



IVAN MINGIREANOV FILHO

**SEGMENTAÇÃO DE IMAGENS DE
ROCHAS E CLASSIFICAÇÃO DE
LITOFAÇIES UTILIZANDO
*FLORESTA DE CAMINHOS ÓTIMOS***

CAMPINAS
2013



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
E INSTITUTO DE GEOCIÊNCIAS

IVAN MINGIREANOV FILHO

**SEGMENTAÇÃO DE IMAGENS DE
ROCHAS E CLASSIFICAÇÃO DE
LITOFAÇIES UTILIZANDO
*FLORESTA DE CAMINHOS ÓTIMOS***

Orientador: Prof. Dr. Alexandre Campane Vidal

Co-Orientador: Prof. Dr. Alexandre Xavier Falcão

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciências e Engenharia de Petróleo da Faculdade de Engenharia Mecânica e Instituto de Geociências da Universidade Estadual de Campinas para obtenção de título de **Mestre** em Ciências e Engenharia de Petróleo na área de **Reservatórios e Gestão**.

Este exemplar corresponde à versão final da dissertação defendida pelo aluno Ivan Mingireanov Filho e orientada pelo Prof. Dr. Alexandre Campane Vidal.



Prof. Dr. Alexandre Campane Vidal

CAMPINAS
2013

**FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP**

M663s	<p>Mingireanov Filho, Ivan Segmentação de imagens de rochas e classificação de litofácies utilizando floresta de caminhos ótimos / Ivan Mingireanov Filho. --Campinas, SP: [s.n.], 2013.</p> <p>Orientador: Alexandre Campane Vidal Coorientador: Alexandre Xavier Falcão. Dissertação de Mestrado - Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica e Instituto de Geociências.</p> <p>1. Processamento de imagens. 2. Reservatórios. 3. Reconhecimento de padrões. 4. Segmentação de imagens. 5. Petrofísica. I. Vidal, Alexandre Campane, 1969-. II. Falcão, Alexandre Xavier, 1966-. III. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica e Instituto de Geociências. IV. Título.</p>
-------	---

Título em Inglês: Segmentation of rock images and lithofacies classification using optimum-path forest

Palavras-chave em Inglês: Image segmentation, Reservoir, Pattern recognition, Image Segmentation, Petrophysics

Área de concentração: Reservatórios e Gestão

Titulação: Mestre em Ciências e Engenharia de Petróleo

Banca examinadora: Célio Maschio, João Paulo Papa

Data da defesa: 21-02-2013

Programa de Pós Graduação: Ciências e Engenharia de Petróleo



UNICAMP

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
E INSTITUTO DE GEOCIÊNCIAS

DISSERTAÇÃO DE MESTRADO ACADÊMICO

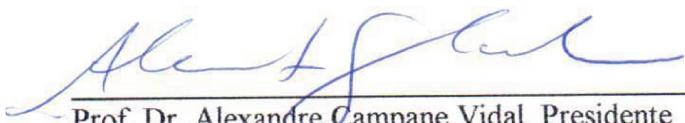
**SEGMENTAÇÃO DE IMAGENS DE
ROCHAS E CLASSIFICAÇÃO DE
LITOFAÇIES UTILIZANDO
*FLORESTA DE CAMINHOS ÓTIMOS***

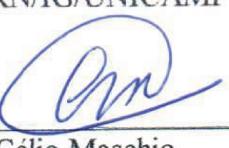
Orientador: Ivan Mingireanov Filho

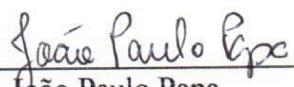
Orientador: Prof. Dr. Alexandre Campane Vidal

Co-Orientador: Prof. Dr. Alexandre Xavier Falcão

A banca examinadora composta pelos membros abaixo aprovou esta dissertação:


Prof. Dr. Alexandre Campane Vidal, Presidente
DGRN/IG/UNICAMP


Dr. Célio Maschio
UNISIM/CEPETRO/UNICAMP


Dr. João Paulo Papa
UNESP/BAURU

Campinas, 21 de fevereiro de 2013

Dedicatória

À minha mãe, Kátia Riccardi, dedico.

"A mente que se abre a uma nova ideia
jamais voltará ao seu tamanho original."

Albert Einstein

"Todas as vitórias ocultam uma abdicação."

Simone de Beauvoir

Agradecimentos

Agradeço primeiramente à Deus, pois sem Ele nada disso faria sentido.

Agradeço aos meus pais, que me ensinaram desde pequeno a importância da educação e a responsabilidade do conhecimento. Dedico um agradecimento especial à minha mãe Kátia Riccardi, e minha irmã, Tatiana Riccardi Mingireanov, que sempre estiveram ao meu lado, me apoiando e acreditando em meu potencial.

Agradeço à minha família por suas contribuições diretas e indiretas na minha formação.

À minha noiva, Marcela Mendes Salazar, pelo carinho, atenção, paciência e até algumas correções e sugestões no trabalho.

Aos meus amigos e colegas de trabalho por todo apoio durante essa jornada. Em especial à Michelle Kuroda e Thiago Spina pelas grandes contribuições que deram ao meu trabalho.

Ao meu orientador, Alexandre Vidal, e co-orientador, Alexandre Falcão pela oportunidade, apoio, sugestões sempre construtivas, incentivo e amizade que surgiu ao longo dessa jornada.

Aos funcionários do Departamento de Engenharia de Petróleo (DEP) e em especial à Sonia e Michelle.

Agradeço também à Agência Nacional do Petróleo pelo apoio financeiro e todo suporte.

À Universidade Estadual de Campinas (UNICAMP) por oferecer uma estrutura de excelência para a minha formação.

Resumo

A caracterização de reservatórios é fundamental na construção do modelo geológico para a produção do campo. O melhoramento de técnicas matemáticas, que auxiliam a interpretação geológica, influenciam diretamente o plano de desenvolvimento e gerenciamento dos poços. Nesse sentido, este trabalho utiliza uma aplicação inédita na caracterização de reservatórios da técnica de *Transformada Imagem Floresta* (Image Foresting Transform –IFT) em segmentação de imagens de rocha para a análise petrofísica. A técnica interpreta a imagem como um grafo, onde os pixels são os nós e os arcos são definidos por um relação de adjacência entre os pixels. O custo de um caminho no grafo é determinado por uma função que depende das propriedades locais da imagem. As raízes da floresta surgem de um conjunto de pixels escolhidos como sementes e a IFT atribui um caminho de custo mínimo das sementes à cada pixel da imagem para gerar uma *Floresta de Caminhos Ótimos* (Optimum-Path Forest – OPF). Com isso, nas imagens de lâminas de arenito, os grãos são segmentados em relação ao poro e os grãos em contato são separados entre si. Com os resultados obtidos é possível o estudo da morfologia dos grãos e porosidade da amostra. O método consiste de dois processos principais, um totalmente automático para segmentar a imagem e outro que utiliza uma interface gráfica para permitir correções dos erros de classificação gerados pelo processo automático. A acurácia é medida comparando a imagem corrigida por interação do usuário com a segmentada automaticamente. Outra aplicação inédita apresentada no trabalho é a utilização do classificador supervisionado baseado em OPF para a classificação de dados de perfilagem geofísica do campo de Namorado.

Palavras-chave: segmentação de imagens, Transformada Imagem Floresta, Floresta de Caminhos Ótimos, classificação de litofácies, classificador OPF supervisionado, morfologia de grãos.

Abstract

The reservoir characterization is fundamental in the construction process of geological model for field production. The improvement of mathematical techniques that assist the geological interpretation, has a directly influence in the development plan and management of the wells. Accordingly, this study uses a novel application in reservoir characterization, Image Foresting Forest (IFT) technique to image segmentation of rock for petrophysical analysis. The IFT interprets an image as a graph, whose nodes are the image pixels, the arcs are defined by an adjacency relation between pixels, and the paths are valued by a connectivity function. The roots of forest are a set of pixels selected as seeds and the IFT assigns a minimum path-cost to each image pixel generation an Optimum-Path Forest (OPF). The result is a segmentation of grains from pore in sandstone thin section images and the separation of the touching grains automatically. This allows the study of grain morphology and sample porosity. The method consists of two major processes: first, a totally automatic image segmentation and second an user interaction to correct misclassified grains. The accuracy is computed comparing the corrected image by the user with the image segmented automatically. Another novel application presented in the work is the use of supervised classification based on OPF for classification of geophysical logging data from Campo de Namorado.

Keywords: image segmentation, Image Foresting Transform, Optimum-Path Forest, lithofacies classication, supervised OPF classificator, grain morphology

Sumário

1	Introdução	1
1.1	Introdução à IFT e OPF	2
2	Lithofacies classification using Optimum-Path Forest method	7
2.1	Introdução	8
2.2	Metodologia	11
2.3	Resultados	13
2.4	Conclusões	14
2.5	Agradecimentos	16
3	Segmentation of sandstone thin section images with separation of touching grains using optimum-path forest operators	18
3.1	Introduction	19
3.2	Methods	21
3.2.1	Image Foresting Transform	21
3.2.1.1	Graphs from images	21
3.2.1.2	Connectivity Functions	22
3.2.1.3	Optimum-path forest	22
3.2.1.4	Clustering by optimum-path forest	24
3.2.1.5	Euclidean distance transform	26
3.2.1.6	Segmentation by inverted watershed	26
3.2.2	Automatic Grain Image Segmentation Pipeline	27
3.2.3	Interactive Correction	28
3.2.4	Evaluation parameters	29
3.3	Results and discussion	31
3.4	Conclusions	37

4 Aplicabilidade do método de segmentação automática em análise morfológica dos grãos	39
4.1 Introdução	39
4.1.1 Determinação da forma do grão	40
4.1.2 Estimativa de porosidade da rocha	41
4.2 Resultados e discussão	42
4.3 Conclusões	51
5 Referências Bibliográficas	53
A Imagens dos resultados da segmentação automática e correções interativas	57
B Imagens dos contornos e eixos dos grãos	61
C Resultados para análise dos eixos dos grãos	65

Listas de Figuras

1.1	IFT	4
2.1	(a) Grafo completo ponderado nas arestas para um determinado conjunto de treinamento. (b) Árvore Geradora Mínima (MST) do grafo completo. (c) Protótipos escolhidos como sendo os elementos adjacentes de classes diferentes na MST (nós circulados). (d) Floresta de caminhos ótimos resultante para a função de valor de caminho f_{\max} e dois protótipos. Os identificadores (x, y) acima dos nós são, respectivamente, o custo e o rótulo dos mesmos. A seta indica o nó predecessor no caminho ótimo. (e) Uma amostra de teste (triângulo) da classe 2 e suas conexões (linhas pontilhadas) com os nós do conjunto de treinamento. (f) O caminho ótimo do protótipo mais fortemente conexo, seu rótulo 2 e o custo de classificação 0.4 são associados à amostra de teste. Note que, mesmo a amostra de teste estando mais próxima de um nó da classe 1, ela foi classificada como sendo da classe 2 (Papa et al., 2009b).	10
2.2	Perfis dos resultados da classificação por OPF do poço NA07.	15
2.3	Matriz de confusão dos resultados da classificação por OPF do poço NA07.	15
3.1	Sequence of image operations for grain determination.	20
3.2	(a) A 4-neighborhood graph with set of seeds $\mathcal{M} = \{(0, 0), (2, 2)\}$, considering the origin $(0, 0)$ of pixels coordinates (x, y) in top left and the numbers as arc weights. (b) An optimum-path forest P computed to the function f_{\max} with two roots in \mathcal{S} . The numbers inside the nodes show the optimum connectivity map $V(t)$ by Eq. 3.5 and the arrows indicate predecessor node $P(t)$.	23
3.3	(a) Result of automatic segmentation with misclassification. (b) One grain marker and two background markers to correct with DIFT-SC. (c) Correction segment with LWOF. (d) LM correction obtaining better delineation of grain shape.	28

3.4 Examples of common misclassifications and their corrections. (a) The grain is split in two. The desired label is picked by a tool in the interface and the correction region is marked. (c) The two touching grains are segmented as one. The correction is analog the other, except the creation of a new label. (b) and (d) are the results after running DIFT-SC.	30
3.5 (a) Sample S1 - Input image of the porous sandstone, showing irregular grains of varied sizes and clayey matrix. (b) Three-cluster image, including background. (c) Grain binary mask from the brighter clusters. (d) Edges detected by stronger gradient of features Cb and Cr. (e) Combination of Euclidean IFT within grains and edges image. (f) Image of labeled grains. Each grain has its label as pixel values. (g) Original image combined with the image of labeled grain.	33
3.6 (a) Sample S2 - Input image of the more compact sandstone. (b) Three-cluster image, including background. (c) Grain binary mask from the brighter clusters. (d) Edges detected by stronger gradient of features Cb and Cr. (e) Combination of Euclidean IFT within grains and edges image. (f) Image of labeled grains. Each grain has its label as pixel values. (g) Original image combined with image of labeled grain.	34
3.7 (a) Detailed image of grain segmented from the background and others grains. (b) Image with misclassifications corrected by Live Markers.	35
3.8 (a) Details of misclassification of rock fragments by automatic segmentation. (b) In the correction, DIFT-SC markers had a small leaking in (i) and (ii). LM needed a little more interaction but the delineation was more precise in (iii) and (iv).	35
3.9 Relationship between automatic segmentation areas and interactive corrections area of sample S1 (a) and sample S2 (b).	37
4.1 Diagramas triangulares (a) as 10 classes descritivas definidas por Sneed and Folk (1958) C - Compact (Compacta), P - Platy (achatada), B - Bladed (lamelar), E - Elongate (Alongada) e V - Very (Muito); (b) Isolinhas de Máxima Projeção de Esfericidade (MSP); (c) Isolinhas de Índice de Oblato-Prolato. Figuras adaptadas de Benn e Ballantyne (1993)	42
4.2 (a) Resultado da segmentação automática da Amostra S3. (b) Resultado da correção interativa da Amostra S3.	43

LISTA DE FIGURAS

4.3	(a) Resultado da segmentação automática da Amostra S6. (b) Resultado da correção interativa da Amostra S6.	44
4.4	Contorno dos grãos e eixos das Amostras S3 (a) e S6 (b).	45
4.5	Diagramas de Zingg (1935) das amostras S3 (a) e S6 (b).	46
4.6	Diagrama para determinação de classes das amostras S3 (a) e S6 (b) segundo critério de classificação de Sneed and Folk (1958).	47
4.7	Diagrama de frequência de Fator de Forma das amostras S3 (a) e S6 (b); Diagrama de frequência da esfericidade das amostras S3 (c) e S6 (d).	48
4.8	Diagrama triangular do Índice Oblato-Prolato das amostras S3 (a) e S6 (c); Diagrama de frequência dos respectivos Índices Oblato-Prolato das amostras S3 (b) e S6 (d).	49
4.9	Diagrama triangular do Índice MSP das amostras S3 (a) e S6 (c); Diagrama de frequência dos respectivos Índices MSP das amostras S3 (b) e S6 (d).	50
A.1	(a) Resultado da segmentação automática da Amostra S4 (b) Resultado da correção interativa da Amostra S4.	58
A.2	(a) Resultado da segmentação automática da Amostra S5 (b) Resultado da correção interativa da Amostra S5.	59
A.3	(a) Resultado da segmentação automática da Amostra S7 (b) Resultado da correção interativa da Amostra S7.	60
B.1	Contorno dos grãos e eixos das amostras: (a) S1 (b) S2.	62
B.2	Contorno dos grãos e eixos das amostras: (a) S4 (b) S5 (c) S7.	63
C.1	Amostra S1 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Sneed & Folk (1958) (c) Fator de forma F (d) Esfericidade.	66
C.2	Amostra S1 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.	67
C.3	Amostra S2 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Sneed & Folk (1958) (d) Fator de forma F (d) Esfericidade.	68
C.4	Amostra S2 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.	69

LISTA DE FIGURAS

C.5 Amostra S4 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Sneed & Folk (1958) (c) Fator de forma F (a) Esfericidade.	70
C.6 Amostra S4 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.	71
C.7 Amostra S5 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Sneed & Folk (1958) (c) Fator de forma F (d) Esfericidade.	72
C.8 Amostra S5 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.	73
C.9 Amostra S7 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Sneed & Folk (1958) (c) Fator de forma F (d) Esfericidade.	74
C.10 Amostra S7 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.	75

Lista de Tabelas

2.1	Atributos utilizados para implementação do classificador baseado em OPF	11
2.2	Descrição das classes para classificação das rochas do Campo de Namorado pelo método OPF	12
2.3	Distribuição das classes por poço	13
2.4	Resultados obtidos das duas baterias de classificação.	14
3.1	Comparative results after processes	36
3.2	Evaluation parameters results	36
4.1	Descrição das equações para estimativa da forma do grão de acordo com os três eixos maior (a), intermediário (b) e menor (c). São utilizadas as relações $p = b/a$ e $q = c/b$	40
4.2	Classes segundo as formas dos seixos segundo Zingg (1935).	41
4.3	Descrição das imagens das amostras	42
4.4	Medidas de acurácia do método de segmentação automática e correções.	44
4.5	Distribuição dos grãos segundo critério de classificação de Zingg (1935).	46
4.6	Distribuição dos grãos segundo critério de classificação de Sneed and Folk (1958) para as 7 amostras.	47
4.7	Porosidade estimada.	50

Lista de abreviações

- ANN** – Artificial Neural Networks
BC – Bayes Classifier
CA – Cellular Automata
DIFT-SC – Differential IFT with seed competition
EDT – Euclidean Distance Transform
GIS – Geographic Information Systems
IFT – Image Foresting Transform
k-NN – k-nearest neighbor
LM – Live Markers
LST – Level Sets
LWOFL – Live Wire On-the-Fly
MLP – Multi-Layer Perceptrons
OPF – Optimum-Path Foresting
PDE – Partial Differential Equations
PDF – Probability Density Function
SOM – Self-Organizing Maps
SRG – Seed Region Growing
USIS – User-Steered Image Segmentation
WGSE – Weight Grain Sub-division Error
WGSE-global – Weight Grain Sub-division Error - global

1 Introdução

A caracterização de reservatórios é fundamental para a sua exploração, na qual a importância da construção do modelo influencia diretamente no plano de desenvolvimento e gerenciamento de um campo de petróleo ou gás (Deutsch, 2002). Para tal, é necessária uma caracterização realista das propriedades dos fluídos e das rochas que compõem o reservatório (Maschio et al., 2008) e os métodos que determinam essas propriedades estão em constante aperfeiçoamento e desenvolvimento. Dentre eles, a perfilagem geofísica e a análise petrofísica atuam somente após a abertura do poço e escalas diferentes, permitindo assim a obtenção de testemunhos para a análise petrofísica e o deslocamento das ferramentas pelo poço para aquisição de dados de perfilagem (Miyoshi, 2010).

A perfilagem geofísica registra as medidas geofísicas (perfis elétricos, acústicos, radioativos, mecânicos, térmicos, etc.) realizadas por deslocamento de sensores de perfilagem em poços (Girao, 2006). A interpretação dos dados permite inferir sobre propriedades de formação (Girao, 2006) e de propriedades como tipos de fácies, porosidade, permeabilidade, bem como informação precisa das superfícies estratigráficas e das falhas (Deutsch, 2002). O grande viés da classificação de litofácies é o processamento dos dados obtidos, existindo diversas tecnologias de inteligência artificial, das quais podemos citar entre as mais difundidas e utilizadas as redes neurais artificiais (*Artificial Neural Network - ANN: Self-Organizing Maps - SOM*) (Haykin, 2001; Kohonen et al., 2001). Nesse sentido, foi realizado um estudo preliminar da aplicação do classificador baseado em Floresta de Caminhos Ótimos (*Optimum-Path Foresting - OPF*) supervisionada Papa et al. (2009a) para a classificação de litofácies.

O capítulo 2 apresenta o estudo realizado em dados de poços do campo de Namorado com o classificador baseado em OPF proposto por Papa et al. (2009a). A aplicação do classificador foi realizada durante um estudo dirigido e posteriormente publicada no 12º Congresso Internacional da Sociedade Brasileira de Geofísica, em 2011.

Mudando para uma escala menor, a petrofísica está intrinsecamente ligada à mineralogia e geologia pois a maioria do petróleo do mundo ocorre em rochas sedimentares porosas. A precisão da análise petrofísica é imprescindível para a previsão do comportamento dos fluídos na rocha (Tiab and Donaldson, 2004). Ela pode ser definida como o estudo das propriedades das rochas e suas interações com fluidos (gases, hidrocarbonetos líquidos e soluções aqu-

osas). A descrição das rochas sedimentares pode ser determinada por características do grão, como forma, esfericidade, textura, tamanho, distribuição, orientação e grau de compactação. A combinação destas variáveis podem induzir informações sobre os processos diagenéticos e mecanismos de transporte, deposição, compactação e deformação. E em alguns casos ainda é possível fornecer informações sobre a permeabilidade e porosidade (Tiab and Donaldson, 2004).

Desse modo, a principal motivação deste trabalho é adaptar a Transformada Imagem Floresta (*Image Foresting Transform -IFT*) descrita em Falcão et al. (2004), uma técnica eficiente de segmentação de imagens, para automatizar e melhorar a qualidade da análise petrofísica. O estudo desse método aplicado à rochas de arenito é apresentado na forma de artigo submetido à revista Computer & Geosciences em outubro de 2012, no capítulo 3. Na sequência, o capítulo 4 apresenta possíveis aplicações dos resultados em diversas técnicas de análise da forma do grão.

1.1 Introdução à IFT e OPF

A segmentação de imagens consiste em separar a informação de interesse de uma imagem para torná-la comprehensível e permitir a análise. As técnicas basicamente procuram por objetos e bordas, agrupando e rotulando os pixels definidos a partir de certas características. Diversas técnicas tem sido desenvolvidas nessa área nas últimas décadas em diversas áreas da ciência. O maior desafio é obter métodos totalmente automáticos de segmentação de imagens naturais, pois a maioria deles requer a intervenção do usuário em alguma etapa do processamento, por menor que seja. A limitação é devido aos humanos serem muito superiores na tarefa de reconhecimento de objetos e os computadores muito superiores no delineamento. Uma maneira de contornar essa limitação é o conhecimento prévio do objeto a ser segmentado, porém isso nem sempre é possível, pois os objetos nem sempre tem o mesmo padrão de cor, formato ou de aquisição da imagem (Falcão et al., 1998).

As técnicas de segmentação de grãos em imagens de rochas mostram avanços significativos. Podemos citar as técnicas desenvolvida por Van de Berg et al. (2002), *Seed Region Growing - (SRG)* (Choudhury et al., 2006), *Level Sets - (LST)* (Lu et al., 2009), *Partial Differential Equations - (PDE)* (Lu and Ning, 2010), *Geographic Information Systems - (GIS)* (Choudhury et al., 2006; Li et al., 2008; Gorsevski et al., 2012), e *Cellular Automata (CA)* (Gorsevski et al., 2012).

A aplicação de novas técnicas desenvolvidas em outras áreas da ciência visa reduzir as incertezas e riscos gerados pelos métodos na construção dos modelos. A técnica de segmentação de imagens IFT tem se mostrado bastante eficiente, com aplicações em diversas áreas, como medicina (Suzuki et al., 2012; Yu et al., 2012), reconhecimento facial (Chiachia et al., 2011), metalografia (Papa et al., 2012), e outras.

A IFT é uma ferramenta geral para projetar, implementar e avaliar operadores de imagens baseados em conectividade dos pixels adjacentes. O algoritmo utilizado para o cálculo da IFT é basicamente uma generalização do algoritmo de Dijkstra (Dijkstra, 1959) para caminhos mais curtos, levemente adaptado para fontes múltiplas e funções de custo de caminhos suaves. A imagem é interpretada como um grafo, onde os pixels são os nós e os arcos dos grafos são definidos por uma relação de adjacência entre os pixels. Grafos podem ser definidos como uma estrutura matemática utilizada para modelar relações entre objetos de um certo conjunto. O custo de um caminho no grafo é determinado por uma função que depende das propriedades locais da imagem ao longo do caminho, como cor, gradiente e posição do *pixel*.

O algoritmo inicia com caminhos triviais (somente um único *pixel* ligado à ele mesmo) propagando-se a partir das raízes, gerando uma competição para conquistar os pixels remanescentes. A conquista é feita quando o custo do caminho é menor (ou maior) do pixel à raiz, ficando o pixel atribuído à essa raiz. A Figura 1.1-a é uma representação de um grafo, onde o pixel t está ligado pelo caminho $P(t)$ à raiz $P^0(t)$. O processo exemplificado na Figura 1.1-b representa uma imagem 2D em escala de cinza, onde os valores são os pixels (nós) da imagem e os três círculos maiores são as raízes.

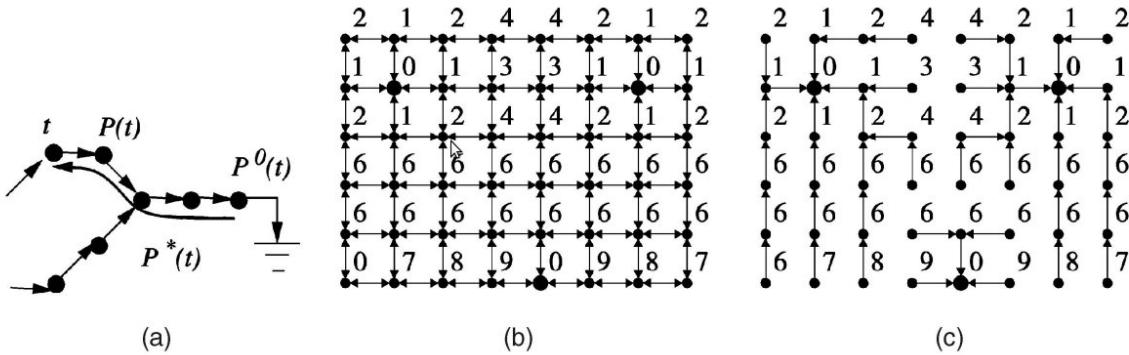


Figura 1.1: (a) Os elementos principais da floresta geradora. (b) Um grafo de imagem 2D com adjacência 4-conexos, onde os inteiros são os valores $I(t)$ da imagem. (c) Uma floresta de caminhos ótimos para a função de custo mínimo, restritos aos três pixels sementes representados pelos pontos maiores (Falcão et al., 2004).

