

MIRIAM MARIA PEDROSA

**DETECÇÃO AUTOMÁTICA DE CRATERAS DE
IMPACTO NA SUPERFÍCIE DE MERCÚRIO**



Presidente Prudente
2015



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE PRESIDENTE PRUDENTE
FACULDADE DE CIÊNCIAS E TECNOLOGIA
Programa de Pós-Graduação em Ciências Cartográficas

MIRIAM MARIA PEDROSA

DETECÇÃO AUTOMÁTICA DE CRATERAS DE IMPACTO NA SUPERFÍCIE DE MERCÚRIO

Tese apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista - Campus de Presidente Prudente, para obtenção do título de Doutor.

Orientador: Prof. Dr. Erivaldo Antonio da Silva.
Coorientador: Dr. Pedro Miguel Berardo Duarte Pina.

Presidente Prudente
2015

FICHA CATALOGRÁFICA

P414d Pedrosa, Miriam Maria.
 Detecção automática de Crateras de Impacto na superfície de Mercúrio /
 Miriam Maria Pedrosa. - Presidente Prudente: [s.n], 2015

 134 f.


 Orientador: Erivaldo Antônio da Silva
 Coorientador: Pedro Miguel Berardo Duarte Pina
 Tese (doutorado) - Universidade Estadual Paulista, Faculdade de
Ciências e Tecnologia
 Inclui bibliografia

 1. Crateras de impacto. 2. Sensoriamento Remoto. 3. Processamento de
imagens. 4. Reconhecimento de Padrões. I. Silva, Erivaldo Antônio. II. Pina,
Pedro Miguel Berardo Duarte. III. Universidade Estadual Paulista. Faculdade
de Ciências e Tecnologia. IV. Título.

BANCA EXAMINADORA



Prof. Dr. ERIVALDO ANTONIO DA SILVA
(Orientador)



Prof. Dr. ALVARO PENTEADO CRÓSTA
(UNICAMP)



Prof. Dr. THIAGO STATELLA
(IFMT)



Prof. Dr. JOSÉ ROBERTO NOGUEIRA
(UNESP/FCT)



Prof. Dr. AYLTON PAGAMISSE
(UNESP/FCT)



MIRIAM MARIA PEDROSA

Presidente Prudente (SP), 24 de junho de 2015.

Resultado: **APROVADO.**

Dedico este trabalho aos meus pais,
Francisco e Marta, aos meus irmãos, Aline e
Bruno e ao meu sobrinho Guilherme.

Minhas conquistas se devem a vocês!

AGRADECIMENTOS

Registro aqui a minha mais sincera gratidão a todos que me ajudaram durante o desenvolvimento deste trabalho, direta ou indiretamente.

Agradeço a Deus, por ter me dado força, sabedoria e oportunidade de chegar até aqui.

Ao meu orientador Dr. Erivaldo Antonio da Silva, obrigada pelo apoio, orientação, confiança, paciência, amizade e principalmente, por sempre me fazer acreditar que eu seria capaz de conquistar esse objetivo.

Ao Dr. Pedro Pina, obrigada pela excelente orientação, pelo apoio e pela paciência. Obrigada por ter me recebido tão bem no Instituto Superior Técnico e por ter dividido seus conhecimentos e experiências. O destino não poderia ter me sugerido um melhor coorientador que você.

Aos docentes do PPGCC e do departamento de Matemática, em especial ao professor Dr. José Roberto Nogueira e Maurício Araújo Dias, por confiarem em meu trabalho e por estarem sempre presentes.

Ao Lourenço Bandeira e à Marlene Machado pelas sugestões para realização deste trabalho e por sempre estarem à disposição nas inúmeras vezes que precisei. Muito obrigada!

Agradeço à Samara Calçado, pessoa que foi um presente que a pós-graduação colocou no meu caminho. Obrigada pelas ajudas, pelas conversas e pelo apoio. Crescemos muito nesse tempo de troca de experiência e de amizade. Obrigada minha amiga.

Agradeço às minhas amigas que fizeram com que este trabalho se tornasse menos doloroso: Tayná, pela amizade, pelos bolos e pelos pães caseiros que alegraram muitas tardes; Chaenne, pelas conversas e momentos de descontração; Raquel, pela companhia e amizade. Eu não poderia deixar de agradecer à minha parceira Fernanda Puga, por todos os momentos vividos durante o estágio no exterior, pelas palhaçadas, pela amizade, e pelas conversas, aprendi muito contigo, amiga! Ao Guilherme Cardim, por estar sempre disponível para ajudar na parte de programação e a me socorrer com problemas informáticos. E aos colegas do PPGCC, pelas ajudas e pelos momentos de descontração.

Agradeço aos amigos que fiz durante o doutorado sanduiche. Eu não imaginava que poderia encontrar amigos tão verdadeiros do outro lado do oceano. Em especial, agradeço a Liliana Barros, Telma Tomaz, Cátia Mantas, Eva Zupančič e Adriana Cepa. Tenho mesmo muita sorte de encontrar, e ter como amigas pessoas como vocês.

Aos membros da banca examinadora: Dr. Alvaro Crósta, Dr. Thiago Statella, Dr. Aylton Pagamisse e Dr. José Roberto Nogueira, pelas correções e sugestões.

À Coordenação de Aperfeiçoamento de Nível Superior (CAPES) e ao programa ciências sem fronteiras pelo auxílio financeiro.

Em especial, agradeço ao meu pai, Francisco, à minha mãe, Marta, que é uma fortaleza de mulher e sempre foi o meu maior exemplo. Obrigada por sempre acreditar, mesmo quando eu já não tinha forças para achar que seria possível. Aos meus irmãos, Aline e Bruno, por estarem sempre ao meu lado e por me ajudarem nas minhas decisões. Ao meu sobrinho, Guilherme, por me fazer acreditar e lutar por um mundo melhor.

“O pensamento lógico pode levar você de A a B, mas a imaginação te leva a qualquer parte do Universo.”

Albert Einstein

RESUMO

Crateras de impacto são estruturas formadas pela colisão de meteoritos com a superfície de corpos planetários rochosos. O estudo de crateras de impacto é um ponto chave para o entendimento da história do sistema solar, visto que o processo de colisão está presente desde a formação dos planetas até os dias atuais. Desta forma, existem inúmeros trabalhos realizados que envolvem crateras de impacto; dentre eles estão os desenvolvidos na tentativa de realizar a detecção automática dessas feições. A maioria dos trabalhos utilizam imagens da Lua e de Marte, devido à grande quantidade de imagens disponíveis para esses dois corpos planetários. Em contrapartida, a realização desta tarefa para Mercúrio só se tornou possível há poucos anos atrás, com o envio da sonda Messenger. Por esse motivo, existem poucos trabalhos desenvolvidos na tentativa de realizar a detecção de crateras em Mercúrio. Neste sentido, este trabalho apresenta uma metodologia para detecção de crateras em Mercúrio em imagens digitais MDIS-NAC. As imagens utilizadas possuem diferentes resoluções espaciais e pertencem a três bacias da superfície de Mercúrio. A metodologia é dividida em quatro etapas principais, sendo a primeira a construção do mosaico de imagens, em seguida realiza-se a seleção de áreas candidatas a crateras, por meio de operações morfológicas e análise da forma. Posteriormente, as características das áreas candidatas são extraídas pelas máscaras Haar-like. Por fim, utiliza-se SVM (do inglês, *Support Vector Machine*) para classificar as áreas candidatas em crateras e não crateras. A metodologia foi aplicada a um conjunto de imagens e os resultados foram comparados com imagens de referência em que as crateras de impacto foram marcadas manualmente. A metodologia alcançou melhores resultados para imagens de alta resolução. Entretanto, considerando a irregularidade da superfície de Mercúrio e a baixa resolução de algumas imagens utilizadas, pode-se considerar que os resultados são relevantes para todas as imagens utilizadas.

Palavras-chave: Crateras de impacto, Sensoriamento Remoto, Processamento Digital de Imagens, Reconhecimento de Padrões.

ABSTRACT

Impact craters are geological structures formed by the collision of a meteorite with rocky planetary surfaces. The study of impact craters is a key point in understanding the history of solar system as the collision process has been present from the planet's formation until the present day. Consequently, several works have been carried out involving impact craters. Among them, some have been developed with the aim of identifying these features automatically. However, the vast majority deal only with images from the surfaces of Mars and the Moon. This is directly related to the huge amount of image data available for these two bodies, in comparison with other surfaces. However, just a couple of years ago it became possible to carry out this work for the planet Mercury. Images of the whole of the planet's surface have been obtained only after the Messenger probe. For this reason, few attempts have been made to make automated crater detections on Mercury. This work, presents a methodology to detect impact craters on Mercury from MDISC-NAC images. The images cover three of Mercury's basins and they have different spatial resolutions. The methodology is divided into four main steps. The first consists of creating image mosaics of the areas of interest; the second of finding crater candidates on the mosaics by using morphological operation and shape analysis. Subsequently, the set of features is extracted from the candidates by a Haar-like mask. Finally, the candidates are classified as crater or non-crater by SVM (*Support Vector Machine*). The methodology was applied to a set of images and the results compared with ground truth images in which craters were marked manually. The methodology achieved better results for high resolution images. However, taking into account the irregularity of the surface and the low resolution of some of the images used, the results from all these images can be considered relevant.

Keywords: Impact Craters, Remote Sensing, Digital Image Processing, Pattern Recognition.

LISTA DE FIGURAS

Figura 1: Contato do projétil com a superfície do planeta.	30
Figura 2: Fim do estágio de contato e compressão.	30
Figura 3: Estágio de escavação.	31
Figura 4: Fim do estágio de escavação.	32
Figura 5: (a) Estágio de modificação e (b) cratera final.	33
Figura 6: Exemplo de cratera simples.	34
Figura 7: Formação de cratera complexa. (a) Estágio de escavação, (b) fim do estágio de escavação e começo do estágio de modificação, (c) estágio de modificação e (d) estrutura final.	34
Figura 8: Exemplo de cratera complexa.	35
Figura 9: Morfologia de bacias de Mercúrio de acordo com a disposição dos picos. (a) Bacia com pico central (ringed peak-cluster); (b) Protobacia, bacia com um pico central e conjunto de picos em forma de anel; (c) bacia Peak-Ring, anel formado por um grande conjunto de picos e ausência de pico central; (d) Eminescu (exemplo de bacia com pico central em forma de anel); (e) Bacia Van Gogh (exemplo de protobacia); (f) Bacia Raditladi (exemplo de bacia peak-ring).	36
Figura 10: Localização de crateras de impacto na Terra.	37
Figura 11: Cratera do Meteoro.	37
Figura 12: Instrumentos a bordo da sonda MESSENGER.	42
Figura 13: Instrumento MDIS.	43
Figura 14: Mapa das áreas da superfície de Mercúrio imageadas durante os três sobrevoos da sonda Messenger antes de entrar em órbita.	44
Figura 15: Exemplos de imagens da superfície de Mercúrio com resolução de 12 m/pixel. ...	45
Figura 16: Órbita da sonda MESSENGER.	46
Figura 17: Primeira imagem da Lua obtida por uma sonda espacial.	47
Figura 18: Convenção dos eixos para representação de imagens digitais.	48
Figura 19: Quantização de imagens.	49
Figura 20: Forma geométrica de alguns elementos estruturantes.	52
Figura 21: Resultado da aplicação do operador erosão binária.	53
Figura 22: Resultado da erosão de imagem em níveis de cinza. (a) imagem original (b) imagem erodida.	54
Figura 23: Resultado da aplicação do operador dilatação em uma imagem binária.	55

Figura 24: Exemplo numérico de dilatação binária.....	55
Figura 25: Resultado da dilatação de imagem em tons de cinza: a imagem original (a) e sua contraparte dilatada (b).....	56
Figura 26: Exemplo numérico de dilatação.....	56
Figura 27: Resultado da abertura de um conjunto X por um disco 3 x 3.....	57
Figura 28: Resultado do fechamento de um conjunto X por um disco 7 x 7.....	59
Figura 29: Exemplo do funcionamento do top-hat por abertura em um sinal unidimensional.....	60
Figura 30: Exemplo do top-hat por fechamento em um sinal unidimensional.....	60
Figura 31: (a) Imagem original, (b) redimensionada e transladada, (c) rotacionada em 45°, (d) redimensionada transladada e rotacionada em 180°; (e) Círculo e (f) curva.....	63
Figura 32: Exemplo de construção de Max-tree. (a) Superfície topográfica da imagem I; (b) árvore dos componentes conectados; (c) Imagem I e sua decomposição baseada nos limiares n.....	65
Figura 33: Máscaras propostas por Viola e Jones para extração das características das imagens.....	67
Figura 34: Exemplo de conjuntos separáveis por retas.....	69
Figura 35: Hiperplano de separação para o caso linearmente separável.....	70
Figura 36: Hiperplano de separação para o caso linearmente não separável.....	75
Figura 37: Hiperplano de separação para o caso não linear.....	76
Figura 38: Regiões selecionadas para teste do algoritmo. Bacias Multi-rings Rachmaninoff, Raditladi e Mozart.....	80
Figura 39: Footprints das imagens usadas da câmara MDIS-NAC nas suas respectivas crateras. (a) Footprint das 10 imagens de resolução espacial de 15 m/pixel na Raditladi; (b) footprint das 37 imagens com pior resolução na Rachmaninoff; (c) footprint das 06 imagens usadas na bacia Mozart; (d) footprint das 02 imagens usadas na bacia Raditladi.....	82
Figura 40: Fluxograma contendo as principais etapas do trabalho.....	84
Figura 41: Fluxograma contendo as etapas para seleção das candidatas.....	87
Figura 42: Etapas seguidas para evidenciar regiões iluminadas e sombreadas.....	88
Figura 43: Exemplos de templates contidas no banco de dados.....	89
Figura 44: Exemplo de duas regiões candidatas a serem par de uma cratera de impacto.....	90
Figura 45: Máscaras usadas para extração das características das feições de interesse.....	91
Figura 46: Exemplo de máscara dividida em setores.....	91
Figura 47: Exemplo de imagem integral. (a) Imagem original; (b) Imagem integral.....	92
Figura 48: Exemplos de variações das máscaras em relação ao tamanho e a localização.....	92

Figura 49: Resumo do processo sequencial de classificação.	93
Figura 50: Crateras marcadas manualmente. (a) Imagens da bacia Rachmaninoff; (b) Imagem EN0221023202M pertencente à bacia Raditladi.	95
Figura 51: Mosaico das bacias selecionadas para área teste. (a) Bacia Rachmaninoff; (b) Bacia Raditladi e (c) Bacia Mozart.....	96
Figura 52: Imagem original e resultado da filtragem por meio do filtro bilateral.....	97
Figura 53: Realce das regiões de sombra e de iluminação.....	98
Figura 54: Filtragem por meio da maxtree e da abertura por área.	99
Figura 55: Filtragem pela forma.....	100
Figura 56: Resultado da detecção para a imagem EN0219562953M. Os círculos verdes indicam as detecções verdadeiras, os vermelhos as falsas detecções e os azuis as crateras que estavam no GT, mas que não foram detectadas pela metodologia proposta.	102
Figura 57: Bacia Raditladi e os footprints das imagens utilizadas.....	103
Figura 58: Conjunto de treino formado a partir das imagens EN0221023192M (a) e EN0221066394M (b) (exemplos de crateras em azul e de não-crateras em vermelho).....	104
Figura 59: Taxa de detecções verdadeiras utilizando o conjunto de treino da imagem EN0221023192M.....	105
Figura 60: Taxa de detecção falsa utilizando o conjunto de treino da imagem EN0221023192M.....	106
Figura 61: Sobreposição das detecções nas imagens originais projetadas (verde-TP, vermelho-FP e FN-azul).	107
Figura 62: Quantidade de crateras verdadeiras detectadas em relação ao diâmetro das crateras.	108
Figura 63: Delimitação das áreas de estudo. (a) Bacia Rachmaninoff; (b) Bacia Raditladi e (c) Bacia Mozart.....	109
Figura 64: Detecção de crateras de impacto na Bacia Rachmaninoff (verde-TP, vermelho-FP e FN-azul).....	110
Figura 65: Detecção das crateras na bacia Mozart (verde-TP, vermelho-FP e FN-azul).....	111
Figura 66: Detecção das crateras na Bacia Raditladi (verde-TP, vermelho-FP e FN-azul). ..	112
Figura 67: Quantidade de crateras detectadas corretamente em relação ao diâmetro.....	113
Figura 68: Imagem EN029563068 com exemplos de crateras (círculo azuis) e de não crateras (quadrados vermelhos). (a) exemplos na proporção 1:2 e (b) exemplos na proporção 1:4....	115
Figura 69: Taxa de detecção verdadeira utilizando o conjunto de treino formado por exemplos da imagem EN029563068. (a) Variação da taxa de detecção para o conjunto formado na	

proporção 1:2 e (b) variação da taxa de detecção para o conjunto formado na proporção 1:4.	116
Figura 70: Taxa de detecção falsa utilizando o conjunto de treino formado por exemplos da imagem EN029563068. (a) Variação da taxa de detecção para o conjunto formado na proporção 1:2 e (b) variação da taxa de detecção para o conjunto formado na proporção 1:4.	117
Figura 71: Imagem EN0219477788 com exemplos de crateras (círculo azuis) e de não crateras (quadrados vermelhos).	118
Figura 72: Taxa de detecção verdadeira utilizando um conjunto de treino formado por informações retiradas das imagens EN029563068 e EN0219477788.	118
Figura 73: Taxa de detecção falsa utilizando um conjunto de treino formado por informações retiradas das imagens EN029563068 e EN0219477788.	119
Figura 74: Exemplos de crateras e de não crateras retirados das imagens EN0219563031 e EN0219562911.	120
Figura 75: Taxa de detecção verdadeira utilizando um conjunto de treino formado por exemplos das imagens EN029563068, EN0219477788, EN0219563031 e EN0219562911.	120
Figura 76: Taxa de detecção falsa utilizando um conjunto de treino formado por exemplos da imagem EN029563068, EN0219477788, EN0219563031 e EN0219562911.	121
Figura 77: Desempenho do algoritmo nas imagens (a) EN0219562997 e (b) EN0219563033 (verde-TP, vermelho-FP e FN-azul).	123

LISTA DE TABELAS

Tabela 1: Momentos invariantes das imagens apresentadas da Figura 29.	63
Tabela 2: Informações sobre as áreas selecionadas.	80
Tabela 3: Nome das imagens utilizadas com as respectivas resoluções espaciais.	83
Tabela 4: Informações das imagens apresentadas na Figura 57.	103
Tabela 5: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros c e g do RBF.	105
Tabela 6: Taxa de falsas detecções por validação cruzada para seleção dos parâmetros c e g do RBF.	105
Tabela 7: Desempenho do algoritmo para imagens de alta resolução.	106
Tabela 8: Resultado da classificação para cada imagem.	108
Tabela 9: Desempenho da detecção para cada bacia.	113
Tabela 10: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:2, com base na taxa de detecção verdadeira.	115
Tabela 11: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:4, com base na taxa de detecção verdadeira.	116
Tabela 12: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:2, com base na taxa de detecção falsa.	116
Tabela 13: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:4, com base na taxa de detecção falsa.	116
Tabela 14: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção verdadeira.	118
Tabela 15: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção falsa.	119
Tabela 16: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção correta.	120
Tabela 17: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção incorreta.	121
Tabela 18: Desempenho da classificação para cada imagem do conjunto.	122

SUMÁRIO

1	INTRODUÇÃO.....	18
1.1	Contextualização	18
1.2	Objetivos.....	20
1.3	Justificativa.....	20
1.4	Estado da arte	22
2	FUNDAMENTAÇÃO TEÓRICA	29
2.1	Crateras de impacto	29
2.1.1	Contato e compressão	30
2.1.2	Estágio de escavação	31
2.1.3	Estágio de modificação	32
2.2	Sensoriamento Remoto.....	38
2.2.1	Sensoriamento Remoto de Crateras de Impacto	39
2.2.2	Sensoriamento Remoto de Mercúrio	40
2.3	Processamento Digital de Imagens.....	46
2.3.1	Conceito de Imagem e Imagem Digital	48
2.3.2	Processamento Morfológico de Imagens	50
2.3.2.1	Teoria dos reticulados	50
2.3.2.2	Elemento Estruturante	51
2.3.2.3	Erosão	53
2.3.2.4	Dilatação.....	54
2.3.2.5	Abertura.....	57
2.3.2.6	Fechamento	58
2.3.2.7	Top-hats.....	59
2.3.3	Momentos	60
2.3.4	Filtro de Suavização.....	64
2.3.4.1	Filtro bilateral	64
2.3.4.2	Max-tree	65
2.3.5	Características de Haar-like	66
2.3.6	Aprendizado de Máquina.....	67
2.3.6.1	Máquinas de Vetores de Suporte.....	68
2.3.6.2	SVMs com Margens Rígidas.....	69
2.3.6.3	SVMs com Margens Suaves.....	74
2.3.6.4	SVMs não lineares.....	76
2.3.7	Métricas Quantitativas e Qualitativas para Avaliação de Desempenho	77
3	MATERIAIS E MÉTODO.....	79
3.1	Materiais	79
3.2	Seleção das imagens	79
3.3	Metodologia.....	83
3.3.1	Construção do mosaico	84
3.3.2	Seleção das candidatas a crateras.....	87
3.3.3	Extração das características	90
3.3.4	Classificação via SVM.....	93
3.3.5	Avaliação da Metodologia.....	94
3.3.5.1	Criação do <i>Ground Truth</i>	95

4	RESULTADOS	96
5	CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES	124
	REFERÊNCIAS	127

1 INTRODUÇÃO

1.1 Contextualização

Crateras de impacto são estruturas formadas pela colisão de meteoritos com a superfície de corpos planetários rochosos. Tratam-se de feições comuns em todos os corpos rochosos do sistema solar, porém são mais abundantes em corpos tais como a Lua, Mercúrio e Marte, nos quais elas se acumulam com o passar do tempo, devido à baixa taxa de erosão da superfície.

O estudo de crateras de impacto é um ponto chave para o entendimento da história do sistema solar, visto que o processo de colisão está presente desde a formação dos planetas até os dias atuais, com os impactos que continuamente acontecem no sistema solar. Portanto, conhecer a população existente de crateras de impacto, bem como o fluxo de impacto através do tempo, são questões cruciais para compreender os processos e o passado geológico de um corpo planetário. Uma análise detalhada da distribuição de crateras de impacto e das suas morfologias pode trazer uma grande quantidade de informações. Além disso, elas representam a única ferramenta disponível para medir, remotamente, a idade relativa de formações geológicas em planetas (URBACH e STEPINSKI, 2009).

Por meio do conhecimento da geomorfologia das crateras, são possíveis estudos de uma série de questões pendentes na geomorfologia do planeta, tais como do processo natural de degradação (SODERBLOM, CONDIT, e WEST, 1974), da análise de variações regionais do material geológico (CINTALA, HEAD e MUTCH, 1976) e que serviu de base para a estratigrafia da Lua e de Marte (TANAKA, 1986).

A identificação de crateras em superfícies planetárias também assume importância crucial para a exploração espacial, visto que o homem tem se preparado para o envio de uma futura missão espacial tripulada para o planeta Marte. Esse feito representa um passo significativo na exploração espacial.

Devido à grande relevância das crateras de impacto, em 1988, Barlow gerou manualmente o primeiro catálogo de crateras de impacto, o qual continha informações de crateras marcianas com diâmetro acima de 5 km. Posteriormente, outros catálogos também foram gerados manualmente, contendo mais informações sobre as crateras, além de crateras com diâmetros menores (BARLOW, 2003; FASSET *et al.*, 2011; HERRICK, 2011; ROBBINS e HYNEK, 2012).

Entretanto, os catálogos manuais são limitados com relação ao tamanho das crateras. Tentando superar essa limitação e acelerar o processo de geração destes, a comunidade científica tem desenvolvido algoritmos visando automatizar o processo de detecção. Atualmente, há um número extenso de algoritmos desenvolvidos, alguns com abrangência global (STEPINSKI *et al.*, 2009; SALAMUNICCAR *et al.*, 2011), mas a maioria deles no âmbito local (BARATA *et al.*, 2004; BANDEIRA *et al.*, 2007; MARTINS *et al.*, 2009; PEDROSA *et al.*, 2011; BANDEIRA *et al.*, 2012), onde primeiro selecionam-se algumas regiões da superfície planetária para testes, e só depois, se for comprovada a eficiência do algoritmo, este é aplicado em imagens de toda a superfície do planeta.

A maioria desses trabalhos lida com a superfície de Marte e da Lua, devido à grande quantidade de imagens disponíveis para esses dois corpos planetários. Nos últimos 50 anos, mais de 40 sondas foram enviadas a Marte, 73 à Lua, enquanto que somente duas foram enviadas a Mercúrio, sendo a última enviada em 2004 com o intuito de fazer o mapeamento de toda a superfície do planeta (NATIONAL GEOGRAPHIC, 2015). Esta sonda, chamada Messenger, fez dois sobrevoos em Vênus entre 2006 e 2007, posteriormente, sobrevoou Mercúrio por três vezes entre 2008 e 2009 e entrou na órbita de Mercúrio em 2011, onde adquiriu imagens e dados inéditos (SOLOMON *et al.*, 2001; SANTO *et al.*, 2001; GOLD *et al.*, 2001), tendo terminado a sua missão no dia 30 de Abril de 2015.

A construção de catálogos globais de crateras de impacto para Mercúrio só foi possível após o envio da sonda Messenger, pois antes dela apenas se conhecia 45% da superfície do planeta, que foi a área imageada pela sonda Mariner 10 em 1974 (MURRAY *et al.*, 1974; MURRAY *et al.*, 1975).

O primeiro catálogo global de crateras de impacto de Mercúrio foi feito por Fassett *et al.* (2011), no qual estão presentes crateras de impacto com diâmetro acima de 20km. Em seguida, Herrick *et al.* (2011) compilaram um catálogo contendo crateras com diâmetro acima de 10 km. Os dois autores utilizaram um mosaico constituído por imagens das sondas Messenger e Mariner 10, cuja resolução é de aproximadamente 500 m/pixel. Ambos os catálogos foram construídos manualmente.

Existem poucas tentativas realizadas com o objetivo de tornar automático o processo de detecção de crateras em Mercúrio. Neste sentido, este trabalho tem por objetivo o desenvolvimento de um algoritmo para detecção de crateras em imagens MDIS-NAC (do inglês, *Mercury Dual Imaging System-Narrow Angle Camera*) de três bacias que atualmente são foco de interesse para a descoberta da origem de terrenos planos e de outras feições de

interesse (BLAIR, 2013). O método adotado utiliza técnicas de processamento digital de imagens e de reconhecimento de padrão e foi inspirado nos trabalhos de Urbach e Stepinski (2009) e Martins *et al.* (2009). A metodologia foi dividida em quatro etapas principais, sendo a primeira delas a construção de um mosaico de imagens das áreas de interesse; a segunda utilizou basicamente operadores morfológicos e análise da forma para seleção das áreas candidatas a crateras de impacto. A terceira consistiu da extração das características das áreas candidatas por meio de máscaras *Haar-like*, e por fim, a discriminação dessas áreas candidatas em crateras e não crateras foi feita pelo classificador SVM (*Support Vector Machine*).

