

CARACTERIZAÇÃO AUTOMÁTICA DE MINÉRIO DE FERRO POR MICROSCOPIA DIGITAL E ANÁLISE DE IMAGENS*

Julio César Álvarez Iglesias¹
Karen Soares Augusto²
Otávio da Fonseca Martins Gomes³
Alej Leite Alcântara Domingues⁴
Maria Beatriz Vieira⁵
Catia Casagrande⁶
Sidnei Paciornik⁷

Resumo

Foi desenvolvido um sistema automático para classificação mineralógica e textural de minério de ferro, baseado em microscopia digital, processamento e análise de imagens. O sistema captura imagens em mosaico cobrindo áreas representativas de amostras de *pellet feed*. As imagens são capturadas tanto em campo claro, que permite discriminação mineralógica por tonalidade, quanto no modo de polarização circular, que revela a orientação cristalina dos cristais de hematita. Diferentes classificadores automáticos discriminam hematitas compactas de não-compactas, partículas policristalinas de monocristalinas, e identificam as partículas como granulares, lamelares e lobulares. Todo o procedimento é automático, sem interferência do operador, e produz um relatório automático contendo as imagens representativas e valores de fração de área das diversas fases e grupos texturais.

Palavras-chave: Minério de Ferro; Hematita; Classificação Automática; Análise de Imagens.

AUTOMATIC CHARACTERIZATION OF IRON ORE BY DIGITAL MICROSCOPY AND IMAGE ANALYSIS

Abstract

An automatic system was developed for mineralogical and textural classification of iron ore, based on digital microscopy, image processing and analysis. The system captures mosaic images covering representative areas of pellet feed samples. The images are captured both in bright field, which allows mineralogical discrimination by hue, and in circular polarization mode, which reveals the crystalline orientation of the hematite crystals. Different automatic classifiers discriminate compact from non-compact hematite, polycrystalline from monocrystalline particles, and identify the particles as granular, lamellar and lobular. The entire procedure is automatic, without operator interference, and produces an automatic report containing the representative images and area fraction values of the various phases and textural groups.

Keywords: Iron Ore; Hematite; Automatic Classification; Image Analysis.

¹ Físico. D.Sc. Pós-doutorando. DEQM PUC-Rio. Rio de Janeiro, RJ, Brasil.

² Eng. Química. D.Sc. Pós-doutorando. DEQM PUC-Rio. Rio de Janeiro, RJ, Brasil.

³ Eng. Químico. D.Sc. Tecnologista Sênior. Centro de Tecnologia Mineral (CETEM), MCTI

⁴ Geólogo. Coordenador Técnico do Laboratório de Caracterização de Materiais. Centro de Tecnologia de Ferrosos, Vale. Nova Lima, MG, Brasil.

⁵ Geóloga.

⁶ Geóloga. M.Sc. Engenheira Sênior. Diretoria de Pelotização, Vale. Vitória, ES, Brasil.

⁷ Eng. Eletrônico e Físico. D.Sc. Professor Associado. DEQM PUC-Rio. Rio de Janeiro, RJ, Brasil.

1 INTRODUÇÃO

Na indústria mineral, a caracterização microestrutural (mineralógica e textural) do minério de ferro e seus aglomerados é tradicionalmente realizada por operadores humanos, pela observação de amostras ao Microscópio Óptico de Luz Refletida (MO), para identificar as fases presentes e estimar suas frações. Esse é um procedimento rotineiro, realizado algumas vezes por dia e conseqüentemente suscetível a falhas decorrentes da fadiga humana, além de erros aleatórios diversos. Deste modo, tem havido um interesse crescente no desenvolvimento de sistemas automáticos de análise quantitativa que possam conferir maior reprodutibilidade, confiabilidade e velocidade. Em um projeto conjunto entre a PUC-Rio e a Vale, novos métodos baseados em microscopia digital e análise de imagem vem sendo desenvolvidos e implementados nos laboratórios da empresa, há alguns anos.⁽¹⁻⁶⁾

Foi assim que surgiu a ideia de englobar as técnicas de caracterização de minério de ferro, antes desenvolvidas, com o intuito de unificá-las numa análise completa deste material. Para isto foram criadas duas rotinas totalmente automáticas, uma para a captura e outra para o processamento e a análise das imagens. O escopo deste trabalho é detalhar a metodologia desta análise.