1. INTRODUÇÃO

As raízes da floresta surgem a partir de um conjunto de pixels escolhidos como sementes e estão representadas com círculos maiores na Figura 1.1-b. Inicialmente, a IFT atribui um caminho de custo mínimo das sementes à cada pixel da imagem para determinar as funções de custo mínimo, de modo que a união destes caminhos é uma floresta orientada se propagando pela imagem toda, ou seja, a IFT define uma floresta de caminhos de custos mínimos em um grafo. O resultado apresentado na Figura 1.1-c é denominado OPF.

O algoritmo determina como resultado três atributos a cada pixel: o pixel predecessor no caminho ótimo, o custo deste caminho e a sua raiz correspondente (ou algum rótulo associado ao pixel). Uma grande variedade de operadores de imagens pode ser implementada através de um simples processamento local destes atributos.

A técnica de classificação supervisionada baseada em OPF modela as amostras como sendo um grafo completo. Os elementos mais representativos de cada classe são denominados protótipos, e são escolhidos nas regiões de sobreposição e de fronteiras entre as classes, pois estas regiões são muito mais propensas a erros de classificação. Durante o processo de treinamento, os protótipos competem pelas amostras oferecendo o caminho de menor custo e seus respectivos rótulos, gerando uma OPF. Os benefícios dessa abordagem em relação à outros métodos de classificação supervisionada são a independência de parâmetros, permissão de tratamento nativo de problemas multiclasses e a não dependência da forma ou separabilidade entre as classes Papa et al. (2009a).

O objetivo da segmentação de imagens é separar objetos da imagem para permitir sua análise. A separação pode ser realizada utilizando a IFT para particionar a imagem em zonas de influência, onde a zona de cada semente consiste no conjunto de pixels mais fortemente ligados à esta semente do que a qualquer outra. Estas zonas de influência são simplesmente as árvores da floresta definida pela IFT (Falcão et al., 2004). Um processo utilizado para este fim é denominado agrupamento – identificação de grupos naturais de amostras de um conjunto de dados – e pode ser realizado pelo classificador OPF não-supervisionado (Rocha et al., 2009) em amostras de pixels da imagem com seus correspondentes vetores de atributos. O problema consiste em identificar as altas concentrações de amostras, as quais podem caracterizar os grupos relevantes para a aplicação. Desse modo, os grupos naturais podem ser detectados e separados, pois são caracterizados pelas altas concentrações de amostras no espaço de atributos, formando domos da função de densidade de probabilidade (*probability density function - PDF*) (Rocha et al., 2009). A detecção dos grupos naturais é realizada por uma busca exaustiva, calculando a pdf para uma relação de adjacência dos k -vizinhos próximos (*k-nearest neighbor - k-nn*) a partir de um k_{min} até um k_{max} , procurando o k que otimiza a PDF, isto é, onde os pixels similares forem mais próximos, a pdf é máxima. A determinação do melhor valor do

1. INTRODUÇÃO

k considera o corte mínimo no grafo, provida pelos resultados do processo de agrupamento, considerando os pesos dos arcos entre os agrupamento e os demais.

O método proposto para segmentar os grãos na imagem consiste de dois processos principais, baseados em IFT: segmentação automática de imagem com grãos em contato e correções interativas dos erros de classificação.

O processo de segmentação automática tem como princípio separar os grãos do fundo primeiramente e então a separação dos grãos em contato entre eles mesmos. Para isso, o processo utiliza o algoritmo da IFT em três passos: no primeiro passo é feito o agrupamento baseado na similaridade de cor, o que permite gerar uma máscara de grãos binária da imagem original, já que os grãos estão nos grupos com os pixels mais claros. A máscara é utilizada para a detecção das bordas dos grãos. O segundo passo consiste em calcular a Transformada de Distância Euclidiana (*Euclidean Distance Transform - EDT*) propagando para dentro do grãos a partir das bordas dos grãos. Isso gera uma imagem de domos cujos picos são utilizados no terceiro passo para separar os grãos com uma transformada *watershed* invertida.

O método *watershed* pode ser simplificado por um fechamento de bacias com volume abaixo de um *threshold*, e no caso *watershed* invertida, pode ser controlada pela abertura dos domos acima de um *threshold*. A separação dos grãos é feita ao permitir a competição entre as sementes em cada domo, entendendo como distintos os grafos das sementes quando encontram o grafo de outra semente, atribuindo diferentes rótulos para cada semente, que no caso, os grãos ficam rotulados e distintos. Como resultado, tem-se uma imagem de rótulos dos grãos, onde o valor do pixel corresponde ao rótulo do grão.

Apesar do processo anterior ter como objetivo a segmentação completamente automática, eventuais erros de classificação ocorrem e podem ser corrigidos por uma interface gráfica adaptada para este problema. A segmentação de imagens guiada pelo usuário (*user-steered image segmentation - USIS*) permite as correções dos erros de classificação que ocorrem em fragmentos de rocha, vazamentos de segmentação de grãos em contato com matriz, e divisão de grãos maiores em outros menores ou grãos pequenos serem interpretados como um grão único. A interface utiliza a ferramenta *Live Markers* baseada em IFT que trabalha apenas na região em que foram usados marcadores, trocando as posições das sementes originais do processo automático de acordo com a decisão do especialista, gerando uma competição apenas entre essas sementes, sendo computacionalmente muito rápido, gerando uma visualização do resultado quase em tempo real. Porém, a correção de uma imagem com cerca de 500 grãos demanda tempo do operador para verificar quais grãos necessitam de correções e corrigí-las. Essa opção da interface de correção oferece a possibilidade de obter uma imagem tão precisa quanto seja desejado ou necessário. Outro propósito da interface é gerar uma imagem

1. INTRODUÇÃO

padrão para servir de referência para medidas de acurácia do processo automático. Como dito anteriormente, o estudo realizado apresenta-se no capítulo 3.

2 Lithofacies classification using Optimum-Path Forest method

Authors: Ivan Mingireanov Filho, Alexandre Campane Vidal

Abstract

Pattern classification aims to find the label of each sample using a feature vector in dataset samples. As traditional methods usually do, the learning process distributes samples into different labels using a training subset and determines rules to decide the classification of each subset. The pattern recognition algorithm, based in Optimum-Path Forest (OPF) used here, models the problem like a graph. In this graph the nodes are the samples and the arcs are defined by some adjacency relation, the most relevant samples are called prototypes. A competition process among samples starts offering optimum-path costs to the remaining dataset samples. Using the complete graph in adjacency relation the competition becomes global, not based only in local geometry as traditional methods. The search is done finding the prototypes samples that belongs to overlap regions and boundaries between the labels in the training set. These regions are very susceptible to misclassification. The prototypes samples offer optimum-path cost computed as the maximum path arc-weight between these prototypes and the other dataset samples. These arc-weights are computed by the distance between their features vectors. The goal of this work is validate the OPF method classifying non-cored wells information set, from Campo de Namorado, in Bacia de Campos, RJ, freely available by National Petroleum Agency (ANP). The dataset is composed by 5 attributes for each depth, totaling 4732 samples, which 1950 are core samples. The results show the time spent on both, training and classification process. They were very short always less than 1 second. In cross-validation, 87,1% of the core samples maintained their label. The average accuracy computed to each well was 64,8%, and using all core samples in training process the accuracy was 76,8%. These results suggest a new approach suitable to process a large volume dataset in a short time, being an alternative for non-cored wells classification.

2.1 Introdução

O método de classificação por Floresta de Caminhos Ótimos (OPF) é baseado na Transforma Imagem Floresta (IFT), uma ferramenta geral para modelar, implementar e avaliar operadores baseados em conexidade Falcão et al. (2004), reduzindo o problema de classificação ao cálculo de uma floresta de caminhos ótimos em um grafo derivado do conjunto de dados das amostras. O valor de um caminho é normalmente calculado por uma função dependente dos atributos e da posição do atributo ao longo do caminho do grafo (Papa et al., 2009b).

Para utilização do classificador baseado em OPF com aprendizado supervisionado, o modelamento do problema de reconhecimento de padrões é considerado como um problema de OPF em um grafo definido no espaço de atributos, onde os nós são as amostras, as quais são representadas pelos seus respectivos vetores de atributos, e os arcos são definidos de acordo com uma relação de adjacência pré-estabelecida. Tanto os nós quanto os arcos podem ser ponderados por alguma métrica de distância aplicada a seus vetores de atributos, diferente dos métodos tradicionais por não utilizar apenas a ideia de geometria do espaço de atributos, permitindo melhores resultados em bases com outliers e sobreposição de classes. Diversas funções de custo podem ser empregadas para particionar o grafo em árvores de caminhos ótimos, as quais são enraizadas pelos seus respectivos protótipos (sementes) na fase de treinamento. O rótulo de uma amostra a ser classificada é o mesmo do protótipo mais fortemente conexo a ela. A abordagem adotada utiliza o grafo completo como relação de adjacência. Durante a fase de treinamento, assume os elementos que pertencem à intersecção entre as classes no conjunto de treinamento como os elementos mais representativos de cada classe (Papa et al., 2009b).

Os protótipos participam de um processo de competição disputando as outras amostras oferecendo-lhes caminhos de menor custo e seus respectivos rótulos. Ao final deste processo, obtém-se um conjunto de treinamento particionado em árvores de caminhos ótimos, sendo que a união das mesmas nos remete a uma floresta de caminhos ótimos. Esta abordagem apresenta vários benefícios com relação a outros métodos de classificação de padrões supervisionados: (i) é livre de parâmetros, (ii) possui tratamento nativo de problemas multiclasse e (iii) não faz alusão sobre forma e/ou separabilidade das classes (Papa et al., 2009b).

O algoritmo OPF com grafo completo tem sido amplamente utilizado em diversas aplicações, tais como avaliação de descritores de textura, diagnóstico automático de patologias na laringe e classificação de impressões digitais (Papa et al., 2009b). Essas aplicações fundamentam a aplicação em dados de poços para classificação da litologia.

2. LITHOFACIES CLASSIFICATION USING OPTIMUM-PATH FOREST METHOD

A fase de treinamento do classificador baseado em OPF usando o grafo completo consiste em encontrar o conjunto S de protótipos, ou seja, os elementos mais representativos de cada classe. Essa escolha pode ser de várias maneiras heurísticas, inclusive, por uma escolha aleatória de protótipos. Entretanto, tal escolha pode prejudicar o desempenho do classificador, tornando-o instável e com um alto grau de sensibilidade com relação aos protótipos escolhidos. Deseja-se estimar os protótipos nas regiões de sobreposição de amostras e nas fronteiras entre as classes, visto que são regiões muito susceptíveis a erros de classificação. Outra técnica que pode ser abordada é a utilização do grafo k-vizinhos mais próximos (k-NN), onde estima estes protótipos nos pontos de alta concentração de amostras (Papa et al., 2009b).

Calculando uma árvore mínima geradora (MST) no grafo completo (Z_1, A) (Figura 2.1a), obtemos um grafo conexo acíclico cujos nós são todas as amostras em Z_1 , e os arcos são não direcionados e ponderados, Figura 2.1(b). Seus pesos são dados pela distância d entre os vetores de atributos de amostras adjacentes. Esta árvore de espalhamento é ótima no sentido em que a soma dos pesos de seus arcos é mínima se comparada a outras árvores de espalhamento no grafo completo. Os protótipos a serem escolhidos são os elementos conectados na MST com diferentes rótulos em Z_1 , ou seja, elementos mais próximos de classes diferentes, Figura 2.1(c). Removendo-se os arcos entre classes diferentes, tais amostras adjacentes tornam-se protótipos em S e pode-se computar uma floresta de caminhos ótimos em Z_1 , Figura 2.1(d). Nota-se que uma dada classe pode ser representada por múltiplos protótipos e deve existir pelo menos um protótipo por classe. A ideia consiste em ponderar os arcos entre amostras de diferentes classes com um valor muito alto, impossibilitando assim que os protótipos de uma classe conquistem elementos de outras classes (Papa et al., 2009b).

Para a classificação, todos os arcos são considerados conectando a amostra teste com as amostras do grafo original, onde na Figura 2.1(d) está representado pelo triângulo. Considerando todos esses possíveis caminhos, desejamos encontrar o caminho ótimo com a classe de seu protótipo mais fortemente conexo. Assim, a classificação simplesmente associa a amostra à classe que satisfaz essas condições, Figura 2.1(e). Vale ressaltar que, embora a amostra a ser classificada esteja mais próxima de um elemento da classe bola, Figura 2.1(c), a mesma é classificada como sendo da classe quadrado, o que demonstra que os classificadores baseados em OPF utilizam a força de conexidade entre as amostras para a classificação dos dados, ou seja, não são algoritmos baseados em conexidade local apenas como, por exemplo, os classificadores de redes neurais artificiais (ANN) (Hecht-Nielsen, 1990; Bishop, 1994) e k-vizinhos próximos (k-NN) (Papa et al., 2009b).

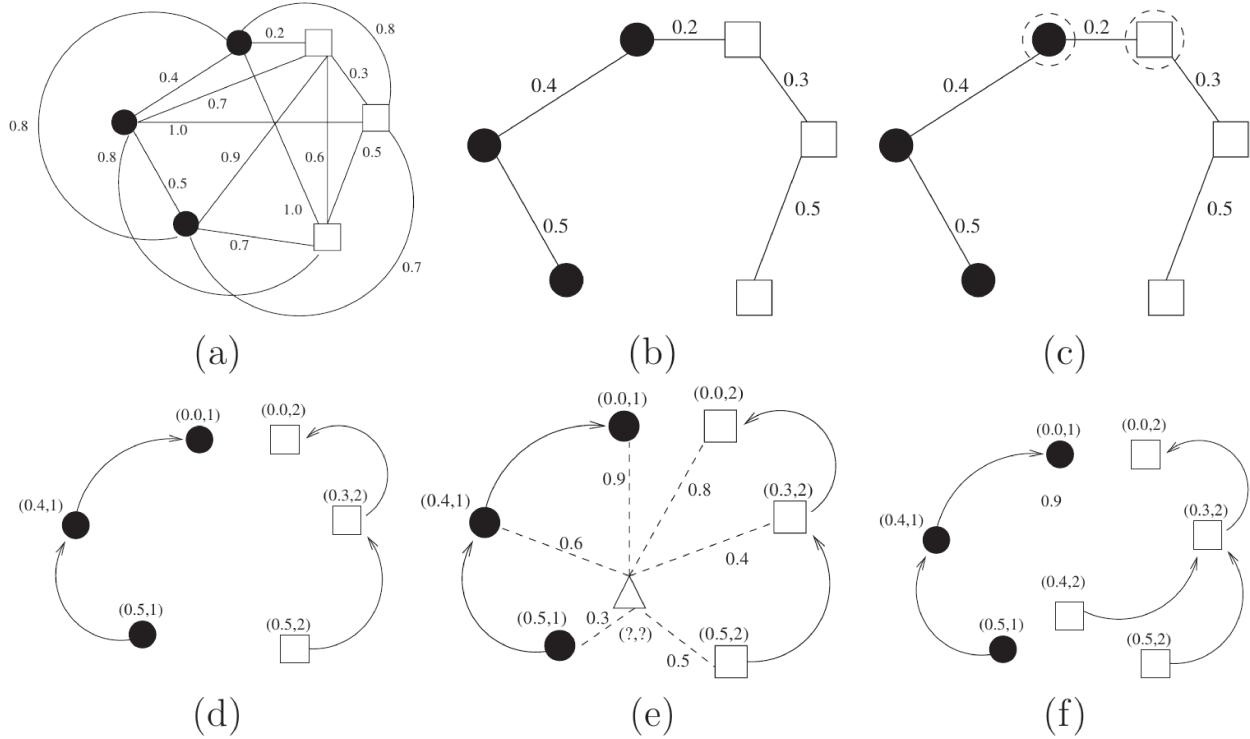


Figura 2.1: (a) Grafo completo ponderado nas arestas para um determinado conjunto de treinamento. (b) Árvore Geradora Mínima (MST) do grafo completo. (c) Protótipos escolhidos como sendo os elementos adjacentes de classes diferentes na MST (nós circulados). (d) Floresta de caminhos ótimos resultante para a função de valor de caminho f_{max} e dois protótipos. Os identificadores (x, y) acima dos nós são, respectivamente, o custo e o rótulo dos mesmos. A seta indica o nó predecessor no caminho ótimo. (e) Uma amostra de teste (triângulo) da classe 2 e suas conexões (linhas pontilhadas) com os nós do conjunto de treinamento. (f) O caminho ótimo do protótipo mais fortemente conexo, seu rótulo 2 e o custo de classificação 0.4 são associados à amostra de teste. Note que, mesmo a amostra de teste estando mais próxima de um nó da classe 1, ela foi classificada como sendo da classe 2 (Papa et al., 2009b).

O classificador baseado em OPF com grafo completo assemelha-se ao algoritmo vizinho mais próximo (k -NN) somente no caso onde todos os elementos do conjunto de treinamento são considerados protótipos, sendo este um caso atípico onde, certamente, o conjunto de atributos escolhido não foi o mais adequado para a representação do conjunto de dados. Outra diferença a ser considerada é que os classificadores ANN e k -vizinhos mais próximos (k -NN) tomam uma decisão local para a classificação dos dados, ao contrário dos classificadores baseados em OPF, os quais possibilitam uma solução em âmbito global, criando uma floresta

2. LITHOFACIES CLASSIFICATION USING OPTIMUM-PATH FOREST METHOD

de caminhos ótimos que mapeia, para cada amostra do conjunto de dados, o caminho ótimo entre ela e o seu protótipo mais fortemente conexo (Papa et al., 2009b).

O objetivo do presente trabalho foi classificar um conjunto de informações de poços não-testemunhados utilizando o método de classificação supervisionada de padrões por floresta de caminhos ótimos, com validação cruzada.

2.2 Metodologia

Foi utilizado um conjunto de informações de diferentes atributos referentes ao Campo de Namorado, da Bacia de Campos, RJ, disponibilizado livremente pela Agência Nacional de Petróleo (ANP). Dentre todas as informações fornecidas, foram utilizados 5 atributos, de acordo com a tabela 2.1.

Tabela 2.1: Atributos utilizados para implementação do classificador baseado em OPF.

Atributos Avaliados	Sigla	Aplicação
Densidade	RHOB	Detecção de raios gamas defletidos pelos elétrons pro uma fonte situada dentro de um poço
Porosidade Neutrônica	NPHI	Medida de quantidade de nêutrons da rocha após o bombardeio
Sônico	DT	Medida da diferença dos tempos de trânsito de uma onda mecânica através das rochas
Indução	ILD	Leitura aproximada da resistividade
Raio Gama	GR	Detecção da radioatividade total da formação geológica

O conjunto de dados contém informações medidas dos atributos de 7 poços, em função da profundidade, no total de 4732 amostras, das quais 1950 possuem testemunho, ou seja 41,2% do total. É um conjunto privilegiado pela quantidade de testemunhos dos poços, pois normalmente esse número é bem menor, não ultrapassando os 20% do total, devido ao alto custo e dificuldade de gerar os testemunhos. Para a classificação, de acordo com o interesse do trabalho proposto, as fácies foram agrupadas em quatro classes, de acordo com a tabela 2.2. São essas rochas sem testemunho o objetivo de classificação pelo o método OPF, totalizando de 2782 amostras.

2. LITHOFACIES CLASSIFICATION USING OPTIMUM-PATH FOREST METHOD

Tabela 2.2: Descrição das classes para classificação das rochas do Campo de Namorado pelo método OPF.

Classes	Descrição
1	Rochas Reservatórios
2	Rochas Possível Reservatório
3	Rochas Não Reservatório
	Rochas Sem Testemunho

As informações foram separadas para cada um dos 7 poços, de acordo com a tabela 2.3, e foram realizadas duas baterias de classificação após o treinamento do algoritmo, utilizando o algoritmo 3 - Classificador Supervisionado baseado em Floresta de Caminhos Ótimos usando grafo completo, disponibilizado em linguagem C para utilização em plataforma Linux em www.ic.unicamp.br/~afalcao/LibOPF (Papa et al., 2009b).

Tabela 2.3: Distribuição das classes por poço.

Poço	Classe	Classe	Classe	Sem	Total de Amostras
	1	2	3	Testemunho	
NA1A	4,76%	3,13%	1,75%	90,36%	799
NA02	9,26%	0,93%	6,17%	83,64%	648
NA04	25,65%	5,34%	24,61%	44,41%	581
NA07	10,59%	6,98%	29,07%	53,36%	774
NA11A	6,49%	1,40%	90,53%	1,58%	570
RJS234	1,47%	0,00%	51,54%	46,99%	747
RJS42	16,31%	2,77%	1,47%	79,45%	613

A primeira bateria foi feita apenas com as informações de cada poço, individualmente, utilizando metade dos dados de rochas com testemunhos do poço para treinar o classificador. Na sequência, foram classificados os dados sem testemunhos juntos com a outra metade de dados com testemunhos, para validação cruzada.

A segunda bateria agrupou todos os 1950 dados de rochas com testemunhos para treinamento, e classificou os dados sem testemunhos e metade dos dados com testemunhos, individualmente para cada um dos 7 poços. Ou seja, a diferença entre as duas baterias de classificação foi na fase de treinamento, onde a segunda utiliza todo o conjunto de informações dos testemunhos, com o intuito de melhorar esta fase pela quantidade de informações maior, mantendo o conjunto de classificação e de validação cruzada.

2.3 Resultados

Os resultados obtidos foram bastante satisfatórios em ambas as baterias. Na bateria 1, a classificação das amostras sem testemunhos foi feita após treinamento do algoritmo com metade das amostras com testemunhos e a outra metade com as classes agrupada com as amostras sem testemunhos. Por essa validação cruzada, algumas dessas amostras com testemunhos foram reclassificadas, alterando a classe original, e outras se mantiveram. Os números absolutos e percentuais das amostras que mantiveram a classe e das amostras que foram alteradas de classe estão apresentados a seguir na 2.4.

Ainda nessa bateria, são apresentadas as medidas de acurácia, que o próprio algoritmo determina. A acurácia utiliza em sua função um erro calculado quando a amostra a ser rotulada não recebe o rótulo determinado corretamente no treinamento. Quanto menor for este erro, maior será a acurácia.

Tabela 2.4: Resultados obtidos das duas baterias de classificação.

	Bateria				Bateria 2
	Mantiveram	Alteraram	Acurácia	Acurária	
NA1A	23	60,5%	15	29,5%	59,0%
NA02	49	92,4%	4	7,6%	69,7%
NA04	138	85,7%	23	14,3%	71,9%
NA07	145	80,5%	35	19,5%	66,5%
NA11A	262	93,6%	18%	6,4%	67,6%
RJS234	192	96,9%	6	3,1%	53,6%
RJS42	53	84,1%	10	15,9%	65,6%

Já na bateria 2, foram utilizadas todas as 1950 amostras com testemunhos de todos os poços na fase de treinamento, para realizar um treino com um banco de dados maior. A classificação foi realizada como na bateria 1, isto é, os dados a serem classificados eram as amostras sem testemunhos agrupados com a outra metade das amostras com testemunhos. Por isso, ao analisar a validação cruzada, não foi detectada nenhuma alteração nas amostras com testemunhos, pois estas amostras já estavam contidas no conjunto de treinamento. Mas, como esperado, ao utilizar um conjunto maior de treinamento, a tendência do elemento mais representativo da classe ser escolhido durante a competição é maior, diminuindo o erro, aumentando significativamente a acurácia. O perfil de classificação deste poço pode ser observado na Figura 2.2. A matriz de confusão do poço NA07 é apresentada na Figura 2.3, onde 89,75% dos rótulos foram mantidos.

2. LITHOFACIES CLASSIFICATION USING OPTIMUM-PATH FOREST METHOD

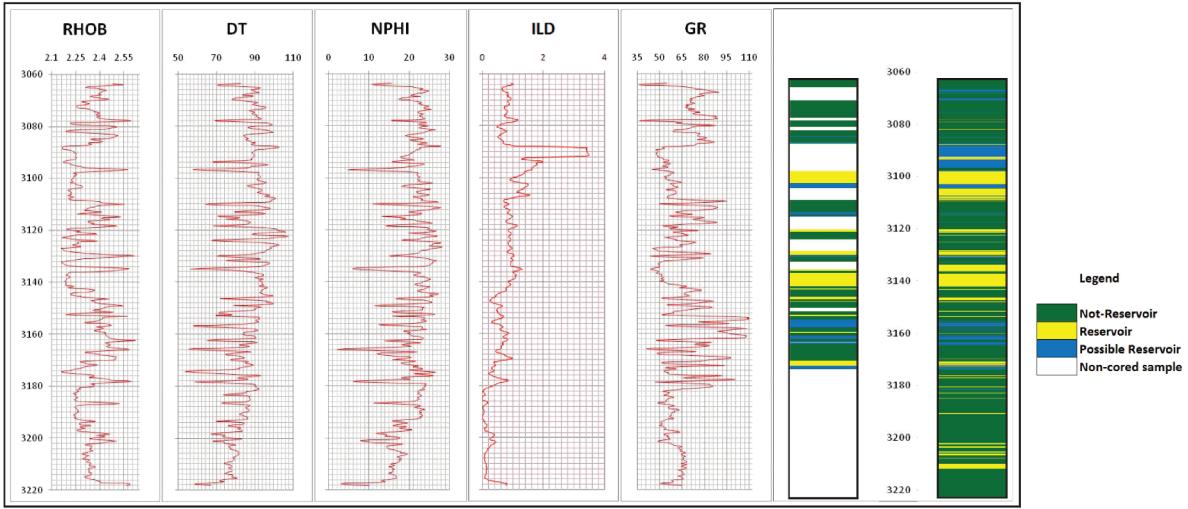


Figura 2.2: Perfis dos resultados da classificação por OPF do poço NA07.

Treinamento				
Classificação	1	2	3	
	73 20.22%	1 0.28%	6 1.66%	91.3% 8.75%
	2 0.55%	40 11.08%	11 3.05%	75.5% 24.53%
	7 1.94%	10 2.77%	211 58.45%	92.5% 7.46%
	89.02% 10.98%	78.43% 21.57%	92.54% 7.46%	89.75%

Figura 2.3: Matriz de confusão dos resultados da classificação por OPF do poço NA07.

2.4 Conclusões

O método de classificação supervisionada de padrões baseada em Floresta de Caminhos Ótimos (Papa et al., 2009b) utilizado nesse trabalho para classificação de dados de poços, mostrou-se ser um método simples, rápido e eficiente.