1.2 Objetivos

O objetivo geral deste trabalho foi desenvolver uma metodologia para detecção de crateras de impacto em imagens digitais da superfície de Mercúrio.

Destacam-se como objetivos específicos:

- Contribuir para a automatização do processo de detecção de feições em imagens planetárias digitais;
- Realizar a detecção de crateras em imagens de variadas resoluções espaciais;
- Detectar as crateras de impacto de três bacias relevantes de Mercúrio.

1.3 Justificativa

Primeiramente, deve-se ressaltar que crateras de impacto são as estruturas mais estudadas na área de ciências planetárias, devido à quantidade de informações que uma análise detalhada de sua distribuição e morfologia podem trazer. Por exemplo, estatísticas de tamanho de crateras formaram a base para a estratigrafia da Lua e Marte (CRATER ANALYSIS TECHNIQUES WORKING GROUP, 1979; TANAKA, 1986). Além disso, as crateras de impacto são a única ferramenta disponível para inferir remotamente a idade de formações geológicas em planetas (WERNER, 2014), baseando-se no princípio de que uma superfície que acumulou mais crateras é mais antiga do que outra que acumulou menos. O estudo de alguns tipos de crateras, como as *peak-ring* e outras transições de morfologias entre crateras complexas e *multi-rings* é importante para o entendimento do mecanismo de formação de bacias em corpos rochosos. Mercúrio tem a maior população de bacias *peak-ring*

e protobacias do sistema solar, o que o torna um planeta em destaque para o estudo desse tipo de feição geológica (NEUKUM *et al.*, 2001; BAKER *et al.*, 2011).

A maioria dos catálogos de crateras de impacto existentes atualmente foi feita manualmente, como por exemplo, os catálogos de Marte, contendo 19.308 crateras (RODIONOVA *et al.*, 2000), 42.283 crateras (BARLOW, 1988), 57.633 crateras (SALAMUNICCAR e LONCARIC, 2008) e 378.540 (ROBBINS e HYNEK, 2012). Todos esses catálogos, com exceção do catálogo de Robbins e Hynek que contém crateras com diâmetro de 1 km, contêm apenas crateras acima de 5 km. Para a Lua o catálogo mais completo contém 8.497 crateras (ANDERSSON e WHITAKER, 1982) e para Mercúrio, Fassett *et al.* (2011) geraram um catálogo contendo crateras com diâmetro acima de 20km e em seguida Herrick *et al.* (2011) compilaram um contendo crateras com diâmetro acima de 10 km.

O fato de não haver catálogos globais contendo crateras sub-km é justificado devido existir uma grande quantidade de crateras com diâmetros menores do que 1 km, o que torna inviável o trabalho de identificar cada uma dessas crateras manualmente (URBACH e STEPINSKI, 2009).

A automatização desse processo é a única solução prática para pesquisas de crateras com menores dimensões (URBACH e STEPINSKI, 2009). Tais pesquisas podem fornecer cobertura regional ou global e podem facilitar o estudo em questão, permitindo que repetidas análises possam ser feitas.

Apesar de não haver nenhum algoritmo de detecção de crateras – CDA (do inglês, *Crater Detection Algorithm*) totalmente eficiente a ponto de substituir o trabalho de um especialista, a ideia de desenvolvimento de CDAs não é recente. Existem diversos algoritmos desenvolvidos com esse intuito, principalmente para Marte e Lua, devido à grande quantidade de dados disponíveis para esses dois corpos planetários. Em contrapartida, para Mercúrio o aumento de dados só está se tornando significativo nos últimos anos, com o envio da sonda Messenger, a qual adquiriu diversos tipos de informações por meio de oito instrumentos científicos a bordo da sonda. Dentre os instrumentos presentes, há o MDIS (do inglês, *Mercury Dual Imaging System*), um sistema dual composto pelas câmaras WAC (do inglês, *Wide Angle Camera*) e NAC (do inglês, *Narrow Angle Camera*), que têm adquirido imagens com diversas resoluções, sendo que a melhor resolução delas alcança 15 m/pixel para regiões específicas do planeta.

Como consequência disso, os CDAs desenvolvidos para Mercúrio são recentes. O único encontrado na literatura foi realizado por Salamuniccar (2013), o qual aplicou em três regiões de Mercúrio um CDA desenvolvido para detecção de crateras de impacto em Marte e na Lua. Dados da topografia reconstruídos a partir de imagens óticas e com resolução de 1 km/pixel foram utilizados pelo algoritmo, o que implicou na detecção de crateras acima de 1 km, e maior confiabilidade para crateras acima de 16 km.

Esse contexto reflete a necessidade da continuidade dos estudos para desenvolvimento de algoritmos para a realização do mapeamento de crateras de impacto de Mercúrio, e aponta para a necessidade de maiores investigações a respeito da automatização do processo de detecção de crateras de impacto para todos os corpos rochosos do sistema solar.

1.4 Estado da arte

As crateras de impacto foram vistas pela primeira vez por Galileo em 1610, quando ele apontou seu telescópio para Lua e reconheceu as bordas elevadas e os picos centrais dessas feições, mas as descreveu como pontos circulares. Embora Galileu não tenha registrado nenhuma opinião, astrônomos argumentaram sobre suas possíveis origens durante os próximos três séculos. Até 1930, a maioria dos astrônomos acreditava que as maiores crateras da Lua eram gigantes vulcões extintos estando todas as outras crateras associadas também a fenômenos vulcânicos. A hipótese de impacto não teve credibilidade até que avanços nos conhecimentos sobre impactos físicos mostraram que mesmo um impacto oblíquo, em alta velocidade, pode produzir uma cratera circular. Mas foi somente a descoberta de efeitos de choque nos materiais alvos na Terra (CHAO, 1960; SHOEMAKER, 1961) que permitiu identificar de uma forma inequívoca que essas estruturas circulares tinham origem em impactos. Por meio de imagens de alta resolução espacial e de investigação *in situ* do programa Apollo, foi possível resolver também a questão em relação a origem de impactos a respeito das crateras Lunares (MELOSH, 2011).

O sensoriamento remoto de crateras de impacto em outros planetas começou com as imagens adquiridas pela Mariner 4, em 1965, que apesar da sua baixa resolução (3 km/pixel) revelaram uma grande quantidade de crateras de impacto na superfície de Marte (MELOSH, 2011). Desde então, crateras de impacto têm sido encontradas em todos os corpos sólidos do sistema solar e têm despertado grande interesse da comunidade científica, a qual

tem desenvolvido diversos trabalhos com o objetivo de fazer o seu mapeamento. Esses trabalhos apresentam metodologias manuais, semiautomáticas e automáticas. Alguns dos trabalhos mais relevantes são discutidos a seguir.

Atualmente, o trabalho de detecção de crateras de impacto, em sua maioria, ainda é feito manualmente, via inspeção de imagens. Esse trabalho manual, além de possibilitar a criação do banco de dados de crateras de impacto, tem permitido estudos de uma série de questões nos estudos dos planetas. Contudo, esses bancos de dados são limitados a crateras maiores do que um determinado tamanho, o que torna necessário o desenvolvimento de metodologias automáticas para alargar esse trabalho manual.

O primeiro catálogo de crateras de impacto foi criado para superfície de Marte, por Barlow em 1988, no qual crateras com diâmetro acima de 5 km foram mapeadas. Para criação deste catálogo, um mosaico composto por imagens Viking na escala de 1:2.000.000 foi analisado e manualmente as crateras de impacto foram medidas e registradas. Este catálogo, que formou uma base de dados significativa desde sua publicação, continha 42.284 crateras, todas contendo diâmetro acima de 5 km. Posteriormente, em 2003, Barlow revisou este catálogo e realizou algumas atualizações, como por exemplo, correção da localização das crateras e tamanho de diâmetros. Além disso, nessa nova versão, algumas novas análises foram feitas e incluídas no catálogo, tais como, profundidade, altura, altura do pico central, etc. Nesta nova versão, denominada de *Catalog 2.0*, foram incluídas 1.280 novas crateras.

Rodionova *et al.* (2000) catalogaram as crateras de Marte cujo diâmetro excedia 10 km. No total, foram registradas informações das coordenadas do centro, diâmetro, altitude e características morfológicas de 19.308 crateras de impacto. Em relação às características morfológicas, foram registradas informações sobre o grau de degradação das bordas, a presença de terreno plano ou falhas, pico central, vales, morros, material escuro no fundo das crateras, albedo, dentre outras características.

Robbins e Hynek (2012) criou um catálogo que é completo para crateras Marcianas com diâmetro acima de 1 km. Este catálogo foi gerado manualmente pela análise detalhada do mosaico de imagens THEMIS Daytime IR, cuja resolução espacial é de 232 m/pixel, e de dados MOLA cuja resolução espacial é de 463 m/pixel. Além da localização e tamanho, o catálogo de Robbins e Hynek apresenta a morfologia do interior das crateras e do material ejetado, do estado de degradação, e a informação se a cratera é ou não uma cratera secundária. Este novo catálogo contém 380.540 crateras de impacto, sendo o mais completo dos dias atuais.

Para a Lua, o catálogo mais abrangente contém 8.497 crateras de impacto, sendo todas de dimensão quilométrica (ANDERSSON e WHITAKER, 1982). Há também conjuntos menores de grandes crateras existentes em alguns satélites de Júpiter, 232 crateras foram catalogadas para Ganimede e 130 crateras para Callisto (Schenk *et al.*, 2004).

Para Mercúrio, existem dois catálogos de crateras de impacto criados até o momento. O primeiro foi gerado por Fassett *et al.* (2011), no qual estão presentes crateras com diâmetro acima de 20 km. Para a concepção deste catálogo foi utilizado um mosaico de imagens global, cuja resolução espacial é de ~500 m/pixel. Esse mosaico de imagens foi construído por Becker *et al.* (2009) que combinou imagens obtidas pelo sistema dual de imageamento MDIS a bordo da Messenger e pela câmara Mariner 10. Um total de 6.040 crateras de impacto foi incluído neste catálogo, representando o mapeamento de 95% da superfície do planeta. Tais crateras foram localizadas e medidas manualmente.

Herrick *et al.* (2011) compilaram um catálogo de crateras de impacto da superfície de Mercúrio com diâmetro maior do que 10 km. Este catálogo foi gerado a partir do mosaico de imagens global com ~500 m/pixel de resolução, além de um mosaico contendo apenas imagens da Mariner 10. Assim como Fassett *et al.* (2011), esse catálogo foi gerado pela detecção manual das crateras de impacto. Além da localização e do tamanho, Herrick *et al.* acrescentaram a informação da morfologia das crateras de impacto, tais como características do terreno, forma das bordas e das estruturas centrais das crateras. A principal diferença entre o trabalho de Herrick *et al.* e Fassett *et al.* é que no primeiro mais de 60% das crateras têm diâmetro entre 10 e 20 km, o que torna os mapas de densidade significativamente diferentes com relação a população de crateras.

Nenhum dos catálogos globais citados acima apresenta crateras de impacto menores do que 1 km. Isso porque todos eles foram gerados manualmente, e como a quantidade de crateras menores do que 1 km é abundante, catalogar cada uma dessas crateras de forma manual seria um trabalho muito laborioso e exigiria muito tempo por parte de um especialista.

Neste sentido, a comunidade científica tem concentrado esforços na tentativa de desenvolver algoritmos de detecção de crateras, algumas vezes semiautomáticos e outras automáticos.

O primeiro algoritmo desenvolvido para a detecção global de crateras de impacto foi desenvolvido por Stepinski e Urbach (2008) e Stepinski *et al.* (2009). O sistema

desenvolvido, denominado AutoCrat, consiste de dois módulos principais: um algoritmo que procura por depressões topográficas circulares e outro que utiliza técnicas de aprendizagem de máquina para separar o conjunto em crateras e não crateras. O sistema foi testado em oito regiões da superfície de Marte e, em regiões com abundância de crateras degradadas. Foram detectadas 70% das crateras que estavam listadas no catálogo de Barlow, sendo que em regiões com menor quantidade de crateras degradadas o sistema encontrou 85% das crateras listadas. Além disso, o sistema encontrou um grande número de crateras que ainda não constavam no catálogo de Barlow. Este catálogo, de acordo com o autor, é completo para crateras com diâmetro acima de 3 km. O número total de crateras nesse catálogo é de 75.919.

Uma revisão relevante de diversos CDAs desenvolvidos foi feita por Salamuniccar e Loncaric (2008). Eles revisaram 73 CDAs com o objetivo de fazer a integração de vários catálogos existentes. O grande problema para a integração dos diversos catálogos está no fato de que cada autor utiliza diferentes locais de testes, diferentes catálogos de *ground truth* e diferentes metodologias para avaliação dos CDAs. Neste sentido, Salamuniccar e Loncaric (2008) propuseram uma metodologia e compuseram um único catálogo. Como resultado, eles obtiveram um catálogo global da superfície de Marte contendo 57.633 crateras de impacto.

Salamuniccar *et al.* (2011) construíram um catálogo de crateras marcianas por meio de técnicas semi-automáticas. Tal catálogo foi compilado pela fusão de dois catálogos anteriores, o MA75919T desenvolvido por Stepinski *et al.* (2009) e o MA115225GT desenvolvido por Salamuniccar e Loncaric (2010). As crateras desses dois catálogos são correlacionadas para verificar duplicidades. Posteriormente, todas as candidatas a crateras são verificados manualmente e medidos novamente. Além das crateras presentes nesses dois catálogos, foram incluídas algumas crateras detectadas em dados MOLA e em imagens ópticas. Em dados MOLA as crateras foram detectadas por meio de um CDA baseado no método de Shen-Castan; entretanto para imagens ópticas dos sensores MDIM, THEMIS-DIR e MOC a detecção foi feita manualmente. Este novo catálogo contém 130.301 crateras de impacto, sendo completo para crateras acima de 2 km de diâmetro.

Além dos CDAs desenvolvidos e aplicados no âmbito global, existe uma grande quantidade de CDAs que foram desenvolvidos e aplicados em regiões selecionadas de superfícies planetárias. Alguns dos trabalhos mais relevantes são discutidos a seguir.

Os CDAs que existem na literatura são basicamente divididos em duas frentes principais, os que trabalham com abordagens supervisionadas e os que trabalham com

abordagens não supervisionadas. Os trabalhos que tratam de abordagens supervisionadas consistem, de forma geral, de técnicas para identificação das bordas das crateras como feições circulares ou elípticas. Os métodos, no geral, consistem basicamente em primeiro realizar uma filtragem e um realce na imagem, de forma a destacar as feições de interesse dos outros alvos presentes nas imagens, e em uma segunda etapa utilizam técnicas de detecção de feições circulares.

Barata *et al.* (2004) apresentaram uma metodologia para reconhecer automaticamente crateras de impacto na superfície de Marte. A metodologia consiste de três fases principais: primeiro as imagens são segmentadas por meio da medida de suas texturas, em seguida crateras são reconhecidas por meio da técnica de *template matching* e por último as bordas das crateras são localmente ajustadas pela transformação *watershed*. Essa metodologia resultou num total de 64,77% de detecção correta e 62,25% de falsas detecções.

Bandeira *et al.* (2007) desenvolveram uma metodologia para detecção de crateras em Marte, a qual consiste de três fases principais. A primeira é a seleção das candidatas, fase na qual áreas que correspondem à borda das crateras são identificadas, enquanto que a maioria dos ruídos é eliminada. Em seguida, essas candidatas são submetidas ao processo de *template matching* utilizando a transformada rápida de Fourier, o qual produz um volume de probabilidades, onde formas circulares de crateras são procuradas, numa terceira fase, em uma matriz de três dimensões.

Pedrosa *et al.* (2011) também utilizaram a mesma abordagem adotada por Bandeira *et al.* (2007), porém propuseram uma modificação na primeira fase, na qual utilizaram apenas operadores morfológicos para fazer uma melhor seleção das candidatas.

Kim *et al.* (2005) produziram um algoritmo composto por uma etapa que define os segmentos de borda dos objetos como sendo regiões de interesse. Em seguida, utilizaram função de ajuste e *template matching* para encontrar círculos ou elipses ótimas e, por fim, removeram falsas detecções por meio de redes neurais.

Bue e Stepinski (2007) utilizaram dados de topografia para fazer a detecção das crateras em Marte. Eles partiram do princípio de que crateras são curvaturas topográficas para extrair as bordas das crateras. Em seguida, utilizaram técnicas de processamento de imagens, morfologia matemática e transformada de *Hough* para fazer a segmentação e identificação das feições circulares.

Os CDAs que lidam com abordagens supervisionadas utilizam técnicas de aprendizagem de máquina para realizar a tarefa de identificação das crateras. Nesse tipo de

abordagem, há a necessidade de um conjunto de treinamento, isto é, o especialista fornece ao algoritmo cenas da imagem que representem crateras de impacto, bem como cenas da imagem que não representam crateras de impacto. Na fase de detecção, o algoritmo utiliza as informações fornecidas na fase de treinamento, para prever e classificar os novos dados não rotulados.

Wetzler *et al.* (2005) testaram alguns algoritmos de aprendizagem supervisionada para verificar qual seria capaz de identificar crateras de impacto com melhor desempenho. Os algoritmos foram aplicados em imagens da superfície de Marte, a qual continha crateras com até cinco pixels de diâmetro. Os algoritmos escolhidos para testes foram redes neurais *feed-forward*, *support vector machines* (SVM), e *continuously-scalable template models* (CSTM), dentre os quais, o SVM se mostrou ser mais eficiente na tarefa detecção de crateras de impacto.

Martins *et al.* (2009) propuseram uma abordagem para detecção automática de crateras de impacto na superfície de Marte utilizando algoritmos de aprendizagem baseados em *boosting* e características de *Haar*. Os métodos desenvolvidos foram inspirados no trabalho de Viola e Jones (2001) no contexto de detecção de faces.

Ding *et al.* (2011) focaram na detecção de crateras marcianas menos do que 1 km. Eles abordaram o problema utilizando morfologia matemática para identificar as candidatas a crateras. Em seguida, extraíram e selecionaram características de textura e integraram transferência de aprendizagem no *boosting*, com o objetivo de classificar em crateras e não crateras, as candidatas a crateras.

Bandeira *et al.* (2012) também propuseram uma abordagem embasada nos conceitos de forma e textura para identificar crateras menores do que 1 km da superfície de Marte. Primeiramente, as imagens foram analisadas por meio de operadores morfológicos, os quais buscaram regiões na imagem com características de crateras. Posteriormente, características de textura em combinação com o algoritmo *boosting* foram utilizadas para classificar previamente candidatas identificadas em crateras e não crateras.

O único CDA aplicado em dados de Mercúrio foi desenvolvido por Salamuniccar (2013). O CDA, originalmente desenvolvido para detecção de crateras de impacto em Marte e na Lua, foi testado em três regiões de Mercúrio, em dados da topografia reconstruídos a partir de imagens óticas. Tais dados possuem resolução de 1 km/pixel, o que implica na confiabilidade de detecção de crateras com diâmetros acima de 16 km. Além da detecção, foi possível comparar o perfil topográfico das crateras detectadas com as da Lua e de Marte. O

algoritmo desenvolvido utiliza detecção de bordas por lógica fuzzy para extrair características das crateras requeridas para transformação *fuzzy Radon-Hough* (RH). Seguindo esses passos, Modelo de Elevação Digital DEM e dados de parâmetro de espaço são interpolados para o cálculo de medidas morfométricas (relação diâmetro/profundidade, circularidade, borda, pico central, dentre outros) e análise do espaço de parâmetro.

Fassett *et al.* (2012) catalogaram e caracterizaram a população de bacias de Mercúrio. Nesta análise, 46 bacias foram classificadas como certas ou prováveis bacias de impacto, enquanto que poucas bacias que se encontravam em estado de degradação foram classificadas como incertas. O estudo envolveu a catalogação das bacias, a avaliação da distribuição do tamanho-frequência das bacias, análise das características e história das modificações das bacias. Além disso, fizeram uma breve exploração da interação entre vulcanismo, tectonismo e evolução das bacias em Mercúrio. Os dados obtidos foram comparados com os da Lua, visto que a superfície de Mercúrio e da Lua possuem muitas similaridades.

O estudo de crateras *peak-ring* e de outras morfologias de crateras de impacto, como a transição entre crateras complexas e *multi-ring*, é importante para o entendimento dos mecanismos de formação de bacias em planetas terrestres. Mercúrio tem a maior população, e a maior população por área, de bacias *peak-ring* e protobacias no interior do sistema solar, o que o torna um importante laboratório para análise dessas questões. Com base nisso, Baker *et al.* (2011) analisaram o mais recente mosaico de imagens constituído por dados da Messenger e da Mariner 10 (Becker *et al.*, 2009) e geraram um banco de dados de bacias *peak-ring* e protobacias. Desta forma, o foco foi distinguir características morfológicas de protobacias, de bacias *two-ring* e de bacias *multi-rings*.

Barnouin *et al.* (2012) utilizaram imagens e dados Laser para investigar a relação entre o diâmetro e a profundidade das crateras de impacto em Mercúrio. Técnicas de sombras foram utilizadas para medir a profundidade das crateras, e indicam que em ambos os casos, tanto as crateras simples quanto as mais complexas apresentam a relação de diâmetro/profundidade em concordância com dados medidos anteriormente pela Mariner 10.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Crateras de impacto

Crateras de impacto foram vistas pela primeira vez por Galileu em 1610, quando ele apontou seu primeiro telescópio para a Lua. Galileu reconheceu as bordas levantadas e o pico central dessas feições, mas as descreveu apenas como pontos circulares na Lua e não discutiu a possível origem dessas feições. Entretanto, os astrônomos se questionaram durante os três séculos seguintes, pois eles acreditavam que aquelas feições circulares da Lua eram vulcões extintos gigantes. Somente no início de 1970, quando foram adquiridas imagens de alta resolução e com a investigação *in situ* do programa Apollo 11, essa questão foi resolvida, comprovando-se que quase todas as crateras da Lua tinham origem de impacto (MELOSH, 2011).

Crateras de impacto são estruturas geológicas formadas quando um meteorito, ou um asteroide ou um cometa, colide com a superfície de um planeta. Asteróides são grandes pedaços de rocha e metal que possuem tamanhos variados, podendo ter algumas centenas de metros até algumas centenas de quilômetros. A maioria dos asteróides se encontra orbitando o Sol no cinturão de asteróides entre as órbitas de Marte e Júpiter. Os cometas são uma mistura de gelo, rocha e poeira. Há provavelmente um trilhão de cometas que orbitam o Sol nos arredores do sistema solar. Um meteoróide é um pedaço de pedra, metal, ou detritos de gelo de um cometa ou um asteroide que viaja no espaço. Quando um meteoróide voa através da atmosfera da Terra, ele é chamado de meteoro, pois ele queima devido o atrito com a atmosfera. Se o meteoróide é suficientemente grande, parte dele pode sobreviver ao atrito com a atmosfera e cair na superfície da Terra. Essas peças são então chamadas de meteoritos (MELOSH, 2011).

As crateras de impacto são feições aproximadamente circulares. A forma circular não se justifica pela forma do corpo impactante (meteorito, asteroide ou cometa), pelo contrário, quase nunca o material que colide com a superfície é redondo. A forma circular das crateras provém da onda de choque do bólido que ejeta o material da superfície para fora, como resultado da explosão no momento do impacto (FRENCH, 1998).


A formação de uma cratera de impacto é um processo complexo e contínuo, e convenientemente dividido em três estágios distintos, cada um dominado por diferentes forças e mecanismos (MELOSH, 1989; FRENCH, 1998):

2.1.1 Contato e compressão

Contato e compressão é o estágio mais rápido dentre os três. É neste estágio que o projétil entra em contato com a superfície do planeta e transfere a sua energia e o seu impulso. A energia cinética de um projétil viajando a alguns quilômetros por segundo é extremamente alta, pois é proporcional a massa do projétil e ao quadrado de sua velocidade.

Durante o contato e a compressão, o projétil mergulha na superfície do planeta, gerando fortes ondas de choque, as quais se propagam tanto no projétil (comprimindo e desacelerando), quanto na superfície alvo (comprimindo e acelerando para baixo e para fora). A Figura 1 ilustra este processo.


Figura 1: Contato do projétil com a superfície do planeta.



Fonte: Adaptado de FRENCH (1998).

Na fase final do estágio de contato e compressão, o projétil foi comprimido a alta pressão, frequentemente alcançando centenas de gigapascals, e mediante a descompressão o projétil pode estar no estado líquido ou gasoso devido ao calor nele depositado durante o processo de compressão. A Figura 2 ilustra o processo do fim do estágio de compressão.

Figura 2: Fim do estágio de contato e compressão.




Fonte: Adaptado de FRENCH (1998).

2.1.2 Estágio de escavação

À medida que a fase de compressão termina, o projétil está rodeado por ondas de choques que se expandem rapidamente através da rocha alvo. As ondas de choque que viajam para cima e cruzam a superfície do solo são refletidas para baixo como rarefação (liberação de ondas). Esse processo de reflexão também converte algumas das ondas de choque iniciais em energia cinética, e a rocha envolvida é acelerada para fora, como fragmentos isolados viajando a altas velocidades.

Esse processo complexo impulsiona a rocha alvo para fora a partir do ponto de impacto, produzindo um fluxo de escavação simétrico em torno do centro da estrutura em desenvolvimento. Nos níveis superiores, a rocha alvo move-se predominantemente para cima e para fora, enquanto nos níveis mais baixos, a rocha alvo move-se para baixo e para fora. Esses movimentos produzem uma depressão em forma de tigela nas rochas alvo, que são chamadas de cavidade transitória ou cratera transitória. A cratera transitória é dividida em zona superior e inferior, as quais são muito similares. Na zona superior, as velocidades transmitidas para a rocha alvo podem ser tão elevadas chegando a alcançar quilômetros por segundo, altas suficientes para escavar o material fragmentado e ejetá-lo para além da borda definitiva da cratera. Mesmo com distâncias significativas do ponto do impacto, as pressões de choque e as velocidades de ejeção resultantes permanecem suficientemente elevadas para o material (acima de 100 m/s). Por essa razão, o diâmetro final da cratera é muitas vezes maior do que o diâmetro do projétil, geralmente 20 a 30 vezes maior. Enquanto que o diâmetro da cratera, de forma grosseira, chega a medir de três a quatro vezes a sua profundidade.

Figura 3: Estágio de escavação.




Fonte: Adaptado de FRENCH (1998).