A grande maioria dos minérios de ferro brasileiros é essencialmente hematítica, geralmente envolvendo outros minerais como magnetita, goethita e minerais de ganga, principalmente quartzo. No entanto, estes minérios apresentam grande diversidade de microestruturas. Sistemas automáticos de análise de imagens são capazes de identificar hematita, magnetita e goethita pelas suas tonalidades em imagens obtidas em campo claro (CC) pelo MO.

A hematita, por exemplo, é um mineral fortemente anisotrópico que apresenta pleocroísmo de reflexão (birrefletância). Isto faz com que o brilho na imagem mude com diferentes orientações dos cristais. Assim, quando se utiliza luz polarizada, o contraste entre os cristais aumenta o suficiente para diferenciá-los.

A Vale classifica os cristais de hematita como: granular, lamelar, lobular, microcristalina ou martita, segundo sua morfologia e textura. As hematitas granular, lamelar e lobular são chamadas de hematitas compactas, enquanto a microcristalina e a martita são chamadas de não-compactas.

Desta forma a ideia é capturar, de forma automática, imagens mosaico em CC para identificar através delas as diferentes fases mineralógicas (hematita, magnetita e goethita). Estas fases são identificadas pelas suas tonalidades usando segmentação por limiar. Contudo, imagens capturadas em CC não permitem a visualização dos cristais da hematita. Para isto é necessário usar luz polarizada.

Assim, outro mosaico da mesma região, desta vez com luz polarizada, também será capturado. A imagem polarizada é usada para identificar os diferentes tipos de hematita. Desta forma, a hematita compacta é discriminada da hematita não compacta através de uma classificação supervisionada usando parâmetros de textura Haralick.⁽⁷⁾ Por sua vez a hematita compacta é classificada em granular, lamelar ou lobular segundo a sua morfologia.

O número e o tamanho dos mosaicos são definidos de modo que os resultados quantitativos obtidos sejam estatisticamente representativos da amostra analisada. Finalmente, os resultados alcançados nesta análise são combinados em um relatório gerado, também de forma automática.

2 MATERIAIS E MÉTODOS

2 Preparação de Amostras

Frações de finos de minério de ferro, fornecidos pela Vale, foram embutidas em resina epóxi e posteriormente desbastadas e polidas. O processo de desbaste das seções foi iniciado com disco metálico com partículas de diamante de 70 μm passando, em seguida, pelos de granulação 40, 15, 9 e 6 μm . Este desbaste foi realizado com água durante 2 min, nas três primeiras granulações, e durante 4min, nas duas últimas.

Quando terminado o processo de desbaste, as seções foram levadas ao banho ultrassônico para eliminar resíduos, evitando deste modo arranhá-las durante o polimento. O processo de polimento foi realizado com panos e suspensões diamantadas de 3 e 1 μm durante 1h, gerando seções polidas com 30 mm de diâmetro.

2.2 Microscopia Ótica Digital

Na aquisição de imagens foi utilizado um microscópio óptico motorizado e controlado por computador Zeiss AxioImager.M2m com câmera digital Zeiss AxioCam MRc5 de resolução máxima 2584x1936 pixels. O microscópio é controlado através do software AxioVision 4.9.1 o qual permite uma programação mais simples na linguagem de script e outra mais complexa na linguagem VBA (VB6.0). Todas as imagens foram obtidas com a lente objetiva de 20X (EC Epiplan 20X/0,40 HD M27) no modo RGB, com uma quantização de 24 bits e resolução da câmera de 1292x968 pixel, levando a uma resolução espacial de 0,53 $\mu\text{m}/\text{pixel}$.