Foram feitas duas baterias de treinamento e classificação: a bateria 1 resultou em acurácia média de cerca de 64,8% e apresentou a manutenção de 87,1% das classes originais na validação cruzada utilizando metade das amostras de treinamento. Na bateria 2 foi utilizado todo o conjunto de amostras com testemunhos para treinamento e a acurácia média aumentou para cerca de 76,8%.

2. LITHOFACIES CLASSIFICATION USING OPTIMUM-PATH FOREST METHOD

O método apresenta também algumas qualidades interessantes, como não necessitar de que o número de classes das amostras seja igual. Isso pode ser confirmado já que alguns poços apresentavam um número muito pequeno de amostras de certa classe e em alguns casos não possuíam nenhuma amostra.

2.5 Agradecimentos

Gostaríamos de agradecer à Agência Nacional de Petróleo (ANP) pela disponibilização dos dados para estudos e pelo apoio financeiro.

2. LITHOFACIES CLASSIFICATION USING OPTIMUM-PATH FOREST METHOD

3 Segmentation of sandstone thin section images with separation of touching grains using optimum-path forest operators

Authors: Ivan Mingireanov Filho, Alexandre Campane Vidal,
Alexandre Xavier Falcão, Thiago Vallin Spina

Abstract

The segmentation of detrital sedimentary rock images is still a challenge for characterization of grain morphology in sedimentary petrography. We propose a fast and effective approach that first segments the grains from pore in sandstone thin section images and separates the touching grains automatically, and second lets the user to correct the misclassified grains with minimum interaction. The method is mostly based on the image foresting transform (IFT) — a tool for the design of image operators using optimum connectivity. The IFT interprets an image as a graph, whose nodes are the image pixels, the arcs are defined by an adjacency relation between pixels, and the paths are valued by a connectivity function. The IFT algorithm transforms the image graph into an optimum-path forest and distinct image operators are designed by suitable choice of the IFT parameters and attributes of that forest. The solution involves a sequence of three IFT-based image operators for automatic segmentation and the interactive segmentation combines region- and boundary-based object delineation using two IFT operators. Tests with thin section images of two different sandstone samples have shown very satisfactory results, yielding r^2 and accuracy parameters of 0.8712 and 94.8% on average, respectively. Biases were the presence of the matrix and rock fragments.

3.1 Introduction

The morphology of grains is important to the textural characterization of detrital sedimentary rocks. Grain properties such as roundness and sphericity, for instance, allow us to

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

infer information about provenance and transport. However, touching grains and the high variability of grain shapes in a single rock make the problem very challenging for automatic image analysis (Ehrlich and Chin, 1980).

Many techniques have been proposed to automate the characterization of grain morphology in sandstone thin section images. However, the accuracy of the automatic image segmentation methods (Van de Berg et al., 2002; Choudhury et al., 2006; Lu et al., 2009; Gorsevski et al., 2012) has been severely compromised by the presence of touching grains, despite the large number of distinct strategies based on: Partial Differential Equations (PDE) (Lu and Ning, 2010), Level Sets (LST) (Lu et al., 2009), Seed Region Growing (SRG) (Choudhury et al., 2006), Geographic Information Systems (GIS) using arcGIS ModelBuilder to combine images (Choudhury et al., 2006; Li et al., 2008; Gorsevski et al., 2012), and cellular automata (CA) (Gorsevski et al., 2012).

Indeed, automatic segmentation remains a challenge in most image processing applications. The absence of previous knowledge about the object under segmentation very often makes user intervention a necessity (Dengiz et al., 2005; Choudhury et al., 2006; Lu et al., 2009). We may divide the image segmentation process into two tightly coupled tasks: object recognition (location and verification) and delineation. While humans are superior than computers in recognition, computers are able to do precise delineation even when inaccurate. Therefore, the aim of semi-automatic image segmentation methods is usually to minimize the time spent by the user and amount of interaction required for delineation, while maximizing the accuracy and precision of segmentation (Falcão et al., 1998; Spina et al., 2011a).

We propose a grain image segmentation method consisting of two major components: automatic image segmentation of touching grains and interactive correction of the misclassifications using Live Markers (LM) (Spina et al., 2011b). Both parts of our method are based on the Image Foresting Transform (IFT) (Falcão et al., 2004) — a tool for the design of image operators using *optimum connectivity*. The IFT interprets an image as a graph, whose nodes are the image pixels, the arcs are defined by an *adjacency relation* between pixels, and the paths are valued by a *connectivity function*. The IFT algorithm transforms the image graph into an optimum-path forest and distinct image operators are designed by suitable choice of the IFT parameters and attributes of that forest.

Our strategy is first to segment the grains from the darker background and separate touching grains automatically (Figure 3.1). Our automatic grain segmentation method can be divided into three steps, each using a distinct IFT-based image operator. First, we use clustering based on color similarity to output a binary segmentation mask from the grain image, by considering the clusters with brighter pixels as representative of the grains. Then, we compute

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

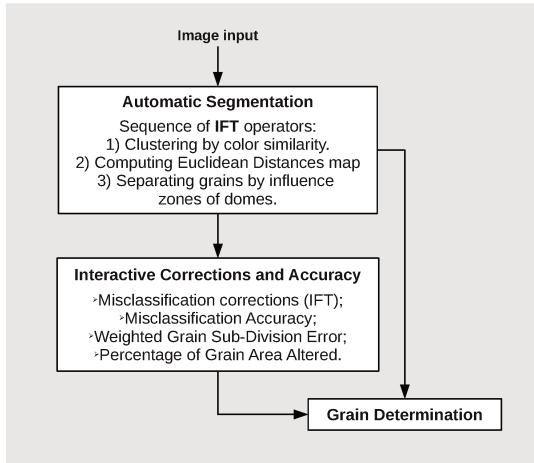


Figure 3.1: Sequence of image operations for grain determination.

an *Euclidean distance transform* (EDT) constrained to propagate inwards from the connected grains' boundaries. The resulting image has domes with peaks inside each grain, which are used to split the grains through a controlled *inverted watershed transform* (i.e., this IFT outputs an image that assigns a unique grain label to every pixel).

Live Markers is an IFT-based method for effective user-steered image segmentation (Spina et al., 2011b). LM allows fine corrections of our automatic approach result by giving the user tight control over the selection of where to do the adjustments. We also use LM to generate ground-truth images to be compared with the automatically segmented image (Choudhury et al., 2006; Falcão et al., 1998; Spina et al., 2011a). We measure the effectiveness of our method by considering our results' accuracy with respect to the ground-truths (Papa et al., 2009b) and the amount of the user's effort required for correction (Spina et al., 2011a).

This paper is organized as follows. We detail our method in Section 3.2. Section 3.3 presents our results and Section 3.4 states conclusion remarks.

3.2 Methods

In the following sections, we first describe the IFT and the image processing operators we use in our automatic grain segmentation method. Then, we describe the automatic segmentation pipeline and how to use Live Markers for interactive correction. Since we allow interactive intervention, we measure the method's accuracy according to the measures proposed in (Spina et al., 2011a) and (Papa et al., 2009b), respectively.

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

3.2.1 Image Foresting Transform

The Image Foresting Transform (IFT) is a generalization of Dijkstra's algorithm (Dijkstra, 1959) which handles multiple sources and more general connectivity functions Falcão et al. (2004). The IFT algorithm works by computing an optimal partition of the graph into sets of nodes (forest), where each set is a tree of *optimum paths* whose nodes are most strongly connected to the *root* of their tree (minima/maxima of the *optimum connectivity map*) than to any other.

The IFT algorithm starts with trivial paths for all the nodes, and propagates optimum paths from the roots by forcing them to compete for the remaining nodes of the graph. The process follows a non-decreasing order of the optimum cost (non-increasing order of connectivity values). The IFT outputs several attributes, organized as mapping functions/images, for each node in the graph that are used differently depending on the image processing operator being designed (Falcão et al., 2004) (e.g., the node's root label, optimum-path cost, and predecessor node in the optimum-path).

3.2.1.1 Graphs from images

Formally, an image \hat{I} can be defined as a pair $(D_{\hat{I}}, \vec{I})$, where $D_{\hat{I}} \subset Z^2$ corresponds to the image domain and $\vec{I}(t)$ determines a color vector $(I_1(t), I_2(t), I_3(t))$ in the RGB color space. The extraction of attributes transforms an image $\hat{I} = (D_{\hat{I}}, \vec{I})$ into a pair $\hat{F} = (D_{\hat{I}}, \vec{F})$, where $\vec{F}(t) = (F_1(t), F_2(t), \dots, F_m(t))$ is a vector of attributes assigned to t . In our case, we seek some lightness invariance by defining \hat{F} using simply the Cb and Cr channels after converting \hat{I} to the YCbCr colorspace (i.e., $m = 2$).

In our approach, a graph $(\mathcal{N}, \mathcal{A})$ may be created by taking a set $\mathcal{N} \subseteq D_{\hat{I}}$ of pixels as nodes and defining an *adjacency relation* \mathcal{A} between the nodes of \mathcal{N} as arcs. The notation $t \in \mathcal{A}(s)$ or $(s, t) \in \mathcal{A}$ indicates that a node $t \in \mathcal{N}$ is adjacent to node $s \in \mathcal{N}$. The adjacency relations we use in our method are:

$$t \in \mathcal{A}_1(s) \quad \text{if} \quad \|t - s\| \leq \sqrt{2}, \forall s, t \in D_{\hat{I}}, \quad (3.1)$$

$$\begin{aligned} t \in \mathcal{A}_2(s) \quad \text{if} \quad & t \in \mathcal{N} \text{ is a } k\text{-nearest neighbor} \\ & \text{of } s \in \mathcal{N} \text{ in the feature space.} \end{aligned} \quad (3.2)$$

The adjacency relation \mathcal{A}_1 is used in the EDT and inverted watershed transform with $\mathcal{N} = D_{\hat{I}}$, making adjacent every 8-neighbor pixel on the image domain. The other adja-

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

cency relation \mathcal{A}_2 is used by the clustering algorithm and will be detailed in section 3.2.1.4. The weights $w(s, t)$ for all arcs $(s, t) \in \mathcal{A}$ are computed in different ways for each IFT-based operator, sometimes using the feature vectors \hat{F} and selected markers (user-drawn strokes, when the user's correction is necessary).

3.2.1.2 Connectivity Functions

A path $\pi_t = \langle t_1, t_2, \dots, t \rangle$ in a graph is a sequence of adjacent nodes ending at node t . The extension of a path π_s by an arc (s, t) is expressed by $\pi_t = \pi_s \cdot \langle s, t \rangle$, with $\pi_t = \langle t \rangle$ denoting the trivial path. A connectivity function f assigns a value $f(\pi_t)$ to any path π_t in a graph, which represents how strongly connected node t is to the path's root. For example, functions f_{\max} and f_{\min} propagate the maximum and minimum arc weight values along the path, respectively

$$\begin{aligned} f_{\max}(\langle t \rangle) &= H(t) \\ f_{\max}(\pi_s \cdot \langle s, t \rangle) &= \max\{f_{\max}(\pi_s), w(s, t)\}, \end{aligned} \quad (3.3)$$

$$\begin{aligned} f_{\min}(\langle t \rangle) &= H(t) \\ f_{\min}(\pi_s \cdot \langle s, t \rangle) &= \min\{f_{\min}(\pi_s), w(s, t)\}, \end{aligned} \quad (3.4)$$

where $H(t)$ is a handicap value specific to each IFT-based operator (Falcão et al., 2004; Spina et al., 2011a).

3.2.1.3 Optimum-path forest

A path π_t is optimum when $f(\pi_t) \leq f(\tau_t)$ for any other path τ_t in $(\mathcal{N}, \mathcal{A})$. An optimum connectivity map $V(t)$ is created by considering every possible path ending at each node $t \in \mathcal{N}$ using the function

$$V(t) = \min_{\forall \pi_t \text{ in } (\mathcal{N}, \mathcal{A})} \{f(\pi_t)\}, \text{ or} \quad (3.5)$$

$$V(t) = \max_{\forall \pi_t \text{ in } (\mathcal{N}, \mathcal{A})} \{f(\pi_t)\}. \quad (3.6)$$

An optimum path forest is computed using the IFT algorithm 1 to solve the above minimization (or maximization) problem. An OPF is an acyclic function P that assigns to every node $t \in \mathcal{N}$ its predecessor $P(t) \in \mathcal{N}$ in an optimum-path or a distinctive marker $P(t) = \text{nil} \notin \mathcal{N}$, when $\langle t \rangle$ is optimum (i.e., t is said a root of the forest). Figure 3.2 rep-

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

resents an OPF computed by forcing the roots to be in the seed set \mathcal{M} using $f_{\max}(\langle t \rangle)$ with $H(t) = 0$ if $t \in \mathcal{M}$, or $H(t) = +\infty$ otherwise.

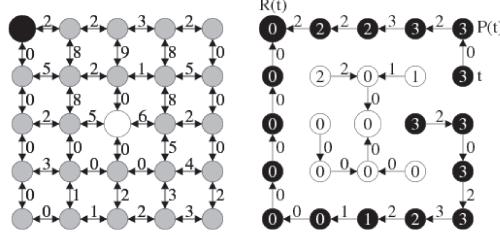


Figure 3.2: (a) A 4-neighborhood graph with set of seeds $\mathcal{M} = \{(0,0), (2,2)\}$, considering the origin $(0,0)$ of pixels coordinates (x, y) in top left and the numbers as arc weights. (b) An optimum-path forest P computed to the function f_{\max} with two roots in S . The numbers inside the nodes show the optimum connectivity map $V(t)$ by Eq. 3.5 and the arrows indicate predecessor node $P(t)$.

The general IFT algorithm solves the minimization (maximization) problem of Eq. 3.5 (Eq. 3.6), for a connectivity function f that satisfies certain conditions required for only optimum paths (Falcão et al., 2004). The root $R(t)$ of each pixel t can be obtained by following its optimum path backwards in P (Figure 3.2b). However, it is more efficient to propagate $R(t)$ on-the-fly, creating a root map.

Algorithm 1 – IFT ALGORITHM FOR f_{\max}

INPUT: Graph $(\mathcal{N}, \mathcal{A})$ and connectivity function f .
OUTPUT: Optimum-path forest P , its connectivity value map V and its root map R .
AUXILIARY: Priority queue Q and variable tmp .

1. **For each** $t \in \mathcal{N}$, **do**
2. $P(t) \leftarrow \text{nil}$, $R(t) \leftarrow t$ and $V(t) \leftarrow f(\langle t \rangle)$.
3. **If** $V(t) \neq +\infty$, **then** insert t in Q .
4. **While** $Q \neq \emptyset$, **do**
5. Remove s from Q such that $V(s)$ is minimum.
6. **For each** $t \in \mathcal{A}(s)$, such that $V(t) > V(s)$, **do**
7. Compute $tmp \leftarrow f(\pi_s \cdot \langle s, t \rangle)$.
8. **If** $tmp < V(t)$, **then**
9. **If** $V(t) \neq +\infty$, **then** remove t from Q .
10. Set $P(t) \leftarrow s$, $R(t) \leftarrow R(s)$, $V(t) \leftarrow tmp$.
11. Insert t in Q .

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

Lines 1–3 initialize maps for trivial paths. The minima of the initial map V compete with each other and some of them become roots of the forest. They are pixels with optimum trivial-path values, which are inserted in queue Q . The main loop computes an optimum path from the roots to every node s in a non-decreasing order of path value (Lines 4–11). At each iteration, a path of minimum value $V(s)$ is obtained in P when we remove its last pixel s from Q (Line 5). Ties are broken in Q using first-in-first-out policy. The remaining lines evaluate if the path that reaches an adjacent pixel t through s is cheaper than the current path with terminus t and update Q , $V(t)$, $R(t)$ and $P(t)$ accordingly.

3.2.1.4 Clustering by optimum-path forest

Let $\mathcal{N} = \mathcal{S} \subset D_{\vec{I}}$ be a set of pixels randomly sampled from the image, such that $|\mathcal{S}| \approx 200$. The clustering process takes a set of sample pixels from \vec{I} , along with their corresponding feature vectors from \vec{F} , and feeds them to an OPF unsupervised classifier (Rocha et al., 2009). High concentration of samples indicates data clusters which are represented by prototypes (key nodes) of the OPF classifier. Each prototype becomes the root of an optimum-path tree (cluster), thus partitioning \mathcal{S} into an optimum-path forest (clustering of \mathcal{S}). The Euclidean distance $d(s, t) = \|\vec{F}(s) - \vec{F}(t)\|$ between the feature vectors $\vec{F}(s)$ and $\vec{F}(t)$, of samples $s, t \in \mathcal{S}$, determines the arc-weights $w(s, t)$ of the graph $(\mathcal{S}, \mathcal{A}_2)$. We compute graph $(\mathcal{S}, \mathcal{A}_2)$ according to those arc weights by considering the k nearest samples t of s when defining the arcs $(s, t) \in \mathcal{A}_2$.

Another parameter used to weigh the nodes of the graph is the probability density function (pdf) computed according to Eq. 3.7. If a region contains a high concentration of samples, the distances between the k nearest neighbors will be smaller, thus resulting in a pdf maximum. Considering that the lowest density along a path in the graph represents its value, and that the optimum path from a pdf maximum to a sample is the one with maximum value, the pdf maxima will compete for samples $s \in \mathcal{S}$ and each maximum will define an influence zone (optimum-path tree or cluster) composed of the samples most strongly connected to it than to any other maximum.

$$\rho(s) = \frac{1}{\sqrt{2\pi\sigma^2}|\mathcal{A}_2(s)|} \sum_{t \in \mathcal{A}_2(s)} \exp\left(\frac{-d^2(s, t)}{2\sigma^2}\right) \quad (3.7)$$

$$\text{where } \sigma = \max_{\forall(s, t) \in \mathcal{A}_2} \left\{ \frac{d(s, t)}{3} \right\}.$$

For such purpose, f_{\min} is used with $H(t) = \rho(t)$, if $t \in \mathcal{R} \subset \mathcal{S}$, where \mathcal{R} is the root (prototype) set of the forest with one sample per pdf maximum, or $H(t) = \rho(t) - \delta$, with

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

$\delta = \min_{(s,t) \in \mathcal{A}_2 | \rho(t) \neq \rho(s)} |\rho(t) - \rho(s)|$, if otherwise. The maximization of f_{\min} using the IFT algorithm automatically defines the prototypes $s \in \mathcal{R}$, which are identified as samples s removed from Q in Line 5 of Algorithm 1 with $P(s) = \text{nil}$. This requires to initialize $V(t) \leftarrow \rho(t) - \delta$ for all pixels $t \in \mathcal{S}$ in Line 2, verify between Lines 5 and 6 if $P(s) = \text{nil}$, and then to set $V(s) \leftarrow \rho(s)$, $C(s) \leftarrow c$, $c \leftarrow c + 1$ (where $c = 1, 2, \dots, |\mathcal{R}|$ is a variable that assigns a unique label c to each cluster), and finally to propagate the cluster labels in Line 11 by adding $C(t) \leftarrow C(s)$.

The unsupervised learning of the OPF classifier consists of finding a suitable value for k in the adjacency relation \mathcal{A}_2 and computing an optimum-path forest in the feature space. If a pdf maximum is located on a plateau, it is necessary to make sure that only one prototype conquers the remaining samples of this maximum. This cannot be solely assured by the initialization of f_{\min} , because \mathcal{A}_2 is not a symmetric adjacency relation. Therefore, \mathcal{A}_2 must be extended to guarantee that plateau samples are interconnected. This is accomplished by defining \mathcal{A}_3 such that if $t \in \mathcal{A}_2(s)$, $s \notin \mathcal{A}_2(t)$, and $\rho(s) = \rho(t)$ then

$$\mathcal{A}_3(t) \leftarrow \mathcal{A}_2(t) \cup \{s\}. \quad (3.8)$$

The choice of the most suitable k is done by computing the result of the algorithm on the graph $(\mathcal{S}, \mathcal{A}_3)$, for $k = k_{\min}, k_{\min} + 1, \dots, k_{\max}$, and selecting the k^* -adjacent graph (and forest) that minimizes the normalized cut (Shi and Malik, 2000).

A sample $t \in D_{\hat{I}} \setminus \mathcal{S}$ is classified in one of the clusters by identifying which root would offer it an optimum path. By considering the adjacent samples $s \in \mathcal{A}_3(t) \subset \mathcal{S}$, we compute $\rho(t)$ using Eq. 3.7, evaluate the paths $\pi_s \cdot \langle s, t \rangle$, and select the one that satisfies

$$V(t) = \max_{\forall (s,t) \in \mathcal{A}_3} \{\min\{V(s), \rho(t)\}\}. \quad (3.9)$$

Let $s^* \in \mathcal{S}$ be the node that satisfies Eq. 3.9. The classification simply assigns $C(s^*)$ as the cluster of t .

3.2.1.5 Euclidean distance transform

In the Euclidean IFT, the path-cost function is such that the cost of a path from a seed s to a pixel t in the forest is the Euclidean distance between s and t in the image domain. The algorithm considers an 8-neighbor image-graph $(D_{\hat{B}}, \mathcal{A}_1)$, derived from a binary image \hat{B} , and assigns three attributes to each object pixel p : the squared Euclidean distance $V(t)$ between t and its closest point s in the contour (forming an optimum path-value map), its closest seed

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

$R(t) = s$ (forming a root map), and the label $L(t) = L(s)$ of the segment that contains s (forming a root label map). The corresponding connectivity function is simply given by

$$\begin{aligned} f_{eucl}(\langle t \rangle) &= H(t) \\ f_{eucl}(\pi_s \cdot \langle s, t \rangle) &= (x_s - x_{R(t)})^2 + (y_s - y_{R(t)})^2 \end{aligned} \quad (3.10)$$

where $s = (x_s, y_s)$ represents the (x, y) coordinates for a pixel s in the image, and $H(t) = 0$ for all samples t in a set \mathcal{B} defined by the pixels belonging to the desired contour.

3.2.1.6 Segmentation by inverted watershed

A classical watershed transform can oversegment the image into all catchment basins of a given grayscale image $I(t)$. The segmentation can be simplified by closing basins of $I(t)$ with volume below a threshold (Salembier et al., 1998) (i.e., a morphological volume closing). Similarly, the inverted watershed segmentation can be controlled by opening the domes of $I(t)$ above a certain threshold value and using the result as grayscale markers for IFT (Lotufo et al., 2002). The accomplishment of such operation via IFT requires the following parameters for segmenting a few regions within the grains. For the image graph $(D_{\hat{f}}, \mathcal{A}_1)$, the weight of edge $(s, t) \in \mathcal{A}_1$ is defined as $w(s, t) = I(t)$. We use function f_{\min} from Eq. 3.4 with

$$H(t) = \begin{cases} I(t) & \text{if } t \in \mathcal{R}, \\ \max\{VO(t) - 1, 0\} & \text{otherwise,} \end{cases} \quad (3.11)$$

where \mathcal{R} is the root set of the forest (maxima of $VO(t) - 1$) and $VO(t)$ is the resulting function from morphological volume opening of $I(t)$. Given that $VO(t) \leq I(t)$, $VO(t) - 1$ is used to guarantee the roots in \mathcal{R} will conquer all pixels in their domes. However, this requires a variant in Algorithm 1. Initially, all pixels start with $H(t) = \max\{VO(t) - 1, 0\}$. When a pixel s is removed from Q in line 5 and $P(s) = \text{nil}$, this implies that $s \in \mathcal{R}$ is a maximum of $VO(t) - 1$ and a new label $l = 1, 2, \dots, |\mathcal{R}|$ must be created for s (i.e., we have the same situation during OPF clustering). By reducing $H(s)$ to $I(s)$ for all maxima s , the image is partitioned into an optimum-path forest with roots in \mathcal{R} , whose result is a controlled segmentation of the image outputting a label map $L(t)$. Note how clustering in the feature-space and watershed transformation in the image domain are closely related by the IFT algorithm.

3.2.2 Automatic Grain Image Segmentation Pipeline

Let $C(t)$ be the cluster image resulting from unsupervised classification using OPF, after merging overlapping clusters (Figures 3.5-b, 3.6-b). Since the grains are brighter than the pores and the background, their cluster is selected to create a binary mask $M(t)$ containing only the grains (Figures 3.5-c, 3.6-c).

We compute the Euclidean IFT using as roots the set of pixels \mathcal{B} from the boundary of grains in $M(t)$. The distance transform is further constrained to propagate inwards with respect to the boundary of the grains in the binary mask (i.e., the optimum-path forest only considers pixels t where $M(t) > 0$). Hence, the final cost map $V(t)$ possesses domes of bright values with maxima located near the center of the corresponding grains. Concurrently, we extract image edges by computing the gradient of the feature image \hat{F} using an 8-neighbor adjacency relation, considering the stronger edge of the Cb and Cr features (Figures 3.5-d, 3.6-d). Afterwards, we combine the distance map $V(t)$ with the edge detection result to better divide the connected domes/grains (Figures 3.5-e, 3.6-e).

The domes are automatically divided using the IFT-based inverted watershed from gray-scale markers previously described, also constrained to the binary segmentation mask $M(t)$. The final result of the inverted watershed transform is an image $L(t)$ that assigns a label $l = 0, 1, \dots, n$ to every pixel representing either the background, $l = 0$, or a unique grain, $l > 0$ (Figures 3.5-f, 3.6-f). Label image $L(t)$ is ready to be used in any other program to compute petrophysical parameters as desired. Examples of automatic grain image segmentation can be seen in Figures 3.5-g, 3.6-g, 3.7-a.

3.2.3 Interactive Correction

Even though our automatic grain image segmentation method is quite effective, such task remains a great challenge. Therefore, the misclassified grains can be corrected interactively by an specialist using Live Markers (Spina et al., 2011b). LM is a hybrid tool that combines two powerful IFT-based methods, the *differential IFT with seed competition* (DIFT-SC) (Falcão and Bergo, 2004) and *live-wire-on-the-fly* (LWOF) (Falcão et al., 2000), benefiting from their best qualities. We use interactive segmentation by LM to both correct misclassification from our automatic approach and to generate ground-truth data.

In DIFT-SC, object delineation relies on the competition between object and background markers (seeds) selected by the user during the object recognition task. The seeds compete to conquer regions of the images using the IFT algorithm with function f_{\max} (Falcão et al., 2004),

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

in a graph $(D_{\hat{f}}, \mathcal{A}_1)$ with arc weights defined by the image edges. The object is defined by the union of optimum-path trees rooted at the object marker pixels (Figure 3.3b). The user can add or remove markers and the segmentation is recomputed differentially only for the region influenced by the altered seed.