Em níveis mais profundos, a liberação de ondas de choques tensionais é mais baixa. Como resultado, a fratura é menos acentuada, as velocidades de fluxo de escavação são

mais baixas e as próprias linhas de fluxo de escavação não são orientadas para ejetar o material para além da borda da cratera.

Enquanto as zonas da cratera transitória continuam a expandir, a elevação das rochas próximas à superfície forma a borda da cratera. Esse processo continua enquanto as ondas de choque de expansão e as ondas de liberação forem suficientemente fortes para ejetar ou deslocar o material da cavidade em formação. No entanto, ao deformar e ejetar o material, essas ondas perdem a energia continuamente, até que as ondas de choque já não podem escavar ou deslocar a rocha alvo. Nesse momento, o crescimento da cratera transitória atinge a extensão máxima.

Figura 4: Fim do estágio de escavação.



Fonte: Adaptado de FRENCH (1998).


A fase de escavação é considerada breve para os padrões temporais geológicos. Por exemplo, se o fluxo de escavação perto da superfície tem uma velocidade média mínima de 1 km/s, a cratera transitória de 200 km de diâmetro pode ser escavada em menos de 2 minutos. A escavação de uma cratera de 1 km de diâmetro irá ocorrer em cerca de 6 segundos, enquanto que uma cratera de 200 km de diâmetro requer apenas 90 segundos (MELOSH, 1989).

2.1.3 Estágio de modificação

A etapa de escavação termina quando a cratera transitória atinge seu tamanho máximo, e é neste momento que o estágio de modificação começa. Nessa fase, a cratera transitória é modificada por fatores mais convencionais, como o da gravidade e dos mecanismos das rochas, como por exemplo, os detritos soltos tendem a deslizar, formando

terraços ao lado da cratera. A fase de modificação não tem fim claramente marcado, e os processos de modificação de elevação e queda fundem-se gradualmente nos processos normais de movimento de massa geológica, soerguimento isostático, erosão e sedimentação.


Figura 5: (a) Estágio de modificação e (b) cratera final.



Fonte: Adaptado de FRENCH (1998).

As alterações da cratera transitória durante a fase de modificação dependem do seu tamanho, da estrutura e das propriedades da rocha alvo. Crateras pequenas são alteradas principalmente pelo colapso das suas paredes superiores, neste caso, a forma da cratera final é pouco alterada em relação à cratera transitória. Já em estruturas maiores, a modificação pode envolver mudanças estruturais importantes, tais como, a elevação da parte central do terreno e grande colapso periférico ao redor desse pico central. Dependendo do grau em que a cratera transitória é modificada, três tipos diferentes de estruturas de impacto podem ser formadas: crateras simples, crateras complexas e bacias *multi-ring*. O tipo clássico de cratera são depressões em forma de tigela, como mostra a Figura 6. Esse tipo é comum em tamanhos menores do que alguns quilômetros de diâmetro.


Figura 6: Exemplo de cratera simples.



Fonte: PSI (2013).


Grandes estruturas apresentam diferentes formas. São caracterizadas por uma região central levantada, um piso geralmente plano e um grande colapso em torno da borda. De acordo com French (1998), os detalhes destas interações são incertos, mas o resultado geral é que a cratera transitória original, em forma de tigela, é modificada, as rochas profundas, abaixo do centro da cratera transitória, se elevam para formar um soerguimento central. Ao mesmo tempo, rochas em torno da região de desmoronamento, se depositam ao longo das falhas concêntricas de modo a formar um ou mais anéis, e uma série de terraços ao longo das margens exteriores da estrutura final. A Figura 7 ilustra as etapas da formação de crateras complexas.

Figura 7: Formação de cratera complexa. (a) Estágio de escavação, (b) fim do estágio de escavação e começo do estágio de modificação, (c) estágio de modificação e (d) estrutura final.



Fonte: Adaptado de FRENCH (1998).

Figura 8: Exemplo de cratera complexa.



Fonte: PSI (2013).


A complexidade da morfologia aumenta conforme o aumento do diâmetro das crateras. Crateras com centenas de quilômetros são denominadas de bacias e classificadas em: protobacias, bacias *peak-ring* e bacias *multi-ring*, como definido por Pike (1988).

As protobacias são definidas morfologicamente pela presença de um pico central acompanhado por um conjunto de picos na forma de um anel completo ou parcial. Essa estrutura de elevação central é o que diferencia as protobacias de crateras complexas. A presença de um anel interno sugere que as protobacias dividem similaridades com grandes bacias *peak-ring* e assim representam uma forma transicional entre crateras complexas e bacias *peak-ring*. O anel interior e o pico central nas protobacias são significativamente menores do que nas *peak-ring* ou nas crateras complexas.

As bacias *peak-rings* são definidas como tendo um ou dois anéis topográficos interiores ou um conjunto de picos que formam um anel descontínuo, e neste caso, não há a presença de um pico central.

Bacias *Multi-ring* contem três ou mais anéis topográficos reconhecíveis, entretanto, muitas vezes esses anéis são incompletos e o seu reconhecimento se torna ambíguo, especialmente quando se trata de bacias de maiores dimensões. A Figura 9 ilustra a morfologia dos diferentes tipos de bacias e apresenta um exemplo para cada classe.

Figura 9: Morfologia de bacias de Mercúrio de acordo com a disposição dos picos. (a) Bacia com pico central (*ringed peak-cluster*); (b) Protobacia, bacia com um pico central e conjunto de picos em forma de anel; (c) bacia *Peak-Ring*, anel formado por um grande conjunto de picos e ausência de pico central; (d) Eminescu (exemplo de bacia com pico central em forma de anel); (e) Bacia Van Gogh (exemplo de protobacia); (f) Bacia Raditladi (exemplo de bacia *peak-ring*).




Fonte: Adaptada de BAKER (2011)

As crateras de impacto são muito menos frequentes em corpos rochosos geologicamente ativos, como a Terra e Vênus, por exemplo. Entretanto, algumas crateras terrestres resistiram aos processos de erosão, tais como vento, chuva, fluxo de água, atividades sedimentares, vulcânicas e tectônicas, como mostra a Figura 10, que apresenta 188 estruturas reconhecidas como crateras de impactos (EARTH IMPACT DATABASE, 2015).

No Brasil, até o momento, existem sete estruturas com origem meteorítica comprovada (CRÓSTA, 2014). Entretanto, existem outras estruturas que supõem-se que foram originadas por impactos, mas que ainda não dispõem de evidências comprobatórias. De

acordo com Crósta (2013), a quantidade de crateras reconhecidas até o momento é considerada pequena quando comparada com outras regiões da Terra com condições geológicas similares. Porém, houve um avanço significativo nos últimos anos, visto que até 2004 apenas 05 estruturas tinham sido reconhecidas como sendo crateras de impacto.

Figura 10: Localização de crateras de impacto na Terra.



Fonte: *Earth Impact Database* (2015).

A cratera terrestre talvez mais famosa é a Cratera do Meteoro, apresentada na Figura 11, também conhecida como *Barringer Crater*, localizada no Arizona. Essa cratera foi a primeira estrutura terrestre a ser comprovada de origem de impacto. Ela possui aproximadamente 1.200 metros de diâmetro e foi formada há cerca de 50.000 anos.

Figura 11: Cratera do Meteoro.



Fonte: LPI (2013).

De acordo com Melosh (2011), a análise da população de crateras existentes, em conjunto com algumas suposições sobre a taxa de formação de crateras, pode revelar muito sobre a história geológica de uma superfície. Uma população normal é composta por crateras com uma vasta gama de tamanhos, algumas são relativamente frescas, com bordas afiadas, material expelido radialmente em grandes extensões e nítidos campos de pequenas crateras secundárias, ao passo que outras são progressivamente mais degradadas.

Estudos das populações de crateras são ferramentas poderosas para a investigação geológica da superfície de planetas e satélites. Se a distribuição de fluxo e tamanho dos corpos de impacto for conhecida, estudos de populações de crateras podem produzir idades relativas para a superfície e justificar algumas das suas características (MELOSH, 2011).

As crateras de impacto são as únicas ferramentas disponíveis para determinar a idade relativa de superfícies planetárias. Embora a cronologia absoluta seja preferível, só há, por enquanto, amostras de rochas isotopicamente datadas da Terra e da Lua, o que torna impossível o uso dessa ferramenta para determinar a idade das superfícies planetárias (BARLOW, 1988).

2.2 Sensoriamento Remoto

Novo (2008) define Sensoriamento Remoto (SR) como o sistema de aquisição da informação de um objeto, a partir de medidas feitas por um sensor, sem o contato físico direto com o mesmo. Os sistemas sensores são definidos como qualquer equipamento capaz de transformar a radiação eletromagnética em um sinal que possa ser convertido em informações sobre o meio ambiente.

Satélites de SR ópticos usam a luz refletida para detectar a energia eletromagnética na superfície da Terra ou de qualquer outro corpo planetário. O sensor coleta e armazena informações sobre essa energia. Essa informação é transmitida para uma estação receptora na forma de dados, os quais são processados formando uma imagem (USGS, 2013).

No contexto de ciências planetárias, o Sensoriamento Remoto é primordial, pois é por meio dele que se conseguem informações de onde o homem não consegue chegar. Desta forma, temos informações sobre os planetas e sobre as luas no nosso sistema solar.

De acordo com Novo (2008), os diferentes sistemas sensores são caracterizados por suas resoluções espacial, espectral, radiométrica e temporal. A resolução espacial é a medida da menor separação linear ou angular entre dois objetos da superfície terrestre que o

sensor é capaz de detectar, ou seja, a resolução espacial descreve o nível de detalhe, ou o tamanho do menor objeto que pode ser identificado na imagem. A resolução espectral é uma medida da largura das faixas espectrais e da sensibilidade do sistema sensor em distinguir entre dois níveis de intensidade do sinal de retorno (NOVO, 2008). A resolução radiométrica tem relação com a capacidade do sensor de diferenciar dois níveis de intensidade do sinal de retorno. E a resolução temporal se refere ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área, isto é, o ciclo de cobertura, ou a frequência com que os dados são coletados a partir de um satélite ou um sensor.

Os dados registrados pelos sensores e armazenados em imagens digitais são armazenados em forma matricial, no qual cada elemento da matriz é chamado de pixel, redução de *picture element*. Cada pixel representa uma área na imagem, a qual corresponde a capacidade do sensor considerado em capturar informação de diferentes tamanhos, isto é, a resolução espacial. Por exemplo, se um sensor tem resolução máxima de 15 metros, significa que cada pixel representa uma área de 15m x 15m, ou 225 m². Quanto maior a resolução, menor a área representada pelo pixel, e significa que o sensor é capaz de discernir pequenos objetos.

2.2.1 Sensoriamento Remoto de Crateras de Impacto

A análise de dados de SR tem sido a primeira opção para estudos de crateras de impacto. As imagens permitem a busca por estruturas que apresentam as características de crateras de impacto. O SR também possibilita a obtenção da elevação da superfície, a qual pode ser obtida por meio de imagens estereoscópicas e técnicas ativas, tais como radar e altimetria laser.

De acordo com Osinski e Pierazzo (2012), um dos usos primários de dados topográficos, particularmente com respeito a aplicações para crateras de impacto, é a medida de aspectos morfométricos dessas feições, tais como profundidade, diâmetro, volume de preenchimento das crateras e análise de material ejetado com o impacto.

Para análise 3D de crateras na superfície da Terra, existem diversas opções de conjunto de dados tais como o SRTM (do inglês, *Shuttle Radar Topography Mission*) como, por exemplo, no trabalho de Van Zyl (2001), e o GDEM (do inglês, *Global Digital Elevation Model*), produto criado por imageamento estéreo da *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER) sensor de alta resolução aéreo LiDAR quando sobrevoa

alvos específicos. Os dados globais têm resolução espacial da ordem de 30 m/pixel, considerando que o aéreo LiDAR pode ter alta resolução, da ordem de centímetros. O LiDAR é uma ferramenta importante, pois permite a aquisição dos dados da topografia independente da vegetação local, uma vez que o pulso laser que reflete a vegetação pode ser filtrado. O LiDAR tem sido útil para avaliação da estrutura e da morfologia de estruturas de impacto terrestre cobertas por vegetação densa que, devido à sua alta acurácia, permite o monitoramento de mudanças (OSINSKI e PIERAZZO, 2012).

Outro dado proveniente do SR é a energia radiante, que contém informação da temperatura, que pode ser usado para determinar informações mais profundas do que das camadas superiores da superfície. Tais propriedades termofísicas incluem *brightness temperature*, inércia termal e estimativa de abundância de rochas. A temperatura radiante e a inércia termal têm sido usadas para estudos mais acurados de locais de impacto em Marte (PELKEY *et al.*, 2001) e recentemente para a Lua (BANDFIELD *et al.*, 2011). Mudanças no tamanho da partícula ou nas propriedades termofísicas podem ajudar a derivar a umidade do solo, detectar bordas das crateras cobertas por depósito de areia grossa e distinguir os mantos de ejeção do terreno circundante (OSINSKI e PIERAZZO, 2012).

O planeta Vênus possui uma atmosfera espessa, rica em CO₂, portanto obscura à maioria das técnicas ópticas de SR. O seu mapeamento foi conseguido graças ao *Pioneer Venus Orbiter* enviada em 1980, a bordo da qual um sensor radar adquiriu, pela primeira vez, dados da topografia do planeta com a resolução de 150 km. Posteriormente, a sonda *Magellan* foi enviada e adquiriu dados de radar com melhores resoluções, os quais permitiram melhores análises e revelaram a escassez de crateras de impacto em Vênus, indicando que a superfície é mais jovem do que previamente suscitado (OSINSKI e PIERAZZO, 2012).

2.2.2 Sensoriamento Remoto de Mercúrio

De todos os planetas terrestres do sistema solar, Mercúrio é o menos conhecido. Até 2008, menos de 50% de sua superfície tinha sido imageada. Até aquela data, a única sonda a visitar Mercúrio tinha sido a Mariner 10.

A Mariner 10 foi lançada em novembro de 1973, sendo a primeira missão multiplanetária, a qual realizou um sobrevoo em Vênus e três sobrevoos em Mercúrio, retornando mais de 12.000 imagens para a Terra. A sonda passou por Vênus em fevereiro de 1974 a uma distância de 4.200 km e cruzou a órbita de Mercúrio em março de 1974 a uma

distância de 704 km de sua superfície. Posteriormente, foi colocada em órbita ao redor do Sol e sobrevoou Mercúrio por mais duas vezes em seis meses.

Em 1991, astrônomos utilizando observações de radar levantaram a possibilidade de haver água em forma de gelo, em Mercúrio, nos polos Norte e Sul, dentro de crateras profundas que são permanentemente sombreadas.

Em 2004 a NASA lançou a sonda Messenger que, antes de entrar na órbita de Mercúrio, fez dois sobrevoos em Vênus, sendo um em 2006 e o outro em 2007 e, posteriormente, sobrevoou Mercúrio por três vezes entre os anos de 2008 e 2009. Em 2011 a Messenger entrou na órbita de Mercúrio com o objetivo de cumprir a missão primária estimada para ser realizada entre 18 de março de 2011 a 17 de março de 2012. Após esse período, iniciou-se a primeira extensão da missão que durou de 18 de março de 2012 a 17 de março de 2013. Em seguida, houve a segunda extensão da missão com duração até março de 2015. A sonda terminou a sua missão em 30 de abril de 2015, após ter esgotado todo o seu combustível. Como a sonda foi perdendo altitude, devido à falta de combustível, imagens com resoluções inéditas foram adquiridas nos seus últimos meses de operação.


A missão Messenger tinha seis objetivos específicos (NASA, 2011):

- Fornecer o mapeamento dos principais elementos de Mercúrio com uma incerteza relativa de 10% na escala de 1.000 km e determinar a composição e mineralogia local na escala de 20 km;
- Fornecer um mapa global com mais de 90% de cobertura (monocromático) com resolução média de 250m, e mais de 80% do planeta imageada estereoscopicamente. Também fornecer um mapa global multiespectral com 2 km/pixel de resolução média, e mostrar metade do hemisfério norte, topograficamente, com resolução média de 1,5 m de altura;
- Fornecer um modelo de campo magnético multipolo, através de termos quadrupolo, com uma incerteza de menos de ~20% na magnitude do dipolo e direção;
- Fornecer um campo de gravidade global, de grau e ordem de 16 e determinar a razão entre o momento do planeta sólido de inércia para o momento de inércia total de ~20% ou melhor;
- Identificar o principal componente do material radar-reflexivo no polo norte de Mercúrio;

- Fornecer perfis de altitude em 25 km de resolução das principais espécies neutras da atmosfera e caracterizar as principais distribuições de energia como funções de hora local, distância heliocêntrica de Mercúrio, e a atividade solar;

Para alcançar todos os objetivos, a sonda Messenger adquiriu diversos tipos de observações a partir de diferentes porções da órbita de Mercúrio. Conforme a Figura 12, existem oito instrumentos científicos a bordo da sonda Messenger: o *Mercury Dual Imaging System* (MDIS), o *Gamma-Ray and Neutron Spectrometer* (GRNS), o *X-Ray Spectrometer* (XRS), o *Magnetometer* (MAG), o *Mercury Laser Altimeter* (MLA), o *Mercury Atmospheric and Surface Composition Spectrometer* (MASCS), e o *Energetic Particle and Plasma Spectrometer* (EPPS). Os instrumentos se comunicam com a sonda através das DPUs (*Data Processing Units*).

Figura 12: Instrumentos a bordo da sonda MESSENGER.




Fonte: MESSENGER (2013).

Neste trabalho, foram utilizados dados do instrumento MDIS. O MDIS, apresentado na Figura 13, é composto por duas câmaras, a WAC (do inglês, *Wide-Angle Camera*) e a NAC (do inglês, *Narrow-Angle Camera*). A WAC é uma câmara de grande angular que adquire imagens multiespectrais por meio das suas 12 bandas espectrais de

regiões relativamente extensas. A NAC é uma câmara de ângulo estreito e adquire imagens monocromáticas de elevada resolução para regiões menores. Somente uma câmara opera por vez, o que permite que elas dividam o mesmo conjunto de controle eletrônico.

Figura 13: Instrumento MDIS.




Fonte: MESSENGER (2013).

O MDIS foi programado para adquirir mais de 75.000 imagens durante o primeiro ano da missão orbital. Durante os três sobrevoos em Mercúrio, antes da inserção em órbita, o MDIS adquiriu imagens de mais de 80% da superfície do planeta, conforme mostra o mapa da Figura 14. A área mais estreita (delimitada em amarelo) refere-se à região imageada durante o terceiro sobrevoo. As áreas maiores são regiões da superfície imageadas durante o primeiro e segundo sobrevoos. Somente com os sobrevoos, a Mariner 10 e a Messenger forneceram imagens de mais de 98% da superfície do planeta. Devido à alta velocidade da sonda e a lenta rotação de Mercúrio, o encontro com o planeta é rápido, o que faz com que o ângulo de iluminação varie dentro do mosaico global, resultando em uma aparência não uniforme do planeta.

Durante os primeiros 176 dias da missão orbital, que equivale a um dia solar em Mercúrio, o MIDS adquiriu imagens para produzir um mapa base de alta resolução da morfologia da superfície (250 m/pixel, ou melhor). Devido à órbita da Messenger ser altamente elíptica, a sonda passa perto da superfície em altas latitudes ao norte, mas muito longe no hemisfério sul, assim ambas as câmaras estão sendo utilizadas para a construção do mapa global. Para o hemisfério sul, as imagens são obtidas com a NAC, que possui um campo de visada de 1,5° e pode adquirir imagens com sete vezes melhor resolução do que a WAC. Para o hemisfério norte, quando a sonda está mais próxima e se movendo mais rápido sobre a superfície, a WAC é utilizada, pois possui o campo de visão de 10,5°, o que permite uma boa

cobertura da imagem. As imagens tanto da NAC quanto da WAC estão sendo mosaicadas para produzir o mapa global de Mercúrio (NASA, 2011).

Figura 14: Mapa das áreas da superfície de Mercúrio imageadas durante os três sobrevoos da sonda Messenger antes de entrar em órbita.



Fonte: NASA (2011).

Além do mapa global da superfície (mosaico de imagens em níveis de cinza), o MDIS está adquirindo um mapa de cor. O mapa de cor é composto por imagens WAC, tomadas por oito bandas espectrais, cuja resolução espacial média é de 1 km/pixel, ou melhor. Em contraste com as condições no momento de aquisição das imagens monocromáticas, mais adequadas para a representação da superfície topográfica, as imagens coloridas de alta qualidade são obtidas quando ambos, a sonda e o Sol, estão alinhados, fazendo com que as sombras sejam limitadas. Os oito filtros de comprimento de onda diferentes da WAC começam em 430 nm e vão até 1.000 nm. As imagens adquiridas através desses filtros de bandas estreitas são combinadas para criar imagens e cores que acentuam as diferenças da composição da superfície de Mercúrio (NASA, 2011).


Após a construção do mapa da morfologia da superfície, foram combinadas imagens de resolução média de 250 m/pixel, para a construção de um mapa estéreo. Tal como acontece com o mapa da morfologia da superfície, as imagens são adquiridas sob iluminação solar não vertical, de modo que as sombras acentuam a topografia da superfície. Além disso, as imagens do mapa estéreo são adquiridas sob ângulos de vista diferentes daqueles

adquiridos para o mapa da morfologia, cerca de 20°, o que permite obter informações tridimensionais da superfície, a partir de imagens estereoscópicas (NASA, 2011).

Além da obtenção de imagens para a produção de mapas globais, o MDIS tem por objetivo monitorar a região polar sul de Mercúrio. Para tanto, a região polar foi imageada uma vez a cada quatro passagens da sonda. Assim, feições que estavam sob o efeito de sombras durante alguma passagem da sonda puderam ser imageadas em passagens seguintes com diferentes condições de iluminação. A identificação de áreas permanentemente sombreadas são de interesse para entender os materiais presentes nos polos de Mercúrio e se estes materiais, altamente reflexivos para radar, são compostos de gelo (NASA, 2011).

Estão sendo adquiridas também, imagens de alta resolução de algumas outras áreas de elevado interesse científicos. Nessas áreas a resolução espacial das imagens chega a 12 m/pixel.


Figura 15: Exemplos de imagens da superfície de Mercúrio com resolução de 12 m/pixel.



Fonte: MESSENGER (2013).

Como dito, a órbita da Messenger é altamente elíptica, a sonda passa a 200 km da superfície no ponto mais próximo e a mais de 15.193 km de distância da superfície, no mais distante. Desde o início da fase orbital da missão, o plano da órbita da sonda é inclinado 82,5° em relação ao equador de Mercúrio, e o ponto mais baixo da órbita é atingido em uma latitude de 60° Norte. A Figura 16 ilustra a órbita da sonda em Mercúrio.

Figura 16: Órbita da sonda MESSENGER.



Fonte: NASA (2011).

A órbita da sonda é elíptica ao invés de circular, devido à superfície do planeta refletir muito o calor que recebe do Sol. Na altitude de 200 km, a reflexão do calor é equivalente a quatro vezes a intensidade solar na Terra. Assim, passando somente uma pequena parte de cada órbita perto do planeta, a temperatura da sonda pode ser mais bem regulada. As órbitas denominadas amanhecer - entardecer são boas para obter imagens das características da superfície, tais como crateras, pois as sombras são proeminentes e fazem com que a topografia e textura sejam claramente vistas. Outras vezes, a sonda segue um caminho que a leva diretamente acima de um hemisfério totalmente iluminado de Mercúrio e, em seguida, sobre um hemisfério completamente escuro. Essas são chamadas de órbitas meio-dia e meia-noite, e são boas para observações de cor no lado diurno, pois há menos sombras para obscurecer as características da superfície (NASA, 2011).

2.3 Processamento Digital de Imagens

A área de Processamento Digital de Imagens (PDI) vem apresentando, ao longo dos anos, um aumento significativo no desenvolvimento tecnológico, estando presente na solução de aplicações em diversas áreas do conhecimento humano.


De acordo com Gonzalez e Woods (2010), o interesse em métodos de processamento de imagens digitais decorre de duas áreas principais de aplicação: melhoria da

informação visual para interpretação humana e o processamento de dados de cena para percepção automática através de máquinas.

O PDI teve seu início, propriamente dito, em mil novecentos e sessenta, quando um número limitado de pesquisadores começou a analisar dados espectrais aerotransportados e fotografias aéreas digitalizadas. Entretanto, só após o lançamento do primeiro satélite da saga Landsat, em 1972, é que os dados de imagens digitais orbitais se tornaram extensamente disponíveis para aplicações de SR.

O emprego de técnicas de computação para o melhoramento de imagens produzidas por uma sonda espacial iniciou-se no *Jet Propulsion Laboratory* (Pasadena, California) em 1964, quando imagens da Lua, transmitidas pela sonda Ranger 7, foram processadas por um computador para corrigir vários tipos de distorção de imagem inerentes à câmara de televisão a bordo. Essas técnicas serviram de base para métodos melhorados no realce e restauração de imagens das missões *Surveyor* para a Lua, série *Mariner* de missões para Marte, voos tripulados da Apollo para a Lua e outros (GONZALEZ e WOODS, 2010). Na Figura 18 apresenta-se a primeira imagem da Lua, tirada pelo veículo espacial U.S. Ranger 7, obtida em 31 de julho de 1964.

Figura 17: Primeira imagem da Lua obtida por uma sonda espacial.



Fonte: Gonzalez e Woods (2010).

2.3.1 Conceito de Imagem e Imagem Digital

De acordo com Pedrini (2008), uma imagem pode ser definida como uma função de intensidade luminosa, denotada $f(x,y)$, cujo valor ou amplitude nas coordenadas espaciais (x,y) fornece a intensidade ou o brilho da imagem naquele ponto. Esse valor de intensidade, em cada coordenada espacial, consiste da luz refletida dos objetos e da quantidade de luz incidindo na cena observada. Assim, a função $f(x,y)$ pode ser representada pela Equação 1:

$$f(x,y) = i(x,y) * r(x,y) \quad (1)$$


para $0 < i(x,y) < \infty$ e $0 < r(x,y) < 1$, onde $i(x,y)$ é a *luminância* e $r(x,y)$ é *reflectância*.

A natureza de $i(x,y)$ é determinada pela fonte de luz, enquanto $r(x,y)$ é determinada pelas características dos objetos na cena.

Uma imagem digital pode ser considerada como uma função bidimensional, $f(x,y)$, sendo que todos os valores de $f(x,y)$ são discretos.

Por convenção, a origem da imagem está localizada no canto superior esquerdo da imagem. A Figura 18 representa um exemplo de uma imagem digital.

Figura 18: Convenção dos eixos para representação de imagens digitais.




Outra abordagem é de que uma imagem digital pode ser considerada como sendo uma matriz de pontos amostrados de uma imagem contínua, cada ponto com um valor de brilho, de acordo com a quantização da imagem. Esses pontos são denominados de pixels.