Em trabalhos anteriores, o grupo de pesquisa em microscopia digital do DEQM/PUC-Rio desenvolveu uma rotina para identificar e classificar os diferentes tipos de hematitas através de imagens polarizadas.⁽¹⁾ Com o intuito de aprimorar esta rotina, algumas mudanças foram incorporadas a fim de otimizar as etapas de captura e de processamento de imagens polarizadas.

A nova rotina utiliza imagens com polarização circular (CPOL) para identificar e classificar os tipos de hematita.⁽²⁾ Contudo, o uso do recurso CPOL criava um gradiente de iluminação que degradava a qualidade da imagem, especialmente quando era capturada em forma de mosaico. Este problema de iluminação era corrigido através de uma subtração de fundo, mas a imagem resultante apresentava borramento, o que diminuía, em parte, o contraste entre os cristais de hematita.

Assim, aproveitando as características das câmeras científicas digitais, mais uma mudança foi implementada, desta vez apenas na etapa de captura das imagens CPOL.⁽³⁾ Em lugar de capturar as imagens em campo completo da câmera (*full frame*), passou-se a capturar imagens de subcampos (*subframes*) centrados, aproveitando a região com iluminação mais homogênea. Desta forma, otimizando o tamanho do *frame* da câmera, é possível capturar imagens CPOL com fundo uniforme. Outra melhoria incorporada aproveita o controle digital de saturação da cor na câmera. A saturação da cor, na hora de capturar as imagens CPOL, permite aumentar ainda mais o contraste entre os cristais de hematita.

O uso de *subframes* (200x200 pixel) faz com que o tempo de captura das imagens CPOL aumente consideravelmente, uma vez que o MO deve que capturar um número bem maior de imagens menores para varrer a mesma região que em *full frame* (1292x968 pixel). Contudo, este problema é minimizado com a automação da

* Contribuição técnica ao 47º Seminário de Redução de Minério de Ferro e Matérias-Primas e 5º Simpósio Brasileiro de Aglomeração de Minério de Ferro, parte integrante da ABM Week, realizada de 02 a 06 de outubro de 2017, São Paulo, SP, Brasil.

rotina. Anteriormente, para capturar estas imagens o operador tinha que posicionar a platina do microscópio manualmente no lugar certo, definir o tamanho do mosaico, ajustar as condições de captura (iluminação, filtros, polarizadores, tempo de exposição, ajuste do branco, saturação e tamanho do frame da câmera) para CC e para CPOL. Todos estes ajustes manuais faziam com que o tempo de uso do microscópio para a captura em *full frame* fosse similar ao tempo gasto pela rotina automática usando subframes. Além disto, o método de captura manual retinha o operador na manipulação do MO. Agora com a rotina de captura automática o operador fica livre para se dedicar a outras tarefas - na verdade ele só precisa colocar a amostra no MO, centrá-la e especificar onde as imagens serão salvas. Assim, 3 pares de mosaicos CC e CPOL de tamanho 6x3 (full frame) e 49x25 (subframes), respectivamente, são capturados por amostra. Os ajustes no microscópio e na câmera das condições de captura, para cada tipo de imagem, são previamente definidos. Estes valores são carregados automaticamente na rotina antes de começar a captura. Da mesma forma, as posições dos mosaicos na amostra são previamente definidos. Finalmente, os mosaicos são montados a partir de imagens de campos individuais, parcialmente sobrepostos, obtidas com ajuda de um estágio motorizado com foco automático.⁽⁸⁾ O tempo de captura dos 3 pares de mosaicos é de aproximadamente 90 minutos. Na Figura 1(a) e 1(b) pode-se observar um par de imagens CC e CPOL, respectivamente, obtidos por esta rotina. É bom salientar que estas imagens são apenas uma pequena região dos mosaicos capturados. Isto se deve a que o tamanho dos mosaicos originais impediriam observar em detalhe as estruturas mais finas.

