

**UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO**

**CARACTERIZAÇÃO DE MINERIO DE FERRO POR  
VISÃO COMPUTACIONAL**

**DISSERTAÇÃO DE MESTRADO**

**MARCIO ANDRÉ DELL'AGLIO FRICK**

**Santa Maria, RS, Brasil**

**2008**

# **CARACTERIZAÇÃO DE MINÉRIO DE FERRO POR VISÃO COMPUTACIONAL**

por

**Marcio André Dell'Aglio Frick**

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação em Engenharia de Produção, Área de Concentração em Tecnologia da Informação, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Engenharia de Produção.**

**Orientador: Dr. José Antônio Trindade Borges da Costa**

**Santa Maria, RS, Brasil**

**2008**

**Universidade Federal de Santa Maria  
Centro de Tecnologia  
Programa de Pós-Graduação em Engenharia de Produção**

A Comissão Examinadora, abaixo assinada,  
aprova a Dissertação de Mestrado

**CARACTERIZAÇÃO DE MINÉRIO DE FERRO  
POR VISÃO COMPUTACIONAL**

elaborada por  
**Marcio André Dell'Aglio Frick**

como requisito parcial para obtenção do grau de  
**Mestre em Engenharia de Produção**

**COMISSÃO EXAMINADORA:**

**José Antônio Trindade Borges da Costa, Dr.**  
(Presidente/Orientador)

**Lucy Takehara, Dra** (UFRGS)

**José Luiz Silvério da Silva, Dr.** (UFSM)

Santa Maria, 12 de Setembro de 2008

*Dedico à mãe de minha filha,  
**Ângela Fernandes Gomes** (in memoriam).  
Eterna. Mãe zelosa e protetora, que seja sempre iluminada.  
5 de julho de 1980 -23 de junho de 2008*

## **AGRADECIMENTOS**

Agradeço, em primeiro lugar a toda minha família por tudo que me proporcionou, para que eu alcançasse mais esse objetivo, que cada um saiba o quanto foram importantes em cada momento dessa trajetória e em cada tempestade que atravessei durante este duro e longo caminho. Aos colegas Angélica, Edson, Elaine, Eliana, Glaucia, Jolvani, Paulo, grandes companheiros com os quais compartilhei medos, angústias e preocupações nos almoços de quinta no CT, e de onde surgiram grandes amizades que levarei para o resto de minha vida. Um agradecimento especial à colega Marlise Rosa, pois convivemos por maior tempo e nos amparamos em momentos difíceis e cansativos, nas madrugadas de estudo. Aos colegas da minha graduação, Adriane, Gerson e Luciana, que me apresentaram o PPGEP, sem cuja influência não teria vindo cursar este mestrado. Ao Prof. Marcos Cordeiro d'Ornellas, aos colegas do LaCA, aos demais professores e funcionários do PPGEP e, a todos que direta ou indiretamente contribuíram com este trabalho. E em especial, a esta pessoa extraordinária que tive o prazer de conviver nestes dois anos, sempre me incentivando, cobrando ou não cobrando no momento certo, ouvindo meus problemas e sempre ajudando com palavras sábias, as quais, sempre eram muita inspiradoras na medida e no momento certos, meu orientador, José Antônio Trindade Borges da Costa, meu amigo Juca, que foi muito mais que orientador e sim um amigo como poucos que existem hoje em dia, sem o qual eu não teria conseguido concluir este trabalho, meu muito obrigado e eterna gratidão.

## **RESUMO**

Dissertação de Mestrado  
Programa de Pós-Graduação em Engenharia de Produção  
Universidade Federal de Santa Maria

### **CARACTERIZAÇÃO DE MINÉRIO DE FERRO POR VISÃO COMPUTACIONAL**

AUTOR: MÁRCIO ANDRÉ DELL'AGLIO FRICK

ORIENTADOR: DR. JOSÉ ANTÔNIO TRINDADE BORGES DA COSTA

Data e Local de Defesa: Santa Maria, 12 de Setembro de 2008.

A classificação de minérios é útil para o entendimento e controle processos de beneficiamento industrial. O presente trabalho contribui para o desenvolvimento de um sistema de visão computacional para realizar a classificação automática de minério de ferro por análise de imagens de micrografia ótica. Com este propósito, algoritmos de extração de características morfológicas foram implementados e algoritmos de classificação com base em características foram desenvolvidos. Estes métodos foram aplicados com sucesso à classificação de grãos de hematita em quatro classes determinadas pela sua forma (lamelar ou granular) e porosidade (porosa e compacta) utilizando apenas quatro características, a saber, circularidade, razão de aspecto, razão de fibra e porosidade.

Palavras-chave: visão computacional; reconhecimento de padrões, minério de ferro; classificação de minérios.

## **ABSTRACT**

Master Dissertation  
Production Engineering Graduate Program  
Federal University of Santa Maria

### **IRON ORE CHARACTERIZATION BY COMPUTER VISION**

AUTHOR: MÁRCIO ANDRÉ DELL'AGLIO FRICK

ADVISOR: DR. JOSÉ ANTÔNIO TRINDADE BORGES DA COSTA

Date and place of the dissertation seminar: Santa Maria, September, 12 of 2008.

Ore classification is useful for understanding and controlling industrial beneficiation processes. The present work contributes to the development of a computer vision system for automated classification of iron ores by image analysis of optical micrographs. For this purpose, morphological feature extraction algorithms were implemented and feature based classification algorithms were developed. These methods were successfully applied to the classification of hematite grains into four classes determined by their shape (lamellar or granular) and porosity (porous and compact) as characterized by just four features, namely, circularity, aspect ratio, fiber ratio and porosity.

Key words: computer vision; pattern recognition, iron ore; ore classification.

## LISTA DE ILUSTRAÇÕES

FIGURA 2.1 – Processo de transformação de minérios de ferro em aço .....	16
FIGURA 2.2 – Orientações e fatores angulares .....	24
FIGURA 2.3 - Textura geométrica e coeficientes de textura.....	25
FIGURA 3.1 – Diagrama dos níveis de processos de visão .....	32
FIRURA 3.2 – Tipos de abordagens em reconhecimento estatístico de padrões .....	37
FIGURA 4.1 – Rotulagem de componentes conectados .....	41
FIGURA 4.2 – Estrutura de dados do algoritmo “union-find” para dois conjuntos de rótulos.....	42
FIGURA 4.3 – Estrutura “union-find” mostrando as equivalências.....	43
FIGURA 4.4 – (A) Imagem colorida. (B) Matriz de rótulos da imagem colorida.....	44
FIGURA 4.5 – Matriz de rótulos da borda dos objetos.....	45
FIGURA 4.6 – Retas dos ferrets .....	45
FIGURA 4.7 – Pontos para cálculo dos ferrets. ....	46
FIGURA 4.8 – Objeto com comprimento e largura de fibra iguais. ....	47
FIGURA 4.9 – Espaço de característica. ....	48
FIGURA 5.1 – Fotomicrografia de minério de ferro.....	50
FIGURA 5.2 – Fotomicrografia com luz polarizada.....	51
FIGURA 5.3 –Figura 5.2 segmentada manualmente .....	52
FIGURA 5.4 – Grãos recortados da Figura 5.2I.....	52
FIGURA 5.5 – Grãos compactos .....	54
FIGURA 5.6 – Classificação dos grãos compactos em. Granular e lamelar .....	54
FIGURA 5.7 – Identificação dos grãos lamelares porosos .....	55
FIGURA 5.8 – Identificação de grãos granulares porosos.....	56
FIGURA 5.9 – Todos os grãos classificados.....	56



FIGURA 5.10 – Fluxograma demonstrando os limites de decisão.....	57
FIGURA 5.11 – Detalhe da Figura 5.3.....	58
FIGURA 5.12 – Classificação dos grãos da fotomicrografia da Figura 5.2.....	58

## LISTA DE EQUAÇÕES

EQUAÇÃO 2.1 .....	24
EQUAÇÃO 4.1 .....	46
EQUAÇÃO 4.2 .....	46
EQUAÇÃO 4.3 .....	46
EQUAÇÃO 4.4 .....	47
EQUAÇÃO 4.5 .....	47
EQUAÇÃO A.1 .....	61
EQUAÇÃO A.2 .....	61
EQUAÇÃO A.3 .....	61
EQUAÇÃO A.4 .....	61
EQUAÇÃO A.5 .....	61
EQUAÇÃO A.6 .....	61
EQUAÇÃO A.7 .....	61
EQUAÇÃO A.8 .....	62
EQUAÇÃO A.9 .....	62
EQUAÇÃO A.10 .....	62
EQUAÇÃO A.11 .....	62
EQUAÇÃO A.12 .....	62

## LISTA DE TABELAS

TABELA 2.1 – Panorama Mineral Brasileiro .....	14
TABELA 2.2 – Reservas de minério no Brasil em bilhões de toneladas.....	15
TABELA 2.3 – Principais minerais de ferro e suas classes .....	18
TABELA 2.4 – Texturas comuns de hematita .....	21
TABELA 2.5 – Tipos de texturas de óxido e hidróxido de ferro .....	26
TABELA 2.6 – Tipos morfológicos dos cristais de óxidos de Fe .....	26
TABELA 2.7 – Comparação entra amostras com desempenho excelente e amostras que apresentaram desempenho ruim na sinterização da USIMINAS,.....	27
TABELA 3.1 – Modelos de reconhecimento de padrões .....	36
TABELA 4.1 – Descritores visuais e características morfológicas usadas na classificação dos cristais de hematita. ....	41
TABELA 5.1 – Características extraídas da imagem .....	53

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>12</b>
<b>2 MINÉRIO DE FERRO .....</b>	<b>14</b>
2.1 Importância econômica .....	14
2.2 Processo siderúrgico .....	15
2.3 Caracterização do minério de ferro .....	17
2.3.1 Caracterização microestrutural .....	18
2.3.1.1 Caracterização mineralógica .....	19
2.3.1.2 Caracterização textural .....	22
2.4 Caracterização do minério brasileiro.....	25
<b>3 VISÃO COMPUTACIONAL .....</b>	<b>28</b>
3.1 Campos relacionados .....	30
3.2 Níveis de visão .....	31
3.3 Processamento de imagens .....	33
3.4 Reconhecimento de padrões .....	34
<b>4 MATERIAS E MÉTODOS .....</b>	<b>39</b>
4.1 Método proposto.....	39
4.2 Algoritmo de rotulagem.....	41
4.3 Características geométricas .....	44
4.3.1 Área e área total.....	44
4.3.2 Perímetro .....	44
4.3.3 Ferret máximo e ferret mínimo .....	45
4.4 Cálculo do comprimento e largura de fibra .....	47
4.5 Combinações de características.....	48
<b>5 RESULTADOS ALCANÇADOS .....</b>	<b>50</b>
<b>6 CONCLUSÕES .....</b>	<b>59</b>
<b>7 BIBLIOGRAFIA .....</b>	<b>60</b>
<b>APÊNDICE A – CARACTERÍSTICAS MORFOLÓGICAS.....</b>	<b>65</b>

# 1 INTRODUÇÃO

Sistemas de visão computacional são usualmente aplicáveis na automação industrial, sendo que, tais sistemas são altamente dependentes do domínio de aplicação, pois, para projetar um sistema de visão, questões sobre a imagem e as informações que se pretende obter dela, devem ser levadas em consideração. Por esse motivo a visão computacional tem sido aplicada em diversas áreas, para reconhecimento e análise de imagem. Métodos de processamento e análise de imagens digitais são hoje rotineiramente aplicados como ferramentas auxiliares em microscopia quantitativa.

Nos processos de beneficiamento industrial de minério de ferros, a qualidade e quantidade do sinter feed são fatores que dependem do desenvolvimento do tratamento dos minérios (VIEIRA et al., 2000; COSTA et al., 1998), para prever estes fatores, deve-se conhecer o comportamento de cada tipo de minério.

No entanto, não existe um método universal para a avaliação automatizada das fases minerais ou para a caracterização da microestrutura de minérios (FORTEY, 1995). De fato, este é um problema complexo, uma vez que são diversos os atributos que caracterizam forma, textura, trama ou porosidade, assim como as maneiras como são combinados em cada caso.

A classificação automatizada de minérios baseada na análise de imagens digitais é, portanto, uma tarefa de reconhecimento de padrões que envolve a escolha das características a serem medidas e o estabelecimento de critérios de classificação baseados nos valores destas grandezas. Estas características ou atributos mensuráveis devem ser a tradução matemática (topológica, geométrica ou morfológica) dos descritores visuais usados pelos petrógrafos para classificar os minérios. Já os critérios de classificação devem levar em conta a conjunção de diferentes características.

O objetivo do presente trabalho é contribuir para o desenvolvimento de técnicas de visão computacional que auxiliem na classificação automatizada de

minérios de ferro apresentando uma técnica de reconhecimento de padrões para a identificação de partículas hematíticas.

Este trabalho está organizado em seis capítulos. No Capítulo 2 trata do objeto de estudo do presente trabalho, o minério de ferro, onde informações como importância econômica, o processo industrial e a caracterização do minério são encontradas, assim como o estado da arte dos métodos para análise. No Capítulo 3 conceitos de visão computacional, procedimentos de análise de imagem e reconhecimento de padrões são apresentados, onde auxiliam na compreensão do método proposto no presente trabalho. No Capítulo 4 o método de análise proposto é apresentado, em seguida, os materiais e métodos necessários para a execução do método proposto são descritos. No capítulo 5 são discutidos e apresentados os resultados encontrados. E finalmente no capítulo 6 as conclusões são apresentadas indicando os possíveis trabalhos a serem desenvolvidos após a apresentação do método proposto por este trabalho.

## 2 MINÉRIO DE FERRO

### 2.1 Importância econômica

O ferro é um dos elementos mais abundantes da crosta terrestre e matéria-prima fundamental para a indústria. Uma vez que o ferro e o aço estão presentes em uma grande variedade de produtos, o consumo de minério de ferro ainda é um dos índices considerados na medida de industrialização de um país (GROSS, 1993; apud TAKEHARA, 2004).

O Brasil é o um dos maiores produtores de minério de ferro do mundo. Em 2006, o país produziu 317 milhões de toneladas, o que corresponde a 18,52% da produção mundial (ver Tabela 2.1).

Ano	2000	2001	2002	2003	2004	2005	2006
Produção Mundial	1.060	1.060	1.080	1.060	1.340	1.540	1.712
Produção Brasil	212	237	214	264	262	278	317
% Brasil	20	22	19,8	22,7	19,5	18	18,5
Colocação Mundial	2°	2°	2°	2°	2°	2°	2°

**Tabela 2.1 - Panorama Mineral Brasileiro (em milhões e toneladas métricas). Fonte: IBRAM 2008.**

As reservas brasileiras de minério de ferro destacam-se não apenas pelo seu volume (ver Tabela 2.3), mas também pelos teores médios, que são superiores a 62% de ferro, contra os 51,6 % verificados pela média mundial. As reservas medidas e indicadas de minério de ferro no Brasil ultrapassam 26 bilhões de toneladas, situando o país em quinto lugar em relação às reservas mundiais, de 370 bilhões de toneladas. Além disso, as jazidas brasileiras são de fácil extração, pois não é necessário escavação as mesmas se encontram a céu aberto, o que possibilita a produção de grandes volumes a custos baixos (TAKEHARA, 2004).