A maioria das técnicas de análise de imagem realiza o processamento dos dados em um espaço discreto, por um computador digital. Para que o processamento desses dados seja possível, é necessário realizar a conversão destes, do espaço contínuo (R, R^2, R^3) para o discreto (Z, Z^2, Z^3) . A passagem do espaço contínuo para o discreto é conseguida através da obtenção de amostras do espaço contínuo. Esse processo é chamado de digitalização.

Ao processo de discretização das intensidades luminosas dá-se o nome de *quantização*. Esse processo de quantização está associado com a sensibilidade dos detectores utilizados na aquisição da imagem, que usualmente varia de 1 bit/pixel a 24 bits/pixel. Assim, imagens de 1 bit/pixel comportam 2^1 níveis, sendo então uma imagem binária. Imagens com 8 bits/pixel comportam 2^8 intensidades diferentes para cada pixel, ou seja, 256 níveis de cinza.

A Figura 19 ilustra diferentes exemplos de quantização.

Figura 19: Quantização de imagens.



Fonte: Gonzalez e Woods (2010).

2.3.2 Processamento Morfológico de Imagens

O processamento morfológico de imagens (PMI) tem sido cada vez mais empregado em trabalhos sobre detecção de crateras em imagens de superfícies planetárias. Ele se baseia na teoria dos conjuntos, mais precisamente na combinação de operações de intersecção, união, complementação e translação (SOILLE, 2003). Inicialmente, o PMI era usado apenas para tratar imagens binárias e posteriormente foi estendido para tratar imagens em níveis de cinza, utilizando a teoria dos reticulados.

2.3.2.1 Teoria dos reticulados

O primeiro conceito fundamental em PMI é o de relação de ordem parcial. Esta relação permite a comparação de certos subconjuntos entre si (SERRA, 1986):

Definição 01: Seja L um conjunto não vazio. Dizemos que a relação $\leq$ em L é dita uma relação de ordem parcial se e somente se para todo $a, b, c \in L$, valem:

$a < a$ Reflexividade

$a \leq b \text{ e } b \leq a \Rightarrow a = b$ Anti-simetria

$a \leq b \text{ e } b \leq c \Rightarrow a \leq c$ Transitividade

Dizemos nesse caso que L , juntamente com a relação $\leq$, é um conjunto parcialmente ordenado.

Definição 02: $(L, \leq)$ é totalmente ordenado ou uma cadeia $\Leftrightarrow \forall a, b \in L$, tem-se que $a \leq b$ ou $b \leq a$.

Seguem definições de ínfimo e supremo. Tais definições são a base para a construção dos operadores elementares do PMI: erosão e dilatação.

Definição 03: Seja $X \subset L$. O elemento a é um limitante superior de $X \Leftrightarrow a \in L \text{ e } x \leq a, \forall x \in X$. O elemento a é um limitante inferior de $X \Leftrightarrow a \in L \text{ e } a \leq x, \forall x \in X$.

Definição 04: Se a é um limitante superior de X e $a \in X$, então a é único e chamado de maior elemento de X . Se a é um limitante inferior de X e $a \in X$ então a é único e chamado de menor elemento de X .

Definição 05: Seja $X \subset L$. Se existir um menor elemento para o conjunto dos limitantes superiores de X , então este elemento é chamado de supremo de X e denotado $\sup X$. De outra forma, tem-se que $\forall a \in L, a$ é um limitante superior de $X \Leftrightarrow \sup X \leq a$.

Definição 06: Seja $X \subseteq L$. Se existir um maior elemento para o conjunto dos limitantes inferiores de X , então este elemento é chamado de ínfimo de X e denotado $\inf X$. De outra forma, tem-se que $\forall a \in L. a$ é um limitante inferior de $X \Leftrightarrow a \leq \inf X$.

Definição 07: $(L, \leq)$ é um reticulado completo se, e somente se, qualquer subconjunto de L possuir um ínfimo e um supremo.

Definindo imagem como uma função $f: D_f \rightarrow E$, onde $E = \{0,1\}$ (imagem binária) ou $E = \{0, 1, \dots, N\}$ (imagens em tons de cinza), podemos dizer que o conjunto de todas as imagens provido da relação de ordem dada por:

$$f \leq g \Leftrightarrow \forall x \in D_f \cap D_g, f(x) \leq g(x)$$

é um conjunto parcialmente ordenado, mas não é totalmente ordenado. Porém, segundo Soille (2003), possui a propriedade importante que é a de ser um reticulado completo.

A partir das definições de supremo e ínfimo, são obtidas as definições dos operadores elementares do PMI: erosão e dilatação. Essa terminologia é usada porque a decomposição de qualquer operador pode ser feita em termos desses operadores (BANON e BARRERA, 1993).

Porém, antes de definir a erosão e a dilatação, é importante introduzir o conceito de elemento estruturante, que é a grande potencialidade do PMI.

2.3.2.2 Elemento Estruturante

Operadores morfológicos visam extrair estruturas relevantes da imagem, isto é alcançado através da sondagem na imagem utilizando um conjunto de forma conhecida, chamada elemento estruturante. A forma do elemento estruturante é geralmente escolhida de acordo com algum conhecimento a priori sobre a geometria das estruturas relevantes e irrelevantes presentes na imagem.


Ele é um conjunto completamente definido e conhecido (forma, tamanho e orientação), que é comparado, a partir de uma transformação, ao conjunto desconhecido da imagem. O resultado dessa transformação permite avaliar o conjunto desconhecido (FACON, 1996).

O elemento estruturante pode assumir várias formas e sua origem pode ser definida em qualquer ponto. Por isso o seu uso requer cautela, pois para obter resultados satisfatórios é necessário que a escolha do mesmo seja adequada. Segundo Goutsias e Heijmans (2000), a escolha do elemento estruturante mais apropriado depende principalmente

da aplicação a ser realizada. Assim, para selecionar o elemento estruturante mais adequado pode-se considerar a forma dos objetos, ou definir um tamanho específico e para alguns elementos estruturantes considera-se uma orientação (SOILLE, 2003).

O elemento estruturante percorre toda a cena (linha a linha e coluna a coluna), deslocando-se na imagem pixel a pixel. Nesse processo de deslocamento do elemento estruturante na imagem, o mesmo realiza algumas transformações com relação aos valores mínimos e máximos considerados na vizinhança do pixel analisado. O resultado dessa transformação é atribuído ao pixel correspondente da nova imagem. A Figura 20 exemplifica algumas configurações de elementos estruturantes.

Figura 20: Forma geométrica de alguns elementos estruturantes.



Na Figura 20, o elemento estruturante disco possui tamanho 9x9, o caixa 7x7, o cruz 5x5 e o linha 1x4. O tamanho do elemento estruturante define o número de vizinhos (representados pelos quadrados contendo um círculo branco) do pixel de origem, o pixel de origem está representado com o quadrado hachurado. Na maioria das vezes, o pixel de origem encontra-se no centro do elemento estruturante, porém dependendo do objetivo, a origem pode ser definida em qualquer posição dentro da janela do elemento estruturante, como é o caso do elemento linha mostrado na Figura 20. Em alguns casos, o centro podem não pertencer sequer ao elemento estruturante.

Nas próximas seções serão discutidas as transformações morfológicas elementares denominadas, erosão e dilatação, sobre imagens binárias e em nível de cinza. Pode-se afirmar que a MM binária é um caso particular da morfologia em tons de cinza.

2.3.2.3 Erosão

Definição 08: Segundo Soille (2003), a erosão de uma imagem f por um elemento estruturante B , denotada por $\varepsilon_B(f)$ é definida como o mínimo das translações de f pelos vetores $-b \in B$:


$$\varepsilon_B(f) = \bigwedge_{b \in B} f_{-b}. \quad (2)$$

O valor de $\varepsilon_B(f)$ em um pixel x é dado por:

$$[\varepsilon_B(f)](x) = \min_{b \in B} f(x+b). \quad (3)$$

Na Figura 21, é mostrado o efeito visual da aplicação do operador de erosão numa determinada imagem utilizando o elemento estruturante disco com 01 pixel de vizinhança, o qual equivale ao elemento estruturante caixa 3x3.


Figura 21: Resultado da aplicação do operador erosão binária.



Em geral, a erosão binária apresenta os seguintes efeitos em seus resultados: diminuição do tamanho de partículas; eliminação dos grãos de tamanho inferior ao tamanho do elemento estruturante; aumento dos buracos; e separação dos grãos próximos.

Um exemplo de erosão de imagem em níveis de cinza é mostrado na Figura 22.

Figura 22: Resultado da erosão de imagem em níveis de cinza. (a) imagem original
(b) imagem erodida.



Fonte: SDC Information Systems.

Como pode ser visto na Figura 22, os efeitos visuais da erosão em níveis de cinza são: escurecimento da imagem; alargamento e aumento dos padrões escuros; conexão dos padrões escuros próximos; redução ou eliminação dos padrões claros; e separação dos padrões claros próximos.

2.3.2.4 Dilatação

Definição 09: Segundo Soille (2003), a dilatação de uma imagem f por um elemento estruturante B , denotada por $\delta_B(f)$ é definida como o máximo das translações de f pelos vetores $b \in B$:


$$\delta_B(f) = \vee_{b \in B} f_b. \quad (4)$$

O valor de $\delta_B(f)$ em um pixel x é dado por:

$$[\delta_B(f)](x) = \max_{b \in B} f(x + b). \quad (5)$$

A Figura 23 ilustra o resultado da dilatação de uma imagem binária, utilizando um elemento estruturante disco de tamanho de raio 2 pixels.

Figura 23: Resultado da aplicação do operador dilatação em uma imagem binária.



Um exemplo numérico da dilatação binária utilizando o elemento estruturante cruz 3x3 é mostrado na Figura 24.

Figura 24: Exemplo numérico de dilatação binária.


<table style="border-collapse: collapse; margin: auto;"> <tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>1</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>0</td><td>1</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr> </table>	0	0	0	0	0	0	0	1	0	0	0	1	0	1	0	0	1	0	0	0	0	0	0	0	1	<table style="border-collapse: collapse; margin: auto;"> <tr><td>0</td><td>1</td><td>0</td></tr> <tr><td>1</td><td>1</td><td>1</td></tr> <tr><td>0</td><td>1</td><td>0</td></tr> </table> Elemento Estruturante	0	1	0	1	1	1	0	1	0	<table style="border-collapse: collapse; margin: auto;"> <tr><td>0</td><td>0</td><td>1</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>1</td><td>1</td><td>0</td></tr> <tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr> <tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr> <tr><td>0</td><td>1</td><td>0</td><td>1</td><td>1</td></tr> </table>	0	0	1	0	0	0	1	1	1	0	1	1	1	1	1	1	1	1	1	1	0	1	0	1	1
0	0	0	0	0																																																									
0	0	1	0	0																																																									
0	1	0	1	0																																																									
0	1	0	0	0																																																									
0	0	0	0	1																																																									
0	1	0																																																											
1	1	1																																																											
0	1	0																																																											
0	0	1	0	0																																																									
0	1	1	1	0																																																									
1	1	1	1	1																																																									
1	1	1	1	1																																																									
0	1	0	1	1																																																									
(a)		(b)																																																											

A aplicação desse operador produz os seguintes efeitos visuais na imagem: aumento do tamanho dos objetos da imagem; preenchimento de pequenos buracos; e conexão de objetos próximos.

Os efeitos visuais da dilatação em níveis de cinza são: clareamento da imagem; alargamento e aumento dos padrões claros; conexão dos padrões claros próximos; redução ou eliminação dos padrões escuros; separação dos padrões escuros próximos.

Um exemplo de dilatação de imagem em níveis de cinza é mostrado na Figura 25.

Figura 25: Resultado da dilatação de imagem em tons de cinza: a imagem original (a) e sua contraparte dilatada (b).



Fonte: SDC Information Systems.

Embora este trabalho vise tratar predominantemente imagens de Mercúrio, as figuras utilizadas para exemplificar os efeitos da erosão e dilatação, são imagens de Saturno somente pelo fato dela ser mais representativa.

Um exemplo numérico da dilatação em níveis de cinza é mostrado na Figura 26.

Figura 26: Exemplo numérico de dilatação.

10	134	53	68	245
32	19	137	170	5
80	104	57	43	16
43	22	224	39	145
77	100	255	157	13
(a)				

0	1	0
1	1	1
0	1	0
Elemento Estruturante		

134	134	137	245	245
80	137	170	170	245
104	104	224	170	145
80	224	255	224	145
77	255	255	255	157
(b)				

A Figura 26(a) representa uma matriz contendo os valores de intensidade de uma imagem em níveis de cinza, enquanto que a Figura 26(b) apresenta o resultado da dilatação de (a) pelo elemento estruturante cruz, com origem no centro.

Na maioria dos casos, quando aplicados isoladamente os operadores dilatação e erosão, eles não evidenciam características das imagens, entretanto, eles são a base para a construção de funções importantes, como por exemplo, o gradiente morfológico, o fechamento, a abertura, a segmentação etc.

A erosão e a dilatação podem corrigir defeitos em uma imagem relacionados com filtragem, tais como ruídos e conexões. Porém, nenhum conjunto processado por essas operações mantém o mesmo tamanho, pois a erosão reduz e a dilatação aumenta. Entretanto, por meio da abertura e do fechamento é possível filtrar modificando “pouco” as características de forma e tamanho dos conjuntos relevantes.

2.3.2.5 Abertura

Definição 08. A abertura de uma imagem f por um elemento estruturante B é definida como a erosão de f por B , seguida da dilatação com o elemento estruturante, B , (SOILLE, 2003):

$$\gamma_B(f) = \delta_B[\varepsilon_B(f)]. \quad (6)$$

onde: γ_B representa a abertura;

B o elemento estruturante;


f a imagem original;

δ_B a dilatação com o elemento estruturante B ;

ε_B é a erosão com o elemento estruturante B .

A Figura 27 exibe um exemplo de abertura de um conjunto X por um elemento estruturante disco 3x3, com origem no centro.

Figura 27: Resultado da abertura de um conjunto X por um disco 3 x 3.



Alguns efeitos de visualização ocasionados pela abertura são: não devolve, de forma geral, o conjunto inicial; nivela os contornos pelo interior; separa as partículas; elimina as pequenas partículas inferiores em tamanho em relação ao elemento estruturante; as entidades restantes após a abertura ficam quase idênticas às originais; o conjunto aberto é mais regular que o conjunto inicial; e o conjunto aberto é menos rico em detalhes que o conjunto inicial.

2.3.2.6 Fechamento

De acordo com Soille (2003), a ideia por trás do fechamento morfológico é a construção de um operador tendendo a recuperar a forma inicial das estruturas da imagem que tem sido dilatada, isto é alcançado erodindo a imagem dilatada.

Definição 09. O fechamento da imagem f pelo elemento estruturante B , segundo Soille (2003), é definido como a dilatação de f com o elemento estruturante B seguido da erosão com elemento estruturante transposto $\tilde{B}$:

$$\phi_B(f) = \varepsilon_{\tilde{B}}[\delta_B(f)]. \quad (7)$$

onde: ϕ_B representa o fechamento;

B o elemento estruturante;

f a imagem original;


$\varepsilon_{\tilde{B}}$ a erosão com o elemento estruturante B transposto;

δ_B é a dilatação com o elemento estruturante B .

Os efeitos do fechamento morfológico são: suaviza as fronteiras pelo exterior; preenche os buracos no interior das partículas inferior em tamanho em relação ao elemento estruturante; emenda partículas próximas; o conjunto fechado é mais regular que o conjunto inicial; e o conjunto fechado é menos rico em detalhes que o conjunto inicial.

A Figura 28 ilustra o fechamento de um conjunto X por um elemento estruturante disco 7×7 .

Figura 28: Resultado do fechamento de um conjunto X por um disco 7 x 7.



2.3.2.7 Top-hats


As propriedades de aberturas e fechamentos podem ser exploradas na construção de operadores morfológicos por subtração conhecidos por *top-hats*. Uma abertura ou fechamento remove as estruturas da imagem que não contém o elemento estruturante. Essas estruturas são recuperadas através da diferença aritmética entre a imagem original e sua abertura ou entre o fechamento e a imagem original.

Definição 10: Seja f uma imagem binária ou em tons de cinza e $\gamma_B(f)$ sua abertura. O *top-hat* por abertura de f , também chamado de *White Top-Hat*, é a diferença entre a imagem original, f , e sua abertura $\gamma_B(f)$ (SOILLE, 2003):

$$WTH(f) = f - \gamma_B(f). \quad (8)$$

Como aberturas são anti-extensivas, os valores de $WTH(f)$ são sempre maiores que zero.

Figura 29: Exemplo do funcionamento do top-hat por abertura em um sinal unidimensional.



Fonte: adaptado de Soille (2003).

Definição 11: A transformação dual do *top-hat* por abertura é o *Black Top-Hat*, BTH, e é definido como a diferença entre o fechamento da imagem original, $\phi_B(f)$, e a imagem original (SOILLE, 2003):

$$BTH(f) = \phi_B(f) - f. \quad (9)$$

Figura 30: Exemplo do *top-hat* por fechamento em um sinal unidimensional.



Fonte: adaptado de Soille (2003).

2.3.3 Momentos

Os momentos de uma imagem permitem descrever informações relevantes da imagem. Os momentos e as funções derivadas deles se caracterizam por valores numéricos calculados a partir da imagem previamente segmentada e que descrevem a distribuição espacial dos pontos contidos nela ou em uma região específica. Dada uma imagem f de

tamanho $M \times N$, os momentos são calculados como mostra a Equação 10 (GONZALEZ e WOODS, 2010):

$$m_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} x^p y^q f(x, y), \quad (10)$$

onde m_{pq} é o momento de ordem $(p+q)$ da imagem f .

O momento central correspondente de ordem $(p+q)$ é definido como:

$$\mu_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (x - \bar{x})^p (y - \bar{y})^q f(x, y), \quad (11)$$

Onde $\bar{x}$ e $\bar{y}$ são definidos em função dos momentos regulares de ordem 0 e 1, os quais permitem o cálculo do centro de massa do objeto. Esses valores são definidos como segue:

$$\bar{x} = \frac{m_{10}}{m_{00}} \text{ e } \bar{y} = \frac{m_{01}}{m_{00}}. \quad (12)$$

Os momentos centrais são definidos como

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma}, \quad (13)$$

sendo

$$\gamma = \frac{p+q}{2} + 1. \quad (14)$$

As ordens mais baixas representam algumas propriedades geométricas fundamentais de um corpo. Por exemplo, o momento M_{00} de uma $f(x, y)$ representa a massa total da imagem. Isso pode ser facilmente visto por meio do cálculo do M_{00} a partir da Equação 10:

$$M_{00} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y). \quad (15)$$

Os momentos de primeira ordem, M_{10} e M_{01} , são usados para localizar o centro de massa de um objeto. As coordenadas $\bar{x}$ e $\bar{y}$ representam as linhas onde todas as massas podem ser concentradas.

Os momentos de segunda ordem, M_{02} , M_{11} , M_{20} , também são chamados de momentos de inércia e podem ser usados para determinar algumas características relevantes dos objetos, tais como, a orientação das feições e os eixos principais de um objeto (PROKOP, 1992).

Os momentos de terceira ordem descrevem a assimetria em relação do centro da imagem.

Com base nos momentos da imagem, Hu (1962) propôs uma combinação de momentos de modo que fosse invariante à escala, à rotação e à translação. Esses momentos são chamados de momentos invariantes ou momentos de Hu, e são definidos a seguir:

$$\phi_1 = \eta_{20} + \eta_{02}, \quad (16)$$

$$\phi_2 = (\eta_{20} + \eta_{02})^2 + 4\eta_{11}^2, \quad (17)$$

$$\phi_3 = (\eta_{30} + 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \quad (18)$$

$$\phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} - \eta_{03})^2, \quad (19)$$


$$\phi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{12} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \quad (20)$$

$$\phi_6 = (\eta_{20} + \eta_{02})[(\eta_{30} - \eta_{12})^2 - (\eta_{21} - \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}), \quad (21)$$

$$\phi_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} - \eta_{03})^2] + (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]. \quad (22)$$

A Figura 31 apresenta alguns exemplos da aplicação da técnica de momentos de Hu para cálculo de informações que permitem comparar objetos. A Figura 31(a) apresenta uma imagem de uma meia lua, e as três imagens seguintes representam variações dessa imagem, sendo (b) a imagem original redimensionada por 0,5 e transladada, (c) a imagem original rotacionada em 45°, (d) a imagem original redimensionada por 0,5, rotacionada em 180° e translada, (e) um círculo e (f) uma curva.

Figura 31: (a) Imagem original, (b) redimensionada e transladada, (c) rotacionada em 45°, (d) redimensionada transladada e rotacionada em 180°; (e) Círculo e (f) curva.



A Tabela 1 apresenta os valores dos momentos de Hu para cada imagem. Para simplificar a interpretação, os valores apresentados correspondem ao $\sin(\phi_i) \log(|\phi_i|)$. O que é importante observar na Tabela 1 é a invariância dos valores obtidos mediante as variações dos objetos quanto à rotação, translação e redimensão dos objetos.

Tabela 1: Momentos invariantes das imagens apresentadas da Figura 29.

Momentos Imagem	ϕ_1	ϕ_2	ϕ_3	ϕ_4	ϕ_5	ϕ_6	ϕ_7
Original	2,9589	6,2572	9,3164	10,2730	-20,0698	-13,4027	21,0760
Reduzida	2,9587	6,2571	9,3161	10,2726	-20,0691	-13,4022	21,0738
Reduzida e rotacionada 45°	2,9582	6,2549	9,3154	10,2705	-20,0664	-13,3995	21,0061
Reduzida e rotacionada 180°	2,9589	6,2572	9,3164	10,2730	-20,0698	-13,4027	21,0760
Círculo	3,2035	8,6700	17,2701	20,1566	-40,0314	-25,4693	38,8710
Linha	1,6149	3,2486	6,9213	7,7994	-15,8748	-9,8725	15,1680

2.3.4 Filtro de Suavização

Entende-se por realce o processamento que vai melhorar uma imagem de acordo com alguma finalidade específica, isto é, se a finalidade for análise visual, o realce auxiliará na melhora visual da imagem; se a finalidade for análise computacional, realçará as feições de interesse a serem extraídas (GONZALEZ e WOODS, 2010).

Existem diversos filtros para realce de imagens, o que se mostrou mais adequado a este trabalho foi o bilateral.

2.3.4.1 Filtro bilateral

O filtro bilateral foi proposto originalmente por Tomasi e Manduchi em 1998, como uma ferramenta para remoção de ruídos. Esse filtro possui a característica de remover ruídos preservando as bordas dos objetos da imagem.

O filtro bilateral considera a soma ponderada dos pixels na vizinhança de um local, sendo os pesos dependentes tanto da distância espacial, quanto da distância da intensidade. Desta forma, as bordas são bem preservadas, enquanto o ruído é eliminado. Matematicamente, isso é feito da seguinte maneira (ZHANG, 2009):

$$\tilde{I}(X) = \frac{1}{C} \sum_{y \in N(x)} e^{\frac{-\|y-x\|}{2\sigma_d^2}} e^{\frac{-\|I(y)-I(x)\|^2}{2\sigma_r^2}} I(y). \quad (23)$$

Onde σ_d e σ_r são os parâmetros que controlam o peso no domínio espacial e de intensidade, respectivamente, $N(x)$ é uma vizinhança espacial de $I(x)$, e C a constante de normalização representada pela seguinte expressão:


$$C = \sum_{y \in N(x)} e^{\frac{-\|y-x\|}{2\sigma_d^2}} e^{\frac{-\|I(y)-I(x)\|^2}{2\sigma_r^2}}. \quad (24)$$

2.3.4.2 Max-tree

Max-tree é uma ferramenta que pode ser usada tanto para segmentação de imagens, quanto para filtragem. Essa ferramenta consiste da representação de uma imagem em níveis de cinza que contém informações sobre os componentes da imagem e relaciona esses componentes em uma sequência de níveis de cinza da imagem. Desta forma, constrói-se uma estrutura hierárquica de regiões baseada no relevo formado pela decomposição por limiares de uma imagem em níveis de cinza (SILVA, 2009).

Max-tree é definida como um conjunto de nós conectados por um conjunto de bordas, onde cada nó representa um componente particular do nível de cinza da imagem. O nó é uma representação abstrata de um conjunto de pixels na imagem que possuem os mesmos valores de níveis de cinza. A Figura 32(c) mostra um exemplo de uma imagem em níveis de cinza e a Figura 32(b) apresenta uma representação, em nós, da relação dos componentes baseada na decomposição por limiares dos níveis de cinza.

Figura 32: Exemplo de construção de Max-tree. (a) Superfície topográfica da imagem I ; (b) árvore dos componentes conectados; (c) Imagem I e sua decomposição baseada nos limiares n .



Fonte: adaptado de Jones (1999).

Na Figura 32, cada componente da imagem possui um nó correspondente, o qual o relaciona a outros componentes com diferentes níveis de cinza. Fazendo uma analogia da Figura 32 com uma estrutura de árvore, a Imagem I apresentada na Figura 32(c) representa

uma imagem em níveis de cinza e sua decomposição com base nos limiares n , (a) corresponde a sua superfície topográfica, (b) uma representação, em nós, da relação dos componentes baseada na decomposição por limiares dos níveis de cinza, onde a raiz representa os pixels correspondentes ao fundo da imagem e as folhas seriam os últimos nós da árvore de componentes. As setas entre os nós correspondem às bordas da região ou do objeto (JONES, 1999).

De acordo com Salembier (1998), o processo de filtragem realizado pela Max-tree consiste de três passos. O primeiro passo é a criação da árvore de componentes, onde os pixels são estruturados de uma forma que facilite o processo de filtragem. O segundo passo consiste do processo de filtragem, onde cada nó é analisado e é realizada a decisão de qual nó deve ser removido e qual deve ser preservado. O terceiro e último passo consiste da restauração da imagem filtrada, que se dá pela transformação da saída da Max-tree em uma imagem em níveis de cinza.

O processo de filtragem é baseado no valor de atributo $\tau(P_h^k)$ de um nó N_h^k , a partir desses dois valores o algoritmo decide se preserva ou se mantém um determinado nó.

Definição: Dado um critério T em um subconjunto de E associado a τ quando $T(X) = \rho(\tau(X))$ com $\rho: \mathbb{R} \rightarrow \{false, true\} \forall X \subseteq E$.

Um exemplo frequentemente utilizado é fornecer um valor qualquer escalar como critério.


