

Dissertação de Mestrado

Categorização de Formas de Lagos Amazônicos a partir de Imagens CBERS

Gilberto Pedro da Silva Júnior
gp7junior@gmail.com

Orientador:
Dr. Alejandro C. Frery

Maceió, Maio de 2012

Gilberto Pedro da Silva Júnior

Categorização de Formas de Lagos Amazônicos a partir de Imagens CBERS

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Modelagem Computacional de Conhecimento do Instituto de Computação da Universidade Federal de Alagoas.

Orientador: Dr. Alejandro C. Frery

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico
Bibliotecária: Fabiana Camargo dos Santos

S586c Silva Júnior, Gilberto Pedro da.

Categorização de Formas de Lagos Amazônicos a partir de
Imagens CBERS / Gilberto Pedro da Silva Júnior. – 2012
53 f. : il.

Orientador: Alejandro C. Frery.
Dissertação (Mestrado em Modelagem Computacional de
Conhecimento) – Universidade Federal de Alagoas. Instituto de
Computação. Maceió, 2012.

Bibliografia: f. 49–53.

1. Imagens – Análise – Lagos. 2. Imagens – Classificação.
3. Sensoriamento Remoto. 4. Estimador de máxima verossimilhança.
I. Título.

CDU: 004.932

Membros da Comissão Julgadora da Dissertação de Mestrado de Gilberto Pedro da Silva Júnior intitulada “Categorização de Formas de Lagos Amazônicos a partir de Imagens CBERS”, apresentada ao Programa de Pós-Graduação em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas em 31 de maio de 2012, às 15h00min, na sala de aula do Mestrado em Modelagem Computacional de Conhecimento. Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Curso de Mestrado em Modelagem Computacional de Conhecimento do Instituto de Computação da Universidade Federal de Alagoas, aprovada pela comissão examinadora que abaixo assina.

Dr. Alejandro C. Frery – Orientador
Instituto de Computação
Universidade Federal de Alagoas

Dr. Leonardo Pereira Viana – Examinador
Instituto de Computação
Universidade Federal de Alagoas

Dra. Sandra Aparecida Sandri – Examinador
Programa de Pós-Graduação em Computação Aplicada
Instituto Nacional de Pesquisas Espaciais

A minha mãe, Aparecida, e ao meu companheiro,
Marcos, dedico este trabalho.

RESUMO

Nesta dissertação propomos uma técnica de análise de imagens com o objetivo de categorizar lagos da bacia do rio Amazonas. As imagens estudadas são as geradas pelo sensor CBERS, e o procedimento consiste em extrair bordas, obter atributos de forma a partir dessas bordas classificá-los em uma dentre um número conhecido de classes. A classificação é feita por máxima verossimilhança gaussiana, e os melhores atributos em termos de expressividade e custo computacional são identificados por uma busca exaustiva.

Palavras-chave: Reconhecimento de Padrões. Lagos. Morfometria. Bacia Amazônica. Classificador de Máxima Verossimilhança Gaussiana.

ABSTRACT

In this thesis we propose a technique of image analysis in order to categorize lakes of the Amazon River basin. The images studied are generated by the sensor CBERS, and the procedure is to extract edges, in order to get features from these edges and classify them into one of a known number of classes. The classification process is made by maximum likelihood Gaussian classifier, and the best features in terms of expressiveness and computational cost are identified by an exhaustive search.

Keywords: Pattern Recognition. Lakes. Mathematical Morphometry. Amazon Basin. Maximum Likelihood Classifier.

AGRADECIMENTOS

Começo os agradecimentos falando da pessoa que mais me motivou a estudar e mais contribuiu para ser a pessoa que sou hoje. Durante minha infância minha mãe sempre me incentivou aos estudos e continuou assim até eu entrar na faculdade, onde continuamente ela estava do meu lado me dando forças para vencer cada batalha. Ao meu irmão Flávio e minha irmã Kézia que muito me ajudaram.

Aos meus amigos do mestrado Leonardo Torres, Davy Baia, Fabiano Brião, Rodrigo Pinheiro, Marcelo Queiroz e Felipe Prata. Agradeço por todas as horas de estudo que passamos juntos.

Aos meus amigos que estão no Rio de Janeiro: Emanuela Toledo por ter ser a grande amiga que é, Paulo Rogério por toda a ajuda que me deu no \LaTeX e Bruno Lopes pela amizade sincera que me faz bem.

Aos que passaram pelo LaCCAN: Jônathas Nunes e Wylken Santos por terem me ajudado no início dessa pesquisa. Não posso esquecer também da Deise e de nossos almoços. E do Tony por todo suporte dado.

Agradecimentos especiais a todos que fizeram meu semestre em Belo Horizonte muito produtivo: Evellyn, Dona Goreti, Letícia Decker, Philipe Samer, e claro Loureiro.

Agradeço infinitamente a Marcos Nicolau, meu companheiro que me deu palavras de consolo quanto eu estava triste, de incentivo quando eu achava que não ia conseguir, elogios quando eu não merecia, e o mais importante paciência sempre.

Também gostaria de lembrar das pessoas que chegaram no finalzinho do meu trabalho e merecem ser citadas: Larissa Peixoto, Israel Vasconcelos, Guilherme Medeiros, Raquel Queiroz.

A profa Eliana por sempre agir com muita classe e beleza em tudo que faz.

Pedro Almodóvar e por sua filmografia que me faz querer viver a vida mais intensamente.

E por último e nem perto de ser menos importante ao professor Alejandro, que mais que um orientador foi um verdadeiro pai, orientando não só academicamente mas me dando lições de vida, e por provar que posso mais do que acredito poder.

O presente trabalho foi realizado com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil.

Gilberto P. da S. Júnior

“Por suerte, la naturaleza me ha dotado de una curiosidad irracional hasta para las cosas más nimias. Eso me salva. La curiosidad es lo único que me mantiene a flote. Todo lo demás me hunde. ¡Ah! Y la vocación. No sé si sería capaz de vivir sin ella.”

Pedro Almodóvar

LISTA DE FIGURAS

2.1	Exemplos de Máscaras Para Detecção de Pontos e Linhas	18
3.1	Metodologia de Desenvolvimento da Pesquisa	24
3.2	Imagem original e bordas detectadas	33
3.3	Aquisição de dados para Análise de Fourier de Raios igualmente espaçados.	36
3.4	Reconstrução de Bordas por Análise de Fourier em Raios igualmente espaçados.	37
3.5	Análise de Fourier aplicada ao ângulo da tangente em função do perímetro	38
3.6	Reconstrução de borda a partir de Análise Elíptica de Fourier	39
4.1	Índice de Acurácia por Atributo para a Análise Univariada	48
4.2	Verossimilhanças para cada classe segundo o melhor atributo univariado	49
A.1	Amostras da Classe C1 utilizadas no conjunto de Treinamento	54
A.2	Amostras da Classe C1 utilizadas no conjunto de Teste	55
A.3	Amostras da Classe 2 utilizadas no conjunto de Treinamento	56
A.4	Amostras da Classe C2 utilizadas no conjunto de Teste	57
A.5	Amostras da Classe C3 utilizadas no conjunto de Treinamento	58
A.6	Amostras da Classe C3 utilizadas no conjunto de Teste	59
A.7	Amostras da Classe C4 utilizadas no conjunto de Treinamento	60
A.8	Amostras da Classe C4 utilizadas no conjunto de Teste	61

LISTA DE TABELAS

3.1	Valores de F atribuídos a forma	25
3.2	Características, Resoluções e Frequências das Câmaras do Satélite CBERS-2	30
3.3	Tamanho e número de bandas dos instrumentos no CBERS-2	30
3.4	Características Paisagísticas de Sistema Lacustre por tipo de Lago	31
3.5	Principais Funções Utilizadas do pacote <i>biOps</i>	33
3.6	Matriz de Confusão para Sistema com duas Classes	44
4.1	Matriz de Confusão Atributo $a_n, n = 9, AC = 0.588$	47
4.2	Matriz de Confusão Atributo $r = 1, AC = 0.588$	48

LISTA DE EQUAÇÕES

2.1 Exemplo de uma Máscara de Resposta	17
2.2 Função genérica para processo de convolução.	17
2.3 Gradiente da Imagem Intensidade	18
2.4 Função Magnitude Gradiente	18
2.5 Máxima Diferença Absoluta entre Pixels Vizinhos	18
2.6 Máscara de Roberts	19
2.7 Aproximação Prewitt	19
2.8 Máscara de Prewitt	19
2.9 Máscara de Sobel	20
2.10 Máscara de Robinson	20
2.11 Distribuição Gaussiana	20
2.12 Derivada da Distribuição Gaussiana	20
2.13 Convolução Bidimensional	21
3.1 Índice F	25
3.2 Expressão geral de Fourier para uma função periódica	35
3.3 Forma Exponencial de uma função periódica $f(t)$	35
3.4 Representação de raios r como uma função periódica do ângulo θ	36
3.5 Estimador de Máxima Verossimilhança para a média	41
3.6 Estimador de Máxima Verossimilhança para a matriz de covariância	41
3.7 Teorema de Bayes	42
3.8 Regra do Classificador	43
3.9 Classificador de Máxima Verossimilhança	43
3.10 Acurácia de uma Matriz de Confusão	44
3.11 Sensibilidade de uma Matriz de Confusão	44
3.12 Especificidade de uma Matriz de Confusão	44
3.13 Precisão de uma Matriz de Confusão	44
3.14 Taxa de Erro de C1	44
3.15 Taxa de Errp de C2	44

