

PONTIFÍCIA UNIVERSIDADE CATÓLICA  
DO RIO DE JANEIRO



**Karen Soares Augusto**

**Identificação Automática do Grau de Maturação de Pelotas  
de Minério de Ferro**

**Dissertação de Mestrado**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Engenharia de Materiais e de Processos Químicos e Metalúrgicos da PUC-Rio.

Orientador: Prof. Sidnei Paciornik  
Co-Orientador: Dr. Otávio da Fonseca Martins Gomes

Rio de Janeiro  
Agosto de 2012



**Karen Soares Augusto**

**Identificação Automática do Grau de Maturação de Pelotas  
de Minério de Ferro**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Engenharia de Materiais e de Processos Químicos e Metalúrgicos da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Sidnei Paciornick**

Orientador

Departamento de Engenharia de Materiais – PUC-Rio

**Dr. Otávio da Fonseca Martins Gomes**

Co-Orientador

Centro de Tecnologia Mineral – CETEM

**Dr. Reiner Neumann**

Centro de Tecnologia Mineral – CETEM

**Prof. Guilherme Lúcio Abelha Mota**

Departamento de Informática e Ciência da Computação – UERJ

**Prof. José Eugênio Leal**

Coordenador Setorial de Pós-Graduação do Centro Técnico Científico -  
PUC-Rio

Rio de Janeiro, 9 de agosto de 2012

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

### **Karen Soares Augusto**

Formada em Engenharia Química pela Universidade do Estado do Rio de Janeiro em 2010. As áreas de atual interesse são Ciência dos Materiais, Processamento Químico e Metalúrgico, Microscopia Digital e Processamento e Análise de Imagens.

#### Ficha Catalográfica

Augusto, Karen Soares

Identificação automática do grau de maturação de pelotas de minério de ferro / Karen Soares Augusto ; orientador: Sidnei Paciornik ; co-orientador: Otávio da Fonseca Martins Gomes – 2012.

183 f. : il. (color.) ; 30 cm

Dissertação (mestrado)-Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia de Materiais, 2012.

Inclui bibliografia

1. Engenharia de materiais – Teses. 2. Pelotas de minério de ferro. 3. Caracterização microestrutural. 4. Microscopia digital. 5. Análise de imagens. 6. Reconhecimento de padrões. I. Paciornik, Sidnei. II. Gomes, Otávio da Fonseca Martins. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia de Materiais. IV. Título.

CDD: 620.11

Aos meus pais Luiz e Dalva e à minha irmã Erika  
com todo o meu amor!

## Agradecimentos

A Deus, em primeiro lugar, por me permitir a vida e a São Francisco de Assis por ser a inspiração do meu modo de viver.

Aos meus pais, por terem me incentivado em todas as minhas escolhas, pelas suas incansáveis batalhas para que eu chegasse até onde cheguei. Por agirem com tanta sabedoria para me ensinar as coisas que realmente importam na vida. Por entenderem todos os meus momentos de estresse e ansiedade (e olha que foram muitos!), sempre retribuindo com carinho, ainda que eu não merecesse naquele momento. Tenho muito orgulho deles!

À minha irmã Erika Augusto Camacho, por ser um belo exemplo, no qual posso me espelhar desde que nasci. Sempre inteligente e dedicada, ajudando-me, incentivando as minhas escolhas e compartilhando conhecimentos. Certamente teria sido diferente sem ela por perto.

Ao meu cunhado Márcio Camacho, que esteve presente nas etapas mais recentes e importantes da minha vida. Agradeço pelas vezes em que precisei “ensaiar” minhas apresentações ou de qualquer outra ajuda e ele estivera sempre disponível com tranquilidade para me atender.

À amiga Débora Turon, pela agradável companhia durante todo o Mestrado e que tenho a certeza de que será pela vida inteira. Por transmitir todo o conhecimento e experiência, sempre disposta a ajudar com toda a atenção

necessária, independente da hora, do lugar e do tempo disponível. Pela convivência maravilhosa, da qual guardo boas lições, sejam no âmbito profissional ou pessoal.

Ao orientador Prof. Sidnei Paciornik, pela competente e sempre presente orientação. Por ser, além de orientador, um grande amigo, a quem devo grande parte do que sou hoje. Por trabalhar com tanto amor e ser um excelente profissional, cujos ensinamentos são incontáveis. Com ele aprendi a amar ainda mais a pesquisa. Por isso tudo, pretendo continuar nesta trajetória por muitos anos ainda.