2.3.5 Características de Haar-like

As características *Haar-like* permitem a extração da característica de um objeto, de acordo com uma forma definida. Esse método foi primeiramente motivado por Papageorgiou *et al.* (1998) e posteriormente proposto por Viola e Jones (2001) no contexto de detecção de faces em imagens. Viola e Jones (2001) propuseram o uso da característica Haar-like ao invés das intensidades de cor de uma imagem para melhorar a análise da forma de um objeto. O método proposto extrai as características a partir de máscaras retangulares, apresentadas na

Figura 33. Essas máscaras percorrem blocos da imagem calculando a soma das intensidades das regiões correspondentes às áreas definidas pelos retângulos, isto é, efetua-se

a soma de todos os pixels correspondentes à área definida pela parte branca da máscara retangular, e a soma dos pixels da região correspondente à área definida pela parte preta da máscara retangular. A definição da característica do bloco da imagem analisado é dada pela diferença entre as somas das regiões definidas pela parte preta e pela parte branca do retângulo.

Figura 33: Máscaras propostas por Viola e Jones para extração das características das imagens.



Viola e Jones (2001) propuseram o uso da imagem integral para acelerar o cálculo das características. Na imagem integral, cada ponto (x, y) da imagem contém o somatório dos pixels da origem da imagem até a localização (x, y) , isto é, o valor da imagem integral I no ponto (x, y) , é a soma das intensidades de todos os pixels das imagens O acima e a esquerda de (x', y') , como representado na Equação 25:

$$I(x, y) = \sum_{x' \leq x, y' \leq y} O(x', y'). \quad (25)$$

onde $I(x, y)$ é a imagem integral e $O(x, y)$ é a imagem original.

Por meio da imagem integral a soma de qualquer retângulo pode ser calculada a partir de quatro pontos de referência, como mostrado na seção 3.3.3.

2.3.6 Aprendizado de Máquina

Técnicas de aprendizagem de máquina empregam um princípio de inferência denominado indução, no qual se obtém conclusões genéricas a partir de um conjunto particular de exemplos. Esse aprendizado pode ser dividido em dois tipos principais: supervisionado e não supervisionado.

No aprendizado supervisionado tem-se a necessidade da presença de um professor externo, o qual ensina o algoritmo por meio de um conjunto formado por exemplos que

representam as entradas e as saídas desejadas. O algoritmo utiliza os exemplos fornecidos para gerar uma representação dos conhecimentos, a qual seja capaz de produzir saídas corretas para novas entradas não apresentadas previamente.

No caso do aprendizado não supervisionado, não há a presença de um professor externo, neste caso o objetivo é encontrar conjuntos padrões ou tendências que auxiliem o entendimento desses dados.

2.3.6.1 Máquinas de Vetores de Suporte

Máquinas de Vetores de Suporte (SVMs, do inglês *Support Vector Machine*) é uma técnica de classificação inserida no contexto de aprendizagem supervisionada. Neste caso, o algoritmo constrói um classificador capaz de rotular novos dados com base no que lhe foi apresentado no conjunto de treinamento.


Matematicamente, dado um conjunto de exemplos rotulados na forma (X, Y) , em que X corresponde às características de um elemento do conjunto de treino e Y representa o seu respectivo rótulo, o objetivo é produzir um classificador, o qual pode ser representado por uma função f , que ao receber um novo x possa predizer com precisão o seu rótulo y .

Os rótulos, ou classes, representam o fenômeno de interesse sobre o qual se deseja fazer as previsões. Cada exemplo é tipicamente representado por um vetor de características, também denominada de atributo (MONARD e BARANAUSKAS, 2003).

Para que seja possível estimar as taxas de acerto e de erro obtidas por um classificador, o conjunto de dados é, geralmente, dividido em dois subconjuntos: o subconjunto de treino e o subconjunto de teste. O subconjunto de treino é utilizado no aprendizado do conceito e o subconjunto de teste é utilizado para medir o grau de efetividade do conceito aprendido na predição da classe de novos dados.

O princípio base das SVM é definir uma margem máxima entre dois conjuntos de dados. A Figura 34 apresenta um exemplo, no qual diversas retas são capazes de separar dois conjuntos de dados. Entretanto, apenas uma reta está localizada a uma mesma distância dos dois conjuntos, ou melhor, a uma mesma distância dos dados mais próximos de cada conjunto. A reta que possui essa característica está destacada em verde e representa o objetivo do SVM.

Figura 34: Exemplo de conjuntos separáveis por retas.



A Figura 34 apresenta um caso simples, em que os dados são linearmente separáveis, onde é possível a obtenção de um hiperplano que define uma margem entre as classes de dados. Neste caso, utiliza-se as SVMs com margens rígidas. Porém, na prática é comum a existência de problemas cujos dados apresentam ruídos ou *outliers*, ou situações em que os dados não são linearmente separáveis. Para esses casos, existem as SVMs com margem suave e as SVMs não lineares, respectivamente.

2.3.6.2 SVMs com Margens Rígidas

As SVMs com margens rígidas definem fronteiras lineares entre dados linearmente separáveis (CAMPBELL, 2000). Consideremos um conjunto de treinamento T formado por n dados, mostrado na Figura 35. Os dados pertencentes a T são da forma (X,Y) , em que X constitui o espaço de dados e é formado pelos vetores $x_i, i = 1, \dots, n, x_i \in \mathbb{R}^n$, e Y representa as classes, sendo formado pelos vetores $y_i \in \{-1, 1\}$. Os pontos x_1 e x_2 são dois exemplos que representam a composição dos dados, no caso de x_1 , (8,4) correspondem às coordenadas e 1 a sua classe, da mesma forma que no caso de x_2 , (5, 2,5) representam as coordenadas e -1 a classe. Desta forma, cada dado é representado por (x_i, y_i) , onde x_i é o vetor de entrada e y_i é a classificação desejada. O conjunto de dados T é linearmente separável, se é possível separar os dados das classes +1 e -1 por um hiperplano.

Um hiperplano pode ser representado pela Equação 26:

$$w \cdot x + b = 0. \quad (26)$$

Onde, $w \cdot x$ é o produto escalar entre os vetores w e x , $w \in \mathbb{R}^n$ é o vetor normal ao hiperplano descrito, $b/\|w\|$ corresponde à distância perpendicular do hiperplano em relação à origem, com $b \in \mathbb{R}$ e $\|w\|$ a norma euclidiana de w .


Os pontos que satisfazem a Equação 26 são os pontos x_i que tocam o hiperplano. A Equação 26 pode ser formulada nas seguintes condições:

$$x_i \cdot w + b \geq +1 \text{ para } y_i = +1, \quad (27)$$

$$x_i \cdot w + b \leq -1 \text{ para } y_i = -1. \quad (28)$$

As Equações 27 e 28 dividem o espaço dos dados em duas regiões. Se essa região entre as duas classes de dados representa a distância máxima entre os pontos mais próximos das classes de dados, essa região é definida como hiperplano ótimo. Os pontos pertencentes às margens máximas carregam informações relevantes sobre o problema de classificação, tais vetores são chamados de vetores de suporte. A Figura 35 mostra o hiperplano de separação ótimo com a margem maximizada e os pontos que estão em destaque representam os vetores de suporte.

Figura 35: Hiperplano de separação para o caso linearmente separável.



Fonte: Adaptado de Hearst et al. (1998).

No exemplo mostrado na Figura 35, o ponto x_1 satisfaz o hiperplano H_1 e o ponto x_2 satisfaz o hiperplano H_2 .

As inequações 27 e 28 podem ser combinadas e reescritas em uma única:

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall (x_i, y_i) \in T \quad (29)$$

Seja x_1 um ponto no hiperplano $H_1: w \cdot x + b = +1$ e x_2 um ponto no hiperplano $H_2: w \cdot x + b = -1$, conforme ilustrado na Figura 35. Consideremos que o ponto x_1 seja o ponto mais próximo de x_2 . A distância entre os hiperplanos H_1 e H_2 pode ser obtida pela diferença de $w \cdot x_1 + b = +1$ e $w \cdot x_2 + b = -1$, que resulta em:

$$x_1 = x_2 + \lambda w. \quad (30)$$

Substituindo o valor de x_1 em H_1 , temos:

$$w \cdot (x_2 + \lambda w) + b = 1. \quad (31)$$

$$w \cdot x_2 + b + \lambda \cdot \|w\|^2 = 1 \Rightarrow \lambda = \frac{2}{\|w\|^2}. \quad (32)$$

O interesse é a margem, isto é:

$$\|x_1 - x_2\| = \|\lambda w\| = \lambda \|w\| = \frac{2}{\|w\|^2} \|w\| = \frac{2}{\|w\|}. \quad (33)$$

A Equação 33 corresponde a distância d , ilustrada na Figura 35, entre os hiperplanos H_1 e H_2 , paralelos ao hiperplano separador.

A partir das considerações anteriores, verifica-se que a maximização da margem de separação dos dados em relação a $w \cdot x + b = 0$ pode ser obtida pela minimização de $\|w\|$ (BURGES, 1998). Desta forma, recorre-se ao seguinte problema de otimização (SMOLA e SCHOLKOPF, 2002):

Minimizar

$$\underset{w, b}{\text{Minimizar}} \frac{1}{2} \|w\|^2. \quad (34)$$

Com as restrições: $y_i(w \cdot x_i + b) - 1 \geq 0, \forall i = 1, \dots, n$ (35)

As restrições são impostas de maneira a assegurar que não haja dados de treinamento entre as margens de separação das classes. Assim, a SVM obtida é definida como SVM com margens rígidas.

Esse problema de otimização é quadrático e como a função objetivo é convexa (um conjunto de pontos é dito convexo se, dados quaisquer dois pontos no conjunto, o segmento de reta que os conecta também está no conjunto) e os pontos que satisfazem as restrições formam um conjunto convexo, esse problema possui um único mínimo global (PASSERINI, 2004). Um método utilizado na procura de máximos e mínimos condicionados é o método de Lagrange.

Em problemas restritos, é necessário definir a função de Lagrange, a qual possui informações sobre a função objetivo e as restrições. A função de Lagrange é definida através da soma da função objetivo com uma combinação linear das restrições, em que os coeficientes da combinação são chamados de multiplicadores de Lagrange, os quais são determinados no transcorrer da solução (SMOLA e SCHÖLKOPF, 2002).

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i (y_i (w \cdot x_i + b) - 1). \quad (36)$$

Para a função Lagrangiana ser minimizada, deve-se maximizar as variáveis e minimizar w e b (MÜLLER *et al.*, 2001). Isto é:

$$\frac{\partial}{\partial b} L(w, b, \alpha) = 0, \frac{\partial}{\partial w} L(w, b, \alpha) = 0. \quad (37)$$

A resolução dessas equações conduz aos resultados apresentados nas Equações 38 e 39:

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (38)$$

$$w = \sum_{i=1}^n \alpha_i y_i x_i . \quad (39)$$

Substituindo as Equações 38 e 39 na Equação 36, temos o seguinte problema de otimização:

$$\text{Maximizar}_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) . \quad (40)$$

$$\text{Com as restrições: } \begin{cases} \alpha_i \geq 0, \forall i = 1, \dots, n \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases}$$

Essa formulação é denominada forma dual. Para resolver um problema dual utiliza-se a teoria de Lagrange por meio do acréscimo das restrições primais à função de custo primal, utilizando os multiplicadores de Lagrange.

Seja α^* a solução do problema dual e w^* e b^* as soluções da forma primal. Obtido o valor de α^* , w^* pode ser determinado pela Equação 39. O parâmetro b^* é definido por α^* e por condições de Kuhn-Tucker, provenientes da teoria de otimização com restrições e que devem ser satisfeitas no ponto ótimo. Tem-se a formulação do problema dual representado na Equação 41 (PONTIL e VERRI, 1998):

$$\alpha_i^* (y_i (w^* \cdot x_i + b^*) - 1) = 0, \quad \forall i = 1, \dots, n . \quad (41)$$

Pela Equação 41, nota-se que α^* pode ser diferente de zero somente para os dados que se encontram sobre os hiperplanos H_1 e H_2 , ou seja, α^* representa os exemplos que estão mais próximos do hiperplano separador (exemplos que estão exatamente sobre as margens), isto é, os vetores de suporte, os quais determinam a equação do hiperplano separador (BURGES, 1998). Para os outros exemplos, a condição da Equação 41 é válida apenas com $\alpha^* = 0$.

O valor de b^* pode ser calculado a partir dos vetores de suporte e das condições representadas na Equação 41 (SMOLA e SCHOLKOPF, 2002). Uma generalização para o cálculo de b^* é apresentada na Equação 42.

$$b^* = \frac{1}{nsv} \sum_{x_j \in SV} \frac{1}{y_j} - w^* \cdot x_j. \quad (42)$$

Onde, nsv é o número de vetores de suporte e sv representa o conjunto dos SVs.

De acordo com w^* , definido pela Equação 39, e b^* pela Equação 42, temos a Equação 43 que representa o classificador, isto é, uma função linear que separa os dados de forma a determinar a maior margem.

$$g(x) = \text{sgn}\left(\sum_{x_i \in SV} y_i \alpha_i^* x_i \cdot x + b^*\right). \quad (43)$$

Nem todo problema é linearmente separável. Existem situações em que há a presença de ruídos e *outliers* nos dados ou a própria natureza do problema pode ser não linear. Para esses casos, existem as SVMs com margens suaves e as SVMs não lineares, respectivamente.

2.3.6.3 SVMs com Margens Suaves

As SVMs com margens suaves representam uma extensão das SVMs com margens rígidas. Neste caso, acrescenta-se uma variável de folga às Equações 27 e 28, com o objetivo de tornar o problema flexível em relação a restrição imposta (SMOLA e SCHÖLKOPF, 2002):


$$x_i \cdot w + b \geq +1 - \xi_i \text{ para } y_i = +1 \quad (44)$$

$$x_i \cdot w + b \leq -1 + \xi_i \text{ para } y_i = -1 \quad (45)$$

$$\xi_i \geq 0 \quad \forall i. \quad (46)$$

A introdução de uma variável de folga suaviza as margens do classificador e permite que haja dados entre os hiperplanos H_1 e H_2 , bem como a presença de alguns erros de classificação.

Figura 36: Hiperplano de separação para o caso linearmente não separável.



A soma dos erros representa um limite no número de erros de treinamento (BURGES, 1998). Neste caso, é importante que esse erro seja mínimo, assim, a função objetivo definida na Equação 34 pode ser reformulada da seguinte maneira:

$$\underset{w, b, \xi}{\text{Minimizar}} \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^n \xi_i \right), \quad (47)$$

Onde, C é uma constante de regularização que atua como um termo que previne que *outliers* afetem o hiperplano ótimo (KWONG e GONG, 1999).

De acordo com a Equação 47, tem-se novamente um problema de otimização quadrático, com as restrições lineares apresentadas na Equação 44 e 45. Desta forma, tem-se novamente um problema dual, que pode ser resolvido conforme apresentado anteriormente, por meio da introdução de uma função Lagrangiana e tornando as suas derivadas parciais nulas. Considerando essas alterações temos o seguinte problema:

$$\underset{\alpha}{\text{Maximizar}} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (48)$$

$$\text{Com as restrições: } \begin{cases} 0 \leq \alpha_i \leq C, \quad \forall i = 1, \dots, n \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (49)$$

O que diferencia essa formulação da formulação anterior, é que nesta, os α_i são limitados pelo valor de C .

O valor de b é obtido similarmente ao procedimento anterior, mas para esse caso específico as condições KKT (Kuhn-Tucker) são definidas por:

$$\alpha_i^* (y_i (w^* \cdot x_i + b^*) - 1 + \xi_i^*) = 0, \quad (50)$$

$$(C - \alpha_i^*) \xi_i^* = 0. \quad (51)$$

A diferença entre a Equação 41 e a Equação 50, é a substituição do termo -1 por $-1 + \xi_i$. Como nas SVMs com margens rígidas, os pontos x_i para os quais $\alpha_i > 0$ são denominados vetores de suporte (VS). Entretanto, neste caso, há alguns tipos de VSs:


Caso 1: Se $\alpha_i < C$, pela Equação 51, $\xi_i = 0$ então, da Equação 50, estes SVs encontram-se sobre as margens e também são denominados livres.

Caso 2: Se $\alpha_i = C$, podem ocorrer três situações. Se $\xi_i > 1$, significa que há presença de erros. Se $0 < \xi_i \leq 1$, os pontos são corretamente classificados, porém entre as margens. E se $\xi_i = 0$, pontos sobre as margens.

2.3.6.4 SVMs não lineares

Quando a função de decisão é não linear, os dados do espaço de entrada são mapeados em um espaço de maior dimensão, denominado espaço de características.

Figura 37: Hiperplano de separação para o caso não linear.



Fonte: Rebelo (2008).

O teorema de Cover diz que considerando um espaço de entrada em que o conjunto de dados é não linear, esse espaço pode ser transformado em um novo espaço de características, onde os padrões são linearmente separáveis com alta probabilidade (HAYKIN, 1999). Para tanto, duas condições devem ser satisfeitas: a transformação deve ser não linear e a dimensão do espaço de características deve ser de ordem superior com relação à dimensão do espaço de entrada.

O mapeamento dos dados em um espaço Euclidiano H será chamado de ϕ :

$$\phi: \mathbb{R}^d \rightarrow H. \quad (52)$$

Desta forma, o algoritmo de treino depende somente do produto escalar em H da forma $\phi(x_i) \cdot \phi(x_j)$. Há uma restrição no produto escalar se o número de vetores de suporte for muito grande e considerando que ϕ não é conhecido a priori, o teorema de Mercer para funções definidas positivas permite substituir $\phi(x_i) \cdot \phi(x_j)$ por uma função kernel simétrica positiva $k(x_i, x_j)$ e $\phi(x_i)$ não precisa ser conhecido desde que isto esteja implicitamente definido pela escolha do kernel $k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$.

Na prática, alguns dos Kernels mais utilizados são: os polinomiais, os gaussianos ou RBF (*Radial-Basis Function*) e os sigmoidais.

Neste trabalho, utilizou-se os Kernels RBF, os quais possuem a representação apresentada na Equação 53 (SCHOLKOPF *et al.*, 1999):

$$K(x, x_i) = e^{\frac{-\|x - x_i\|^2}{2\sigma^2}}. \quad (53)$$

2.3.7 Métricas Quantitativas e Qualitativas para Avaliação de Desempenho

Existem diversos tipos de métricas para medir o desempenho de algoritmos de classificação. Dentre elas, uma muito citada na literatura foi apresentada primeiramente por Shufelt e McKeown (1993). Eles propuseram as métricas para avaliação quantitativa e qualitativa, originalmente pensada para trabalhos de detecção de prédios. Tal métrica é apresentada a seguir:

Percentual de detecção (D):
$$D = \frac{TP}{TP + FN} * 100 . \quad (54)$$

Fator de ramificação ou *Branching Factor* (B):
$$B = \frac{FP}{TP} . \quad (55)$$

Percentual de qualidade (Q):
$$Q = \frac{TP}{TP + FN + FP} * 100 . \quad (56)$$

As definições das métricas são apresentadas a seguir:

TP (*True Positive* ou Verdadeiros Positivos): ambos os conjuntos de dados (crateras detectadas e conjunto de dados de comparação) classificam o pixel como sendo parte de uma cratera;

FP (*False Positive* ou Falsos Positivos): o conjunto de dados detectados classifica o pixel como parte de uma cratera, enquanto o conjunto de dados de comparação o classifica como fundo;

FN (*False Negative* ou Falsos Negativos): o conjunto de dados detectados classifica o pixel como fundo, enquanto o conjunto de dados de comparação o classifica como parte de uma cratera.

3 MATERIAIS E MÉTODO

3.1 Materiais

Para o desenvolvimento deste trabalho foram necessários os seguintes materiais:


- ✓ Microcomputador;
- ✓ Software Matlab R2011b, versão 7.13.0;
- ✓ Software ISIS;
- ✓ Caixa de ferramentas de Morfologia Matemática, *SDC Morphology Toolbox for Matlab*, versão 1.6;
- ✓ Libsvm;
- ✓ Arcmap 10.2.2;
- ✓ CraterTools;
- ✓ Imagens orbitais NAC da superfície de Mercúrio.

3.2 Seleção das imagens

A superfície de Mercúrio contém a maior população de protobacias e bacias *peak-ring* do sistema solar (BAKER, 2011). Desta forma, o critério inicial para seleção das áreas teste foi a busca por regiões que fossem de maior interesse para a comunidade científica e que dispusesse de imagens que cobrissem toda a região. Com base nisso, foram escolhidas três bacias *multi-rings*: Rachmaninoff, Raditladi e Mozart. Como pode ser notado, as três crateras possuem nomes de artistas e esses nomes foram estabelecidos pela IAU (*International Astronomical Union*), uma organização que dentre outras, possui a responsabilidade de definir a nomenclatura das feições de superfícies planetárias. Para Mercúrio, definiu-se que crateras teriam o nome de artistas falecidos, tais como, músicos, pintores e autores que tenham contribuído de forma notável no seu campo e tenham sido reconhecidos como figuras significantes há mais de 50 anos. Outras feições têm sido nomeadas de forma semelhantes, como por exemplo, os vales que recebem nomes de cidades abandonadas e os montes que são nomeados com a palavra “quente” em várias línguas. O nome das feições de Mercúrio e de outros planetas pode ser consultado em IAU - *Gazetteer of Planetary Nomenclature*.

A busca das imagens foi feita por meio do banco de dados PILOT (do inglês, *Planetary Image Locator Tool*), uma ferramenta de pesquisa *web-based open-source* que utiliza o banco de dados UPC (do inglês, *Unified Planetary Coordinate*) para acessar os catálogos de imagens contidos no sistema planetário da NASA, PDS (do inglês, *Planetary Data System*).

Figura 38: Regiões selecionadas para teste do algoritmo. Bacias Multi-rings Rachmaninoff, Raditladi e Mozart.



Fonte: disponível em < <http://pilot.wr.usgs.gov/>>.

Tabela 2: Informações sobre as áreas selecionadas.

Nome	Diâmetro (km)	Latitude	Longitude	Quantidade de imagens
Rachmaninoff	292	27,67	57,52	37
Raditladi	263	27,05	119,05	12
Mozart	236	08,68	169,64	06

A bacia Rachmaninoff foi completamente imageada pela primeira vez durante o terceiro sobrevoo da Messenger em 2009. Ela recebeu o nome do compositor, pianista e maestro russo, Sergei Rachmaninoff. É possível notar, na Figura 39, os restos de um anel interior formado por picos. O chão da cratera contém um número elevado de regiões com material de alta refletância, bem como vales poligonais chamados de *grabens*, que são

estruturas de abatimento gravitacional formadas pela força da tração para além da superfície e podem estar relacionadas ao resfriamento das planícies vulcânicas lisas que cobrem o chão (PROCKTER *et al.*, 2010).


A bacia Raditladi, que recebeu o nome do dramaturgo e poeta africano, Leetile Disang Raditladi, é uma bacia relativamente nova, com poucas crateras de impacto no seu interior de pequenas dimensões. As suas paredes e a estrutura *peak-ring* são bem preservadas. Depressões concêntricas são visíveis no chão da bacia, formadas pela extensão da superfície. O entendimento de como essas depressões são formadas poderia fornecer um importante indicador dos processos relativamente recentes na história geológica de Mercúrio (PROCKTER *et al.*, 2009).

A bacia Mozart foi imageada pela primeira vez pela Mariner 10 em 1974, porém a angulação solar no momento da aquisição das imagens não foi favorável, fazendo com que grande parte da cratera ficasse coberta pela sombra. Entretanto, no primeiro sobrevoo da Messenger em 2008, a Mozart estava completamente iluminada, o que permitiu que a cratera fosse vista em detalhes pela primeira vez. Essa bacia, que recebeu o nome do compositor austríaco Wolfgang Amadeus Mozart, possui no seu interior um arco de montanhas escuras que acredita-se representar os restos de um anel *peak-ring*. Membros da Messenger estão estudando e caracterizando as crateras que se localizam no interior da Mozart para fornecer novas visões sobre o processo de formação de crateras e como ele funcionou em diferentes planetas do sistema solar.

Além de imagens de baixas e médias resoluções cobrindo todas as bacias escolhidas, foram utilizadas algumas imagens de alta resolução espacial, com o intuito de verificar e reforçar o desempenho do algoritmo. No total, foram selecionadas 55 imagens, sendo 37 imagens da Rachmaninoff com resolução entre 100 e 125 m/pixel; 06 imagens da Mozart com resolução de 250 m/pixel; 02 imagens com resolução de 256 m/pixel e 10 imagens com resolução de aproximadamente 15 m/pixel da Raditladi. Todas as imagens selecionadas são provenientes da câmara NAC, que devido à sua pequena abertura angular, adquiriu imagens com melhores resoluções do que a câmara WAC. A câmara NAC adquire imagens monocromáticas no intervalo espectral de 725-775 nm.

A Figura 39 mostra o *footprint* das imagens selecionadas sobre as crateras.

Figura 39: *Footprints* das imagens usadas da câmara MDIS-NAC nas suas respectivas crateras. (a) *Footprint* das 10 imagens de resolução espacial de 15 m/pixel na Raditladi; (b) *footprint* das 37 imagens com pior resolução na Rachmaninoff; (c) *footprint* das 06 imagens usadas na bacia Mozart; (d) *footprint* das 02 imagens usadas na bacia Raditladi.



Cada imagem tem um nome associado com o seguinte padrão EN*M.IMG.

E: tipo de dado EDR (*Experimental Data Record*);

N: Câmera NAC (Narrow Angle Câmera);

*: numeração correspondente ao tempo transcorrido da missão;

M: intervalo espectral que a imagem foi adquirida, no caso NAC, M significa monocromático.

A Tabela 3 contém o nome de todas as imagens utilizadas neste trabalho.

Tabela 3: Nome das imagens utilizadas com as respectivas resoluções espaciais.


Cratera	ID das imagens	Resolução espacial (m)	ID das imagens	Resolução espacial (m)
Mozart	EN0213239801M	231,88	EN0213239986M	222,92
	EN0213239804M	236,02	EN0213240156M	206,23
	EN0213239984M	220,98	EN0213240159M	210,06
Raditladi	EN0108826727M	254,78	EN0108826792M	260,88
	EN0221023192M	15,58	EN0221023202M	15,84
	EN0221023213M	16,12	EN0221023197M	15,71
	EN0221023207M	15,97	EN0221066394M	15,24
	EN0221066399M	15,36	EN0221066404M	15,49
	EN0221066409M	15,62	EN0221066414M	15,74
Rachmaninoff	EN0219477788M	125,26	EN0219563029M	103,21
	EN0219477837M	121,88	EN0219563033M	103,03
	EN0219477843M	120,78	EN0219563068M	100,13
	EN0219562813M	120,45	EN0219477786M	125,75
	EN0219562817M	120,01	EN0219477840M	121,26
	EN0219562861M	116,63	EN0219562815M	120,18
	EN0219562908M	112,84	EN0219562859M	117,02
	EN0219562914M	112,32	EN0219562863M	116,37
	EN0219562920M	112,10	EN0219562871M	116,14
	EN0219562949M	109,58	EN0219562905M	113,24
	EN0219562953M	109,23	EN0219562911M	112,56
	EN0219562957M	109,15	EN0219562917M	112,15
	EN0219562989M	106,41	EN0219562947M	109,90
	EN0219562993M	106,06	EN0219562951M	109,38
	EN0219562997M	105,97	EN0219562955M	109,13
	EN0219562991M	106,22	EN0219563027M	103,38
	EN0219562995M	105,96	EN0219563031M	103,07
	EN0219563065M	100,38	EN0219562987M	106,72
	EN0219563025M	103,62		

3.3 Metodologia

A metodologia adotada neste trabalho utiliza técnicas de PDI e reconhecimento de padrões, com o objetivo de alcançar a detecção automática de crateras de impacto da superfície de Mercúrio. Para tanto, a estratégia adotada neste trabalho é inspirada nos

trabalhos de Martins *et al.* (2009) e Urbach e Stepinski (2009), e se divide em três etapas principais. Primeiramente, selecionam-se as áreas que são candidatas a terem crateras de impacto. Em seguida, as características de *Haar-like* dessas áreas são extraídas, e posteriormente, essas áreas são classificadas em crateras e não crateras. A Figura 40 apresenta um fluxograma contendo as etapas seguidas.