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Definição do Problema	9
1.2	Revisão Bibliográfica	9
1.3	Contribuições	11
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	Tipos de Lagos	13
2.2	Análise de Formas	14
2.3	Detecção de Bordas	16
2.3.1	Operadores para Detecção de Bordas	16
2.3.2	Segmentação e Máscaras para Segmentação	17
2.3.3	Detectores de Bordas	18
2.3.4	Operador de Canny para Detecção de Bordas	20
3	METODOLOGIA	23
3.1	Materiais e Métodos	23
3.2	Morfometria de Um Lago	24
3.3	Sensoriamento Remoto de Lagos	26
3.3.1	O Satélite CBERS	26
3.4	Seleção das Áreas de Interesse	31
3.5	Processamento de Imagens com a Plataforma R	31
3.6	Binarização	33
3.7	Extração de Atributos e Características	34
3.7.1	Análise Fourier Aplicada à Variação de Raios em Bordas Fechadas	36
3.7.2	Análise Fourier do Ângulo Tangente	37
3.7.3	Análise Elíptica de Fourier	37
3.8	Sistema de Classificação	40
3.8.1	Media e Covariância Desconhecidas	40
3.8.2	Classificador de Máxima Verossimilhança	41
3.9	Métricas de Qualidade do Classificador	43
3.9.1	Matriz de Confusão	43
4	RESULTADOS E ANÁLISES	46
4.1	Comentários sobre a qualidade do treinamento	46
4.2	Eficácia do Classificador	47
5	CONCLUSÕES	51
A	AMBIENTE REPRODUTÍVEL E COMPUTACIONAL	53
A.1	Amostras	53
	Referências Bibliográficas	62

1

INTRODUÇÃO

1.1 Definição do Problema

A motivação para o desenvolvimento dessa pesquisa surge com a necessidade de se estabelecer padrões para a identificação remota de lagos através de imagens de satélite. O método clássico de extração de atributos de lagos consiste em realizar diversas visitas ao campo, que levam tempo e podem ser dispendiosas. Com o sucesso dessa pesquisa teremos uma ferramenta capaz de identificar de forma otimizada e precisa características morfométricas de lagos, evitando assim as trabalhosas pesquisas em campo.

1.2 Revisão Bibliográfica

Pelo menos 20% da extensão da bacia Amazônica está constituída por áreas alagáveis margeando os rios. Calcula-se que entre 400.000 km² e 500.000 km² destas áreas são ocupadas por lagos, floresta alagável e vegetação flutuante, sendo que somente a floresta de várzea ocupa cerca de 100.000 km² (Junk & Piedade, 1993; Junk, 1989; Goulding et al., 1995). Os lagos são essenciais para a sustentabilidade dos recursos naturais da Amazônia e componentes importantes das áreas inundáveis. Por exemplo, somente na bacia do Solimões-Amazonas os lagos ocupam cerca de 11% da calha desses dois rios, que inclui 62.000 km² de várzea.

Os lagos amazônicos são superfícies de águas abertas situadas tanto na várzea quanto na terra firme. Esta definição é meramente operacional, visto que as versões do conceito de lago disponível na literatura são aplicáveis a regiões temperadas. Segundo Esteves (1988), os lagos na Amazônia são derivados da atividade fluvial, sendo possível definir três grupos conforme sua posição no terreno e forma: lagos de meandro ou ferradura, lagos de barragem ou

de terra firme e lagos de laterais ou de várzea. Tomando a forma do lago como principal critério de classificação existem cinco expressões morfológicas diferentes; redondo-oval, ferradura, dendrítico-alongado, dendrítico-ramificado e composto-irregular (Nolan et al., 2009; Junk, 1985; Hutchinson, 1975; Sieppel et al., 1992; Melack & Setaro, 1984).

A classificação generalizada das águas da bacia amazônica em branca, preta e clara foi proposta por Harold Sioli há mais de 20 anos e foi validada por vários estudos limnológicos realizados posteriormente (Sioli, 1982). Os rios de água branca nascem na região Andina ou Pré-Andina, carregam uma grande quantidade de material em suspensão oriundo principalmente de formações geológicas como as morenas, depositadas em períodos glaciários, ou da própria erosão dos profundos vales presentes nos Andes Orientais.

Os lagos Amazônicos associados aos rios de águas brancas, originados na Cordilheira dos Andes, fazem parte de um mosaico de diferentes ambientes de origem fluvial que no seu conjunto compõem a várzea. Sazonalmente, e conforme o ciclo de inundação do rio, esses ambientes se interconectam entre si e o rio principal. Os trabalhos de Junk et al. (1997); BR et al. (1993); Forsberg et al. (1988) quantificaram em torno de 8500 lagos amazônicos, incluindo áreas que não fazem parte da Amazônia brasileira. Cerca de 5010 lagos têm forma oval, 1530 são laterais, 830 dendríticos, 270 ferraduras, 270 compostos e 140 crescentes.

Estes sistemas lacustres da várzea são altamente produtivos. Nestes lagos, o nitrogênio e o fósforo são os principais nutrientes limitantes da produção primária, devido à mistura entre as águas do rio principal com as águas locais. Segundo Forsberg et al. (1988), os níveis de alcalinidade da mistura são influenciados pela relação entre a área da bacia de drenagem e a área do lago. Entretanto, Junk et al. (1997) e Kern et al. (1996) consideram que as mudanças físico-químicas dos lagos de várzea seriam determinadas pela relação zona de transição aquática/terrestre e área da bacia do lago (ATTZ – *Aquatic/Terrestrial Zone/LBA – Lake Basin Area*) e a área do lago, portanto, a importação e exportação de nutrientes varia consideravelmente com as diferenças na amplitude do pulso de inundação.

Os sistemas de lagos de barragem ou lagos dendríticos Amazônicos estão localizados na terra firme. Sua forma é ramificada, não sendo possível definir um eixo principal. Os estudos mais recentes evidenciam que estes ambientes lacustres apresentam maior complexidade espacial e heterogeneidade ambiental que os lagos de várzea. Este fato poderia lhes conferir maior estabilidade funcional e mecanismos de retroalimentação, disponibilizando uma maior quantidade de habitats de refúgio, alimentação e reprodução para os peixes e, finalmente, influenciar nos níveis de produção (Nolan, 2000).

Diante da complexidade espaço-geográfica dos sistemas dendríticos amazônicos e de sua importância para a manutenção das cadeias tróficas dos peixes, é possível destacar a importância de aspectos morfológicos e morfométricos de lagos e rios como geradores de micro-habitats que podem representar elementos chave para o equilíbrio dinâmico dos diferentes ecossistemas aquáticos da Amazônia. Em regiões neotropicais, as principais medidas morfométricas consideradas são os valores de área e comprimento de diferentes ele-

mentos da paisagem. [Petrere et al. \(1999\)](#); [Welcomme \(1976, 1992, 1990\)](#); [Bayley \(1981\)](#); [Bayley & Petrere \(1989\)](#) derivaram um grupo de modelos para rios africanos e amazônicos, para prever a produção pesqueira destes rios. Com medidas de área e comprimento realizaram também diferentes comparações entre os sistemas asiáticos, africanos e latino-americanos.

Diante deste quadro, é possível destacar a importância de aspectos morfológicos e morfométricos dos sistemas aquáticos Amazônicos, que podem ser utilizados tanto como preditores dos diferentes níveis de produção, como parâmetros ambientais aplicados na elaboração de modelos que expliquem variações na abundância de populações de peixes.

Apesar da condição essencial dos lagos para a sustentabilidade dos recursos ícticos no contexto amazônico, seja pela sua representatividade, seja pela sua importância na produtividade desses ecossistemas, são poucos os antecedentes científicos sobre a contribuição das propriedades morfométricas dos ambientes lacustres na Amazônia Central. Isto mostra claramente a carência de uma abordagem que avalie a condição, a capacidade e importância dos sistemas e ambientes explorados pela pesca, para que seja possível identificar lagos com potencial para conservação e para exploração pesqueira na Amazônia Central.

Na pesca, a importância dos sistemas lacustres se reflete também pelos valores de exploração calculados. Por exemplo, para o período de 1994–1996, a frota pesqueira de Manaus explorou 277 lagos, com tamanho variando entre menos de 100 hectares até mais de 300 hectares, com um rendimento médio total por área de 7,27 toneladas de pescado por hectare ([Nolan, 2000](#)).

Além disso, tanto peixe quanto pescador estão sujeitos a diferentes níveis de complexidade espacial representados pelas distintas formas de lagos, o que determinou diferenças significativas nos níveis de rendimento pesqueiro durante o período de 1994–1996 ([Nolan et al., 2009](#)).