Ao orientador Otávio Gomes, por ser um dos grandes responsáveis para que eu chegasse nesta etapa da minha vida acadêmica/profissional. Além de orientador, é também um grande amigo, que está guiando meus passos há mais de 4 anos. Agradeço por ter me aberto muitas portas, algumas até inesperadas, através da pesquisa. Por toda calma e paciência ao longo deste tempo, por todo ensinamento, pela confiança... São infinitos os motivos para lhe agradecer!

À Vale, pela oportunidade de trabalhar com este tema e por disponibilizar todas as amostras para as análises. Em especial à Maria Beatriz Vieira, que foi quem nos trouxe este desafio e nos permitiu solucioná-lo através da pesquisa. Todo conhecimento e experiência compartilhados foram de extrema relevância para o desenvolvimento do trabalho em questão.

Ao professor Guilherme Mota, pela gentileza em me ajudar, desde algumas etapas deste trabalho até às aulas de Programação na UERJ. As contribuições dadas foram de imenso valor para a finalização deste trabalho.

Aos amigos do LPDI, em especial aos amigos David Pirrot, Luciana Ferreira, Julio Cesar, Luana Andrade e Marcos Henrique, por toda a disponibilidade em me ajudar e por serem excelentes companhias, fazendo com que as horas de trabalho fossem mais divertidas.

Aos meus melhores amigos, que, apesar da distância, sempre estiveram presentes durante esta jornada. Por compreenderem meus momentos de ausência, pela amizade, companheirismo, carinho e tantos outros motivos, que jamais serão finitos.

Ao CNPq e à FAPERJ, pelo apoio financeiro em momentos diversificados, e à PUC-Rio, pela bolsa de isenção de mensalidades do Mestrado. Sem estes auxílios este trabalho não poderia ter sido realizado.

E, por fim, agradeço àqueles que, mesmo não tendo sido citados aqui, contribuíram de alguma forma para que eu continuasse firme e forte nesta caminhada, por vezes “corrida”. Tudo se torna muito mais fácil quando se tem pessoas queridas por perto.

## Resumo

Augusto, Karen Soares; Paciornik, Sidnei; Gomes, Otávio. **Identificação Automática do Grau de Maturação de Pelotas de Minério de Ferro**. Rio de Janeiro, 2012. 183p. Dissertação de Mestrado - Departamento de Engenharia de Materiais, Pontifícia Universidade Católica do Rio de Janeiro.

O presente trabalho visa o desenvolvimento de um sistema automático de identificação do *Grau de Maturação* de pelotas de minério de ferro, envolvendo técnicas de microscopia digital e processamento e análise digital de imagens. As pelotas de minério de ferro, juntamente com o sinter e o minério granulado, constituem uma das matérias-primas básicas no processo de produção do ferro primário. Numa das etapas de sua produção, as pelotas adquirem diferentes características microestruturais, os chamados *Graus de Maturação*, que influenciam diretamente seu comportamento nos processos de redução. Sendo assim, a caracterização microestrutural constitui-se em uma importante etapa de controle de qualidade do material. A evolução da microestrutura de pelotas específicas para altos-fornos foi dividida em quatro classes: A, B, C e D. A partir das micrografias obtidas por microscópio ótico, foram extraídos atributos capazes de descrever características intrínsecas de cada classe (ou *Grau de Maturação*), posteriormente utilizados para treinar um classificador automático. Para tentativas de otimização do processo, foram utilizadas 3 técnicas para redução de dimensionalidade (Busca exaustiva do conjunto com a melhor taxa de acerto, Análise de Componentes Principais e Análise Discriminante Linear de Fisher), e testados 3 tipos de classificadores (*Quadrático, Mahalanobis e Linear*). A maior taxa de acerto global obtida foi acima de 90%. Este resultado indica que a metodologia desenvolvida mostrou-se efetiva para a classificação automática do *Grau de Maturação* de pelotas de minério de ferro de alto-forno.

## Palavras-chave

Pelotas de Minério de Ferro; Caracterização Microestrutural; Microscopia Digital; Análise de Imagens; Reconhecimento de Padrões.