Figura 40: Fluxograma contendo as principais etapas do trabalho.



3.3.1 Construção do mosaico

As imagens adquiridas no banco de dados da PILOT são disponibilizadas em formato EDR (do inglês, *Experimental Data Record*), que contém os dados brutos. Embora para algumas aplicações seja seguro trabalhar com dados nesse formato, para outras há a necessidade de processar esses dados antes de realizar a aplicação, pois algumas vezes esses

dados apresentam ruídos indesejados ocasionados pelo sensor ou pelas condições atmosféricas.

O *software* utilizado para processar essas imagens foi o *software* ISIS (do inglês, *Integrated Software for Imagers and Spectrometers*). Esse *software* foi desenvolvido pela USGS (do inglês, *United States Geological Survey*) e é capaz de processar dados das missões espaciais da NASA e também de outros centros espaciais, como por exemplo, da missão indiana *Indian Chandrayann* e da missão japonesa *Japanese Kaguya*.

Os elementos geométricos que descrevem as geometrias de imageamento de cada observação são armazenados em arquivos denominados de SPICE kernels e organizados de acordo com os conceitos adotados pela NAIF (do inglês, *Navigational Ancillary Information Facility*). SPICE é um acrônimo para *Spacecraft, Planet, Instrument, C-matrix, and Event kernels*. Cada dado EDR é acompanhado por um SPICE kernel que contém o registro da evolução e de melhoramentos baseados em análises posteriores ao momento de aquisição da informação, isto é, cada imagem possui um rótulo associado construído a partir das informações SPICE atualizadas e disponíveis no momento da criação do produto.

Os modelos e os parâmetros recomendados para tratamento dos dados MDIS NAC e WAC foram obtidos por meio de testes de calibração realizados no OCF (do inglês, *Optical Calibration Facility*) no APL (do inglês, *Applied Physics Laboratory*). A calibração realizada no OCF é realizada por meio de câmaras a vácuo, ligadas a uma série de equipamentos de apoio. A maioria dos testes de calibração foi realizada a uma temperatura aproximada de -30°C. Porém, também foram realizados testes na variação termal de -34°C a 25°C para verificar o comportamento do instrumento mediante as variações de temperatura que ele iria encontrar em Mercúrio.

Uma breve descrição das etapas de correção das imagens é dada a seguir. Para melhor detalhamento dos testes para obtenção dos modelos, dos parâmetros e das equações definidas para tratamento dos dados NAC e WAC pode-se consultar Hawkins *et al.* (2007).

A calibração radiométrica das imagens MDIS NAC foi realizada seguindo os seguintes passos: eliminação de níveis escuros (*Dark Current*), correção da linearidade, eliminação do efeito de borramento, cálculo da uniformidade da resposta do sensor e obtenção do coeficiente absoluto.

A correção do *dark current* foi realizada por meio de um modelo especificamente desenvolvido para tratamento desse sinal indesejado presente no sensor NAC. O modelo foi criado com base nos testes de calibração realizados no OCF. Tal modelo estima o nível de

escuridão por meio de uma função que relaciona a posição da coluna, a posição da linha, o tempo de exposição em milissegundos e a temperatura do sensor CCD (*Charge Coupled Device*).

A correção do efeito de borramento causado devido à arquitetura do dispositivo CCD, foi feita de acordo com a técnica desenvolvida por Murchie *et al.* (1999) para imagens NEAR MSI. Neste tipo de configuração, após o tempo de integração da imagem, a imagem capturada é transferida, em 3,84 ms, para uma seção de armazenamento no CCD, a partir do qual o sinal analógico é digitalizado linha por linha no registrador de saída. Durante o período de transferência, os pixels que ainda não foram lidos continuam armazenando informações da cena, o que pode induzir o surgimento de uma faixa de borramento paralela à direção da transferência de quadro.

A correção da linearidade foi necessária apenas para o CCD. A linearidade foi medida sob a temperatura ambiente e sob temperaturas negativas, os dados foram combinados para examinar a linearidade com relação aos fótons medidos (produto da radiância e tempo de exposição). O que mostrou que o detector da NAC se afasta da linearidade na presença de sinais de baixo nível.


Outra correção realizada foi com relação à uniformidade dos pixels, também chamada de *flat-field*, a qual consistiu da remoção de artefatos causados pela variação da sensibilidade do detector, pixel a pixel. As medições da uniformidade do sensor NAC foram realizadas no OCF, mediante a temperatura ambiente e a baixas temperaturas, imageando a esfera de integração com duas lâmpadas iluminando o seu interior.

O próximo passo foi mapear as coordenadas de três dimensões (latitude, longitude e raio) em um plano com duas dimensões (x , y). Não há rigor na padronização do sistema de projeção a ser adotado, apenas uma convenção em adotar a projeção equirretangular, para baixas e médias latitudes, e a estereográfica polar, para regiões polares. Com base nessa convenção e devido às bacias estarem localizadas entre baixas e médias latitudes, a projeção adotada foi a equirretangular, com o centro de latitude e longitude definido pelas coordenadas de centro de cada bacia. Desta forma, como consequência da propriedade da projeção equirretangular e da localização das bacias, as imagens não sofreram deformação.

3.3.2 Seleção das candidatas a crateras

A primeira etapa do algoritmo é composta pela seleção das áreas candidatas a crateras, a qual consiste da busca por regiões na imagem que apresentem as mesmas características que as crateras de impacto. Nesta etapa, a ideia principal baseou-se no fato que, na maioria dos casos, em imagens digitais, as crateras de impacto são reconhecidas por terem um par formado por uma parte iluminada e a outra parte sombreada. Para tanto, o método de busca se baseia no trabalho de Urbach e Stepinski (2009), o qual consiste em identificar as regiões iluminadas e sombreadas da imagem. Em seguida, feições que não possuem formas aceitáveis para constituírem uma cratera de impacto são eliminadas. Por fim, verifica-se se as formas das feições são geometricamente consistentes para constituírem partes das crateras. O fluxograma apresentado na Figura 41 contém as etapas adotadas para seleção das candidatas.

Figura 41: Fluxograma contendo as etapas para seleção das candidatas.




Conforme o fluxograma da Figura 41, as imagens originais foram submetidas à filtragem por meio do filtro bilateral. A escolha do filtro bilateral se justifica por este apresentar a vantagem de suavizar a imagem, preservando as bordas dos objetos. Nesta filtragem o valor da intensidade de cada pixel em uma imagem é substituído por uma média ponderada de valores de intensidade dos pixels vizinhos. Os pesos não dependem apenas da distância espacial dos pixels vizinhos, mas também dos valores de intensidades desses pixels.

Na sequência, a abertura *top-hat* foi aplicada com o intuito de destacar as regiões iluminadas da imagem. A abertura *top-hat* consiste da diferença entre a imagem original e a imagem aberta. A abertura é definida pela erosão seguida da dilatação, desta forma, os padrões escuros da imagem são destacados e ao subtrair esses padrões da imagem, restam apenas os padrões mais claros.

O fechamento *top-hat* é aplicado com o intuito oposto à aplicação da abertura *top-hat*. Neste caso, o objetivo é evidenciar as regiões de sombra, que é alcançado por meio da diferença da imagem fechada e a imagem original. Como o resultado da imagem fechada consiste do realce dos padrões claros, ao subtrairmos esses padrões da imagem, temos como resultado apenas os padrões mais escuros. A Figura 42 apresenta a sequência de passos para realce das regiões iluminadas e sombreadas.

Figura 42: Etapas seguidas para evidenciar regiões iluminadas e sombreadas.



Após a obtenção das regiões iluminadas e das regiões sombreadas, o próximo passo do algoritmo é verificar se essas regiões correspondem às regiões de crateras de impacto. Antes disso, algumas regiões foram eliminadas pela aplicação do filtro *max-tree* por atributo de abertura *top-hat*, por meio do qual todos os componentes menores do que 200 pixels em extensão de área são eliminados e quando esta imagem é subtraída da imagem original, tem-se apenas as regiões de menores dimensões. Desta forma, eliminam-se estruturas de maiores dimensões como, por exemplo, vales. Em seguida, a abertura de área eliminou regiões da imagem com áreas menores do que 10 pixels. Essa operação consiste da reconstrução da imagem preservando os componentes com área maior do que um limiar estipulado.

Em seguida, cada região é comparada aos *templates* contidos em um banco de dados. Esses *templates* foram construídos manualmente e constituem formas possíveis de regiões de uma cratera. O banco de dados criado contém 22 *templates* que representam as

regiões iluminadas e 24 que representam as regiões sombreadas, alguns exemplos dos *templates* utilizados são mostrados na Figura 43.

Figura 43: Exemplos de *templates* contidas no banco de dados.



A comparação entre as regiões e os *templates* é feita utilizando o critério de forma. Cada comparação é feita por meio de um vetor de atributos contendo os sete momentos de Hu. Os momentos de Hu têm a característica principal de serem invariantes à escala, à rotação e à translação. Assim, a análise feita se baseia apenas na forma dos objetos da imagem, e não considera o tamanho, a orientação e a posição.

Para cada imagem analisada tem-se como resultado duas imagens, sendo uma correspondente às regiões iluminadas e outra às regiões sombreadas. Desta forma, o próximo passo consiste da busca por pares que representem uma cratera de impacto. Assim, cada par é analisado em relação à distância entre as duas regiões; em relação à proporção dos tamanhos de cada região; e em relação à razão da largura e do comprimento da união das duas regiões.

A distância entre as duas regiões deve ser menor do que o tamanho proporcional de cada região. Desta forma, excluem-se pares que estão a longas distâncias. O valor do limiar de aceitação adotado foi de $1,65\sqrt{A_{lum}}$, este valor é o mesmo adotado por Urbach (2009). A Figura 44 apresenta duas meias luas a fim de exemplificar o cálculo da distância. No caso das regiões apresentadas na Figura 44, a área de cada meia lua contém 9.157 pixels e a distância entre os centroides é de 57,28 ($dist = \sqrt{(183-238)^2 + (208-200)^2} = 57,28$). O valor do limiar é 157,89 ($1,65\sqrt{9.157} = 157,89$). Assim, como o valor da distância é menor do que o limiar de área, esse par de regiões é considerado como candidato a cratera e segue para a próxima verificação.

Figura 44: Exemplo de duas regiões candidatas a serem par de uma cratera de impacto.




Em seguida, verifica-se a proporção das áreas das duas regiões. Aceita-se até 4 vezes o tamanho da outra. O terceiro passo consiste da verificação da razão entre o comprimento e a largura da combinação das duas áreas. Esta medida é fornecida pelo primeiro momento de Hu, valores abaixo de 03 significa que não possuem a forma arredondada, e, portanto são excluídos. Além disso, o valor da razão da combinação deve ser menor do que o valor da razão de cada região isolada. No exemplo mostrado na Figura 44, a razão de cada meia lua possui valor de 2,9588, enquanto que a combinação possui valor 3,1455.

Os pares que permanecem após as quatro verificações são consideradas candidatas a crateras e são submetidos à fase de extração das características para, posteriormente, serem classificados em crateras e não crateras.

3.3.3 Extração das características

A extração das características consiste da segunda etapa do algoritmo. Esta etapa foi inspirada no trabalho de Martins *et al.* (2009), o qual utilizou o método proposto por Viola e Jones (2001) no contexto de detecção de faces em imagens, para detecção de crateras. Conforme proposto, a extração de características é realizada a partir da análise de blocos da imagem que são criados em torno de cada candidato. Esses blocos são percorridos por máscaras que extraem valores de atributos para que posteriormente possa ser feita uma diferenciação das feições presentes em uma imagem. As máscaras utilizadas neste trabalho são apresentadas na Figura 45, e são em maior número do que as utilizadas anteriormente por outros autores de forma a descreverem de maneira mais completa as características de uma cratera.

Figura 45: Máscaras usadas para extração das características das feições de interesse.



Essas máscaras variam em relação às suas dimensões e à sua localização dentro do bloco que está sendo analisado. O valor da característica num ponto (x, y) de uma imagem I é o resultado da filtragem linear da imagem com a máscara M de tamanho $a \times b$, definida por:

$$f(x, y) = \sum_{u=1}^a \sum_{v=1}^b M(u, v) I(x + u - 1, y + v - 1). \quad (57)$$

A resposta da filtragem linear num ponto é calculada pela soma do produto dos coeficientes da máscara com os correspondentes pixels da imagem coberta pela máscara. Como temos apenas máscaras binárias, o resultado da filtragem é a diferença entre o somatório dos valores dos pixels correspondentes à área definida pela parte preta da máscara, e o somatório dos pixels da área definida pela região branca. Por exemplo, dado um retângulo com um setor branco (A) e um setor preto (B), como mostra a Figura 46, a característica C de uma região da imagem I pode ser calculada por:

$$C(I) = \sum A - \sum B. \quad (58)$$

Figura 46: Exemplo de máscara dividida em setores.



Como dito anteriormente, a extração das características é obtida pela diferença dos somatórios dos pixels correspondentes à região A e à região B. Dependendo do tamanho da máscara, realizar esse somatório pode exigir um alto custo computacional. Pensando nisso, Viola e Jones (2001) propuseram o uso da imagem integral para facilitar essa operação.

A imagem integral é uma imagem auxiliar contendo a soma acumulada dos pixels de uma imagem original. Na imagem integral cada pixel representa a soma dos pixels acima e


a direita desse pixel, ou seja, a imagem integral I na localização (x, y) é representada pela Equação 59 (VIOLA e JONES, 2001):

$$I(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y'). \quad (59)$$

onde i representa a imagem original.

Um exemplo numérico de uma imagem original e da sua respectiva imagem integral é mostrado na Figura 47.

Figura 47: Exemplo de imagem integral. (a) Imagem original; (b) Imagem integral.




Adaptado de Viola e Jones (2001).

Por meio da imagem integral qualquer área de uma imagem pode ser calculada utilizando apenas alguns pontos de referência. Por exemplo, dada a Figura 47(b), a soma dos pixels do retângulo D pode ser calculada por $I(D) + I(A) - I(B) - I(C)$ que equivale a $20 + 6 - 12 - 10 = 4$.

Desta forma, dado um bloco da imagem contendo um candidato à cratera, conforme apresenta a Figura 48, é possível calcular as características desse candidato por meio de poucos cálculos com a passagem das diversas máscaras que percorrem esse bloco.


Figura 48: Exemplos de variações das máscaras em relação ao tamanho e a localização.



3.3.4 Classificação via SVM

A terceira etapa do método consiste em classificar o conjunto de candidatas obtidas na primeira etapa, com base nas características calculadas na segunda etapa do método, em crateras e não crateras. A classificação entre crateras e não crateras é feita por meio do SVM. A classificação via SVM utiliza um conjunto de treino composto por feições rotuladas em crateras e não crateras. Esse conjunto é utilizado por um algoritmo de aprendizagem para construir uma função que seja capaz de discriminar todas as candidatas em crateras e não crateras. A Figura 49 apresenta as etapas seguidas no processo de classificação.

Figura 49: Resumo do processo sequencial de classificação.



O conjunto de treino é composto por vetores da forma (x, y) , onde x é um vetor contendo características de crateras e de não crateras (regiões extraídas aleatoriamente da imagem e que não sejam candidatas a crateras) e y representa a classe que pode ser $\{0,1\}$. Os exemplos positivos e negativos são extraídos da seleção das candidatas. As candidatas que pertencem ao *ground truth* são aceitos como exemplo positivo e recebem o rótulo 1. A escolha de exemplos negativos é mais complicada, pois se esta fosse feita com base em todas as regiões da imagem que não tivesse crateras, seriam selecionados milhares de exemplos. Desta forma, esse problema foi resolvido selecionando regiões da imagem aleatoriamente, de tal forma, que o número de exemplos negativos seja proporcional ao número de exemplos positivos.

As características são armazenadas nos vetores $x_i \in X$. Desta forma, se um determinado vetor x_i for um exemplo positivo, este contém as características de uma cratera. Entretanto, se for um exemplo negativo, contém características de uma região da superfície do planeta, que pode ou não conter alguma feição. Os vetores x_i são formados pelos valores obtidos com as variações das máscaras em relação ao tamanho, à posição e à forma. Essas combinações geram 1.089 máscaras, o que significa que um vetor x_i pode conter 1.089

características de um exemplo de cratera ou 1089 características de qualquer outra informação da superfície do planeta.

Mediante o comportamento dos dados do conjunto, que possuem a característica de serem não linearmente separáveis, a classificação foi feita com base nos kernels. Os kernels levam os dados para um espaço dimensional mais elevado, de modo que os exemplos possam ser mais facilmente separados. O tipo de kernel adotado é o RBF, por possuir um baixo número de parâmetros que influenciam no resultado do aprendizado. Neste tipo de kernel existem dois tipos de parâmetros que podem ser variados em busca de melhores resultados para o aprendizado do classificador, um deles é o parâmetro γ (gamma) e o outro é o C (custo). No kernel RBF o número de funções radiais e os seus respectivos centros são definidos pelos vetores de suporte obtidos.

A biblioteca libSVM é utilizada para rodar o conjunto de treino e definir um modelo (a superfície do hiperplano de decisão).

3.3.5 Avaliação da Metodologia

A avaliação da metodologia foi feita por meio das métricas descritas na seção 2.3.7. Para o cálculo dessas métricas foram utilizados dois indicadores, TVD (Taxa de Detecção Verdadeira) e o TFD (Taxa de Detecção Falsa):

$$TVD = \frac{TP}{FN} \quad (60)$$


$$TFD = \frac{FP}{TP + FN} \quad (61)$$

Onde TP (*True Positive* ou Verdadeiro Positivo) representa o número de crateras detectadas corretamente, FP (*False Positive* ou Falso Positivo) o número de detecções falsas e FN (*False Negative* ou Falso Negativo) o número de crateras presentes no *Ground Truth* (GT), mas que não foram detectados pela metodologia.

3.3.5.1 Criação do *Ground Truth*

O *ground truth* foi construído por crateras marcadas manualmente utilizando o *software* Crater Helper Tools, uma toolbox do Arcgis. Este *software* disponibiliza um conjunto de ferramentas para medir e vetorizar crateras e outras feições morfológicas. Cada ferramenta armazena informações sobre as medidas realizadas. No caso das crateras, as informações armazenadas foram o centro de cada cratera e seu respectivo valor de diâmetro. No *ground truth* gerado foram marcadas todas as crateras que apresentavam suas características bem definidas, desta forma, as estruturas que geraram incerteza não foram incluídas no *ground truth*. Alguns exemplos de *ground truth* gerados são apresentados na Figura 50.

Figura 50: Crateras marcadas manualmente. (a) Imagens da bacia Rachmaninoff; (b) Imagem EN0221023202M pertencente à bacia Raditladi.




4 RESULTADOS

Conforme o fluxograma apresentado na Figura 40, a primeira etapa da metodologia consistiu da construção do mosaico das imagens. Para tanto, as imagens foram georreferenciadas e corrigidas radiometricamente para que não houvesse nenhuma falha ou falta de informações.

A correção radiométrica foi realizada com o intuito de corrigir alguns ruídos indesejados causados por falhas do sensor. Na correção geométrica as coordenadas das imagens são definidas em função de uma projeção de mapa. Neste trabalho, a projeção escolhida foi a equirretangular por apresentar a característica de não distorcer feições que se encontram em baixas e médias latitudes. Cada bacia foi projetada em função das coordenadas da sua latitude e longitude centrais da bacia. Os sistemas de latitude e longitude escolhidos foram o planetocêntrico, caracterizado por longitudes positivas ao Leste e latitudes planetocêntricas, definidas como o ângulo entre o plano equatorial e o vetor que liga o centro do planeta ao local considerado. A Figura 51 apresenta os mosaicos obtidos após as correções radiométrica e geométrica.


Figura 51: Mosaico das bacias selecionadas para área teste. (a) Bacia Rachmaninoff; (b) Bacia Raditladi e (c) Bacia Mozart.



Após os tratamentos radiométrico e geométrico das imagens, realizou-se a seleção das candidatas. Para tanto, o primeiro passo consistiu da filtragem da cena com o intuito de eliminar os ruídos provenientes do processo de aquisição da imagem e de pequenas sombras

causadas por características do relevo. A Figura 52 apresenta o resultado da aplicação do filtro bilateral sobre uma imagem.

Figura 52: Imagem original e resultado da filtragem por meio do filtro bilateral.




O resultado do filtro bilateral é uma imagem mais homogênea, no sentido de ter menos ruído. Esse filtro foi aplicado, pois ele suaviza a imagem e mantém a bordas nas feições, como pode ser visto na Figura 52(d).

A imagem EN0219562953M, apresentada na Figura 52(a), pertence à bacia Rachmaninoff. Esta imagem tem 1.222 pixels de altura por 1.261 pixels de largura, possui uma resolução espacial de 109 m/pixel, foi adquirida em 10/09/2013 e possui as coordenadas 26,7° N de latitude e 57,42° L de longitude.

Após a filtragem, as áreas correspondentes às regiões de sombras e de iluminação foram realçadas com a aplicação da abertura e do fechamento *top-hat*, respectivamente. A abertura consiste da erosão da imagem, seguida da dilatação. Esse processo elimina as regiões mais claras da imagem, ao passo que atenua as mais escuras. Ao subtrair a imagem aberta da imagem original, tem-se como resultado uma imagem com as áreas mais claras, como mostra a Figura 53(a).

Paralelamente à abertura, aplicou-se o fechamento com o objetivo de atenuar as regiões iluminadas da imagem. O fechamento consiste da dilatação seguida da erosão. Desta forma, eliminam-se feições escuras das imagens e são mantidas as mais claras. Assim, a diferença da imagem fechada com a imagem original resulta na obtenção das regiões de sombra, como mostra a Figura 53(b).


Figura 53: Realce das regiões de sombra e de iluminação.



As imagens resultantes da abertura e do fechamento *top-hat*, apresentam além das regiões de sombra e de iluminação pertencentes às crateras, outras regiões da imagem que também são regiões de sombra e iluminação. Desta forma, com o objetivo de eliminar tais regiões, realizou-se uma filtragem por meio do filtro *max-tree*. Aplicou-se a *max-tree* por

atributo de abertura *top-hat*, por meio do qual todos os componentes menores do que 200 pixels em extensão de área são eliminados e quando esta imagem é subtraída da imagem original, tem-se apenas as regiões de menores dimensões. Desta forma, eliminam-se estruturas de maiores dimensões como, por exemplo, vales, conforme mostram a Figura 54(a). Em seguida, a abertura de área eliminou regiões da imagem com áreas menores do que 10 pixels. Essa operação consiste da reconstrução da imagem preservando os componentes com área maior do que um limiar estipulado. O resultado da aplicação dessas duas operações é mostrado na Figura 54. O mesmo procedimento foi realizado com as imagens referentes às regiões de sombras. O resultado é mostrado na Figura 54(c) e (d).

Figura 54: Filtragem por meio da *maxtree* e da abertura por área.



(a)



(b)




(c)



(d)

Após remover feições muito grandes, feições muito pequenas e feições que não apresentavam contraste, como as crateras apresentam, o próximo passo consistiu na filtragem pela forma, com o intuito de remover feições que possuem a forma incompatível com a forma de uma cratera. Essa filtragem foi realizada por meio dos momentos invariantes de Hu. Cada feição da imagem foi comparada com os *templates* presentes no banco de dados. A vantagem da comparação entre as feições por meio dos momentos de Hu é que essa técnica não se baseia no tamanho, na orientação ou na localização das feições e sim exclusivamente na forma. Assim, com base nos valores do vetor de atributos de um *template* e nos valores do vetor de atributos de uma feição, as feições foram discriminadas por meio do critério da distância euclidiana mínima entre os dois vetores. Na Figura 55(b) os quadrados 1, 2, 3, 4 e 5, representam exemplos de regiões candidatas à cratera. E os quadrados 6 e 7 exemplos de estruturas que não fazem parte das crateras. Logo, os valores do vetor de atributo dessas estruturas não possuem proximidade com os valores do vetor de atributo do *template*.

Figura 55: Filtragem pela forma.



Os passos anteriores foram aplicados em duas imagens, uma contendo as regiões iluminadas e a outra contendo as regiões de sombra. Portanto, o próximo passo consiste em relacionar um par constituído por uma região iluminada e por uma região de sombra, de tal modo que esse par corresponda a uma única cratera. As regiões foram comparadas com relação à distância entre as duas regiões, ao tamanho das regiões (pois as duas regiões têm que


ter os seus tamanhos proporcionais), a forma do par das regiões (pois dois pares relacionados devem ter a forma aproximadamente circular), e com relação à forma, pois a relação do comprimento e da largura do par combinado deve ser menor do que a relação do comprimento e da largura de cada área individual.

Essa sequência de passos resultou em 12.272 candidatas a cratera. Para cada candidato é extraído um bloco, centralizado no candidato e com o tamanho de duas vezes o diâmetro do candidato. Cada bloco é redimensionado para um tamanho de 24x24 pixels. Em seguida, esses blocos são percorridos pelas máscaras binárias e valores numéricos são extraídos. Como explicado na seção 3.3.3, o valor de uma máscara é obtido pela passagem da máscara em uma parte do bloco da imagem onde se calcula a diferença da soma dos pixels que estão sob o setor branco com a soma dos pixels que estão sob o setor preto. Cada máscara varia quatro vezes em relação ao seu tamanho, a primeira delas tem o tamanho de 6x6 pixels, em seguida 12x12, 18x18 e por fim 24x24 pixels. Desta forma, cada candidato é representado por 1.089 características, pois a cada bloco, cada máscara resulta em 121 características, sendo 100 para as máscaras de tamanho 6x6, 16 para as máscaras de tamanho 12x12, 04 para as máscaras de tamanho 18x18 e, 01 para as máscaras de tamanho 24x24 pixels. Por fim, todas as características são normalizadas linearmente para o intervalo (-1,1).