O Projeto LBA – *Large-Scale Biosphere-Atmosphere Experiment in Amazonia* – indica que para a compreensão do ciclo do carbono na Amazônia se requer mais do que simples medições, em pontos espalhados. Neste sentido, sugere-se a estratificação e compilação de ambientes com dados de sensoriamento remoto disponíveis do JERS - *Japanese Earth Resources Satellite* - e do SRTM - *Shuttle Radar Topography Mission*; segmentação para cada ambiente; e sensoriamento remoto e biometria feitos com base nesses ambientes ([Nobre, 2004](#)).

1.3 Contribuições

O trabalho proposto faz uso de modelos computacionais que representam os atributos morfométricos e, através de técnicas de reconhecimento de padrões, realiza classificações automáticas quanto à forma do lago.

Outra contribuição relevante deste trabalho é a obtenção de dados morfométricos de

lagos de forma automatizada, além de ser um método mais preciso de coleta de dados é também mais econômico pois não será mais necessária a locomoção de equipes a locais de interesse de análise.

Neste capítulo, vimos uma breve introdução aos principais termos da pesquisa. A definição do problema foi apresentada, bem como a motivação para o desenvolvimento do trabalho. O capítulo foi finalizado apresentado de uma maneira sucinta as colaborações que essa pesquisa proporciona para as áreas envolvidas.

2

FUNDAMENTAÇÃO TEÓRICA

O objetivo desse capítulo é definir e sintetizar conceitos que serão utilizados no decorrer do trabalho.

2.1 Tipos de Lagos

Lagos são superfícies de águas abertas situadas tanto na várzea quanto na terra firme.

Os tipos de lagos são definidos com base nos trabalhos de [Hutchinson \(1975\)](#); [Cole \(1979\)](#); [Melack & Setaro \(1984\)](#); [Sieppel et al. \(1992\)](#); [Junk \(1984\)](#). Esses trabalhos sobre classificação de lagos quanto à sua forma foram realizados também com base na bacia amazônica. Essa definição se baseia quanto a origem e ao tipo do lago levando-se em conta sua formação. Eles podem ser:

Lagos laterais: São lagos situados muito próximo a grandes rios. São formados devido ao acúmulo de sedimentos trazidos pelos rios que possibilitam a criação de 'represas naturais'.

Lagos de meandro: A dinâmica dos rios em planícies pode fazer um curso sinuoso. Quando a curvatura é muito acentuada, especialmente depois de uma enchente, quando o rio recupera seu curso em linha reta, essas curvaturas são abandonadas formando esse tipo de lago.

Lagos de barragem: São frequentes nas altas montanhas, onde os obstáculos formados por detritos dão origem a barragens, logo cobertas por água.

Contudo, a classificação utilizada nesse trabalho se baseia nas formas dos lagos. Logo, temos:

Redondo-Oval: possuem forma circular, subcircular e elíptica na concepção de Hutchinson.

Dendrítico: aspecto ramificado semelhante a um neurônio ou uma raiz. Dividem-se em: Dendrítico Alongado e Dendrítico Ramificado.

Ferradura: são geralmente lagos de meandro abandonados pelo rio e recebem esse nome por possuir sua forma parecida com a de uma ferradura.

Composto-Irregular: forma indefinida ou combinação de formas.

Nolan (2000) utiliza essa classificação e baseado em imagens satelitais e de radar subdivide a classificação de dendrítico em dendrítico alongado e dendrítico ramificado.

A classe de lagos 'Redondo-oval' foi separada também em 'Redondo-alongado' por possuir uma certa distinção em sua forma. As classes de lagos utilizadas nessa pesquisa foram:

C1 Redondo Oval;

C2 Redondo Alongado;

C3 Dendrítico Ramificado;

C4 Dendrítico Alongado.

2.2 Análise de Formas

Avanços computacionais tem trazido grandes possibilidades para a captura e análise de formas de objetos. Essas informações podem ser utilizadas para solucionar questões importantes em disciplinas como a biologia, medicina, arqueologia e visão computacional, dentre outras (Amaral, 2004).

Alguns procedimentos devem ser tomados para podermos representar matematicamente a forma de um objeto de uma maneira conveniente. Uma forma objetiva consiste em estabelecer pontos referenciais no objeto, que identificam propriedades especiais do objeto. As coordenadas numéricas desses pontos de referência são utilizadas para representar um objeto às quais pertencem, ao que chamamos de espaço vetorial de referências (Kendall, 1984).

O novo conjunto de coordenadas do objeto é chamado de coordenadas de pre-forma, podendo ser obtido a partir de um conjunto de coordenadas de um espaço vetorial de referência, aplicando-se transformações que removem os efeitos de escala e translação, os quais não são interessantes para essa análise. Esse novo sistema de coordenadas também representa um mapeamento do espaço vetorial de referência para um novo espaço chamado de espaço vetorial de pré-forma.

As coordenadas de pre-forma servem principalmente para obter a média da forma e sua matriz produto. A matriz produto representa a variação das coordenadas de pre-forma e a média da forma é definida como o autovetor associado ao maior autovalor dessa matriz.

A forma é finalmente obtida removendo as coordenadas de rotação da pre-forma, essa eliminação é realizada rotacionando o objeto até que ele fique o mais parecido possível do modelo. O novo conjunto de coordenadas do objeto estão em um novo espaço chamado espaço vetorial de forma. Esses espaços vetoriais não são euclidianos¹, com isso é difícil realizar qualquer análise estatística nesses espaços.

Com o objetivo de minimizar tais dificuldades inerentes aos espaços vetoriais não euclidianos, é possível definir uma aproximação linear para esse espaço. Um espaço tangente é uma aproximação linear local em um ponto particular. As novas coordenadas são chamadas de coordenadas da tangente. Métodos de inferência em análises de forma são frequentemente utilizados no espaço da tangente. Nesse espaço grande parte dos processos de análise multivariada linear padrão já podem ser utilizadas (Amaral, 2004).

Os conceitos de espaço de forma foram apresentados primeiramente por Kendall (1984), como também um sistema de coordenadas conhecido como sistema Kendall de coordenadas, nesse sistema a localização é removida utilizando a matriz de Helmert também conhecida como a transformada de Helmert². Outra importante contribuição de Kendall (1984) foi a definição matemática da forma, definida como um conjunto de k pontos e m dimensões.

Em paralelo existe também o sistema de coordenadas de Bookstein (1986) que exclui os efeitos de rotação, translação e escala. Esse autor fornece a base matemática para o estudo da morfometria, e a análise dos objetos depende de qual área de pesquisa se está trabalhando como biologia ou medicina, e os pontos de interesse do objeto são selecionados de acordo com as peculiaridades de cada aplicação.

É possível estabelecer uma conexão entre essas duas teorias. Kendall rotulou um conjunto de k pontos em m dimensões correspondente aos pontos de referencia de Bookstein. Apesar de usarem diferentes maneiras de calcular o tamanho em diferentes sistemas de coordenadas, suas idéias são bastante similares no sentido da representação da forma de um objeto como um ponto num conjunto de pontos (Bookstein, 1986; Kendall, 1984; Amaral, 2004).

Um outro autor que muito contribuiu para a análise de formas foi Goodall. Ele considera a Análise de Procruste³ como um método para estimação de um conjunto particular de objetos, transformações ótimas de escala, transformação de rotação e transformação de translação. Goodall definiu a média da forma através da análise de Procruste, se a soma dos quadrados das distâncias entre um ponto e as pre-formas é mínima, então esse ponto é tomado como sendo a média da forma. Esse autor ainda desenvolveu muitos algoritmos para análise procruste (Goodall, 1991).

¹Espaço euclidiano é um espaço vetorial real de dimensão finita munido de um produto interno.

²é um método de transformação dentro de um espaço tridimensional. É frequentemente usada em geodésia para produzir sem distorção transformações de um dado para outro

³É uma técnica de análise de forma estatística utilizada para analisar a distribuição de um conjunto de formas.

2.3 Detecção de Bordas

Na área de geoprocessamento encontramos várias definições do processo de detecção de bordas e segmentação de imagens. No Tutorial de Geoprocessamento disponível no site do projeto SPRING⁴ encontramos a seguinte definição:

Segmentação de Imagens constitui um processo de análise de pixels de forma isolada. Esta abordagem apresenta a limitação da análise pontual ser baseada unicamente em atributos espectrais (Bins et al., 1996).

Para superar estas limitações, propõe-se o uso de segmentação de imagem, anterior à fase de classificação, onde se extraem os objetos relevantes para a aplicação desejada. Neste processo, divide-se a imagem em regiões que devem corresponder às áreas de interesse da aplicação. Entende-se por regiões um conjunto de “pixels” contíguos, distribuídos bidirecionalmente e que apresentam uniformidade (dos Santos et al., 2010; Câmara et al., 1996).

Detecção de borda é uma técnica de processamento de imagens para determinar pontos de uma imagem digital em que a intensidade luminosa muda repentinamente. Mudanças repentinas em imagens geralmente refletem eventos importantes no cenário, como a descontinuidade da profundidade (transição entre o objeto e o fundo), descontinuidade da orientação da superfície, mudança das propriedades do material ou variações na iluminação da cena.