A região conhecida como Quadrilátero Ferrífero, localizado na região sudeste do Brasil, no estado de Minas Gerais, juntamente com a Serra dos Carajás, localizada na região norte do Brasil, no estado do Pará, formam as duas principais províncias minerais do país, ambas apresentam depósitos de ferro de notável importância econômica para o país (CPRM, 2007)

Ano	2000	2001	2002	2003	2004	2005
Reserva medida	11,2	15,1	17,8	15,6	15,5	15,8
Reserva indicada	9,8	9,7	10,3	11,3	10,9	10,7

**Tabela 2.2 - Reservas de minério no Brasil em bilhões de toneladas. Fonte: IBRAM 2008**

A maior empresa produtora de minério de ferro no Brasil é a Vale, responsável por 66% da produção nacional. Esta empresa foi criada em 1942 pelo governo brasileiro como Companhia Vale do Rio Doce (CVRD) e privatizada em 1997, atuando hoje nos 5 continentes.

## 2.2 Processo siderúrgico

O processo de transformação do minério de ferro em aço é esquematizado na Figura 2.1. O tipo de minério disponível determina todo o seu processamento até ser usado como matéria-prima do processo siderúrgico, que se inicia com a redução.

Ainda na mineração, o minério bruto é fracionado para ser aproveitado de acordo com as suas características. Cada fração é identificada conforme o seu destino.

O minério granulado apresenta uma granulometria entre 12,5mm a 200 mm e subdivide-se em cinco grupos, os quais passam por processos de peneiramento. Por ser uma fração grossa, vai direto ao alto-forno.

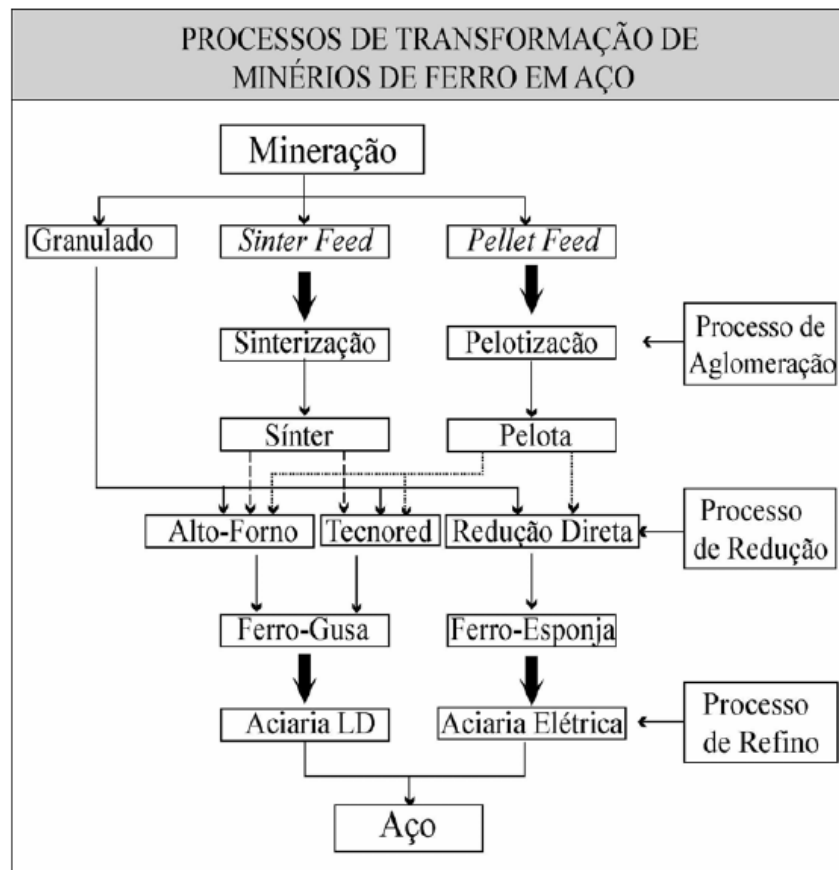
Já as partículas de minério menores do que 12,5mm, ou *finos*, não são adequadas para serem usadas diretamente como carga em fornos de redução, pois tendem a se compactar não permitindo a circulação do ar. Os finos com granulometrias entre 12,5 mm a 0,15 mm são aglomerados com cal e coque



formando partículas maiores chamadas de *sinter*. (VIEIRA et al., 2000). Atualmente, 95 % do ferro primário mundial é produzido via alto-forno, sendo que no Brasil, 80 % é alimentado por sinter: (SOUZA NETO et al., 1998).

O aproveitamento de minérios com granulometria abaixo de 0,15 mm (superfinos) exige outro processo de formação de partículas maiores, com granulometria aceitável para seu uso em altos-fornos, que consiste na formação de pelotas, ou pelotização. O beneficiamento de minérios de granulometria mais fina e de teores mais baixos, aumentou a vida útil das minas de ferro.

As frações utilizadas nos processos de sinterização e pelotização são denominadas *sinter-feed* e *pellet-feed*, respectivamente (CASTRO, 1989).



**FIGURA 2.1 – Processo de transformação de minérios de ferro em aço. (ZAVAGLIA, 1995; apud TAKEHARA, 2004)**

Um estudo sistemático das correlações entre as características de cada uma destas frações e o seu desempenho durante o processamento, permite estimar os custos e o rendimento do processo. (HUNDERTMARK, 1996; VIEIRA et al., 2000).

Atualmente, grandes esforços têm sido voltados ao melhor conhecimento do minério de ferro e seu beneficiamento, que envolve desde o conhecimento do depósito do minério, até a produção do ferro primário, na forma de gusa ou ferro-esponja (SOUZA NETO et al., 1998).

Para um melhor processo de redução, o minério de ferro, deve apresentar alto teor de Fe. Além disso algumas especificações químicas e físicas também influenciam no processo. A quantidade total dos elementos menores e impurezas (tanto do minério de ferro, quanto dos fundentes) deve ser controlada, uma vez que os excessos de impurezas acumulam-se dentro do alto-forno tornando o processo metalúrgico ineficiente. Os teores máximos destes elementos variam para cada usina. (GROSS, 1993).

Também as características mineralógicas, macroestruturais e texturais do minério, podem influenciar na qualidade do sinter produzido. (ROSIÈRE et al., 1997; VIEIRA, 2003 et al.; TAKEHARA, 2004).

Uma grande variação desses minérios ocorre nos tipos e formas dos cristais de hematita, resultante das diferentes condições para sua formação. Em estudos recentes alguns autores têm sugerido que as características texturais têm uma importância relevante para o entendimento do comportamento das partículas de minério de ferro em processos siderúrgicos (VIEIRA et al. 2003).

### **2.3 Caracterização do minério de ferro**

Os minérios de ferro podem ser classificados de acordo com a sua composição química. Os teores de ferro são determinados tanto pela quantidade de ferro presente nos minerais como pela concentração desses minerais nas rochas. Os principais minerais de ferro são listados na Tabela 2.3.

As classes minerais são representadas por um ou mais minerais, sendo que destes, apenas os minerais de ferro da classe óxido são explorados economicamente, nas condições atuais. (TAKEHARA, 2004).

<b>Classes</b>	<b>Minerais</b>	<b>Composição química do Mineral Puro</b>	<b>Teor Fe (%)</b>	<b>Designação Comum</b>
<b>ÓXIDOS</b>	Magnetita	$\text{Fe}_3\text{O}_4$	72,4	Óxido ferroso-férrico
	Hematita	$\text{Fe}_2\text{O}_3$	69,9	Óxido férrico
	Goethita	$\text{HFeO}_2$	62,8	Hidróxido de ferro
	Lepidocrocita	$\text{FeO}(\text{OH})$	62,85	
<b>CARBONATO</b>	Siderita	$\text{FeCO}_3$	48,2	Carbonato de ferro
<b>SULFETOS</b>	Pirita	$\text{FeS}_2$	46,5	
	Pirrotita	$\text{FeS}$	63,6	
<b>SILICATOS</b>	Fayalita	$\text{Fe}^{2+}_2(\text{SiO}_4)$	54,81	Grupo da Olivina
	Laihunite	$\text{Fe}^{2+} \text{Fe}^{3+}_2(\text{SiO}_4)_2$	47,64	Grupo da Olivina
	Greenalita	$\text{Fe}^{2+}_2 \text{Fe}^{3+}_{0,5} \text{Si}_2 \text{O}_5(\text{OH})_{3,3}$	44,14	Grupo da Serpentina
	Grunerita	$\text{Fe}^{2+}_7(\text{Si}_8 \text{O}_{22})(\text{OH})_2$	39,03	Grupo dos Anfibólios
	Antofilita	$\text{Fe}^{2+}_7(\text{Si}_8 \text{O}_{22})(\text{OH})_2$	39,03	Grupo dos Anfibólios

**Tabela 2.3** – Principais minerais de ferro e suas classes (TAKEHARA, 2004).

A magnetita tem cor cinza a preto. Por ser um mineral fortemente magnético é facilmente separado da ganga com uso de eletroímãs, produzindo um concentrado de alta qualidade. A hematita tem a cor cinza azulado a vermelho, brilhante a fosca, podendo ser terrosa, compacta ou cristalina. É o mais importante mineral de ferro, devido a sua larga ocorrência em vários tipos de rochas e suas origens diversas. A limonita é um nome genérico dado para os óxidos hidratados de ferro, que mineralogicamente são compostos de misturas variadas dos minerais goethita e lepidocrocita. Sua cor é geralmente amarela ou marrom a quase preta e pode ser compacto a terroso e ocre. (TAKEHARA, 2004).

### 2.3.1 Caracterização microestrutural

Os minérios brasileiros apresentam estruturas internas muito variadas, devido às diferentes condições de metamorfismo, tectonismo e intemperismo a que foram

sujeitos, ou, mesmo, em virtude de sua gênese. Dessa forma, originaram-se minérios com diferentes constituintes mineralógicos, trama, tamanho e morfologia dos cristais, tamanho e morfologia dos poros, porosidade, forma e superfícies das partículas, etc. (ROSIÈRE, 1996; VIEIRA, 1996; ROSIÈRE et alii, 1997).

Para um melhor controle dos processos de beneficiamento industrial, como granulação ou sinterização, o minério deve ser bem caracterizado (CLOUT, 1998; apud DONSKOI, 2007). Esta caracterização deve incluir informação sobre a mineralogia das partículas, associações minerais, morfologia, porosidade, textura, dureza, distribuição de tamanho e liberação mineral. Para isto uma combinação de técnicas complementares deve ser usada, incluindo microscopia e microssonda eletrônica, microscopia ótica de transmissão e a análise de imagens.

#### 2.3.1.1 Caracterização mineralógica

A caracterização mineralógica do minério consta da descrição das diferentes fases minerais e a sua distribuição (TAKEHARA, 2004). A determinação da mineralogia de partículas de minério de ferro pode ser dada por vários métodos, os quais se dividem em diretos e indiretos. Métodos indiretos assumem que o minério é estequiométrico, o que nem sempre é verdade.

Entre os métodos diretos, destaca-se a microanálise de raios-X característicos, a qual é realizada em microscópios eletrônicos dotados de espectrômetros, que permitem observar a microestrutura, a associação mineral e a liberação juntamente com a composição química (DONSKOI et al., 2007). Entretanto para fazer uma distinção confiável entre diferentes óxidos e hidróxidos de minério, o tempo de análise aumenta significativamente.

Sistemas de análise de imagens óticas são capazes de identificar a porosidade em diferentes minerais e diferenciar vários minerais do minério de ferro. Esta diferenciação é baseada nas diferenças de refletância entre óxidos e hidróxidos do ferro.

A densidade das partículas é fator determinante do comportamento dos finos durante o beneficiamento. (DONSKOI et al., 2008). Assim, a determinação da porosidade de diferentes partículas e minerais constituintes é parte importante da

sua caracterização. Neste particular, a análise de imagens óticas é uma ferramenta extremamente eficiente em comparação com as técnicas baseadas em microscopia eletrônica. Além de identificar a porosidade, os sistemas de análise de imagens óticas são capazes de diferenciar vários minerais com base nas diferenças de refletância entre óxidos e hidróxidos do ferro.

Para prever a performance do beneficiamento de minérios, partículas têm sido classificadas pela análise de liberação, com base na proporção de minerais indesejados em cada partícula (KING, 2001). Tal abordagem pode ser muito apropriada para minérios simples, onde apenas um mineral é de interesse. Minério de ferro, entretanto, pode ser complexo e muito freqüentemente, consiste de 5 a 6 minerais principais. Assim, por exemplo, diferentes partículas com a mesma quantidade de hematita podem ter muitas quantidades diferentes de ferro se o resto da partícula consistir de minerais que podem ou não conter ferro, tais como *goethita* ou *caolinita*. (DONSKOI et al., 2008).

No método de modelação da performance, descrito por Donskoi (DONSKOI et al., 2008), as partículas dentro de uma fração de tamanho do *feed* são classificadas conforme uma variante de classificações propostas anteriormente (BOX et al. 2002; DONSKOI e CLOUT, 2005; DONSKOI et al., 2006; apud DONSKOI, 2008) de acordo com a composição química dos minerais, o tipo de textura mineral e porosidade. A informação química é obtida previamente por análise de microsonda de raios-X. Para a caracterização dos minérios, são usados atributos como área de cada mineral, perímetro fechado (que não está em contato com a resina), perímetro aberto (conectado com a resina). Características dimensionais de cada partícula foram calculadas por um programa especialmente desenvolvido para este fim (*MINERAL*, DONSKOI et al., 2007). Estas informações foram então carregadas em outro programa (*RECOGNITION*, DONSKOI et al., 2007), para classificar cada partícula em um grupo de textura particular do minério de ferro, xisto, ganga e partículas não reconhecidas.

As características individuais dos minérios podem ter uma influência importante nas propriedades dos *sinters* produzidos e, conseqüentemente, nos processos do forno (GOLDRING e FRAY, 1989). A reação das partículas grandes depende da sua composição, especialmente a basicidade, o ferro contido e o potencial de oxigenação. Com base em testes que envolvem a reação dos minérios individuais comparados com dados mineralógicos, os minérios foram classificados

em quatro grupos: (a) difíceis de fundir (baixa reatividade); (b) intermediário (moderadamente reativos); (c) fácies de fundir (altamente reativos); (d) essencialmente fundíveis (extremamente reativos). Materiais com alta basicidade e baixo teor de ferro não derretem facilmente quando sujeitos a redução por altas temperaturas. Contudo a presença de material residual pode ser relacionada a instabilidade no processo de redução em alto forno.

As características relevantes no processo de sinterização podem ser divididas em 6 categorias (GOLDRING e FRAY, 1989):

1. Conteúdo da mistura;
2. Distribuição dos tamanhos das partículas;
3. Composição química (total de Fe e demais elementos encontrados no minério), química das frações de tamanho;
4. Propriedades físicas, dureza, densidade, porosidade, molhabilidade;
5. Mineralogia, total dos componentes de Fe e materiais da ganga, minerais contidos nas frações;
6. Textura, tamanho do cristal e morfologia, tamanho e distribuição dos poros, textura entre os minerais e a maneira como ocorrem nas partículas, em especial a distribuição dos minerais  $\text{SiO}_2$  e  $\text{Al}_2\text{O}_3$ .

A maioria dos minérios é constituída principalmente de hematita além de outros minerais como goethita, limonita. A hematita mostra uma grande variedade de textura e tamanho nos cristais, refletindo sua origem diversa. As texturas comuns de hematita são listadas na Tabela 2.4 (GOLDRING e FRAY, 1989).

