RGB	69,92
HSV	74,33
YCbCr	69,93
YCgCr	67,06
YIQ	68,98
YPbPr	69,87
YUV	69,79
YDbDr	69,88
CIE XYZ	58,63
CIELAB	74,23
rgb	63,71
I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	70,99

### **3.9.2.2. Atributos Estatísticos de Histogramas**

A fim de se melhorar a etapa de classificação por cor, avaliou-se o uso de outros atributos em um novo experimento. Acreditando que as informações de cor estavam muito dispersas pelas frequências dos histogramas, e que uma técnica para condensá-las em um menor número de atributos poderia melhorar a acurácia, optou-se por extrair atributos estatísticos dos histogramas e utilizá-los como descritores. Os atributos utilizados foram: média, variância, obliquidade, curtose, energia, entropia e suavidade. A forma de calculá-los é apresentada pelas equações abaixo.

Tendo um histograma dividido em I intervalos, e sendo  $F(i) \in [0,1]$  a frequência normalizada associada ao intervalo i, calculamos seus atributos estatísticos como abaixo (MALIK; BAHARUDIN, 2013):

$$Média = \sum_{i=1}^I iF(i) \quad (3.7)$$

$$Desvio\ Padrão = \sqrt{\sum_{i=1}^I (i - Média)^2 F(i)} \quad (3.8)$$

$$\text{Variância} = (\text{Desvio Padrão})^2 \quad (3.9)$$

$$\text{Obliquidade} = \frac{1}{(\text{Desvio Padrão})^3} \sum_{i=1}^I (i - \text{Média})^3 F(i) \quad (3.10)$$

$$\text{Curtose} = \frac{1}{(\text{Desvio Padrão})^4} \sum_{i=1}^I (i - \text{Média})^4 F(i) \quad (3.11)$$

$$\text{Energia} = \sum_{i=1}^I (F(i))^2 \quad (3.12)$$

$$\text{Entropia} = - \sum_{i=1}^I [ F(i) \log_2 F(i) ] \quad (3.13)$$

$$\text{Suavidade} = 1 - \frac{1}{1 + (\text{Desvio Padrão})^2} \quad (3.14)$$

Analisando os resultados da Tabela 3, nota-se três espaços de cor que se destacaram positivamente – HSV, CIELAB e  $I_1I_2I_3$  – e dois que se destacaram negativamente – rgb e CIE XYZ. O restante apresentou resultados razoáveis e muito parecidos. Então, para avaliar o segunda abordagem de atributos de cor, foram escolhidos os três espaços que se destacaram positivamente e um dos que apresentaram resultados medianos, o RGB. Assim, para esta nova avaliação foram utilizados os espaços de cor HSV, CIELAB e  $I_1I_2I_3$  e RGB.

Cada um dos sete atributos estatísticos foi calculado para cada um dos canais dos quatro espaços de cor. Os atributos foram extraídos de histogramas de 100 intervalos ( $I = 100$ ), os quais foram calculados quantizando os espaços de cor segundo a Equação (3.6) para  $N_{\text{val}} = 100$ . Todos os atributos extraídos foram utilizados em conjunto como vetor de características, o qual contou, portanto, com 84 elementos. Esse vetor de características foi submetido à mesma avaliação que os vetores formados por histogramas, pela validação cruzada com 10 folds e redes PMC. As mesmas classes e o mesmo banco de amostras foram utilizados.

O resultado dessa avaliação proporcionou uma acurácia de 80,09%, enquanto que a melhor classificação, também sob o critério da validação cruzada, utilizando histogramas de frequências normalizadas, teve a acurácia de 74,33%.

### **3.9.2.3. Atributos de Cor Seleccionados**

Pelos resultados apresentados, nota-se que um considerável ganho de acurácia foi obtido pela abordagem da extração de atributos estatísticos em relação a utilização dos histogramas diretamente, e assim, os atributos seleccionados para a análise de cor, e para posterior seleção de atributos, foram os 84 atributos estatísticos: média, variância, obliquidade, curtose, energia, entropia e suavidade extraídos de cada um dos histogramas (com 100 intervalos cada) dos canais dos espaços de cor HSV, CIELAB e  $I_1I_2I_3$  e RGB.

Esses 84 atributos foram calculados para cada uma das amostras do banco de amostras e os valores foram armazenados no Bancoc.

### **3.9.3. Atributos de Textura**

Para se definir os atributos a serem utilizados na análise de textura avaliaram-se os descritores de Haralick calculados para diferentes espaços de cor. A fim de se obter melhores resultados uma modificação nesses descritores foi proposta. Os resultados foram comparados e então definiu-se o conjunto de atributos para a análise.

#### **3.9.3.1. Descritores de Haralick**

Primeiramente avaliaram-se os descritores de Haralick como vetor de características para a análise por textura. Assim, como foi feito para os atributos de cor, vários espaços de cor foram avaliados. Os descritores de Haralick foram calculados com suas GLCMs sendo computadas em relação a todos os pixels de um grão. Os quatro possíveis ângulos de vizinhança ( $\theta = 0^\circ, 45^\circ, 90^\circ$  e  $135^\circ$ ) foram utilizados ao mesmo tempo para o cálculo da mesma GLCM, com a distância do pixel vizinho sendo  $d = 1$ . Os cálculos foram feitos com os pixels tendo 32 valores diferentes ( $N_{NC} = 32$ ), sendo que esses valores não necessariamente representam níveis de cinza, mas diferentes valores de um canal do espaço de cor. A quantização dos espaços de cor, para que cada canal tenha 32 valores, foi feita pela aplicação da Equação (3.6) com  $N_{val} = 32$ .

Foram avaliados os seguintes espaços de cor para o cálculo dos descritores: RGB, RGB normalizado (rgb),  $I_1I_2I_3$ , HSV e CIELAB. Além destes foi avaliado o espaço de cor de níveis



de cinza, o qual possui apenas um canal, e pode ser calculado dos valores RGB pela Equação (3.15).

$$C = 0,29894R + 0,58704G + 0,11402B \quad (3.15)$$

Para cada um dos espaços de cor foram avaliados 4 vetores de característica:

$$v_1^E = \{14 \text{ descritores de Haralick do canal 1 de } E\}$$

$$v_2^E = \{14 \text{ descritores de Haralick do canal 2 de } E\}$$

$$v_3^E = \{14 \text{ descritores de Haralick do canal 3 de } E\}$$

$$v_4^E = v_1^E \cup v_2^E \cup v_3^E$$

Sendo E um espaço de cor. Excepcionalmente para espaço de cor de níveis de cinza apenas o vetor  $v_1^E$  foi avaliado, já que ele conta apenas com um canal.

Do mesmo modo pelo qual foram avaliados os atributos de cor, foram avaliados os descritores de Haralick: pelo método da validação cruzada com 10 folds, com o uso de redes PMC. O mesmo banco de amostras foi utilizado para calcular os descritores e as mesmas classes foram definidas. O resultado das avaliações é apresentado na Tabela 4.

**Tabela 4 – Acurácias (em %), para cada vetor de características avaliado, das classificações utilizando descritores de Haralick**

<b>E</b>	<b><math>v_1^E</math></b>	<b><math>v_2^E</math></b>	<b><math>v_3^E</math></b>	<b><math>v_4^E</math></b>
CIELAB	L: 45,98	a*: 56,13	b*: 47,28	59,81
HSV	H: 45,38	S: 38,57	V: 23,59	53,66
rgb	r: 59,01	g: 64,54	b: 61,62	78,95
RGB	R:58,34	G:60,54	B:59,89	79,08
I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	I <sub>1</sub> : 59,02	I <sub>2</sub> : 65,07	I <sub>3</sub> : 62,14	<b>80,98</b>
Níveis de Cinza	C: 60,11	-	-	-

### 3.9.3.2. Modificação dos Descritores de Haralick

Com o intuito de se realizar uma análise de macrotextura de imagens, modificaram-se os descritores de Haralick para utilizar dois pixels de referência, ao invés de um, no cálculo da GLCM. O segundo pixel de referência é tido como aquele posicionado logo abaixo do primeiro pixel de referência, como ilustrado na Figura 25.

PV_8	PV_9	PV_0
PV_7	PR_1	PV_1
PV_6	PR_2	PV_2
PV_5	PV_4	PV_3

Figura 25 – Utilização de dois pixels de referência para o cálculo da GLCM  
Sendo PR\_1 o primeiro pixel de referência e PR\_2 o segundo

Portanto, a GLCM passa a ser uma matriz de três dimensões, sendo a primeira dimensão o valor do pixel de referência 1 (PR\_1), a segunda o valor do pixel de referência 2 (PR\_2), e a terceira o pixel vizinho (PV). Dessa forma, o elemento  $V_{i,j,k}$  da GLCM indica quantas ocorrências de PR\_1 com nível de cinza **i**, tendo PR\_2 com nível de cinza **j** e tendo um PV que apresenta nível de cinza **k** há na imagem. A Figura 26 ilustra uma GLCM para dois pixels de referência para uma imagem em preto e branco (com 2 níveis de cinza).

VPR1* ->		0		1	
VPR2* ->		0	1	0	1
Valor do pixel vizinho	0	V(0,0,0)	V(0,1,0)	V(1,0,0)	V(1,1,0)
	1	V(0,0,1)	V(0,1,1)	V(1,0,1)	V(1,1,1)

Figura 26 – GLCM para 2 níveis de cinza utilizando a abordagem de dois pixels de referência.

\* VPR1: Valor do pixel de referência 1; VPR2: Valor do pixel de referência 2

A normalização da GLCM em probabilidades  $P_{i,j,k}$  é dada, então, segundo a equação (3.16), para  $N_{NC}$  níveis de cinza.

$$P_{i,j,k} = \frac{V_{i,j,k}}{\sum_{p=0}^{N_{NC}-1} \sum_{q=0}^{N_{NC}-1} \sum_{r=0}^{N_{NC}-1} V_{p,q,r}} \quad (3.16)$$

Uma peculiaridade que surge quando tomamos dois pixels como referência é que deixa-se de ter uma simetria radial dos pixels vizinhos em relação à referência. Para o caso de um único pixel de referência, a ocorrência de um pixel vizinho na posição ( $d = d_0$  e  $\theta = 0^\circ$ ) com nível de cinza  $x$  e a ocorrência de outro pixel vizinho na posição ( $d = d_0$  e  $\theta = 45^\circ$ ) com o mesmo nível de cinza  $x$  representam a mesma relação entre pixel de referência e pixel vizinho, porém vistos de perspectivas diferentes (com uma rotação de  $45^\circ$ , neste caso), como se vê na Figura 27a. O mesmo não ocorre quando dois pixels são tomados como referência, pois ocorrências do mesmo nível de cinza em posições diferentes podem representar relações que não diferem por uma simples rotação, como fica claro na Figura 27b. Ainda assim, pode-se estabelecer relações de simetria em três configurações diferentes: para pixels vizinhos em posições diagonais em relação aos pixels de referência, para pixels vizinhos em posições horizontais em relação aos pixels de referência, e para pixels vizinhos em posições verticais em relação aos pixels de referência. Essas três configurações são mostradas na Figura 28. Sendo assim, podem ser calculadas três GLCMs, uma para cada uma dessas configurações. São definidas, então, três GLCMs: diagonal, vertical e horizontal, cujos elementos são definidos, respectivamente, como  $V_{i,j,k}^D$ ,  $V_{i,j,k}^V$  e  $V_{i,j,k}^H$ .

PV <sub>3</sub> (d = 1, θ = 135°)	PV <sub>2</sub> (d = 1, θ = 90°)	PV <sub>1</sub> (d = 1, θ = 45°)
PV <sub>4</sub> (d = 1, θ = 0°)	PR	PV <sub>0</sub> (d = 1, θ = 0°)
PV <sub>5</sub> (d = 1, θ = 45°)	PV <sub>6</sub> (d = 1, θ = 90°)	PV <sub>7</sub> (d = 1, θ = 135°)

PV <sub>3</sub> (d = 1, θ = 135°)	PV <sub>2</sub> (d = 1, θ = 90°)	PV <sub>1</sub> (d = 1, θ = 45°)
PV <sub>4</sub> (d = 1, θ = 0°)	PR	PV <sub>0</sub> (d = 1, θ = 0°)
PV <sub>5</sub> (d = 1, θ = 45°)	PV <sub>6</sub> (d = 1, θ = 90°)	PV <sub>7</sub> (d = 1, θ = 135°)

a)

PV <sub>8</sub>	PV <sub>9</sub>	PV <sub>0</sub>
PV <sub>7</sub>	PR <sub>1</sub>	PV <sub>1</sub>
PV <sub>6</sub>	PR <sub>2</sub>	PV <sub>2</sub>
PV <sub>5</sub>	PV <sub>4</sub>	PV <sub>3</sub>

PV <sub>8</sub>	PV <sub>9</sub>	PV <sub>0</sub>
PV <sub>7</sub>	PR <sub>1</sub>	PV <sub>1</sub>
PV <sub>6</sub>	PR <sub>2</sub>	PV <sub>2</sub>
PV <sub>5</sub>	PV <sub>4</sub>	PV <sub>3</sub>

b)

Figura 27 – Comparação de simetrias no cálculo das GLCM.

Simetria radial presente em a), mas ausente em b)




Figura 28 – As três configurações de simetria para a GLCM utilizando dois pixels de referência.

a) diagonal b) vertical e c) horizontal

Tomando como referência a Figura 25, a GLCM diagonal é computada para os pixels vizinhos PV\_0, PV\_3, PV\_5 e PV\_8; a GLCM vertical é computada para os pixels vizinhos PV\_4, e PV\_9; e a GLCM horizontal é computada para os pixels vizinhos PV\_1, PV\_2, PV\_6 e PV\_7. A Figura 29 ilustra a simetria para a configuração diagonal. Deve-se atentar que para certos pixels vizinhos, os pixels de referência aparecem invertidos em relação às configurações apresentadas na Figura 28, como pode ser observado na Figura 29, e esta inversão deve ser levada em conta na atualização da GLCM.

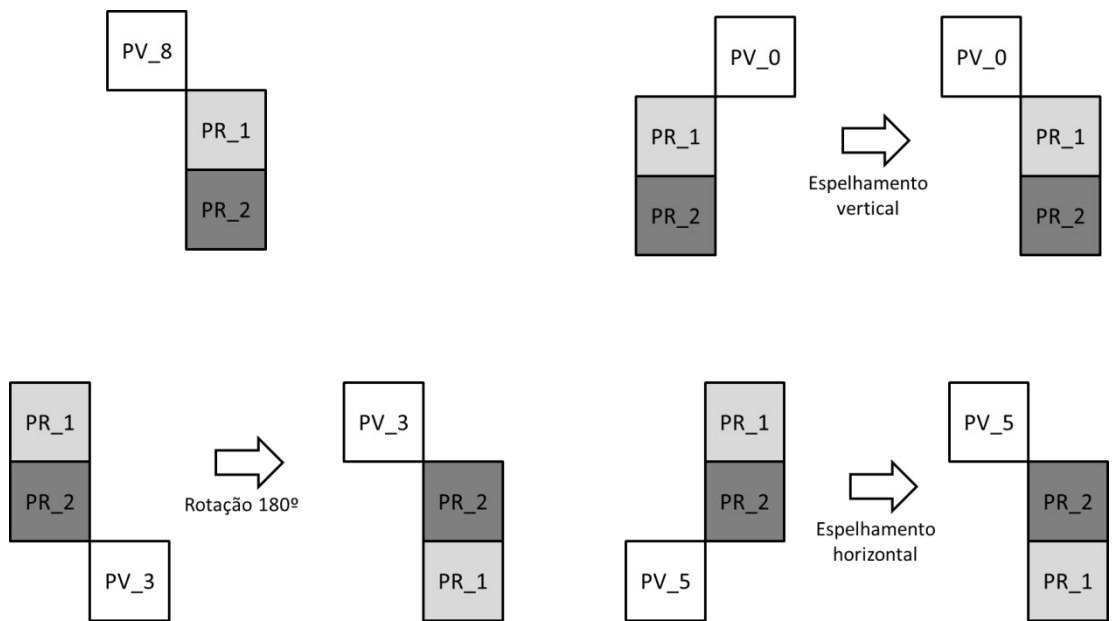


Figura 29 – Simetria diagonal para os pixels PV\_8, PV\_0, PV\_3 e PV\_5

Portanto, a Tabela 5 mostra para cada um dos pixels vizinhos, como é feita a atualização das GLCMs.

Tabela 5 – Atualização da GLCM para cada posição do pixel vizinho

Para pixel de referência 1 com nível de cinza  $i$ , pixel de referência 2 com nível de cinza  $j$  e pixel vizinho com nível de cinza  $k$

Pixel Vizinho	Elemento a ser incrementado	Pixel Vizinho	Elemento a ser incrementado	Pixel Vizinho	Elemento a ser incrementado
PV_0	$V_{i,j,k}^D$	PV_1	$V_{i,j,k}^H$	PV_9	$V_{i,j,k}^V$
PV_8		PV_7			
PV_3	$V_{j,i,k}^D$	PV_2	$V_{j,i,k}^H$	PV_4	$V_{j,i,k}^V$
PV_5		PV_6			

Havendo três GLCMs diferentes, a modificação proposta gera 42 descritores (14 para cada uma das matrizes). Os cálculos dos descritores também devem ser modificados para poderem comportar a nova abordagem. Os 14 descritores (de  $f_1$  a  $f_{14}$ ) foram definidos conforme as equações abaixo, com  $N_{NC}$  sendo o número de níveis de cinza da imagem.

$$P_x(i, j) = \sum_{k=0}^{N_{NC}-1} P_{i,j,k} \quad (3.17)$$

$$P_y(k) = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j,k} \quad (3.18)$$

$$P_{x+y}(a, b) = \sum_{i=1}^{N_{NC}} \sum_{j=1}^{N_{NC}} \sum_{k=1}^{N_{NC}} P_{i,j,k}, \quad (3.19)$$

$$\begin{cases} i + k = a \\ j + k = b \\ a = 2, \dots, 2N_{NC} \\ b = 2, \dots, 2N_{NC} \end{cases}$$

$$P_{x-y}(a, b) = \sum_{i=1}^{N_{NC}} \sum_{j=1}^{N_{NC}} \sum_{k=1}^{N_{NC}} P_{i,j,k}, \quad (3.20)$$

$$\begin{cases} |i - k| = a \\ |j - k| = b \\ a = 0, \dots, N_{NC} - 1 \\ b = 0, \dots, N_{NC} - 1 \end{cases}$$

$$\text{segundo momento angular} = f_1 = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} P_{i,j,k}^2 \quad (3.21)$$

$$\text{contraste} = f_2 = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} (i^2 + j^2) P_{x-y}(i, j) \quad (3.22)$$

$$\text{correlação} = f_3 = \frac{r_{ab} - r_{ac}r_{bc}}{\sqrt{(1 - r_{ac}^2)(1 - r_{bc}^2)}} \quad (3.23)$$

Onde

$$P_a(i) = \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} P_{i,j,k} \quad (3.24)$$

$$P_b(j) = \sum_{i=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} P_{i,j,k} \quad (3.25)$$

$$P_c(k) = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{i,j,k} \quad (3.26)$$

$$r_{ab} = \frac{\sum_{i=0}^{N_{NC}-1} (P_a(i) - \mu_a)(P_b(i) - \mu_b)}{\sigma_a \sigma_b} \quad (3.27)$$

$$r_{ac} = \frac{\sum_{i=0}^{N_{NC}-1} (P_a(i) - \mu_a)(P_c(i) - \mu_c)}{\sigma_a \sigma_c} \quad (3.28)$$

$$r_{bc} = \frac{\sum_{i=0}^{N_{NC}-1} (P_b(i) - \mu_b)(P_c(i) - \mu_c)}{\sigma_b \sigma_c} \quad (3.29)$$

Sendo  $\mu_a$ ,  $\mu_b$  e  $\mu_c$  as médias de  $P_a$ ,  $P_b$  e  $P_c$ , respectivamente, e  $\sigma_a$ ,  $\sigma_b$  e  $\sigma_c$  as variâncias de  $P_a$ ,  $P_b$  e  $P_c$ , respectivamente.

$$\text{variância} = f_4 = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} (|i-j| - \mu_{dif})^2 P_{i,j,k} \quad (3.30)$$

Onde  $\mu_{dif}$  é a média da diferença entre níveis de cinza do pixel de referência 1 e o pixel de referência 2.

$$\text{momento inverso da diferença} = f_5 = \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} \frac{P_{i,j,k}}{(1 + (i-k)^2 + (j-k)^2)} \quad (3.31)$$

$$\text{média da soma} = f_6 = \sum_{i=0}^{2N_{NC}-1} \sum_{j=0}^{2N_{NC}-1} (i+j) P_{x+y}(i,j) \quad (3.32)$$

$$\text{variância da soma} = f_7 = \sum_{i=0}^{2N_{NC}-1} \sum_{j=0}^{2N_{NC}-1} (i+j-f_8)^2 P_{x+y}(i,j) \quad (3.33)$$

$$\text{entropia da soma} = f_8 = - \sum_{i=0}^{2N_{NC}-1} \sum_{j=0}^{2N_{NC}-1} P_{x+y}(i,j) \log(P_{x+y}(i,j) + \epsilon) \quad (3.34)$$