## Abstract

Augusto, Karen Soares; Paciornik, Sidney; Gomes, Otávio. **Automatic Identification of the Maturation Degree in Iron Ore Pellets**. Rio de Janeiro, 2012. 183p. MSc. Dissertation - Departamento de Engenharia de Materiais, Pontifícia Universidade Católica do Rio de Janeiro.

The present work aims to develop an automatic system to identify the maturation degree of iron ore pellets, involving techniques of microscopy and digital image processing. Iron ore pellets, as well as *sinter* and *lump ore*, are the basic iron-bearing burden used in ironmaking. In one of the steps of their production, the pellets acquire different microstructural characteristics, the so-called *Maturation Degree*, which influences directly in the reduction processes. Thus, microstructural characterization is an important step in quality control of the material. The microstructure evolution of pellets for blast furnaces was divided into four classes: A, B, C and D. Attributes that describe intrinsic characteristics of each class were extracted from optical microscope images and were used to train an automatic classifier. Three dimensionality reduction techniques were tested to optimize the classification system: exhaustive search, Principal Component Analysis and Fisher's Linear Discriminant Analysis. Three types of classifiers were tested (*Quadrático*, *Mahalanobis* and *Linear*). The highest global success rate was above 90%. This indicates that this methodology is effective for automatic classification of the *Maturation Degree* in blast furnace pellets.

## Keywords

Iron Ore Pellets; Microstructure Characterization; Digital Microscopy; Images Analysis; Pattern Recognition.

# Sumário

1	Introdução	22
2	Minério de Ferro	25
3	Pelotas de Minério de Ferro	29
3.1.	Processo de Pelotização	31
3.1.1.	Preparação das Matérias-Primas	32
3.1.2.	Formação das Pelotas Cruas	33
3.1.3.	Endurecimento das Pelotas Cruas	36
3.2.	Grau de Maturação	40
4	Microscopia	47
4.1.	Microscopia Ótica de Luz Refletida em Campo Claro	47
4.2.	Microscopia Digital	48
4.2.1.	Autofoco	49
4.2.2.	Aquisição Automática de Imagens	50
5	Processamento e Análise Digital de Imagens	52
5.1.	Aquisição da Imagem	54
5.2.	Pré-Processamento	58
5.3.	Segmentação	61
5.4.	Pós-Processamento	63
5.5.	Extração de Atributos	69
5.5.1.	Medidas de Campo	70
5.5.2.	Medidas de Tamanho	72
5.5.3.	Medidas de Textura	75
5.5.4.	Medidas de Forma	80
5.6.	Reconhecimento de Padrões e Classificação	83
5.6.1.	Classificação Supervisionada	84

6	Materiais e Métodos	93
6.1.	Materiais e Preparação de Amostras	93
6.2.	Procedimentos Experimentais	93
6.2.1.	Microscopia Ótica	93
6.2.2.	Processamento de Imagens	97
6.2.3.	Escolha dos Atributos	110
6.2.4.	Classificação	113
7	Resultados e Discussão	114
7.1.	Seleção de Atributos	
	(Busca exaustiva do conjunto com a melhor taxa de acerto)	116
7.2.	Análise de Componentes Principais (PCA)	121
7.3.	Análise Discriminante Linear de Fisher (LDA)	128
7.4.	Comparação entre Técnicas	136
8	Conclusões e Trabalhos Futuros	143
9	Referências Bibliográficas	145
10	Anexo	149