A detecção de borda é bastante usada na área de extração de características. Sua utilização reduz significativamente a quantidade de dados a serem processados, e descarta informação que é considerada menos relevante, ainda que preservando importantes propriedades estruturais de uma imagem. A detecção pode ser prejudicada por bordas falsas criadas por ruídos na imagem (provenientes da digitalização, compressão ou pelo processo de captura da imagem). Isso pode ser amenizado ao utilizar alguma técnica de redução de ruído antes da detecção de borda.

2.3.1 Operadores para Detecção de Bordas

Borda é o contorno entre um objeto e o fundo indicando o limite entre objetos sobrepostos. É uma linha fechada formada pelos limites de um objeto. Bordas são definidas como picos da magnitude do gradiente, ou seja, são variações abruptas que ocorrem ao longo de curvas baseadas nos valores do gradiente da imagem. As bordas são regiões da imagem onde ocorre uma mudança de intensidade em um certo intervalo do espaço, em uma certa direção.

A aquisição de imagens está sujeitas a vários tipos de ruído. A situação ideal, sem ruído, na prática não existe. Ruídos não podem ser previstos pois são de natureza aleatória e não

⁴O SPRING é um SIG (Sistema de Informações Geográficas) no estado-da-arte com funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta a bancos de dados espaciais.

podem nem mesmo ser medidos precisamente. Porém, algumas vezes eles pode ser caracterizados pelo efeito ocasionado na imagem, e são geralmente caracterizados por meio de distribuições de probabilidade de forma paramétrica ou semi-paramétrica (com uma média e um desvio padrão, por exemplo).

2.3.2 Segmentação e Máscaras para Segmentação

Não existe um único modelo formal para a segmentação de imagens. O processo é essencialmente empírico e se ajusta a diferentes tipos de imagem. Esta etapa é a mais difícil do processo e também a mais delicada porque todas as medidas serão realizadas sobre as regiões identificadas nesta etapa.

A segmentação é complexa porque tenta traduzir para o computador um processo cognitivo extremamente sofisticado realizado pela visão. Algoritmos de segmentação podem ser utilizados para:

Detecção de Pontos: Um ponto possui uma mudança drástica do valor de cinza em relação ao seu vizinho.

Detecção de Linhas: Procura-se pixels semelhantes e verifica-se se fazem parte da mesma linha.

Detecção de Bordas: Localização e realce dos pixels de borda, aumentando o contraste entre o pixel de borda e o fundo.

Os algoritmos de segmentação frequentemente utilizam máscaras sobre os pixels da imagem para detecção de uma descontinuidade. Cada pixel e seus pixels vizinhos tem um valor do nível de cinza multiplicados por uma constante.

$$\begin{bmatrix} m_1 & m_2 & m_3 \\ m_4 & m_5 & m_6 \\ m_7 & m_8 & m_9 \end{bmatrix} * \begin{bmatrix} p_1 & p_2 & p_3 \\ p_4 & p_5 & p_6 \\ p_7 & p_8 & p_9 \end{bmatrix} = m_1 p_1 + m_2 p_2 + \dots + m_9 p_9 = \sum_{i=1}^9 m_i p_i \quad (2.1)$$

Na equação (2.1) m_i é o valor da máscara correspondente a p_i , o nível de cinza do pixel.

A Convolução é uma técnica que pode ser incorporada em várias funções em processamento de imagens. A máscara de convolução de lado ℓ (ímpar) é um importante conceito neste processo, e pode ser definida por um conjunto de valores reais $w = w(i, j)$ com $-(\ell - 1)/2 \leq i, j \leq (\ell - 1)/2$, onde o ponto central da máscara é (0,0). A equação genérica de convolução é dada por

$$g(x, y) = \sum_{i, j} f(x + i, y + j) w(i, j), \quad (2.2)$$

Percorrendo a imagem linha por linha, uma nova matriz é criada semelhante à imagem original, porém contendo os valores da máscara de resposta ao invés do valor do pixel. Es-

tes valores da máscara de resposta podem então ser comparados com o valor mínimo de limiar (*threshold*)⁵ para determinar quais pixels são mais prováveis de ser parte de uma borda. Este limiar é ajustado para variar seletivamente de acordo com os pixels de borda, permitindo conduzir o algoritmo para um melhor desempenho para uma imagem específica.

$$\begin{array}{ccccc} \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix} & \begin{bmatrix} -1 & -1 & -1 \\ 2 & 2 & 2 \\ -1 & -1 & -1 \end{bmatrix} & \begin{bmatrix} -1 & 2 & -1 \\ -1 & 2 & -1 \\ -1 & 2 & -1 \end{bmatrix} & \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix} & \begin{bmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \\ 2 & -1 & -1 \end{bmatrix} \\ \text{(a)} & \text{(b)} & \text{(c)} & \text{(d)} & \text{(e)} \end{array}$$

Figura 2.1: Exemplos de Máscaras Para Detecção de Pontos e Linhas

A figura 2.1 apresenta exemplos de máscaras para diferentes casos de detecção. Detecção de um ponto isolado 2.1(a), detecção de linhas horizontais 2.1(b), linhas verticais 2.1(c), e linhas oblíquas a 45° 2.1(d) e 2.1(e). Na figura 2.1(c), 2.1(b), 2.1(d), 2.1(e) os valores centrais das máscaras são pontos de descontinuidade, portanto seriam pixels de borda.

2.3.3 Detectores de Bordas

O principal objetivo da detecção de bordas é extrair informações sobre a projeção bidimensional geométrica da imagem para uso processamento de alto nível como reconhecimento de padrões. Vamos referenciar uma imagem como $f(x,y)$. Para identificar as bordas, estamos interessados na busca de regiões da imagem onde há uma rápida mudança nos valores de $f(x,y)$.

Assim, consideramos propriedades diferenciais locais, tais como o gradiente da imagem intensidade. A equação (2.3) define uma grandeza vetorial que pode ser vista de forma intuitiva como “na direção da descida mais brusca” em cada ponto (x,y) .

$$\nabla f = \left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right)^T. \quad (2.3)$$

Uma importante função escalar é a magnitude gradiente, dada pela equação (2.4), também conhecida como “Magnitude Gradiente Quadrado”. Gonzalez (2002), defende que a utilização da função magnitude gradiente na detecção de bordas é computacionalmente muito cara. O que se faz na prática é aproximação da equação (2.4) para a forma (2.5).

$$\|\nabla f\|^2 = \left(\frac{\partial f}{\partial x} \right)^2 + \left(\frac{\partial f}{\partial y} \right)^2. \quad (2.4)$$

$$\nabla f(x,y) = \max|[f(x,y) - f(x+1,y) + f(x,y) - f(x,y+1)]|. \quad (2.5)$$

⁵Um valor de referencia para validar os dados.

Operador de Roberts

O operador de Roberts é o mais antigo e simples dos algoritmos de detecção de bordas. Utiliza uma matriz 2×2 para encontrar as mudanças nas direções x e y . A soma de todos os coeficientes da máscara é igual a 0, como também, a soma das diagonais. Já em regiões em que os pixels estão situados entre duas fronteiras o resultado do operador é diferente de zero, dando origem à borda ou contorno da região.

$$G_x = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix} G_y = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \quad (2.6)$$

Operador de Prewitt

O operador de Prewitt é uma máscara de tamanho 3×3 utilizada na detecção de bordas com um princípio de detecção similar ao utilizado pelo operador cruzado de Roberts. Para os pixels no interior das regiões de valor constante o valor de R é igual a zero, nas fronteiras ou bordas da imagem o valor de R é diferente de 0.

Podem ser utilizados com aproximações como a encontrada na equação (2.7).

$$\nabla f = |(p_7 + p_8 + p_9) - (p_1 + p_2 + p_3)| + |p_3 + p_6 + p_9) - (p_1 + p_4 + p_7)|. \quad (2.7)$$

Em (2.8) vemos os operadores de Prewitt nas direções horizontal e vertical respectivamente. As diferenças entre a primeira e a terceira linha aproxima a derivada na direção x , e a diferença entre a primeira e a terceira coluna aproxima a derivada na posição y .

$$G_x = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} G_y = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad (2.8)$$

Operador de Sobel

A extração de bordas pode ser realizada por um algoritmo de detecção de bordas, conhecido como filtro de Sobel. O algoritmo considera os gradientes de nível de cinza da imagem original, para gerar uma imagem gradiente ou imagem de intensidade de borda:

- Calcula-se um limiar para a perseguição de bordas.
- Quando se encontra um "pixel" com valor superior ao limiar estabelecido, dá-se início o processo de perseguição da borda.
- Observa-se a vizinhança para identificar o próximo "pixel" de maior valor de nível digital e segue-se nesta direção até que se encontre outra borda ou a fronteira da imagem.

Deste processo gera-se uma imagem binária com os valores de 1 referentes às bordas e 0, a regiões de não-bordas (dos Santos et al., 2010).

A imagem binária será rotulada de modo que as porções da imagem com valores 0 constituirão regiões limitadas pelos valores 1 da imagem.

$$G_x = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} G_y = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (2.9)$$

Na equação (2.9) apresenta-se o operador de Sobel nas direções horizontal e vertical respectivamente. A desvantagem desse método é que o deslocamento da máscara ou é realizado no eixo x ou no eixo y , ou seja, só detecta bordas nestas direções.