, sendo  $\epsilon$  um número positivo pequeno, para evitar a ocorrência da indefinição  $\log(0)$ .

$$\text{entropia} = f_9 = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} P_{i,j,k} \log(P_{i,j,k} + \epsilon) \quad (3.35)$$

$$\text{diferença da variância} = f_{10} = \text{variância de } P_{x-y} \quad (3.36)$$

$$\text{entropia da diferença} = f_{11} = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_{x-y}(i,j) \log(P_{x-y}(i,j) + \epsilon) \quad (3.37)$$

$$\text{medida de correlação 1} = f_{12} = \frac{f_9 - HXY1}{\max\{HX, HY\}} \quad (3.38)$$

$$\text{medida de correlação 2} = f_{13} = \sqrt{1 - e^{-2(HXY2 - f_9)}} \quad (3.39)$$

Sendo

$$HX = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_x(i,j) \log(P_x(i,j) + \epsilon) \quad (3.40)$$

$$HY = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} P_y(i) \log(P_y(i) + \epsilon) \quad (3.41)$$

$$HXY1 = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} P_{i,j,k} \log(P_x(i,j) P_y(k) + \epsilon) \quad (3.42)$$



$$\text{HXY2} = - \sum_{i=0}^{N_{NC}-1} \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} P_x(i,j) P_y(k) \log(P_x(i,j)P_y(k) + \epsilon) \quad (3.43)$$

Na proposta original de Haralick o descritor de máximo coeficiente de correlação ( $f_{14}$ ) exige o cálculo dos autovalores da matriz de coocorrência. Para evitar se calcular autovalores em uma matriz de três dimensões, cuja abstração não é trivial, somente o pixel de referência 1 é utilizado em seu cálculo:

$$\text{máximo coeficiente de correlação} = f_{14} = (\text{segundo maior autovalor de } Q)^{\frac{1}{2}} \quad (3.44)$$

$$Q_{i,k} = \frac{P_{i,j}^{PR1} P_{k,j}^{PR1}}{P_x^{PR1}(i) P_y(k)} \quad (3.45)$$

Onde:

$$P_{i,k}^{PR1} = \sum_{j=0}^{N_{NC}-1} P_{i,j,k} \quad (3.46)$$

$$P_x^{PR1}(i) = \sum_{j=0}^{N_{NC}-1} \sum_{k=0}^{N_{NC}-1} P_{i,j,k} \quad (3.47)$$

Para se avaliar os efeitos da modificação, os descritores de Haralick calculados com dois pixels de referência foram submetidos aos mesmos procedimentos utilizados para avaliar os descritores de Haralick originais, conforme descrito anteriormente nesta seção. Desta vez foram avaliado três espaços de cor: RGB,  $I_1 I_2 I_3$  e níveis de cinza. Sendo que os dois primeiros foram os que obtiveram os melhores resultados para os descritores de Haralick com um pixel de referência e o último é o espaço abordado pela concepção original dos descritores. Os resultados obtidos são apresentados e comparados com os respectivos valores dos descritores originais na Tabela 6 (o melhor deles aparece destacado). Uma análise sobre esses resultados será realizada na Seção 4.2.

**Tabela 6 – Acurácias (em %), para cada vetor de características avaliado, das classificações utilizando descritores de Haralick com 2 pixels de referência. Comparadas com as respectivas acurácias dos descritores calculados com 1 pixel de referência**

Método	E	$v_1^E$	$v_2^E$	$v_3^E$	$v_4^E$
1 pixel	RGB	R:58,34	G:60,54	B:59,89	79,08
2 pixels	RGB	R:59,14	G:60,68	B:59,10	80,02
1 pixel	$I_1I_2I_3$	$I_1$ : 59,02	$I_2$ : 65,07	$I_3$ : 62,14	80,98
2 pixels	$I_1I_2I_3$	$I_1$ : 61,35	$I_2$ : 64,87	$I_3$ : 63,92	82,32
1 pixel	Níveis de cinza	60,11	-	-	-
2 pixels	Níveis de cinza	61,73	-	-	-

### 3.9.3.3. Atributos de Textura Selecionados

Constata-se que a modificação proposta superou a original em 7 das 9 classificações, ainda que de forma singela, conferindo a melhor classificação para análise de textura quando empregada sobre o espaço de cor  $I_1I_2I_3$ . Sendo assim, os atributos selecionados para compor a análise de textura foram os descritores de Haralick computados com 2 pixels de referência calculados para cada um dos canais do espaço de cor  $I_1I_2I_3$ , num total de 126 atributos.

Os 126 atributos foram calculados para cada uma das amostras do banco de amostras e os valores foram armazenados no BancOT.

## 3.10. Definição das Classes

Na determinação dos atributos utilizados em cada uma das análises, as classificações foram realizadas incluindo somente as classes de grãos e objetos discrimináveis para cada etapa de análise. Por exemplo, a classe de grão quebrado foi omitida das classificações que determinaram os atributos da análise por cor, pois ela não é discriminável por sua coloração, mas sim por sua forma. No entanto, ao se realizar uma análise não se tem a informação de antemão se um objeto é pertencente a uma dessas classes omitidas. Dessa forma, o objeto deve ser classificado de acordo com os critérios da análise em questão (mesmo que esta classificação não determine sua classe real), e sua classe real deve ser determinada pela análise que tiver poder de discriminá-la (a análise morfológica, no caso, da classe ‘quebrado’ citada no exemplo). Apesar de certas classes não serem discrimináveis por uma dada análise, amostras pertencentes

a elas devem ter uma classificação esperada em tal análise, e a rede neural responsável por ela deve utilizar instancias dessas classes em seus treinamentos, a fim de evitar saídas inesperadas. A Tabela 7 relacionada quais classes são discrimináveis pelo aspecto avaliado em cada análise.

**Tabela 7 – Relação das classes discrimináveis em cada análise**

<b>Classe</b>	<b>A<sub>M</sub></b>	<b>A<sub>C</sub>, A<sub>T</sub>, A<sub>CT</sub></b>	<b>A<sub>MCT</sub></b>
Perfeito	✓	✓	✓
Ardido		✓	✓
Barrento		✓	✓
Branco		✓	✓
Brocado		✓	✓
Cabeça	✓		✓
Casca	✓	✓	✓
Casca de marinho	✓	✓	✓
Chocho	✓		✓
Coco	✓	✓	✓
Concha	✓	✓	✓
Marinho		✓	✓
Melado		✓	✓
Pau	✓	✓	✓
Pedra	✓	✓	✓
Preto		✓	✓
Preto Verde		✓	✓
Quebrado	✓		✓
Triângulo	✓		✓
Velho		✓	✓
Verde		✓	✓

Dada esta situação, foi decidido fundir classes não discrimináveis com classes discrimináveis. Após a análise visual das amostras, determinou-se quais as classes aparentavam ser quase indistinguíveis entre si sob o aspecto avaliado por uma dada análise e essas classes foram fundidas. Por exemplo, é difícil distinguir as classes ‘casca’ e ‘coco’ ao se analisar somente sua cor e textura, já que elas são compostas pelo mesmo material. Então as classes ‘casca’ e ‘coco’ foram fundidas em uma só:  $\overline{casc\bar{a}}$ . O resultado dessas fusões é apresentado na Tabela 8. A Tabela 9 mostra as classes definidas para cada uma das análises.

Tabela 8 – Classes fundidas para cada análise

Análises	Classe Fundida	Classes Originais
$A_C, A_T, A_{CT}$	$\overline{Perfeito}$	{Perfeito, Cabeça, Chocho, Quebrado, Triângulo}
$A_C, A_T, A_{CT}$	$\overline{Casca}$	{Casca, Coco}
$A_C, A_T, A_{CT}$	$\overline{Marinheiro}$	{Marinheiro, Casca de Marinheiro}
$A_M$	Oval	{Ardido, Barrento, Branco, Coco, Marinheiro, Melado, Preto, Preto-Verde, Velho, Verde, Perfeito}
$A_M$	Irregular	{Quebrado, Brocado, Casca, Casca de Marinheiro, Concha}

Tabela 9 – Classes de cada análise

Análises	Classes
$A_C, A_T, A_{CT}$	{Ardido, Barrento, Branco, Brocado, $\overline{Casca}$ , Concha, $\overline{Marinheiro}$ , Melado, Pau, Pedra, $\overline{Perfeito}$ , Preto, Preto-verde, Velho, Verde}
$A_M$	{Cabeça, Chocho, Irregular, Oval, Pau, Pedra, Triângulo}
$A_{MCT}$	{Ardido, Barrento, Branco, Brocado, Cabeça, Casca, Casca de marinheiro, Chocho, Coco, Concha, Marinheiro, Melado, Pau, Pedra, Perfeito, Preto, Preto-verde, Quebrado, Triângulo, Velho, Verde}

Com a fusão das classes, houve um grande desbalanceamento no número de instâncias de cada classe, o que poderia acabar influenciando negativamente no treinamento das redes neurais e na avaliação dos resultados de classificações teste. Portanto, fez-se necessário um procedimento de balanceamento do número de instâncias por classes, tanto das classes fundidas, quanto das classes originais. Este procedimento consistiu em descartar amostras aleatoriamente, de modo que restasse somente o número esperado de instâncias por classe. A distribuição resultante, tanto do ponto de vista das classes originais, quanto do ponto de vista das classes fundidas, e da distribuição por peneiras (para os grãos perfeitos), é apresentada abaixo para os bancos de dados utilizados nas análises.

Após a execução do procedimento a situação do banco de dados de atributos morfológicos (Banco<sub>M</sub>) é apresentada nos Gráficos 3-6. A distribuição de amostras por classe é apresentada no Gráfico 3. A composição das amostras da classe fundida ‘Ovalado’ por classes originais é mostrada no Gráfico 4. A distribuição de peneiras nas amostras da classe ‘Perfeito’ é

apresentada no Gráfico 5. No Gráfico 6 é dada a distribuição de amostras da classe fundida 'Irregular' pelas classes originais.




Gráfico 3 – Distribuição das amostras por classe, para o banco de atributos morfológicos




Gráfico 4 – Distribuição das amostras da classe Ovalado por classe original, para o banco de atributos morfológicos

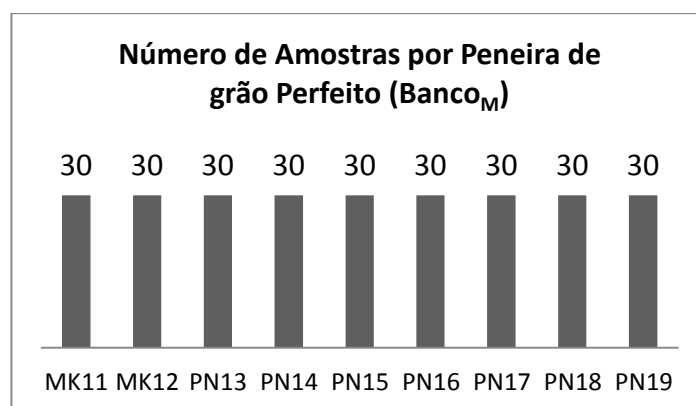


Gráfico 5 – Distribuição das amostras da classe Perfeito por peneira, para o banco de atributos morfológicos




Gráfico 6 – Distribuição das amostras da classe Irregular por classe original, para o banco de atributos morfológicos

Os bancos de dados de atributos de cor (Banco<sub>C</sub>), textura (Banco<sub>T</sub>) e cor-textura (Banco<sub>CT</sub>) apresentaram a mesma distribuição de amostras, a qual é apresentada nos Gráficos 7-9. A distribuição de amostras por classe é apresentada no Gráfico 7. A composição das amostras da classe fundida ‘*Perfeito*’ pelas classes originais e por peneiras de grãos ‘Perfeito’ é mostrada no Gráfico 8. A composição das amostras das classes fundidas ‘*Marinheiro*’ e ‘*Casca*’ por classes originais é apresentada no Gráfico 9.




Gráfico 7 – Distribuição das amostras por classe, para os bancos de cor e textura

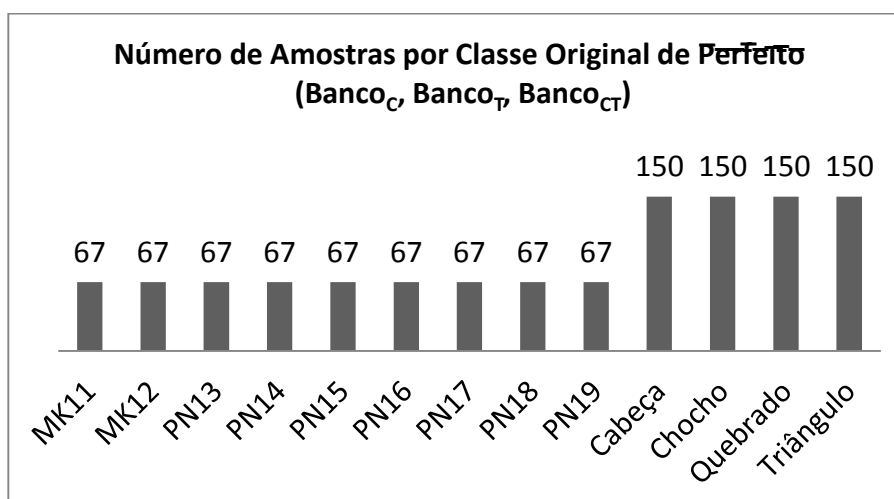


Gráfico 8 – Distribuição das amostras da classe fundida Perfeito por classe original e peneira, para os bancos de cor e textura




Gráfico 9 – Distribuição das amostras das classes fundidas Marinho e Casca por classe original, para os bancos de cor e textura

Mesmo que para a análise  $AM_{CT}$  não tenha havido fusão de classes, a distribuição das amostras do banco de atributos  $Banco_{MCT}$  foi balanceada. A distribuição de amostras por classe é apresentada no Gráfico 10 e a distribuição da classe ‘Perfeito’ por peneira é mostrada no Gráfico 11.




Gráfico 10 – Distribuição das amostras por classe, para o banco de atributos morfológicos, de cor e de textura




Gráfico 11 – Distribuição das amostras da classe Perfeito por peneira, para o banco de atributos morfológicos, de cor e de textura

O número de amostras disponíveis para o processo de treinamento e avaliação de cada análise está resumido na Tabela 10.

Tabela 10 – Número de amostras disponíveis para cada análise

Análises	Número de amostras
$A_M$	5933
$A_C, A_T, A_{CT}$	10469
$A_{CMT}$	14088



### 3.11. Seleção de Atributos

Uma vez definidas as configurações dos atributos e das classes para abordar o problema e tendo sido uniformizadas as distribuições de classes das bases de dados, técnicas de seleção de atributos foram aplicadas sobre as instâncias dos bancos de dados a fim de diminuir redundâncias de informação entre os atributos, e conseqüentemente, melhorar sua eficácia. Três técnicas foram utilizadas independentemente: ordenação dos atributos por ganho de informação, ordenação dos atributos por chi-quadrado e aplicação da PCA, seguida de ordenação por variância. A discretização dos valores dos atributos, necessária para o cálculo do ganho de informação e do chi-quadrado foi feita pelo método Minimum Description Length (FAYYAD; IRANI; BAJCSY, 1993).

Após as ordenações classificações teste foram executadas para variados números de atributos.

Para cada um dos cinco banco de dados definidos (BANCOM, BancOC, BancOT, BancOCT e BancOMCT) foi realizado o seguinte procedimento:

1. Determinou-se o número de atributos ( $N_{at}$ ) do banco de dados.
2. Ordenou-se os atributos do banco de dados de forma independente por cada uma das três técnicas. Sendo que a técnica T definiu a ordenação  $O^T = \{A_1^T, A_2^T, \dots, A_{N_{at}}^T\}$ , onde  $\{A_i^T\}$  são atributos (ou componentes principais, no caso da PCA), de modo que  $critério^T(A_i^T) \geq critério^T(A_{i+1}^T), \forall i < N_{at}$ . Dado que  $critério^T(\cdot)$  é o valor do critério de avaliação utilizado pela técnica T para ordenar os atributos, ou seja, quanto maior  $critério^T(A)$ , mais bem avaliado é o atributo A.
3. Para cada técnica T foram realizadas classificações de teste, pelo método da validação cruzada com 10 folds, de acordo com os parâmetros definidos na Seção 3.5, variando-se o número atributos. Em um teste com k atributos, estes foram dados por  $\{A_j^T\}, j = 1, \dots, k$ , ou seja, foram utilizados somente os k atributos mais bem avaliados. O número de testes realizados foi escolhido levando em consideração  $N_{at}$  e o tempo de processamento envolvido. Nenhum critério específico foi definido na determinação do número de atributos utilizados em cada teste.
4. Os conjuntos de atributos que proporcionaram os melhores resultados para as técnicas de ordenação por ganho de informação e por chi-quadrado foram transformados pela PCA, a fim de se reduzir as covariâncias dos atributos, e os conjuntos de componentes

principais resultantes, sem nenhuma exclusão, foram submetidos ao mesmo processo de avaliação.

Após a execução do procedimento em todos os bancos de dados, os resultados foram comparados e os melhores conjuntos de atributos foram definidos como os vetores de características para cada uma das análises.

### 3.12. Definição do Processo Classificatório

Conforme citado na Seção 3.3, propôs-se avaliar três processos classificatórios. O primeiro deles ( $P_{MCT}$ ) está bem definido, e nada mais é do que a própria análise  $A_{MCT}$ : utilizar uma rede neural que toma como entradas atributos selecionados das três naturezas (morfológicos, de cor e de textura) e a classificação do grão é dada diretamente por essa rede neural. O segundo processo classificatório ( $P_{M+C+T}$ ) propõe realizar as análises intermediárias de cor ( $A_C$ ), morfológica ( $A_M$ ) e de textura ( $A_T$ ) paralelamente, e definir um procedimento para cruzar os resultados e gerar a classificação final. O terceiro ( $P_{F+CT}$ ) é análogo ao segundo, porém as análises intermediárias são a morfológica ( $A_M$ ) e a de cor-textura ( $A_{CT}$ ). A seguir será definido o processo classificatório  $P_{M+C+T}$ , que por analogia também caracteriza o  $P_{M+CT}$ .

Cada uma das análises foi refinada pelos vários procedimentos apresentados, porém os seus resultados (com exceção da análise  $A_{MCT}$ ) determinam, individualmente, somente um dos aspectos da aparência dos objetos e pode atribuir uma classificação ambígua para um grão (uma classe fundida). Dessa forma se fez necessário um procedimento para unificar as análises e atribuir ao objeto em questão uma classe, que indique que tipo de defeito ou impureza ele representa, ou se é um grão perfeito. Definiu-se, então, que a geração dos resultados finais seria realizada a partir das saídas das análises parciais, também pelo uso de redes neurais PMC. O processo de classificação de um grão ou impureza foi definido como passos a seguir: após o grão ter sido segmentado e individualizado, todas as características a serem utilizadas pelas três análises – morfológica, de cor e de textura – são extraídas. As características são agrupadas para formar os vetores de características destinados a cada análise, os quais foram definidos no processo apresentado na Seção 3.11. Os vetores de características são submetidos à classificação de redes neurais pré-treinadas. Cada uma das redes neurais gera um vetor de probabilidades, indicando a probabilidade do objeto de pertencer a cada uma das classes

definidas pela rede neural em questão. Têm-se então três vetores de probabilidade, conforme apresentado abaixo:

$$\begin{aligned} V_{cor} &= \{PCC_i\}, i = 1, \dots, N_{cc} \\ V_{morfologia} &= \{PCM_j\}, j = 1, \dots, N_{cm} \\ V_{textura} &= \{PCT_k\}, k = 1, \dots, N_{ct} \end{aligned}$$

Sendo  $N_{cc}$ ,  $N_{cm}$  e  $N_{ct}$  os números de classes utilizadas nas análises de cor, forma e textura, respectivamente, conforme definido na Seção 3.10.  $PCC_i$  é a probabilidade de o grão pertencer à  $i$ -ésima classe de cor,  $PCM_j$  a probabilidade de o grão pertencer à  $j$ -ésima classe de forma e  $PCT_k$  a probabilidade de o grão pertencer à  $k$ -ésima classe de textura.

Esses vetores são então concatenados para se formar um vetor de características único:

$$V_{concatenado} = V_{cor} \cup V_{morfologia} \cup V_{textura}$$

O vetor concatenado é então submetido a mais uma rede neural pré-treinada, a qual definirá a classe final do objeto. Essa abordagem visa não somente diferenciar as classificações intermediárias não conclusivas proveniente da fusão de classes, mas também lidar com incertezas recorrentes. O procedimento é ilustrado na Figura 30.