3 RESULTADOS E DISCUSSÃO

3.1 Processamento e Análise de Imagens

Todas as etapas do processamento e análise de imagens foram realizadas nos softwares FIJI (Fiji Is Just ImageJ), uma implementação do conhecido software ImageJ, e Octave, um software livre desenvolvido para computação matemática e muito parecido com MATLAB.^(9,10) Por sua vez, a paralelização multicore, com o intuito de acelerar o processamento, e a integração dos softwares FIJI e Octave, foi feita na linguagem de programação Scheme.⁽¹¹⁾

Como pode ser observado das Figuras 1(a) e 1(b) as imagens CC e CPOL não estão corretamente alinhadas. Isto se deve basicamente a dois fatores, o primeiro é a diferença de tamanho dos frames de captura (full frame nas CC e subframes nas CPOL), e o segundo é o mecanismo de polarização circular que gera um pequeno deslocamento entre os campos CC e CPOL.

Assim, o primeiro passo da rotina de processamento será corrigir este problema. O registro destas imagens é muito importante uma vez que, como vai ser detalhado mais adiante, a hematita segmentada da imagem CC será usada como máscara binária na imagem CPOL. De tal modo, se estas imagens não estivessem corretamente registradas as partículas seriam deformadas.

As imagens corretamente registradas podem ser observadas nas figuras 1(c) e 1(d). Este registro automático foi realizado usando o plugin do FIJI Linear Stack Alignment with SIFT. Este procedimento detecta pontos homólogos nas duas imagens com o método SIFT e usa esses pontos em uma transformação espacial para coincidir com as posições dos pontos e registrar as imagens.⁽¹²⁾ Neste caso foi utilizado uma

* Contribuição técnica ao 47º Seminário de Redução de Minério de Ferro e Matérias-Primas e 5º Simpósio Brasileiro de Aglomeração de Minério de Ferro, parte integrante da ABM Week, realizada de 02 a 06 de outubro de 2017, São Paulo, SP, Brasil.

transformação afim e, após o registro, pode-se observar que há um excelente alinhamento entre as duas imagens.




Figura 1. Imagens CC e CPOL: (a), (b) Após serem obtidas pela rotina de captura; (c) e (d) Após serem registradas pela rotina de processamento.

Uma vez registradas as imagens pode-se proceder para a seguinte etapa do processamento. A Figura 2 mostra o fluxograma da rotina a fim de facilitar uma melhor compreensão das próximas etapas.

De acordo com o fluxograma, apenas a imagem CC serve como imagem de entrada na etapa de identificação de fases. Nesta etapa as diferentes fases mineralógicas são identificadas pelas suas tonalidades através de uma segmentação por limiar.

Como a distância tonal entre estas fases é relativamente grande, torna-se fácil definir limiares fixos que as delimitem. Estes limiares permanecem constantes sempre que as condições de captura, tais como tempo de exposição, ajuste do branco, iluminação e filtros, fiquem invariantes. Esta reprodutibilidade é precisamente uma das vantagens do uso da rotina de captura automática em contraposição ao operador humano.

Não obstante, outros passos de pré e pós processamento são usados antes e depois da segmentação para garantir uma correta identificação de cada fase. Como exemplo de pré-processamento foi usado uma função do AxioVision chamada *delin* que torna mais abrupta a transição tonal entre as fases, diminuindo desta forma o conhecido efeito halo na segmentação. No pós-processamento foi usado uma abertura euclidiana a fim de eliminar, por completo, resquícios do efeito halo e demais objetos espúrios remanescentes da segmentação.