Operador de Robinson

O operador de Robinson é similar em operação ao de Sobel, porém usa um conjunto de oito máscaras, onde quatro delas estão em (2.10). As outras quatro são negações das expostas em (2.10). A magnitude do gradiente é o valor máximo obtido ao aplicar todas as oito máscaras ao pixel vizinho, e o ângulo do gradiente pode ser aproximado como o ângulo na linha de zeros na máscara dando a resposta máxima. Esse algoritmo requer mais computação que do que Roberts e Sobel, devido ao tamanho das máscaras.

$$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \begin{bmatrix} 2 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -2 \end{bmatrix} \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \begin{bmatrix} 0 & -1 & -2 \\ 1 & 0 & -1 \\ 2 & 1 & 0 \end{bmatrix} \quad (2.10)$$

2.3.4 Operador de Canny para Detecção de Bordas

Canny (1986) propôs um filtro com o objetivo de contornar os problemas com ruídos, no qual a imagem é convoluída com as derivadas de primeira ordem do filtro Gaussiano para a suavização na direção do gradiente local seguido pela detecção de bordas pelo uso de limiares.

A distribuição Gaussiana é expressa por

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(\frac{-x^2}{2\pi\sigma^2}\right) \quad (2.11)$$

e sua derivada é

$$G'(x) = \frac{-x}{\sqrt{2\pi\sigma^3}} \exp\left(\frac{-x^2}{2\pi\sigma^2}\right) \quad (2.12)$$

A convolução é relativamente simples de ser computada, mas é custosa computacionalmente, especialmente se for bidimensional, dada por:

$$G(x,y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (2.13)$$

O objetivo principal desse algoritmo é obter um método ótimo de detecção de bordas, o que significa:

1. marcar tantas bordas quanto possível. O detector deverá detectar e achar somente bordas e nenhuma borda deverá faltar.
2. bordas marcadas devem estar mais próximas o possível da borda real. A distância entre os pixels encontrados pelo detector e a borda atual, deverá ser a menor possível.
3. cada borda da imagem deve ser marcada uma única vez, e o ruído da imagem não deve criar bordas falsas. O detector não deve encontrar múltiplos pixels onde somente exista um único pixel.

Etapas do algoritmo (Canny, 1986):

1. **Uniformização da imagem:** A imagem é uniformizada por uma função gaussiana bidimensional de tamanho especificado por um parâmetro usual. Na prática, convoluções gaussianas bidimensionais de tamanho elevado, levam muito tempo para serem processadas, portanto é comum aproximá-las por duas funções gaussianas unidimensionais, uma no eixo x e a outra no eixo y . Isso resulta em dois valores para cada pixel.
2. **Diferenciação:** Considerando a convolução bidimensional apresentada no estágio anterior, a imagem uniformizada é separada nas direções x e y . Assim é possível calcular o gradiente da superfície uniforme da imagem convolucionada. Uma borda em uma imagem pode estar em vários sentidos. Assim 4 máscaras são usadas para detectar bordas horizontais, verticais e diagonais.
3. **Omissão de pontos de mínima intensidade :** Encontrada a medida da intensidade de cada ponto da imagem, precisa-se localizar agora as bordas. Isso é possível localizando-se os pontos de máxima intensidade, ou de maneira inversa, localizando-se pontos de mínima intensidade, que precisam ser omitidos. Um valor de máxima intensidade ocorre no local mais alto da função gradiente ou onde a derivada da função gradiente possui valor zero. Entretanto, desejamos omitir os pontos de mínima intensidade ou pontos de mínimas direções perpendiculares com a borda. Cada pixel em volta do pixel atual forma o centro de um novo pixel na vizinhança. Interpolando os valores dos pixels ao redor do pixel atual, as magnitudes dos gradientes são calculadas pelos limites das fronteiras vizinhas em ambas as direções perpendiculares do pixel central. Se o pixel considerado possuir valor menor do que os valores dos pixels vizinhos, ele será omitido.

4. **Limiarização da borda:** O algoritmo Canny usa o método chamado *histerese*⁶. Considerando um segmento de borda, para todo valor situado acima do limite superior de limiarização, ele é imediatamente aceito. Para todo valor situado abaixo do limite inferior de limiarização, ele é imediatamente rejeitado. Pontos situados entre os dois limites serão aceitos se eles estiverem relacionados com pixels que apresentem respostas fortes.

Uma vez que este processo está completo, tem-se uma imagem binária onde cada pixel é marcado como um pixel da borda ou de não-borda.

Os algoritmos Canny contêm parâmetros que podem afetar o tempo de computação e a eficácia do algoritmo. O tamanho do filtro Gaussiano usado afeta diretamente os resultados do algoritmo. Os filtros menores permitem a detecção de linhas pequenas e bem nítidas. Um filtro maior é mais útil para detectar bordas maiores, mais suaves. o uso de dois limiares dá mais flexibilidade do que um único, mas os problemas usuais da técnica de limiarização ainda ocorrem. Esses limiares quando são tomados valores muito elevados informações podem ser perdidas, se baixos identificações falsas podem ser consideradas como importantes.

Neste Capítulo foram definidos os principais conceitos utilizados no decorrer da pesquisa. A fundamentação teórica trouxe as bases de tipos de lagos e os conceitos de Análise de Formas. Todo o processo de detecção de bordas também foi detalhado e exemplificado por meio de imagens processadas.

⁶A idéia também chamada de *tresholding com histerese* requer dois limiares iniciais um superior outro inferior.

3

METODOLOGIA

ESTE capítulo tem como objetivo apresentar os materiais e métodos a serem utilizados nessa dissertação. Podemos afirmar que a principal importância desse capítulo é nos dar subsídios suficientes e fidedignos para elaboração e conclusão dos objetivos propostos nesse trabalho.

Na figura 2.3.4 vemos um diagrama que generaliza o processo de desenvolvimento desta pesquisa. Primeiramente, a partir de uma imagem de satélite da área de estudo, aplicamos algoritmos para a detecção de borda. Com as bordas já extraídas, enviamos os dados aos especialistas da biologia para uma classificação visual. Em paralelo obtemos os atributos do lago e utilizamos as ferramentas de classificação. Enviamos os dados já classificados a um sistema de data mining ao mesmo tempo que enviamos a um grupo de teste ou controle. Este grupo permitem criar regras para a medição da precisão e acurácia dos dados e métodos aqui utilizados.

3.1 Materiais e Métodos

As imagens que serão analisadas são as do satélite CBERS-2B. O Programa CBERS nasceu de uma parceria inédita entre Brasil e China no setor técnico-científico espacial. Essas imagens estão disponíveis gratuitamente através da Internet, no endereço eletrônico <http://www.cbears.inpe.br>.

Essa análise se torna possível com o uso de ferramentas de modelagem computacionais tais como a linguagem R (R Development Core Team, 2009). Essa plataforma oferece grandes recursos tanto para o tratamento de imagens (Frery & Perciano, 2009), quanto para o estudo de atributos de forma (Claude, 2008).

A Morfometria pode ser definida como o estudo matemático das formas de objetos pertencentes à mesma população. Comumente classificada como um ramo da estatística, é

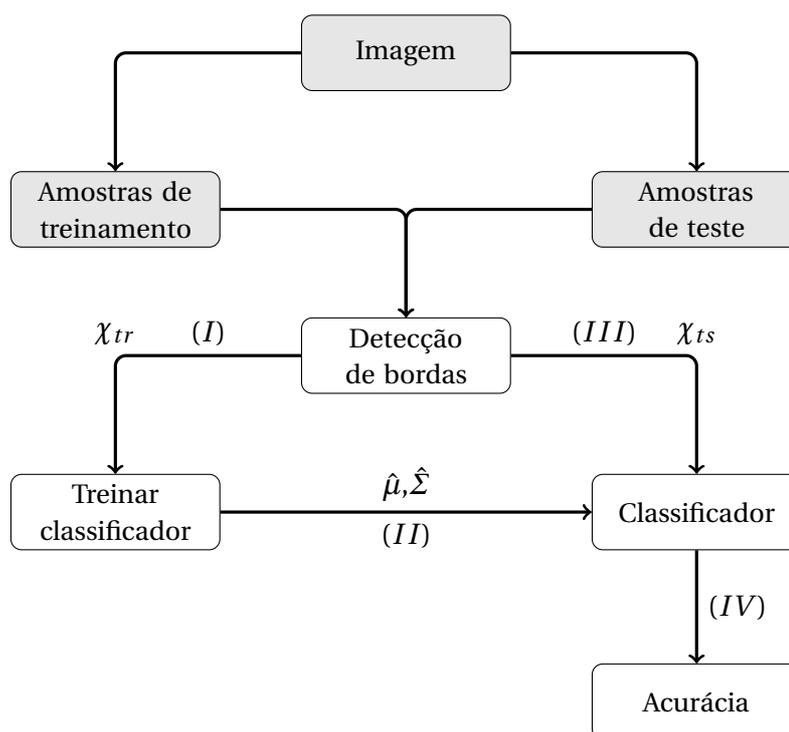


Figura 3.1: Metodologia de Desenvolvimento da Pesquisa

muito usada em conjunto com outras disciplinas como a arqueologia, paleontologia, geografia e a medicina. O livro de [Claude \(2008\)](#) discute como utilizar de maneira eficaz a linguagem R para análises morfométricas. Essa combinação irá possibilitar uma excelente base para o estudo da categorização de formas de lagos e seus indicadores morfométricos.