## **Lista de siglas e abreviaturas**

ADI: Análise Digital de Imagens

BF: Branching Factor

Conv: Convexidade

CPC: Contagem de partículas conectadas

CPD: Contagem de partículas desconectadas

DCE: Diâmetro circular equivalente

FFC: Fator de forma circular

LDA: Análise Discriminante Linear de Fisher

MDE: Mapa de Distâncias Euclidianas

MR: Modification Ratio

PADI: Processamento e Análise Digital de Imagens

PCA: Análise de Componentes Principais

PDI: Processamento Digital de Imagens

RA: Razão de Aspectos

## Lista de figuras

Figura 1 – Etapas do processo de beneficiamento do minério de ferro	26
Figura 2 – Minério granulado	27
Figura 3 – (a) Sínter; (b) Pelota	28
Figura 4 – Fluxograma do processo de produção do aço a partir de tecnologias tradicionais	28
Figura 5 – Fluxograma do Processo de Pelotização	31
Figura 6 – Mecanismo de formação da pelota	34
Figura 7 – Crescimento das pelotas: (a) arredondada; e (b) irregular	35
Figura 8 – Princípio de funcionamento do disco de pelotização: (a) Vista lateral do disco de pelotamento e a formação de diferentes camadas. (b) Vista frontal do disco de pelotamento e a movimentação das pelotas cruas em várias etapas de crescimento.	35
Figura 9 – Princípio de funcionamento dos tambores rotativos	36
Figura 10 – Tipos e capacidade de fornos utilizados para a pelotização em alguns países	39
Figura 11 – Forno de Grelha Móvel	39
Figura 12 – Perfil térmico de um forno tipo Grelha Móvel	40
Figura 13 – Desenho esquemático do fenômeno de sinterização	40
Figura 14 – (a) Micrografia de uma pelota crua; (b) Micrografia de uma pelota queimada (sinterizada)	42
Figura 15 – Imagem típica de uma pelota com grau de maturação A.	43
Figura 16 – Imagem típica de uma pelota com grau de maturação B.	44
Figura 17 – Imagem típica de uma pelota com grau de maturação C.	45
Figura 18 – Imagem típica de uma pelota com grau de maturação D.	46
Figura 19 – Teoria do Microscópio Ótico de Luz Refletida	48
Figura 20 – Imagens antes (a) e após (b) o procedimento de autofoco	49

Figura 21 – LMD Captura: (a) Amostra;	
(b) Dados de entrada da rotina de aquisição automática: 2 coordenadas x-y;	
(c) Área delimitada e calculada pela rotina;	
(d) Aquisição de imagens igualmente espaçadas entre si dentro da região delimitada;	
(e) Número máximo de imagens adquiridas na região de interesse, numeradas na figura conforme a ordem de aquisição.	51
Figura 22 – Sequência padrão de PADI	53
Figura 23 – Histogramas correspondentes a quatro tipos básicos de imagens:	
(a) Imagem escura (histograma deslocado para a esquerda);	
(b) imagem clara (histograma deslocado para a direita);	
(c) imagem de baixo contraste (histograma estreito); e	
(d) imagem de brilho e contraste ideais (histograma bem espalhado).	57
Figura 24 – Função de <i>delineamento</i> (transformação de níveis de cinza para o realce de bordas)	60
Figura 25 – Delineamento:	
(a) Imagem original, seu histograma e região ampliada para melhor visualização; e	
(b) imagem delineada, seu histograma e a mesma região ampliada.	60
Figura 26 – Histograma de níveis de cinza que podem ser particionados por (a) um limiar único e (b) limiares múltiplos	62
Figura 27 – Limiarização bimodal na imagem de pelota de minério de ferro:	
(a) imagem original em 256 tons de cinza;	
(b) imagem binária; (c) tons de corte.	62
Figura 28 – Operações Lógicas	64

Figura 29 – Exemplo de pós-processamento:	
(a) Imagem original;	
(b) imagem binária da segmentação da fase clara;	
(c) imagem resultante da aplicação de um NOT.	65
Figura 30 – Método dos divisores de águas ( <i>watersheds</i> ):	
(a) imagem binária inicial; e	
(b) imagem binária com objetos separados.	67
Figura 31 – Eliminação de objetos por área: (a) Imagem segmentada;	
(b) imagem sem objetos menores do que 1000 pixels.	68
Figura 32 – Conectividade entre os pixels:	
(a) Imagem original, onde o pixel circulado é o pixel analisado;	
(b) Conectividade 4, considerando que são dois objetos separados;	
(c) Conectividade 8, considerando que os pixels fazem parte de um mesmo objeto.	71
Figura 33 – Cálculo da Fração de Área de uma imagem binária	71
Figura 34 – Medidas de Área:	
(a) área simples (toda a região em preto);	
(b) área preenchida (toda a região em preto e em cinza);	
(c) área convexa (toda a região em preto e em cinza)	72
Figura 35 – Medidas de Perímetro: (a) perímetro simples;	
(b) perímetro preenchido; (c) perímetro convexo	73
Figura 36 – (a) Interseções; (b) Interceptos	74
Figura 37 – Vetor $d$	77
Figura 38 – Calibres ( <i>Ferets</i> )	80
Figura 39 – Diâmetro do maior círculo circunscrito no objeto ( $W$ )	82
Figura 40 – Classificação supervisionada	84
Figura 41 – Classificação não-supervisionada	84
Figura 42 – Correlação entre dois atributos	86
Figura 43 – Atributos para a descrição dos objetos em uma imagem	87
Figura 44 – Interpretação geométrica do LDA:	
Caso unidimensional com duas classes.	89