<b>Tipos</b>	<b>Abreviatura</b>
Coarsely Crystalline	c.c
Interlocking granular	int. gr.
Flaky	fl.
Martitic	mart.
Microplaty	m.p
Ultrafine platy	ultf.
Ultrafine submicroscopic	ultf. sub.
Ochreous	ochr.

**Tabela 2.4 – Texturas comuns de hematita (GOLDRING e FRAY, 1989).**

### 2.3.1.2 Caracterização textural

A textura tem duplo significado na caracterização de partículas minerais, pois é amplamente conhecida tanto como a distribuição espacial dos diferentes minerais, como de diferentes grãos cristalinos de um mesmo mineral em uma partícula. Muitos autores usam a palavra *textura*, para designar o primeiro tipo de distribuição e a palavra *fabric* (trama) para descrever a orientação cristalina de populações minerais (PIRARD, 2007). A respeito do primeiro significado, King e Schneider (KING, 1998) demonstraram que a textura mineralógica dos cristais tem uma influência decisiva na distribuição de liberação. Por outro lado, o tamanho, forma, e distribuição espacial dos cristais e poros influenciam na redução do sinter. (GOLDRING e FRAY, 1989).

Não existe até o momento um esquema universal de classificação de textura. Uma classificação de minérios baseada nas principais texturas de hematita e ganga é descrita por Goldring (GOLDRING e FRAY, 1989). Clout (CLOUT, 2003) propõe um sistema de classificação do minério de ferro que cria agrupamentos com base na similaridade mineralógica, textura, porosidade, associação mineral e dureza. Os principais grupos de textura incluem: martita/hematita densa, “microplaty” hematita, “microplaty” hematita–goethita, martita–goethita, goethita–martita e rico em goethita. Cada grupo pode ser ainda subdividido em fisicamente duro a categorias mais macias.

A trama corresponde ao empilhamento tridimensional das organizações minerais em várias escalas. Para uma descrição confiável dos processos que atuaram na formação da rocha é necessária uma quantificação da trama, isto é, dos tamanhos dos objetos, sua forma, orientação e posição relativa em todas as escalas. O desenvolvimento da trama é o resultado da superposição de processos fisicamente diferentes tais como cristalização deformação, e circulação fluídica, que atuam nos sistemas complexos, os quais formam as rochas (DARROZES et al., 1997).

A determinação automática da orientação preferencial dos cristais que compõem a trama (shape preferred orientation SPO) vem sendo usada há cerca de duas décadas (ALLARD e BENN, 1989; LAUNEAU, BOUCHEZ and BENN 1990; apud DARROZES et al., 1997). Entretanto esta análise ignora as distribuições de

múltipla escala, tais como agrupamentos (clusters) de minerais e alinhamento dos clusters.

A descrição da trama em termos de *wavelets* é particularmente útil para detecção de estruturas pequenas sobrepostas a estruturas maiores. Um exemplo artificial apresentado por Darrozes, (DARROZES et al., 1997), mostra como esta técnica pode ser usada para quantificar em diferentes escalas a anisotropia de forma e orientação, assim como a distribuição espacial de objetos, para descrever a trama das rochas. Um método para quantificação da trama em termos de tamanho, forma, orientação e localização, em duas dimensões usando *anisotropic wavelets* é descrito por Gaillot (GAILLOT et al., 1999).

Prikryl (PRIKRYL, 2006) descreve um sistema de quantificação de trama, que combina diversos parâmetros na tentativa de estabelecer uma relação com as propriedades mecânicas das rochas. Embora os resultados sejam negativos para todos os parâmetros, exceto tamanho de grão, não se pode descartar a possibilidade de que exista uma correlação entre estes parâmetros e o desempenho nos processos de beneficiamento. Os parâmetros usados foram: tamanho, área e perímetro de cada grão, tamanho dos *ferrets* máximo e mínimo e suas orientações, razão de aspecto, suavidade dos contornos de grão, índice micropetrográfico de qualidade, coeficiente de textura (HOWARTH e ROWLANDS, 1986), índice de entrelaçamento (*index of interlocking*) e homogeneidade do tamanho do grão (DREYER, 1973; apud PRIKRYL, 2006).

Modelos de caracterização textural baseados em medidas de rugosidade e entrelaçamento (*interlocking*) foram anteriormente discutidos por (DREYER, 1973; apud PRIKRYL, 2006), o qual desenvolveu um índice de textura para rochas de sal. Porém o uso destes modelos pareceu limitado somente para rochas de sal. Entretanto estes modelos indicaram o papel do tamanho do grão e a densidade do grão em determinar a força mecânica da rocha (HOWARTH e ROWLANDS, 1986) e as características extraídas podem ser testadas no que se refere a possíveis correlações com o desempenho de minérios durante o beneficiamento.

O método de avaliação quantitativa da textura de rochas desenvolvido por Howarth (HOWARTH e ROWLANDS, 1986), analisa quatro componentes: (1) circularidade; (2) alongamento e (3) orientação dos grãos; e (4) ponderação dos resultados com base no grau de empacotamento dos grãos. O coeficiente de textura é então definido como




$$TC = AW \left[ \left( \frac{N_0}{N_0 + N_1} \times \frac{1}{FF_0} \right) + \left( \frac{N_1}{N_0 + N_1} \times AR_1 \times AF_1 \right) \right] \quad (2.1)$$

onde  $TC$  é o coeficiente de textura,  $AW$  é o fator de ponderação de empacotamento dos grãos,  $N_0$  = número de grãos com razão de aspecto abaixo do nível pré-ajustado de discriminação,  $N_1$  = número de grãos com razão de aspecto acima do nível pré-ajustado de discriminação,  $FF_0$  é a média aritmética do fator de forma,  $AR_1$  é a média aritmética da razão de aspecto e  $AF_1$  é o fator angular, que quantifica a orientação dos grãos (HOWARTH e ROWLANDS, 1986).

Para calcular cada um dos parâmetros da Equação 2.1 é necessário medir parâmetros geométricos como área, perímetro, comprimento, largura e o ângulo para cada grão. Comprimento e largura foram definidos como o maior e menor diâmetro dos *ferrets* (HERDAN, 1953; apud HOWARTH e ROWLANDS, 1986). Os ângulos dos *ferrets* foram medidos em relação à direção horizontal do campo e usados para determinar o fator angular,  $AF_1$ .


Na Figura 2.2 o significado do fator angular é ilustrado. Em cada campo, dezoito segmentos de reta estão orientados de forma diferente e os respectivos fatores angulares são calculados. Um fator angular baixo está associado a um alto grau de paralelismo.



**Figura 2.2 – Orientações e fatores angulares: (a) paralelas,  $AF_1 = 0,20$ ; (b) semi-paralelas,  $AF_1 = 0,62$ ; e (c) aleatórias,  $AF_1 = 1,00$ . (Modificado de HOWARTH e ROWLANDS 1986)**

Na Figura 2.3 são mostrados arranjos de objetos geométricos simples para ilustrar os efeitos das variáveis que determinam o coeficiente de textura. Nas Figuras 2.3 (b) e (c) pode-se observar o efeito de aumento da rugosidade e da variação da orientação (das partículas alongadas). Na Figura 2.3 (d) pode-se observar os efeitos do aumento da rugosidade e da variação da orientação para produzir um forte aumento no coeficiente de textura. Na Figura 2.3 (e) é mostrado o aumento do grau

de empacotamento. Finalmente, na Figura 2.3 (f) é mostrado o resultado de todos os processos que influem na combinação (HOWARTH e ROWLANDS, 1986).



**Figura 2.3 - Textura geométrica e coeficientes de textura: (a)  $TC = 0.43$ , (b)  $TC = 0.41$ , (c)  $TC = 0.53$ , (d)  $TC = 0.79$ , (e)  $TC = 0.87$ , e (f)  $TC = 1.57$ . (Modificado de HOWARTH e ROWLANDS 1986)**

#### 2.4 Caracterização do minério brasileiro

Em estudo realizado em 1998 (CVRD, 1998), a Vale, caracterizou o minério extraído de três minas quanto aos minerais presentes buscando uma correlação entre as características do minério e o seu desempenho no processo de sinterização. Os principais tipos de texturas de óxidos e hidróxidos de ferro, identificados naquele estudo, são apresentadas na Tabela 2.5 (CVRD, 1998).

Um estudo realizado pela Vale, entre de 6 amostras de sinter feeds, três delas são representativas de lotes que apresentaram um excelente desempenho na sinterização e três representantes dos lotes que apresentaram desempenho ruim

Duas amostras apresentaram diferenças significativas na proporção dos tipos morfológico de hematita. A amostra com desempenho industrial ruim possui conteúdos maiores de hematita do tipo lamelar, 61% contra 51% na amostra que apresentou desempenho excelente.




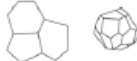

TIPO	CARACTERÍSTICAS	FORMA/TEXTURA
<b>HEMATITA CRIPTOCRISTALINA</b>	- Cristais muito pequeno < 0.01 mm; - Textura porosa; - Contatos pouco desenvolvidos.	
<b>MAGNETITA</b>	- Cristais euédricos, isolados ou em agregados; - Cristais compactos.	
<b>MARTITA</b>	- Hematita com hábito de magnetita; - Oxidação segundo os planos cristalográficos da magnetita; - Geralmente porosa.	
<b>HEMATITA RECRISTALIZADA</b>	- Formatos irregulares inequidimensionais; - Contatos irregulares geralmente imbricados.	
<b>HEMATITA GRANULAR</b>	- Formatos regulares equidimensionais; - Contatos retilíneos e junções triplices; - Cristais compactos.	
<b>HEMATITA LAMELAR</b>	- Cristais inequidimensionais, hábito tabular; - Contatos retilíneos; - Cristais compactos.	
<b>HIDRÓXIDOS DE FERRO (Goethita-Limonita)</b>	- Material amorfo e/ou criptocristalino; - Estrutura colóide, hábito botrioidal; - Textura porosa.	

Tabela 2.5 –Tipos de texturas de óxido e hidróxido de ferro e suas características principais (CVRD, 1998).

Amostras	Mina ALEGRIA		Mina SECE		Mina SECA	
	Excelente	Ruim	Excelente	Ruim	Excelente	Ruim
<b>Hematita Total</b>	78	79	97	96	97	97
Criptocristalina	~0,5%	~0,8%	~0,5%	~0,5%	1	1
Martita	35	42	~0,8%	5	2	2
Recristalina	5	4	3	3	6	5
Granular	16	10	41	26	40	40
Lamelar	23	22	51	61	47	49
<b>Magnetita</b>	4	5	1	2	1	~0,8%

Tabela 2.6 – Tipos morfológicos dos cristais de óxidos de Fe (em % vol.), (CVRD, 1998).

As partículas de hematita de forma lamelar têm pequena área por unidade de massa e superfície muito lisa. Assim, deve-se esperar que núcleos formados por partículas lamelares possuem baixa capacidade de retenção aderentes, o que reduz a permeabilidade a frio da mistura. O tamanho dos cristais de hematita mostrou-se também um pouco diverso nas duas amostras. Na amostra ruim existe 5% a mais de

granulação grossa (diâmetro maior de grão entre 0,12 e 0,22mm) do que na amostra excelente. Essa diferença na distribuição de tamanho resultou num tamanho de cristal de 87  $\mu\text{m}$  para a amostra ruim contra 75 na boa.

Amostras	Característica Ocorrência	Desempenho do processo/ produto		Conhecimento do Fenômeno
		Caráter	Razão	
Excelentes	Distribuição de massa elementar Sílica e alumina concentradas na fração + 1 mm	Positivo	Combinado com o maior grau de liberação favoreceu reações de assimilação no Ferrito de cálcio	Em construção
	Quartzo Mais finamente cristalizado Mais livre na fração +1 mm	Positivo	Aumento da reatividade à assimilação pelo banho de Ferrito de Cálcio	Consistente (aumentar número de amostras)
	Porosidade aberta Minérios pouco mais porosos	Positivo	Aumento da reatividade a sinterização	Consistente (aumentar número de amostras)
Ruins	Composição química Sílica supergênica	Negativo	Sílica menos reativa	Consistente
	Distribuição granulométrica Pequeno afinamento	negativo	Provável redução da permeabilidade a frio da mistura	Consistente
	Morfologia dos cristais de minerais de ferro Aumento da quantidade de hematita martita e lamelar	Negativo	Efeito da martita é desconhecido	Em construção
			Hematita lamelar possui menor capacidade de aglomeração a frio	Consistente

**Tabela 2.7 – Comparação entre amostras com desempenho excelente e amostras que apresentaram desempenho ruim na sinterização da USIMINAS, demonstrando diferenças nas características tanto macroscópicas quanto microscópicas. (CVRD, 1998)**

Comparando-se as amostras com desempenho excelente e amostras que representaram desempenho ruim na sinterização, verificaram-se diferenças tanto nas características macroscópicas quanto nas microscópicas, as quais são resumidas na Tabela 2.6:

As variações mais significativas entre duas amostras de uma mesma mina ocorreram a nível textural, com relação aos tipos morfológicos dos cristais de óxidos de ferro (tabela).

Texturalmente as amostras SECE apresentaram diferenças significativas na proporção de cristais de hematita lamelar e granular: a amostra SECE ruim possui conteúdos maiores do tipo lamelar ( 61% contra 51% na amostra SECE excelente), e martita (5% contra 1%) e, conseqüentemente apresenta conteúdo menor do tipo granular (apenas 26%).

### 3 VISÃO COMPUTACIONAL

Como uma disciplina científica, a visão computacional está relacionada com a teoria para a construção de sistemas artificiais que obtêm informação de imagens. Como uma disciplina tecnológica, a visão computacional busca aplicar as teorias e modelos da visão computacional para a construção de sistemas de visão computacional.

Atualmente existem muitas máquinas construídas para ver. Como exemplos, podem ser citas as máquinas de inspeção industrial, usadas para verificar a integridade de filamentos de lâmpadas ou de placas de circuitos eletrônicos em linhas de montagem, caixas eletrônicos que identificam o usuário pela íris ou pela impressão digital etc. (SHAPIRO e STOCKAMN, 2001)

A visão computacional pode ser descrita como uma extensão da visão biológica. Muitas de suas técnicas podem ser usadas na automação industrial para a detecção de eventos, localização e reconhecimento e classificação de objetos ou, ainda a determinação de posições e orientação de objetos. O objetivo da visão computacional é automatizar a tomada de decisões úteis sobre objetos físicos e cenas reais com base em imagens detectadas.(SHAPIRO e STOCKAMN, 2001)

Visão é exatamente o oposto da computação gráfica. Os processos em computação gráfica iniciam com uma descrição funcional, e terminam com uma imagem de representação. Neste caso, a imagem possui as informações completas, assim, a maior parte dos problemas é de natureza algorítmica. Na visão não se tem a informação completa. Conseqüentemente, devemos usar o domínio específico de conhecimento, suposições ou heurísticas para alcançar o objetivo. (YANG e GILLIES, 2008)

Embora a construção de sistemas de visão seja altamente dependente do domínio, algumas técnicas têm utilidade além de sua aplicação imediata.

Para projetar um sistema de visão algumas questões específicas precisam ser respondidas:

1. Que informação é procurada na imagem?
2. Como esta informação aparece na imagem?

3. Que conhecimento “a priori” é exigido para recuperar a informação?
4. Qual a natureza do processo computacional?
5. Como a informação requerida deve ser apresentada?