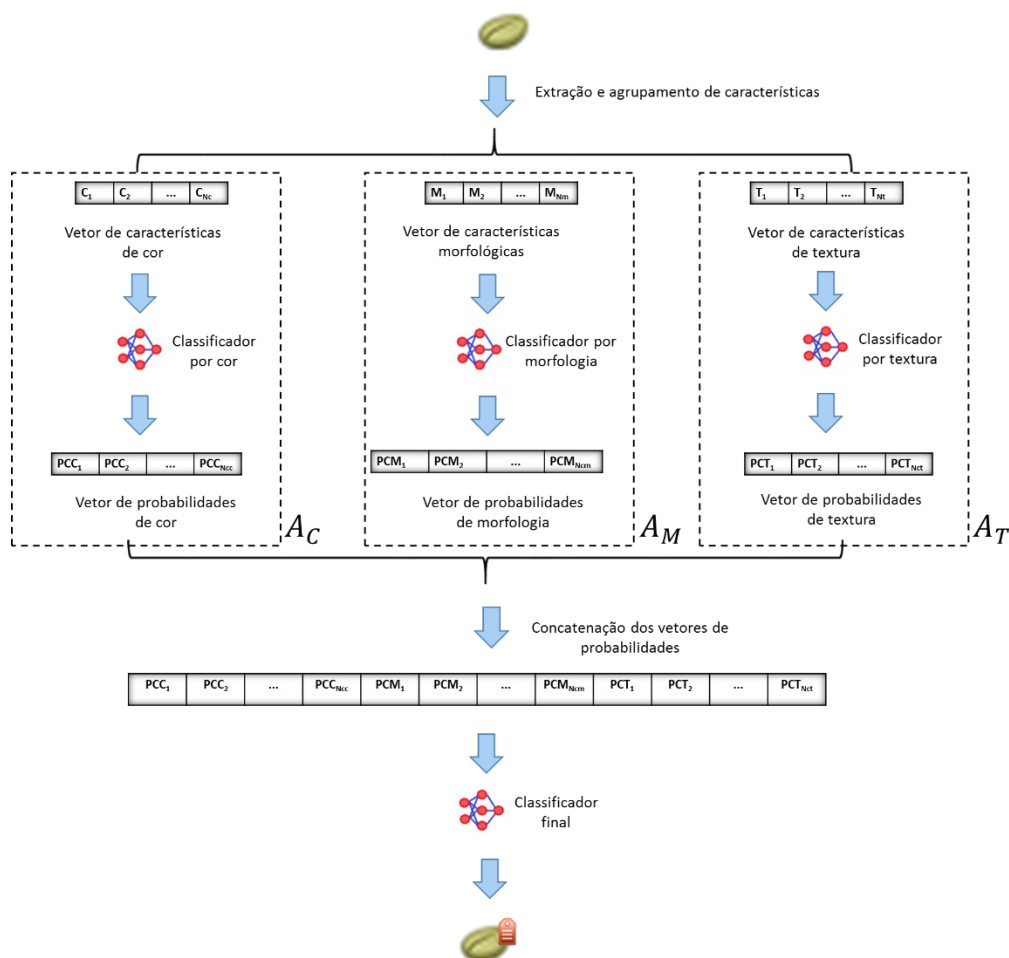
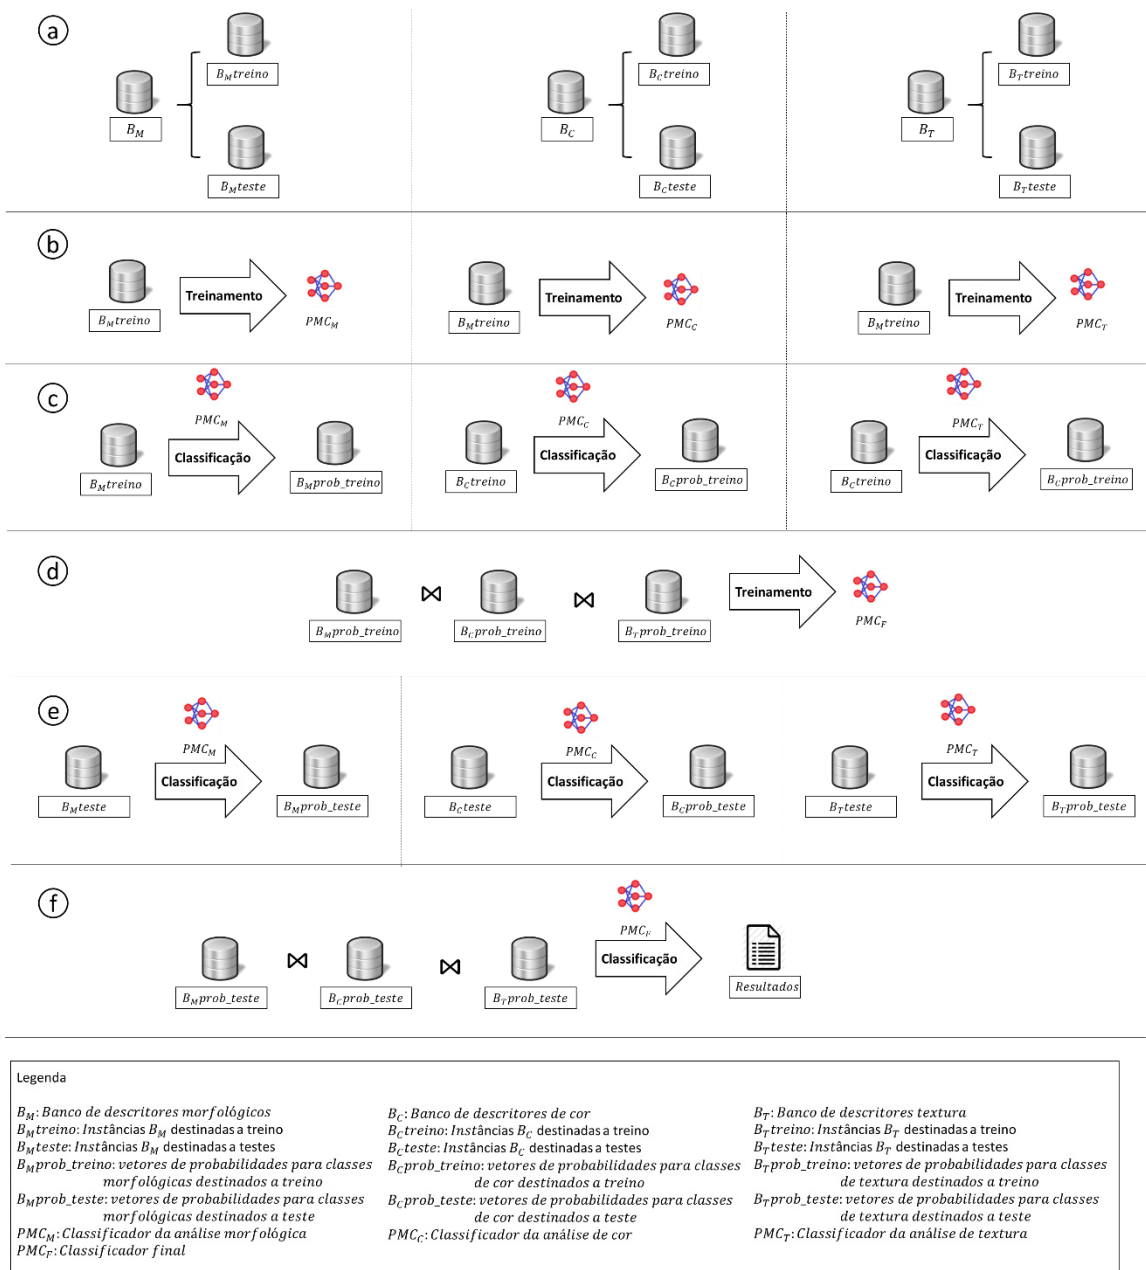


Figura 30 – Processo classificatório envolvendo análises paralelas de cor, morfologia e textura

Os processos classificatórios  $P_{M+C+T}$  e  $P_{M+CT}$  envolvem classificações em dois níveis, ou seja, é preciso treinar redes neurais do primeiro nível, para então aplicá-las em um conjunto de dados a fim de se obter vetores de probabilidades, os quais são utilizados como conjunto de treinamento para a rede neural do segundo nível. Essa dinâmica de classificação não permite a aplicação direta dos métodos de validação cruzada disponíveis nas ferramentas utilizadas, sendo necessário modificá-las ou implementar uma ferramenta própria. Para contornar o problema foi utilizado um procedimento alternativo para treinamento e avaliação dos processos classificatórios, o qual é ilustrado na Figura 31 para o  $P_{M+C+T}$ . Dividiu-se cada banco de dados em dois conjuntos, um para treinamento e outro para teste dos classificadores (Figura 31a). As redes neurais responsáveis pelas análises intermediárias foram treinadas pelo conjunto de treinamento (Figura 31b). Essas redes foram utilizadas para classificar as instâncias do conjunto de treinamento, gerando um conjunto de vetores de probabilidade (Figura 31c). Os vetores foram concatenados e utilizados no treinamento da rede neural responsável pela classificação

final (Figura 31d). Finalmente, as instâncias do conjunto de testes foram classificadas pelas redes neurais das análises intermediárias, gerando vetores de probabilidade (Figura 31e), os quais foram concatenados e passados como entrada para o classificador final (Figura 31f), que gera a avaliação final. Para efeitos de comparação o processo classificatório  $P_{MCT}$  também teve que ser avaliado treinando sua rede neural com o conjunto de treinamento para então utilizá-la na classificação do conjunto de teste. Os bancos de dados foram então divididos da seguinte forma: 60% das instâncias foram destinadas a formar o conjunto de treinamento, e os 40% restantes para o conjunto de testes.



**Figura 31 – Treinamento e avaliação do processo classificatório  $P_{M+C+T}$**



## 4. RESULTADOS E DISCUSSÃO

Neste capítulo serão apresentados e discutidos os resultados obtidos. Detalhes sobre os critérios de avaliação (acurácia, precisão, recall e F-Measure) foram apresentados na Seção 3.4.

### 4.1. Classificação por Histogramas de Frequências Normalizadas de Cores

Os resultados das classificações por histogramas de frequências normalizadas de cor foram apresentados brevemente na Seção 3.9.2.1 e serão discutidos mais profundamente nesta seção. As acurácias obtidas pela submissão dos histogramas oriundos de diferentes espaços de cor ao método da validação cruzada são rerepresentadas na Tabela 11.

**Tabela 11 – Acurácias para cada espaço de cor, das classificações utilizando histogramas de frequências normalizadas das cores do grão como vetor de características**

Espaço de Cor	Acurácia (%)
RGB	69,92
HSV	74,33
YCbCr	69,93
YCgCr	67,06
YIQ	68,98
YPbPr	69,87
YUV	69,79
YDbDr	69,88
CIE XYZ	58,63
CIELAB	74,23
rgb	63,71
I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	70,99

Nota-se que as diferenças entre os resultados são muito pequenas, com exceção dos modelos CIE XYZ, rgb, CIELAB e HSV. Sendo que os dois primeiros apresentaram resultados muito inferiores ao dos outros, enquanto os dois últimos apresentaram valores muito semelhantes, com significativa superioridade em relação aos outros modelos.

Supõe-se que a boa vantagem obtida pelo espaço de cor HSV se deva pelo fato de ele descorrelacionar informações bem distintas e com significados concretos – matiz, saturação e brilho – entre os canais. Essa separação pode ter deixado a classificação mais robusta em relação a variações da distribuição de luz pelo sistema de iluminação, por exemplo. Como a câmara de captura de imagens não conta com um sistema de iluminação totalmente homogênea, os grãos de uma mesma imagem não são iluminados da mesma forma.

Acredita-se que o bom desempenho do CIELAB se deva por ele ser perceptualmente uniforme, de modo que as grandes diferenças de cor que poderiam ser percebidas por classificadores humanos seriam transcritas numericamente pelo sistema de cor em grandes diferenças de valor, e pequenas diferenças que passariam despercebidas por humanos seriam representadas por pequenas diferenças de valores.

Constata-se que com exceção do HSV, CIELAB e rgb, todos os espaços de cor avaliados são combinações lineares do RGB. Acredita-se que essa seja a razão pela qual os espaços de cor obtiveram resultados muito semelhantes, sendo justamente as exceções os espaços que proporcionaram acurácias destoantes. Das combinações lineares, apenas o CIE XYZ apresentou resultados muito distintos.

## **4.2. Modificação dos Descritores de Haralick**

Os resultados obtidos nas classificações com os descritores de Haralick modificados para serem utilizados dois pixels de referência no cômputo das GLCM serão discutidos e comparados aqui com os resultados dos descritores em sua concepção original.

Os critérios de classificação adotados nesta comparação são: acurácia, precisão média, recall médio e F-Measure média. As Equações (3.2)-(3.4) apresentam o cálculo dos critérios para uma única classe. Seus valores médios são calculados pela média aritmética simples entre os valores obtidos para cada classe.

Nove ensaios foram realizados para cada uma das duas abordagens, sendo que em cada ensaio diferentes bandas de espaços de cor foram utilizadas para calcular os descritores, conforme descrito na Seção 3.9.3.2. As acurácias, as precisões médias, os recalls médios e as F-Measures médias são apresentadas nas Tabelas 12-15. Em cada tabela o melhor resultado de cada ensaio é destacado e é apresentado a diferença, em porcentagem, entre o melhor e o pior resultado ( $\text{Diferença} = (\text{Melhor} - \text{Pior}) / \text{Pior}$ ).



**Tabela 12 – Comparação das acurácias obtidas pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência**

	RGB	R	G	B	I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	I <sub>1</sub>	I <sub>2</sub>	I <sub>3</sub>	Níveis de Cinza
1 pixel	79,08%	58,34%	60,54%	59,89%	80,98%	59,02%	65,07%	62,14%	60,11%
2 pixels	80,02%	59,14%	60,68%	59,10%	82,32%	61,35%	64,87%	63,92%	61,73%
Diferença	1,19%	1,37%	0,23%	1,34%	1,65%	3,95%	0,31%	2,86%	2,69%

**Tabela 13 – Comparação das precisões médias obtidas pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência**

	RGB	R	G	B	I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	I <sub>1</sub>	I <sub>2</sub>	I <sub>3</sub>	Níveis de Cinza
1 pixel	77,97%	56,55%	57,42%	56,67%	79,72%	55,77%	62,33%	60,66%	56,92%
2 pixels	78,73%	57,83%	58,43%	56,61%	81,59%	59,23%	63,22%	63,76%	59,53%
Diferença	0,97%	2,25%	1,75%	0,11%	2,35%	6,20%	1,43%	5,11%	4,59%

**Tabela 14 – Comparação dos recalls médios obtidos pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência**

	RGB	R	G	B	I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	I <sub>1</sub>	I <sub>2</sub>	I <sub>3</sub>	Níveis de Cinza
1 pixel	76,73%	53,74%	55,18%	53,83%	79,03%	53,28%	60,23%	57,67%	54,43%
2 pixels	78,00%	55,23%	56,19%	53,55%	80,69%	56,75%	60,36%	60,55%	57,47%
Diferença	1,65%	2,78%	1,84%	0,54%	2,11%	6,52%	0,22%	5,01%	5,59%

**Tabela 15 – Comparação das F-Measures médias obtidas pelas duas abordagens de cálculo dos descritores de Haralick: com 1 e 2 pixels de referência**

	RGB	R	G	B	I <sub>1</sub> I <sub>2</sub> I <sub>3</sub>	I <sub>1</sub>	I <sub>2</sub>	I <sub>3</sub>	Níveis de Cinza
1 pixel	77,35%	55,11%	56,28%	55,21%	79,37%	54,49%	61,26%	59,13%	55,65%
2 pixels	78,36%	56,50%	57,29%	55,03%	81,14%	57,96%	61,76%	62,12%	58,48%
Diferença	1,31%	2,52%	1,80%	0,33%	2,23%	6,37%	0,81%	5,06%	5,10%

Dos nove ensaios realizados a utilização dos descritores com 2 pixels de referência obteve melhor acurácia em sete. Apenas com os canais B e I<sub>2</sub> os descritores originais apresentaram melhor acurácia. Para todos os outros critérios (precisão média, recall médio e F-Measure médias) a versão modificada dos descritores apresentou melhores resultados em todos os ensaios com exceção daquele em que o canal B foi utilizado. Para todos os critérios, a média das diferenças dos resultados dos ensaios em que a versão modificada foi melhor é superior a média das diferenças dos resultados dos ensaios em que a versão modificada foi pior. Para o caso mais extremo, da precisão média: a diferença média quando o descritor modificado foi

superior foi de 3,08%, enquanto a diferença média quando o descritor original foi superior foi de 0,11%.

Dadas as informações apresentadas, e contando que todos os ensaios foram realizados utilizando o método da validação cruzada de 10 folds, utilizando um número considerável de amostras (12.537), pode-se concluir que a modificação realizada nos descritores de Haralick conseguiu uma melhora de desempenho em relação a sua versão original, para os espaços de cor avaliados e sendo aplicado ao problema aqui tratado.

### 4.3. Seleção de Atributos

Esta seção apresentará os resultados obtidos no processo de seleção de atributos detalhado na Seção 3.11. Para cada uma das cinco análises ( $A_M$ ,  $A_C$ ,  $A_T$ ,  $A_{CT}$  e  $A_{MCT}$ ) será apresentada uma tabela contendo os resultados das classificações teste conduzidas para seus atributos. Os conjuntos de atributos selecionados pelas técnicas chi-quadrado e ganho de informação reavaliados após a aplicação da PCA terão seus resultados apresentados entre parênteses. O melhor resultado da tabela aparecerá destacado. Os valores da tabela (com exceção dos reavaliados após a PCA) serão mostrados em um gráfico para uma melhor visualização.

Os 15 primeiros atributos das ordenações por chi-quadrado e ganho de informação para cada uma das cinco análises estão listados na Tabela 16. As ordenações completas são listadas no Apêndice.

**Tabela 16 – Quinze primeiros atributos das ordenações por chi-quadrado e por ganho de informação (G.I.) para cada análise.**

Os atributos aparecem em ordem decrescente de classificação, com os mais bem avaliados no topo. Os atributos morfológicos são apresentados segundo a notação utilizada na Seção 2.3. Os atributos de cor são: média (MED), variância (VAR), suavidade (SVD), energia (ENG), entropia (ENT). E  $f_i^X(C)$  é o descritor de Haralick  $f_i$  calculado pela GLCM de simetria X ( $X \in \{H,V,D\}$ ). H: Horizontal, V: Vertical, D: Diagonal) para o canal de cor C.

$A_M$		$A_C$		$A_T$		$A_{CT}$		$A_{MCT}$	
Chi <sup>2</sup>	G.I.	Chi <sup>2</sup>	G.I.	Chi <sup>2</sup>	G.I.	Chi <sup>2</sup>	G.I.	Chi <sup>2</sup>	G.I.
Perímetro	Perímetro	MED( $I_1$ )	MED( $I_1$ )	$f_7^H(I_1)$	$f_7^H(I_1)$	MED( $I_1$ )	MED( $I_1$ )	MED( $I_1$ )	MED( $I_1$ )
Spread	Spread	MED(V)	MED(V)	$f_7^V(I_1)$	$f_7^V(I_1)$	MED(V)	MED(V)	MED(V)	MED(V)
$Z_{0,0}$	$Z_{0,0}$	MED(S)	MED(L)	$f_7^D(I_1)$	$f_7^D(I_1)$	MED(S)	$f_7^H(I_1)$	MED(S)	$f_7^H(I_1)$
Área	Área	ENG(R)	MED(S)	$f_6^H(I_1)$	$f_6^H(I_1)$	$f_7^V(I_1)$	$f_7^V(I_1)$	$f_7^H(I_1)$	$f_7^V(I_1)$
$Z_{2,0}$	$Z_{2,0}$	ENG(G)	VAR(R)	$f_6^V(I_1)$	$f_6^V(I_1)$	$f_7^D(I_1)$	$f_7^D(I_1)$	$f_7^V(I_1)$	$f_7^D(I_1)$
F(0)	F(0)	VAR(G)	SVD(R)	$f_6^D(I_1)$	$f_6^D(I_1)$	$f_7^H(I_1)$	$f_6^H(I_1)$	$f_7^D(I_1)$	$f_6^H(I_1)$
DGF(0,2)	$Z_{6,0}$	SVD (G)	ENG(R)	$f_2^D(I_1)$	$f_2^D(I_1)$	ENG(R)	$f_6^V(I_1)$	ENG(R)	$f_6^V(I_1)$


$Z_{6,0}$	Slenderness	SVD (R)	MED(G)	$f_2^V(I_1)$	$f_2^V(I_1)$	ENG(G)	$f_6^D(I_1)$	ENG(G)	$f_6^D(I_1)$
Slenderness	DGF(0,2)	VAR(R)	VAR(G)	$f_2^H(I_1)$	$f_2^H(I_1)$	SVD(R)	MED(L*)	SVD(G)	MED(L*)
F(2)	$Z_{10,0}$	MED(L)	SVD(G)	$f_7^V(I_2)$	$f_7^V(I_2)$	VAR(R)	MED(S)	VAR(R)	MED(G)
$D_3$	$A_1$	MED(G)	ENG(G)	$f_2^V(I_2)$	$f_2^V(I_2)$	$f_6^V(I_1)$	SVD(R)	SVD(R)	SVD(R)
DGF(0,1)	Eixo maior	MED(B)	MED(R)	$f_7^D(I_2)$	$f_7^D(I_2)$	VAR(G)	VAR(R)	VAR(G)	VAR(R)
$Z_{10,0}$	$A_3$	VAR(L)	VAR(L)	$f_6^H(I_2)$	$f_6^H(I_2)$	SVD(G)	ENG(R)	$f_6^H(I_2)$	MED(S)
$A_1$	DGF(0,0)	SVD(L)	SVD(L)	$f_6^D(I_2)$	$f_6^D(I_2)$	$f_6^D(I_1)$	MED(G)	$f_6^D(I_2)$	ENG(R)
Eixo maior	DGF(0,1)	ENT(G)	VAR( $I_3$ )	$f_7^H(I_2)$	$f_7^H(I_2)$	$f_6^H(I_1)$	VAR(G)	$f_7^H(I_2)$	VAR(G)

Os resultados da seleção de atributos da análise morfológica ( $A_M$ ) são apresentados na Tabela 17 e no Gráfico 12.