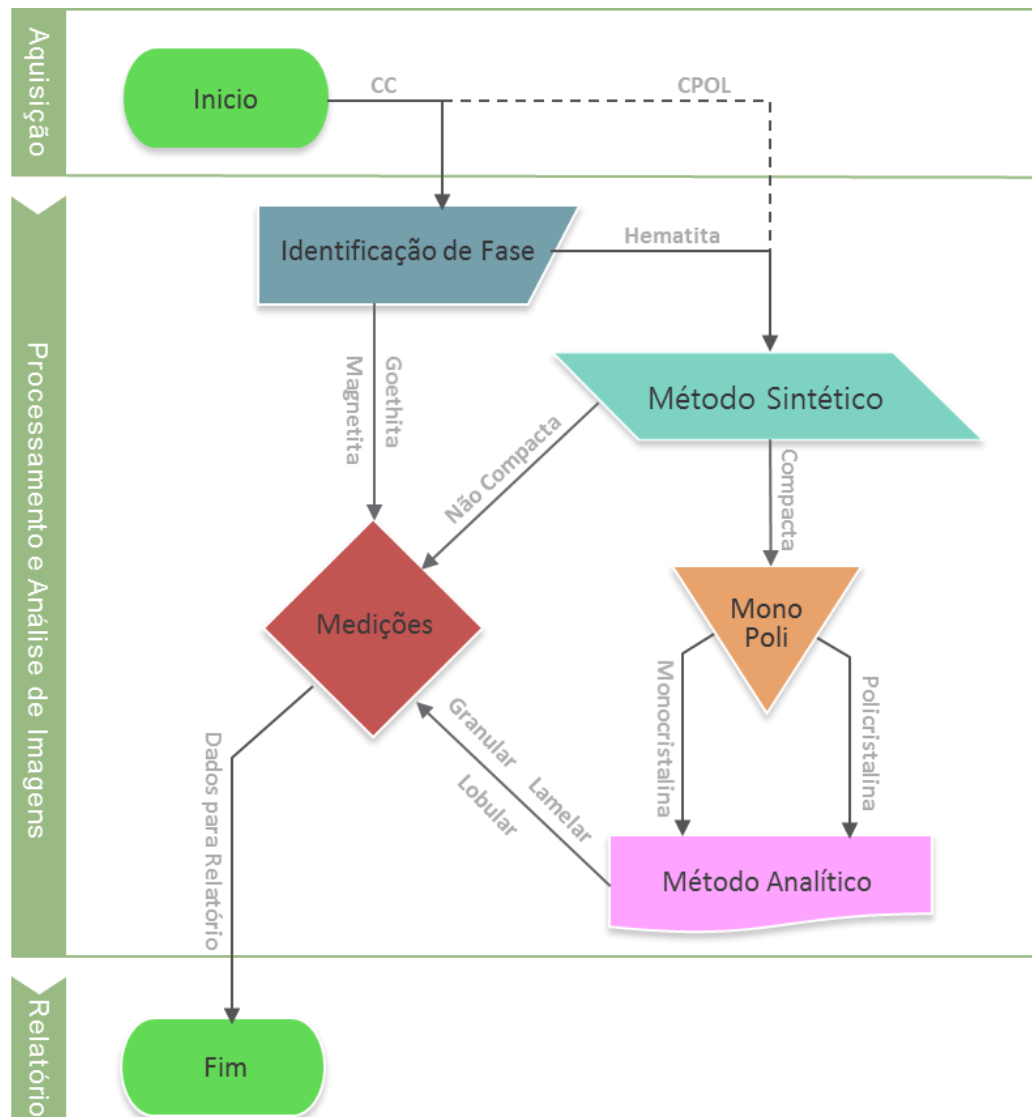


Figura 2. Fluxograma da rotina.

Finalmente o resultado da etapa de identificação de fases são as regiões de hematita, magnetita e goethita, como pode ser observado na Figura 3b. Neste caso foram dadas cores artificiais às fases para diferenciá-las, onde a hematita está representada em ciano, a magnetita em amarelo e a goethita em magenta (neste campo a magnetita tem fração de 1%, e não é visível). Do fluxograma pode-se observar que as fases magnetita e goethita passam diretamente para a etapa de medidas enquanto a hematita serve como imagem de entrada para a etapa seguinte da rotina, denominada “Método Sintético”.