As candidatas foram classificadas em crateras e não crateras com base nas características extraídas por meio das máscaras quadradas utilizadas. Para tanto, primeiramente definiu-se um conjunto de treino composto por crateras e não crateras e os seus respectivos valores de características. Em seguida, as imagens pertencentes ao conjunto de teste foram classificadas de acordo com o modelo gerado a partir dos exemplos contidos no conjunto de treino. Nesta etapa, foram feitos alguns experimentos para a definição do melhor conjunto de treino, bem como para a escolha dos valores dos parâmetros do kernel RBF. No total foram realizados três tipos de experimentos. No primeiro, o algoritmo foi testado com imagens de alta resolução. No segundo, foram utilizadas imagens de médias e baixas resoluções para a detecção de crateras no interior de cada bacia. E, no terceiro, expandiu-se a área de estudo para detecção das crateras. As estratégias utilizadas em cada experimento são apresentadas em detalhe a seguir.

O resultado da classificação das candidatas da imagem utilizada como exemplo é apresentado na Figura 56.

Figura 56: Resultado da detecção para a imagem EN0219562953M. Os círculos verdes indicam as detecções verdadeiras, os vermelhos as falsas detecções e os azuis as crateras que estavam no GT, mas que não foram detectadas pela metodologia proposta.



Esse resultado foi alcançado com o procedimento explicado a seguir no Experimento 2, onde o objetivo é fazer a detecção das crateras no interior das bacias.

Experimento 01: Detecção das crateras em imagens de alta resolução.

O primeiro experimento consistiu em utilizar as informações presentes em uma imagem para treinar o classificador, e em seguida, testar o desempenho do classificador em subconjuntos de imagens e em todo o conjunto. Esta estratégia foi adotada para avaliar como o classificador se comporta quando treinado com diferentes conjuntos de treino e testado em diferentes conjuntos de imagens.

Neste experimento foram utilizadas 10 imagens pertencentes à bacia Raditladi. A localização de cada imagem no interior da Raditladi é mostrada na Figura 57.

Figura 57: Bacia Raditladi e os *footprints* das imagens utilizadas.




Tabela 4: Informações das imagens apresentadas na Figura 57.


Imagem	Footprint	Data de Aquisição	Latitude	Longitude	Resolução (m)	Tamanho (pixels)
EN0221023192M	A1	22/11/2011	27.32	121.43	15,57	1.294x1.137
EN0221023202M	A2	22/11/2011	26.69	121.47	15,83	1.222x1.261
EN0221023213M	A3	22/11/2011	26.00	121.51	16,12	1.217x1.250
EN0221023197M	A4	22/11/2011	27.00	121.45	15,70	1.224x1.266
EN0221023207M	A5	22/11/2011	26.37	121.49	15,96	1.219x1.256
EN0221066394M	B1	22/11/2011	27.55	119.62	15,23	1.221x1.246
EN0221066404M	B2	22/11/2011	26.92	119.67	15,48	1.217x1.235
EN0221066414M	B3	22/11/2011	26.29	119.73	15,74	1.213x1.226
EN0221066399M	B4	22/11/2011	27.23	119.65	15,36	1.219x1.241
EN0221066409M	B5	22/11/2011	26.60	119.70	15,61	1.215x1.231

A estratégia utilizada nesta etapa foi treinar o classificador com as informações presentes em uma imagem de uma fileira e em seguida, testar o seu desempenho nas imagens da mesma fileira, da outra fileira e de todo o conjunto. Para tanto, o primeiro conjunto de treino foi formado por exemplos da imagem EN0221023192M (A1). Neste caso, foram selecionados 825 exemplos, sendo 275 exemplos de crateras e 550 exemplos de não crateras, conforme apresenta a Figura 58(a). Em seguida, realizou-se a validação cruzada com os diferentes conjuntos de teste, sendo o primeiro deles realizado no subconjunto de imagens formado pelas imagens da fileira em que as informações foram retiradas. O segundo teste foi


realizado testando o classificador no subconjunto de imagens da fileira B. No terceiro teste verificou-se o desempenho do classificador em todas as imagens do conjunto de treino.

O segundo conjunto de treino foi construído por informações da imagem EN0221066394M. Este conjunto de treino foi composto por 247 exemplos de crateras e 494 exemplos de não crateras, apresentados na Figura 58(b). O processo de treino e classificação foi realizado como no teste anterior. Ambos os conjuntos de treino foram compostos por exemplos na proporção de 1:2, ou seja, a cada exemplo de cratera selecionado, foram escolhidos dois exemplos de não crateras.

Figura 58: Conjunto de treino formado a partir das imagens EN0221023192M (a) e EN0221066394M (b) (exemplos de crateras em azul e de não-crateras em vermelho).



(a)



(b)

A definição dos parâmetros do kernel RBF foi feita por meio da validação cruzada, conforme mostram as Tabelas 5 e 6. A Tabela 5 apresenta a variação da taxa de detecções verdadeiras conforme a mudança dos parâmetros do kernel RBF para a classificação com o classificador treinado por informações retiradas da imagem EN0221023192M. Da mesma forma, a Tabela 6 apresenta a variação da taxa de falsas detecções para os respectivos parâmetros.

Tabela 5: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros c e g do RBF.

c\g	0.001	0.003	0.005	0.05	0.1	0.5
0.3	0,00	23,54	63,13	79,13	78,99	71,47
0.5	0,00	70,07	68,85	79,03	78,85	73,37
0.7	3,28	76,07	76,09	79,02	79,22	73,57
0.9	25,47	76,49	72,36	73,12	79,15	79,50

Figura 59: Taxa de detecções verdadeiras utilizando o conjunto de treino da imagem EN0221023192M.





Tabela 6: Taxa de falsas detecções por validação cruzada para seleção dos parâmetros c e g do RBF.

c\g	0.001	0.003	0.005	0.05	0.1	0.5
0.3	0,00	1,94	16,61	24,71	23,51	33,49
0.5	0,00	12,73	27,75	24,72	23,31	33,64
0.7	1,02	15,66	19,64	24,46	23,88	33,71
0.9	1,83	19,46	33,18	35,33	23,40	26,02

Figura 60: Taxa de detecção falsa utilizando o conjunto de treino da imagem EN0221023192M.



Conforme pode ser notado nos gráficos, os valores dos parâmetros RBF que fornecem melhor resultado para a classificação são $c = 0,7$ e $g = 0,003$, os quais permitem que o classificador alcance a taxa de detecção verdadeira de 76% e de detecções falsa de 15,6%.

O resumo dos testes realizados é apresentado a seguir na Tabela 7.


Tabela 7: Desempenho do algoritmo para imagens de alta resolução.

Imagens de Treino	Imagens de Teste	TP	FP	FN	TDV (%)	TFD (%)	B	Q (%)
A1	A2 - A5	1.133	177	312	78,4	13,5	0,15	69,85
A1	B1 - B5	1.556	317	511	75,27	16,9	0,2	65,27
A1	A2 - A5 + B1 -B5	2.607	484	820	76,07	15,66	0,19	66,66
B1	B2 - B5	1.318	539	391	77,12	29	0,4	58,63
B1	A1 - A5	1.591	499	345	82,18	23,9	0,31	65,34
B1	A1 - A5 + B2 -B5	2.909	1.038	736	79,65	26,4	0,35	61,98

A Tabela 7 apresenta as estatísticas obtidas pelo classificador mediante o treino com diferentes conjuntos. Os resultados obtidos são similares, entretanto, o classificador obteve melhor desempenho quando treinado com as informações da imagem A1.

A sobreposição de todas as detecções é apresentada na Figura 61. As detecções verdadeiras são representadas pelos círculos verdes, as falsas pelos círculos vermelhos e as crateras que constavam no *ground truth*, mas que não foram detectadas, são representadas pelos círculos azuis.

Figura 61: Sobreposição das detecções nas imagens originais projetadas (verde-TP, vermelho-FP e FN-azul).




A Tabela 8 apresenta o desempenho do classificador para cada imagem individual.

Tabela 8: Resultado da classificação para cada imagem.

Imagem	Footprint	TP	FP	FN	TVD	TFD	B	Q
EN0221023197M	A2	406	36	64	86,38	8,14	0,09	80,24
EN0221023202M	A3	143	17	89	61,64	10,63	0,12	57,43
EN0221023207M	A4	205	29	70	74,55	12,39	0,14	67,43
EN0221023213M	A5	376	80	69	84,49	17,54	0,21	71,62
EN0221066394M	B1	283	43	107	72,56	13,19	0,15	65,36
EN0221066399M	B2	242	48	102	70,35	16,55	0,20	61,73
EN0221066404M	B3	331	68	86	79,38	17,04	0,21	68,25
EN02210666409M	B4	350	74	124	73,84	17,45	0,21	63,87
EN0221066414M	B5	271	89	109	71,32	24,72	0,33	57,78
Total		2.607	484	820	76,07	15,66	0,19	66,66

A taxa de detecção global alcançada é considerada boa, visto que as imagens possuem alta complexidade. O classificador obteve melhor desempenho na imagem EN0221023197M, apresentada em destaque na Figura 61. Para esta imagem, o classificador alcançou 86% de taxa de detecções corretas e 8% de detecções incorretas. O pior resultado foi para a imagem EN0221023202M, na qual o classificador obteve 61% de detecções corretas. Esses resultados foram obtidos para crateras com diâmetro de 14 pixels em diante, isso significa que foram detectadas crateras com diâmetro acima de 210 metros. A Figura 62 apresenta a quantidade de crateras detectadas corretamente de acordo com o diâmetro.


Figura 62: Quantidade de crateras verdadeiras detectadas em relação ao diâmetro das crateras.



Experimento 02: Detecção das crateras no interior das Bacias.

O segundo experimento consistiu em realizar a detecção das crateras no interior de três bacias selecionadas de Mercúrio. A detecção de crateras no interior das bacias é relevante, pois por meio de uma análise detalhada da quantidade e da distribuição das crateras no seu interior é possível estimar a idade da bacia. A Figura 63 apresenta as áreas estudadas em cada Bacia.

Figura 63: Delimitação das áreas de estudo. (a) Bacia Rachmaninoff; (b) Bacia Raditladi e (c) Bacia Mozart.



Neste experimento, o processo de definição do conjunto de treino foi realizado armazenando informações de cada bacia em um mesmo conjunto de treino. O conjunto de treino foi formado por 800 exemplos, sendo 240 exemplos de crateras e 560 exemplos de não crateras. A distribuição da extração das informações seguiu a seguinte ordem: 200 exemplos de crateras e 400 de não crateras da bacia Rachmaninoff, 20 exemplos de crateras e 80 de não crateras da Mozart e 20 exemplos de crateras e 80 de não crateras da Raditladi.

Os parâmetros do kernel RBF foram definidos por meio da realização da validação cruzada. Os parâmetros que forneceram melhores resultados foram $c = 0,015$ e $g = 0,2$ para a bacia Rachmaninoff; $c = 0,9$ e $g = 0,01$ para a bacia Mozart e para a bacia Raditladi $c = 0,2$ e $g = 0,15$. O resultado do desempenho do algoritmo é apresentado nas Figuras 64, 65 e 66, por meio da sobreposição das detecções nas respectivas bacias.

Figura 64: Detecção de crateras de impacto na Bacia Rachmaninoff (verde-TP, vermelho-FP e FN-azul).




Figura 65: Detecção das crateras na bacia Mozart (verde-TP, vermelho-FP e FN-azul).





Figura 66: Detecção das crateras na Bacia Raditladi (verde-TP, vermelho-FP e FN-azul).



Os resultados obtidos são considerados bons, dadas as diferentes resoluções das imagens e as diferentes características das superfícies a que o algoritmo foi exposto. A Tabela 09 apresenta as estatísticas alcançadas pelo algoritmo. O desempenho do algoritmo foi um pouco diferente em cada bacia, como pode ser visto na Tabela 09. Em todas as bacias, a quantidade de detecções corretas é alta, variando entre 86% e 95%, ao mesmo tempo em que a quantidade de crateras não detectadas, mas que constava no *ground truth* é baixa. Em


contrapartida, o número de detecções falsas é um pouco elevado, o que contribui para a diminuição do desempenho do algoritmo. Isso acontece principalmente nos anéis internos das bacias, devido esses anéis serem formados por regiões sobrelevadas, as quais apresentam nas imagens zonas iluminadas seguidas por zonas sombreadas, o que as tornam com características similares às características das crateras. A menor resolução das imagens também contribui para a diminuição do desempenho do algoritmo, visto que a quantidade de falsas detecções diminui conforme o aumento da resolução.

Tabela 9: Desempenho da detecção para cada bacia.

Imagens	TP	FP	FN	TDV	TFD	B	Q
Rachmaninoff	846	262	73	92,05	23,64	0,30	71,63
Mozart	44	08	07	86,27	15,38	0,18	74,57
Raditladi	75	70	4	94,93	48,27	0,93	50,33

Os resultados apresentados na Tabela 9 foram obtidos para detecção de crateras com diâmetro mínimo de 09 pixels e diâmetro máximo de 100 pixels, o que significa que foram detectadas crateras com tamanho variando de 900 metros até aproximadamente 18 km. A Figura 67 apresenta a relação da quantidade de crateras detectadas em relação ao tamanho das crateras.

Figura 67: Quantidade de crateras detectadas corretamente em relação ao diâmetro.



Como mostra o gráfico da Figura 67, as crateras detectadas na Bacia Rachmaninoff variam de 900 metros de diâmetro a aproximadamente 2 km. Na Bacia Raditladi o tamanho das crateras detectadas variam de cerca de 2.300 m a cerca de 18 km e na Bacia Mozart o tamanho varia de 1.800 m a 13 km.

Os experimentos anteriores comprovam a eficiência do algoritmo. Entretanto, como pode ser visto na Figura 66, o algoritmo é sensível à presença de estruturas que contêm uma parte sombreada e a outra iluminada. Desta forma, embora já fosse esperado um baixo desempenho do algoritmo em situações complexas onde até o operador humano tem dificuldades em identificar as crateras devido à baixa resolução das imagens e ao fato da superfície ser altamente irregular, foram feitos alguns experimentos com o objetivo de verificar o comportamento do algoritmo nesses tipos de situações. Para tanto, a área de estudo foi expandida para o entorno das bacias, conforme detalhado no experimento a seguir.

Experimento 03: Detecção das crateras em imagens de média e baixa resoluções.


Neste experimento as imagens de cada bacia foram classificadas de acordo com o modelo obtido com o conjunto de treino formado por exemplos retirados da própria bacia. Em todos os casos, as imagens utilizadas para construir os conjuntos de treino foram retiradas da análise estatística para o cálculo das taxas de detecções.

➤ Bacia Rachmaninoff


A primeira estratégia adotada para a detecção das crateras da bacia Rachmaninoff foi de utilizar as informações presentes na imagem de melhor resolução para treinar o classificador e posteriormente testá-lo nas demais imagens. A imagem escolhida possui a resolução de 100 m/pixel. A partir desta imagem foram gerados dois conjuntos de treino, um formado por exemplos selecionados na proporção 1:2, isto é, a cada exemplo de cratera há dois exemplos de não crateras. Desta forma, o primeiro conjunto foi composto por 141 exemplos, apresentados na Figura 68(a), sendo 47 exemplos de crateras representados pelos círculos azuis e 94 exemplos de não crateras representados pelos quadrados vermelhos. O segundo conjunto de treino foi formado na proporção de exemplos de 1:4, assim, este

conjunto foi composto por 47 exemplos de crateras e 188 exemplos de não crateras, mostrados na Figura 68(b).

Figura 68: Imagem EN029563068 com exemplos de crateras (círculo azuis) e de não crateras (quadrados vermelhos). (a) exemplos na proporção 1:2 e (b) exemplos na proporção 1:4.



(a)



(b)

A definição dos parâmetros do kernel RBF foi feita por meio da validação cruzada. As taxas alcançadas com a variação dos parâmetros são apresentadas nas Tabelas 10, 11, 12 e 13, sendo que as Tabelas 10 e 11 apresentam as taxas de detecções verdadeiras e as Tabelas 12 e 13 as taxas de detecções falsas.

Tabela 10: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:2, com base na taxa de detecção verdadeira.

$c \backslash g$	0.001	0.005	0.01	0.05	0.1
0.05	0	76,59	0	0	0
0.07	0	0	0	25,89	25,89
0.1	0	0	0	75,22	68,95
0.3	0	4,95	82,44	91,74	91,74
0.5	0	76,59	87,98	92,73	92,92

Tabela 11: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:4, com base na taxa de detecção verdadeira.

c\g	0.01	0.03	0.05	0.1	0.3
0.3	0	3	5,86	0	0
0.5	0	63,89	76,11	70,57	0
0.7	4,66	82,93	90,17	89,84	34,54
0.9	50,43	90,98	91,37	91,68	59,64

Figura 69: Taxa de detecção verdadeira utilizando o conjunto de treino formado por exemplos da imagem EN029563068. (a) Variação da taxa de detecção para o conjunto formado na proporção 1:2 e (b) variação da taxa de detecção para o conjunto formado na proporção 1:4.





Tabela 12: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:2, com base na taxa de detecção falsa.

c\g	0.001	0.005	0.01	0.05	0.1
0.05	0	40,94	0	0	0
0.07	0	0	0	6,68	6,68
0.1	0	0	0	43,4	41,16
0.3	0	2,86	51,77	68,44	68,44
0.5	0	40,94	59,79	71,14	71,50

Tabela 13: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do kernel RBF para o conjunto de treino formado por exemplos na proporção 1:4, com base na taxa de detecção falsa.

c\g	0.01	0.03	0.05	0.1	0.3
0.3	0	3	0	0	0
0.5	0	24,83	43,78	40,14	0
0.7	0	54,29	63,73	61,70	40,25
0.9	22	64,87	67,15	66,67	57,04

Figura 70: Taxa de detecção falsa utilizando o conjunto de treino formado por exemplos da imagem EN029563068. (a) Variação da taxa de detecção para o conjunto formado na proporção 1:2 e (b) variação da taxa de detecção para o conjunto formado na proporção 1:4.




Como pode ser notado nos gráficos mostrados na Figura 69(a), quando o classificador é treinado com o conjunto de treino formado na proporção de exemplos de 1:2, o classificador alcança melhores taxas de detecção quando $c = 0,3$ e g varia entre 0,05 e 0,1, ou $c = 0,5$ e g varia entre 0,05 e 0,1. Entretanto, para esses mesmos parâmetros as taxas de detecções falsas variam entre 54% e 68%, conforme pode ser visto no gráfico da Figura 70(a). Quando o classificador é treinado com um conjunto de treino formado na proporção de 1:4, quando c varia entre 0,7 e 0,9 e g varia entre 0,03 e 0,1, o classificador alcança alta taxa de detecções corretas, entretanto para esses mesmos parâmetros a taxa de detecção incorreta varia entre 54% e 67%. A melhor configuração se deu com $c=0,5$ e $g=0,03$, onde a TVD = 64% e TFD = 25%.

Em seguida, outro teste foi realizado utilizando informações de duas imagens para treinar o classificador e testá-lo nas imagens restantes. O novo conjunto foi formado pela imagem EN029563068, que é a imagem de melhor resolução, e pela imagem EN0219477788, que possui a resolução de 126 m/pixel, sendo a imagem de resolução mais baixa do conjunto.

Os exemplos extraídos da imagem EN0219477788 são mostrados na Figura 71. Dessa imagem, foram extraídos 72 exemplos, sendo 24 exemplos positivos (círculos azuis) e 48 negativos (quadrados vermelhos). A união das informações extraídas das duas imagens deu origem a um novo conjunto formado por 213 exemplos, sendo 71 exemplos de crateras e 142 exemplos de não crateras.

Figura 71: Imagem EN0219477788 com exemplos de crateras (círculo azuis) e de não crateras (quadrados vermelhos).



As Tabelas a seguir apresentam a variação das taxas de detecções verdadeiras e falsas obtidas pelo classificador quando treinado com o conjunto de treino contendo informações das imagens EN029563068 e EN0219477788.

Tabela 14: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção verdadeira.

$c \backslash g$	0.001	0.005	0.01	0.05	0.1
0.05	0	0	0	0	0
0.07	0	0	0	0	0
0.1	0	0	0	59,19	46,32
0.3	0	0	73,40	89,71	88,62
0.5	0	60	89,29	91,10	91,52

Figura 72: Taxa de detecção verdadeira utilizando um conjunto de treino formado por informações retiradas das imagens EN029563068 e EN0219477788.





Tabela 15: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção falsa.

c\g	0.001	0.005	0.01	0.05	0.1
0.05	0	0	0	0	0
0.07	0	0	0	0	0
0.1	0	0	0	29,27	31,25
0.3	0	0	36,44	70,44	70,42
0.5	0	23,36	65,13	70,13	71,69

Figura 73: Taxa de detecção falsa utilizando um conjunto de treino formado por informações retiradas das imagens EN029563068 e EN0219477788.



Como mostra os gráficos apresentados nas Figuras 72 e 73, o classificador obteve melhor desempenho com $c = 0,3$ e g variando entre 0,05 e 0,1 e $c = 0,5$ e g variando entre 0,01 e 0,1, com valores da taxa de detecção verdadeira variando entre 89 e 91,5%. Entretanto, para esses mesmo parâmetros a taxa de detecção falsa varia de 65% a 72%. Desta forma, o melhor valor alcançado foi para os parâmetros de $c = 0,3$ e $g = 0,01$, onde a taxa de detecção verdadeira chega a 73% e a taxa de detecção falsa 36%.

Por fim, o último teste deste experimento consistiu em formar um conjunto de treino a partir de informações retiradas de quatro imagens. Para tanto, foram utilizadas as duas imagens apresentadas no teste anterior, juntamente com as imagens: EN0219563031 e EN0219562911. A imagem EN0219563031 possui a resolução de 103 m/pixel e foi escolhida por conter uma porção da superfície com estruturas complexas e a EN0219562911 possui a resolução de 112 m/pixel e foi escolhida por apresentar uma parte da superfície mais homogênea.

Figura 74: Exemplos de crateras e de não crateras retirados das imagens EN0219563031 e EN0219562911.




Tabela 16: Taxa de detecções verdadeiras por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção correta.

$c \backslash g$	0.001	0.005	0.01	0.05	0.1
0.05	0,00	0,00	0,00	65,35	50,42
0.07	0	0,00	0,00	85,19	80,80
0.1	0,00	0,00	13,89	89,18	87,95
0.3	0,00	83,69	89,73	93,89	94,51
0.5	0,00	89,33	91,31	94,49	94,93

Figura 75: Taxa de detecção verdadeira utilizando um conjunto de treino formado por exemplos das imagens EN029563068, EN0219477788, EN0219563031 e EN0219562911.





Tabela 17: Taxa de detecções falsas por validação cruzada para seleção dos parâmetros do RBF, com base na taxa de detecção incorreta.

c\g	0.001	0.005	0.01	0.05	0.1
0.05	0,00	0,00	0,00	27,05	19,49
0.07	0,00	0,00	0,00	58,80	53,63
0.1	0,00	0,00	3,50	63,41	61,70
0.3	0,00	30,62	62,55	69,34	72,18
0.5	0,00	61,16	65,30	71,34	74,93

Figura 76: Taxa de detecção falsa utilizando um conjunto de treino formado por exemplos da imagem EN029563068, EN0219477788, EN0219563031 e EN0219562911.



Como pode ser visto nos gráficos apresentados nas Figuras 75 e 76, o melhor valor dos parâmetros c e g para o kernel RBF foi de $c = 0,3$ e $g = 0,005$, com esses valores a função de mapeamento conseguiu discriminar os novos valores de entrada com uma taxa de acerto de 83,69%, enquanto que a taxa de erro (taxa de falsas detecções) foi de 30,62%. A Tabela 18 apresenta o desempenho do classificador para cada imagem do conjunto.

Tabela 18: Desempenho da classificação para cada imagem do conjunto.


Imagem	TP	FP	FN	TVD	TFD	B	Q
EN0219477786M	39	16	6	86,67	29,09	0,41	63,93
EN0219477837M	19	14	10	65,52	42,42	0,74	44,19
EN0219477840M	23	13	8	74,19	36,11	0,57	52,27
EN0219477843M	22	17	8	73,33	43,59	0,77	46,81
EN0219562813M	31	44	1	96,88	58,67	1,42	40,79
EN0219562815M	43	21	6	87,76	32,81	0,49	61,43
EN0219562817M	51	27	9	85,00	34,62	0,53	58,62
EN0219562859M	62	35	6	91,18	36,08	0,56	60,19
EN0219562861M	50	25	3	94,34	33,33	0,50	64,10
EN0219562863M	30	36	8	78,95	54,55	1,20	40,54
EN0219562871M	55	28	6	90,16	33,73	0,51	61,80
EN0219562905M	35	24	9	79,55	40,68	0,69	51,47
EN0219562908M	60	27	8	88,24	31,03	0,45	63,16
EN0219562914M	92	36	8	92,00	28,13	0,39	67,65
EN0219562917M	46	23	3	93,88	33,33	0,50	63,89
EN0219562920M	9	6	7	56,25	40,00	0,67	40,91
EN0219562947M	54	29	21	72,00	34,94	0,54	51,92
EN0219562949M	85	41	14	85,86	32,54	0,48	60,71
EN0219562951M	56	33	18	75,68	37,08	0,59	52,34
EN0219562953M	159	53	14	91,91	25,00	0,33	70,35
EN0219562955M	41	16	11	78,85	28,07	0,39	60,29
EN0219562957M	35	9	10	77,78	20,45	0,26	64,81
EN0219562987M	44	29	11	80,00	39,73	0,66	52,38
EN0219562989M	52	23	13	80,00	30,67	0,44	59,09
EN0219562991M	26	13	8	76,47	33,33	0,50	55,32
EN0219562993M	63	19	10	86,30	23,17	0,30	68,48
EN0219562995M	57	11	16	78,08	16,18	0,19	67,86
EN0219562997M	106	7	9	92,17	6,19	0,07	86,89
EN0219563025M	59	20	25	70,24	25,32	0,34	56,73
EN0219563027M	98	17	23	80,99	14,78	0,17	71,01
EN0219563029M	78	38	11	87,64	32,76	0,49	61,42
EN0219563033M	62	17	8	88,57	21,52	0,27	71,26
EN0219563065M	23	12	16	58,97	34,29	0,52	45,10
Total	1765	779	344	83,69	30,62	0,44	61,11

Os resultados alcançados com esse conjunto de imagens são razoáveis, visto que as imagens são de média resolução e contém uma parte da superfície do planeta que é irregular, além de conterem a borda da bacia que é altamente irregular. A taxa de detecção verdadeira varia pouco entre a maioria das imagens, em 27 imagens o algoritmo alcançou uma


taxa de detecção verdadeira acima de 75%, sendo que das 27 imagens, em 19 o classificador obteve uma taxa de detecção verdadeira acima de 80%. Devido à irregularidade da superfície o desempenho do algoritmo diminui e alcança uma taxa de falsas detecções de 30,62%.