**Tabela 17 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise  $A_M$ .**

Os resultados da reavaliações após a aplicação da PCA são dadas entre parênteses

Número de Atributos	Ganho de Informação	Chi <sup>2</sup>	PCA
10	62,95	63,24	62,92
15	64,15	64,32	64,60
20	64,27	64,82 (64,62)	63,95
25	63,34	64,57	63,95
30	64,28	64,45	61,98
35	64,79 (64,30)	64,25	60,76
40	63,36	63,34	59,33
45	63,54	62,87	57,91
50	63,05	63,16	57,37
55	63,24	62,45	56,67
60	62,73	62,41	56,85
90	61,94	60,96	56,99
120	60,95	61,82	57,88
150	61,52	61,00	59,41
180	62,19	62,08	58,37
211	62,14	62,14	60,51



**Gráfico 12 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise Am**

Assim, para a análise morfológica foram selecionados 20 atributos, obtidos pela ordenação por chi-quadrado. Esses atributos são: 9 atributos unitários (perímetro, spread, área, slenderness, eixo maior,  $A_1$ ,  $A_2$ ,  $A_3$  e  $A_4$ ), 6 Momentos de Zernike, 2 Descritores de Fourier (frequências 0 e 2) e 3 DGF (todos com frequência radial 0). O Descritor de Fourier de frequência zero, também conhecido como componente DC, coincide com o valor médio do sinal. Portanto, como a assinatura utilizada no cálculo dos descritores de Fourier foram as distâncias dos pixels da borda do grão ao seu centroide, a componente DC nada mais é do que a distância média da borda ao centroide. O Modelo Autorregressivo foi o único atributo a ficar de fora da seleção de atributos morfológicos e a melhor colocação de um de seus elementos nas ordenações da seleção de atributos foi 66°. Assim, conclui-se que o atributo não é apropriado para o problema tratado.

Dos 12 atributos unitários avaliados, 9 foram selecionados, mostrando certa superioridade em relação aos outros. Diferentemente dos outros atributos, que decompõem a representação de forma em um conjunto de elementos, os descritores unitários extraem da forma informações específicas, geralmente contendo significados físicos bem definidos (área, perímetro, etc.). Assim, acredita-se que informações importantes se condensam no atributo, contribuindo para uma melhor diferenciação pela rede neural. Os outros atributos possuem um grande número de elementos, mas cada um deles, separadamente, carrega poucas informações significantes sobre

a forma, não conseguindo filtrar as características realmente importantes na discriminação das classes de grãos de café.


A baixa acurácia obtida pelos atributos morfológicos (64,82% no melhor caso) mostra a deficiência em reconhecer as diferenças nos contornos dos objetos que separaram as classes. Essa deficiência pode ser devida a limitações dos atributos utilizados ou à própria dificuldade inerente ao problema ser elevada. Apesar de um número significativo de atributos terem sido avaliados, estudos mais profundos são necessários para comprovar ou refutar qualquer uma das hipóteses. Além disso, o modo como as classes foram fundidas e o número reduzido de amostras utilizadas no treinamento podem ter influenciado negativamente o desempenho.

Os resultados da seleção de atributos da análise de cor ( $A_C$ ) são apresentados na Tabela 18 e no Gráfico 13. Os resultados para a análise de textura ( $A_T$ ) são dados pela Tabela 19 e pelo Gráfico 14. E os resultados para análise de cor-textura ( $A_{CT}$ ) são apresentados na Tabela 20 e no Gráfico 15.

**Tabela 18 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise  $A_C$ .**

Os resultados da reavaliações após a aplicação da PCA são dadas entre parênteses

Número de Atributos	Ganho de Informação	Chi <sup>2</sup>	PCA
15	70,83	68,21	72,64
25	73,80	74,85	75,58
35	75,56	75,78	75,44
45	75,73	76,42	76,09
55	76,88	76,51	76,58
65	76,96	76,74	78,09
75	77,08 (78,66)	77,51(78,90)	<b>79,10</b>
84	77,77	77,77	78,63



**Gráfico 13 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise  $A_c$**

O melhor vetor de características para análise de cor, com acurácia de 79,10%, foi composto por 75 das 84 componentes principais. Como cada uma das componentes principais é uma combinação linear dos atributos inicialmente propostos, tem-se que cada um dos atributos teve uma contribuição para a classificação.

Constata-se pelo Gráfico 13 que a acurácia das classificações foram evoluindo conforme novos atributos foram adicionados ao vetor de características, mesmo que os atributos adicionados já estivessem presentes, porém calculados por outros espaços de cor. Deve-se notar que os diferentes espaços de cor são apenas representações diferentes da mesma propriedade física. Então, acredita-se que a adição de atributos calculados por outros espaços de cor possam melhorar o desempenho da análise.


Ao se analisar a ordenação gerada pelo algoritmo chi-quadrado para os atributos de cor, constata-se que os seis piores classificados são curtoses, e todas as doze curtoses estão classificadas entre os 24 piores atributos. Resultados similares são observados na ordenação pelo ganho de informação. Sob a óptica oposta, nota-se que os três melhores classificados pelo chi-quadrado são médias e que todas as doze médias encontram-se entre os 30 melhores atributos. Novamente, observa-se uma situação parecida para a ordenação por ganho de informação. Como esses dois atributos estatísticos são as duas situações extremas a serem

destacadas ao se analisar as ordenações, conclui-se que a média é o atributo com mais informações discriminantes do histograma de cor para o problema abordado, enquanto que a curtose é a menos discriminante.

**Tabela 19 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise AT.**

Os resultados da reavaliações após a aplicação da PCA são dadas entre parênteses

Número de Atributos	Ganho de Informação	Chi <sup>2</sup>	PCA
10	55,94	55,80	72,39
30	75,06	76,92	78,52
50	77,17	76,49	79,27
70	77,77	79,33	80,44
90	80,49	79,84	81,12
100	80,35	80,56	81,13
110	80,49	81,02	82,40
120	81,20 (83,09)	81,16 (82,97)	82,26
126	81,52	81,52	<b>83,67</b>



**Gráfico 14 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise AT**

O melhor resultado para a análise de textura (acurácia de 83,67%) foi obtido com a utilização de todas as 126 componentes principais, sem nenhuma exclusão. É possível notar


pela Tabela 16 (e pela sua extensão no Apêndice) que os descritores de Haralick que diferem apenas pela simetria utilizada para calcular GLCM são geralmente ordenados em posições contiguas, sugerindo uma alta correlação entre eles. Essa hipótese é de fato confirmada quando as correlações são calculadas. Acredita-se que esse é o motivo por que a PCA obteve bons resultados em melhorar a acurácia quando havia atributos de textura envolvidos, sobretudo nas análises  $A_T$  e  $A_{CT}$ , em que esses atributos compunham a maioria dos elementos do vetor de característica. Apesar de a alta correlação não estar presente em todos os descritores de Haralick, escolher apenas uma simetria para compor o conjunto de atributos de textura pode melhorar não só a acurácia da classificação, como também reduzir sobremaneira o tempo de processamento.

**Tabela 20 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise  $A_{CT}$ .**

**Os resultados da reavaliações após a aplicação da PCA são dadas entre parênteses**

Número de Atributos	Ganho de Informação	Chi <sup>2</sup>	PCA
30	74,10	75,54	78,94
60	77,59	77,75	81,87
90	79,32	79,62	84,02
120	81,17	82,96	85,01
150	83,47	83,61	86,01
160	83,61	83,69	86,01
170	83,89	83,72	85,89
180	84,22	84,43	86,08
190	84,73	84,47 (86,41)	86,11
200	84,90 (86,59)	84,30	86,51
210	84,72	84,72	86,09






**Gráfico 15 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise ACT**

Como a maioria das classes é visualmente caracterizada por aspectos envolvendo coloração, era esperado que os atributos de cor e textura tivessem melhor poder discriminante, como de fato foi corroborado pelos resultados. Tendo em vista que as análises  $A_C$ ,  $A_T$  e  $A_{CT}$  foram conduzidas utilizando exatamente o mesmo conjunto de amostras e com as mesmas classes fundidas, torna-se apropriado comparar seus resultados. Os atributos de textura selecionados para a Análise  $A_T$  superaram os atributos de cor selecionados para análise  $A_C$  em 5,78%, ao se comparar as acurácias obtidas, com os primeiros classificando corretamente 83,67% das amostras e os últimos 79,10%. Portanto, o padrão com que as cores são distribuídas pelos grãos é mais discriminante que o aspecto geral da coloração do grão. A união dos atributos de cor e textura proporcionou melhor eficácia do que a utilização de qualquer um dos dois separadamente, de modo que a acurácia obtida com essa união foi de 86,59%, superando os atributos de textura em 3,49%. Esse resultado coincide com as conclusões apresentadas por Majumdar e Jayas (2000d), trabalho envolvendo classificação de grãos de trigo, em que os resultados da utilização de atributos de diferentes naturezas – cor, morfologia e textura – superaram significativamente o emprego de atributos exclusivos de uma natureza.

**Tabela 21 – Acurácias (em %) das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise  $A_{MCT}$ .**

Os resultados da reavaliações após a aplicação da PCA são dadas entre parênteses

Número de Atributos	Ganho de Informação	Chi <sup>2</sup>	PCA
50	79,11	77,80	76,24
100	80,42	80,34	76,40
150	81,45	81,12	78,27
200	82,47	82,62	80,83
250	82,97	83,17	81,96
300	79,43	83,71 (84,74)	82,71



**Figura 32 – Acurácias das classificações utilizando os melhores atributos de cada técnica de seleção de atributos para a análise  $A_{MCT}$**

Os atributos selecionados para a análise  $A_{MCT}$ , os quais proporcionaram a acurácia de 85,08%, foram o conjunto das componentes principais resultantes da aplicação da PCA nos 250 atributos mais bem avaliados sendo o critério chi-quadrado. Os 250 atributos selecionados pelo chi-quadrado foram: 111 atributos de textura (88,10% dos atributos de textura avaliados), 82 atributos de cor (97,62% dos atributos de cor avaliados) e 57 atributos morfológicos (27,01% dos atributos morfológicos avaliados). Esses dados reforçam o baixo desempenho dos atributos morfológicos e sugere que apesar de os atributos de textura serem mais discriminantes como

um todo, individualmente os atributos de cor são mais poderosos, já que quase todos eles foram selecionados para compor essa análise. Para reforçar essa ideia, pode ser verificado que na análise  $A_{CT}$ , dos 10 atributos excluídos, apenas 2 são de cor. Esses dois atributos são curtoses, que é o atributo estatístico que extraiu menos informações dos histogramas de cor.

Deve-se notar que o número de atributos da análise  $A_{MCT}$  submetidos ao processo de seleção foi de 421, mas as avaliações utilizaram no máximo 300 deles. As avaliações não foram além devido ao longo tempo de processamento envolvido, que chegou a ser de semanas, quando 300 atributos foram utilizados com o método da validação cruzada. As técnicas de seleção de atributos, com exceção da ordenação por ganho de informação, apresentaram curvas crescentes de acurácia em função do número de atributos, sugerindo que os resultados poderiam ser melhorados caso mais atributos fossem incorporados ao vetor de características.

A melhor acurácia da análise  $A_{CT}$  (86,59%) foi maior que a melhor acurácia da análise  $A_{MCT}$  (85,08%), entretanto, como os conjuntos de classes das análises não são os mesmos (a análise  $A_{CT}$  teve seu problema simplificado ao fundir algumas das classes) não cabe comparação entre os resultados.

A Tabela 22 resume os resultados apresentados nesta seção. Por ela constata-se que a máxima disparidade entre a acurácia e o recall médio provenientes das classificações geradas com os atributos selecionados foi de 2,42%. Portanto, pode se dizer que o desbalanceamento da distribuição das amostras entre as classes não afetou os treinamentos ao ponto de produzir classificações muito enviesadas, gerando acurácias enganosas. Assim sendo, os resultados dos experimentos foram utilizados para definir os vetores de características adotados por cada análise.

**Tabela 22 – Resumo do processo de seleção de atributos**

Análise	Números de atributos do vetor de características avaliados	Número de amostras	Número de atributos com melhor acurácia	Melhor Acurácia (%)	Respectivo Recall Médio (%)	Técnica do Melhor Resultado
$A_M$	10,15,20,25,30,35,40,45, 50, 55, 60, 90, 120,150,180, 211	5933	20	64.82	66.39	Chi <sup>2</sup>
$A_C$	15,25,35,45,55,65,75,84	10469	75	79.10	78.98	PCA
$A_T$	10,30,50,70,90,100,110,120,126	10469	126	83.67	83.69	PCA

$A_{CT}$	30,60,90,120,150,160,170,180,190,200,210	10469	200	86.59	86.69	Ganho de informação seguido de PCA
$A_{MCT}$	50,100,150,200,250,300	14088	250	85.08	85.62	Ganho de informação seguido de PCA

#### 4.4. Definição do Processo Classificatório

As avaliações dos processos classificatórios foram conduzidas com os vetores de características de cada análise definidos pelos resultados apresentados na seção anterior. Os resultados das classificações de cada processo são apresentadas na Tabela 23. São dados os recalls por classe (com os melhores destacados), a acurácia, o recall médio e a melhoria obtida pelo melhor resultado em comparação ao segundo melhor.

Tabela 23 – Recalls das classes dos Processos Classificatórios

Classe	$P_{M+C+T}$	$P_{M+CT}$	$P_{MCT}$	Melhoria
Perfeito	69.0%	70.7%	85.3%	20.65%
Coco	80.3%	65.6%	87.2%	8.59%
Pedra	71.1%	72.5%	81.0%	11.72%
Triangulo	58.2%	58.8%	62.8%	6.80%
Melado	90.0%	86.0%	92.5%	2.78%
Marinheiro	91.3%	91.8%	95.4%	3.92%
Branco	84.3%	84.6%	90.3%	6.74%
Concha	72.8%	68.9%	87.7%	20.47%
Preto-Verde	80.6%	85.3%	88.6%	3.87%
Casca	61.6%	64.1%	86.4%	34.79%
Barrento	85.4%	76.2%	88.6%	3.75%
Preto	82.7%	84.8%	90.0%	6.13%
Chocho	63.9%	59.9%	76.8%	20.19%
Cabeça	81.4%	82.8%	87.8%	6.04%
Pau	68.6%	78.8%	75.3%	4.65%
Quebrado	56.0%	55.2%	75.8%	35.36%
Ardido	72.0%	74.9%	74.4%	0.67%
Casca de Marinheiro	67.0%	69.5%	74.0%	6.47%
Brocado	54.9%	58.5%	71.8%	22.74%
Velho	69.2%	74.7%	83.0%	11.11%
Verde	75.0%	80.4%	88.0%	9.45%
Recall Médio	73.11%	73.52%	82.99%	12.87%
Acurácia	72.01%	72.61%	82.85%	14.10%

A classificação utilizando um único passo, com a utilização de atributos de todas as naturezas de uma vez, conseguiu o melhor resultado para quase todos os recalls comparados, sendo superada na classificação em apenas duas das 21 classes ('Pau' e 'Ardido'). É importante que todas as classes sejam corretamente discriminadas, pois, como citado na Introdução, cada tipo de impureza e defeito deprecia a qualidade da bebida produzida de forma diferente, tendo, portanto, diferentes pesos na avaliação da amostra, variando de acordo com o critério de avaliação adotado. O processo  $P_{MCT}$  não só obteve significativa vantagem na acurácia, mas também apresentou larga superioridade no recall de algumas classes específicas, como 'Quebrado', para a qual foi observada uma melhoria de 35,36% em relação aos outros processos. Das sete classes com recall inferior a 80%, quatro não podem ser distinguidas sem uma análise morfológica: 'Triângulo', 'Quebrado' e 'Chocho' (que nada mais são do que grãos perfeitos, porém com contornos característicos que os torna impróprios) e 'Casca de Marinheiro' (que é a casca do defeito 'Marinheiro', geralmente encontrada em pedaços e com um formato muito irregular). Essa observação reforça que o reconhecimento da forma do grão é o principal desafio da classificação.

A abordagem de realizar classificações em duas etapas se mostrou inferior à abordagem com uma classificação única e direta. Os processos classificatórios que utilizam a primeira abordagem,  $P_{M+C+T}$  e  $P_{M+CT}$ , obtiveram acurácias similares (72,01% e 72,61%, respectivamente), enquanto a segunda abordagem, dada pelo processo  $P_{MCT}$ , superou a acurácia do melhor dos processos anteriores em 14,10%, proporcionando o valor de 82,85%. Portanto, pode-se inferir que é desenvolvida uma sinergia quando os atributos em questão são empregados em conjunto. A perda dessa sinergia pela utilização dos atributos separadamente não é compensada na união dos resultados das classificações intermediárias.

O processo classificatório  $P_{MCT}$  nada mais é do que a própria análise  $A_{MCT}$ , cujos resultados foram apresentados na seção anterior. Como a análise  $A_{MCT}$  foi avaliada com um conjunto mais completo de amostras e pelo método da validação cruzada, seu resultado é mais confiável e será entendido como o resultado do método proposto neste trabalho. A matriz de confusão da análise  $A_{MCT}$ , ou seja do processo classificatório  $P_{MCT}$ , é apresentada na Tabela 24 e os recalls obtidos são dados na

Tabela 25. Assim, a acurácia de 85,08% e o recall médio de 85,62% serão utilizados para comparar a eficácia do método de classificação deste estudo com trabalhos correlatos.

Tabela 24 – Matriz de confusão do processo classificatório proposto.

Os valores destacados são o número de classificações corretas. a) perfeito, b) coco, c) pedra, d) triângulo, e) melado, f) marinheiro, g) branco, h) concha, i) preto-verde, j) casca, k) barrento, l) preto, m) chocho, n) cabeça, o) pau, p) quebrado, q) ardido, r) casca de marinheiro, s) brocado, t) velho, u) verde

		Classe atribuída																				
		a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u
Classe real	a	<u>671</u>	0	0	53	1	0	4	11	0	0	7	0	48	37	0	15	2	1	22	8	20
	b	0	<u>485</u>	0	0	0	1	0	0	37	0	0	19	0	0	0	0	0	1	0	0	1
	c	1	2	<u>611</u>	0	5	0	1	2	0	17	8	0	2	0	36	8	8	5	4	0	0
	d	54	0	1	<u>618</u>	0	0	7	17	0	0	5	0	14	0	4	65	2	3	8	6	16
	e	0	0	0	0	<u>464</u>	2	1	3	0	3	7	0	0	2	1	0	8	1	0	10	0
	f	0	0	0	0	2	<u>518</u>	2	0	0	4	0	0	0	1	1	0	0	5	2	12	0
	g	9	0	0	5	0	5	<u>614</u>	1	0	0	0	0	1	6	6	1	0	1	4	14	0
	h	17	0	3	9	2	0	0	<u>516</u>	0	0	5	1	1	2	3	3	8	5	6	5	2
	i	1	24	1	0	0	0	0	0	<u>673</u>	1	0	43	0	0	1	0	0	1	0	0	1
	j	0	2	10	0	8	1	0	1	0	<u>442</u>	3	0	0	0	7	0	11	11	0	0	0
	k	5	0	7	2	8	0	0	3	0	2	<u>710</u>	0	2	2	7	4	8	5	2	17	4
	l	0	16	0	0	0	0	0	0	36	0	0	<u>525</u>	0	0	0	0	0	0	0	0	0
	m	46	0	1	22	0	0	1	3	0	0	7	0	<u>656</u>	0	1	31	0	1	11	7	11
	n	24	0	0	1	0	1	4	2	0	0	1	0	0	<u>654</u>	0	0	2	0	3	1	5
	o	0	0	41	3	2	1	8	0	1	18	8	0	2	1	<u>505</u>	5	3	28	4	6	1
	p	16	1	7	62	0	0	3	11	1	0	3	0	54	0	1	<u>727</u>	0	7	26	0	1
	q	1	0	7	1	5	0	0	18	0	14	19	3	0	1	4	0	<u>431</u>	1	9	1	3
	r	0	2	7	6	3	11	0	2	1	3	6	0	0	3	29	15	2	<u>395</u>	6	8	0
	s	35	0	6	17	0	0	3	11	0	1	6	0	15	2	6	37	15	3	<u>528</u>	5	20
	t	2	0	1	8	6	12	6	5	0	1	17	0	20	2	5	1	0	4	1	<u>542</u>	0
u	19	0	0	21	2	1	2	1	2	0	4	0	7	5	0	2	5	1	16	1	<u>701</u>	

Tabela 25 - Recalls do processo classificatório proposto.