Quando se fala em características morfométricas de lagos, entende-se o tamanho do lago, seu formato, coloração e proximidade com rios. Esses indicadores podem trazer informações que delatam as espécies, a qualidade do ambiente e a biodiversidade da laguna. Somente com a análise e processamento das imagens de satélite tiradas do espaço amostral pré-selecionado, especificamente as lagunas da bacia amazônica, poderá ser criado um modelo matemático/computacional que correlacione esses indicadores.

3.2 Morfometria de Um Lago

Um mapa é uma representação, no plano de duas dimensões, de uma parte ou de toda a superfície terrestre desenhada numa escala específica ([Tarbuck & Lutgens, 1999](#)). Os mapas batimétricos mostram depressões de terra abaixo do nível do mar. As elevações topográficas e as depressões batimétricas são representadas com linhas de contorno. Para determinar a morfologia de um lago é necessário um mapa batimétrico que contenha a descrição de todos os parâmetros morfométricos do lugar ([Bookstein, 1989](#); [Hannay, 1978](#)).

Lagos são corpos d'água interiores sem comunicação direta com o mar. Sua água tem, em geral, baixo teor de íons dissolvidos quando comparada às águas oceânicas. Os lagos

não são elementos permanentes das paisagens da Terra, pois eles são fenômenos de curta durabilidade na escala geológica, surgindo e desaparecendo no decorrer do tempo (Esteves, 1988).

A capacidade de manter, armazenar e eventualmente fornecer água e a natureza lântica desses sistemas, tornam os lagos, reservatórios e áreas alagadas, componentes essenciais dos ciclos hidrológico e biogeoquímico, com grande influência em muitos aspectos da ecologia, economia e bem estar humano. Os lagos amazônicos são morfologicamente dependentes dos pulsos de inundação. Esta variação na característica morfológica exerce importante influência nos parâmetros físicos, químicos e biológicos dos lagos, assim como nos eventos de movimento de água em seu interior, e no grau de carga sedimentar da bacia de drenagem (Lehner & Döll, 2004; Wetzel, 1976).

Alguns parâmetros morfométricos são utilizados para quantificar e medir os diversos elementos da forma, como: área, volume, perímetro, comprimento, desenvolvimento do perímetro e fator de envolvimento. Um dos parâmetros mais utilizados para indicar o grau de irregularidade do corpo de água é o índice F , de forma, e consiste na razão entre o perímetro do lago (ℓ) – medida do contorno de uma figura – em relação ao comprimento da circunferência de um círculo com área equivalente à do corpo de água (França, 2005):

$$F = \frac{\ell}{\sqrt{A\pi}}, \quad (3.1)$$

em que A é a área em metros quadrados.

Por França (2005), sabe-se que quanto menor o valor do índice F , mais próxima de um círculo será a forma do lago. Qualquer variação no contorno das margens fará com que o valor de F aumente, sendo tanto maior quanto mais forte for o grau de irregularidade do contorno superficial do lago (Sperling, 1999).

De acordo com o valor de F obtido para a área de estudo da pesquisa de França (2005) foi definida a classificação apresentada na tabela 3.1.

Tabela 3.1: Valores de F atribuídos a forma

Forma	Limiar
Redondo - Oval	$1.27 < F < 2.9$
Alongado	$2.9 < F < 3.5$
Composto	$3.5 < F < 5$
Dendrítico	$F > 5.0$

Neste trabalho não empregamos este critério de classificação pois ele não se adapta aos interesses específicos relatados por Nolan (2004). Tal como vimos na seção 2.1, as classes a serem empregadas são: Redondo Oval; Redondo Alongado; Dendrítico Ramificado e Den-

drítico Alongado. E a categorização feita até o presente momento é realizada pela inspeção visual in situ dos lagos.

3.3 Sensoriamento Remoto de Lagos

Apesar da importância ecológica dos lagos, são escassos os estudos e conjuntos de dados existentes que incluam informações a respeito da localização, extensão e outras características básicas de corpos de água abertos e áreas alagáveis em escala global. Suas grandes dimensões, sua dinâmica sazonal e, principalmente, a dificuldade de acesso limitam o conhecimento sobre tais áreas, o que faz do Sensoriamento Remoto uma forma viável para sua caracterização e monitoramento (Lehner & Döll, 2004; Novo et al., 1998; Barbosa et al., 2000).

A tecnologia de sensoriamento remoto favorece a obtenção de informações instantâneas sobre amplas áreas e fornece imagens de cobertura global da terra em crescente qualidade e resolução, possibilitando o monitoramento das variações espaço-temporais das extensões dos lagos e áreas alagáveis (Lehner & Döll, 2004; França, 2005).

3.3.1 O Satélite CBERS

CBERS é a sigla para Satélite Sino-Brasileiro de Recursos Terrestres (*China-Brazil Earth-Resources Satellite*). Estes satélites fazem parte do INPE, Instituto Nacional de Pesquisas Espaciais, subordinado ao Ministério da Ciência e Tecnologia. O INPE é o responsável no Brasil pelo programa em parceria com a China, em vigor desde 1988.

Os satélites do programa CBERS se destinam à monitoração do clima, projetos de sistematização e uso da terra, gerenciamento de recursos hídricos, arrecadação fiscal, imagens para licenciamento e monitoramento ambiental, entre outras aplicações. Suas imagens são utilizadas por empresas privadas e instituições como Ibama, Incra, Petrobras, Aneel, Embrapa e secretarias de Fazenda e Meio Ambiente. O CBERS-2 foi integrado e testado no Laboratório de Integração e Testes do INPE, após acordo para a montagem dos equipamentos chineses no Brasil (INPE, 2007b).

O CBERS-2 possui órbita heliossíncrona, o que permite ao CBERS fazer uma cobertura de todo o planeta.

O CBERS-2 é munido dos seguintes sensores:

Câmera Imageadora de Alta Resolução: possui resolução espacial de 20m , cinco bandas espectrais, e campo de visada de 113km. Destina-se à observação de fenômenos ou objetos em escala municipal ou regional englobando aplicações em Vegetação, Agricultura, Meio ambiente, Água, Cartografia, Geologia e solos, e Educação.

Imageador por Varredura de Média Resolução: tem três bandas espectrais, com 80m de resolução espacial, mais uma banda na região do infravermelho termal com 160m. A câmera IRMSS, além das aplicações da Câmera CCD, presta-se à análise de fenômenos que apresentem alterações de temperatura da superfície, à geração de mosaicos estaduais e à geração de cartas-imagens. Foi substituído no CBERS-2B pela câmera HRC. IRMSS¹.

Imageador de Amplo Campo de Visada: pode imagear grandes extensões territoriais, de mais de 900km. WFI².

Câmera Pancromática de Alta Resolução: O sensor HRC possui uma única banda espectral, que opera no espectro do visível e infravermelho próximo. Encontra-se a bordo do satélite CBERS-2B e destaca-se pela alta resolução espacial que oferece, o que possibilita um maior detalhamento da superfície em relação aos dados captados pela câmera CCD.

O segundo satélite CBERS-2 foi lançado no dia 21 de outubro de 2003, do Centro de Lançamento de Taiyuan, na China. Ao completar dois anos de operação do CBERS-2, realizou-se um Seminário de Aplicações CBERS, com exemplos concretos relatados por diversas instituições. Cada um desses sensores tem características próprias que os tornam mais adequados a certas categorias de aplicações.

O potencial de aplicação de um dado sensor é estabelecido em função de suas características de resolução espacial, resolução temporal, e características espectrais e radiométricas. A fim de maximizar os resultados para melhor relação custo/benefício deve-se considerar o compromisso entre as necessidades da aplicação e as características dos sensores.

Todas as apresentações encontram-se disponíveis na Biblioteca Digital CBERS.

A Câmera Imageadora de Alta Resolução (CCD), por possuir uma boa resolução espacial em quatro bandas espectrais, mais uma pancromática, presta-se à observação de fenômenos ou objetos cujo detalhamento seja importante. Dada a sua frequência temporal, pode servir de suporte na análise de fenômenos que tenham duração compatível. Essa resolução temporal pode ser melhorada, pois a CCD tem capacidade de visada lateral. Suas bandas estão situadas na faixa espectral do visível e do infravermelho próximo, o que permite bons contrastes entre vegetação e outros tipos de objetos (INPE, 2007c).

Destacam-se como aplicações potenciais da CCD:

Vegetação: identificação de áreas de florestas, alterações florestais em parques, reservas, florestas nativas ou implantadas, quantificações de áreas, sinais de queimadas recentes.

¹Infrared Multispectral Scanner.

²Wide Field Imager.

Agricultura: identificação de campos agrícolas, quantificação de áreas, monitoramento do desenvolvimento e da expansão agrícola, quantificação de pivôs centrais, auxílio em previsão de safras, fiscalizações diversas.