Figura 45 – Diferença entre PCA e LDA	90
Figura 46 – Parâmetros de entrada para a aquisição automática de imagens pelo método <i>LMD Captura</i>	95
Figura 47 – Imagem típica da pelota em um aumento de 20X adquirida em campo claro	96
Figura 48 – Imagem típica da pelota em um aumento de 20X adquirida em polarização	96
Figura 49 – (a) Imagem original; (b) Quadrantes da imagem original	97
Figura 50 – Histograma de intensidades da Figura 47	98
Figura 51 – Fluxograma da rotina de extração dos atributos do grupo I	102
Figura 52 – (a) Imagem original; (b) imagem após aplicação do <i>Delineate</i> ; (c) imagem segmentada; (d) histograma; (e) imagem resultante da aplicação do <i>Scrap</i> , com objetos menores do que 100 pixels eliminados.	103
Figura 53 – Fluxograma da rotina de extração dos atributos do grupo II	104
Figura 54 – Imagem resultante da aplicação do <i>NOT</i>	105
Figura 55 – (a) Imagem anterior à aplicação do <i>Watersheds</i> ; (b) imagem resultante da aplicação do <i>Watersheds</i>	106
Figura 56 – Fluxograma da rotina de extração dos atributos do grupo III	107
Figura 57 – Fluxograma da rotina de extração dos atributos do grupo IV	107
Figura 58 – Imagem de poros pequenos	108
Figura 59 – Fluxograma da rotina de extração dos atributos do grupo V	108
Figura 60 – Fluxograma da rotina de extração dos atributos do grupo VI	109
Figura 61 – Imagem resultante da aplicação do <i>AND</i> (Imagem final para extração dos atributos)	110

Figura 62 – Classificação dos grupos de parâmetros obtidos pela seleção de atributos	116
Figura 63 – Atributos selecionados para cada conjunto com a melhor taxa de acerto	117
Figura 64 – Autovalidação e validação cruzada com o classificador <i>Quadratic</i>	118
Figura 65 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Quadratic</i>	119
Figura 66 – Classificação do PCA com até 26 componentes	121
Figura 67 – Autovalidação e validação cruzada com o classificador <i>Quadratic</i>	122
Figura 68 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Quadratic</i>	123
Figura 69 – Classificação do PCA com até 45 componentes	125
Figura 70 – Autovalidação e validação cruzada com o classificador <i>Linear</i>	126
Figura 71 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Linear</i>	127
Figura 72 – Resultado da aplicação do LDA nos 26 atributos	129
Figura 73 – Autovalidação e validação cruzada com o classificador <i>Linear</i>	130
Figura 74 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Linear</i>	131
Figura 75 – Classificação da aplicação do LDA nos 45 atributos	133
Figura 76 – Autovalidação e validação cruzada com o classificador <i>Linear</i>	134
Figura 77 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Linear</i>	135
Figura 78 – Comparação entre técnicas com o classificador <i>Quadratic</i>	137
Figura 79 – Comparação entre técnicas de PCA e LDA com o classificador <i>Linear</i>	139
Figura 80 – Exemplo de imagens de Graus de Maturação diferentes: (a) Classe B; (b) Classe C.	140

Figura 81 – Exemplo de imagens de Graus de Maturação diferentes: (a) Classe A; (b) Classe D.	141
Figura 82 – Autovalidação e validação cruzada com o classificador <i>Mahalanobis</i>	149
Figura 83 – Atributos selecionados para cada conjunto com a melhor taxa de acerto	150
Figura 84 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Mahalanobis</i>	150
Figura 85 – Autovalidação e validação cruzada com o classificador <i>Linear</i>	151
Figura 86 – Atributos selecionados para cada conjunto com a melhor taxa de acerto	151
Figura 87 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Linear</i>	152
Figura 88 – Autovalidação e validação cruzada com o classificador <i>Quadratic</i>	152
Figura 89 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Quadratic</i>	153
Figura 90 – Autovalidação e validação cruzada com o classificador <i>Linear</i>	153
Figura 91 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Linear</i>	154
Figura 92 – Autovalidação e validação cruzada com o classificador <i>Mahalanobis</i>	154
Figura 93 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Mahalanobis</i>	155
Figura 94 – Autovalidação e validação cruzada com o classificador <i>Mahalanobis</i>	155
Figura 95 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Mahalanobis</i>	156
Figura 96 – Autovalidação e validação cruzada com o classificador <i>Quadratic</i> (26 parâmetros)	156