Considerando as questões 1 e 2 é preciso estabelecer a relação entre as entidades físicas (o objeto real da imagem) e as suas características. Por exemplo, caso seja necessário extrair a posição de uma casa em uma cena que contenha árvores, devemos considerar, o fato de que as linhas retas são uma característica da casa, mas não das árvores. As linhas retas são as características relevantes a serem extraídas da imagem original (YANG e GILLIES, 2008).

A questão 3 é de muita importância, pois, o objetivo da visão computacional é fornecer a informação que está em uma imagem. Algum conhecimento prévio é sempre necessário. Aceita-se universalmente que a visão humana depende de uma quantidade vasta de conhecimento. Para estabelecer um relacionamento entre o brilho do pixel e as propriedades da imagem, é necessário conhecer alguma informação sobre o modelo da cena, o padrão de iluminação e o modelo do sensor de captação da imagem.

A questão 4 inclui considerações sobre os recursos de computacionais, e o tempo requerido para o processamento da imagem. A natureza exata do processo computacional será estabelecida pelas respostas das questões 1, 2 e 3, porém, as exigências reais de tempo precisam ser levadas em conta (YANG e GILLIES, 2008). Por exemplo, o tempo de análise de uma lâmina para inspeção anatomopatológica pode ser importante para um diagnóstico de urgência.

Representação é em parte importante da visão para realizar a codificação do conhecimento extraído, de uma forma útil, e também na apresentação de resultados em uma forma compreensível. Todos temos alguma dificuldade em descrever exatamente as propriedades visuais com base nas quais tomamos decisões (YANG e GILLIES, 2008).

O campo da visão computacional pode ser considerado como imaturo e diverso. Embora existissem trabalhos anteriores, foi na década de 70, com avanço dos computadores que se iniciou um estudo mais focalizado do campo, com o aumento da capacidade de processar grande quantidade de dados. Os primeiros estudos originaram-se de campos diversos e, como consequência, não houve a formulação do problema padrão de visão de computacional. Também não há nenhuma formulação padrão de como deveriam ser resolvidos problemas de visão

de computacional. O que existe é uma abundância de métodos para resolver problemas específicos de visão computacional, os quais raramente podem ser generalizados sobre uma variedade de aplicações. Muitos dos métodos e aplicações ainda estão no estado de pesquisa básica, mas há cada vez mais métodos em produtos comerciais que freqüentemente fazem parte de um sistema maior, projetado para realizar tarefas complexas

### 3.1 Campos relacionados

Uma parte significativa da *inteligência artificial trata do planejamento de sistemas autônomos*, isto é, que realizam ações baseadas na interpretação de dados coletados por sensores. Os sistemas de *visão computacional* utilizam sistemas de captura de imagens, cujo conteúdo é um sinal bidimensional, cuja intensidade também varia no domínio de freqüências, ou faixas espectrais.

Outras áreas que são entendidas como integrantes da inteligência artificial e que estão relacionadas à visão computacional são o reconhecimento de padrões e o aprendizado de máquinas. Assim, deste ponto de vista, a visão computacional é como uma parte da inteligência artificial.

A física é outro campo que é fortemente relacionada com a visão computacional, pois, existem métodos que requerem o entendimento da natureza da radiação eletromagnética, tipicamente nas regiões visível ou infravermelha, que é refletida pelas superfícies dos objetos e medida pelo sensor para produzir os dados das imagens. Estes processos são descritos pela ótica e a física do estado sólido. Vários problemas de medidas físicas podem ser designados a visão computacional.

Também o conhecimento adquirido pela neurobiologia, especialmente o estudo do sistema de visão biológica, tem contribuído para o desenvolvimento da visão computacional. Desde o século passado existem estudos para compreender o funcionamento dos olhos, dos neurônios, e das estruturas do cérebro destinadas aos estímulos visuais em seres humanos e em diversos animais. Isso levou uma descrição aproximada de como o sistema de visão real realiza determinadas tarefas. Estes resultados são usados para construir sistemas de visão artificial que imitam o comportamento do sistema biológico, em níveis diferentes de complexidade.

Muitos dos tópicos de pesquisa relacionados podem ser estudados de um ponto de vista da matemática pura. Pois muitos métodos de visão computacional, são baseados em estatística, otimização e geometria.

Implementação de sistemas de visão computacional pode ser definida, também, como uma subárea, pois, está destinada aos aspectos de como estes métodos podem ser implementados em várias combinações de software e hardware, ou como estes métodos podem ser modificados para ganhar velocidade de processamento sem perder desempenho.

As áreas que estão mais relacionadas com a visão computacional são processamento e a análise de imagens. Existe uma sobreposição dos termos e as técnicas de aplicação que cobrem esta área. Isto implica que técnicas básicas desenvolvidas para estes campos são algumas vezes muito semelhantes, as vezes pode ser interpretado como a existência de somente uma área com diferentes nomes. Mas isso parece ser necessário, para os grupos de pesquisa, as revistas científicas, e para as companhias se apresentarem ou se introduzirem no mercado como pertencendo especificamente a um campo, onde são apresentados várias características que distinguem cada um dos campos dos outros.

Processamento e análise de imagens tem foco para imagens em 2D, como a transformação de uma imagem em outra, por exemplo em operações de realce do contraste, operações locais como detecção de contorno ou remoção de ruídos, ou ainda a transformações geométricas como a rotação da imagem. Esta característica implica que a imagem analisada ou processada, não exija suposições nem produza interpretações sobre características da imagem. Esta definição pode ser considerada mas não deve ser aceita como universal. (WIKIPEDIA, 2008)

### **3.2 Níveis de visão**

É geralmente aceito que a visão pode ser tratada em 3 diferentes níveis de processamento, baixo, médio e intermediário. Porém os limites entre estes níveis não são totalmente distintos.

No nível de processamento baixo as operações são realizadas nos pixels das imagens, para extrair propriedades do gradiente (no que diz respeito à intensidade)



ou a profundidade em cada ponto na imagem. Ao se extrair regiões uniformes em uma imagem, o gradiente dos pixels permanece constante, mudanças no gradiente, correspondem a linhas retas, mudanças mais bruscas podem ser usadas para extrair propriedades da superfície, tais como picos, poços e etc. O processamento de baixo nível conduz a dados invariáveis chamado as vezes de *bottom up*.

O nível intermediário de processamento esta relacionado com o agrupamento de entidades unidas. O caso mais simples é quando os pixels são agrupados em linhas. A linha pode ser apresentada na sua forma funcional. Similarmente, se a saída do processamento de baixo nível é um mapa de profundidade, no nível intermediário apresentar as bordas do objeto, ou outras características. Pode-se assim extrair uma esfera de uma imagem, o que não é fácil como uma representação de profundidade, é necessário encontrar uma representação para o centro e o raio. O processamento intermediário está relacionado com o agrupamento. (YANG, 2008)

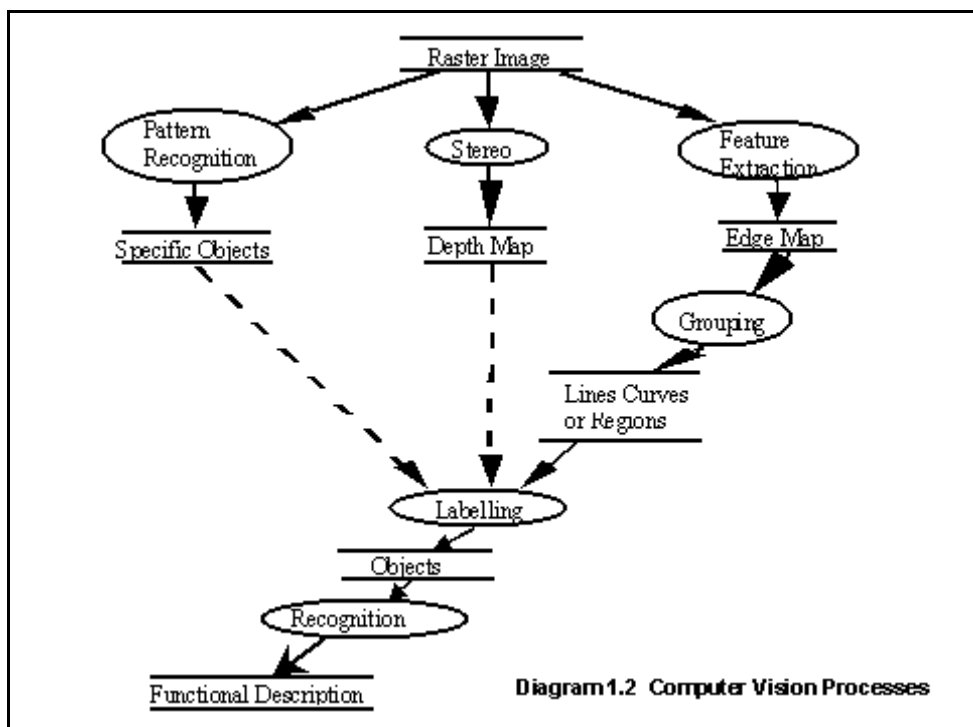


Figura 3.1 – Diagrama dos níveis de processos de visão. (YANG e GILLIES, 2008)

A interpretação de uma cena exige que sejam tomadas decisões sobre tipos das bordas, como, quais estão fechadas, e que informação é escondida. Um

agrupamento mais complexo é essencial nesta fase, poder decidir ou identificar que grupo linhas, unidas, formam um objeto. Para fazer isto, é necessário distinguir as linhas que fazem parte da estrutura dos objetos, daquelas que são parte de uma textura de superfície, ou causado por sombras. Exigem quase sempre algum formulário do conhecimento sobre os objetos da cena. O diagrama abaixo ilustra os três níveis em que a visão é geralmente tratada, demonstrando os níveis descritos.

Ao adotar três níveis de aproximação, pode-se observar que na mudança de um nível para outro mais alto, algumas informações são descartadas. Ao definir um nível de threshold em uma imagem onde espera-se identificar as bordas por diferenciação, um número considerável de pixels é eliminado. Isto é desejável do ponto de vista computacional, para minimizar os cálculos realizados e limitá-los aos pontos da borda, entretanto, corre-se o risco de remover um ponto fraco mas significativo da borda da imagem, e assim fazendo uma decisão antecipadamente errada. Deve-se evitar carregar tanta informação de um nível ao seguinte. O limite praticável para fazer isto dependerá dos recursos computacionais utilizados. (YANG e GILLIES, 2008)

### **3.3 Processamento de imagens**

O campo de visão é fortemente relacionado ao processamento de imagens e, freqüentemente, o nome processamento de imagens é usado para cobrir ambos os campos. (YANG e GILLIES, 2008) .

O interesse em métodos de processamento de imagens digitais, decorre de duas áreas principais de aplicação: melhoria da informação visual para a interpretação humana e o processamento de dados contidos na imagem, para percepção automática através de máquinas ou avaliações quantitativas, as quais envolvem contagens e medidas de objetos de interesse (GONZALEZ e WOODS, 2002).

Técnicas de processamento de imagens digitais são atualmente utilizadas para solucionar uma variedade de problemas. Esses problemas, têm em comum a necessidade de implementar e desenvolver métodos capazes de melhorar a informação visual para a análise e interpretação humana. Processos são usados na

medicina, para melhorar o contraste ou codificar os níveis de intensidade em cores, de modo a facilitar a interpretação das imagens de raios-X e outras imagens biomédicas. Geógrafos usam técnicas idênticas ou similares para estudar padrões de poluição em imagens aéreas ou de satélites. Arqueólogos usam métodos de processamento de imagens para restaurar fotografias históricas. Assim podemos encontrar aplicações de processamento de imagens em diversas áreas como astronomia, biologia, medicina nuclear e aplicações industriais.

No que se refere à solução de problemas relacionados à percepção por máquina, ou seja, problemas relacionados com reconhecimento de padrões, o interesse concentra-se em procedimentos para extrair da imagem a informação adequada para o processamento computacional. Frequentemente esta informação apresenta pouca semelhança com as características utilizadas pelo homem na interpretação do conteúdo de uma imagem.

Embora o sistema visual humano seja excelente para reconhecer padrões em seus aspectos qualitativos, identificando e interpretando até mesmo pequenas divergências da normalidade, os humanos não são tão bons em interpretações quantitativas. Mesmo uma tarefa simples de contar o número de objetos presentes em uma imagem digital, torna-se rapidamente tediosa e difícil na medida que o número de objetos se torna muito grande. Estimar a forma, tamanho e textura quantitativamente é outra tarefa difícil e usualmente impregnada de uma certa subjetividade. Por isso, desde o início da era digital, muitos esforços têm sido feitos para a aplicação dos computadores em tarefas de análise quantitativa de imagens, uma vez que, diferentemente dos humanos, as máquinas são excelentes para a contagem e medição de objetos (RODENACKER e BENGTSSON, 2003).

### **3.4 Reconhecimento de padrões**

Reconhecimento de padrões é a ciência que trata da classificação, descrição ou o agrupamento automático de objetos, tem por objetivo classificar informações extraídas de conjuntos de dados.

Reconhecer padrões é intuitivamente fácil para os seres humanos, pois exercitamos o reconhecimento de padrões o tempo todo em nossa vida. Quando

estamos lendo um texto, nossos olhos capturam um sinal físico que representa o texto, os caracteres são reconhecidos, palavras, sentenças e por fim a semântica do texto é extraída em um nível mais elevado de processamento de informação (RAUBER, 1997).

Um humano pode recorrer a sistemas de reconhecimento de padrões de forma interativa, para restringir a sua atenção a um conjunto de casos selecionados pelo sistema, ou para automatizar completamente o processo de tomada de decisão, sem necessidade de intervenção.

Um projeto de reconhecimento de padrões envolve três processos, extração de características dos modelos que se deseja classificar ou descrever; seleção das características mais discriminativas, e construção de um descritor (*mecanismo de tomada de decisão* sobre a classe a que pertence um padrão em função de suas características).

A necessidade de sistemas de reconhecimento automático de padrões tem aumentado em decorrência do aumento da quantidade de dados a serem processados e da demanda por melhoria do desempenho tanto em velocidade, como exatidão e custo.

O reconhecimento de padrões pode ser visto também como redução de informação, por exemplo, o sistema de visão humano, ao ler um texto, recebe uma grande quantidade de informação física de cada átomo do papel, onde somente a transmissão de uma cena em preto e branco é interessante para a leitura do texto. (RAUBER, 1997)

O reconhecimento de um caractere é baseado em certas características, como existência ou a ausência de um traço ou de linhas curvas. Tais curvas de um caractere podem ser representadas numericamente, podendo-se medir a curvatura de cada traço. A vantagem de uma representação numérica para o reconhecimento de padrões é a disponibilidade de uma variedade de ferramentas para computação matemática e estatística.

O uso de estatística é fortemente justificado, pois, objetos de uma mesma classe podem ser apresentados por uma distribuição estatística. Permitindo o uso de inferência estatística para dizer a que classe um determinado padrão pertence.

Um padrão pode ser descrito por um vetor cujas componentes são características numéricas dos objetos de interesse, as quais são obtidas por meio de um conjunto de observações (JAIN et al., 1999).

Conjuntos de padrões semelhantes formam classes, ao se estabelecer critérios, de proximidade de valores das componentes dos vetores de características, entre os padrões. Os componentes definem pontos no espaço de características, onde a proximidade é traduzida em termos de uma certa medida de “distância”.