Meio ambiente: identificação de anomalias antrópicas ao longo de cursos d'água, reservatórios, florestas, cercanias urbanas, estradas; análise de eventos episódicos naturais compatíveis com a resolução da Câmera, mapeamento de uso do solo, expansões urbanas.

Água: identificação de limites continente-água, estudos e gerenciamento costeiros, monitoramento de reservatórios.

Cartografia: dada a sua característica de permitir visadas laterais de até 32° a leste e a oeste, em pequenos passos, possibilita a obtenção de pares estereoscópicos e a conseqüente análise cartográfica. Essa característica também permite a obtenção de imagens de uma certa área no terreno em intervalos mais curtos, o que é útil para efeitos de monitoramento de fenômenos dinâmicos.

Geologia e solos: apoio a levantamentos de solos e geológicos.

Educação: geração de material de apoio a atividades educacionais em geografia, meio ambiente, e outras disciplinas.

O **IRMSS**, Imageador por Varredura de Média Resolução, presente nos CBERS-1 e 2, tem duas bandas espectrais na região do infravermelho médio e uma pancromática, com 80 m de resolução espacial, mais uma banda na região do infravermelho termal com 160 m. Suas aplicações são as mesmas da CCD, com as devidas adaptações. Outras aplicações são: análise de fenômenos que apresentem alterações de temperatura da superfície, geração de mosaicos estaduais, geração de cartas-imagens (INPE, 2007c).

O **WFI**, Imageador de Amplo Campo de Visada, pode imagear grandes extensões territoriais, de 890 km. Essa característica torna o WFI muito interessante para observar fenômenos cuja magnitude ou interesse seja nas escalas macro-regionais ou estaduais. Em função dessa ampla cobertura espacial, sua resolução temporal também tem um ganho - podem ser geradas imagens de uma dada região com menos de cinco dias de intervalo. Entre as aplicações, podem ser mencionadas:

- Geração de mosaicos nacionais ou estaduais.
- Geração de índices de vegetação para fins de monitoramento.
- Monitoramento de fenômenos dinâmicos, como safras agrícolas, queimadas persistentes.

- Sistema de alerta, em que a imagem WFI serve como indicativo para a aquisição de imagens de mais alta resolução da CCD ou do IRMSS.
- Acoplamento a outros sistemas mundiais de coleta de dados de baixa a média resolução.

A **HRC**, Câmera Pancromática de Alta Resolução, pode imagear uma faixa relativamente estreita de 27 km, mas com altíssima resolução, de 2,7 de dimensão de pixel. O modo de operação está estabelecido em uma revisita de 130 dias, ou seja, ao longo do ano é possível ter ao menos duas coberturas completas do país. Com esta câmera não é possível ter estereoscopia³ (INPE, 2007c). Entre as aplicações, podem ser mencionadas:

- Geração de mosaicos nacionais ou estaduais detalhados.
- Atualização de cartas temáticas e outros tipos de cartas.
- Geração de produtos para fins de planejamento local ou municipal.
- Aplicações urbanas e de inteligência.

Uma característica importante dos satélites CBERS-1, 2 e 2B é a diversidade de câmeras com diferentes resoluções espaciais e frequências de coleta de dados. A tabela 3.2 mostra essas configurações, onde BE denota Bandas Espectrais, CV Campo de visada, Re Resolução espacial, Lfi largura da faixa imageada, CaE Capacidade de apontamento do Espelho, Rt Resolução temporal, FRF Frequência da portadora de RF, Tdi Taxa de dados da imagem, PEII Potência Efetiva Isotrópica Irradiada, IR infra vermelho (INPE, 2007a). A órbita do CBERS é heliosíncrona a uma altitude de 778 km, perfazendo aproximadamente 14 revoluções por dia. Nesta órbita, o satélite cruza o Equador sempre na mesma hora local, 10 : 30h da manhã, permitindo assim que se tenha sempre as mesmas condições de iluminação solar para a comparação de imagens tomadas em dias diferentes.

O satélite obtém uma cobertura da Terra a cada 26 dias. Esse é o tempo necessário para se ter imagens de todo o globo terrestre com suas câmeras CCD e IRMSS. Já com a câmera WFI, o tempo necessário para uma cobertura global é de cinco dias.

No caso do CBERS-2B, no lugar do sensor IRMSS foi instalada a HRC - Câmera Pancromática de Alta Resolução, com pixel de 2,7 m em uma banda larga no visível. Com a HRC, é adotada uma sistemática especial de imageamento, de modo a que o país tenha cobertura completa em alta resolução a cada cinco ciclos de 26 dias de imageamento, ou seja a cada 130 dias. A cada ciclo de 26 dias, todo o território é coberto pela CCD, mas apenas uma parte

³A estereoscopia é a simulação de duas imagens da cena que são projetadas nos olhos em pontos de observação ligeiramente diferentes, o cérebro funde as duas imagens, e obtém informações quanto à profundidade, distância, posição e tamanho dos objetos, gerando uma sensação de visão 3D.

Tabela 3.2: Características, Resoluções e Frequências das Câmaras do Satélite CBERS-2

	WFI	CCD	IRMSS	HCR
BE	0,63 – 0,69 μ (vermelho)	0,51 – 0,73 μ (pan)	0,50 – 1,10 μ (pan)	0,50 – 0,80 μ (pan)
	0,77 – 0,89 μ (IR)	0,45 – 0,52 μ (azul)	1,55 – 1,75 μ (IR médio)	
		0,52 – 0,59 μ (verde)	2,08 – 2,35 μ (IR médio)	
		0,63 – 0,69 μ (vermelho)	10,40 – 12,50 μ (termal)	
		0,77 – 0,89 μ (IR próximo)		
CV	60°	8,3°	8,8°	2,1°
Re	260 m × 260 m	20 m × 20 m	80 m × 80 m (160 m × 160 m termal)	2,7 m × 2,7 m
Lfi	890 km	113 km	120 km	27 km
CaE	$\pm 30^\circ$			
Rt	5 dias	26 dias	26 dias	130 dias
FRF	8203,35 MHz	8103 MHz e 8321 MHz	8216,84 MHz	
Tdi	1,1 Mbit/s	2×53 Mbit/s	6,13 Mbit/s	432 Mbit/s
PEII	31,8 dBm	43 dBm	39,2 dBm	8 bits

é coberta pela HRC ou seja 27 km de largura de faixa de imageamento. Portanto, são necessários cerca de cinco ciclos de imageamento para que os 113 km da CCD sejam completamente cobertos pelos 27 km da HRC. Assim, para cada cinco coberturas completas do país com a CCD, tem-se uma cobertura completa com a HRC.

A capacidade de apontamento lateral da câmera CCD de alta resolução aliada ao tipo de órbita do satélite torna possível obter-se pares estereoscópicos de uma certa região com um intervalo de três dias entre duas imagens.

Tabela 3.3: Tamanho e número de bandas dos instrumentos no CBERS-2

Instrumento	Número de Bandas	Tam. do Arquivo TIFF	Tam. do TIFF Compactado
CCD	5	≈ 42 MB	≈ 20 MB
IRMSS	4	$\approx 3,2$ MB	$\approx 1,7$ MB
WFI	2	≈ 16 MB	≈ 9 MB

3.4 Seleção das Áreas de Interesse

O ambiente amazônico apresenta, pelo menos, dois critérios fundamentais para a escolha de imagens onde são analisadas as paisagens lacustres: a data de aquisição dos dados e a cobertura de nuvens. É muito importante escolher imagens que possuam dados em diferentes ciclos hidrológicos. A cobertura de nuvens é um fator limitante principalmente no caso de análise com produtos de sensores ópticos passivos; em algumas situações não é possível sequer visualizar o sistema lacustre (Novo et al., 1997; Burrough, 1986; Nolan, 2004).

O procedimento de seleção das áreas de interesse de estudo dos lagos, foi feito pelos especialistas da área de biologia, uma vez que os mesmos tinham a sua disposição grandes quantidades de dados referentes a índices de produtividade pesqueira. Um dos objetivos iniciais desse trabalho seria traçar um paralelo entre o índice de biodiversidade de espécies com os formatos de lagos existentes na bacia amazônica.

Contudo, com o desenvolvimento da pesquisa, o trabalho tomou um viés estritamente computacional, e essa análise, só seria permitida com um estudo mais aprofundado na extração de dados biológicos e com uma maior sinergia entre as equipes de desenvolvimento e biólogos, o que na prática não aconteceu.

A tabela 3.4 descreve as principais características de lagos da bacia amazônica, apresenta dados de tamanho da área e do perímetro bem como os nomes dos principais lagos conhecidos.