O “Método Sintético” usa como imagem de entrada a máscara binária da hematita e a imagem CPOL. Esta máscara é essencial para separar a fase hematita na imagem CPOL (Na figura 3c), através de uma operação lógica de intersecção. O próximo passo do método sintético é a discriminação das hematitas não-compactas (Figura 3d) das compactas (Figura 3e), através de uma classificação supervisionada usando parâmetros de textura Haralick. Neste caso foi utilizado um classificador quadrático, treinado com um conjunto de imagens conhecidas e cuja taxa de acerto global foi superior ao 90%.




Figura 3. Resultados qualitativos da rotina: (a) Imagem CC; (b) Fases mineralógicas identificadas (hematita em ciano, magnetita em amarelo (não visível) e goethita em magenta); (c) Imagem CPOL; (d) Hematita porosa; (e) Hematita compacta; (f) Partículas monocristalinas; (g) Partículas policristalinas e (h) Tipos de hematitas compactas (granular em vermelho, lamelar em verde e lobular em azul).

A hematita não compacta passa diretamente para a etapa de medidas, enquanto a hematita compacta serve como imagem de entrada para a próxima etapa do fluxograma denominada “Separação Mono-Poli”.

Como o nome sugere, esta etapa tem por objetivo separar as partículas de hematita monocristalinas (Figura 3f) das policristalinas (Figura 3g). Este tipo de discriminação também é feito através de uma classificação supervisionada, desta vez, usando medidas morfológicas das partículas e dos cristais. Como no caso anterior, também foi utilizado um classificador quadrático, treinado com um conjunto de imagens conhecidas e teve uma taxa de acerto superior a 90%.

Finalmente, as imagens de hematita monocristalina e policristalina passam pela etapa chamada de “Método Analítico”, é encarregado de classificar as partículas em granular, lamelar ou lobular (Figura 3h). Esta classificação, como a anterior, é uma classificação supervisionada que usa medidas morfológicas apenas das partículas. Da mesma forma que nos outros dois casos, foi utilizado um classificador quadrático, treinado com um conjunto de imagens conhecidas e teve uma taxa de acerto superior ao 90%.

Assim, todos os resultados das etapas anteriores passam para a etapa onde são gerados os resultados quantitativos, chamada de “Medições”. O primeiro resultado obtido é a fração de área das fases mineralógicas mais a martita (Figura 4). As fases de hematita, magnetita e goethita podem ser medidas da imagem resultante da etapa de identificação de fases, contudo a martita não pode ser identificada nesta etapa, uma vez que ela está composta por hematita e magnetita. Assim, a martita tem que ser medida da imagem resultante do método sintético, especificamente da hematita porosa.