Figura 97 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Quadratic</i> (26 parâmetros)	157
Figura 98 – Autovalidação e validação cruzada com o classificador <i>Quadratic</i> (45 parâmetros)	157
Figura 99 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Quadratic</i> (45 parâmetros)	158
Figura 100 – Autovalidação e validação cruzada com o classificador <i>Mahalanobis</i> (26 parâmetros)	158
Figura 101 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Mahalanobis</i> (26 parâmetros)	159
Figura 102 – Autovalidação e validação cruzada com o classificador <i>Mahalanobis</i> (45 parâmetros)	159
Figura 103 – Taxa de acerto de cada classe na validação cruzada com o classificador <i>Mahalanobis</i> (45 parâmetros)	160

## Lista de tabelas

Tabela 1 – Composição química de pelotas da Vale	30
Tabela 2 – Parâmetros de Haralick	79
Tabela 3 – Taxas de acerto de cada classe utilizando-se medidas de textura (Haralick 1-11 + Média de tons de cinza + Desvio padrão dos tons de cinza)	114
Tabela 4 – Taxas de acerto de cada classe na melhor validação cruzada (8 atributos / classificador <i>Quadrático</i> )	119
Tabela 5 – Resultados das classificações das melhores taxas de acerto global obtidas com a técnica de validação cruzada e com a correspondente técnica de autovalidação de todos os classificadores	120
Tabela 6 – Matriz de confusão do melhor resultado obtido na autovalidação (23 atributos / classificador <i>Quadrático</i> )	120
Tabela 7 – Taxas de acerto de cada classe na melhor validação cruzada (15 componentes / classificador <i>Quadrático</i> )	123
Tabela 8 – Resultados das classificações das melhores taxas de acerto global obtidas com a técnica de validação cruzada e com a correspondente técnica de autovalidação de todos os classificadores	124
Tabela 9 – Matriz de confusão do melhor resultado obtido na autovalidação (25 componentes / classificador <i>Quadrático</i> )	124
Tabela 10 – Taxas de acerto de cada classe na melhor validação cruzada (40 componentes / classificador <i>Linear</i> )	127
Tabela 11 – Resultados das classificações das melhores taxas de acerto global obtidas com a técnica de validação cruzada e com a correspondente técnica de autovalidação de todos os classificadores	128
Tabela 12 – Matriz de confusão do melhor resultado obtido na autovalidação (45 componentes / classificador <i>Linear</i> )	128

Tabela 13 – Taxas de acerto de cada classe na melhor validação cruzada (26 atributos reduzidos a 3 componentes / classificador <i>Linear</i> )	131
Tabela 14 – Resultados das classificações das melhores taxas de acerto global obtidas com a técnica de validação cruzada e com a correspondente técnica de autovalidação de todos os classificadores	132
Tabela 15 – Matriz de confusão do melhor resultado obtido na autovalidação (26 atributos reduzidos a 3 componentes / classificador <i>Quadrático</i> )	132
Tabela 16 – Taxas de acerto de cada classe na melhor validação cruzada (45 atributos reduzidos a 3 componentes / classificador <i>Linear</i> )	135
Tabela 17 – Resultados das classificações das melhores taxas de acerto global obtidas com a técnica de validação cruzada e com a correspondente técnica de autovalidação de todos os classificadores	136
Tabela 18 – Matriz de confusão do melhor resultado obtido na autovalidação (45 atributos reduzidos a 3 componentes / classificador <i>Linear</i> )	136
Tabela 19 – Taxas de acerto de cada classe nas melhores validações cruzadas de cada técnica aplicada nos 26 atributos	138
Tabela 20 – Taxas de acerto de cada classe nas melhores validações cruzadas de cada técnica aplicada nos 45 atributos	139