Classe	Recall
Perfeito	74,6%
Coco	89,2%
Pedra	86,1%
Triangulo	75,4%
Melado	92,4%
Marinheiro	94,7%
Branco	92,1%
Concha	87,8%
Preto-Verde	90,2%
Casca	89,1%

Barrento	90,1%
Preto	91,0%
Chocho	82,2%
Cabeça	93,7%
Pau	79,3%
Quebrado	79,0%
Ardido	83,2%
Casca de Marinheiro	79,2%
Brocado	74,4%
Velho	85,6%
Verde	88,7%
Recall Médio	85.62%
Acurácia	85.08%

Da matriz de confusão identificaram-se as 10 maiores confusões cometidas pela classificação, ou seja, as mais frequentes ocorrências de um grão de uma dada classe ser classificado como sendo de outra classe específica. Essas confusões são apresentadas na Tabela 26.

**Tabela 26 – Dez maiores confusões entre classes**  
**Apresenta a porcentagem de grãos da classe real que foram classificados com a classe atribuída**

Classe real	Classe atribuída	%
Triângulo	Quebrado	7,93
Coco	Preto-verde	6,80
Quebrado	Triângulo	6,74
Triângulo	Perfeito	6,59
Pau	Pedra	6,44
Preto	Preto-verde	6,24
Perfeito	Triângulo	5,89
Quebrado	Chocho	5,87
Casca de Marinheiro	Pau	5,81
Chocho	Perfeito	5,76

Nota-se que a maior confusão se dá entre as classes ‘triângulo’ e ‘quebrado’, sendo que 7,93% dos grãos ‘triângulo’ foram classificados como ‘quebrado’ e 6,74% dos grãos ‘quebrado’ foram classificados como ‘triângulo’. Constata-se que 6 das 10 confusões são em classes que teriam que ser distinguidas pela sua morfologia, reforçando que atributos capazes de identificar satisfatoriamente diferenças morfológicas são vitais para obter uma melhora no processo de classificação.

Como constatado na Seção 1.2, não há muitos trabalhos acadêmicos publicados em que o problema aqui tratado é abordado. Os trabalhos de Carrillo e Penãloza (2009) e Ahmad et al. (2010) são dois deles, em que são tratados problemas similares, mas em versões mais simples. No primeiro o recall médio de 67,7% foi obtido ao se classificar sete classes de grãos e impurezas, e no segundo a acurácia foi de 78,32% e o número de classes envolvidas era quatro. Como os problemas não são exatamente os mesmos e não há como se determinar se há classes coincidentes, não é possível realizar uma comparação quantitativa, e mesmo uma comparação qualitativa pode ser grosseira. Entretanto, como há uma disparidade muito grande nos números de classes, é razoável se considerar que a acurácia significativamente superior obtida neste trabalho representa um progresso na busca de um método capaz de classificar grãos de café sem erros. Este avanço, em relação aos trabalhos comparados, pode ser creditado à incorporação de atributos de textura e à exploração de mais espaços de cor na análise, à avaliação de um vasto conjunto de atributos, os quais utilizam abordagens bem distintas para extração e representação de informação, e à seleção dos atributos mais promissores por técnicas bem consolidadas.



## 5. CONCLUSÕES

Na busca por um método para classificação de amostras de grãos de café, 421 atributos – 211 morfológicos, 126 de textura e 84 relacionados a cor – foram reunidos e organizados em cinco subconjuntos definidos pelas naturezas de seus elementos (morfologia, cor, textura, cor-textura e morfologia-cor-textura). Cada um dos subconjuntos teve seus elementos submetidos a um processo de seleção em que foram descartados aqueles que não contribuíam para uma boa classificação. Os elementos selecionados foram utilizados como entrada para três processos classificatórios propostos, os quais foram submetidos a avaliações visando determinar o mais efetivo.

Com o intuito de se melhorar a análise por textura dos grãos, os descritores de Haralick foram modificados, proporcionando um aumento do desempenho dos classificadores na maioria dos casos testados. Apesar de a comparação dos resultados das duas versões dos descritores (original e modificada) terem sido feitas especificamente para alguns poucos espaços de cor, e para algumas classificações no problema abordado neste trabalho, a modificação proposta pode indicar um caminho a ser explorado na busca de melhores formas de descrever textura, e assim uma contribuição foi dada nessa área.

Um vasto conjunto de atributos foi avaliado, e selecionaram-se os mais promissores por uma série de classificações-teste conduzidas pelo método da validação cruzada. Esse processo de seleção mostrou que cor e textura são os aspectos mais importantes a serem considerados para se distinguir as classes do problema aqui tratado. Também foi mostrado que, apesar de espaços de cor serem apenas diferentes representações de uma mesma característica física, utilizar várias versões de um mesmo atributo, sendo cada uma proveniente de um espaço de cor distinto, em um vetor de características pode ser vantajoso. Após todas as avaliações, e tendo sido determinada a melhor configuração, o processo classificatório selecionado proporcionou a acurácia de 85,08%, atestada pelo método da validação cruzada, com recalls das classes variando de 62,80% a 95,4%, superando resultados obtidos em trabalhos correlatos que abordam versões mais simples do problema tratado.

A principal deficiência do método de classificação proposta é a dificuldade em identificar as nuances de forma que separam certas classes. Acredita-se que um esforço para superar essa dificuldade melhoraria significativamente o desempenho da classificação e é a direção sugerida para futuros trabalhos. Sugere-se a exploração de novos atributos que visem extrair

características específicas da forma (como é o caso do perímetro, e da excentricidade, por exemplo), em detrimento de atributos que se caracterizam por apresentar maneiras alternativas de representar formas ou contornos (como é o caso do modelo autorregressivo, por exemplo), já que atributos do primeiro tipo apresentaram melhor poder discriminante nas classificações conduzidas.

Assim, foi dada uma contribuição para a busca de uma técnica de classificação automática de café, rápida e livre de erros e subjetividade, podendo ajudar o setor de café a vencer importantes gargalos atualmente presentes no ciclo de vida do produto, que tem significativa importância para o país. Essa contribuição pode também ser estendida para problemas similares de classificação de outros tipos de grãos.

## 6. TRABALHOS PUBLICADOS

Os trabalhos publicados em mídias e eventos científicos frutos desta pesquisa de mestrado foram os seguintes:

- Capítulos de Livro:
  1. **JORGE, L.A.C; GONCALVES, D. S. ; OYAMA, P. I. C. .** Uso de sistemas de imagem para classificação de frutas e hortaliças. Tecnologias pós-colheita em frutas e hortaliças. Tecnologias pós-colheita em frutas e hortaliças. 1ed.São Carlos/SP: Embrapa Instrumentação, 2011, v. 1, pp. 125-157.
  2. **OYAMA, P. I. C.;** Jorge, L.A.C ; RODRIGUES, E. L. L. ; GOMES, C.C.. Sistema para Classificação Automática de Café em Grãos por Cor e Forma Através de Imagens Digitais. Avanços em Visão Computacional. Omnipax. Curitiba/PR, 2012, v.1, pp. 119-139.
- Trabalhos completos publicados em anais de congressos
  1. **OYAMA, P. I. C.;** Jorge, L. A. C. ; RODRIGUES, E. L. L. . Comparação de Descritores de Forma aplicados na Classificação de Grãos de Café. In: VIII Workshop de Visão Computacional, 2012, Goiânia-GO. VIII Workshop de Visão Computacional, 2012.
  2. **OYAMA, P. I. C.;** Rodrigues, Evandro Luis Linhari ; Jorge, L.A.C.. Metodologia para classificação de café em grãos utilizando imagens digitais. In: IV Jornada Científica Embrapa - São Carlos, 2012, São Carlos/SP. Anais da IV Jornada Científica Embrapa - São Carlos, 2012.
  3. **OYAMA, P. I. C.;** Rodrigues, Evandro Luis Linhari ; Jorge, L.A.C..In: .Desenvolvimento de uma metodologia de visão computacional para classificação de grãos de café. In: V Workshop de Pós-Graduação em Engenharia Elétrica, 2012, São Carlos-SP. V Workshop de Pós-Graduação em Engenharia Elétrica, 2012.
  4. **OYAMA, P. I. C.;** Jorge, L. A. C. ; RODRIGUES, E. L. L. . Methodology to Classify Coffee Beans Samples through Shape, Colour and Texture Descriptors. In: IX Workshop de Visão Computacional, 2013, Rio de Janeiro-RJ. IX Workshop de Visão Computacional, 2013.
  5. **OYAMA, P. I. C.;** Jorge, L. A. C. ; RODRIGUES, E. L. L. . Computer Vision System to Identify Impurities amongst Coffee Beans: Fuzzy and Neural Approaches. In: IX Workshop de Visão Computacional, 2013, Rio de Janeiro-RJ. IX Workshop de Visão Computacional, 2013.



## REFERÊNCIAS BIBLIOGRÁFICAS<sup>1</sup>

AHMAD, I. et al. Color classifier for symptomatic soybean seeds using image processing. **Plant Disease**, v. 83, n. 4, p. 320-327, APR 1999 1999. ISSN 0191-2917.

AHMAD, U. et al. The Development of Automatic Coffee Sorting System Based on Image Processing and Artificial Neural Network. 2010.

AREFI, A.; MOTLAGH, A.; TEIMOURLOU, R. Wheat class identification using computer vision system and artificial neural networks. **International Agrophysics**, v. 25, n. 4, p. 319-325, 2011 2011. ISSN 0236-8722.

BILLMEYER, F. W.; SALTZMAN, M. Describing Colors. In: (Ed.). **Principles of color technology**. 2nd. New York ; Chichester: Wiley, 1981. cap. 2, p.25-66. ISBN 047103052X : <sup>1</sup>20.00.

BROGAN, W. L.; EDISON, A. R. Automatic classification of grains via pattern recognition techniques. **Pattern Recognition**, v. 6, n. 2, p. 97-103, 1974. ISSN 0031-3203.

BROWN, D. A.; CRAW, I.; LEWTHWAITE, J. A SOM based approach to skin detection with application in real time systems. *BMVC*, 2001, Citeseer. p.491-500.

CARRILLO, E.; PEÑALOZA, A. A. Artificial vision to assure coffee-Excelso beans quality. Proceedings of the 2009 Euro American Conference on Telematics and Information Systems: New Opportunities to increase Digital Citizenship, 2009, ACM. p.35.

CARTER, R.; YAN, Y.; TOMLINS, K. Digital imaging based classification and authentication of granular food products. **Measurement Science & Technology**, v. 17, n. 2, p. 235-240, FEB 2006 2006. ISSN 0957-0233.

CHAVES-GONZALEZ, J. et al. Detecting skin in face recognition systems: A colour spaces study. **Digital Signal Processing**, v. 20, n. 3, p. 806-823, MAY 2010 2010. ISSN 1051-2004.

CHEN, X. et al. Combining discriminant analysis and neural networks for corn variety identification. **Computers and Electronics in Agriculture**, v. 71, p. S48-S53, APR 2010 2010. ISSN 0168-1699.

CHOUDHARY, R.; PALIWAL, J.; JAYAS, D. Classification of cereal grains using wavelet, morphological, colour, and textural features of non-touching kernel images. **Biosystems Engineering**, v. 99, n. 3, p. 330-337, MAR 2008 2008. ISSN 1537-5110.

CHTIOUI, Y. et al. Identification of seeds by colour imaging : comparison of discriminant analysis and artificial neural network. **Journal of the Science of Food and Agriculture**, v. 71, p. 433-441, 1996.

COSTA, L. D. F.; CESAR, R. M. **Shape analysis and classification : theory and practice**. Boca Raton, FL: CRC Press, 2000. ISBN 0849334934 (alk. paper)  
CIP entry.

COX, E. et al. **The Fuzzy Systems Handbook with Cdrom**. Academic Press, Inc., 1998. ISBN 0121944557.

DE DIOS, J. J.; GARCÍA, N. Face detection based on a new color space YCgCr. *Image Processing*, 2003. ICIP 2003. Proceedings. 2003 International Conference on, 2003, IEEE. p.III-909-12 vol. 2.

---

<sup>1</sup> De acordo com a Associação Brasileira de Normas Técnicas. NBR 6023/2002.

DELWICHE, S.; YANG, I.; GRAYBOSCH, R. Multiple view image analysis of freefalling U.S. wheat grains for damage assessment. **Computers and Electronics in Agriculture**, v. 98, p. 62-73, OCT 2013 2013. ISSN 0168-1699.

DUBOIS, S.; GLANZ, F. An autoregressive model approach to two-dimensional shape classification. **Ieee Transactions on Pattern Analysis and Machine Intelligence**, v. 8, n. 1, p. 55-66, JAN 1986 1986. ISSN 0162-8828.

FARIDAH, F.; PARIKESIT, G. O.; FERDIANSJAH, F. Coffee bean grade determination based on image parameter. **TELKOMNIKA (Telecommunication, Computing, Electronics and Control)**, v. 9, n. 3, p. 547-554, 2013. ISSN 2302-9293.

FAYYAD, U.; IRANI, K.; BAJCSY, R. Multi-interval discretization of continuous-valued attributes for classification learning. **Ijcai-93, Vols 1 and 2**, p. 1022-1027, 1993 1993.

FORD, A.; ROBERTS, A. Colour space conversions. **Westminster University, London**, 1998.

GALLOWAY, M. M. Texture analysis using gray level run lengths. **Computer graphics and image processing**, v. 4, n. 2, p. 172-179, 1975. ISSN 0146-664X.

GONZALEZ, R. C.; WOODS, R. E. Digital image processing. In: (Ed.). 3rd. Upper Saddle River, NJ ; Harlow: Pearson/Prentice Hall, 2008a. cap. Wavelets and Multiresolution Processing, p.xxii, 954 p. ISBN 9780131687288 (hbk.)  
013168728X (hbk.).

\_\_\_\_\_. **Digital image processing**. 3rd ed. Upper Saddle River, N.J. ; Harlow: Pearson/Prentice Hall, 2008b. ISBN 9780131687288 (hbk.) : <sup>1</sup>46.99  
013168728X (hbk.) : <sup>1</sup>46.99.

HARALICK, R.; SHANMUGA.K; DINSTEIN, I. TEXTURAL FEATURES FOR IMAGE CLASSIFICATION. **Ieee Transactions on Systems Man and Cybernetics**, v. SMC3, n. 6, p. 610-621, 1973 1973. ISSN 0018-9472.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. H. Model assessment and selection. In: (Ed.). **The elements of statistical learning : data mining, inference, and prediction**. 2nd ed. New York: Springer, 2009. cap. 7, p.219-260. ISBN 9780387848570 (hbk.) : <sup>1</sup>55.99  
0387848576 (hbk.) : <sup>1</sup>55.99.

HAYKIN, S. S. Neural networks : a comprehensive foundation. In: (Ed.). 2nd. Upper Saddle River, N.J.: Prentice Hall, 1999. cap. Multilayer Perceptrons, p.xxi, 842 p. ISBN 0132733501.

INTERNATIONAL COFFEE ORGANIZATION. **Exporting countries: total production**. 2014a

\_\_\_\_\_. **Exports by exporting countries to all destinations**. 2014b

JACK, K. **Video demystified a handbook for the digital engineer**. Amsterdam ; Boston: Newnes/Elsevier,: 944 p. 2007.

JACOBS, R. Increased rates of convergence through learning rate adaptation. **Neural Networks**, v. 1, n. 4, p. 295-307, 1988 1988. ISSN 0893-6080.

JAIN, A. K. **Fundamentals of digital image processing**. Englewood Cliffs, NJ: Prentice Hall, 1989. ISBN 0133361659.

JOLLIFFE, I. **Principal component analysis**. Wiley Online Library, 2005. ISBN 0470013192.

JORGE, L. A. C. et al. Uso de sistemas de imagem para classificação de frutas e hortaliças. In: FERREIRA, M. D. (Ed.). **Tecnologias Pós-Colheita em Frutas e Hortaliças**. São Carlos, SP: Embrapa Instrumentação, 2011. cap. 7, p.127-153.

KHATCHATOURIAN, O.; PADILHA, F. R. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. **Eng Agric Jaboticabal**, v. 28, n. 4, p. 759-69, 2008.

KUHL, F.; GIARDINA, C. Elliptic fourier features of a closed contour. **Computer Graphics and Image Processing**, v. 18, n. 3, p. 236-258, 1982 1982. ISSN 0148-664X.

MACKAY, D. J. C. **Information theory, inference and learning algorithms**. Cambridge: Cambridge University Press, 2003. ISBN 0521642981 : No price. Disponível em: < Publisher description <http://www.loc.gov/catdir/description/cam032/2003055133.html> >.Disponível em: < Table of contents <http://www.loc.gov/catdir/toc/cam031/2003055133.html> >.

MAHALANOBIS, P. C. On the generalized distance in statistics. **Proceedings of the National Institute of Sciences (Calcutta)**, v. 2, p. 49-55, 1936.

MAJUMDAR, S.; JAYAS, D. Classification of cereal grains using machine vision: I. Morphology models. **Transactions of the Asae**, v. 43, n. 6, p. 1669-1675, NOV-DEC 2000 2000a. ISSN 0001-2351.

\_\_\_\_\_. Classification of cereal grains using machine vision: II. Color models. **Transactions of the Asae**, v. 43, n. 6, p. 1677-1680, NOV-DEC 2000 2000b. ISSN 0001-2351.

\_\_\_\_\_. Classification of cereal grains using machine vision: III. Texture models. **Transactions of the Asae**, v. 43, n. 6, p. 1681-1687, NOV-DEC 2000 2000c. ISSN 0001-2351.

\_\_\_\_\_. Classification of cereal grains using machine vision: IV. Combined morphology, color, and texture models. **Transactions of the Asae**, v. 43, n. 6, p. 1689-1694, NOV-DEC 2000 2000d. ISSN 0001-2351.

MALIK, F.; BAHARUDIN, B. The statistical quantized histogram texture features analysis for image retrieval based on median and laplacian filters in the DCT domain. **International Arab Journal of Information Technology**, v. 10, n. 6, p. 616-624, NOV 2013 2013. ISSN 1683-3198.

MCLACHLAN, G. J. **Discriminant analysis and statistical pattern recognition**. Hoboken, N.J.: Wiley-Interscience, 2004. ISBN 9780471691150 (pbk.) 0471691151 (pbk.) : No price.

MENDENHALL, W.; BEAVER, R. J.; BEAVER, B. M. Analysis of Categorical Data. In: (Ed.). **Introduction to probability and statistics**. 14th ed. [Pacific Grove, Calif.]: Brooks/Cole, 2013. cap. 14, p.574-605. ISBN 9781133111504 (pbk.) : 144.99 1133111505 (pbk.) : 144.99.

NEUMAN, M. et al. Wheat-grain color analysis by digital image-processing .1. methodology. **Journal of Cereal Science**, v. 10, n. 3, p. 175-182, NOV 1989 1989a. ISSN 0733-5210.

\_\_\_\_\_. Wheat-grain color analysis by digital image-processing .2. wheat class discrimination. **Journal of Cereal Science**, v. 10, n. 3, p. 183-188, NOV 1989 1989b. ISSN 0733-5210.

OHTA, Y.; KANADE, T.; SAKAI, T. Color information for region-segmentation. **Computer Graphics and Image Processing**, v. 13, n. 3, p. 222-241, 1980 1980. ISSN 0148-664X.

OLIVER, N.; ROSARIO, B.; PENTLAND, A. A Bayesian computer vision system for modeling human interactions. **Ieee Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 8, p. 831-843, AUG 2000 2000. ISSN 0162-8828.