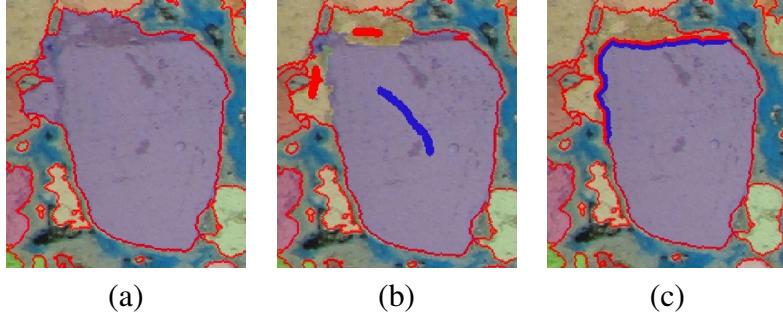


Figure 3.3: (a) Result of automatic segmentation with misclassification. (b) One grain marker and two background markers to correct with DIFT-SC. (c) Correction segment with LWOF. (d) LM correction obtaining better delineation of grain shape.

A different interactive approach is used by LWOF (Falcão et al., 2000), in which delineation aims to have the user roughly guide the computer in selecting the object’s boundary. The object boundary segments are computed with constraints imposed by the user on the frontier between object and background (anchor points). Each segment is an optimum-path computed by the IFT between two adjacents anchor points, and the user guides the segmentation process while watching the optimum-path being generated on-the-fly, from the last point until the current mouse cursor position. Upon the selection of a new anchor point with a mouse click, the optimum-path segment snaps onto the boundary and is fixed throughout the delineation process.

Both of the aforementioned segmentation paradigms have complementary strengths and weaknesses, which can be exploited to reduce the user’s involvement. DIFT-SC is more effective with complex object shapes but inefficient due to leakages in regions with weak boundary information. LWOF allows to segment weak borders being able to block the leaking of DIFT-SC, despite requiring more user interaction and time. LM combines DIFT-SC and LWOF by transforming each boundary segment computed between two anchor points by LWOF into internal and external markers that block DIFT-SC leaking (Figure 3.3c).

LM’s hybrid approach allows the segmentation of the image with linear time in the first iteration and sublinear time in subsequent corrections, further reducing the required amount of the user’s time. Nevertheless, the segmentation quality strongly depends on a good estimation

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

of the arc weights for the IFT graphs (Miranda et al., 2010). The pattern classifiers based on IFT (Papa et al., 2009b; Rocha et al., 2009) are used to automatically choose the marked pixels that best help distinguish the object from the background (3.3b) (Spina et al., 2011a). The best pixels are used to compute a rich image gradient and estimate the arc weights for the DIFT-SC and LWOF graphs. This activity is naturally integrated with LM further simplifying the method's interface, because the approach of (Spina et al., 2011a) also automatically determines where and when the arc weights can be recomputed to maintain the delineation's accuracy.

3.2.4 Evaluation parameters

Accuracy is a parameter usually computed to validate classification processes and the proposition in Papa et al. (2009b) was adapted to evaluate the misclassification. The ground truth image is generated by user's interactive corrections in automatic segmentation result. The accuracy parameter considers changes in the labels occurred during the segmentation correction process, generating a remapped image from the root map and the ground-truth image, identifying which grain pixels kept their labels and which were altered. The different sizes of labels after the corrections are considered. Typical and expected missclassification are shown in Figures 3.3-a, 3.4.

Let n be the number of pixels of the segmented image, and $nelement_{(i)}$ the number of pixels of each label i and $nlabel$ the number of labels after corrections:

$$e_{i,1} = \frac{FP_{(i)}}{n - nelement_{(i)}} \text{ and} \quad (3.12)$$

$$e_{i,2} = \frac{FN_{(i)}}{nelement_{(i)}}, i = 1, \dots, nlabel \quad (3.13)$$

where $FP_{(i)}$ is false positive and $FN_{(i)}$ is false negative. $FP_{(i)}$ is the number of samples from the other label that were classified as being from the label i in n and $FN_{(i)}$ is the number of samples from the class i incorrectly classified from other classes in n . The accuracy parameter is determined by Eq.3.14.

$$Acc = 1 - \frac{\sum_{i=0}^c (e_{i,1} + e_{i,2})}{2(nlabel)} \quad (3.14)$$

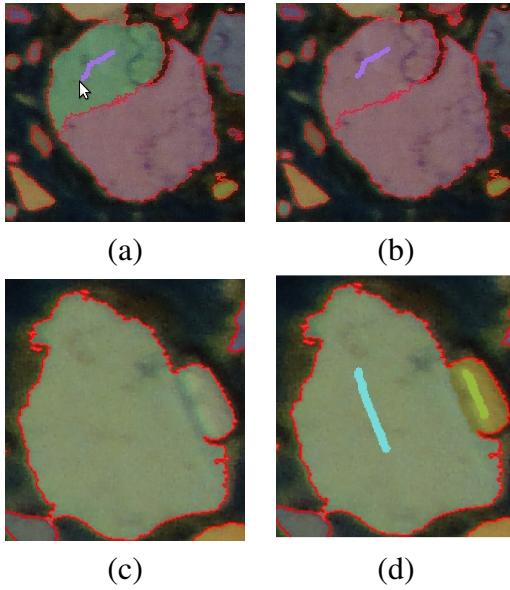


Figure 3.4: Examples of common misclassifications and their corrections. (a) The grain is split in two. The desired label is picked by a tool in the interface and the correction region is marked. (c) The two touching grains are segmented as one. The correction is analog the other, except the creation of a new label. (b) and (d) are the results after running DIFT-SC.

Other parameters are used to quantify the corrections. Weighted Grain Subdivision Error (WGSE) is the sum of the differences between the grain area from automatic segmentation and ground-truth, weighted by the sum of the area of only the corrected grains. For example, if a grain was segmented in four grains in the automatic process, WGSE weighs each area of these subdivisions so that the misclassification in the larger grains become more relevant. To understand the relevance of changes as a whole, Weighted Grain Subdivision Error Global (WGSE - Global) has a slight modification, being weighted by the sum of all grains area of ground-truth image. Similarly, Percentage of Grain Area (PGA) parameter gives another global view computing the area of altered grains weighted by all grains area.

3.3 Results and discussion

The tests were applied to 151 images of sandstone thin sections images, in which porosity is delineated by injection of blue-stained epoxy. In general, all grains were well segmented from the pores and almost all grains in touch were separated properly. They took *ca.* 35 seconds for each 8 megapixel to be processed by a computer with 2.80 GHz CPU frequency, 4GB

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

RAM and using Ubuntu OS. However, there were three groups of missclassification: 79.5% of images need a little user interaction to correct them, 11.9% need more user interaction and effort, and as expected, these misclassifications occurred during separation of touching grains and they were influenced by matrix with quartz grains and rock fragments. In the 8.6% of images, the procedure failed in the segmentation due low pore contrast, high presence of matrix between grains and higher magnification of microscope.

Two more representative samples were chosen to correct and measure the accuracy parameters. Sample S1 (Figure 3.5-a) is a weakly sorted sub-arkose, showing clayey matrix in some portions of the thin section and grain fabric resulting from low compaction and dissolution. The difficulty in segmentation is due the presence of different grain sizes and clay minerals in the fractures and cleavages of the grains. Sample S2 (Figure 3.6-a) is a less porous and better-sorted sub-lithic sandstone. Contacts between grains are more common. Despite the predominance of quartz grains, rock fragment are also present. The rock fragments and the contact between grains interfere in the automatic image segmentation.

The misclassification was characterized by two situation during separation of touching grains. The first situation occurred when the edge was not strong enough between two grains, creating just one label. The other was dark pixels in the grain fabric, creating false edges and extra domes in EDT, consequently creating different grains (Figure 3.7-a). Correction of the first situation was easy by using DIFT-SC makers to add a new label. The second situation was corrected by just using the tool to copy the label from one grain to the other (Figure 3.7-b).

Other misclassification occurred with quartz grains in the matrix that have pixels more similar to the clastic grains, smoothing the edges between them (Figure 3.7-a). The corrections were made by DIFT-SC markers, except when the matrix was darker. In this case, the LM tool was used since the similarity to pore was increased (Figure 3.7-b).

Rock fragments are texturally more heterogeneous, resulting in bright and dark pixels. The algorithm identifies the bright pixels as small grains and the dark pixels as more similar to the pores, and consequently these fragments are not interpreted as only one grain (Figure 3.8-a). To illustrate the differences between corrections of this misclassification, the corrections made in grains (i) and (ii) in Figure 3.8-b using the DIFT-SC tool required more markers than usual, whereas the corrections made in grains (iii) and (iv) in Figure 3.8-b using the LM tool required less markers and effort to obtain a precise segmentation.

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

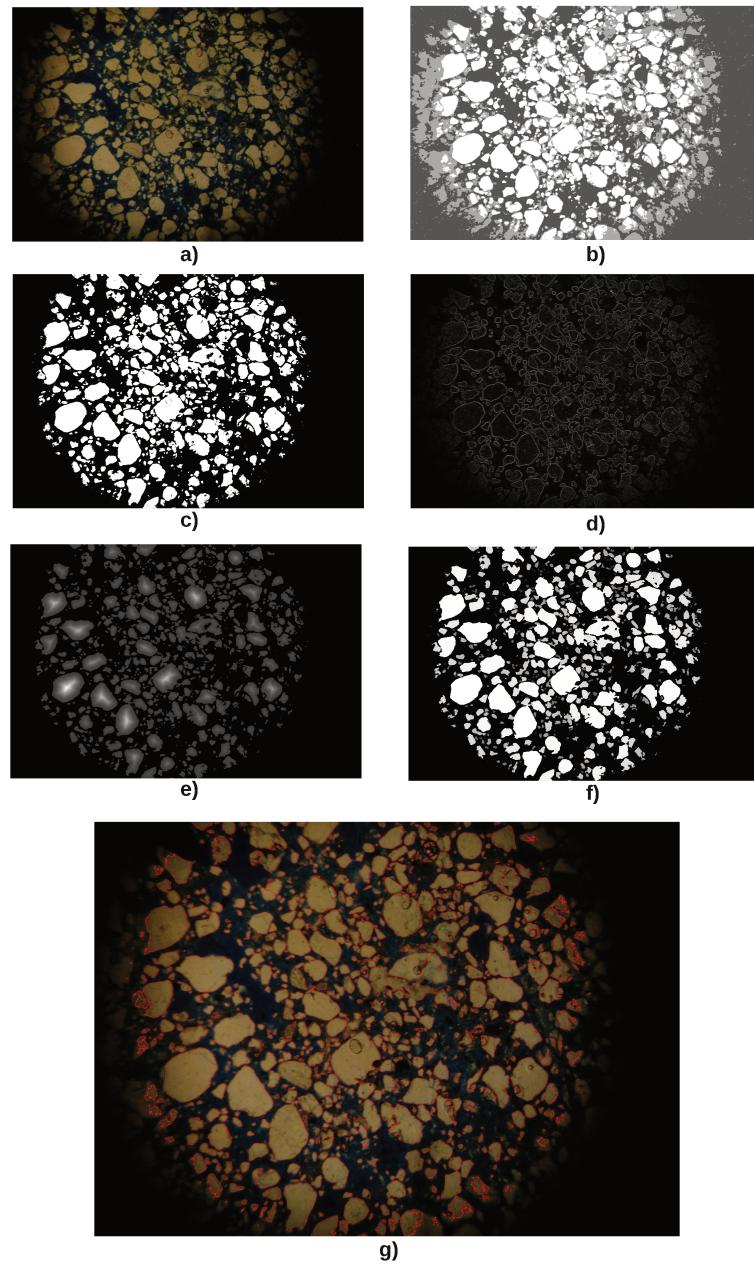


Figure 3.5: (a) Sample S1 - Input image of the porous sandstone, showing irregular grains of varied sizes and clayey matrix. (b) Three-cluster image, including background. (c) Grain binary mask from the brighter clusters. (d) Edges detected by stronger gradient of features Cb and Cr. (e) Combination of Euclidean IFT within grains and edges image. (f) Image of labeled grains. Each grain has its label as pixel values. (g) Original image combined with the image of labeled grain.

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

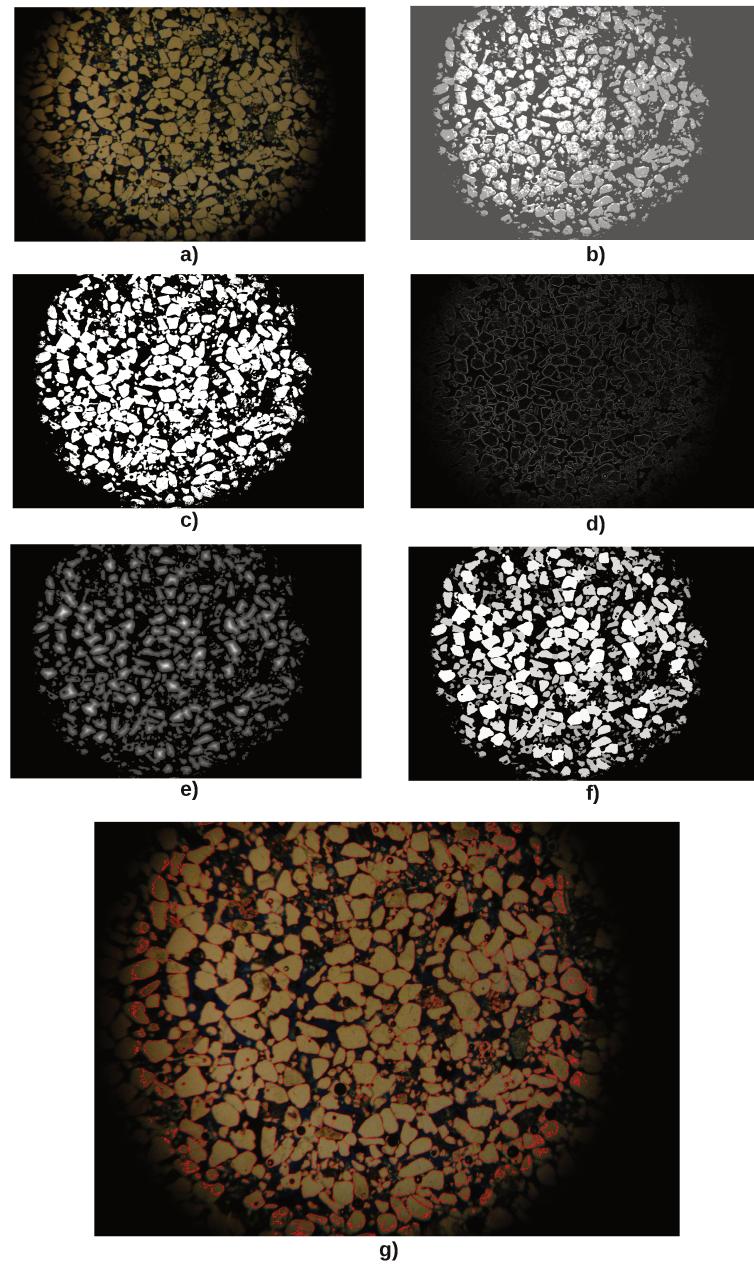


Figure 3.6: (a) Sample S2 - Input image of the more compact sandstone. (b) Three-cluster image, including background. (c) Grain binary mask from the brighter clusters. (d) Edges detected by stronger gradient of features Cb and Cr. (e) Combination of Euclidean IFT within grains and edges image. (f) Image of labeled grains. Each grain has its label as pixel values. (g) Original image combined with image of labeled grain.

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

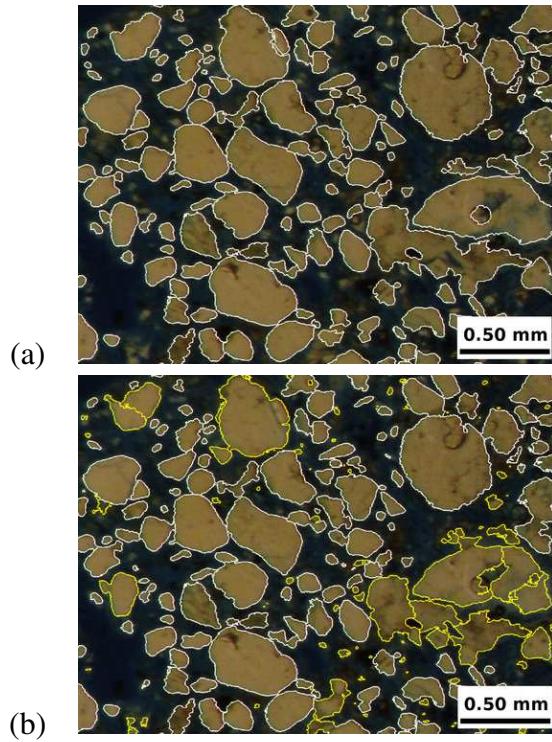


Figure 3.7: (a) Detailed image of grain segmented from the background and others grains. (b) Image with misclassifications corrected by Live Markers.

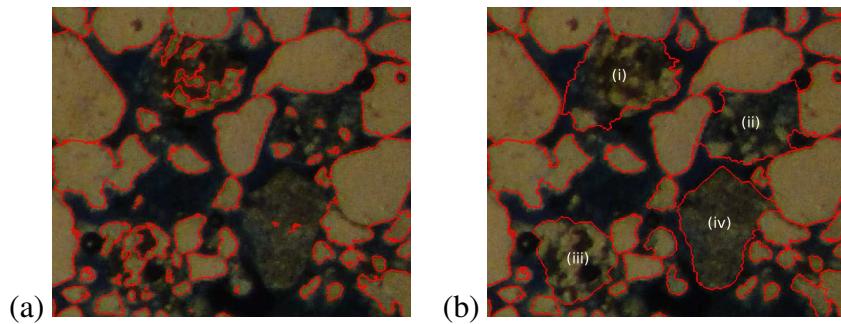


Figure 3.8: (a) Details of misclassification of rock fragments by automatic segmentation. (b) In the correction, DIFT-SC markers had a small leaking in (i) and (ii). LM needed a little more interaction but the delineation was more precise in (iii) and (iv).

A time-consuming process would be deleting tiny grains manually. Thus, a filter was used to delete grains with areas smaller than 10% of average grain area, which corresponded to 254 pixels in sample S1 and 333 pixels in sample S2. Almost 40% of the grains were filtered, corresponding to approximately 1% of the total grain area.

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

The light of compound microscope has created a circular border effect decreasing the pixel brightness from the illuminated to shaded region, making the segmentation of the grains in the shaded region very difficult. These grains were deleted and a considerable area was excluded in the interactive correction.

The final number of grains after the interactive corrections and the ratios between the total grain areas from the ground-truth and the automatic segmentation images are shown in Table 3.1. The corrections of rock fragments in sample S2 led to an increase in the grain-area ratio.

Table 3.1: Comparative results after processes

	Number of grains		Grains area ratio (%)	
	S1	S2	S1	S2
Automatic Segmentation	825	803	-	-
Interactive corrections	409	556	96.2	102.7

The evaluation parameters that compare label changes in the ground-truth image with the automatic segmentation results are highly satisfactory (Table 3.2). The results show the difference between the two samples, given that sample 2 has more matrix and rock fragmentes, demanding more user interaction. Accuracy was higher than 90% and WGSE global lower than 10%, indicating that label changes were few.

Table 3.2: Evaluation parameters results

	S1 (%)	S2 (%)
Accuracy	97.9	91.7
WGSE - Global	6.49	9.47
WGSE	29.1	39.1
PGA	22.3	24.2

Figure 3.9 presents comparison between the total grain areas obtained by automatic segmentation and the respective interactive corrections. If the automatic segmentation were perfect, the points would be aligned in the red line. However, the areas of 9.8% of grains in sample S1 had to be altered and 53.9% of erased grains. For sample S2, the areas of 17.3% of the grains were modified and 40.6% of grains erased. The trend line is represented in blue and R-squared computed for samples S1 and S2 were respectively 0.9365 and 0.8059.

3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS

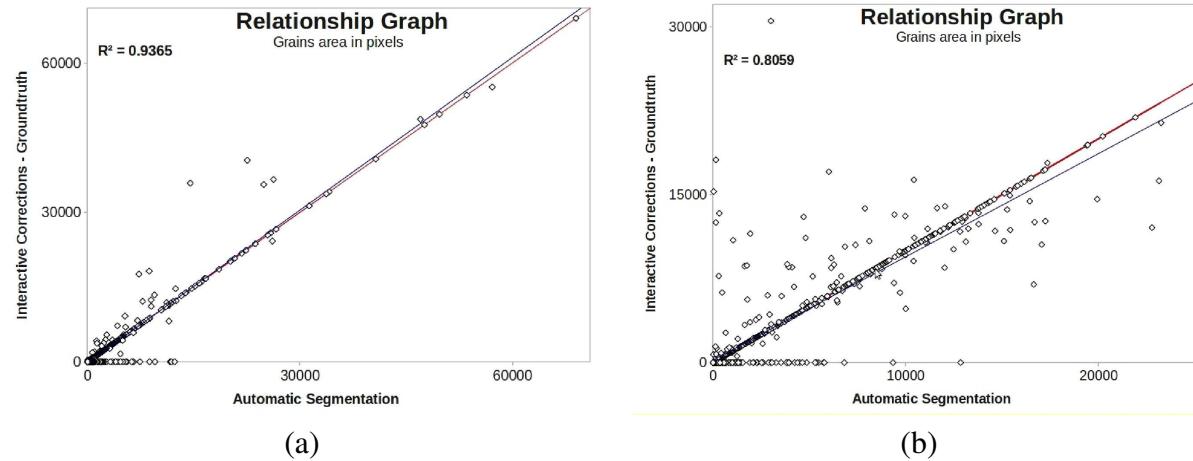


Figure 3.9: Relationship between automatic segmentation areas and interactive corrections area of sample S1 (a) and sample S2 (b).

3.4 Conclusions

A new application of the IFT algorithm in petrophysical image analysis is shown in this work. It proved to be a very quick and precise tool in image segmentation with the advantage of being adaptable to any kind of grain, regardless of its shape or size. An excellent distinction of grains from background and pores is obtained, generating a good binary mask.

The separation of touching grains was relatively good, but with unavoidable misclassification. The option of interactive correction was very easy to use and the effort depends on how precise the specialist wants or needs the segmentation to be. The values of the evaluation parameters comparing the automatic segmentation image with the ground-truth image were very high, proving it to be a reliable automatic process. In other words, the automatic process is an adequate option for a fast result with no need of user interaction.

*3. SEGMENTATION OF SANDSTONE THIN SECTION IMAGES WITH SEPARATION
OF TOUCHING GRAINS USING OPTIMUM-PATH FOREST OPERATORS*

4 Aplicabilidade do método de segmentação automática em análise morfológica dos grãos

4.1 Introdução

O principal objetivo deste capítulo é apresentar possíveis aplicações do método desenvolvido no capítulo 3.

A análise morfológica de partículas sedimentares permite inferir sobre as informações de origem, transporte e ambientes deposicionais de sedimentos. A morfologia do grão pode ser determinada pela combinação de três propriedades independentes: forma – dimensões do grão; arredondamento – suavidade do contorno do grão; e textura – rugosidade da superfície. A fim de demonstrar as possíveis aplicações que podem ser desenvolvidas a partir do método de segmentação automática, descrito no capítulo 3, neste capítulo utilizamos técnicas para determinar a forma dos grãos, na seção 4.1.1. As técnicas utilizadas na seção foram baseadas nos estudos realizados por Aschenbrenner (1956), Barrett (1980) e Benn and Ballantyne (1993).

A porosidade da rocha na análise petrofísica é uma parâmetro de muito interesse para o planejamento da produção dos poços de exploração. Na seção 4.1.2 é realizada uma estimativa da porosidade da rocha baseada na segmentação realizada na imagem.

4.1.1 Determinação da forma do grão

A forma do grão é definida pela determinação de parâmetros como esfericidade (Wadell, 1932; Aschenbrenner, 1956; Snead and Folk, 1958), fator de forma F (Aschenbrenner, 1956), Projeção de Esfericidade Máxima (MSP) (Snead and Folk, 1958) e Índice Oblato-Prolato (Dobkins and Folk, 1970).

Todos esses parâmetros de forma do grão podem ser determinados a partir da medida dos eixos (a) maior, (b) intermediário e (c) menor. Isso torna-se possível a partir do momento em que o método de segmentação automática proposto no capítulo 3 permite gerar uma imagem

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

de rótulos distintos dos grãos. Uma rotina computacional analisa cada grão individualmente, detectando as bordas do grão e por sistema de coordenadas polares. Com isso são determinados os eixos utilizando os pixels da borda. Os trabalhos de Zingg (1935), Aschenbrenner (1956), Snead and Folk (1958) e Dobkins and Folk (1970) propõem as relações da Tabela 4.1 para modelar e representar a forma dos grãos.

Tabela 4.1: Descrição das equações para estimativa da forma do grão de acordo com os três eixos maior (a), intermediário (b) e menor (c). São utilizadas as relações $p = b/a$ e $q = c/b$.

Descrição	Equação	Autor(es)
Razões dos eixos	$p = \frac{b}{a}; q = \frac{c}{b}$	Zingg (1935)
<i>Working Sphericity</i>	$\frac{12.8\sqrt{p^2q}}{1+p(1+q)+6\sqrt{1+p^2(1+q^2)}}$	Aschenbrenner (1956)
Esfericidade de projeção máxima (MSP)	$\sqrt[3]{\frac{c^2}{ac}}$	Sneed and Folk (1958) Aschenbrenner (1956)
Fator de forma F	$\frac{ac}{b^2}$	Aschenbrenner (1956)
Indice Oblato-prolato	$\frac{10((\frac{a-b}{a-c})-0.5)}{\frac{c}{a}}$	Dobkins and Folk (1970)
Indice disco-haste	$\frac{a-b}{a-c}$	Sneed and Folk (1958)

Zingg (1935) propõe um diagrama cartesiano para relacionar as formas dos grãos, sendo que a relação $p = b/a$ é atribuída ao eixo das ordenadas e $q = c/b$ ao eixo das abscissas. As regiões das classes são delimitadas pelos valores $p = 0.67$ e $q = 0.67$, sendo as formas dos seis classificadas de acordo com a Tabela 4.2.