Quando são extraídas as características de um conjunto de objetos pertencentes à mesma classe, os pontos representativos destes objetos no espaço de características agrupam-se mantendo entre si distâncias menores do que aquelas que se medem em relação a objetos pertencentes a outras classes, formando regiões no espaço de característica, onde são identificadas as classes.

Nem sempre um problema de reconhecimento exhibe agrupamentos de pontos no espaço de características bem delineados. Por isso é importante a implementação de algoritmos de extração e seleção de características. A escolha das características deve simplificar o processo de classificação de maneira que os vetores ocupem regiões disjuntas no espaço de características.

As medidas de similaridade são usualmente traduzidas como uma distância entre pares de padrões, que pode ser uma simples distância, euclidiana ou outras propostas na literatura (JAIN et al., 1999). Considerando esta distância, a análise de *clusters* pode ser realizada por agrupamento hierárquico, associação ao vizinho mais próximo, entre outros.

Uma alternativa às medidas simples de distância é considerar a variação local da densidade de pontos no espaço de características, isto é, o gradiente da densidade. De acordo com este tipo de critério, um padrão é agrupado àqueles da sua vizinhança que se encontram mais próximos entre si.

Abordagem	Representação	Função de Reconhecimento	Critério Típico
<b>Coincidência com modelo</b>	Amostras, pixels, curvas	Correlação, Distância	Erro de classificação
<b>Estatística</b>	Características	Função discriminante	Erro de classificação
<b>Sintática ou estrutural</b>	Primitivas	Regras, gramática	Erro de aceitação
<b>Redes neuronais</b>	Amostras, pixels, curvas	Função de rede	Erro quadrático médio

**Tabela 3.1 – Modelos de reconhecimento de padrões (JAIN et al., 2000).**

Segundo Jain (JAIN et al., 2000) a abordagem estatística está entre as quatro abordagens mais bem estabelecidas de reconhecimento de padrões, as quais são listadas na Tabela 3.1. No reconhecimento estatístico de padrões, o objetivo é estabelecer fronteiras de decisão no espaço de características que separem os padrões de classes diferentes. Assume-se que cada padrão é uma observação obtida aleatoriamente com uma certa probabilidade de pertencer a uma determinada classe.

Na Figura 3.2 está representada uma classificação dos tipos de abordagens em reconhecimento estatístico de padrões conforme Jain (JAIN et al., 2000). Quando as classes são previamente conhecidas o problema de classificação pode ser resolvido pela aplicação da teoria de decisão de Bayes. Quando as classes não são previamente conhecidas, os sistemas de classificação são divididos conforme a participação ou não do usuário em supervisionados ou não supervisionados.

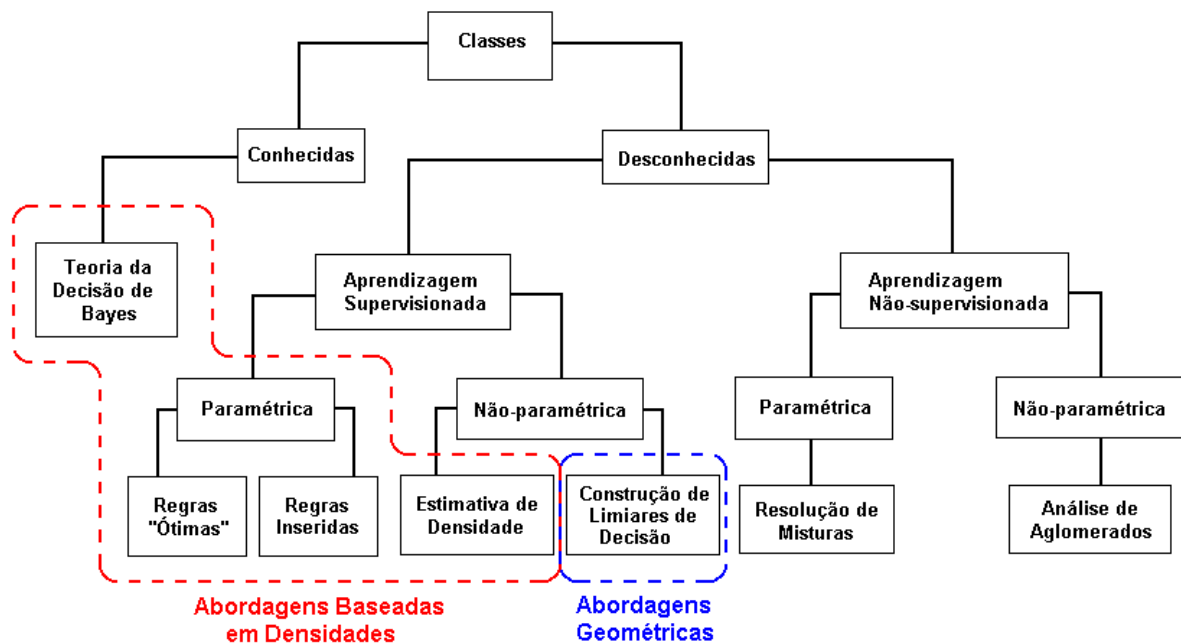


Figura 3.2 – Tipos de abordagens em reconhecimento estatístico de padrões (JAIN et al., 2000).

No *sistema de classificação supervisionado*, a fronteira de decisão pode ser especificada pelo usuário. Neste caso, as classes são *conhecidas* ou previamente determinadas pelo usuário do sistema de classificação que rotula os objetos que lhe são apresentados. Um *conjunto de objetos previamente rotulados pelo usuário*,

*usado para estabelecer os critérios de classificação* com base em suas características, é conhecido como *conjunto de treinamento*.

No *sistema de classificação não supervisionado*, a fronteira de decisão é estabelecida pelo sistema, onde *a semelhança entre os padrões é estabelecida pelo sistema que identifica quantas e quais são as classes*. Este tipo de sistema é usado quando as classes são *desconhecidas*. ( JAIN et. al., 2000).

Nas abordagens de reconhecimento supervisionado de padrões, também podem ser agrupadas pelo modo como são estabelecidos os limites de decisão, se diretamente (*abordagens geométricas*) ou indiretamente (*abordagens baseadas em densidades de probabilidade*), conforme mostram as linhas tracejadas.

No caso em que as classes não são conhecidas previamente, e devem ser aprendidas pelo sistema de forma não supervisionada, há duas possibilidades: As abordagens ditas *paramétricas*, onde a forma da densidade de probabilidade das classes é conhecida (ex., uma gaussiana multivariada), devendo ser determinados alguns dos seus parâmetros (ex., matrizes de covariância), ou *não paramétricas*, onde a forma desta função não é conhecida.

## **4 MATERIAS E MÉTODOS**

Neste Capítulo, descrevemos um método supervisionado de reconhecimento de padrões para classificar os cristais de hematita em amostras minério de ferro hematítico. Este método pressupõe a segmentação dos cristais, isto é, que os cristais de hematita estejam individualmente identificados na imagem digital de entrada. Isto significa que cada pixel desta imagem deve estar rotulado como pertencente a um, e somente um, cristal de hematita ou poro. Embora, em princípio, esta segmentação possa ser realizada por algum outro procedimento, vamos nos referir àquele desenvolvido por Rosa (ROSA, 2008), que analisa imagens digitais de microscopia ótica luz polarizada adquiridas de um mesmo campo. Isto significa que todos os procedimentos de pré-processamento aqui descritos aplicam-se às imagens de saída daquele método. Este trabalho é, neste sentido, uma continuação do trabalho anterior. Ambos fazem parte de um projeto maior que tem por objetivo o desenvolvimento de um sistema completo de classificação de minérios e, em particular, de minério de ferro.

### **4.1 Método proposto**

As imagens analisadas no presente trabalho são das mesmas amostras usadas no trabalho de Rosa (ROSA, 2008), cujas características e preparação são descritas em trabalhos anteriores (ROSA, 2008, TAKEHARA, 2004). Estas imagens contém unicamente grãos de hematita e poros, de modo a facilitar a análise e comparação com os resultados obtidos por inspeção visual. Cada grão cristalino deve ser classificado em uma das seguintes classes:

- Hematita Granular Compacta
- Hematita Granular Porosa
- Hematita Lamelar Compacta
- Hematita Lamelar Porosa



Após a aplicação do método de segmentação sobre um conjunto de imagens de microscopia ótica de luz polarizada de um mesmo campo, uma imagem temática é produzida em que cada grão cristalino é representada por uma falsa cor.

Antes de realizar a análise dos grãos, as imagens temáticas necessitam ser processadas para eliminar os artefatos produzidos pela aplicação do algoritmo de segmentação, tais como falsos pequenos grãos e prolongamentos dos grãos nas regiões de contorno. No presente trabalho, estes artefatos foram eliminados pela aplicação de filtros morfológicos. Como consequência, grãos menores do que o tamanho dos artefatos foram eliminados.

Devido ao processo de filtragem dos poros ser realizado previamente pelo uso de uma máscara binária, todos os poros são identificados com a cor preta e, portanto identificados como um único objeto.

Para facilitar a implementação dos algoritmos usados na análise dos grãos individuais e seu arranjo nas partículas de minério, é melhor que estejam indexados por um número inteiro, ao invés de uma falsa cor, que utiliza três componentes inteiros. No processo de indexação, ou rotulagem, das falsas cores usadas no mapa temático de segmentação dos grãos, é avaliada a conexão espacial entre os pixels de mesma cor. Assim, os poros são individualizados, bem como os grãos que, por terem orientação muito próxima, tenham sido identificados pela mesma falsa cor. A reclassificação realizada deste modo resulta em um refinamento do processo de segmentação e produz imagens prontas para a análise individual de poros e grãos.

Em resumo, cada um dos grãos cristalinos ou poros é rotulado com um número (cada pixel de um mesmo grão recebe o mesmo rótulo), o qual representa o índice da partícula no vetor de características a ser construído.

Após a rotulagem foram extraídas de características geométricas, a partir das quais foram calculadas as características morfológicas usadas no processo de classificação dos grãos. As características geométricas são descritas nas próximas seções e as definições das características morfológicas são apresentadas no Apêndice A.

A cada um dos descritores visuais usados pelos geólogos para identificar os cristais de hematita foi associado um conjunto de características morfológicas cujos valores devem permitir a mesma identificação por um sistema de visão computacional, conforme a Tabela 4.1.


<b>Hematita granular</b>	
formatos regulares	razão perímetro área, razão de aspecto, circularidade
contatos retilíneos	circularidade, razão perímetro área
junções tríplices	não foram identificadas
<b>Hematita lamelar</b>	
cristais inequidimensionais	razão de aspecto
hábito tabular	razão de aspecto
contatos retilíneos	circularidade
cristais compactos	porosidade

**Tabela 4.1 – Descritores visuais e características morfológicas usadas na classificação dos cristais de hematita.**

Todos os métodos desenvolvidos neste trabalho, a saber, o pré-processamento para a remoção de artefatos de segmentação, a rotulagem dos cristais de hematita, a extração de características geométricas, o cálculo das características morfológicas e a classificação dos grãos cristalinos, foram implementados na linguagem Java.

## **4.2 Algoritmo de rotulagem**

Conforme mencionado na Seção anterior, para realizar a análise das partículas, foi necessário inicialmente implementar um algoritmos para indexá-las. Para isso foi usado como referência o algoritmo de rotulagem linha por linha (*Row-by-row Labeling*) descrito por Shapiro e Stockman (SHAPIRO e STOCKAMN, 2001). Este algoritmo, por sua vez é baseado em outro algoritmo clássico, conhecido como algoritmo dos componentes conectados (*connected components algorithm*), descrito por Rosenfeld em 1966 (SHAPIRO e STOCKAMN, 2001).




**Figura 4.1 – Rotulagem de componentes conectados (a) Imagem binária; (b) componentes conectados rotulados.**

O algoritmo faz duas passagens sobre a imagem: na primeira passagem atribui rótulos temporários aos pixels conforme as conexões vão sendo encontradas com pixels já rotulados, e na segunda cada rótulo temporário é substituído pelo rótulo de sua classe equivalente, à medida que são detectadas conexões entre que receberam rótulos diferentes na primeira passagem. Um algoritmo conhecido como *union-find* constrói dinamicamente as equivalências entre as classes geradas na primeira passagem. A estrutura de dados do algoritmo *union-find*, em forma de árvore, permite a construção e manipulação eficiente das equivalências encontradas.

PARENT

1	2	3	4	5	6	7	8
2	3	0	3	7	7	0	3



**Figura 4.2 - Estrutura de dados do algoritmo *union-find* para dois conjuntos de rótulos. O primeiro contém os rótulos {1,2,3,4, 8}, e o segundo conjunto contém os rótulos {5,6,7}.**

A Figura 4.2 apresenta uma estrutura de árvore para dois conjuntos de rótulos, construída na primeira passagem, e que é armazenada em um “array”

denominado “PARENT”. Os zeros atribuídos aos rótulos 3 e 7 indicam que eles não têm nenhum “pai” (PARENT). Os demais valores da tabela são lidos do seguinte modo: o rótulo 2 é o pai do rótulo 1, o rótulo 3 é o pai dos rótulos 2, 4 e 8 e assim por diante.

Ao procedimento *find* são fornecidos um rótulo X e o array PARENT. O algoritmo segue então árvore acima até encontrar o rótulo na “raiz” da árvore a que X pertence. Ao procedimento *union* são fornecidos dois rótulos (X e Y) e o array PARENT. Este procedimento então modifica a estrutura de dados (se necessário) para trocar o rótulo de X pelo rótulo de Y.

1	1	0	2	2	2	0	3
1	1	0	2	0	2	0	3
1	1	1	1	0	0	0	3
0	0	0	0	0	0	0	3
4	4	4	4	0	5	0	3
0	0	0	4	0	5	0	3
6	6	0	4	0	0	0	3
6	6	0	4	0	7	7	3

(a)

1	1	0	1	1	1	0	3
1	1	0	1	0	1	0	3
1	1	1	1	0	0	0	3
0	0	0	0	0	0	0	3
4	4	4	4	0	5	0	3
0	0	0	4	0	5	0	3
6	6	0	4	0	0	0	3
6	6	0	4	0	3	3	3

(b)

1	2	3	4	5	6	7
0	1	0	0	0	0	3

(c)

**Figura 4.3 – (a) Primeiro passo. (b) Segundo Passo. (c) estrutura union-find mostrando as equivalências**

Como o algoritmo de rotulagem linha por linha rotula imagens binárias, foram necessárias algumas alterações para realizar a rotulagem de imagens coloridas. A Figura 4.4 mostra (a) uma imagem colorida e, (b) os seus pixels rotulados para identificar regiões conexas de mesma cor. É interessante notar que os objetos 3 e 6 foram considerados não conectados. Esta é uma decisão tomada pelo usuário do método, que pode optar por outro critério de conexão, dependendo da informação prévia sobre a imagem.