OYAMA, P. I. C.; RODRIGUES, E. L. L.; JORGE, L. A. C. **Comparação de descritores de forma aplicados na classificação de grãos de café**. VIII Workshop de Visão Computacional. Goiânia, GO 2012.

PRATT, W. K. **Digital image processing : PIKS Scientific inside**. 4th ed., Newly updated and rev. ed. New York ; Chichester: Wiley-Interscience, 2007. ISBN 9780471767770 (hbk.) : 173.95  
0471767778 (hbk.) : 173.95.

RAO, K. R.; YIP, P. C. Karhunen-Loève Transform. In: (Ed.). **The transform and data compression handbook**. Boca Raton ; London: CRC Press, 2001. cap. 1, ISBN 0849336929 : No price.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. DTIC Document. 1985

SETIONO, R.; LIU, H. Improving backpropagation learning with feature selection. **Applied Intelligence**, v. 6, n. 2, p. 129-139, APR 1996 1996. ISSN 0924-669X.

SHI, Y. Q.; SUN, H. **Image and video compression for multimedia engineering : fundamentals, algorithms, and standards**. 2nd ed. Boca Raton, Fla.: CRC ; London : Taylor & Francis [distributor], 2008. ISBN 9780849373640 (hbk.) : 144.99  
0849373646 (hbk.) : 144.99.

SHOUCHE, S. et al. Shape analysis of grains of Indian wheat varieties. **Computers and Electronics in Agriculture**, v. 33, n. 1, p. 55-76, 2001. ISSN 0168-1699.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SYMONS, S. J.; FULCHER, R. Determination of wheat kernel morphological variation by digital image analysis: I. Variation in Eastern Canadian milling quality wheats. **Journal of cereal science**, v. 8, n. 3, p. 211-218, 1988. ISSN 0733-5210.

TEAGUE, M. Image analysis via the general-theory of moments. **Journal of the Optical Society of America**, v. 69, n. 10, p. 1468-1468, 1979 1979. ISSN 0030-3941.

VALIENTE-GONZALEZ, J. et al. Automatic corn (*Zea mays*) kernel inspection system using novelty detection based on principal component analysis. **Biosystems Engineering**, v. 117, p. 94-103, JAN 2014 2014. ISSN 1537-5110.

WALCK, C. **Handbook on statistical distributions for experimentalists**: University of Stockholm Internal Report SUF-PFY/96-01, available from [www.physto.se/~walck](http://www.physto.se/~walck) 2007.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining : practical machine learning tools and techniques**. 3rd ed. / Ian H. Witten, Eibe Frank, Mark A. Hall. San Francisco, Calif. ; London: Morgan Kaufmann, 2011. ISBN 9780123748560 (pbk.) : 142.99  
0123748569 (pbk.) : 142.99.

ZHANG, D.; LU, G. Generic Fourier descriptor for shape-based image retrieval. **Ieee International Conference on Multimedia and Expo, Vol I and Ii, Proceedings**, p. 425-428, 2002 2002.

\_\_\_\_\_. Review of shape representation and description techniques. **Pattern Recognition**, v. 37, n. 1, p. 1-19, JAN 2004 2004. ISSN 0031-3203.



## APÊNDICE

Nas Tabelas 28-32 são apresentadas as ordenações dos atributos pelos algoritmos de ganho de informação e chi-quadrado para as diferentes análises. A notação utilizada nas tabelas é apresentada na Tabela 27.

**Tabela 27 - Notação dos atributos utilizada nas tabelas de ordenações**

Atributo	Descrição
<b>Fu</b>	Descritor de Fourier de frequência <b>u</b>
DGF_R $\rho$ _A $\phi$	Descritor genérico de Fourier de frequência radial <b><math>\rho</math></b> e frequência angular <b><math>\phi</math></b>
AR_SN	Razão sinal-ruído do modelo autorregressivo
AR_i	i-ésimo parâmetro do modelo autorregressivo
Zernike_On_Rm	Momento de Zernike de ordem <b>n</b> e repetição <b>m</b>
Ai	i-ésimo atributo derivado (A <sub>i</sub> )
C_média	Média do histograma do canal de cor <b>C</b>
C_variância	Variância do histograma do canal de cor <b>C</b>
C_suavidade	Suavidade do histograma do canal de cor <b>C</b>
C_energia	Energia do histograma do canal de cor <b>C</b>
C_obliquidade	Obliquidade do histograma do canal de cor <b>C</b>
C_entropia	Entropia do histograma do canal de cor <b>C</b>
C_curtose	Curtose do histograma do canal de cor <b>C</b>
F_C_i(Horizontal)	i-ésimo descritor de Haralick modificado calculado para o canal de cor <b>C</b> e simetria horizontal
F_C_i(Vertical)	i-ésimo descritor de Haralick modificado calculado para o canal de cor <b>C</b> e simetria vertical
F_C_i(Diagonal)	i-ésimo descritor de Haralick modificado calculado para o canal de cor <b>C</b> e simetria diagonal

Tabela 28 – Ordenação dos atributos da análise  $A_M$  pelos algoritmos Ganho de Informação e chi-quadrado

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
1	Perímetro	Perímetro	107	Zernike_O1_R1	Zernike_O20_R0
2	Spread	Spread	108	Zernike_O7_R5	Zernike_O15_R13
3	Zernike_O0_R0	Zernike_O0_R0	109	Zernike_O17_R15	Zernike_O7_R1
4	Área	Área	110	Zernike_O5_R5	Zernike_O13_R11
5	Zernike_O2_R0	Zernike_O2_R0	111	F3	Zernike_O19_R7
6	F0	F0	112	Zernike_O19_R5	Zernike_O17_R11
7	Zernike_O6_R0	DGF_R0_A2	113	DGF_R2_A6	Zernike_O8_R2
8	DGF_R0_A2	Zernike_O6_R0	114	Zernike_O20_R0	Zernike_O19_R5
9	Slenderness	Slenderness	115	Zernike_O12_R2	Zernike_O5_R5
10	Zernike_O10_R0	F2	116	Zernike_O19_R7	Zernike_O7_R5
11	A1	A3	117	Zernike_O13_R11	Zernike_O1_R1
12	F2	DGF_R0_A1	118	Zernike_O17_R11	Zernike_O14_R6
13	A3	Zernike_O10_R0	119	Zernike_O9_R7	Zernike_O11_R9
14	Eixo maior	A1	120	Zernike_O9_R3	Zernike_O9_R7
15	DGF_R0_A1	Eixo maior	121	Zernike_O11_R3	Zernike_O17_R5
16	DGF_R0_A0	DGF_R0_A0	122	Zernike_O11_R9	AR_SN
17	A4	A4	123	Zernike_O15_R13	Zernike_O11_R3
18	A2	A2	124	Zernike_O17_R5	F3
19	Eixo menor	Zernike_O6_R4	125	Zernike_O14_R6	Zernike_O9_R3
20	Zernike_O14_R0	Zernike_O10_R4	126	Zernike_O3_R3	Zernike_O19_R13
21	Zernike_O6_R4	Zernike_O14_R0	127	Zernike_O20_R4	Zernike_O12_R2
22	Zernike_O10_R4	Zernike_O4_R4	128	Zernike_O19_R3	Zernike_O19_R3
23	Zernike_O4_R4	Eixo menor	129	Zernike_O20_R2	Zernike_O20_R4
24	DGF_R1_A5	Excentricidade	130	Zernike_O15_R3	Zernike_O3_R3
25	Excentricidade	DGF_R0_A3	131	Zernike_O16_R2	Zernike_O15_R3
26	DGF_R0_A3	Zernike_O4_R2	132	AR_SN	Zernike_O13_R9
27	Zernike_O4_R2	Zernike_O2_R2	133	Zernike_O19_R13	Zernike_O20_R2
28	Zernike_O14_R4	DGF_R1_A5	134	Zernike_O13_R9	Zernike_O20_R8
29	Zernike_O18_R0	Zernike_O14_R8	135	Zernike_O13_R3	DGF_R2_A3
30	DGF_R1_A6	Zernike_O8_R8	136	AR_1	Zernike_O16_R2
31	Zernike_O14_R8	Zernike_O6_R6	137	Zernike_O20_R8	AR_1
32	Zernike_O8_R8	Zernike_O10_R8	138	Zernike_O17_R3	Zernike_O15_R11
33	Zernike_O18_R4	Zernike_O8_R6	139	Zernike_O11_R1	Zernike_O13_R3
34	Zernike_O2_R2	DGF_R3_A6	140	Zernike_O5_R1	DGF_R3_A0
35	DGF_R1_A4	Zernike_O12_R6	141	Zernike_O15_R11	DGF_R1_A0
36	Zernike_O4_R0	Zernike_O4_R0	142	Zernike_O19_R1	DGF_R2_A2
37	Zernike_O20_R20	DGF_R1_A6	143	F5	DGF_R2_A1
38	Zernike_O12_R12	Zernike_O10_R10	144	Zernike_O9_R1	Zernike_O18_R6
39	Zernike_O18_R18	Zernike_O12_R12	145	Zernike_O17_R13	Zernike_O5_R1
40	Zernike_O16_R16	Zernike_O18_R0	146	Zernike_O18_R6	DGF_R2_A0

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
41	Zernike_O6_R6	DGF_R1_A4	147	Zernike_O15_R1	Zernike_O11_R1
42	Zernike_O10_R10	Zernike_O14_R4	148	DGF_R2_A3	Zernike_O17_R13
43	DGF_R3_A6	Zernike_O16_R16	149	Zernike_O13_R1	Zernike_O17_R3
44	Zernike_O12_R6	Zernike_O20_R20	150	A5	Zernike_O19_R15
45	Zernike_O8_R6	Zernike_O18_R18	151	Zernike_O19_R15	F5
46	Zernike_O10_R6	DGF_R0_A4	152	DGF_R2_A2	Zernike_O19_R1
47	Zernike_O10_R8	Zernike_O14_R14	153	DGF_R2_A1	Zernike_O9_R1
48	Zernike_O14_R14	Zernike_O16_R10	154	Zernike_O17_R1	DGF_R1_A1
49	Zernike_O18_R2	Zernike_O18_R8	155	DGF_R2_A5	DGF_R3_A1
50	Zernike_O3_R1	Zernike_O10_R6	156	Zernike_O12_R4	DGF_R2_A4
51	Zernike_O14_R2	Zernike_O18_R2	157	DGF_R2_A0	Zernike_O15_R1
52	Zernike_O18_R8	Zernike_O12_R10	158	DGF_R1_A0	Zernike_O12_R4
53	Zernike_O19_R19	Zernike_O18_R4	159	F4	Zernike_O13_R1
54	Zernike_O15_R15	DGF_R0_A5	160	DGF_R3_A0	A5
55	Zernike_O17_R17	Zernike_O14_R2	161	DGF_R2_A4	DGF_R2_A5
56	Zernike_O8_R0	Zernike_O14_R12	162	Zernike_O16_R4	DGF_R1_A3
57	Zernike_O16_R6	Zernike_O16_R6	163	DGF_R1_A1	Zernike_O17_R1
58	Zernike_O11_R11	Zernike_O12_R8	164	F7	F4
59	Zernike_O12_R8	Zernike_O20_R18	165	DGF_R1_A3	Zernike_O16_R4
60	Zernike_O16_R10	Zernike_O8_R0	166	DGF_R3_A1	F7
61	Zernike_O13_R13	Zernike_O18_R12	167	DGF_R3_A4	DGF_R1_A2
62	DGF_R0_A4	Zernike_O19_R19	168	DGF_R1_A2	DGF_R3_A4
63	AR_0	Zernike_O20_R10	169	F6	DGF_R3_A2
64	Zernike_O9_R5	Zernike_O15_R15	170	F8	F6
65	Zernike_O12_R10	Zernike_O17_R17	171	F10	F8
66	Zernike_O20_R6	AR_0	172	F9	DGF_R3_A3
67	Zernike_O20_R10	Zernike_O3_R1	173	DGF_R3_A2	F10
68	Zernike_O14_R12	Zernike_O18_R16	174	DGF_R3_A3	F9
69	Zernike_O13_R7	Zernike_O13_R13	175	F11	F11
70	DGF_R0_A5	Zernike_O16_R12	176	F12	F38
71	Zernike_O9_R9	Zernike_O16_R14	177	F38	F12
72	Zernike_O10_R2	Zernike_O14_R10	178	F35	F35
73	Zernike_O8_R4	Zernike_O11_R11	179	F29	F29
74	Zernike_O18_R12	DGF_R0_A6	180	AR_9	AR_9
75	Zernike_O7_R7	Zernike_O20_R14	181	F31	F14
76	Zernike_O14_R10	Zernike_O18_R14	182	F1	F31
77	Zernike_O17_R9	Zernike_O9_R5	183	F14	F13
78	Zernike_O11_R5	Zernike_O20_R16	184	F13	F25
79	Zernike_O20_R12	Zernike_O17_R9	185	F25	F32
80	Zernike_O20_R18	Zernike_O13_R7	186	F32	F28
81	Zernike_O7_R3	Zernike_O8_R4	187	F28	F37
82	Zernike_O18_R10	Zernike_O20_R6	188	F37	F27
83	Zernike_O16_R8	Zernike_O20_R12	189	F34	F1
84	Zernike_O16_R12	Zernike_O10_R2	190	F27	F34

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
85	Zernike_O7_R1	DGF_R3_A5	191	F33	F23
86	Zernike_O17_R7	Zernike_O16_R8	192	F23	AR_4
87	Zernike_O5_R3	Zernike_O6_R2	193	F36	F24
88	Zernike_O18_R16	Zernike_O9_R9	194	F24	F33
89	Zernike_O15_R9	Zernike_O18_R10	195	F21	F36
90	Zernike_O12_R0	Zernike_O11_R5	196	F26	F21
91	Zernike_O18_R14	Zernike_O19_R9	197	AR_4	F26
92	Zernike_O20_R14	Zernike_O19_R17	198	AR_2	AR_2
93	Zernike_O6_R2	Zernike_O17_R7	199	F22	F22
94	Zernike_O13_R5	Zernike_O12_R0	200	F20	F20
95	Zernike_O19_R9	Zernike_O7_R7	201	F30	F30
96	Zernike_O15_R7	Zernike_O7_R3	202	F16	F19
97	Zernike_O11_R7	Zernike_O15_R7	203	F19	AR_3
98	Zernike_O15_R5	Zernike_O15_R9	204	AR_3	F16
99	Zernike_O19_R11	Zernike_O19_R11	205	AR_8	AR_8
100	DGF_R3_A5	Zernike_O16_R0	206	AR_6	F15
101	Zernike_O16_R14	Zernike_O17_R15	207	F15	F18
102	Zernike_O19_R17	DGF_R2_A6	208	F17	AR_6
103	Zernike_O20_R16	Zernike_O13_R5	209	AR_7	AR_7
104	DGF_R0_A6	Zernike_O11_R7	210	F18	AR_5
105	Zernike_O16_R0	Zernike_O5_R3	211	AR_5	F17
106	Zernike_O8_R2	Zernike_O15_R5			

**Tabela 29 – Ordenação dos atributos da análise  $A_C$  pelos algoritmos Ganho de Informação e chi-quadrado**

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
1	I1_média	I1_média	43	I2_suavidade	CIE-b_suavidade
2	V_média	V_média	44	I2_variância	I2_variância
3	CIE-L_média	S_média	45	V_energia	I2_suavidade
4	S_média	R_energia	46	H_energia	H_suavidade
5	R_variância	G_energia	47	CIE-a_entropia	H_variância
6	R_suavidade	G_variância	48	I2_energia	CIE-L_entropia
7	R_energia	G_suavidade	49	R_obliquidade	S_obliquidade
8	G_média	R_suavidade	50	I2_entropia	I2_energia
9	G_variância	R_variância	51	H_entropia	H_energia
10	G_suavidade	CIE-L_média	52	V_entropia	S_variância
11	G_energia	G_média	53	S_energia	I1_entropia
12	R_média	B_média	54	G_obliquidade	S_suavidade
13	CIE-L_suavidade	CIE-L_variância	55	S_entropia	H_entropia
14	CIE-L_variância	CIE-L_suavidade	56	S_variância	B_obliquidade
15	I3_variância	G_entropia	57	S_suavidade	CIE-a_entropia
16	I3_suavidade	R_média	58	CIE-a_energia	CIE-b_energia

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
17	B_média	B_energia	59	B_curtose	I2_entropia
18	I2_média	H_média	60	CIE-b_energia	CIE-a_energia
19	CIE-a_suavidade	I3_variância	61	CIE-b_entropia	B_curtose
20	CIE-a_variância	I3_suavidade	62	CIE-L_obliquidade	B_suavidade
21	G_entropia	I2_média	63	B_variância	B_variância
22	H_média	V_obliquidade	64	B_suavidade	I1_obliquidade
23	B_energia	R_entropia	65	I1_obliquidade	CIE-L_obliquidade
24	CIE-L_energia	CIE-b_média	66	S_curtose	CIE-b_entropia
25	V_obliquidade	CIE-L_energia	67	B_obliquidade	S_curtose
26	I3_média	CIE-a_média	68	H_curtose	V_curtose
27	CIE-b_média	V_energia	69	V_curtose	H_curtose
28	I3_entropia	CIE-a_suavidade	70	I2_curtose	I2_curtose
29	I1_variância	CIE-a_variância	71	I2_obliquidade	I2_obliquidade
30	I1_suavidade	I3_média	72	H_obliquidade	CIE-b_curtose
31	R_entropia	B_entropia	73	R_curtose	H_obliquidade
32	CIE-a_média	I3_entropia	74	CIE-b_curtose	CIE-b_obliquidade
33	I1_energia	S_energia	75	CIE-b_obliquidade	CIE-a_obliquidade
34	CIE-L_entropia	R_obliquidade	76	CIE-a_obliquidade	V_variância
35	H_suavidade	V_entropia	77	V_suavidade	V_suavidade
36	H_variância	S_entropia	78	V_variância	I3_obliquidade
37	I3_energia	I1_variância	79	I3_obliquidade	R_curtose
38	I1_entropia	I1_suavidade	80	G_curtose	CIE-a_curtose
39	B_entropia	I1_energia	81	CIE-a_curtose	I3_curtose
40	S_obliquidade	I3_energia	82	I3_curtose	G_curtose
41	CIE-b_variância	G_obliquidade	83	CIE-L_curtose	CIE-L_curtose
42	CIE-b_suavidade	CIE-b_variância	84	I1_curtose	I1_curtose

**Tabela 30 – Ordenação dos atributos da análise AT pelos algoritmos Ganho de Informação e chi-quadrado**

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
1	F_I1_7(Horizontal)	F_I1_7(Horizontal)	64	F_I3_10(Horizontal)	F_I2_10(Horizontal)
2	F_I1_7(Vertical)	F_I1_7(Vertical)	65	F_I2_5(Diagonal)	F_I3_11(Vertical)
3	F_I1_7(Diagonal)	F_I1_7(Diagonal)	66	F_I3_5(Vertical)	F_I3_1(Diagonal)
4	F_I1_6(Vertical)	F_I1_6(Vertical)	67	F_I2_1(Horizontal)	F_I3_10(Diagonal)
5	F_I1_6(Diagonal)	F_I1_6(Horizontal)	68	F_I2_9(Horizontal)	F_I2_11(Horizontal)
6	F_I1_6(Horizontal)	F_I1_6(Diagonal)	69	F_I2_2(Vertical)	F_I2_2(Diagonal)
7	F_I1_2(Diagonal)	F_I1_2(Diagonal)	70	F_I2_1(Diagonal)	F_I3_1(Vertical)
8	F_I1_2(Horizontal)	F_I1_2(Horizontal)	71	F_I2_9(Diagonal)	F_I2_11(Diagonal)
9	F_I1_2(Vertical)	F_I1_2(Vertical)	72	F_I3_10(Vertical)	F_I3_10(Horizontal)
10	F_I2_7(Vertical)	F_I2_7(Vertical)	73	F_I2_8(Horizontal)	F_I2_5(Diagonal)
11	F_I2_6(Horizontal)	F_I2_6(Horizontal)	74	F_I2_2(Horizontal)	F_I2_10(Diagonal)
12	F_I2_6(Vertical)	F_I2_6(Vertical)	75	F_I2_9(Vertical)	F_I3_5(Vertical)
13	F_I2_6(Diagonal)	F_I2_6(Diagonal)	76	F_I2_1(Vertical)	F_I2_9(Horizontal)