Tabela 4.2: Classes segundo as formas dos seixos segundo Zingg (1935).

Classe	Forma dos seixos
I	Tabular, oblat ou discoidal
II	Equidimensional ou Esférico
III	Laminar ou triaxial
IV	Prolato ou bastonado

O índice de esfericidade primeiramente proposta por Wadell (1932) utiliza as medidas do volume do grão e o volume da maior esfera circunscrita no grão. Krumbein propõe uma aproximação que utilize apenas os eixos propostos por Zingg (1935). Posteriormente, Aschenbrenner (1956) propõe uma aproximação baseada na figura do Tetraedro, denominada

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

'Working Sphericity', também baseada nos eixos principais e que mostra-se ser mais próxima à forma dos detritos dos clastos.

Sneed and Folk (1958) propõem um índice de esfericidade de projeção máxima (MSP), sugerindo que a esfericidade deve ser expressa para seu comportamento em um fluído, representando o arrasto e a força gravitacional que agem em uma partícula imersa em um fluído, sendo um importante índice de comportamento de partículas transportadas ou sedimentadas em água. É considerado um índice útil no contexto hidráulico, porém não pode ser generalizado. O diagrama de Zingg (1935) representa b/a vs c/b e permite Aschenbrenner (1956) expressar a forma dos grãos em termos da 'Working Sphericity' e do Fator de forma F .

Outra proposta realizada por Sneed and Folk (1958) é um diagrama triangular para representar achatamento, alongamento e compactação dos grãos, nos vértices do triângulo. Deste modo, consegue relacionar e dividir as classes em achatado, laminado e alongado, devido à razão c/b e $(a-b)/(a-c)$. O diagrama destaca a característica fundamental das formas e a maneira que convergem no tipo compacta (Figura 4.1-a).

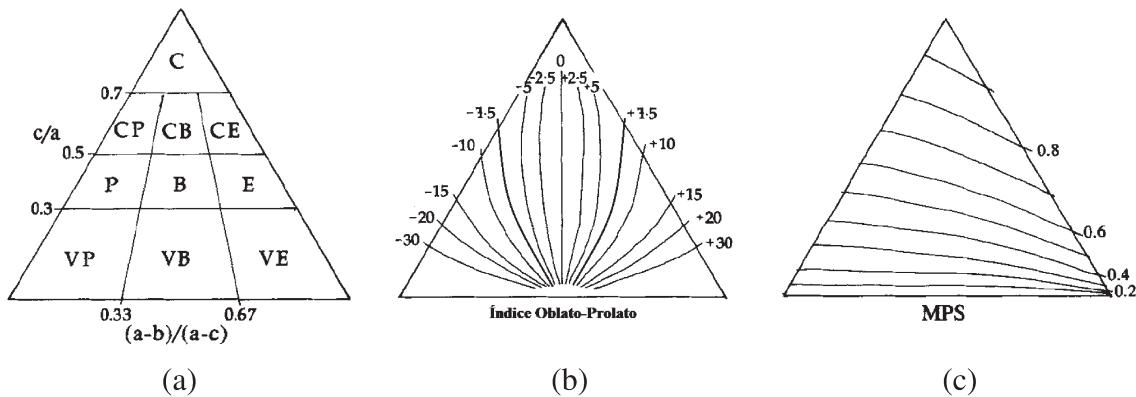


Figura 4.1: Diagramas triangulares (a) as 10 classes descritivas definidas por Sneed and Folk (1958) C - Compact (Compacta), P - Platy (achatada), B - Bladed (laminada), E - Elongate (Alongada) e V - Very (Muito); (b) Isolinhas de Máxima Projeção de Esfericidade (MSP); (c) Isolinhas de Índice de Oblato-Prolato. Figuras adaptadas de Benn e Ballantyne (1993)

Os índices MPS e Oblato-Prolato permitem gerar diagramas triangulares em função de c/b (Figura 4.1-b e 4.1-c). Apesar de todos os gráficos serem gerados do mesmo conjunto de dados, i.e. a partir das dimensões dos eixos principais, uma tendência em um diagrama pode não necessariamente ser legitimada por outro.

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

4.1.2 Estimativa de porosidade da rocha

Os grãos de rocha nunca se encaixam perfeitamente devido à irregularidade nas formas dos grãos. O espaço vazio entre os grãos é denominado poro e é ocupado por fluídos. A porosidade pode ser definida por: $\phi = \frac{V_{poro}}{V_{rocha}}$, onde ϕ é a porosidade, V_{poro} é o Volume do poro e V_{rocha} é o Volume da rocha em análise (Tiab and Donaldson, 2004). Uma estimativa da porosidade da rocha pode ser determinada analisando o número de pixels que compõe a área dos poros e a área total da imagem, levando à $\phi = \frac{A_{poro}}{A_{total}}$, onde A_{poro} corresponde ao número de pixels do poro e A_{total} ao número de pixels total da imagem.

4.2 Resultados e discussão

Para análise morfológica dos grãos foram utilizadas, além das amostras S1 e S2 (apresentados no capítulo 3), mais 5 amostras de arenito para a segmentação automática e correções, denominadas de Amostra S3 a Amostra S7, respectivamente (Tabela 4.3).

Tabela 4.3: Descrição das imagens das amostras

Nome da amostras	Resolução (megapixel)	Breve descrição
S1	14	Menos ampliada, <i>vignetting</i>
S2	14	Menos ampliada, <i>vignetting</i>
S3	14	Menos ampliada, <i>vignetting</i>
S4	14	Mais ampliada, grãos maiores
S5	3.4	Mais ampliada, grãos maiores
S6	3.4	Mais ampliada, grãos maiores
S7	3.4	Mais ampliada, grãos maiores

As novas amostras são semelhantes às Amostras S1 e S2, com diferenças que S5 a S7 têm resolução menor e S4 a S7 estão mais ampliadas, apresentando grãos maiores preenchendo toda a imagem. As imagens S1 a S3 apresentam o efeito de *vignetting* (redução do brilho na periferia da imagem comparado com o centro da imagem), causado pela lente na situação de baixa ampliação do microscópio.

As imagens das amostras S3 a S7 foram segmentadas automaticamente e corrigidas pelo método descrito no capítulo 3. Neste capítulo são apresentadas os resultados apenas das imagens das amostras S3 e S6, os resultados das demais imagens são apresentadas no Anexo A.

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

As Figuras 4.2-a e 4.3-a são os resultados da segmentação automática e as Figuras 4.2-b e 4.3-b são as respectivas correções.

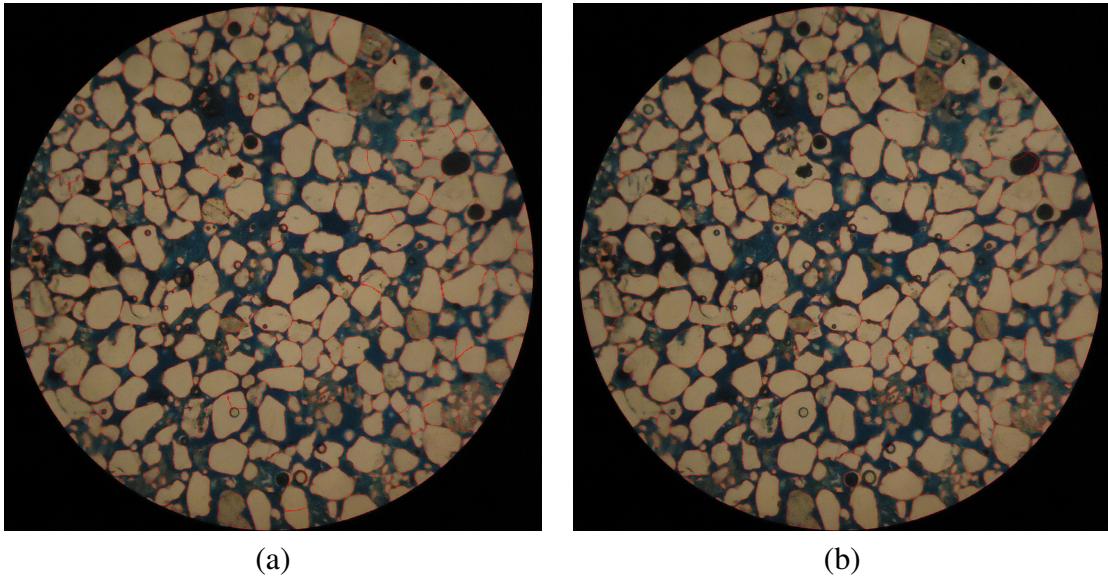


Figura 4.2: (a) Resultado da segmentação automática da Amostra S3. (b) Resultado da correção interativa da Amostra S3.

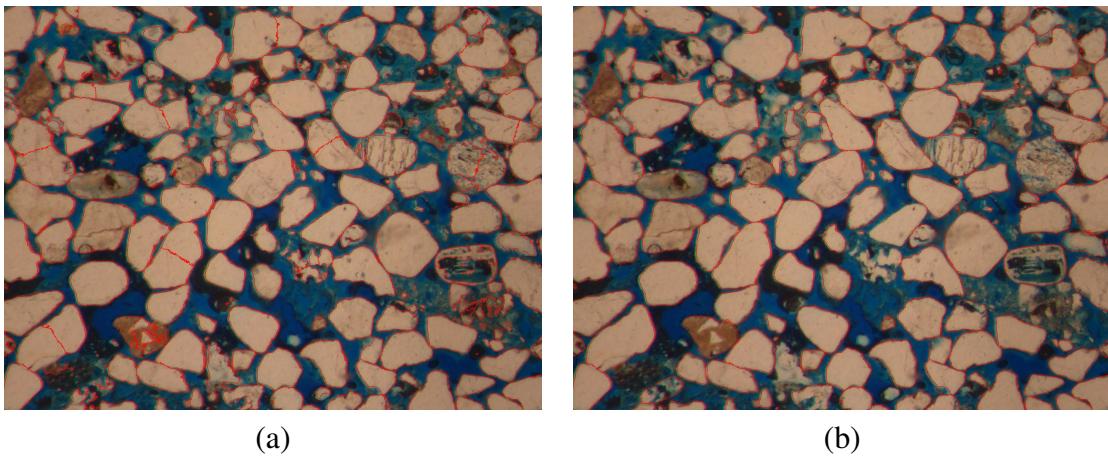


Figura 4.3: (a) Resultado da segmentação automática da Amostra S6. (b) Resultado da correção interativa da Amostra S6.

As medidas de acurárias realizadas de acordo com a seção 3.2.4 e estão apresentadas na Tabela 4.4. Os resultados foram bastante satisfatórios, sendo que as médias das acurárias, WGSE - Global e WGSE foram, repectivamente, 82.4%, 10.4% e 22.7%.

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

Tabela 4.4: Medidas de acurácia do método de segmentação automática e correções.

Nome da amostras	Acurácia (%)	WGSE - Global (%)	WGSE (%)
S1	97.9	6.49	29.1
S2	91.7	9.47	39.1
S3	90.7	9.59	19.3
S4	67.3	14.67	18.3
S5	79.9	15.13	21.3
S6	82.5	14.12	19.9
S7	79.4	3.40	11.7
Média	82.4	10.41	22.7

Os resultados refletem a influência da presença fragmentos de rocha e matriz nas amostras, levando o algoritmo de segmentação automática a interpretar os fragmentos de rocha como pequenos grãos. A presença da matriz faz com que seja necessária a interpretação do especialista para marcar os limites de alguns grãos.

Como o principal objetivo deste capítulo é o estudo da morfologia dos grãos, durante a correção interativa foram descartados os grãos muito diferentes da maioria com coloração muito escura, e mantidos os grãos mais semelhantes ou que conseguiam ser facilmente distinguíveis. Estes grãos representam minerais diagenéticos de óxido de ferro, formados depois da deposição, por isso não podem ser considerados para uma análise morfológica relacionadas a processos deposicionais. Os grãos utilizados na análise representam os grãos de quartzo, que são muitos semelhantes entre si e facilmente distinguíveis. Por consequência, a área total dos grãos corrigidos em relação à área total dos grãos obtidos pela segmentação automática variou de 2%.

Outra observação é a independência da necessidade do fundo escuro, presente nas Amostras S1, S2 e S3. O algoritmo de segmentação automática foi aperfeiçoado de modo a conseguir realizar o agrupamento tanto para recortes de imagens quanto imagens obtidas com maior ampliação e para diferentes resoluções.

Para o estudo da forma dos grãos, a rotina determina os eixos maior, intermediário e menor dos grãos, gerando uma imagem para verificação dos contornos dos grão e os eixos escolhidos. As Figuras 4.4-a e 4.4-b apresentam os resultados. Observa-se nas imagens que os grãos da região de corte das imagens foram influenciados.

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

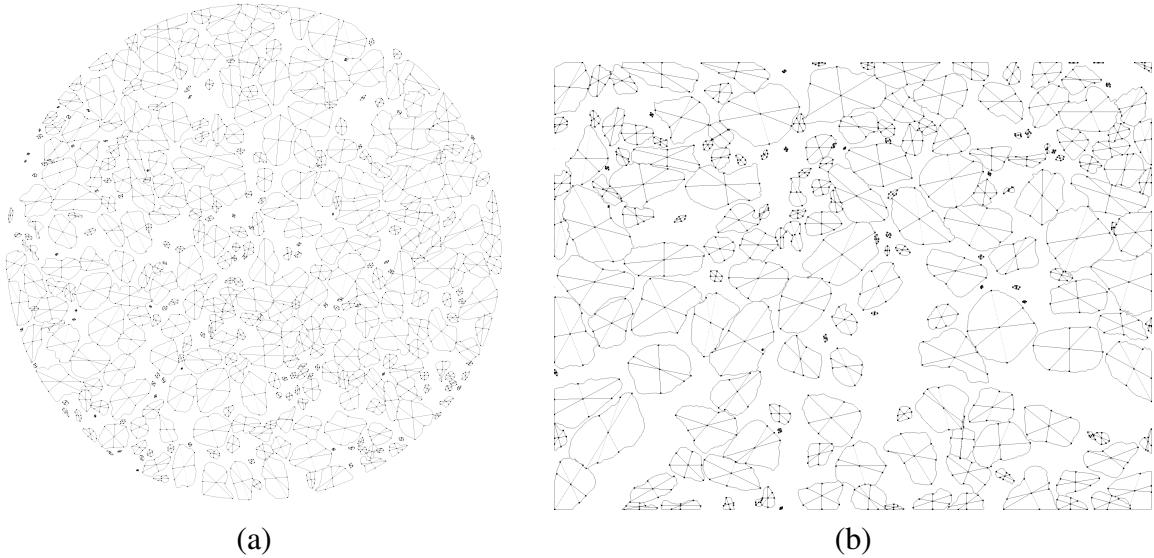


Figura 4.4: Contorno dos grãos e eixos das Amostras S3 (a) e S6 (b).

Com a determinação dos eixos dos grãos, é possível gerar os diagramas 4.5-a e 4.5-b e classificar os grãos segundo o critério de Zingg (1935). A distribuição das classes dos grãos das 7 amostras está apresentada na Tabela 4.5. A distribuição das classes é uniforme entre as classes em todas as amostras.

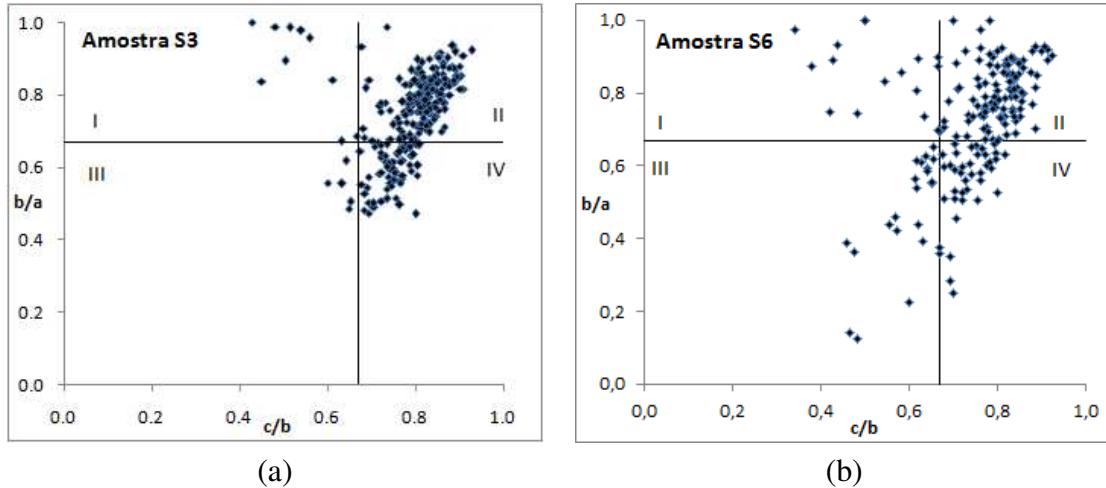


Figura 4.5: Diagramas de Zingg (1935) das amostras S3 (a) e S6 (b).

O diagrama triangular de Sneed and Folk (1958) permite visualizar a distribuição dos grãos pelas classes. As Figuras 4.6a e 4.6b apresentam os diagramas das amostras S3 e S6, respec-

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

tivamente. O percentual da distribuição das classes está detalhado na tabela 4.6. Pode-se observar que a distribuição das classes é uniforme entre as classes em todas as amostras.

Tabela 4.5: Distribuição dos grãos segundo critério de classificação de Zingg (1935).

Nome da amostras	I Tabular (%)	II Equidimensional (%)	III Laminar (%)	IV Prolato (%)
S1	9.0	64.2	12.7	14.1
S2	7.1	58.9	14.1	19.9
S3	4.0	67.5	2.0	26.5
S4	5.3	57.2	6.6	30.9
S5	11.1	54.7	16.7	17.5
S6	9.1	58.3	11.2	21.4
S7	6.2	60.8	11.5	21.5
Média	7.4	60.2	10.7	21.7
Desvio Padrão	2.5	4.4	4.9	5.6

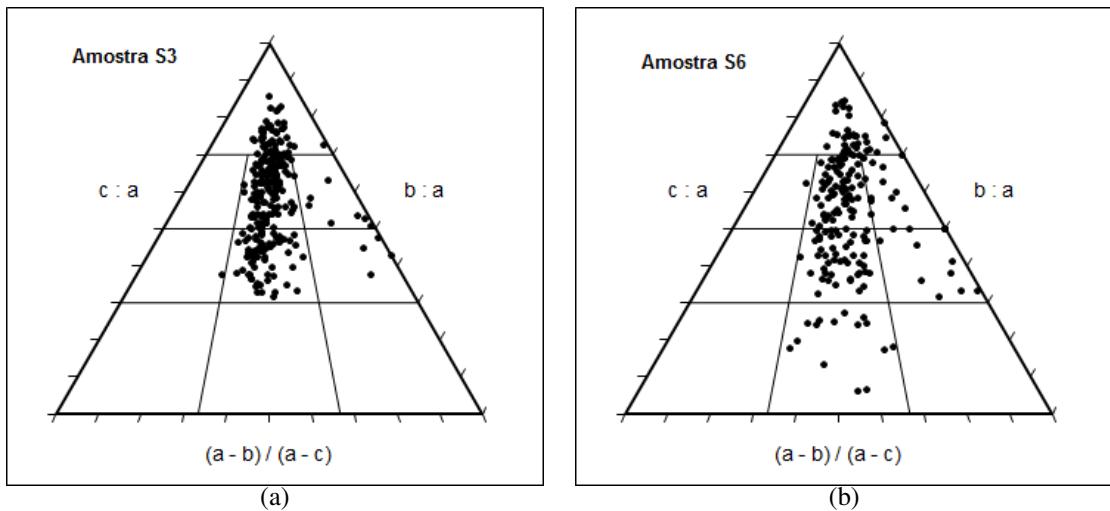


Figura 4.6: Diagrama para determinação de classes das amostras S3 (a) e S6 (b) segundo critério de classificação de Sneed and Folk (1958).

Os diagramas apresentam a distribuição da frequência de Fator de Forma F e do parâmetro de esfericidade, obtidos para amostras S3 (Figuras 4.7a e 4.7c) e S6 (Figuras 4.7b e 4.7d), respectivamente. Apesar das imagens possuirem resoluções e ampliações diferentes, não apresentaram diferenças significativas nas distribuições, pois são do mesmo tipo de amostra.

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

Tabela 4.6: Distribuição dos grãos segundo critério de classificação de Sneed and Folk (1958) para as 7 amostras.

Nome da amostras	C (%)	CP (%)	CB (%)	CE (%)	P (%)	B (%)	E (%)	VP (%)	VB (%)	VE (%)
S1	15.8	0.0	39.7	8.5	0.0	24.8	3.4	0.0	7.1	0.7
S2	16.3	0.0	36.2	7.4	0.0	27.0	3.9	0.0	8.9	0.4
S3	19.3	0.0	49.8	2.8	0.4	26.1	1.6	0.0	0.0	0.0
S4	14.5	0.0	45.4	4.6	0.7	23.7	3.9	0.0	5.9	1.3
S5	12.7	0.0	42.9	6.3	0.8	19.0	7.9	0.8	6.3	3.2
S6	17.6	0.5	35.8	5.3	0.0	25.7	7.0	0.0	8.0	0.0
S7	16.9	0.0	41.5	4.6	0.0	21.5	5.4	0.0	9.2	0.8
Média	16.2	0.1	41.6	5.7	0.3	24.0	4.7	0.1	6.5	0.9
Desvio Padrão	2.1	0.2	5.0	1.9	0.3	2.8	2.2	0.3	3.1	1.1

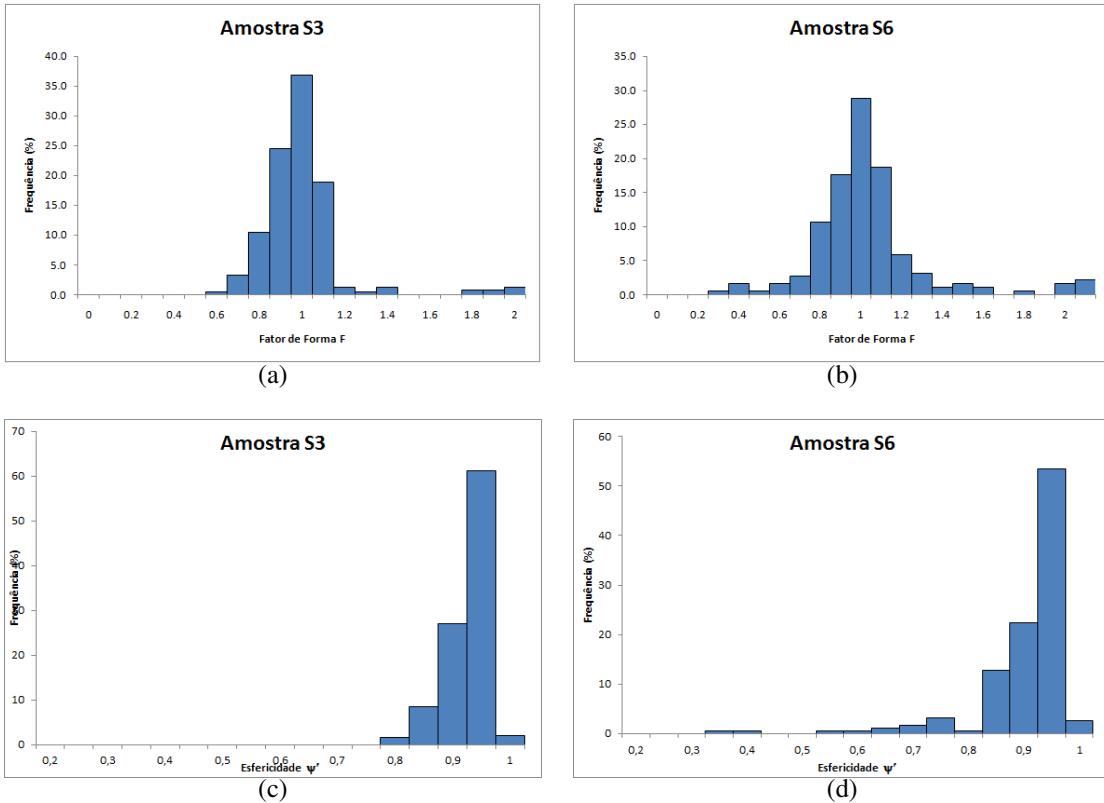


Figura 4.7: Diagrama de frequência de Fator de Forma das amostras S3 (a) e S6 (b); Diagrama de frequência da esfericidade das amostras S3 (c) e S6 (d).

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

Os diagramas triangulares na Figura 4.8 mostram a distribuição do Índice Oblato-Prolato dos grãos e as respectivas isolinhas. Ao lado, encontram-se os respectivos diagramas de distribuição de frequência de ocorrência dos valores para quantificação e análise. Os resultados nas Figuras 4.8a e 4.8b são da amostra S3 e Figuras 4.8c e 4.8d são da amostra S6.