Alguns resultados da classificação são apresentados na Figura 77.

Figura 77: Desempenho do algoritmo nas imagens (a) EN0219562997 e (b) EN0219563033 (verde-TP, vermelho-FP e FN-azul).



(a)



(b)

5 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

Este trabalho teve como objetivo principal desenvolver uma metodologia para detecção automática de crateras de impacto na superfície de Mercúrio. Tal metodologia foi aplicada a um conjunto de imagens proveniente do sensoriamento remoto de Mercúrio. O mapeamento das crateras de impacto de Mercúrio é essencial para um melhor entendimento de uma série de questões geológicas do planeta, visto que até poucos anos atrás apenas 45% da superfície do planeta era conhecida. Somente com o envio da sonda Messenger foi possível a obtenção de imagens de todo o planeta. Assim, até o momento, existem poucos trabalhos com o intuito de automatizar a tarefa de detecção de crateras em Mercúrio. Neste sentido, este trabalho visou contribuir para automatização desse processo.

Apesar das crateras de impacto apresentarem um padrão similar em todas as imagens, as suas características variam dependendo da região em que elas estão inseridas, do seu nível de degradação, do ângulo de imageamento do sensor que pode interferir na quantidade de sombra dentro das crateras, dentre outros fatores. Assim, a metodologia aplicada foi capaz de detectar crateras com as mais variadas características em imagens cujas resoluções espaciais variam desde 15 m/pixel a 260 m/pixel.

Em imagens de alta resolução o algoritmo detectou crateras de 210 metros de diâmetro em diante. Das 3.427 crateras com essas dimensões, existentes no *ground truth*, cerca de 2.610 foram devidamente detectadas. Já nas imagens de médias e baixas resoluções crateras acima de 900 metros foram identificadas. Neste caso, um total de 1.884 crateras foi detectado. A relevância de detectar crateras com diâmetros menores do que 10 km se justifica devido aos catálogos existentes para Mercúrio disporem somente de crateras com diâmetro acima de 10 km.

Os resultados obtidos mostram que o algoritmo alcança melhores resultados quando aplicado em imagens de alta resolução. O resultado global para essas imagens alcançou uma média de 76% de detecções verdadeiras e 15,6% de falsas detecções. No caso das imagens de média resolução, os resultados apontaram uma média de 83,7% de taxa de detecção verdadeira e 30,6% de detecções falsas. Esses resultados são razoáveis, considerando a alta irregularidade da superfície de Mercúrio em algumas regiões analisadas e a baixa qualidade de algumas imagens presentes no conjunto.

Para definição de um conjunto de informações que melhor treinasse o classificador foram testadas diferentes configurações de formação de conjunto de treino. Os melhores resultados foram obtidos quando os conjuntos foram formados por informações retiradas de uma maior quantidade de imagens. Entretanto, para imagens de melhores resoluções a formação do conjunto de treino composto por informações de uma imagem na proporção 1:2 se mostrou eficiente.

No geral, o classificador SVM se mostrou eficiente na discriminação das crateras de impacto em relação às outras estruturas presentes na superfície de Mercúrio. Somente em imagens de baixa resolução e quando exposto a superfícies altamente irregulares o desempenho do classificador teve uma diminuição no seu desempenho.

Um aumento do conjunto de imagens seria necessário para comprovar a confiabilidade da metodologia. Entretanto, a construção das imagens *ground truth* demanda tempo por parte do operador, o que tornou um fator limitante na definição da quantidade de imagens utilizadas. Contudo, o conjunto de imagens utilizado é significativo, visto que é composto por 55 imagens com características variadas quanto ao tamanho das crateras, à resolução das imagens e às diferentes regiões da superfície do planeta.

Para trabalhos futuros recomenda-se testar novas abordagens na fase de seleção das candidatas, visto que a metodologia aqui adotada detecta um elevado número de candidatas. A diminuição da quantidade de regiões candidatas poderia reduzir significativamente a taxa de falsas detecções. Métodos de realce, de filtragem, de análise de forma e de textura podem ser aplicados com esse objetivo.

Além disso, algoritmos de aprendizagem incremental podem ser utilizados na fase de construção do conjunto de treino, visto que esse tipo de abordagem utiliza transferência de aprendizagem que pode ser útil na seleção de informações para comporem o conjunto de treino. Desta forma, um novo exemplo só seria incluído no conjunto de treino se não houvesse nenhum exemplo com características semelhantes.

A utilização do MDT pode ser considerada em uma etapa de pós-processamento, pois a relação entre diâmetro e profundidade poderia excluir elevações e outras feições que não possuem profundidade ou que não obedecem à relação existente para as crateras de impacto. Como consequência disso, a quantidade de detecções falsas seria reduzida. Atualmente, a desvantagem da utilização do MDT é devido à disponibilidade dos dados com baixa resolução em relação à resolução das imagens. Essa incompatibilidade entre as

resoluções faz com que somente detecções obtidas a partir de imagens de baixas resoluções possam ser verificadas pelo MDT.

REFERÊNCIAS

- ANDERSSON, L. E; WHITAKER, E. A. Nasa catalog of Lunar nomenclature. In: **NASA Reference Publication 1097**. 1982.
- BAKER, D. M. H.; HEAD, J. W.; SCHON, S. C.; ERNST, C. M.; PROCKTER, L. M.; MURCHIE, S. L.; DENEVI, B. W.; SOLOMON, S. C.; STROM, R. G. The transition from complex crater to peak-ring basin on Mercury: New observations from MESSENGER flyby data and constraints on basin-formation models. **Planetary and Space Science**. v.59, n. 15, p. 1932–1948. 2011.
- BANDEIRA, L.; SARAIVA, J.; PINA, P. Impact Crater Recognition on Mars Based on a Probability Volume Created by Template Matching. **IEEE Transactions on Geoscience and Remote Sensing**. v. 45, n. 12, p. 4008 – 4015. 2007.
- BANDEIRA, L.; DING, W.; STEPINSKI, T. F. Detection of sub-kilometer craters in high resolution planetary images using shape and texture features. **Advances in Space Research**. v. 49, p. 64 – 74. 2012.
- BANDFIELD, J.; GHEN, R.; VASAVADA, A. Lunar surface rock abundance and regolith fines temperatures derived from LRO Diviner Radiometer data. **Journal of Geophysical Research**. v. 116, E00HO2. 2011.
- BANON, G. J. F.; BARRERA, J. Decomposition of mappings between complete lattices by Mathematical Morphology. **Signal Processing**. v. 30, p. 299 – 327. 1993.
- BARATA, T.; ALVES, E. I.; SARAIVA, J.; PINA, P. Automatic Recognition of Impact Craters on the Surface of Mars. In: **Proceeding of ICIAR**. p. 489 – 496. 2004.
- BARLOW, N. G. Crater size-distributions and a revised Martian relative chronology. **Icarus**. v. 75, n. 2, p. 285-305. 1988.
- BARLOW, N. G. Revision of the “Catalog of Large Martian Impact Craters”. In: **Proceeding of VI International Conference on Mars**. Pasadena, California. 2003.
- BARNOUIN, O. S.; ZUBER, M. T.; SMITH, D. E.; NEUMANN, G. A.; HERRICK, R. R.; CHAPPELOW, J. E.; MURCHIE, S. L.; PROCKTER, L. M. The morphology of craters on Mercury: Results from MESSENGER flybys. **Icarus**. v. 219, n. 1, p. 414 – 427. 2012.
- BLAIR, D. M.; FREED, A. M.; BYRNE, P. K.; KLIMCZAK, C.; PROCKTER, L. M.; ERNST, C. M.; SOLOMON, S. C.; MELOSH, H. J.; ZUBER, M. T. The origin of graben and ridges in Rachmaninoff, Raditladi, and Mozart basins, Mercury. **Journal of Geophysical Research: Planets**. v.118, n. 1, p.47-58. 2013.
- BUE, B. D.; STEPINSKI, T. F. Machine Detection of Martian Impact Craters From Digital Topography Data. **IEEE Transactions on Geoscience and Remote Sensing**. v. 45, n. 1. 2007.

BECKER, K. J.; ROBINSON, M. S.; BECKER, T. L.; WELLER, L. A.; TURNER, S.; NGUYEN, L.; SELBY, C.; DENEVI, B. W.; MURCHIE, S. L.; McNUTT, R. L.; SOLOMON, S. C. Near global mosaic of Mercury. **In: Eos. Transaction AGU.** San Francisco, California. v. 90, n. 52. 2009.

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Knowledge Discovery and Data Mining.** v.2, p. 1- 43. 1998.

CAMPBELL, C. An introduction to kernel methods. **In: Howlett, R. J. e Jain, L. C., editors, Radial Basis Function Networks: Design and Applications.** p. 155-192, Berlin. Springer Verlag. 2000.

CHAO, E. C. T.; SHOEMAKER, E. M.; MADSEN, B. M. First natural occurrence of coesite. **Science.** v. 132, p. 220-222, 1960.

CINTALA, M. J.; HEAD, J.; MUTCH, T. A. Martian crater depth/diameter relationship: comparison with the Moon and Mercury. **In: Proceedings of the VII Lunar Science Conference.** The Woodlands, Texas, USA. v. 3, p. 3375–3587. 1976.

CRATER ANALYSIS TECHNIQUES WORKING GROUP. Standard Techniques for Presentation and Analysis of Crater Size-Frequency Data. **Icarus.** v. 37, p. 467-474, 1979.

CRÓSTA, A. P.; V, M. A. R. Update on the current knowledge of the Brazilian impact craters. **In: Proceeding of the XXXIV Lunar and Planetary Science Conference.** The Woodlands, Texas, USA. 2013.

CRÓSTA, A. P. Crateras de impacto meteorítico no Brasil. **In: Oscar T. Matsuura. (Org.). História da Astronomia no Brasil.** 1ed. Recife: CEPE, v. 1, p. 417-441. 2014.

DING, W.; STEPINSKI, T. F.; BANDEIRA, L.; VILALTA, R.; WU, Y.; LU, Z.; CAO, T. Automatic Detection of Craters in Planetary Images: Na Embedded Framework Using Feature Selection and Boosting. **In: Proceeding of CIKM'10.** Toronto. 2010.

DING, W.; STEPINSKI, T. F.; MU, Y.; BANDEIRA, L.; VILALTA, R.; WU, Y.; LU, Z.; CAO, T.; WU, X. Sub-Kilometer Crater Discovery with Boosting and Transfer Learning. **ACM Transactions on Intelligent Systems and Technology.** v.2. 2011.

EARTH IMPACT DATABASE. Disponível em <<http://www.passc.net/EarthImpactDatabase/index.html>>. Acesso em: 10 jan. 2015.

FACON, J. **Morfologia Matemática: teoria e exemplos.** Curitiba: PUC, 1996. 295p.

FASSETT, C. I.; KADISH, S. J.; HEAD, J. W.; SOLOMON, S. C.; STROM, R. G. The global population of large craters on Mercury and comparison with the Moon. **Geophysical research letters.** v. 38, L10202, p. 1-6. 2011.

FASSETT, C. I.; HEAD, J. W.; BAKER, D. M. H; ZUBER, M. T.; SMITH, D. E.; NEUMANN, G. A.; SOLOMON, S. C.; KLIMCZAK, C.; STROM, R. G.; CHAPMAN, C. R.; PROCKER, L. M.; PHILLIPS, R. J.; OBERST, J.; PREUSKER, F. Large impact basins

on Mercury: Global distribution, characteristics, and modification history from MESSENGER orbital data. **Journal of Geophysical Research**. v. 117, E00L08, p. 1 – 15. 2012.

FRENCH, B. M. **Traces of Catastrophe: a handbook of shock-metamorphic effects in terrestrial meteorite impact structures**. LPI Contribution n. 954, Lunar and Planetary Institute, Houston, 1998. 120 p.

GOLD, R. E.; SOLOMON, S. C.; McNUTT R. L.; SANTPO, A. G.; ABSHIRE, J. B.; ACUÑA, M. H.; AFZAL, R. S.; ANDERSON, B. J.; ANDREWS, G. B.; BEDINI, P. D.; CAIN, J.; CHENG, A. F.; et al. The MESSENGER mission to Mercury: scientific payload. **Planetary and Space Science**. v.49, n. 14-15, p. 1467-1479. 2001.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. São Paulo: Pearson Prentice Hall, 2010. 624p.

GOUTSIAS, J.; HEIJMANS, H. J. A. M. **Fundamenta Morphologicae Mathematicae. Mathematical Morphology**: edição livro do periódico Fundamentae Informaticae. v. 41, n. 1-2, p. 1 – 31, 2000.

HAWKINS, S. E.; BOLDT, J. D.; DARLINGTON, E. H.; ESPIRITU, R.; GOLD, R. E.; GOTWOLS, B.; GREY, M. P.; HASH, C. D.; HAYES, J. R.; JASKULEK, S. E.; KARDIAN, C. J.; KELLER, M. R.; et al. The Mercury Dual Imaging System on the MESSENGER Spacecraft. **Space Science Review**. v.131, p. 247 – 338. 2007.

HAYKIN, S. **Neural Networks: A comprehensive Foundation**. Second ed., Englewood Cliffs: Prentice-Hall, 1999. 823p.

HERRICK, R. R.; CURRAN, L. L.; BAER, A. T. A Mariner/MESSENGER global catalog of mercurian craters. **Icarus**. v. 215, n. 1, p. 452 – 454. 2011.

HU, Ming-kuei. Visual Pattern Recognition by Moment Invariants. **IRE Transactions on Information Theory**. p. 179 – 187. 1962.

JONES, R. Connected filtering and segmentation using component trees. **Computer Vision and Image Understanding**. v.75, n. 3, p. 215–228. 1999.

KIM, J. R.; MULLER, J. P.; GASSELT, S.; MORLEY, J. G.; NEUKUM, G. Automated crater detection, a new tool for Mars cartography and chronology. **Photogrammetric Engineering Remote Sensing**. v.71, n.10, p.1205 -1217. 2005.

KWONG, J. N. S.; GONG, S. Learning support vector machines for a multi-view face model. **In: Proceedings of the Tenth British Machine Vision Conference**. Nottingham, UK. 1999.

MARTINS, R.; PINA, P.; MARQUES, J. S.; SILVEIRA, M. Crater detection by a boosting approach. **IEEE Geoscience and Remote Sensing Letters**. v. 6, n. 1, p. 127 – 131. 2009.

MELOSH, H. J. **Impact Cratering: A Geologic Process**. Oxford University Press: New York, 1989. 245p.

MELOSH, H. J. **Planetary Surface Processes**. Cambridge University Press. 2011. 500p.

MESSENGER. Disponível em <<http://Messenger.jhuapl.edu/>>. Acesso em: 15 mai. 2013.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos de aprendizado de máquina. **In: S. O. Rezende**, editor, *Sistemas Inteligentes - Fundamentos e Aplicações*, p. 89–114. Editora Manole, 2003.

MÜLLER, K. R.; MIKA, S.; RÄTSCH, G.; TSUDA, K.; SCHÖLKOPF, B. An introduction to kernel-based learning algorithms. **IEEE Transactions on Neural Networks**. v.12, n.2, p.181 – 201. 2001.

MURCHIE, S.; ROBINSON, M.; HAWKINS, S. E. III.; HARCH, A.; HELFENSTEIN, P.; THOMAS, P.; PEACOCK, K.; OWEN, W.; HEYLER, G.; MURPHY, P.; DARLINGTON, E. H.; KEENEY, A.; GOLD, R.; CLARK, B.; IZENBERG, N.; BELL, J. F. III; MERLINE, W.; VEVERKA J. Inflight calibration of the NEAR multispectral imager. **Icarus**, v.140, n. 1, p. 66-91. 1999.

MURRAY, B. C.; BELTON, M. J. S.; DANIELSON, G. E.; DAVIES, M. E.; GAULT, D. E.; HAPKE, B.; O'LEARY, B.; STROM, R. G.; SUOMI, V.; TRASK, N. Mercury's surface: preliminary description and interpretation from Mariner 10 pictures. **Science**. v.185, p. 169-179. 1974.

MURRAY, B. C.; STROM, R. G.; TRASK, N. J.; GAULT, D. E. Surface history of Mercury: Implications for terrestrial planets. **Journal of Geophysical Research**. v.80, p.2508-2514. 1975.

NASA – MESSENGER / Mercury Orbit Insertion. Disponível em <http://www.nasa.gov/pdf/525164main_MercuryMOI_PK.pdf>. Acesso em: 15 jun. 2012.

NATIONAL GEOGRAPHIC. Disponível em <<http://books.nationalgeographic.com/map/map-day/>>. Acesso em: 26 Jan. 2015.

NEUKUM, G.; OBERST, J.; HOFFMANN, H.; WAGNER, R.; IVANOV, B. A. Geologic evolution and cratering history of Mercury. **Planetary and Space Science**. v.49, n. 14-15, p.1507-1521. 2001.

NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações**. São Paulo: Edgard Blucher, 2008. 363 p.

OSINSKI, G. R.; PIERAZZO, E. **Impact Cratering: process and products**. Wiley-Blackwell, 2012. 330p.

PAPAGEORGIOU, C.; OREN, M.; POGGIO, T. A general framework for object detection. **In: Proceedings of the Sixth International Conference on Computer Vision**. Bombay, India. 1998.

PASSERINI, A. Kernel Methods, multiclass classification and applications to computational molecular biology. 2004. 154f. **Tese**. (Engenharia da Computação e Controle) Università Degli Studi di Firenze. Florença, Itália.

PEDRINI, H; SCHWARTZ, W. R. **Análise de Imagens Digitais: princípios, algoritmos e aplicações**. 10 ed. São Paulo: Thomson, 2008. 508p.

PEDROSA, M. M. Detecção de Crateras de Impacto em Imagens Digitais. Estudo de caso: Superfície de Marte, 2011. 99 f. **Dissertação** (Ciências Cartográficas) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente – SP.

PELKEY, S. M.; B. M.; MELLON, M. T. Thermal Inertia of crater-related wind streaks on Mars. **Journal of Geophysical Research**. v. 106, p. 23909-23920. 2001.

PIKE, R. J. Geomorphology of impact craters on Mercury. **In: Vilas, F., Chapman, C. R., Mathewa, M. S.** (Eds), Mercury. University of Arizona Press, Tucson, AZ, p. 165-273. 1988.

PONTIL, M.; VERRI, A. Support vector machines for 3-D object recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. v. 20, n. 6, p. 637 – 646. 1998.

PROCKTER, L. M.; WATTERS, T. R.; CHAPMAN, C. R.; DENEVI, B. W.; HEAD III, J. W.; SOLOMON, S. C.; MURCHIE, S. L.; BARNOUIN-JHA, O. S.; ROBINSON, M. S.; BLEWETT, D. T.; GILLIS-DAVIS, J.; GASKELL, R. W. The curious case of Raditladi basin. **In: Proceeding of the XL Lunar and Planetary Science Conference**. The Woodlands, Texas, USA. 2009.

PROCKTER, L. M.; ERNST, C. M.; DENEVI, B. W.; CHAPMAN, C. R.; HEAD III, J. W.; FASSETT, C. I.; MERLINE, W. J.; SOLOMON, S. C.; WATTERS, T. R.; STROM, R. G.; CREMONESE, G.; MARCHI, S.; MASSIRONI, M. Evvidence for young volcanism on Mercury from the third Messenger flyby. **Science**. v. 329, p. 668 – 671. 2010

PROKOP, R. J.; REEVES, A. P. A survey of moment-based techniques for unoccluded object representation and recognition. **Graphical Models and Image Processing**. v.54, p. 438 – 460. 1992.

REBELO, L. D. T. Avaliação automática do resultado estético do tratamento conservador do cancro de mama. 2008. 68f. **Dissertação** (Engenharia Electrotécnica e de Computadores) – Faculdade de Engenharia da Universidade do Porto, Porto – PT.

ROBBINS, S. J.; HYNEK, B. M. A New Global Database of Mars Impact Craters ≥ 1 km: 2. Global Crater Properties and Regional Variations of the Simple-to-Complex Transition Diameter. **Journal of Geophysical Research**. v. 117, E05004, p. 1-18. 2012.

RODIONOVA, F. J.; DEKCHTYAREVA, K. I.; KHRAMCHIKHIN, A.; MICHAEL, G. G.; AJUKOV, S. V.; PUGACHEVA, S. G.; et al. Morphological catalogue of the craters of Mars. **ESA-ESTEC**. 2000.

SALAMUNICCAR, G.; LONCARIC, S. GT-57633 catalogue of Martian impact craters developed for evaluation of crater detection algorithms. **Planetary and Space Science**. v. 56, p. 1992 – 2008. 2008.

SALAMUNICCAR, G.; LONCARIC, S. Method for Crater Detection From Martian Digital Topography Data Using Gradient Value/Orientation, Morphometry, Vote Analysis, Slip Tuning, and Calibration. **IEEE Transactions on Geosciences and Remote Sensing**. v. 48, n. 5, p.2317-2329. 2010.

SALAMUNICCAR, G.; LONCARIC, S.; PINA, P.; BANDEIRA, L.; SARAIVA, J. MA130301GT catalogue of Martian impact craters and advanced evaluation of crater detection algorithms using diverse topography and image datasets. **Planetary and Space Science**. v. 59, p. 111-131. 2011.

SALAMUNICCAR, G.; LONCARIC, S.; PINA, P.; BANDEIRA, L.; SARAIVA, J. Integrated method for crater detection from topography and optical images and the new PH9224GT catalogue of Phobos impact craters. **Advances in Space Research**. v. 53, p 1798-1809. 2014.

SALAMUNICCAR, G. Crater detection from Mercurian digital topography and comparison with Lunar and Martian craters. **In: Proceeding of the XLIV Lunar and Planetary Science Conference**. The woodlands, Texas, USA. 2013.

SALEMBIER, P.; GARRIDO, L. Binary partition tree as an efficient representation for filtering, segmentation and information retrieval. **In: Proceeding of the IEEE International Conference on Image Processing**. Chicago, IL, USA. v. 2, p. 252 - 256. 1998.

SANTO, A. G.; GOLD, R. E.; McNUTT, R. L.; SOLOMON, S. C.; ERCOL, C. J.; FARQUHAR, R. W.; HARTKA, T. J.; JENKINS, J. E.; McADAMS, J. V.; MOSHER, L. E.; PERSONS, D. F.; ARTIS, D. A.; et al. The Messenger mission to Mercury: spacecraft and mission design. **Planetary and Space Science**. v.49, n. 14-15, p.1481-1500, 2001.

SCHÖLKOPF, B.; SMOLA, A.; MÜLLER, K. R. Kernel principal component analysis. **Advances in Kernel Methods – Support Vector Learning**. p. 327 – 352. 1999.

SDC Morphology Toolbox for Matlab 5, 2001. **Tutorial**. Naperville, USA.

SERRA, J. P. F. Introduction to mathematical morphology. **Computer Vision. Graphics and Image Processing**. v.35, n. 3, p. 283 – 308. 1986.

SHOEMAKER, E. M.; CHAO, E. C. T. New evidence for the impact origin of the Ries basin, **Journal of Geophysical Research**. v. 66, p. 3371-3378. 1961.

SHUFELT, J.; MCKEOWN, D. M. Fusion of monocular cues to detect man-made structures in aerial imagery. **Computer Vision and Image Understanding**. v. 57, n.3, p. 3007 – 330. 1993.

SILVA, A. G. Uso de árvore de componentes para filtragem, segmentação e detecção de padrões em imagens digitais. 2009. 123p. **Tese** (Doutorado em Engenharia Elétrica e de Computação) – Universidade Estadual de Campinas. Campinas.

SMOLA, A. J.; BARLETT, P.; SCHÖLKOPF, B.; SCHUURMANS, D. Introduction to large margin classifiers. In Smola, A. J., Barlett, P., Schölkopf, B., Schuurmans, D., editors, **Advances in Large Margin Classifiers**. p. 1-28. MIT Press. 1999.

SMOLA, A. J.; SCHÖLKOPF, B. Learning with Kernels. **Tutorial**. The MIT Press, Cambridge, Massachusetts, England. 2002. 38p.

SODERBLOM, L. A.; CONDIT, C. D.; WEST, R. A. Martian planet wide crater distributions: implications for geologic history and surface processes. **Icarus**. v. 22, n.3, p. 239 – 263. 1974.

SOILLE, P. **Morphological Image Analysis**. Berlin. 2 ed. Berlin: Springer - Verlag, 2003. 391p.

SOLOMON, S. C.; et al. The MESSENGER mission to Mercury: scientific objectives and implementation. **Planetary and Space Science**. v.49, p. 1445-1465. 2001.

STEPINSKI, T. F.; URBACH, E. R. Completion of the first automatic survey of craters on Mars. **In: Proceeding of the XI Mars Crater Consortium Meeting**. Pasadena, California. p.3. 2008.

STEPINSKI, T. F.; MENDENHALL, M. P.; BUE, B. D. Machine cataloging of impact craters on Mars. **Icarus**. v. 203, p. 77 – 87. 2009.

SURESH KUMAR, R.; LAVANYA, A.; VANI, K.; SANJEEVI, S. Texture Based Automatic Lunar-crater Detection and Mapping in Chandrayaan - 1 Image Data. **In: AI in Space: Intelligence beyond planet earth**, IJCAI. Barcelona, Espanha. 2011.

TANAKA, K. L. The stratigraphy of Mars. **Journal of Geophysical Research**. v. 91, p.139-158. 1986.

URBACH, E. R.; STEPINSKI, T. F. Automatic detection of sub-km craters in high resolution planetary images. **Planetary and Space Science**. v. 57, p. 880 – 887. 2009.

USGS. Disponível em <http://pubs.usgs.gov/gip/133/pdf/RemSens-Student_web.pdf>. Acesso em: 25 mar. 2013.

VAN ZYL, J. J. The Shuttle Radar Topography Mission (SRTM): a breakthrough in remote sensing of topography. **Acta astronautica**. v. 48, p. 559 – 565. 2001.

VIOLA, P.; JONES, M. Robust real-time object detection. **In: Proceeding of the VIII International Conference in Computer Vision**. v.2, p.747. 2001.

ZHANG, M. Bilateral Filter in Image Processing. 2009. 67f. **Tese** (Mestrado em Ciências em Engenharia Elétrica). Faculty of the Louisiana State University and Agricultural and Mechanical College, Louisiana.

WERNER, S. C. Moon, Mars, Mercury: Basin formation ages and implications for the maximum surface age and the migration of gaseous planets. **Earth and Planetary Science Letters**. v.400, p.54-65. 2014.

WETZLER, P.; HONDA, R.; ENKE, B.; MERLINE, W.; CHAPMAN, C.; BURL, M. Learning to detect small impact craters. **In: Proceeding of the VII IEEE Workshops on Application of Computer Vision**. v. 1, p. 178 – 184. 2005.