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
14	F_I2_7(Diagonal)	F_I2_7(Horizontal)	77	F_I2_8(Vertical)	F_I2_2(Horizontal)
15	F_I2_7(Horizontal)	F_I2_7(Diagonal)	78	F_I2_11(Vertical)	F_I2_1(Diagonal)
16	F_I1_11(Diagonal)	F_I3_6(Diagonal)	79	F_I2_8(Diagonal)	F_I3_10(Vertical)
17	F_I3_6(Diagonal)	F_I3_6(Horizontal)	80	F_I2_10(Vertical)	F_I2_1(Horizontal)
18	F_I3_7(Vertical)	F_I3_6(Vertical)	81	F_I2_5(Vertical)	F_I2_9(Diagonal)
19	F_I3_6(Horizontal)	F_I3_7(Vertical)	82	F_I2_4(Horizontal)	F_I2_2(Vertical)
20	F_I3_7(Horizontal)	F_I3_7(Diagonal)	83	F_I2_4(Diagonal)	F_I2_9(Vertical)
21	F_I3_7(Diagonal)	F_I3_7(Horizontal)	84	F_I2_4(Vertical)	F_I2_8(Horizontal)
22	F_I3_6(Vertical)	F_I1_11(Diagonal)	85	F_I3_4(Horizontal)	F_I2_1(Vertical)
23	F_I1_11(Horizontal)	F_I1_11(Horizontal)	86	F_I3_4(Diagonal)	F_I2_11(Vertical)
24	F_I1_9(Horizontal)	F_I1_11(Vertical)	87	F_I3_4(Vertical)	F_I2_8(Vertical)
25	F_I1_8(Horizontal)	F_I3_8(Vertical)	88	F_I1_4(Vertical)	F_I2_8(Diagonal)
26	F_I1_8(Vertical)	F_I3_2(Diagonal)	89	F_I1_4(Diagonal)	F_I3_13(Diagonal)
27	F_I1_8(Diagonal)	F_I3_8(Horizontal)	90	F_I1_4(Horizontal)	F_I2_10(Vertical)
28	F_I1_9(Diagonal)	F_I3_8(Diagonal)	91	F_I1_13(Vertical)	F_I2_5(Vertical)
29	F_I1_9(Vertical)	F_I3_9(Horizontal)	92	F_I2_13(Vertical)	F_I3_13(Vertical)
30	F_I1_5(Diagonal)	F_I3_9(Diagonal)	93	F_I3_13(Diagonal)	F_I2_13(Vertical)
31	F_I1_11(Vertical)	F_I1_9(Horizontal)	94	F_I3_13(Vertical)	F_I3_13(Horizontal)
32	F_I1_5(Horizontal)	F_I1_5(Diagonal)	95	F_I2_13(Diagonal)	F_I2_13(Diagonal)
33	F_I1_10(Diagonal)	F_I1_8(Horizontal)	96	F_I3_13(Horizontal)	F_I1_13(Vertical)
34	F_I1_1(Diagonal)	F_I1_9(Diagonal)	97	F_I2_13(Horizontal)	F_I2_13(Horizontal)
35	F_I1_1(Horizontal)	F_I3_9(Vertical)	98	F_I2_3(Vertical)	F_I2_3(Vertical)
36	F_I1_1(Vertical)	F_I1_8(Vertical)	99	F_I1_3(Vertical)	F_I1_3(Vertical)
37	F_I1_10(Horizontal)	F_I1_9(Vertical)	100	F_I1_13(Diagonal)	F_I3_12(Diagonal)
38	F_I3_8(Vertical)	F_I1_8(Diagonal)	101	F_I2_14(Diagonal)	F_I3_14(Diagonal)
39	F_I3_8(Horizontal)	F_I2_4(Diagonal)	102	F_I3_14(Vertical)	F_I2_14(Diagonal)
40	F_I3_8(Diagonal)	F_I2_4(Horizontal)	103	F_I2_14(Vertical)	F_I3_14(Vertical)
41	F_I1_5(Vertical)	F_I1_10(Diagonal)	104	F_I1_3(Horizontal)	F_I3_3(Vertical)
42	F_I3_2(Diagonal)	F_I2_4(Vertical)	105	F_I3_12(Diagonal)	F_I2_14(Vertical)
43	F_I3_9(Horizontal)	F_I3_2(Vertical)	106	F_I1_13(Horizontal)	F_I1_13(Diagonal)
44	F_I1_10(Vertical)	F_I3_4(Horizontal)	107	F_I3_14(Diagonal)	F_I2_12(Diagonal)
45	F_I3_9(Diagonal)	F_I3_4(Vertical)	108	F_I2_14(Horizontal)	F_I3_12(Vertical)
46	F_I3_9(Vertical)	F_I3_4(Diagonal)	109	F_I2_12(Diagonal)	F_I2_14(Horizontal)
47	F_I3_2(Vertical)	F_I1_1(Diagonal)	110	F_I3_3(Vertical)	F_I3_12(Horizontal)
48	F_I3_11(Diagonal)	F_I1_1(Horizontal)	111	F_I3_12(Vertical)	F_I1_3(Horizontal)
49	F_I3_1(Horizontal)	F_I1_5(Horizontal)	112	F_I3_12(Horizontal)	F_I1_13(Horizontal)
50	F_I3_2(Horizontal)	F_I1_10(Horizontal)	113	F_I1_12(Horizontal)	F_I2_12(Vertical)
51	F_I3_1(Diagonal)	F_I1_1(Vertical)	114	F_I2_12(Vertical)	F_I1_12(Horizontal)
52	F_I3_11(Horizontal)	F_I3_2(Horizontal)	115	F_I2_12(Horizontal)	F_I2_12(Horizontal)
53	F_I3_1(Vertical)	F_I3_11(Diagonal)	116	F_I3_14(Horizontal)	F_I3_14(Horizontal)
54	F_I2_10(Horizontal)	F_I2_5(Horizontal)	117	F_I1_14(Vertical)	F_I2_3(Diagonal)
55	F_I3_11(Vertical)	F_I1_4(Horizontal)	118	F_I2_3(Diagonal)	F_I1_12(Diagonal)
56	F_I3_5(Diagonal)	F_I1_4(Vertical)	119	F_I1_12(Diagonal)	F_I1_14(Vertical)
57	F_I2_5(Horizontal)	F_I3_5(Horizontal)	120	F_I1_14(Horizontal)	F_I1_14(Horizontal)

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
58	F_I2_11(Horizontal)	F_I1_4(Diagonal)	121	F_I1_14(Diagonal)	F_I2_3(Horizontal)
59	F_I2_2(Diagonal)	F_I3_5(Diagonal)	122	F_I2_3(Horizontal)	F_I1_14(Diagonal)
60	F_I3_5(Horizontal)	F_I3_1(Horizontal)	123	F_I1_12(Vertical)	F_I3_3(Diagonal)
61	F_I2_11(Diagonal)	F_I1_10(Vertical)	124	F_I1_3(Diagonal)	F_I1_12(Vertical)
62	F_I3_10(Diagonal)	F_I1_5(Vertical)	125	F_I3_3(Diagonal)	F_I1_3(Diagonal)
63	F_I2_10(Diagonal)	F_I3_11(Horizontal)	126	F_I3_3(Horizontal)	F_I3_3(Horizontal)

**Tabela 31 – Ordenação dos atributos da análise ACT pelos algoritmos Ganho de Informação e chi-quadrado**

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
1	I1_média	I1_média	106	F_I3_10(Diagonal)	S_obliquidade
2	V_média	V_média	107	F_I2_5(Horizontal)	F_I2_4(Vertical)
3	F_I1_7(Horizontal)	S_média	108	F_I2_10(Diagonal)	F_I2_11(Horizontal)
4	F_I1_7(Vertical)	F_I1_7(Horizontal)	109	F_I3_10(Horizontal)	F_I3_1(Horizontal)
5	F_I1_7(Diagonal)	F_I1_7(Vertical)	110	H_energia	F_I3_1(Diagonal)
6	F_I1_6(Vertical)	F_I1_7(Diagonal)	111	F_I2_1(Horizontal)	F_I2_4(Diagonal)
7	F_I1_6(Horizontal)	R_energia	112	F_I2_9(Diagonal)	F_I2_5(Horizontal)
8	F_I1_6(Diagonal)	G_energia	113	F_I2_8(Vertical)	F_I3_10(Diagonal)
9	CIE-L_média	R_suavidade	114	F_I2_9(Horizontal)	F_I3_11(Vertical)
10	S_média	R_variância	115	F_I2_9(Vertical)	F_I2_2(Diagonal)
11	R_suavidade	F_I1_6(Vertical)	116	F_I2_5(Diagonal)	F_I2_11(Diagonal)
12	R_variância	G_variância	117	CIE-a_entropia	F_I3_10(Horizontal)
13	R_energia	G_suavidade	118	F_I2_1(Diagonal)	F_I2_10(Horizontal)
14	G_média	F_I1_6(Diagonal)	119	F_I2_8(Horizontal)	I2_energia
15	G_variância	F_I1_6(Horizontal)	120	F_I3_5(Vertical)	F_I2_9(Horizontal)
16	G_suavidade	CIE-L_média	121	F_I2_1(Vertical)	F_I1_4(Vertical)
17	G_energia	F_I1_2(Diagonal)	122	F_I2_8(Diagonal)	F_I1_4(Diagonal)
18	R_média	F_I1_2(Vertical)	123	I2_energia	F_I2_2(Horizontal)
19	F_I1_2(Diagonal)	F_I1_2(Horizontal)	124	F_I3_10(Vertical)	F_I1_4(Horizontal)
20	F_I1_2(Vertical)	G_média	125	F_I2_2(Horizontal)	F_I2_10(Diagonal)
21	F_I1_2(Horizontal)	B_média	126	I2_entropia	F_I3_5(Vertical)
22	CIE-L_variância	CIE-L_variância	127	F_I2_2(Vertical)	H_energia
23	CIE-L_suavidade	CIE-L_suavidade	128	R_obliquidade	F_I2_1(Diagonal)
24	B_média	R_média	129	H_entropia	F_I2_5(Diagonal)
25	I3_variância	G_entropia	130	F_I2_11(Vertical)	F_I2_1(Horizontal)
26	I3_suavidade	B_energia	131	V_entropia	F_I2_9(Vertical)
27	F_I2_7(Vertical)	I3_suavidade	132	S_energia	F_I2_9(Diagonal)
28	CIE-a_suavidade	I3_variância	133	F_I2_10(Vertical)	S_variância
29	CIE-a_variância	H_média	134	S_entropia	S_suavidade
30	F_I2_7(Diagonal)	F_I2_7(Vertical)	135	CIE-a_energia	F_I3_10(Vertical)
31	F_I2_6(Horizontal)	F_I2_7(Diagonal)	136	G_obliquidade	F_I2_8(Vertical)
32	F_I2_6(Diagonal)	F_I2_6(Horizontal)	137	F_I2_5(Vertical)	F_I2_2(Vertical)
33	I2_média	F_I2_6(Diagonal)	138	CIE-b_entropia	F_I2_1(Vertical)

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
34	G_entropia	R_entropia	139	S_variância	I1_entropia
35	F_I2_6(Vertical)	F_I2_6(Vertical)	140	CIE-b_energia	CIE-a_entropia
36	F_I2_7(Horizontal)	I2_média	141	S_suavidade	F_I2_8(Horizontal)
37	H_média	F_I2_7(Horizontal)	142	B_curtose	CIE-b_energia
38	F_I1_11(Diagonal)	V_obliquidade	143	B_variância	B_obliquidade
39	B_energia	CIE-L_energia	144	B_suavidade	F_I2_8(Diagonal)
40	CIE-L_energia	CIE-b_média	145	CIE-L_obliquidade	I2_entropia
41	F_I3_6(Horizontal)	CIE-a_média	146	I1_obliquidade	H_entropia
42	F_I1_11(Horizontal)	CIE-a_suavidade	147	F_I1_13(Vertical)	CIE-a_energia
43	F_I3_6(Vertical)	CIE-a_variância	148	F_I2_13(Vertical)	F_I2_11(Vertical)
44	F_I3_6(Diagonal)	F_I3_6(Horizontal)	149	F_I3_4(Diagonal)	B_curtose
45	F_I3_7(Vertical)	F_I3_6(Vertical)	150	F_I3_4(Horizontal)	B_variância
46	F_I3_7(Horizontal)	F_I3_6(Diagonal)	151	F_I3_4(Vertical)	B_suavidade
47	V_obliquidade	V_energia	152	F_I2_4(Horizontal)	F_I2_5(Vertical)
48	F_I3_7(Diagonal)	F_I3_7(Vertical)	153	F_I2_4(Vertical)	F_I2_10(Vertical)
49	F_I1_8(Vertical)	F_I3_7(Horizontal)	154	F_I2_4(Diagonal)	I1_obliquidade
50	I3_média	F_I3_7(Diagonal)	155	F_I3_13(Diagonal)	F_I3_13(Diagonal)
51	F_I1_8(Horizontal)	F_I1_11(Diagonal)	156	B_obliquidade	CIE-b_entropia
52	F_I1_9(Horizontal)	B_entropia	157	S_curtose	CIE-L_obliquidade
53	F_I1_8(Diagonal)	I3_média	158	F_I1_4(Vertical)	F_I3_13(Vertical)
54	I3_entropia	F_I1_11(Horizontal)	159	F_I1_4(Horizontal)	F_I2_13(Vertical)
55	F_I1_9(Vertical)	I3_entropia	160	F_I1_4(Diagonal)	F_I3_13(Horizontal)
56	F_I1_9(Diagonal)	S_energia	161	F_I3_13(Vertical)	F_I2_13(Diagonal)
57	CIE-b_média	F_I3_8(Vertical)	162	F_I2_13(Diagonal)	S_curtose
58	I1_suavidade	F_I1_11(Vertical)	163	V_curtose	F_I1_13(Vertical)
59	I1_variância	F_I3_8(Horizontal)	164	H_curtose	F_I2_13(Horizontal)
60	R_entropia	F_I3_8(Diagonal)	165	F_I3_13(Horizontal)	V_curtose
61	F_I1_10(Diagonal)	F_I3_2(Diagonal)	166	F_I2_13(Horizontal)	I2_curtose
62	F_I1_5(Diagonal)	F_I3_9(Horizontal)	167	I2_curtose	H_curtose
63	F_I1_11(Vertical)	F_I3_9(Diagonal)	168	F_I2_3(Vertical)	I2_obliquidade
64	F_I1_1(Vertical)	F_I1_8(Vertical)	169	H_obliquidade	F_I2_3(Vertical)
65	CIE-a_média	V_entropia	170	F_I1_3(Vertical)	CIE-b_curtose
66	F_I1_1(Diagonal)	F_I1_8(Horizontal)	171	I2_obliquidade	F_I3_12(Diagonal)
67	F_I1_5(Horizontal)	F_I1_9(Horizontal)	172	F_I2_14(Diagonal)	F_I1_3(Vertical)
68	F_I1_10(Horizontal)	F_I1_8(Diagonal)	173	F_I1_13(Diagonal)	F_I2_14(Diagonal)
69	F_I1_1(Horizontal)	F_I3_9(Vertical)	174	F_I3_14(Vertical)	H_obliquidade
70	F_I1_5(Vertical)	F_I1_9(Diagonal)	175	CIE-b_curtose	CIE-b_obliquidade
71	F_I3_8(Vertical)	R_obliquidade	176	CIE-b_obliquidade	F_I3_14(Diagonal)
72	I1_energia	F_I1_9(Vertical)	177	R_curtose	V_suavidade
73	F_I3_8(Diagonal)	I3_energia	178	F_I2_14(Vertical)	V_variância
74	F_I3_8(Horizontal)	S_entropia	179	V_variância	F_I3_14(Vertical)
75	CIE-L_entropia	I1_energia	180	V_suavidade	CIE-a_obliquidade
76	I3_energia	I1_suavidade	181	CIE-a_obliquidade	F_I1_13(Diagonal)
77	F_I3_9(Horizontal)	I1_variância	182	F_I1_3(Horizontal)	I3_obliquidade



Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
78	H_variância	CIE-b_variância	183	F_I3_12(Diagonal)	F_I2_14(Vertical)
79	H_suavidade	CIE-b_suavidade	184	I3_obliquidade	F_I3_3(Vertical)
80	F_I3_2(Diagonal)	F_I1_10(Diagonal)	185	F_I3_14(Diagonal)	F_I2_12(Diagonal)
81	F_I3_9(Diagonal)	I2_suavidade	186	F_I1_13(Horizontal)	R_curtose
82	F_I1_10(Vertical)	I2_variância	187	F_I2_14(Horizontal)	F_I2_14(Horizontal)
83	F_I3_9(Vertical)	F_I1_5(Diagonal)	188	F_I2_12(Diagonal)	F_I3_12(Vertical)
84	B_entropia	F_I3_2(Vertical)	189	G_curtose	I3_curtose
85	I1_entropia	F_I1_10(Horizontal)	190	CIE-a_curtose	F_I2_12(Vertical)
86	CIE-b_variância	F_I1_1(Vertical)	191	F_I3_3(Vertical)	CIE-a_curtose
87	CIE-b_suavidade	F_I1_1(Diagonal)	192	F_I2_12(Vertical)	F_I3_12(Horizontal)
88	S_obliquidade	F_I1_5(Horizontal)	193	I3_curtose	F_I1_3(Horizontal)
89	F_I3_2(Vertical)	G_obliquidade	194	F_I1_12(Horizontal)	F_I1_12(Horizontal)
90	I2_variância	F_I1_1(Horizontal)	195	F_I3_12(Horizontal)	F_I1_13(Horizontal)
91	I2_suavidade	F_I3_11(Diagonal)	196	F_I3_12(Vertical)	G_curtose
92	F_I3_11(Diagonal)	H_variância	197	F_I3_14(Horizontal)	F_I3_14(Horizontal)
93	F_I3_11(Horizontal)	H_suavidade	198	F_I2_12(Horizontal)	F_I2_12(Horizontal)
94	V_energia	F_I3_5(Horizontal)	199	F_I1_14(Vertical)	F_I1_14(Vertical)
95	F_I3_1(Diagonal)	F_I1_5(Vertical)	200	F_I1_14(Horizontal)	F_I1_12(Diagonal)
96	F_I3_1(Horizontal)	F_I3_5(Diagonal)	201	F_I1_12(Diagonal)	F_I2_3(Diagonal)
97	F_I3_1(Vertical)	F_I3_11(Horizontal)	202	F_I2_3(Diagonal)	F_I1_14(Horizontal)
98	F_I3_2(Horizontal)	F_I1_10(Vertical)	203	F_I1_14(Diagonal)	F_I1_14(Diagonal)
99	F_I3_11(Vertical)	F_I3_2(Horizontal)	204	CIE-L_curtose	CIE-L_curtose
100	F_I3_5(Horizontal)	F_I3_4(Vertical)	205	F_I1_12(Vertical)	F_I2_3(Horizontal)
101	F_I2_11(Horizontal)	F_I3_4(Diagonal)	206	F_I1_3(Diagonal)	F_I1_12(Vertical)
102	F_I3_5(Diagonal)	F_I2_4(Horizontal)	207	F_I2_3(Horizontal)	F_I1_3(Diagonal)
103	F_I2_10(Horizontal)	F_I3_4(Horizontal)	208	I1_curtose	I1_curtose
104	F_I2_11(Diagonal)	CIE-L_entropia	209	F_I3_3(Diagonal)	F_I3_3(Diagonal)
105	F_I2_2(Diagonal)	F_I3_1(Vertical)	210	F_I3_3(Horizontal)	F_I3_3(Horizontal)

**Tabela 32 – Ordenação dos atributos da análise AMCT pelos algoritmos Ganho de Informação e chi-quadrado**

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
1	I1_média	I1_média	212	Zernike_O16_R16	Zernike_O14_R14
2	V_média	V_média	213	F_I3_12(Diagonal)	Zernike_O20_R20
3	F_I1_7(Horizontal)	S_média	214	Zernike_O8_R8	F_I3_12(Vertical)
4	F_I1_7(Vertical)	F_I1_7(Horizontal)	215	Zernike_O12_R12	Zernike_O2_R2
5	F_I1_7(Diagonal)	F_I1_7(Vertical)	216	Zernike_O14_R14	Zernike_O4_R2
6	F_I1_6(Horizontal)	F_I1_7(Diagonal)	217	F_I1_3(Horizontal)	I3_curtose
7	F_I1_6(Vertical)	R_energia	218	F_I3_14(Vertical)	Zernike_O10_R8
8	F_I1_6(Diagonal)	G_energia	219	Zernike_O4_R0	DGF_R1_A6
9	CIE-L_média	R_variância	220	Zernike_O10_R10	Zernike_O4_R0
10	G_média	R_suavidade	221	Zernike_O19_R19	CIE-a_curtose
11	R_suavidade	G_suavidade	222	F_I1_13(Diagonal)	Zernike_O14_R8