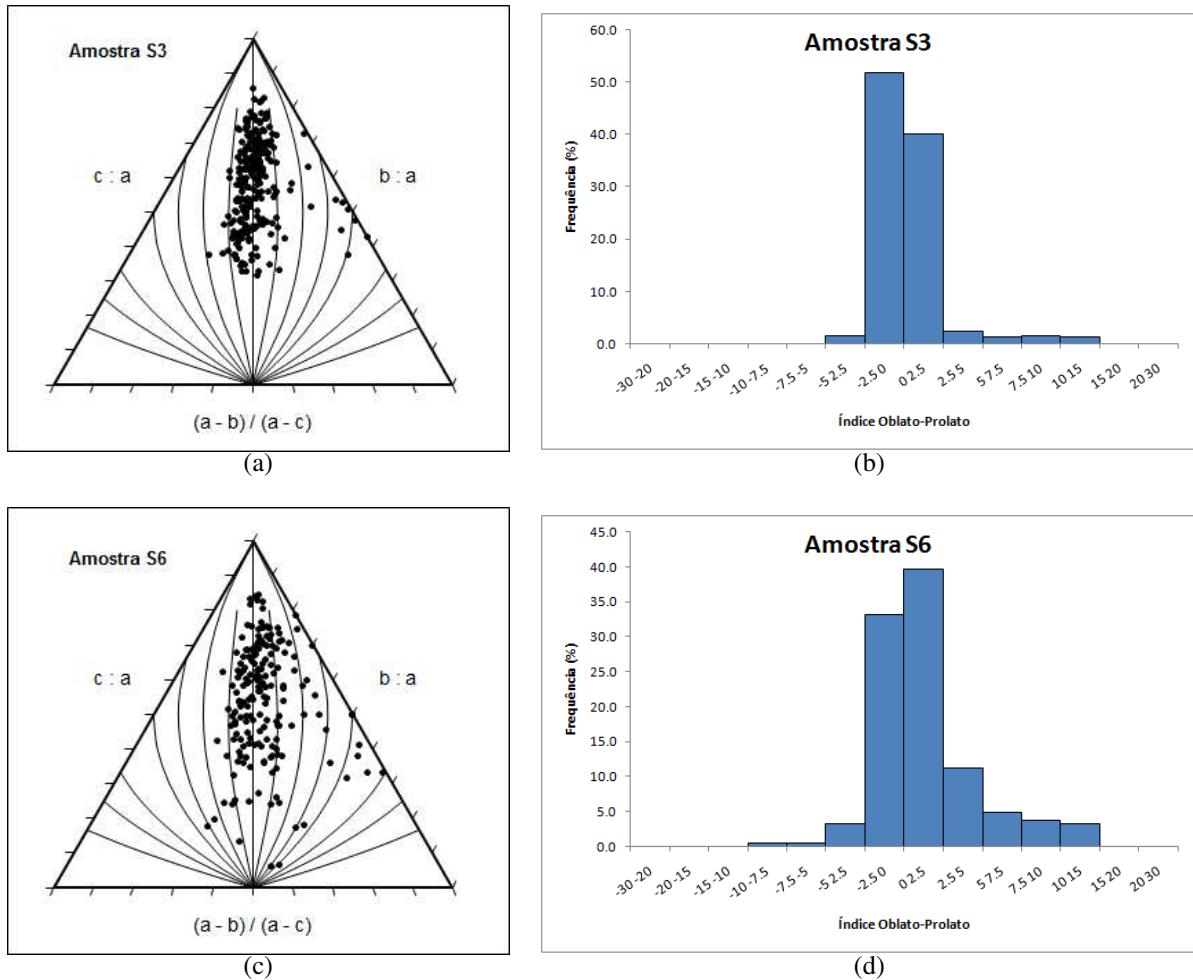


Figura 4.8: Diagrama triangular do Índice Oblato-Prolato das amostras S3 (a) e S6 (c); Diagrama de frequência dos respectivos Índices Oblato-Prolato das amostras S3 (b) e S6 (d).

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

Analogamente, a Figura 4.9 apresenta os diagramas triangulares da distribuição do Índice MSP e as isolinhas, juntamente com os diagramas de distribuição de frequência, das amostras S3 nas Figuras 4.9a e 4.9b, e S6 em 4.9c e 4.9d. Novamente podemos observar que não houve discrepância entre as amostras.

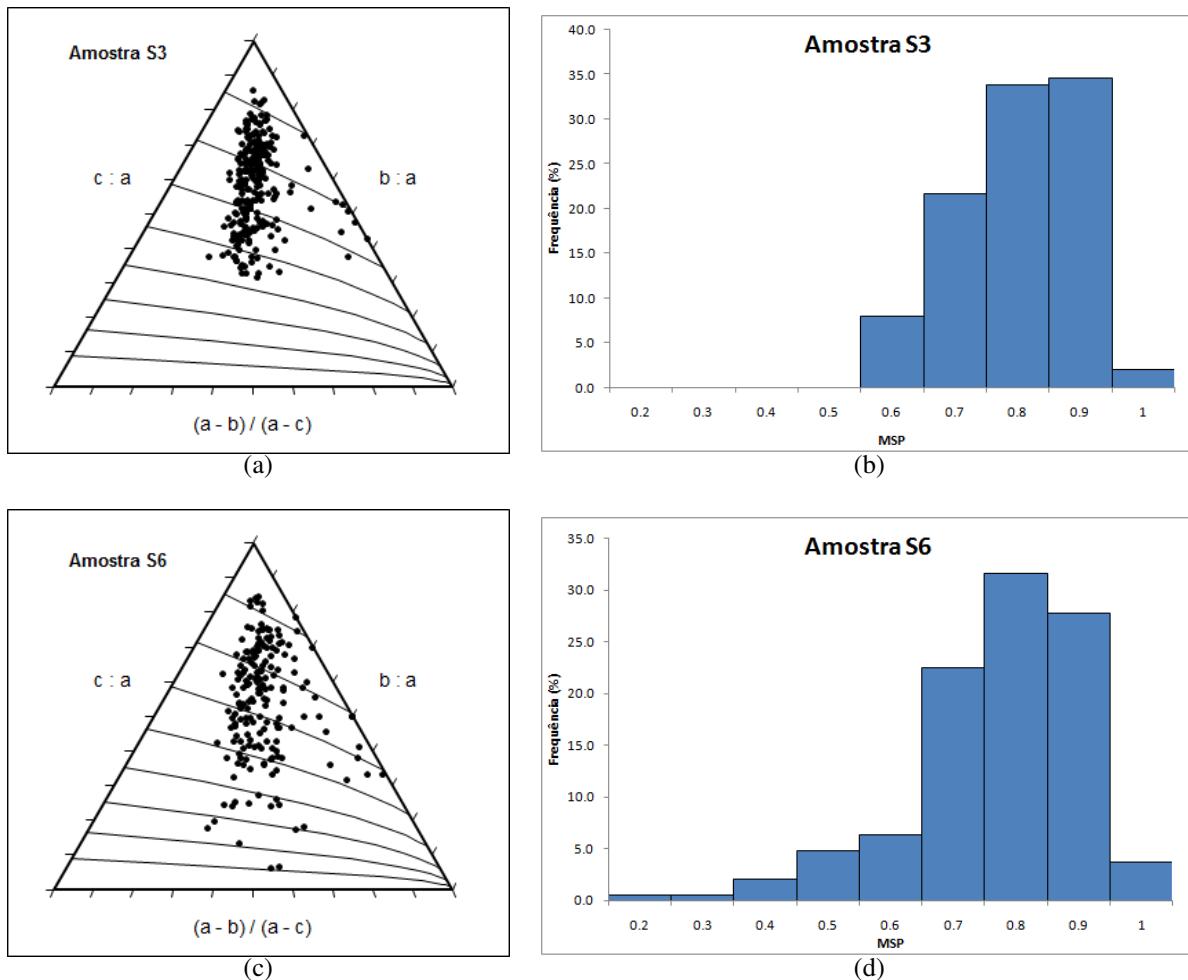


Figura 4.9: Diagrama triangular do Índice MSP das amostras S3 (a) e S6 (c); Diagrama de frequência dos respectivos Índices MSP das amostras S3 (b) e S6 (d).

Os resultados obtidos quanto a forma comprovam a semelhança entre as amostras, entretanto, a análise possibilita um estudo mais robusto conforme o grande número de medidas realizadas. Assim, novos parâmetros podem ser obtidos, o que ocasionará a melhor descrição da rocha.

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

A porosidade da rocha foi estimada para as amostras S4 a S7, pois não possuem o efeito de vignetting, já que a região mais escura do fundo acabaria sendo considerada como poro. Os resultados apresentam-se na Tabela 4.7.

Tabela 4.7: Porosidade estimada.

Nome da amostra	ϕ (%)
S4	41.8
S5	39.9
S6	43.8
S7	43.7

Os resultados de porosidade apontam as boas condições de reservatórios para essas amostras. As amostras são provenientes da Formação Botucatu, um importante aquífero da Bacia do Paraná.

4.3 Conclusões

Os resultados deste capítulo demonstram algumas aplicações para o método de segmentação automática. Foram utilizadas mais 5 imagens de amostras semelhantes às utilizadas no capítulo 3, de lâminas delgadas de rocha semelhantes. Os resultados apresentam altas médias de acurácia do método, reforçando aplicação do método para esse fim. A presença de fragmentos de rocha e matriz nas amostras influenciaram nos resultados, sendo a técnica melhor aplicada para amostras com pouca matriz e mais homogênea em relação a composição mineralógica.

A morfologia do grão pode ser determinada por três propriedades: forma, arredondamento e textura. Neste estudo foi apresentado a utilização dos resultados do método de segmentação automática com o objetivo de definir a forma dos grãos, uma vez que o problema de contato entre grãos está solucionado pelo método de segmentação. Além disso, o fato da técnica ser supervisionada por um especialista, permite o ajuste da imagem para realização das medidas dos eixos e a análise dos grãos. A aplicação mostrou-se bastante satisfatória, pois os diagramas apresentados tiveram alta coerência com a interpretação realizada nas amostras. Houve pequena influência da presença de fragmentos de rocha e matriz nas amostras.

Para trabalhos futuros, a sugestão é que os grãos que estejam na borda das imagens sejam eliminados para melhorar o estudo morfológico. Os grãos não foram eliminados visando manter um padrão nas correções para uma uniformidade no cálculo das acurárias.

4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM ANÁLISE MORFOLÓGICA DOS GRÃOS

Outras sugestões são o aperfeiçoamento da estimativa da porosidade da rocha e o estudo das possibilidades de determinação da permeabilidade a partir da porosidade, descrita em (Tiab and Donaldson, 2004), bem como a tortuosidade e conectividade dos poros.

*4. APLICABILIDADE DO MÉTODO DE SEGMENTAÇÃO AUTOMÁTICA EM
ANÁLISE MORFOLÓGICA DOS GRÃOS*

5 Referências Bibliográficas

Referências Bibliográficas

- Aschenbrenner, B.C., 1956. A New Method of Expressing Particle Shericity. *Journal of Sedimentary Petrology* Vol. 26, 15–31.
- Barrett, P.J., 1980. The shape of rock particles, a critical review. *Sedimentology* 27, 291–303.
- Benn, D.I., Ballantyne, C.K., 1993. The description and representation of particle shape. *Earth Surface Processes and Landforms* 18, 665–672.
- Bishop, C.M., 1994. Neural networks and their applications. *Review of Scientific Instruments* 65, 1803 –1832.
- Chiachia, G., Falcao, A., Rocha, A., 2011. Person-specific face representation for recognition, in: *Biometrics (IJCB)*, 2011 International Joint Conference on, IEEE. pp. 1–8.
- Choudhury, K.R., Meere, P.A., Mulchrone, K.F., 2006. Automated grain boundary detection by casrg. *Journal of Structural Geology* 28, 363–375.
- Dengiz, O., Smith, A.E., Nettleship, I., 2005. Grain boundary detection in microstructure images using computational intelligence. *Comput. Ind.* 56, 854–866.
- Deutsch, C.V., 2002. *Geostatistical Reservoir Modeling*. Oxford University Press, Inc., New York, New York.
- Dijkstra, E.W., 1959. A note on two problems in connexion with graphs. *Numerische Mathematik* 1, 269–271.
- Dobkins, J., Folk, R., 1970. Shape development on tahiti-nui. *Journal of Sedimentary Petrology* 4, 1167–1203.
- Ehrlich, R., Chin, M., 1980. Fourier grain-shape analysis: A new tool for sourcing and tracking abyssal silts. *Marine Geology* 38, 219–231.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- Falcão, A., Udupa, J., Miyazawa, F., 2000. An ultra-fast user-steered image segmentation paradigm: Live-wire-on-the-fly. *IEEE Transactions on Medical Imaging* 19, 55–62.
- Falcão, A.X., Bergo, F.P.G., 2004. Interactive volume segmentation with differential image foresting transforms. *IEEE Transactions on Medical Imaging* 23, 1100–1108.
- Falcão, A.X., Stolfi, J., Lotufo, R.A., 2004. The image foresting transform: Theory, algorithms, and applications. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 26, 19–29.
- Falcão, A.X., Udupa, J.K., Samarasekera, S., Sharma, S., Hirsch, B.E., Lotufo, R.A., 1998. User-steered image segmentation paradigms: Live-wire and live-lane. *Graphical Models and Image Processing* 60, 233–260.
- Girao, G., 2006. Site da hydrolog, serviços de perfilagem ltda. <http://geraldogirao.com/apostilas.htm/>.
- Gorsevski, P.V., Onasch, C.M., Farver, J.R., Ye, X., 2012. Detecting grain boundaries in deformed rocks using a cellular automata approach. *Computers & Geosciences* 42, 136–142.
- Haykin, S., 2001. Redes Neurais - Princípios e Prática. Bookman Companhia Ed.
- Hecht-Nielsen, R., 1990. Neurocomputing. Addison-Wesley Publishing Company, Redwood City.
- Kohonen, T., Schroeder, M.R., Huang, T.S. (Eds.), 2001. Self-Organizing Maps. Springer-Verlag New York, Inc., Secaucus, NJ, USA. 3rd edition.
- Krumbein, W., . Measurement and geological significance of shape and roundness of sedimentary particles. *Journal of Sedimentary Petrology* 11, 64–72.
- Li, Y., Onasch, C.M., Guo, Y., 2008. Gis-based detection of grain boundaries. *Journal of Structural Geology* 30, 431–443.
- Lotufo, R., Falcão, A., Zampirolli, F., 2002. IFT-Watershed from gray-scale marker, in: Proceedings of XV Brazilian Symp. on Computer Graphics and Image Processing, IEEE. pp. 146–152.
- Lu, B., Cui, M., liu liu liu liu, Q., Wang, Y., 2009. Automated grain boundary detection using the level set method. *Computers & Geosciences* 35, 267–275.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- Lu, B., Ning, C., 2010. Pde-based grain boundary detection, in: IITA-GRS 2010 volume 2 content, pp. 170–173.
- Maschio, C., Vidal, A.C., Schiozer, D.J., 2008. A framework to integrate history matching and geostatistical modeling using genetic algorithm and direct search methods. *Journal of Petroleum Science and Engineering* 63, 34–42.
- Miranda, P.A.V., Falcão, A.X., Udupa, J.K., 2010. Synergistic Arc-Weight Estimation for Interactive Image Segmentation using Graphs. *Computer Vision and Image Understanding* 114, 85–99.
- Miyoshi, S.d.C., 2010. Modelo Kernel PCA-Genético para Ajuste de Histórico. Master's thesis. Pontifícia Universidade Católica do Rio de Janeiro.
- Papa, J., Falcao, A., Suzuki, C., 2009a. Supervised pattern classification based on optimum-path forest. *International Journal of Imaging Systems and Technology* 19, 120–131.
- Papa, J., Nakamura, R., de Albuquerque, V., Falcão, A., Tavares, J., 2012. Computer techniques towards the automatic characterization of graphite particles in metallographic images of industrial materials. *Expert Systems With Applications* .
- Papa, J.P., Falcão, A.X., Suzuki, C.T.N., 2009b. Supervised pattern classification based on optimum-path forest. *International Journal of Imaging Systems Technology* 19, 120–131.
- Rocha, L.M., Cappabianco, F.A.M., Falcão, A.X., 2009. Data clustering as an optimum-path forest problem with applications in image analysis. *International Journal of Imaging Systems and Technology* 19, 50–68.
- Salembier, P., Oliveras, A., Garrido, L., 1998. Antiextensive connected operators for image and sequence processing. *IEEE Transactions on Image Processing* 7, 555–570.
- Shi, J., Malik, J., 2000. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 22, 888–905.
- Sneed, E.D., Folk, R.L., 1958. Pebbles in the Lower Colorado River, Texas a Study in Particle Morphogenesis. *Journal of Geology* 66, 114–150.
- Spina, T.V., Falcão, A.X., Miranda, P.A.V., 2011a. Intelligent understanding of user interaction in image segmentation. *International Journal of Pattern Recognition and Artificial Intelligence* To appear.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- Spina, T.V., Falcão, A.X., Miranda, P.A.V., 2011b. User-steered image segmentation using live markers, in: International Conference on Computer Analysis of Images and Patterns (CAIP), Springer-Verlag, Seville, Spain. To appear.
- Suzuki, C., Gomes, J., Falcao, A., Papa, J., Hoshino-Shimizu, S., 2012. Automatic segmentation and classification of human intestinal parasites from microscopy images .
- Tiab, D., Donaldson, E., 2004. Petrophysics: Theory and Practice of Measuring Reservoir Rock and Fluid Transport Properties.
- Van de Berg, E., Meesters, A., Kenter, J., Schlager, W., 2002. Automated separation of touching grains in digital images of thin sections. Computers & Geosciences , 179–190.
- Wadell, H., 1932. Volume, Shape, and Roundness of Rock Particles. Journal of Geology 40, 443–451.
- Yu, C., Ruppert, G., Nguyen, D., Falcao, A., Liu, Y., 2012. Statistical asymmetry-based brain tumor segmentation from 3d mr images. Proc. of the Intl. Conf. on Bio-inspired Systems and Signal Processing (BIOSIGNALS) , 527–533.
- Zingg, T., 1935. Beitrag zur Schotteranalyse. Schweizerische Mineralogische und Petrographische Mitteilungen 15, 38–140.

A

Imagens dos resultados da segmentação automática e correções interativas

A. IMAGENS DOS RESULTADOS DA SEGMENTAÇÃO AUTOMÁTICA E CORREÇÕES INTERATIVAS

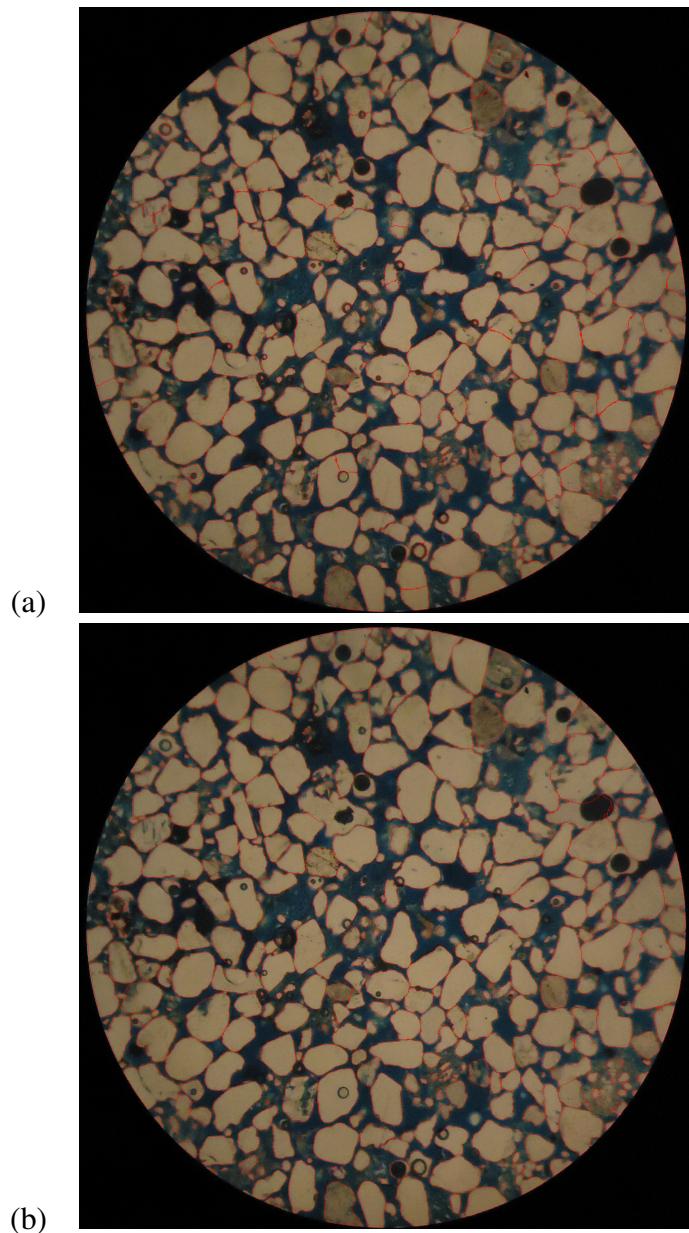


Figura A.1: (a) Resultado da segmentação automática da Amostra S4 (b) Resultado da correção interativa da Amostra S4.

A. IMAGENS DOS RESULTADOS DA SEGMENTAÇÃO AUTOMÁTICA E CORREÇÕES INTERATIVAS

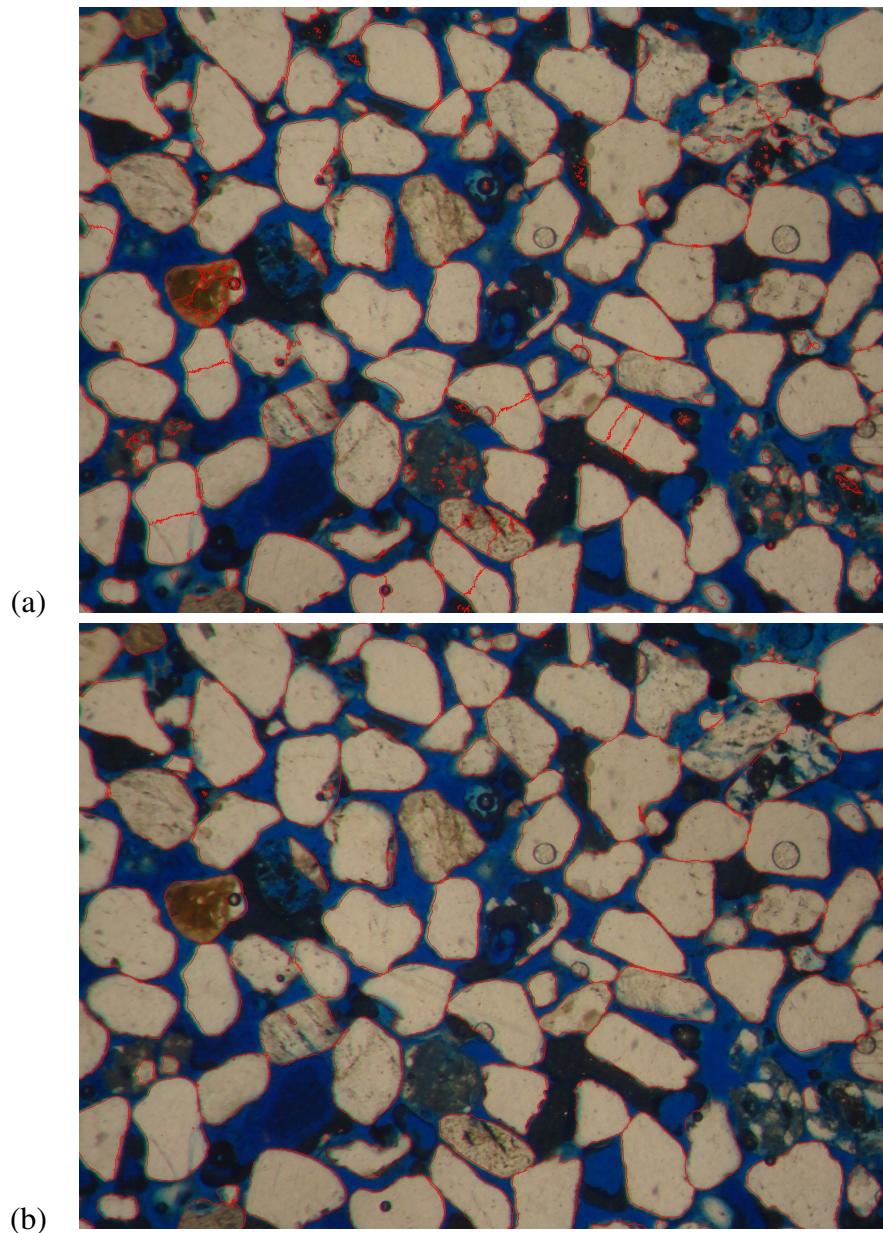


Figura A.2: (a) Resultado da segmentação automática da Amostra S5 (b) Resultado da correção interativa da Amostra S5.

A. IMAGENS DOS RESULTADOS DA SEGMENTAÇÃO AUTOMÁTICA E CORREÇÕES INTERATIVAS

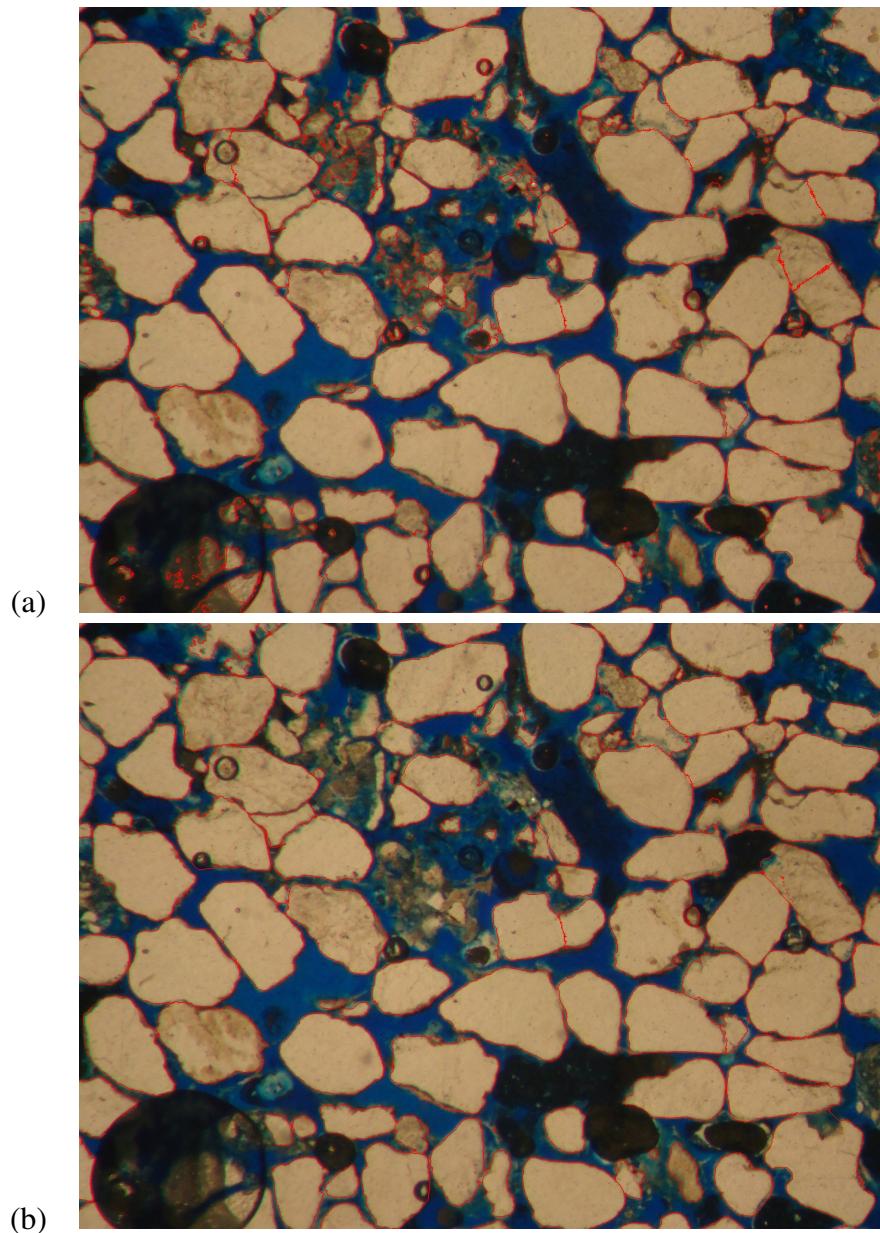


Figura A.3: (a) Resultado da segmentação automática da Amostra S7 (b) Resultado da correção interativa da Amostra S7.