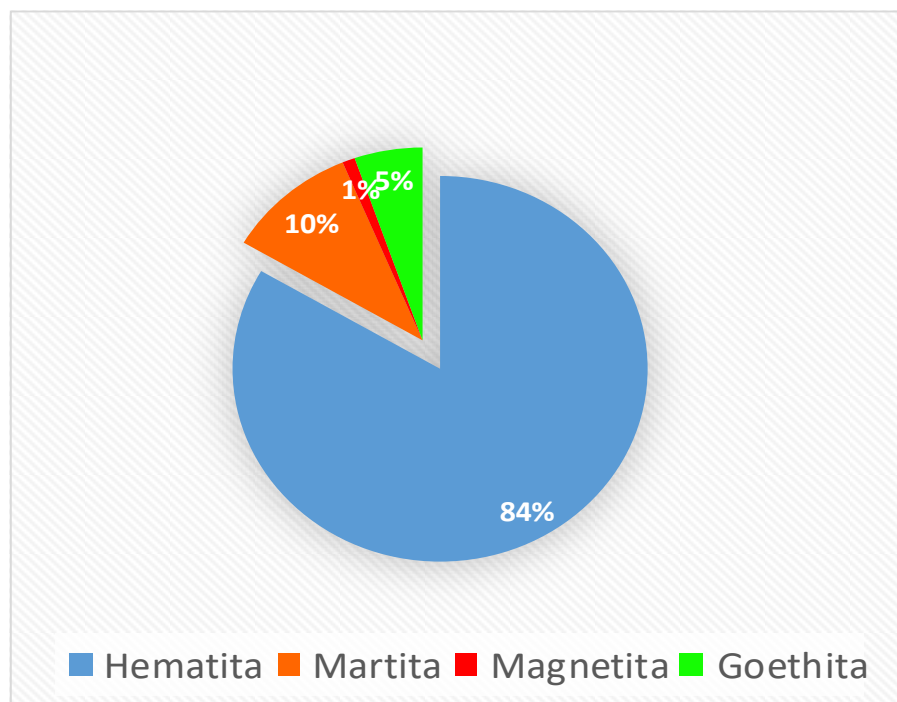


Figura 4. Fração de área das fases mineralógicas mais martita.

É bom salientar que no caso particular deste minério não é necessário separar martita de hematita microcristalina, uma vez que este minério não possui hematita microcristalina. Assim, toda a hematita não compacta pode ser contabilizada como

martita. No caso que o minério tivesse hematita microcristalina, o método sintético geraria uma imagem colorida, para diferenciar a martita da hematita microcristalina. Outro resultado quantitativo que é obtido da etapa de medidas é a fração de área das partículas de hematita monocristalinas e policristalinas (Figura 5).




Figura 5. Fração de área das partículas de hematita mono e policristalinas.

Finalmente, na Figura 6 pode-se observar o resultado da fração de área dos tipos de hematita compacta.

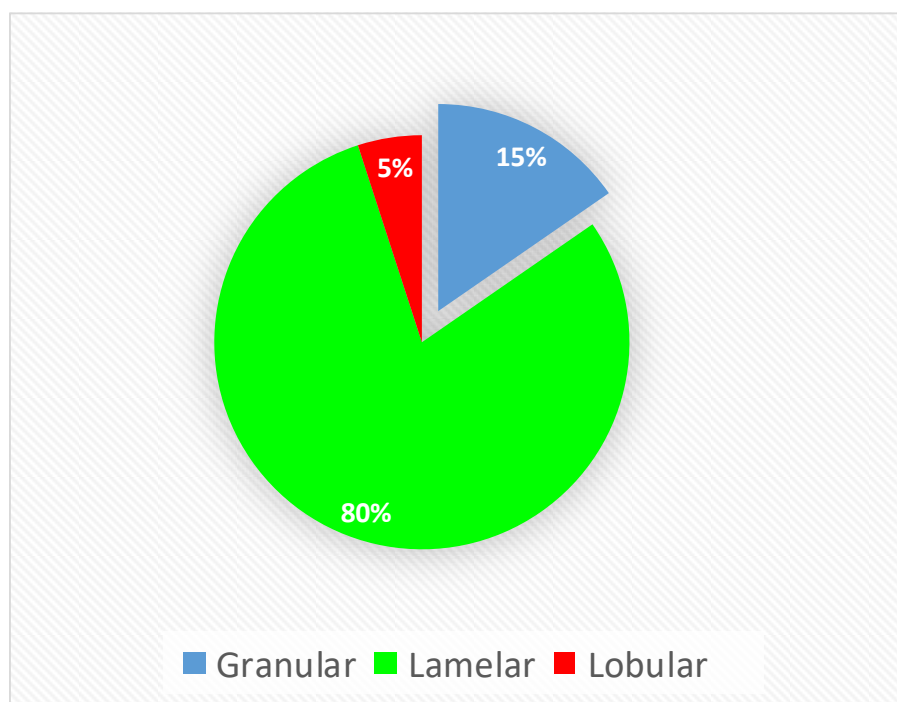


Figura 6. Fração de área dos tipos de hematita compacta.