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
12	R_variância	G_variância	223	Zernike_O15_R15	Zernike_O18_R2
13	S_média	F_I1_6(Vertical)	224	Zernike_O17_R17	Zernike_O8_R6
14	R_energia	F_I1_6(Horizontal)	225	Excentricidade	DGF_R1_A5
15	G_variância	F_I1_6(Diagonal)	226	Zernike_O13_R13	Zernike_O18_R0
16	G_suavidade	CIE-L_média	227	DGF_R0_A3	Zernike_O12_R6
17	G_energia	F_I1_2(Diagonal)	228	Zernike_O11_R11	Zernike_O14_R2
18	R_média	Spread	229	F_I2_14(Vertical)	F_I2_14(Horizontal)
19	CIE-a_suavidade	F_I1_2(Vertical)	230	F_I3_12(Vertical)	F_I2_12(Diagonal)
20	CIE-a_variância	F_I1_2(Horizontal)	231	F_I3_14(Diagonal)	F_I3_14(Vertical)
21	Spread	Perímetro	232	Zernike_O8_R0	F_I2_14(Vertical)
22	F0	Área	233	F_I2_12(Diagonal)	H_obliquidade
23	Área	Zernike_O0_R0	234	F_I2_14(Horizontal)	DGF_R0_A4
24	Zernike_O0_R0	G_média	235	AR_0	Zernike_O19_R19
25	Perímetro	F0	236	Zernike_O6_R6	Zernike_O15_R15
26	F_I1_2(Diagonal)	I2_média	237	Zernike_O3_R1	Zernike_O12_R10
27	I3_suavidade	I3_variância	238	R_curtose	Zernike_O17_R17
28	I3_variância	I3_suavidade	239	V_suavidade	Zernike_O14_R12
29	I2_média	Zernike_O2_R0	240	V_variância	Zernike_O16_R10
30	Zernike_O2_R0	CIE-a_suavidade	241	Zernike_O2_R2	Zernike_O16_R14
31	Zernike_O6_R0	CIE-a_variância	242	Zernike_O14_R8	V_variância
32	F_I2_6(Vertical)	F_I2_6(Vertical)	243	Zernike_O10_R6	V_suavidade
33	F_I1_2(Horizontal)	F_I2_7(Horizontal)	244	Zernike_O12_R8	DGF_R3_A6
34	F_I2_7(Horizontal)	F_I2_7(Diagonal)	245	F_I2_3(Diagonal)	Zernike_O12_R8
35	F_I2_6(Horizontal)	CIE-b_média	246	Zernike_O12_R6	Zernike_O13_R13
36	F_I2_7(Diagonal)	F_I2_6(Horizontal)	247	Zernike_O10_R8	Zernike_O11_R11
37	F_I1_2(Vertical)	F_I2_7(Vertical)	248	G_curtose	AR_0
38	F_I2_6(Diagonal)	F_I2_6(Diagonal)	249	Zernike_O8_R6	Zernike_O18_R16
39	F_I2_7(Vertical)	R_média	250	Zernike_O12_R0	F_I3_12(Horizontal)
40	CIE-L_suavidade	H_média	251	Zernike_O4_R2	Zernike_O18_R12
41	CIE-L_variância	Zernike_O6_R0	252	F_I3_12(Horizontal)	Zernike_O10_R6
42	CIE-b_média	CIE-L_variância	253	Zernike_O9_R9	Zernike_O18_R8
43	I3_média	CIE-L_suavidade	254	Zernike_O20_R6	F_I2_12(Vertical)
44	F_I3_7(Horizontal)	G_entropia	255	Zernike_O20_R4	DGF_R0_A5
45	F_I3_6(Horizontal)	F_I3_6(Vertical)	256	F_I1_12(Horizontal)	DGF_R1_A4
46	F_I3_7(Diagonal)	F_I3_6(Horizontal)	257	Zernike_O9_R5	Zernike_O3_R1
47	F_I3_6(Vertical)	CIE-a_média	258	Zernike_O7_R7	Zernike_O8_R0
48	F_I3_7(Vertical)	I3_média	259	Zernike_O10_R2	Zernike_O18_R14
49	F_I3_6(Diagonal)	B_média	260	Zernike_O16_R6	Zernike_O20_R16
50	F_I1_11(Diagonal)	F_I3_6(Diagonal)	261	DGF_R1_A4	Zernike_O20_R18
51	I3_entropia	F_I3_7(Diagonal)	262	F_I1_13(Horizontal)	Zernike_O16_R12
52	F_I1_11(Horizontal)	B_energia	263	F_I2_12(Vertical)	Zernike_O12_R0
53	F_I1_5(Diagonal)	F_I3_7(Horizontal)	264	F_I3_14(Horizontal)	F_I1_13(Diagonal)
54	F_I1_9(Horizontal)	F_I3_7(Vertical)	265	Zernike_O18_R8	F_I1_3(Horizontal)
55	F_I1_8(Vertical)	V_obliquidade	266	Zernike_O16_R0	DGF_R0_A6

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
56	H_média	CIE-L_energia	267	DGF_R3_A6	Zernike_O14_R10
57	F_I1_9(Vertical)	DGF_R0_A2	268	Zernike_O16_R10	Zernike_O9_R9
58	F_I1_9(Diagonal)	R_entropia	269	Zernike_O13_R7	R_curtose
59	CIE-L_energia	I3_entropia	270	Zernike_O12_R10	Zernike_O9_R5
60	F_I1_8(Horizontal)	F_I1_11(Diagonal)	271	Zernike_O14_R12	Zernike_O20_R14
61	F_I1_5(Horizontal)	V_energia	272	DGF_R0_A4	Zernike_O16_R6
62	B_média	F_I1_11(Horizontal)	273	Zernike_O7_R1	Zernike_O7_R7
63	F_I1_10(Diagonal)	CIE-b_suavidade	274	Zernike_O18_R16	Zernike_O20_R10
64	F_I1_8(Diagonal)	CIE-b_variância	275	Zernike_O20_R0	Zernike_O13_R7
65	CIE-a_média	B_entropia	276	Zernike_O18_R12	F_I3_14(Horizontal)
66	G_entropia	F_I3_8(Vertical)	277	F_I2_12(Horizontal)	Zernike_O17_R15
67	F_I1_10(Horizontal)	F_I3_8(Diagonal)	278	Zernike_O15_R9	Zernike_O16_R0
68	V_obliquidade	F_I3_2(Diagonal)	279	F3	Zernike_O17_R9
69	F_I1_1(Horizontal)	F_I3_8(Horizontal)	280	Zernike_O16_R14	Zernike_O15_R9
70	F_I1_1(Diagonal)	Zernike_O10_R0	281	Zernike_O20_R12	Zernike_O20_R6
71	F_I1_1(Vertical)	I3_energia	282	Zernike_O11_R7	F_I2_3(Diagonal)
72	F_I3_2(Diagonal)	S_energia	283	Zernike_O20_R18	Zernike_O20_R4
73	I3_energia	F_I1_11(Vertical)	284	Zernike_O11_R5	Zernike_O6_R2
74	I1_variância	F_I1_5(Diagonal)	285	Zernike_O18_R10	F_I1_12(Horizontal)
75	I1_suavidade	F_I3_9(Diagonal)	286	F_I2_3(Horizontal)	Zernike_O20_R12
76	F_I3_8(Vertical)	Slenderness	287	Zernike_O17_R9	Zernike_O19_R17
77	F_I3_8(Diagonal)	I2_variância	288	Zernike_O14_R10	Zernike_O18_R10
78	F_I3_8(Horizontal)	I2_suavidade	289	Zernike_O5_R5	Zernike_O19_R11
79	Zernike_O10_R0	F_I3_9(Horizontal)	290	Zernike_O5_R3	Zernike_O10_R2
80	F_I1_11(Vertical)	F_I2_4(Horizontal)	291	Zernike_O19_R11	Zernike_O11_R5
81	B_energia	F_I2_4(Diagonal)	292	Zernike_O16_R2	G_curtose
82	F_I1_5(Vertical)	F_I2_4(Vertical)	293	Zernike_O7_R5	Zernike_O15_R13
83	CIE-L_entropia	F_I1_9(Horizontal)	294	Zernike_O17_R15	Zernike_O20_R0
84	F_I3_9(Horizontal)	F_I3_13(Diagonal)	295	Zernike_O7_R3	Zernike_O16_R8
85	I1_energia	F_I1_9(Vertical)	296	Zernike_O16_R12	Zernike_O5_R5
86	F_I3_9(Diagonal)	F_I2_5(Horizontal)	297	Zernike_O20_R10	Zernike_O11_R7
87	S_obliquidade	F_I1_8(Vertical)	298	Zernike_O1_R1	Zernike_O7_R3
88	CIE-b_variância	F_I1_9(Diagonal)	299	Zernike_O16_R8	Zernike_O15_R7
89	CIE-b_suavidade	F_I1_10(Diagonal)	300	Zernike_O8_R4	Zernike_O5_R3
90	CIE-a_entropia	F_I3_4(Vertical)	301	Zernike_O17_R11	DGF_R2_A6
91	F_I2_5(Horizontal)	F_I3_4(Diagonal)	302	Zernike_O18_R14	Zernike_O13_R11
92	F_I1_10(Vertical)	F_I1_4(Vertical)	303	Zernike_O17_R7	Zernike_O17_R7
93	B_entropia	F_I1_4(Diagonal)	304	Zernike_O19_R17	Zernike_O7_R1
94	F_I3_9(Vertical)	S_entropia	305	F_I3_3(Diagonal)	Zernike_O19_R9
95	F_I3_2(Vertical)	F_I1_4(Horizontal)	306	Zernike_O6_R2	Zernike_O17_R11
96	F_I2_10(Horizontal)	F_I3_9(Vertical)	307	Zernike_O15_R13	Zernike_O7_R5
97	F_I2_11(Diagonal)	F_I1_8(Horizontal)	308	Zernike_O15_R5	Zernike_O16_R2
98	F_I3_11(Diagonal)	F_I1_5(Horizontal)	309	Zernike_O3_R3	Zernike_O1_R1
99	I1_entropia	I1_energia	310	Zernike_O20_R16	F_I2_12(Horizontal)

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
100	DGF_R0_A2	F_I3_4(Horizontal)	311	Zernike_O9_R7	Zernike_O9_R7
101	F_I3_1(Horizontal)	CIE-a_entropia	312	Zernike_O20_R14	F3
102	F_I2_10(Diagonal)	F_I3_2(Vertical)	313	Zernike_O9_R3	F_I1_13(Horizontal)
103	F_I3_1(Vertical)	F_I1_8(Diagonal)	314	Zernike_O15_R7	Zernike_O8_R4
104	F_I3_11(Horizontal)	F_I1_10(Horizontal)	315	Zernike_O19_R9	Zernike_O3_R3
105	F_I2_11(Horizontal)	V_entropia	316	DGF_R0_A5	Zernike_O15_R5
106	F_I3_1(Diagonal)	F_I1_1(Horizontal)	317	Zernike_O13_R11	DGF_R3_A5
107	F_I3_5(Diagonal)	S_obliquidade	318	Zernike_O12_R2	Zernike_O9_R3
108	F_I2_5(Diagonal)	F_I2_11(Horizontal)	319	F_I1_14(Vertical)	Zernike_O13_R5
109	R_entropia	F_I2_11(Diagonal)	320	Zernike_O20_R2	AR_SN
110	F_I3_2(Horizontal)	F_I3_13(Vertical)	321	F_I1_3(Diagonal)	Zernike_O11_R9
111	I2_suavidade	F_I1_1(Vertical)	322	F_I3_3(Horizontal)	Zernike_O20_R2
112	I2_variância	F_I2_10(Horizontal)	323	Zernike_O13_R5	Zernike_O11_R3
113	F_I3_5(Horizontal)	F_I1_1(Diagonal)	324	F_I1_12(Diagonal)	F_I2_3(Horizontal)
114	F_I2_2(Diagonal)	F_I3_5(Diagonal)	325	AR_1	Zernike_O12_R2
115	H_variância	F_I2_2(Diagonal)	326	F5	Zernike_O19_R13
116	H_suavidade	F_I3_5(Horizontal)	327	Zernike_O11_R9	Zernike_O19_R5
117	F_I3_10(Diagonal)	I1_suavidade	328	DGF_R0_A6	F_I3_3(Diagonal)
118	F_I3_11(Vertical)	I1_variância	329	F_I1_14(Horizontal)	Zernike_O19_R7
119	F_I2_2(Vertical)	F_I3_11(Diagonal)	330	Zernike_O8_R2	DGF_R1_A0
120	F_I3_10(Horizontal)	F_I3_2(Horizontal)	331	Zernike_O11_R3	Zernike_O14_R6
121	F_I2_4(Diagonal)	F_I3_1(Vertical)	332	Zernike_O19_R5	F5
122	F_I2_4(Horizontal)	F_I1_5(Vertical)	333	F_I1_14(Diagonal)	F_I1_12(Diagonal)
123	F_I2_4(Vertical)	F_I3_11(Horizontal)	334	AR_SN	AR_1
124	F_I3_10(Vertical)	F_I3_1(Horizontal)	335	Zernike_O15_R3	Zernike_O15_R3
125	F_I3_5(Vertical)	F_I2_5(Diagonal)	336	DGF_R2_A6	Zernike_O13_R9
126	F_I2_2(Horizontal)	F_I2_10(Diagonal)	337	Zernike_O19_R13	Zernike_O15_R11
127	F_I3_4(Diagonal)	F_I3_1(Diagonal)	338	CIE-L_curtose	Zernike_O5_R1
128	F_I3_4(Vertical)	F_I1_10(Vertical)	339	Zernike_O13_R9	F_I3_3(Horizontal)
129	F_I2_1(Horizontal)	F_I3_10(Diagonal)	340	Zernike_O19_R3	Zernike_O8_R2
130	I2_energia	I2_energia	341	Zernike_O14_R6	Zernike_O19_R3
131	CIE-a_energia	F_I3_11(Vertical)	342	Zernike_O15_R11	F_I1_3(Diagonal)
132	F_I2_1(Diagonal)	CIE-L_entropia	343	Zernike_O13_R3	DGF_R2_A3
133	F_I2_8(Horizontal)	A3	344	Zernike_O19_R7	Zernike_O17_R5
134	F_I1_4(Vertical)	F_I2_2(Vertical)	345	DGF_R3_A5	F_I1_14(Vertical)
135	F_I1_4(Diagonal)	CIE-a_energia	346	Zernike_O11_R1	Zernike_O13_R3
136	F_I1_4(Horizontal)	R_obliquidade	347	Zernike_O17_R5	Zernike_O9_R1
137	F_I3_4(Horizontal)	F_I3_10(Horizontal)	348	I1_curtose	Zernike_O19_R15
138	F_I2_9(Diagonal)	F_I2_2(Horizontal)	349	Zernike_O5_R1	Zernike_O11_R1
139	F_I2_1(Vertical)	F_I2_9(Horizontal)	350	Zernike_O9_R1	CIE-L_curtose
140	F_I2_9(Horizontal)	S_suavidade	351	Zernike_O17_R3	Zernike_O20_R8
141	F_I2_8(Vertical)	S_variância	352	A5	Zernike_O17_R13
142	F_I2_8(Diagonal)	F_I2_9(Diagonal)	353	Zernike_O17_R13	F_I1_14(Horizontal)
143	F_I2_9(Vertical)	F_I2_8(Horizontal)	354	F_I1_12(Vertical)	F_I1_14(Diagonal)

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
144	F_I2_10(Vertical)	F_I2_8(Vertical)	355	Zernike_O19_R1	DGF_R2_A0
145	F_I2_11(Vertical)	Eixo maior	356	Zernike_O20_R8	DGF_R3_A0
146	Slenderness	F_I3_10(Vertical)	357	Zernike_O19_R15	I1_curtose
147	I2_entropia	F_I2_8(Diagonal)	358	Zernike_O13_R1	DGF_R2_A1
148	S_variância	CIE-b_energia	359	F7	Zernike_O17_R3
149	S_suavidade	F_I3_5(Vertical)	360	Zernike_O16_R4	A5
150	F_I2_5(Vertical)	H_variância	361	Zernike_O15_R1	DGF_R2_A5
151	V_energia	H_suavidade	362	Zernike_O17_R1	DGF_R2_A2
152	Eixo maior	F_I2_1(Horizontal)	363	DGF_R1_A0	F7
153	A1	F_I2_1(Diagonal)	364	DGF_R2_A5	Zernike_O19_R1
154	B_curtose	A1	365	DGF_R2_A3	DGF_R2_A4
155	H_energia	F_I2_9(Vertical)	366	Zernike_O12_R4	F_I1_12(Vertical)
156	CIE-b_energia	G_obliquidade	367	DGF_R2_A1	Zernike_O13_R1
157	CIE-b_entropia	F_I2_1(Vertical)	368	F4	Zernike_O16_R4
158	F_I3_13(Diagonal)	F_I2_13(Vertical)	369	Zernike_O18_R6	Zernike_O15_R1
159	A3	I1_entropia	370	DGF_R2_A0	Zernike_O17_R1
160	CIE-L_obliquidade	I2_entropia	371	DGF_R2_A4	DGF_R3_A1
161	A2	F2	372	F8	DGF_R1_A1
162	F_I3_13(Vertical)	F_I3_13(Horizontal)	373	DGF_R2_A2	Zernike_O12_R4
163	S_entropia	F_I2_11(Vertical)	374	DGF_R3_A0	Zernike_O18_R6
164	Zernike_O14_R0	F_I2_10(Vertical)	375	DGF_R1_A3	DGF_R1_A3
165	S_curtose	DGF_R0_A0	376	DGF_R1_A1	F4
166	F_I2_13(Vertical)	B_curtose	377	F9	DGF_R1_A2
167	H_entropia	DGF_R0_A1	378	DGF_R1_A2	F8
168	B_variância	F_I2_5(Vertical)	379	DGF_R3_A4	DGF_R3_A2
169	B_suavidade	B_obliquidade	380	F10	DGF_R3_A4
170	DGF_R0_A0	CIE-b_entropia	381	F6	F9
171	V_entropia	A4	382	DGF_R3_A1	F10
172	S_energia	F_I2_13(Diagonal)	383	F11	F6
173	I2_curtose	H_energia	384	F13	F13
174	Eixo menor	I2_curtose	385	F12	F11
175	R_obliquidade	CIE-L_obliquidade	386	DGF_R3_A3	DGF_R3_A3
176	I1_obliquidade	B_suavidade	387	DGF_R3_A2	F12
177	F_I1_13(Vertical)	B_variância	388	F14	F14
178	G_obliquidade	A2	389	F16	F1
179	CIE-b_curtose	H_entropia	390	F15	F38
180	B_obliquidade	S_curtose	391	F1	F16
181	DGF_R0_A1	I1_obliquidade	392	F38	F15
182	F_I2_3(Vertical)	Zernike_O14_R0	393	F17	F17
183	F_I2_13(Diagonal)	CIE-b_curtose	394	F35	F35
184	A4	F_I2_13(Horizontal)	395	F21	F21
185	F_I3_13(Horizontal)	Eixo menor	396	F29	F18
186	V_curtose	F_I2_3(Vertical)	397	F20	F19
187	F2	I2_obliquidade	398	F18	F20

Posição	Ganho de Informação	Chi-quadrado	Posição	Ganho de Informação	Chi-quadrado
188	I2_obliquidade	F_I1_13(Vertical)	399	F19	F29
189	H_curtose	F_I3_12(Diagonal)	400	F37	F37
190	F_I1_3(Vertical)	V_curtose	401	F28	F28
191	F_I2_13(Horizontal)	Zernike_O4_R4	402	F25	F27
192	CIE-b_obliquidade	Zernike_O6_R4	403	F27	F22
193	Zernike_O18_R4	CIE-b_obliquidade	404	F22	F25
194	CIE-a_obliquidade	Zernike_O10_R4	405	F34	F24
195	Zernike_O14_R4	CIE-a_obliquidade	406	F24	F34
196	CIE-a_curtose	H_curtose	407	AR_2	F33
197	F_I3_3(Vertical)	F_I1_3(Vertical)	408	AR_6	F31
198	I3_curtose	Zernike_O8_R8	409	AR_5	F32
199	Zernike_O10_R4	DGF_R0_A3	410	F36	AR_9
200	H_obliquidade	F_I2_14(Diagonal)	411	F32	F30
201	Zernike_O18_R0	Excentricidade	412	AR_7	F26
202	F_I2_14(Diagonal)	Zernike_O10_R10	413	F33	F23
203	DGF_R1_A5	I3_obliquidade	414	F31	AR_7
204	I3_obliquidade	F_I3_3(Vertical)	415	AR_3	AR_8
205	Zernike_O18_R2	Zernike_O18_R4	416	AR_8	AR_6
206	Zernike_O6_R4	Zernike_O12_R12	417	F26	AR_2
207	DGF_R1_A6	F_I3_14(Diagonal)	418	AR_4	AR_3
208	Zernike_O18_R18	Zernike_O14_R4	419	F30	AR_4
209	Zernike_O20_R20	Zernike_O18_R18	420	F23	AR_5
210	Zernike_O4_R4	Zernike_O6_R6	421	AR_9	F36
211	Zernike_O14_R2	Zernike_O16_R16			