B

Imagens dos contornos e eixos dos grãos

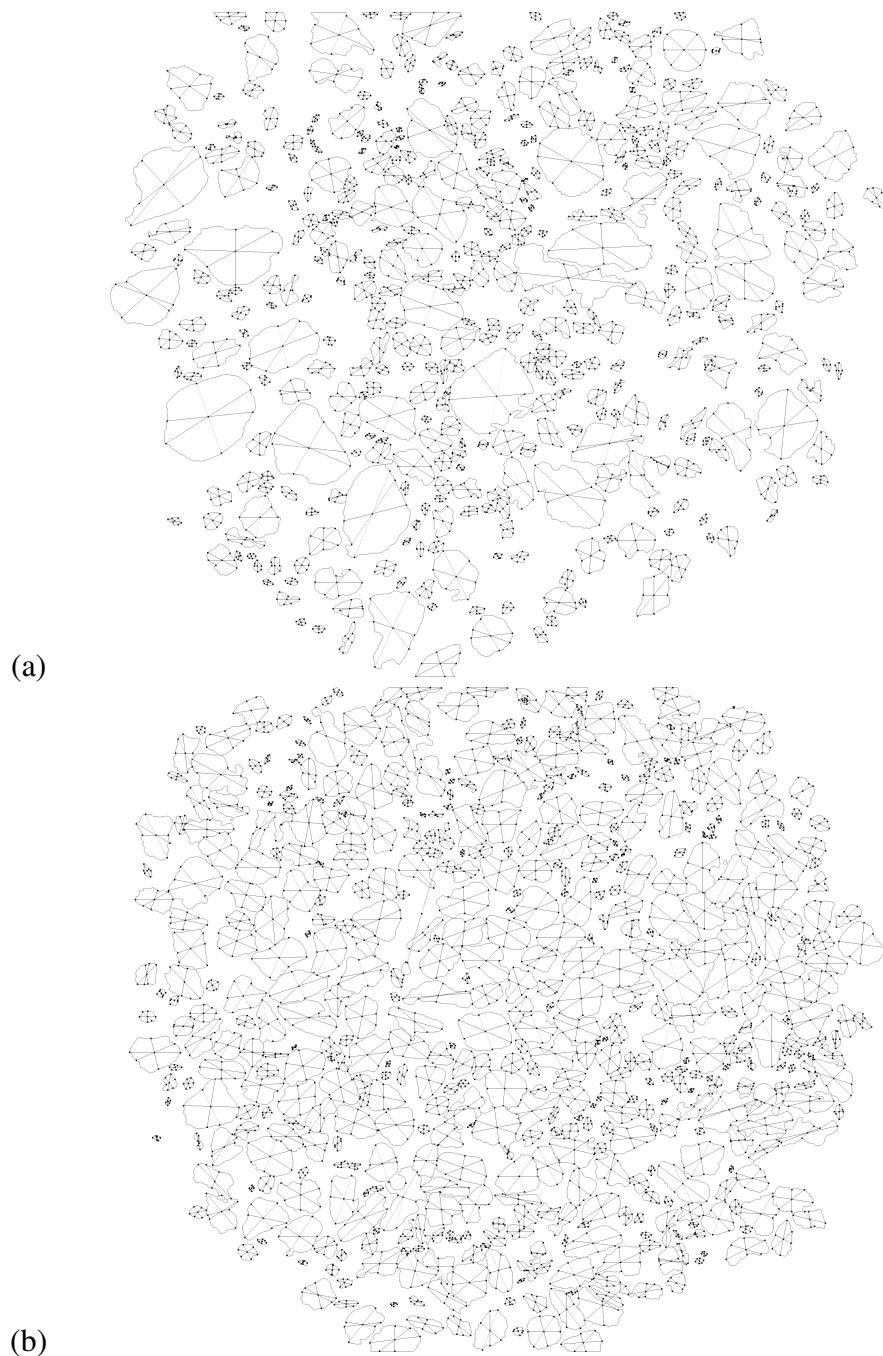


Figura B.1: Contorno dos grãos e eixos das amostras: (a) S1 (b) S2.

B. IMAGENS DOS CONTORNOS E EIXOS DOS GRÃOS

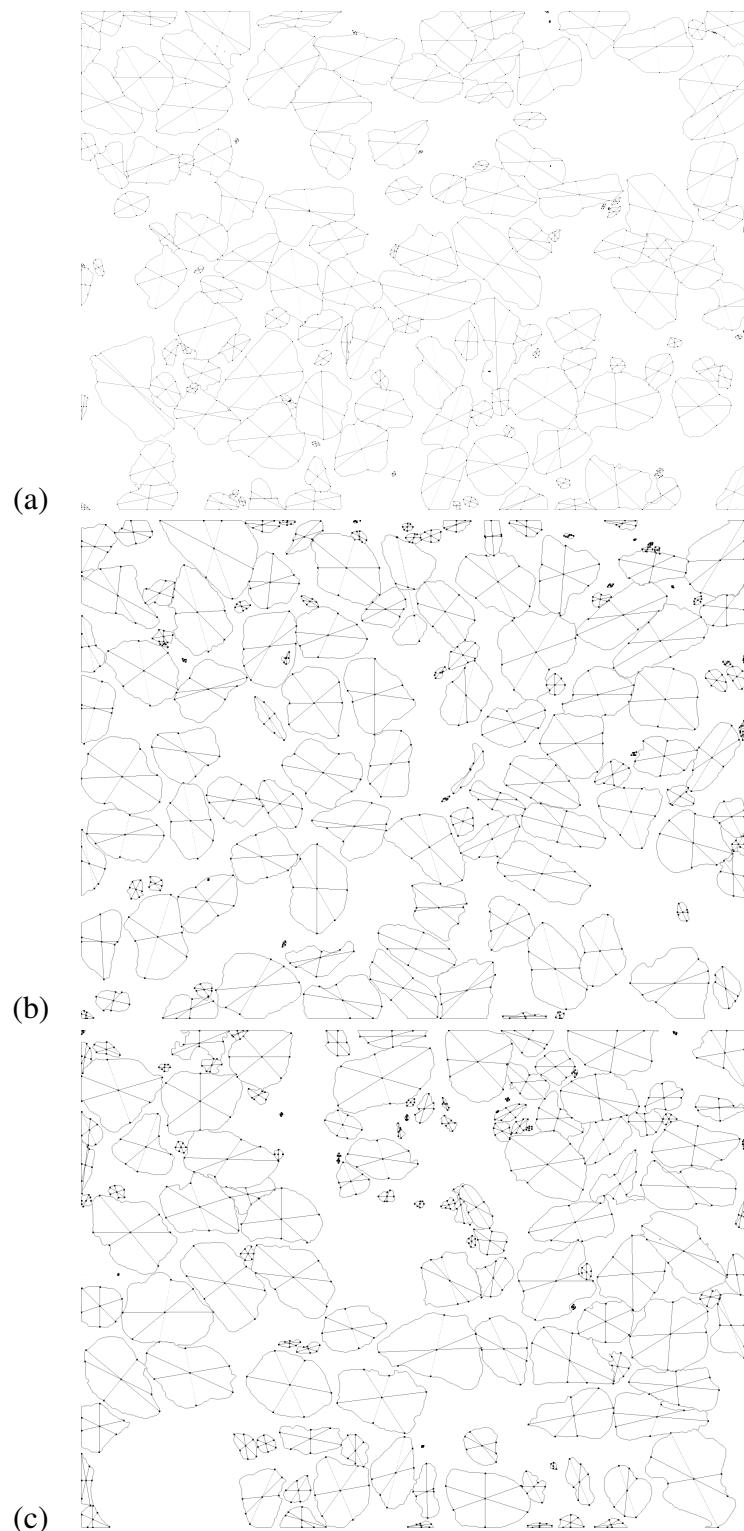


Figura B.2: Contorno dos grãos e eixos das amostras: (a) S4 (b) S5 (c) S7.

B. IMAGENS DOS CONTORNOS E EIXOS DOS GRÃOS

C

Resultados para análise dos eixos dos grãos

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

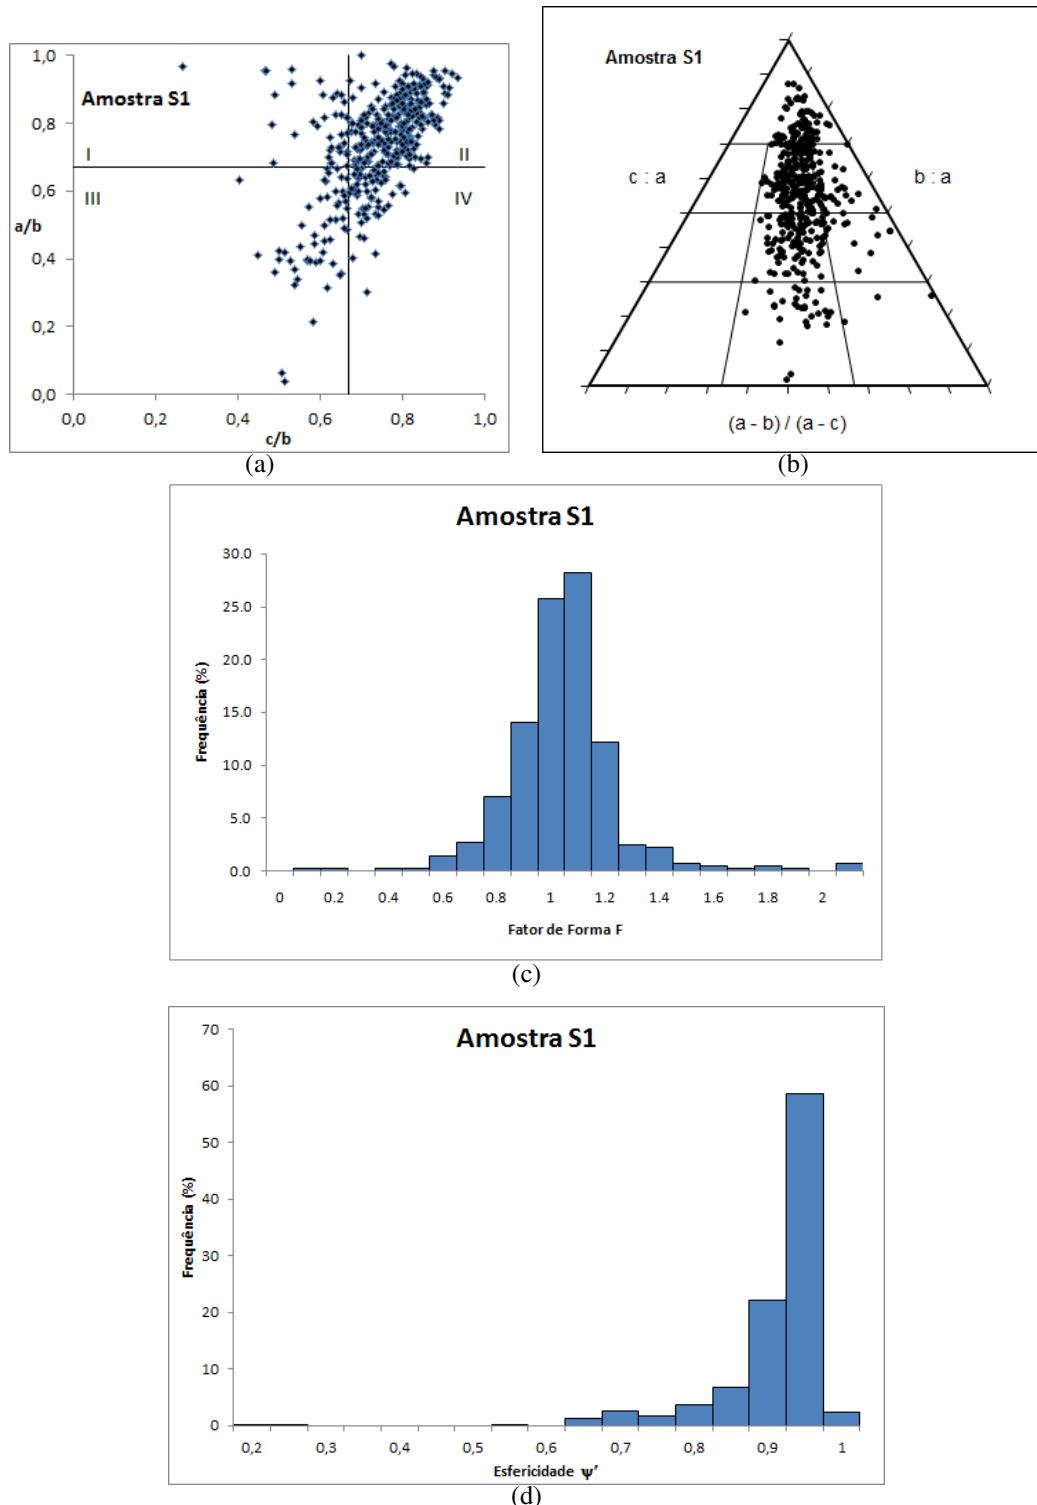


Figura C.1: Amostra S1 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Snead & Folk (1958) (c) Fator de forma F (d) Esfericidade.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

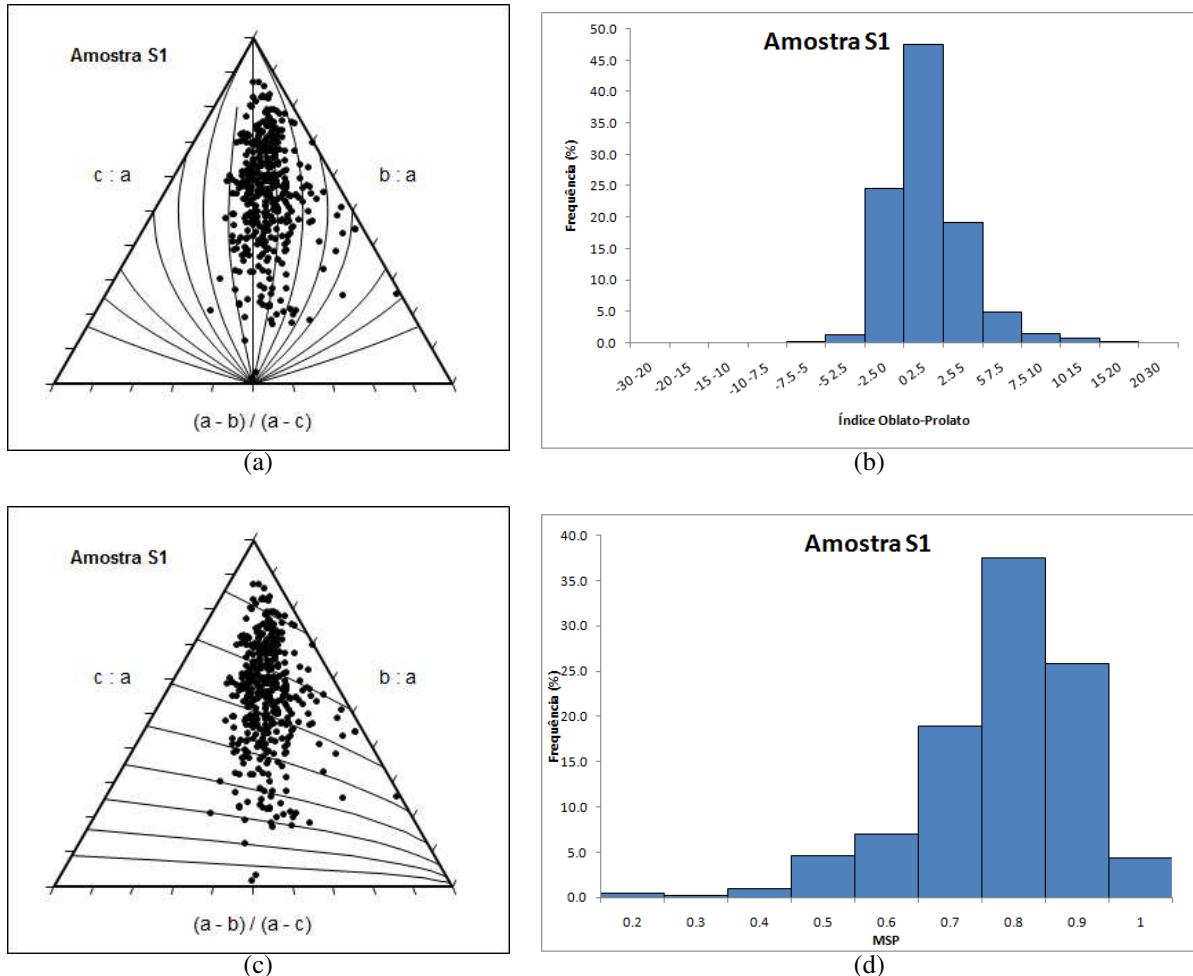


Figura C.2: Amostra S1 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

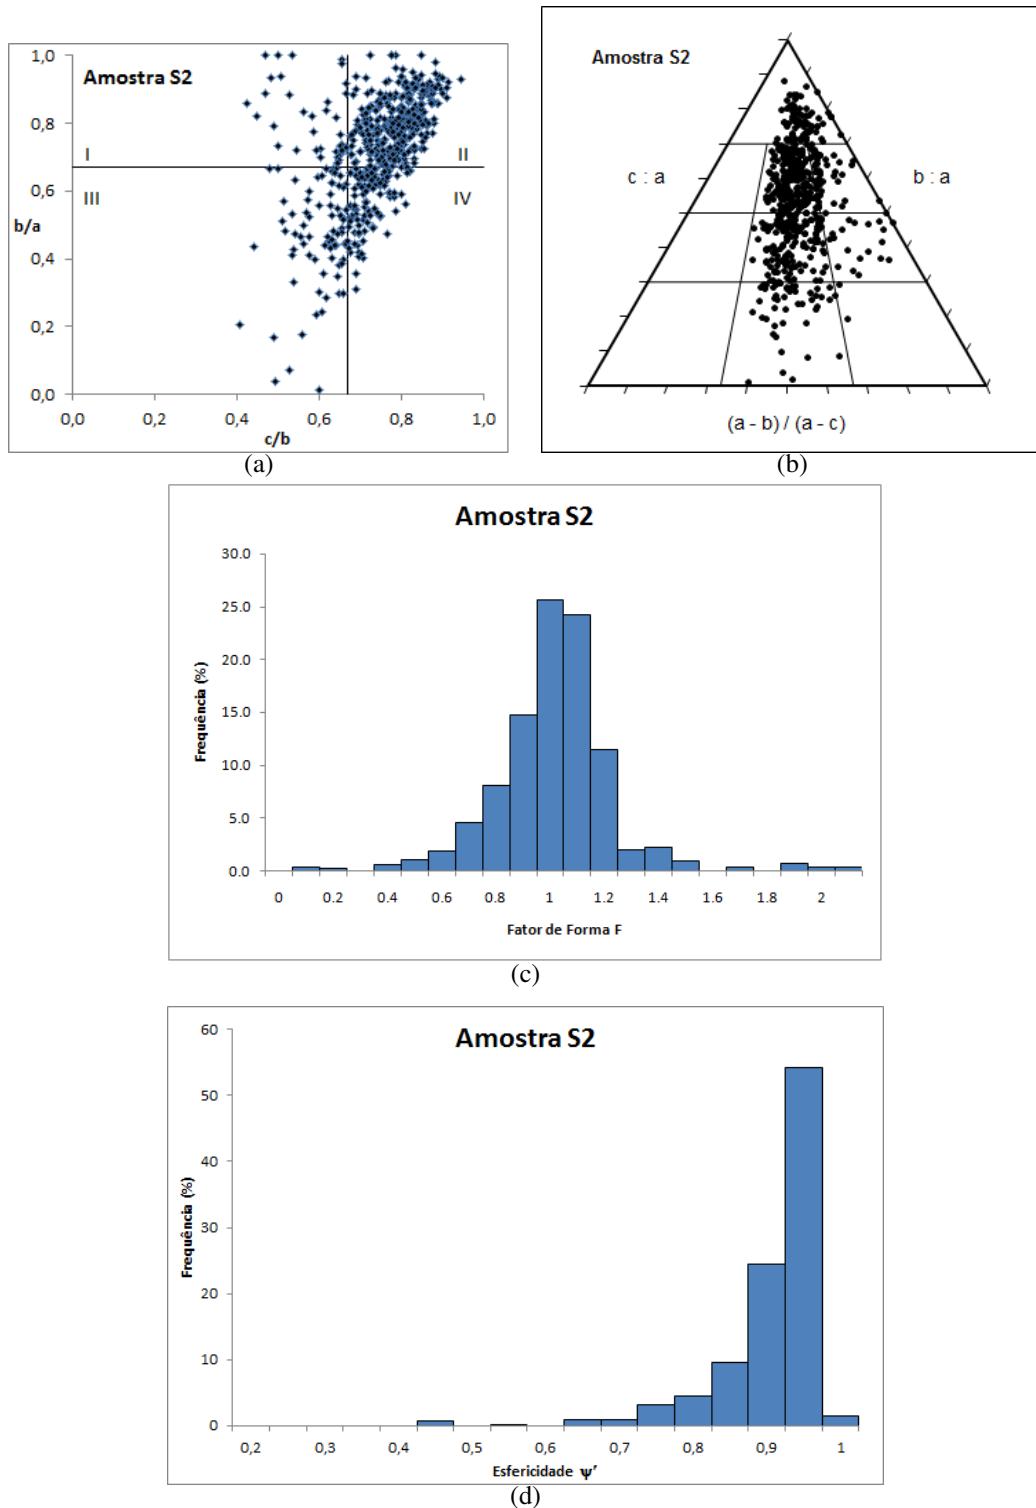


Figura C.3: Amostra S2 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Snead & Folk (1958) (d) Fator de forma F (d) Esfericidade.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