Todos estes resultados qualitativos e quantitativos são colocados num relatório que é gerado na etapa final da rotina, em LaTeX.

4 CONCLUSÃO

O desenvolvimento do sistema e sua implementação paulatina nos laboratórios do CTF e da DIPE (VALE) indicam a viabilidade de automatizar de forma completa procedimentos de caracterização mineral baseados em microscopia.

A combinação de microscopia ótica motorizada, aquisição digital de imagens, captura integrada em diferentes modos de contraste (CC e CPOL) com rotinas de classificação automática gera uma solução de análise para amostras de *pellet feed* que é independente do operador, gerando economia de tempo e reprodutibilidade de resultados.

Os algoritmos de classificação empregados deverão evoluir com o uso continuado do sistema, aumentando sua taxa de acerto, que já é competitiva com a capacidade de reconhecimento humana. Técnicas modernas de inteligência artificial, tais como redes neurais *deep learning* poderão trazer, no futuro, uma solução ainda mais eficiente para as etapas de classificação.

Em última análise, a utilização cotidiana do sistema pelas equipes da VALE permitirá validá-lo, refiná-lo e aplicar os mesmos conceitos a outros problemas da área mineral.

Agradecimentos

Os autores agradecem o apoio das agências CNPq, CAPES e FAPERJ

REFERÊNCIAS

- 1 IGLESIAS JCA, GOMES ODM, PACIORNIK S. Automatic recognition of hematite grains under polarized reflected light microscopy through image analysis. *Minerals Engineering*. 2011;24:1264-1270.
- 2 GOMES ODM, IGLESIAS JCA, PACIORNIK S, VIEIRA MB. Classification of hematite types in iron ores through circularly polarized light microscopy and image analysis. *Minerals Engineering*. 2013;52:191-197.
- 3 DURAND LD, IGLESIAS JCA, GOMES OFM, AUGUSTO KS, DOMINGUES ALA, PACIORNIK S. Optimization of Image Acquisition for Hematite Classification in Iron Ores In: CSBMM 2015, Armação dos Búzios (RJ), 2015;1:50-51.
- 4 Iglesias JCA, Gomes ODM, Schinazi G, Paciornik S, Vieira MB. Caracterização quantitativa de sinter. *TMM*. 2010;7:12-17.
- 5 Wagner DT, Rouco HV, Gomes ODM, Paciornik S, Vieira MB. Caracterização de pelotas de minério de ferro por microscopia digital e análise de imagens. *TMM*. 2009:215-218.
- 6 Castellanos RM, Iglesias JCA, Augusto KS, Domingues ALA, Paciornik S. Optimization of the Characterization of Iron Ore Pellets by Image Analysis. In: CSBMM 2015, Armação dos Búzios (RJ), 2015.
- 7 Haralick RM. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics (SMC-3)*. 1973;6:610-621.
- 8 Bradley AP, Wildermoth M, Mills PC. Virtual microscopy with extended depth of field. In: DICTA 2005, p. 235-242, Cairns, Australia, 2005.
- 9 Schindelin J, Arganda-Carreras I, Frise E. et al. Fiji: an open-source platform for biological-image analysis. *Nature methods*. 2012;9(7):676-682.

- 10 Eaton JW. Octave: Past, present and future. In 2nd International Workshop on Distributed Statistical Computing, 2001.
- 11 Sussman GJ, Steele GL. SCHEME: An interpreter for extended lambda calculus, AI Memo 349, CSAIL/MIT, Cambridge, Massachusetts, 1975. Reprinted in: Higher-Order and Symbolic Computation. 1998;11(4):405–439.
- 12 Lowe DG. Distinctive Image Features from Scale-Invariant Keypoints. Intl. J. Computer Vision. 2004;60 (2):91–110
- 13