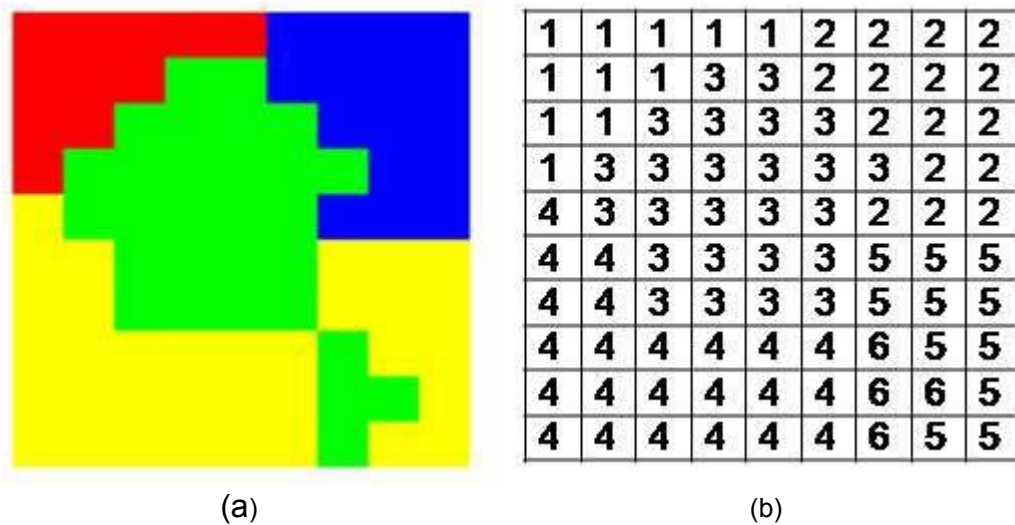


Figura 4.4 – Imagens colorida e seus pixels rotulados. São identificadas regiões conexas de mesma cor.

### 4.3 Características geométricas

#### 4.3.1 Área e área total

Para definir a área o algoritmo implementado faz-se uma busca na matriz de rótulos contando os pixels com rótulos iguais, ao final da contagem atribui esse número ao identificador do objeto.

A área total é calculada levando em conta os poros, presentes dentro das partículas, que para este cálculo, são considerados como parte integrante das partículas e somados a área da mesma.

#### 4.3.2 Perímetro

O perímetro é calculado utilizando a borda interna das partículas. Um pixel é identificado como borda da partícula se ele faz vizinhança com algum pixel de outra partícula. No algoritmo implementado foi utilizada uma vizinhança 4 conexas para determinar a borda das partículas, assim obtém-se uma borda 8 conexas.

1	1	1	1	1	2	2	2	2
1	0	1	3	3	2	0	0	2
1	1	3	0	0	3	2	0	2
1	3	0	0	0	0	3	2	2
4	3	0	0	0	3	2	2	2
4	4	3	0	0	3	5	5	5
4	4	3	3	3	3	5	0	5
4	0	4	4	4	4	6	5	5
4	0	0	0	0	4	6	6	5
4	4	4	4	4	4	6	5	5

Figura 4.5 – Matriz de rótulos da borda dos objetos

Os pixels da borda de cada partícula são ordenados do primeiro ao último pixel. Em seguida é analisada a adjacência dos vizinhos da borda pertencentes a mesma partícula. Para um vizinho com adjacência horizontal ou vertical é somado 1 ao perímetro da partícula, caso a adjacência com o vizinho seja diagonal é somado 1.4 ao perímetro.

#### 4.3.3 Ferret máximo e ferret mínimo

O algoritmo que define o ferret máximo calcula a distância euclidiana entre as coordenadas de todos os pixels pertencentes à borda da partícula, sendo que, a maior distância encontrada é definida como o ferret máximo da partícula.




Figura 4.6 – Retas dos ferrets. (A) Reta do Ferret máximo. (B) Reta do ferret mínimo

Encontrado os dois pontos mais distantes da partícula  $(I_{inicial}, J_{inicial}); (I_{final}, J_{final})$ , uma reta é traçada entre eles, esta reta é chamada de reta do ferret máximo.

$$y = a x + b \quad (4.1)$$

$$a = \frac{J_{final} - J_{inicial}}{I_{final} - I_{inicial}} \quad (4.2)$$

$$b = J_{inicial} - (a) I_{inicial} \quad (4.3)$$

Para o calculo do ferret mínimo o algoritmo encontra  $b$  para todos os pixels da borda (Pixel  $[I_0, J_0]$  até  $[I_n, J_n]$ ), armazenando o maior e o menor valor encontrados ( $B_{maior}$  e  $B_{menor}$ ).

Sendo que  $B$ , é o ponto em que uma reta, traçada paralela a reta do ferret máximo, corta o eixo  $y$  do plano cartesiano, sendo que essa reta passa por um pixel da borda da partícula. Assim obtém os dois pontos mais distantes da reta do ferret Maximo, pertencentes a partícula (Figura 4.7 - ponto A e B)




Figura 4.7 – Pontos para cálculo dos ferrets.  $A = B_{maior}$ .  $B = B_{menor}$ .  $C$  = ponto equivalente de A na reta do ferret máximo.  $D$  = ponto equivalente de B na reta do ferret máximo.

Em seguida calcula-se o ponto equivalente na reta do ferret máximo (Figura 5.7 - ponto C e D), que é dado pela fórmula:

$$X = \frac{B - b}{a + \frac{1}{a}} \quad (4.4)$$

$$Y = a x + b \quad (4.5)$$

Onde **a** e **b** são coeficientes da reta do ferret máximo.

Com as coordenadas dos pontos de  $B_{\text{maior}}$  e  $B_{\text{menor}}$ , (Figura 4.7 - ponto A e B) e as coordenadas dos pontos equivalentes na reta do ferret máximo (Figura 4.7 - ponto C e D), calcula-se a distancia entre os pontos A e C, e de B e D. O ferret mínimo é dado pela soma destas distâncias.

#### 4.4 Cálculo do comprimento e largura de fibra

O comprimento de fibra é um parâmetro que mostra o comprimento de um objeto alongado mesmo que ele esteja dobrado. Na Figura 4.8 é mostrado um objeto alongado (fibra) e esticado e outro, de mesmo comprimento, dobrado em “S”. Os dois objetos possuem o mesmo comprimento de fibra, assim como a mesma largura de fibra.




Figura 4.8 – Objetos com comprimento e largura de fibra iguais.

O comprimento e largura de fibra são calculados a partir do perímetro e da área do objeto pelas Equações A.4 e A.5 do apêndice A.



#### 4.5 Combinações de características

Combinações de características geométricas são usadas para caracterizar a morfologia de objetos de interesse. É fácil entender, por exemplo, que um objeto que tem um ferret máximo muito maior do que o ferret mínimo tem forma alongada, e que valores próximos destas medidas são características de um objeto mais compacto. Por isso, a razão entre o ferret máximo e o ferret mínimo pode ser usado para determinar o “grau de alongamento” de um objeto.

Há entretanto, dependendo da forma do objeto, situações especiais em que esta medida pode levar a uma falsa classificação, de modo que outras medidas que caracterizam o alongamento devem ser usadas de forma complementar. Na Figura 4.9 uma situação como esta é ilustrada. Uma fibra dobrada em “S” tem a mesma razão de aspecto que um objeto mais compacto, não podendo ser distinguidos por esta característica.

Para este caso em particular, definimos uma “razão de fibra” como a razão entre o comprimento de fibra (Eq. A4) e a largura de fibra (Eq. A5). Deve-se observar, por outro lado, que a fibra tem o mesmo comprimento e largura de fibra tanto dobrada em “S” como esticada, de modo que estas duas situações não podem ser distinguidas apenas pela razão de fibra, conforme é ilustrado na Figura 4.9.

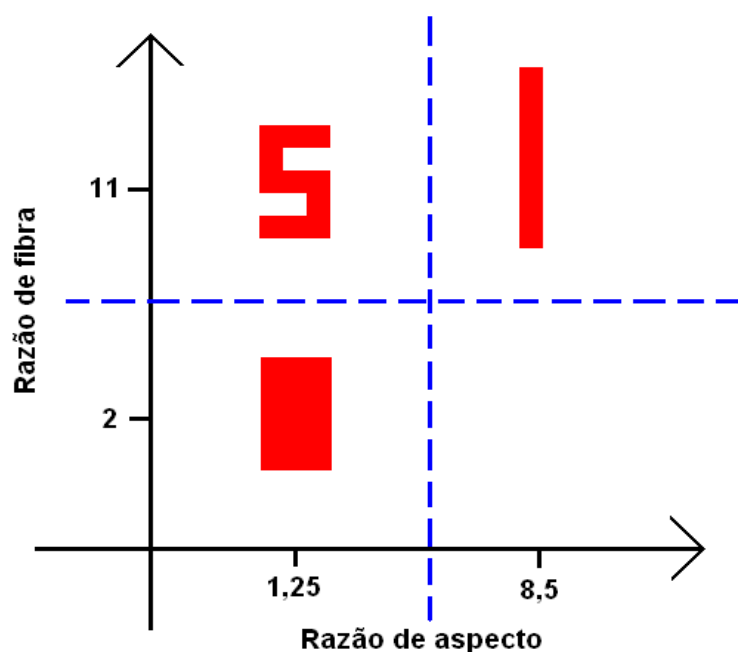


Figura 4.9 – Espaço de característica: Razão de fibra e Razão de aspecto

A classificação dos três tipos de objeto usados como exemplo na Figura 4.9 só é possível quando as duas características (razão de aspecto e razão de fibra) são usadas em combinação. Assim, o objeto compacto tem razão de aspecto e razão de fibra pequenos. A fibra esticada tem razão de aspecto e razão de fibra grandes. Finalmente, a fibra dobrada em “S” tem razão de fibra grande e razão de aspecto pequena.

As características morfológicas testadas e usadas no presente trabalho estão definidas no Apêndice A. É fácil examinar o significado de cada uma delas aplicando as fórmulas de definição a objetos geométricos simples como círculos, retângulos e estrelas, os quais podem ou não incluir “poros”.

A qualidade de um sistema de reconhecimento de padrões depende em grande parte da escolha de características que exibam valores diferentes para objetos pertencentes a classes diferentes.

## 5 Resultados alcançados

Ao iniciar os testes para a compilação dos resultados, foi realizada a rotulagem e a classificação da imagem segmentada utilizando o método proposto por Rosa (ROSA 2008).

Como pode ser observado na Figura 5.1, os grãos cristalinos detectados apresentam bordas que se prolongam, unindo um grão ao outro. Estes artefatos introduzem erro cálculo das características, entre elas o perímetro.

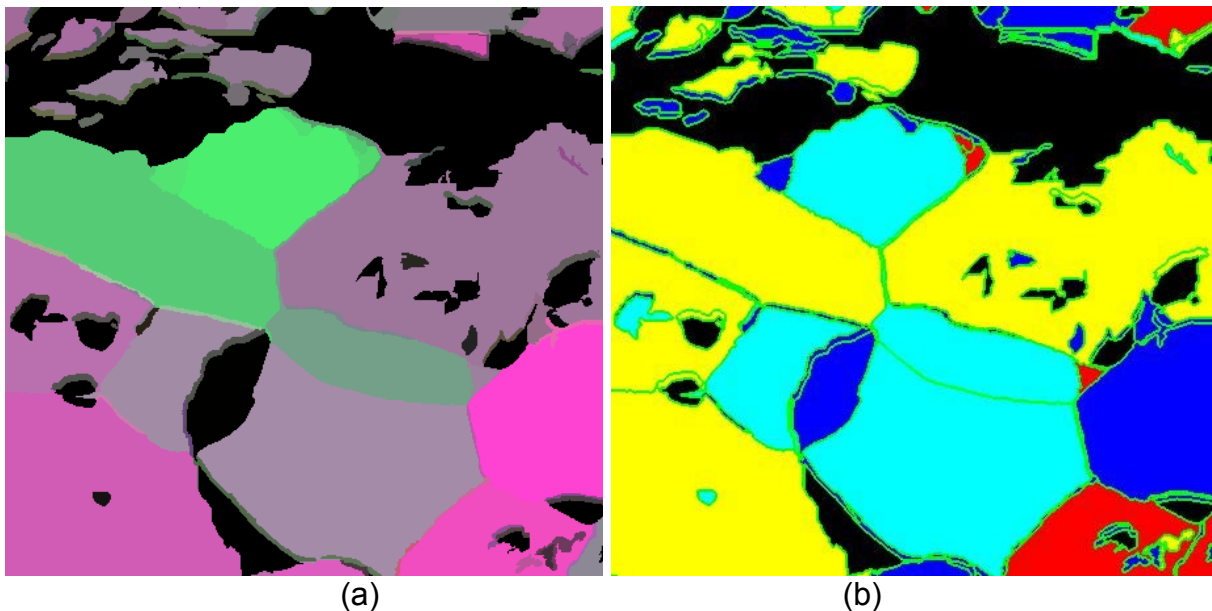


Figura 5.1 – (a) Fotomicrografia de minério de ferro segmentada pelo método desenvolvido por Rosa (ROSA, 2008). (b) Resultado da classificação dos grãos cristalinos. A imagem corresponde a uma região de 0,3mm X 0,3mm.

Este problema, juntamente com a já mencionada detecção de falsos grãos bordas pode ser resolvido com a aplicação de filtros morfológicos.

Depois de eliminados todos os artefatos e concluída a segmentação dos grãos é possível iniciar a extração das características, para a sua classificação. Como o problema de eliminação dos artefatos encontrados é resolvido por um procedimento padrão, foram testados especificamente os métodos de classificação, utilizando uma imagem segmentada manualmente, que é mostrada na Figura 5.2.

Esta imagem foi escolhida por apresentar grãos bem definidos de hematita granular (HG) e hematita lamelar (HL), as quais também podem ser porosas (HGP e HLP).




Figura 5.2 – Fotomicrografia com luz polarizada, obtida com objetiva de 5X e resolução de 750 pixels/mm. A imagem corresponde a uma região de 1,7mm X 1,3mm.

Após a segmentação os representantes de cada uma das classes foram recortados e montados em uma imagem para facilitar a busca de limiares entre os valores das características extraídas.

A imagem segmentada manualmente é mostrada na Figura 5.3 e a imagem editada, contendo grãos recortados da imagem original é mostrada na Figura 5.4.

As características geométricas extraídas e as características morfológicas calculadas das primeiras são mostradas na Tabela 5.1. Nem todas se mostraram úteis no processo de classificação.



Figura 5.3 – Fotomicrografia da Figura 5.2 (1,7mm X 1,3mm) segmentada manualmente




Figura 5.4 – Grãos recortados da fotomicrografia da Figura 5.2.