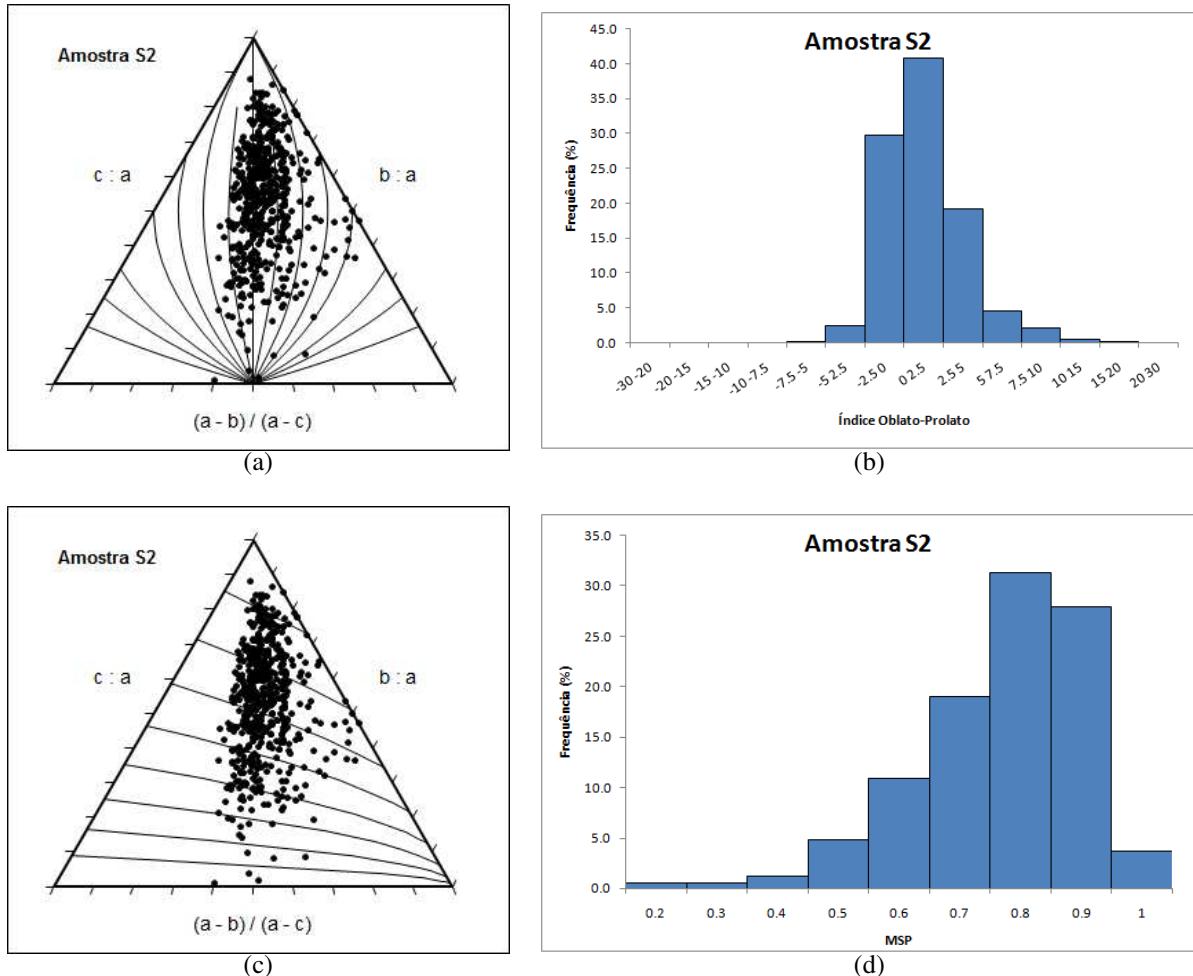


Figura C.4: Amostra S2 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

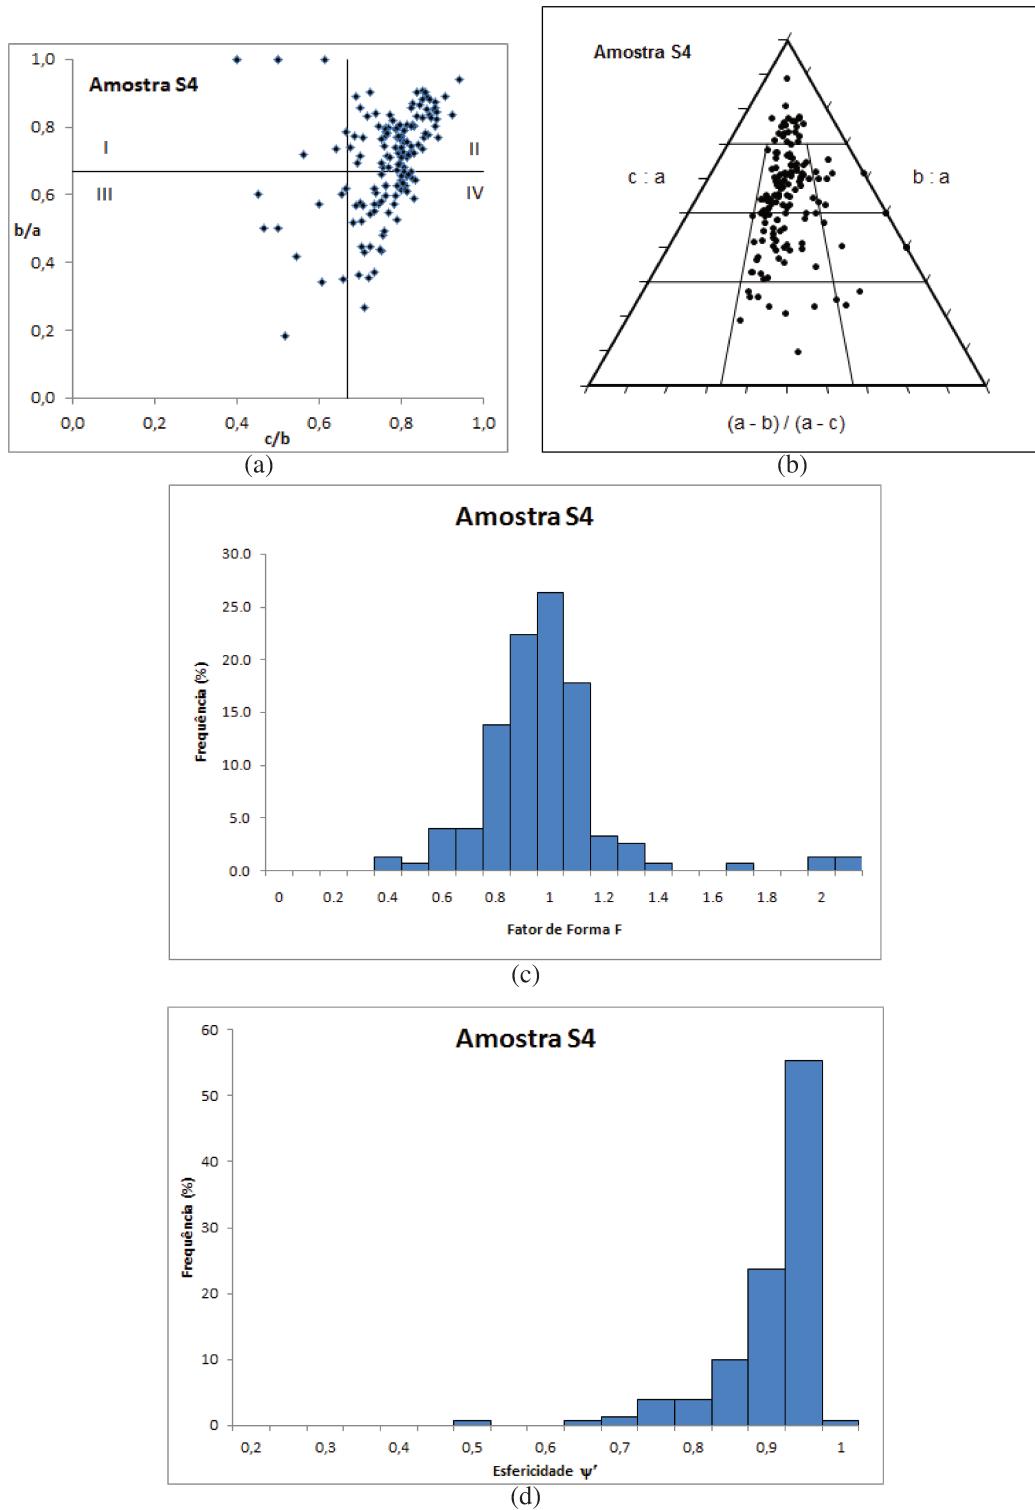


Figura C.5: Amostra S4 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Snead & Folk (1958) (c) Fator de forma F (d) Esfericidade.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

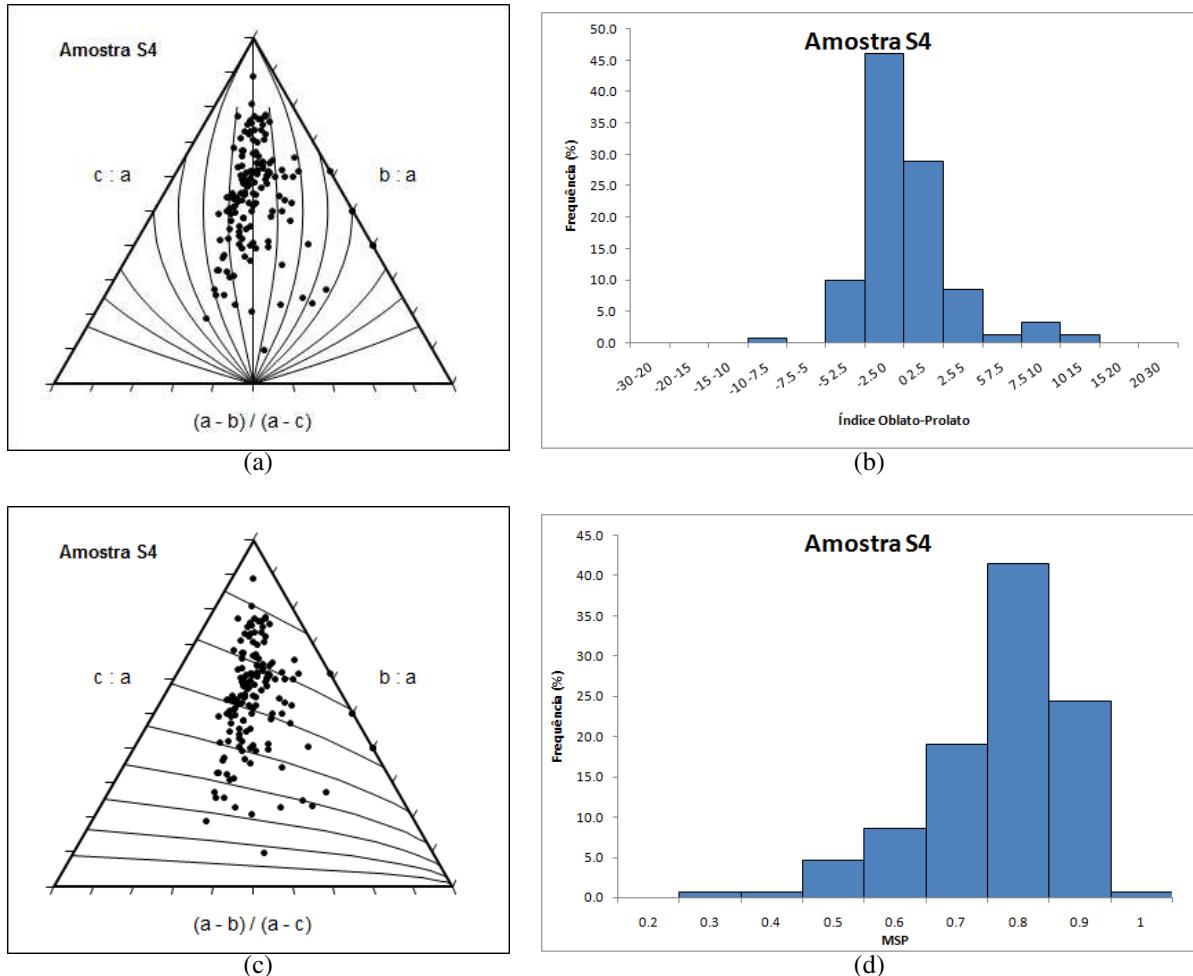


Figura C.6: Amostra S4 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

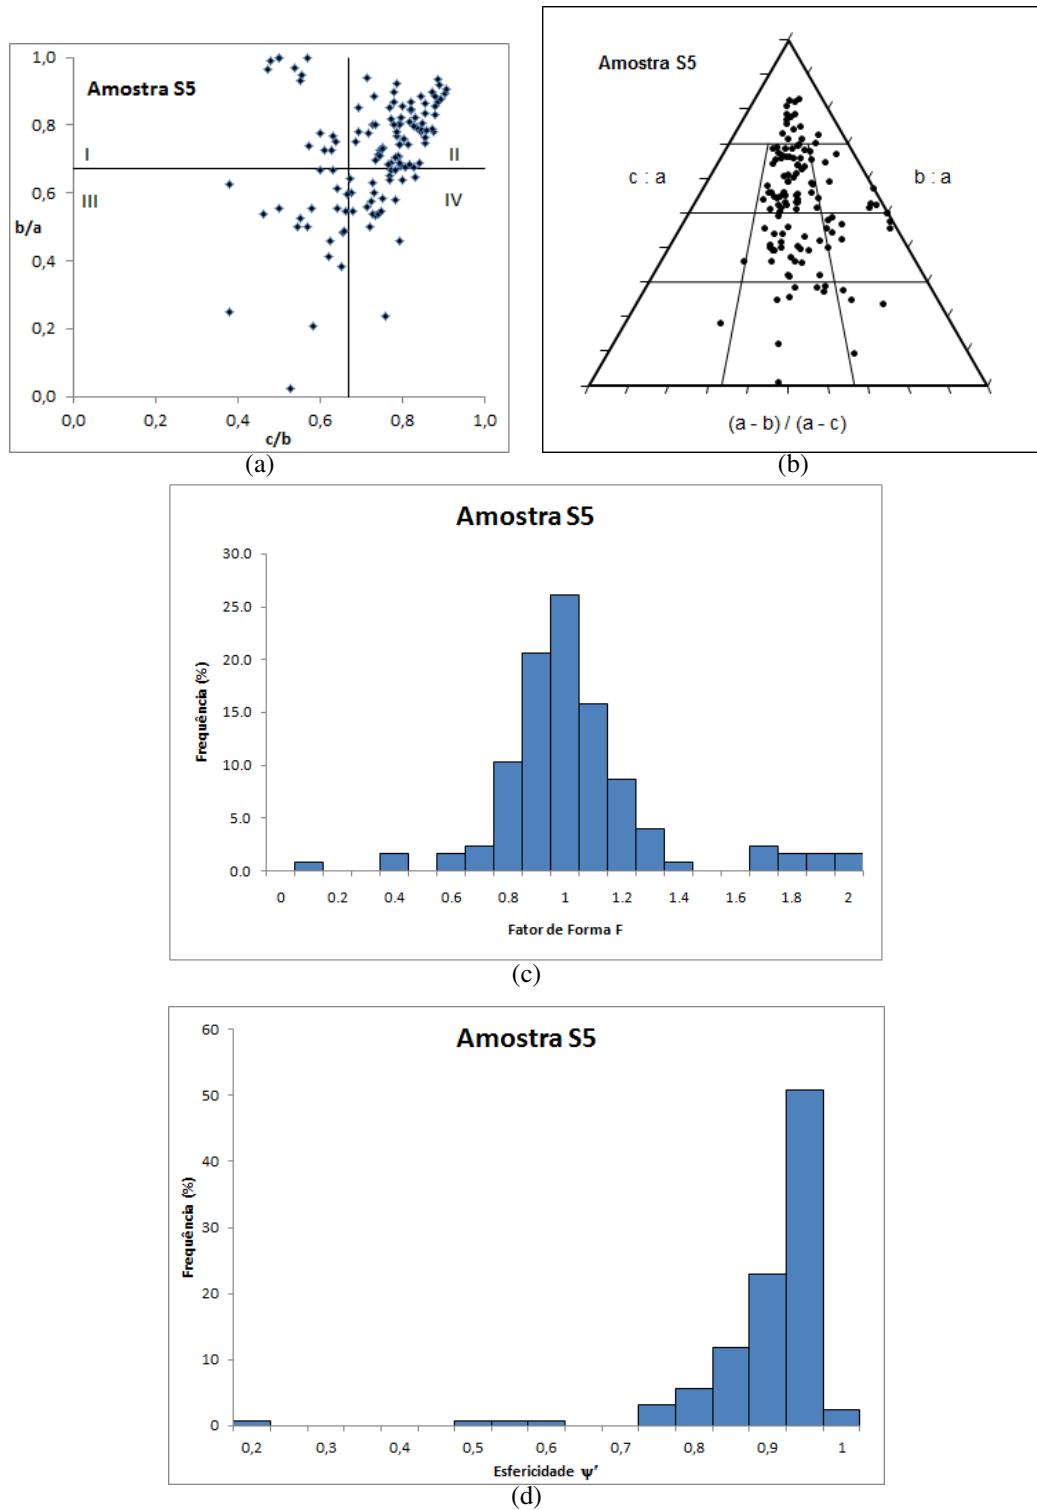


Figura C.7: Amostra S5 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Snead & Folk (1958) (c) Fator de forma F (d) Esfericidade.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

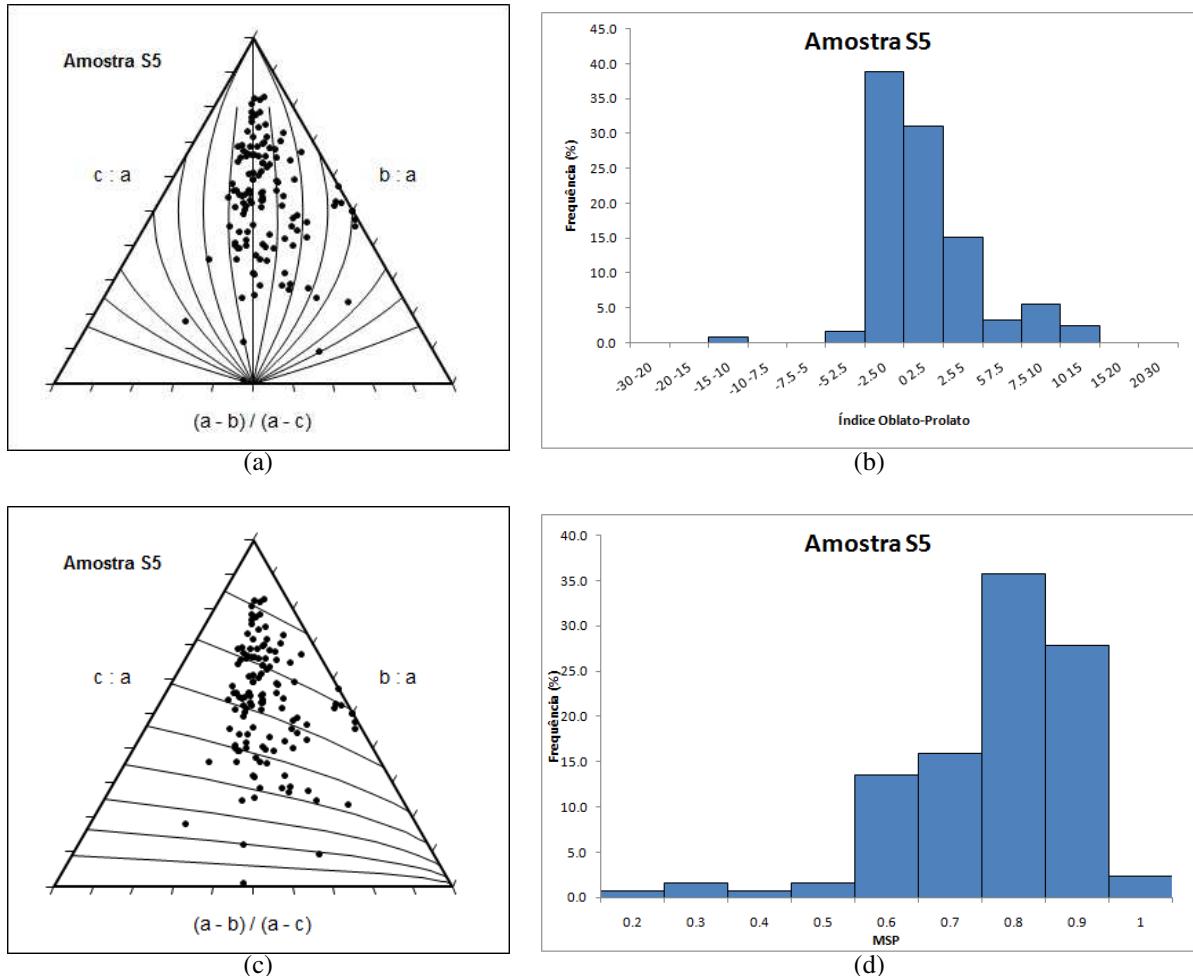


Figura C.8: Amostra S5 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

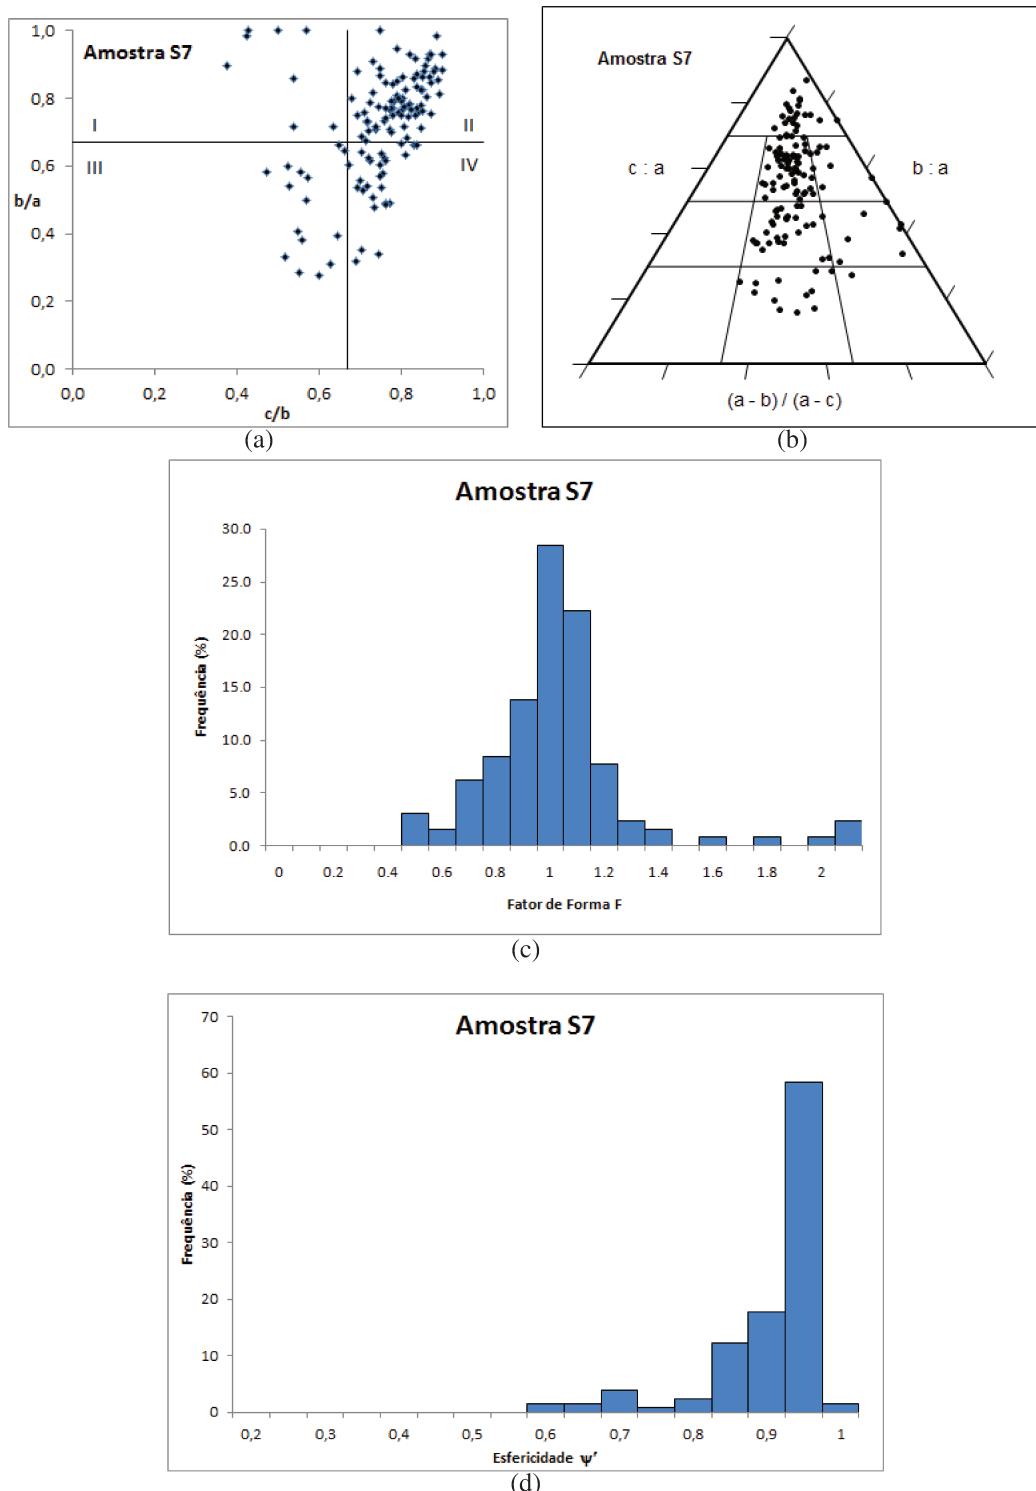


Figura C.9: Amostra S7 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Diagrama de Zingg (1935) (b) Diagrama triangular de Snead & Folk (1958) (c) Fator de forma F (d) Esfericidade.

C. RESULTADOS PARA ANÁLISE DOS EIXOS DOS GRÃOS

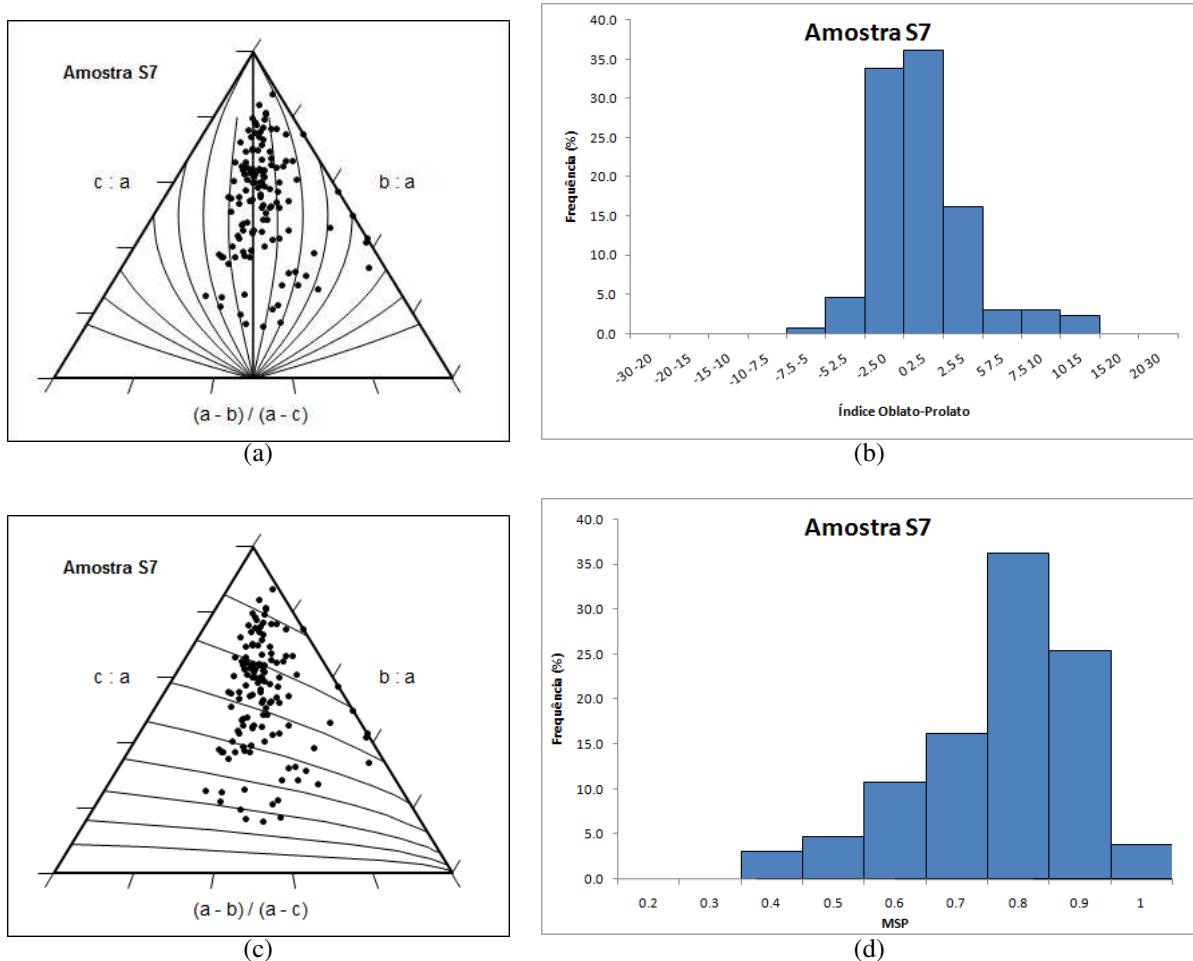


Figura C.10: Amostra S7 – Resultados das aplicações dos métodos para análise da forma dos grãos: (a) Índice Oblato-Prolato (b) Distribuição do Índice Oblato-Prolato (c) Índice MPS (d) Distribuição do Índice MPS.