Grãos	Area	Área Total	Ferret Max	Ferret Min	Perimetro	Fator de Forma	Porosidade	Diâmetro Equivalente	Comprimento da fibra
2	23200	23200	206,3444	198,4837	817,4	0,002804	0	171,8696	340,5811
3	40684	49808	657,7933	415,3797	1142,4	0,002235	0,183183	227,5972	487,7963
4	60694	67888	564,413	260,4689	1419,6	0,001861	0,105969	277,9892	610,3604
6	29952	30606	873,1758	347,2886	965,6	0,002565	0,021368	195,2846	409,6913
18	8209	8380	1049,619	140,8006	400	0,003878	0,020406	102,2351	142,3202
36	18159	18713	1270,613	253,1313	731,6	0,003206	0,029605	152,0551	306,5665
79	8853	10549	840,934	177,7631	752,6	0,006765	0,160774	106,1696	351,0838
80	10388	10704	1114,049	233,5283	958	0,007339	0,029522	115,0061	456,2308
98	4907	4907	805,2739	125,8094	373,6	0,006059	0	79,04294	155,1783
111	13547	14072	873,1695	178,1842	1050,4	0,00617	0,037308	131,3338	497,997
133	3822	5249	1012,138	90,34338	439	0,00914	0,271861	69,75902	200,4311
137	5157	5157	110,5486	630,7541	405,2	0,006253	0	81,03145	172,7471

Grãos	Largura da Fibra	Área retangular	Roundness	Extend	Compactness	Aspect Ratio 3D	Aspect Ratio	Circularidade
2	68,11886	40956	0,693766	0,566462	0,832926	1,000194	2,039603	0,436344
3	83,40366	273234	0,119717	0,148898	0,346001	1,002043	2,583595	0,391739
4	99,43961	147012	0,242584	0,412851	0,492528	1,003288	3,166912	0,378463
6	73,1087	303244	0,050019	0,098772	0,223649	1,006273	3,514266	0,403684
18	57,67979	147787	0,009487	0,055546	0,097402	1,064547	8,454654	0,644733
36	59,23347	321632	0,014321	0,056459	0,119671	1,021977	6,019581	0,426338
79	25,2162	149487	0,01594	0,059223	0,126252	1,019828	5,730645	0,196414
80	22,76918	260162	0,010657	0,039929	0,103233	1,015743	5,770508	0,142236
98	31,62169	101311	0,009635	0,048435	0,098157	1,057824	7,400746	0,441786
111	27,20297	155585	0,022623	0,087071	0,15041	1,014853	5,900376	0,154292
133	19,0689	91440	0,00475	0,041798	0,068922	1,092968	12,20324	0,249213
137	29,85289	69729	0,53728	0,073958	0,732994	0,991858	1,175264	0,394701

**Tabela 5.1 – Características extraídas da imagem**

A primeira classificação separa os objetos compactos dos porosos. Para isso foi usada as características de porosidade e o fato de que os grãos compactos possuem uma circularidade maior do que os porosos, por terem um formato mais regular. No grupo dos grãos compactos foram classificados aqueles com porosidade menor do que 0,03 e com circularidade maior do que 0,39 (Figura 5.5)




Figura 5.5 – Grãos compactos extraídos da Figura 5.4.

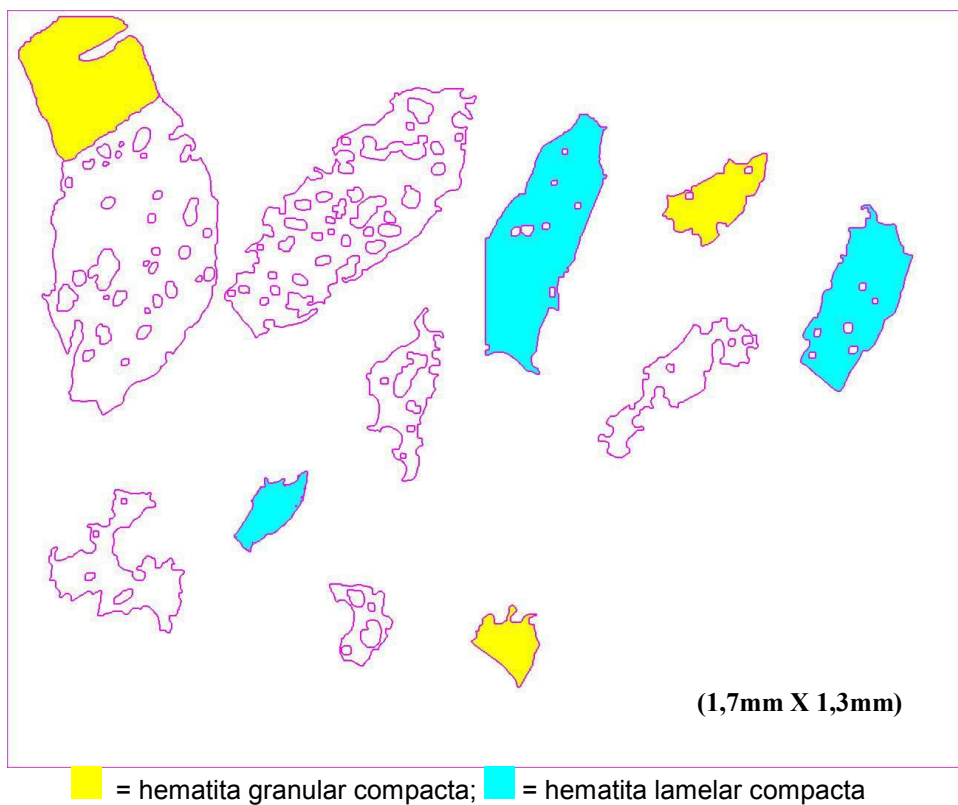
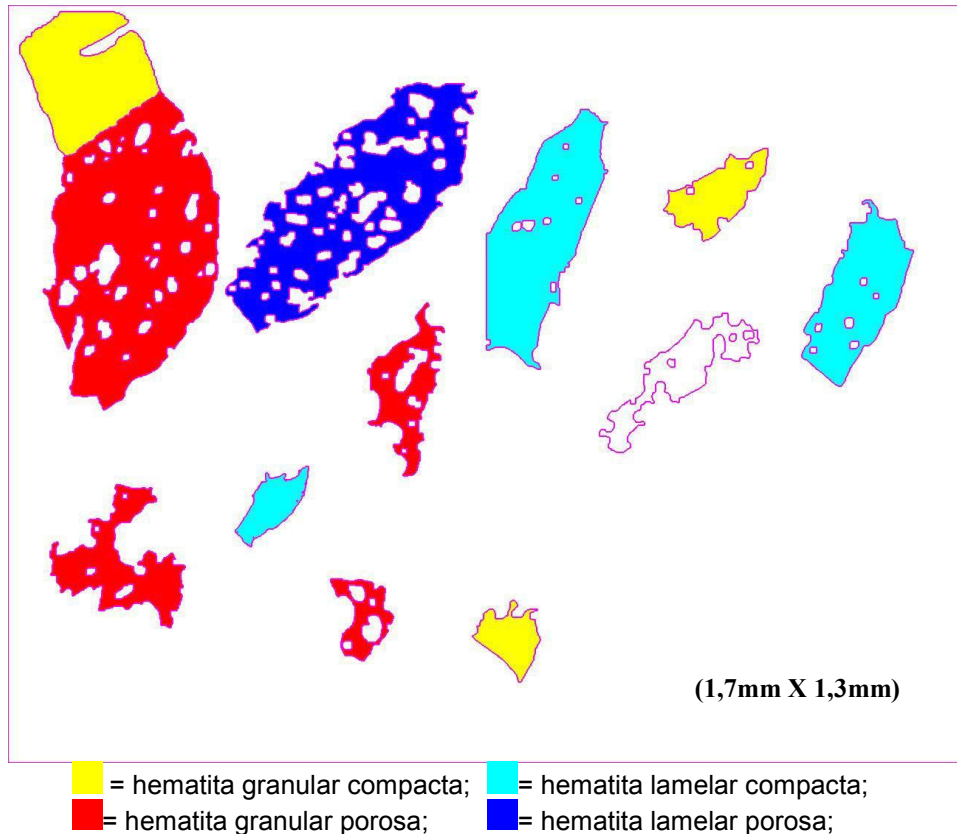



Figura 5.6 – Classificação dos grãos compactos da Figura 5.5 em granulares e lamelares







**Figura 5.8 – Identificação de grãos granulares porosos da fotomicrografia da Figura 5.4**



**Figura 5.9 – Todos os grãos da Figura 5.4 classificados.**

Para os objetos granulares houve um aumento na razão de fibra, também devido a aumento do perímetro em relação à área. Os grãos com razão de aspecto maior do que 3, e com razão de fibra menor do que 19, foram classificadas como granular porosa, (partículas vermelho figura 5.8)

Finalmente a última partícula com razão de aspecto maior do que 19, foi classificada também como lamelar porosa. (Figura 5.9)

A Figura 5.10 apresenta o fluxograma representativo dos liminares de decisão e suas respectivas características.

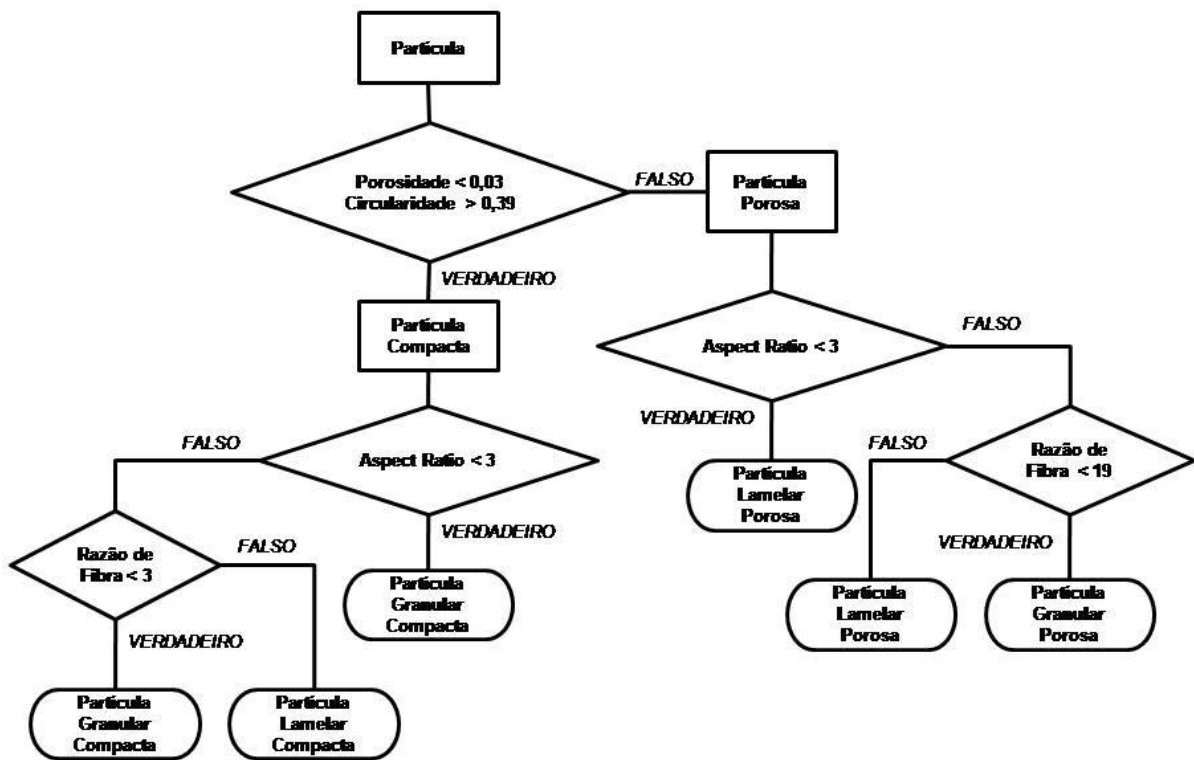


Figura 5.10 – Fluxograma demonstrando os limites de decisão para a classificação

Logo após a definição dos limiares foi aplicada a classificação na imagem original, a Figura 5.11 mostra um recorte da imagem original antes e depois do processamento e análise realizado pelo método implementado, onde pode ser observada a classificação das partículas dispostas na imagem original.

E, por fim, a Figura 5.12 apresenta o resultado da imagem original processada e classificada pelo método proposto neste trabalho

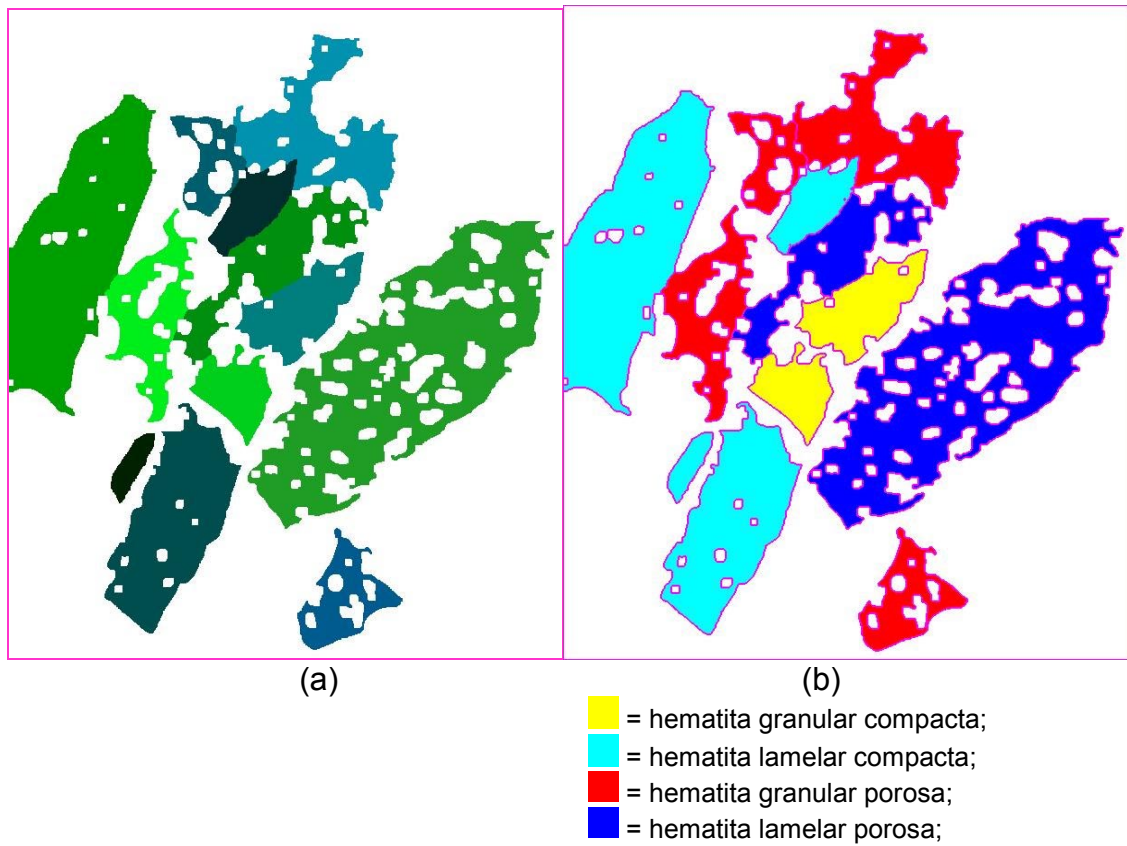


Figura 5.11 – Detalhe da Figura 5.3. (a) Original. (b) Grãos classificados.

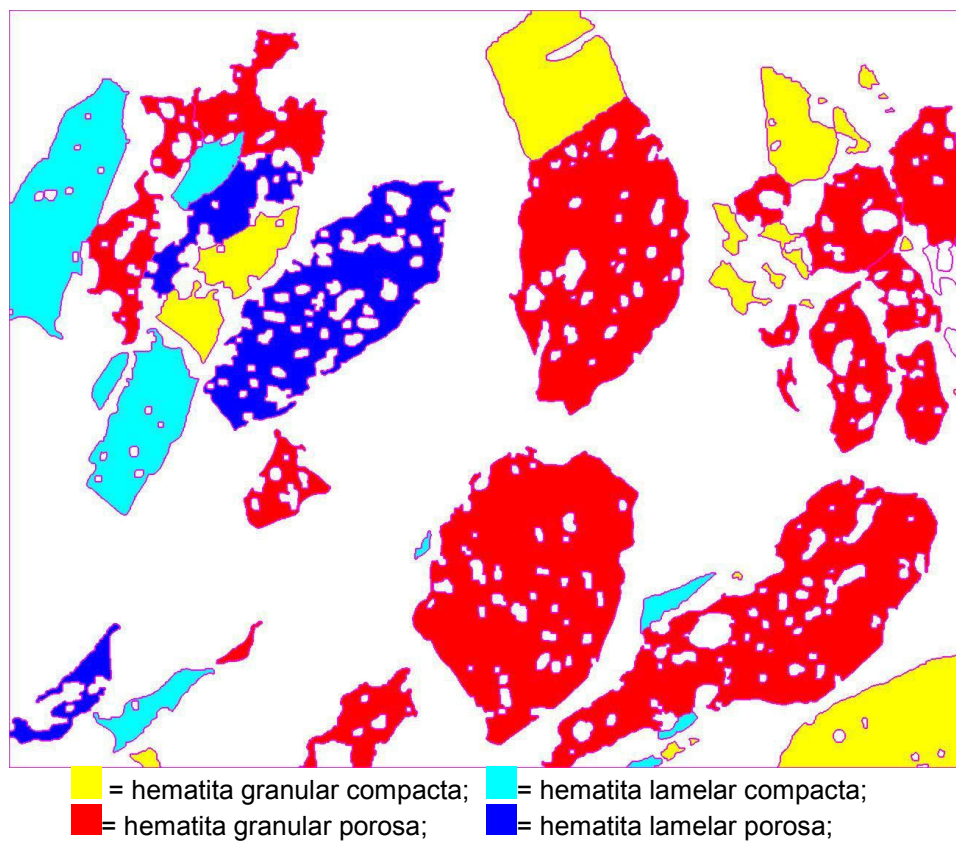


Figura 5.12 – Classificação dos grãos da fotomicrografia da Figura 5.2 (1,7mm X 1,3 mm).

## 6 Conclusões

No presente trabalho foi realizada a classificação de grãos de em hematita granular e lamelar, por um método supervisionado de reconhecimento de padrões. Para a implementação deste método devem ser estabelecidos valores limiares de características morfológicas medidas que permitam a distinção entre partículas pertencentes a diferentes classes.

Os cristais de hematita puderam ser classificados com base na sua porosidade, circularidade, razão de aspecto, e razão de fibra.

Ao nosso conhecimento, esta última característica não é mencionada na literatura.

Uma vez que qualquer segmentação apresenta artefatos, não sendo exceção aquele descrito por Rosa (ROSA 2008), estes devem ser eliminados com um pós-processamento, ou a caracterização deve ser iniciada com um pré-processamento.

Em vista disso, para dar continuidade a este trabalho, de desenvolvimento de um sistema de visão computacional para realizar a classificação automática de minério de ferro, é indispensável a integração ao sistema de filtros morfológicos em cor para o pós processamento da segmentação. Por outro lado, deve-se continuar a busca de características específicas para a classificação de outros tipos de partículas de minério de ferro.

Os métodos implementados no presente trabalho formam uma boa base sobre a qual novos métodos podem ser desenvolvidos e testados.

## 7 BIBLIOGRAFIA

BOX, J.; PHILLIPS, J.; CLOUT, J.M.F. **Use of geological material types for predicting iron ore product characteristics**. Proceedings of the 1st Japan–Australia Symposium on Iron and Steelmaking, Fuwa–Ward Symposium, ISIJ, Kyoto University. Japão, 2002.

CASTRO L. A. Minério de Ferro. In: ABM (Ed.) **Curso sobre matérias primas - Aglomeração e operação de Altos Fornos**. São Paulo, ABM, 1989. p. 5-58, 1989.

CLOUT, J. M .F.,. **The effects of ore petrology on downstream processing performance**: A review. Mine to Mill 1998 Conference. AusIMM, Brisbane, pp. 43–50, 1998.

CLOUT, J. M. F. **Upgrading processes in BIF-derived iron ore deposits: implications for ore genesis and downstream mineral processing**. Applied Earth Science , Vol. 112, 2003

COSTA, A. G. D.; ROCHA, J. M.; BONFIOLI, L. & VIEIRA, C. B. **A importância do modelamento geológico-tipológico** no controle de qualidade dos concentrados e pelotas de minério de ferro da Samarco Mineração S. A.. In: XXIX Seminário de redução de minério de ferro - XIII Seminário de controle químico em metalurgia - IX Seminário de carbomquímicos, Anais., 545 – 553, 1998.

CPRM. **Informativo do serviço geológico do Brasil**. Ano 4 número 16 edição de junho de 2007. Disponível em [www.cprm.gov.br](http://www.cprm.gov.br). Acesso em 18 agosto de 2008.

CVRD **Características estruturais dos finos SECA, SECE, e ALEGRIA que compuseram pilhas de desempenho ruim e excelente na Usiminas**. Relatório Interno 1, 22p.,1998.

DARROZES, J.; GAILLOT, P.; SAINT-BLANQUAT, M.; BOUCHEZ, J.L. **Software for multi-scale image analysis: the normalized optimized anisotropic wavelet coefficient method**. Computers & Geosciences, Vol. 23, No. 8, pp. 889-895, 1997.

DONSKOI, E., SUTHERS, S.P., FRADD, S.B., YOUNG, J.M., CAMPBELL, J.J., RAYNLYN, T.D., CLOUT, J.M.F. **Utilization of optical image analysis and automatic texture classification for iron ore particule characterization**. Minerals Engineering, v. 20, p. 461-471, 2007.

DONSKOI, E.; CLOUT, J.M.F. **Automated textural classification of iron ores using 'Recognition'** — A specialised software package for studying ores. Proceedings, Iron Ore 2005. AusIMM, Fremantle, pp. 203–211.

DONSKOI, E.; SUTHERS, S.P.; CAMPBELL, J.J.; RAYNLYN, T. **Modelling and optimization of hydrocyclone for iron ore fines beneficiation— using optical image analysis and iron ore texture classification.** Int. J. Miner. Process. 87 p. 106–119, 2008.

FORTEY, N.J. **Image analysis in mineralogy and petrology:** Mineral. Mineral Mag., v. 59, p. 117-178, 1995.

FUETEN, F. **A computer-controlled rotating polarizer stage for the petrographic microscope.** Computers & Geosciences, v.23, p. 203-208, 1997.

GAILLOT, P.; DARROZES, J.; BOUCHEZ, J.L. **Wavelet transform: a future of rock fabric analysis?** Journal of Structural Geology 21, pp. 1615-1621, 1999.

GOLDRING, D.C.; FRAY, T.A.T **The characterization of iron ores for production of high quality sinter.** Ironmaking and Steelmaking, v.16, n. 2 p. 83-89, 1989.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing.** 2.ed. Upper Saddle River, New Jersey: Prentice Hall, 2002.

GROSS, G. A. Industrial and genetic models for iron ore in Iron Formations, In: Kirkham, R. V., Sinclair, W. D., Thorpe, F. I. & Duke, J. M. (eds.) - **Mineral Deposit Modeling:** Geological Association of Canada, Special Paper 40, p. 151–170, 1993

HOUAIS, **Dicionário Eletrônico da Língua Portuguesa,** Versão 1.05a , Editora Objetiva, 2002.

HOWARTH, D.F., ROWLANDS, J.C. **Development of an index to quantify rock texture for qualitative assessment of intact rock properties.** Geotechnical Testing Journal, Vol. 9, No. 4, pp. 169-179, 1986.

HUNDERTMARK, A. **Reflexões sobre o desenvolvimento do tratamento de minério de ferro e perspectivas sobre a tecnologia do futuro.** In: I Simpósio Brasileiro de Minério de Ferro, Ouro Preto, Anais..., p. 629 – 654, 1996.

IBRAM, **Panorama mineral brasileiro** Disponível em <http://www.ibram.org.br> Acesso em 28 janeiro de 2008.

JAIN, A.K.; MURTY, M.N.; FLYNN, P. J. Data Clustering: a review, **ACM Computing Surveys**, v. 31, n. 3, set. 1999.

JAIN, A.K.; DUIN R.P.W.; MAO J. Statistical pattern Recognition: a review, **IEEE Transactions on Pattern analysis and Machine Intelligence**, v. 22, n. 1, jan. 2000.

KING, R .P.,. **Modelling & Simulation of Mineral Processing Systems**. Butterworth-Heinemann, Oxford, pp. 1–4, 2001.

KING, R. P.; SCHNEIDER, C.L. **Stereological correction of linear grade distributions for mineral liberation.**, Powder Technology, v.98, p. 21-37, 1998.

LUMBRERAS, F.; SERRAT, J. **Segmentation of petrographical images of marbles**, Computers & Geosciences, Vol. 22, p. 547-558, 1996.

LUMBRERAS, F.; SERRAT, J. **Wavelet filtering for the segmentation of marble images**, Computer Vision Center( CVC ) Tech.Rep. 005 January, 1996.

MDT Universidade Federal de Santa Maria. Pró-Reitoria de Pós-Graduação e Pesquisa. 6. ed. rev. e ampl. – Santa Maria,Ed. da UFSM, 2006

PIRARD, E. ; LEBICHOT, S. **Automated identification of iron oxides under the optical microscope**, Mineral Georesources and Geo-Imaging Group, GeomaC Department, Université de Liège, Liège, Belgium.2006.

PIRARD, E. **Multispectral imaging of ore minerals in optical microscopy**, Mineralogical Magazine, Université de Liège, Liège, Belgium, v.68(2), p.323 –333, April 2004.

PIRARD, E.; LEBICHOT, S.; KRIER, W. **Particle texture analysis using polarized light imaging and grey level intercepts**. Mineral Georesources and Geo-Imaging Group, GeomaC Department, Université de Liège, Liège, Belgium.2007.

PIRARD, E. ; LEBICHOT, S. **Automated identification of iron oxides under the optical microscope**, Mineral Georesources and Geo-Imaging Group, GeomaC Department, Université de Liège, Liège, Belgium.2006.

PRIKRYL, P. **Assessment of rock geomechanical quality by quantitative rock fabric coefficients: Limitations and possible source of misinterpretations**. Engineering Geology, 87, pp. 149–162, 2006.

RAUBER, Thomas W. **Pattern Recognition**. XVI Jornada de atualização em informática. Mini-curso Brasília - DF 1997

RODENACKER, K.; BENGTTSSON, E. **A feature set for cytometry on digitized microscopic images**. Analytical Cellular Pathology, v. 25, p. 1-36, 2003.

ROSA, Marlise. **Segmentação de grãos de hematita em amostras de minério de ferro** por análise de imagens de luz polarizada 2008. Dissertação (Mestrado em engenharia de produção). Universidade federal de Santa Maria. Santa Maria, 2008

RUSS, J. C. **The image processing handbook**. 3.ed. Raleigh, North Carolina: CRC Press LLC, 1999.

SÁ, K.G.; COSTA, G.M.; VIEIRA, C.B. **Efeito da composição mineralógica na resistência à compressão de pelotas de minério de ferro**. Tecnologia em Metalurgia e Materiais, v. 1, n. 2, p.18-22jan. 2004.

SHAPIRO, L; STOCKMAN, G. **Computer vision**. New Jersey: Prentice Hall, 2001.

SOMMERVILLE, I. **Engenharia de software**. São Paulo: Addison-Wesley, 2004.

SOUZA NETO, A. N.; CAPOLARI, L. & SILVA NETO, P. P. **Ênfase da pesquisa de minério de ferro no centro de pesquisas da CVRD**. XXIX Seminário de redução de minério de ferro – XIII Seminário de controle químico em metalurgia - IX Seminário de carboquímicos, ABM, Belo Horizonte, Anais, p. 555 – 565, 1998.

TAKEHARA, L. **Caracterização geometalúrgica dos principais minérios de ferro brasileiros – fração sinter feed**. 2004. 419f. Tese (Doutorado em Geociências) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

VIEIRA, C. B.; SESHADRI, V.; PENA, E. Q. & ROSIÈRE, C. A. **Avaliação técnica de minérios de ferro para sinterização nas siderúrgicas e minerações brasileiras: Análise crítica**. XXIX Seminário de redução de minério de ferro – XIII Seminário de controle químico em metalurgia - IX Seminário de carboquímicos, ABM, Belo Horizonte, Anais, p. 555 – 565, 1998.

VIEIRA, C. B.; ROSIÈRE, C. A.; SESHADRI, V.; ASSIS, P. S.; COELHO, L. H. & PENA H. Q. **Geometallurgical approach for quality control of iron ores for agglomeration in iron and steel industry**. International symposium on beneficiation agglomeration and environment – ISBAN, Bhubaneswar, Índia, Proceedings, p. 1-7, 2000.



VIEIRA, E. et al. **Avaliação técnica de minérios de ferro para sinterização nas siderúrgicas e minerações brasileiras: uma análise crítica**. REM: R. Esc. Minas, Ouro Preto, v. 20, p. 97-102, 2003.

YANG, G.Z., GILLIES, D.F. **Computer Vision**, Department of Computing, Imperial College. Disponível em [www.doc.ic.ac.uk/~gzy](http://www.doc.ic.ac.uk/~gzy). Acesso em 09 de agosto de 2008.

ZAVAGLIA, G. **Condicionantes geológicos do comportamento dos minérios de ferro do Depósito de Tamanduá (MG) no processo metalúrgico de redução direta**. Dissertação (Mestrado em Geologia) Departamento de Geologia, Universidade Federal de Ouro Preto, Ouro Preto, 1995.

## APÊNDICE A – Características Morfológicas

Fator de Forma:

$$\frac{\textit{perímetro}}{4 * \pi * \textit{área}} \quad (\text{A.1})$$

Porosidade:

$$1 - \left( \frac{\textit{área}}{\textit{área total}} \right) \quad (\text{A.2})$$

Diâmetro Equivalente:

$$2 * \sqrt{\frac{\textit{área}}{\pi}} \quad (\text{A.3})$$

Comprimento de Fibra:

$$0,25 * (\textit{perímetro} + \sqrt{\textit{perímetro}^2 - (16 * \textit{área})}) \quad (\text{A.4})$$

Largura de Fibra:

$$0,25 * (\textit{perímetro} - \sqrt{\textit{perímetro}^2 - (16 * \textit{área})}) \quad (\text{A.5})$$

Razão de Fibra

$$\frac{\textit{comprimento de fibra}}{\textit{largura de fibra}} \dots\dots\dots (\text{A.6})$$

Área Retangular:

$$\textit{ferret máximo} * \textit{ferret mínimo} \quad (\text{A.7})$$

Redondeza (Roundness):

$$\frac{4 * \text{área}}{\pi * (\text{ferret máximo})^2} \quad (\text{A.8})$$

Extensão (Extend):

$$\frac{\text{área}}{\text{área retangular}} \quad (\text{A.9})$$

Densidade (Compactness):

$$\frac{\sqrt{\frac{4 * \text{área}}{\pi}}}{(\text{ferret máximo})} \quad (\text{A.10})$$

Razão de aspecto (Aspect ratio):

$$\frac{\text{ferret máximo}}{\text{ferret mínimo}} \quad (\text{A.11})$$

Razão de aspecto 3D (3D Aspect Ratio):

$$1 + \left( \left( \frac{4}{\text{perímetro}} \right) * ((\text{aspect ratio}) - 1) \right) \quad (\text{A.12})$$

Circularidade:

$$\frac{(4 * \pi * \text{área})}{\text{perímetro}^2} \quad (\text{A.13})$$