Tabela 3.4: Características Paisagísticas de Sistema Lacustre por tipo de Lago

Rios	Tipo	Lagos	Desenv. Per.	Perímetro
Solimões	Redondo Alongado	Copeá, Acará Anamã, Miuá,	21,35 km	194,14 km
	Dendrítrico Alongado	Badajós, Coari Piorini, Mamiá	27,05 km	1064,62 km
	Dendrítrico Alongado	Jacaré, Cururu	17,92 km	542,91 km
	Dendrítrico Ramificado	Manaquiri, Janauaca	30,11 km	1218,18 km
Amazonas	Redondo Ovais	Rei, Murutinga, Sampaio	8,63 km	241,44 km
	Dendrítrico Ramificado	Canaçari, Arari	8,29 km	250,74 km
Purus	Dendrítrico Alongado	Surara Beruri, Anori, Arumã Jari Paricatuba	20,96 km	540,84 km
	Redondo Alongado	Caua, Aiuapuá	29,73 km	1374,70 km

3.5 Processamento de Imagens com a Plataforma R

Existem três níveis de processos computadorizados no processamento de imagens: processamento de baixo, médio e de alto nível. Utilizamos a linguagem R por atender a esses

três tipos de processamento de imagens. Hoje o R é uma das linguagens estatísticas mais utilizadas no mundo, sendo quase mandatório no mundo acadêmico e tomando cada vez mais força no mercado. As técnicas estatísticas de ponta tendem a aparecer primeiro nele para depois mais tarde começarem a surgir em outros pacotes. Outra vantagem é a flexibilidade imensa que ele lhe proporciona, por ser uma linguagem de programação completa, com orientação a objetos e suporte a interação com outras linguagens de alto e médio nível.

R é uma linguagem e ambiente que nos permite fazer análises estatísticas de objetos e muito mais. R foi projetada para as nossas necessidades e pode ser adaptado para nossas análises morfométricas. Mais que isso R possui muitas outras qualidades que a tornam atraentes para o uso, além de demonstrar qualidade superior em comparação com outros softwares. R é livre e roda em qualquer sistema operacional, é mais fácil de aprender e entender.

O pacote *'biOps'* para processamento e análise de imagens permite a utilização de técnicas de geometria, aritmética, lógica, morfologia, tabelas de busca, e operações de máscara de convolução. Porém o mais importante para essa pesquisa são as técnicas de detecção de bordas incluídas nesse pacote: Roberts, Sobel, Kirsch, Marr-Hildreth e Canny. Ele permite a leitura de imagens nos formatos *jpeg* e *tiff*.

Uma imagem pode ser definida como uma função bidimensional, $f(x,y)$ onde x e y são coordenadas espaciais, e amplitude de f em qualquer par de coordenadas (x,y) é chamada de intensidade ou nível de cinza da imagem naquele ponto. Quando x,y , e os valores de intensidade de f são todos finitos, chamamos a imagem de imagem digital (Frery & Perciano, 2009).

Imagens coloridas frequentemente possuem valores vetoriais de dimensão 3, as imagens em tons de cinza requerem apenas um escalar em cada posição. O termo usado para denominar esses elementos é o pixel.

Na tabela 3.5 temos alguns métodos do pacote *biOps*.

Tabela 3.5: Principais Funções Utilizadas do pacote *biOps*

Função	Operação
<i>imgCanny</i>	Método de detecção de bordas de Canny.
<i>imgFreiChen</i>	Método de detecção de bordas de Frei-Chen.
<i>imgKirsch</i>	Método de detecção de bordas de Kirsch.
<i>imgMarrHildreth</i>	Método de detecção de bordas de Marr-Hildreth.
<i>imgPrewitt</i>	Método de detecção de bordas de Prewitt.
<i>imgRGB2Grey</i>	Transforma a imagem para tons de cinza
<i>imgRoberts</i>	Método de detecção de bordas de Roberts.
<i>imgRobinson3Level</i>	Método de detecção de bordas de Robinson level-3.
<i>imgRobinson5Level</i>	Método de detecção de bordas de Robinson level-5.
<i>imgShenCastan</i>	Método de detecção de bordas de Shen-Castan.
<i>imgSobel</i>	Método de detecção de bordas de Sobel.
<i>readTiff</i>	Lê um arquivo de imagem <i>tif</i> .

A figura 3.2(a) foi capturada do satélite CBERs a partir do instrumento CCD, ela mostra a órbita 172 no ponto 104, do dia 10/09/2009.

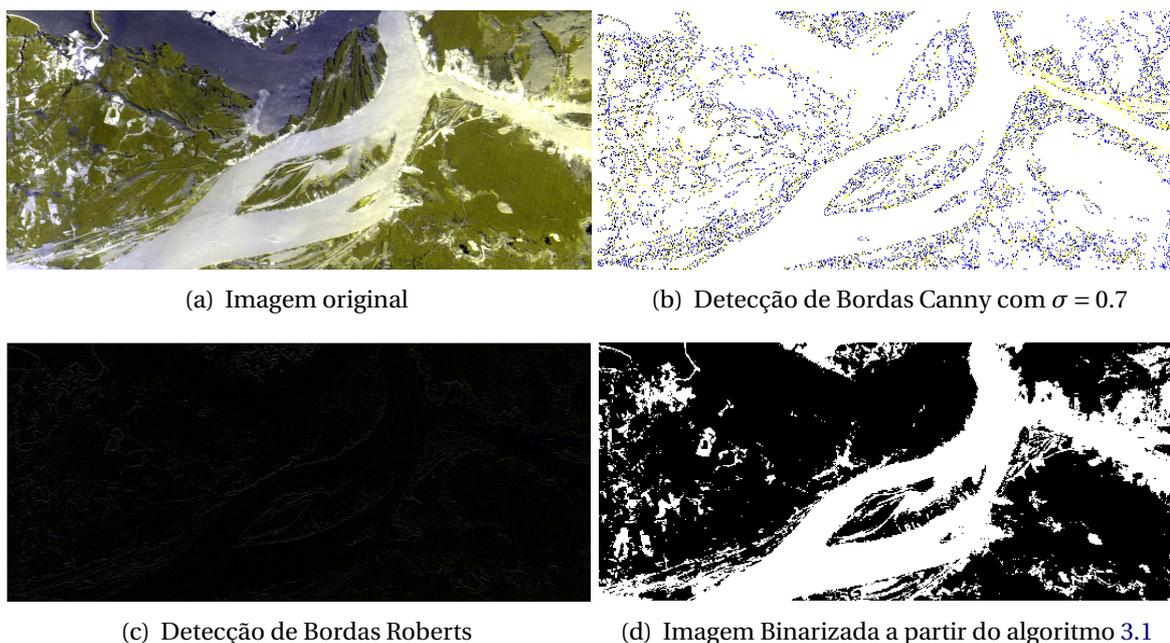


Figura 3.2: Imagem original e bordas detectadas

3.6 Binarização

Para uma melhor detecção de bordas, realiza-se primeiramente o processo de binarização antes.

O processo de binarização nada mais é do que transformar uma imagem, geralmente

já em tons de cinza⁴, em uma outra imagem com apenas duas tonalidades (imagem binarizada), o preto e o branco. Com isso temos o objeto de interesse em preto e o fundo da imagem em branco. A partir daí a etapa de segmentação, ou separabilidade entre objetos, torna-se trivial.

O algoritmo abaixo serve para binarizar imagens coloridas. Temos como entrada uma imagem e um valor que chamamos de limiar para binarização. Esse limiar t determina quais os valores dentro da gama (0 a 255) serão substituídos por 0's e 255's, os valores inferiores a t recebem 0 e os valores superiores a t são substituídos por 255.

Antes de se iniciar o processo, a imagem colorida é transformada em tons de cinza.

Algoritmo 3.1 Binarização de uma Imagem

Require: Img do tipo RGB

```

1: function BINARIZAR( $Img, t$ )                                ▷ Imagem, Limiar para a binarização
2:    $ImgOut \leftarrow \text{imgRGB2Grey}(Img)$                     ▷ Transformando a imagem em tons de cinza
3:    $ImgOut \leftarrow \text{imgKMeans}(ImgOut, 2)$                 ▷ Classificando a imagem em 2 regiões
4:    $i_1 \leftarrow \text{which}(ImgOut < t)$                        ▷ Salvando índices de pixels em  $i_1$  inferiores ao limiar  $t$ 
5:    $i_2 \leftarrow \text{which}(ImgOut \geq t)$                    ▷ Salvando índices de pixels em  $i_2$  a partir do limiar  $t$ 
6:    $ImgOut[i_1] \leftarrow 0$                                 ▷ Binarização
7:    $ImgOut[i_2] \leftarrow 255$                               ▷ Binarização
8:   return  $ImgOut$                                          ▷ Retornando imagem binarizada
9: end function

```

3.7 Extração de Atributos e Características

Em reconhecimento de padrões e em processamento de imagens, a extração de características é uma forma especial de redução dimensional dos dados.

Quando dados de entrada para um algoritmo são muito grandes para serem processados e são notadamente redundantes (muitos dados porém pouca informação) esses deverão ser transformados em um conjunto reduzido de características melhor representativo (também chamado vetor). Transformar os dados de entrada em um conjunto de características é chamado de extração de características. Se as características extraídas forem cuidadosamente escolhidas, espera-se que esse conjunto represente a parte relevante da informação para se executar a tarefa desejada, ao invés de se usar os dados de entrada na íntegra (Rustum et al., 2005).

A etapa de extração de atributos é feita baseada em análise de séries Fourier. Muitos estudos defendem a análise de Fourier como melhor alternativa para extração de atributos em objetos com bordas fechadas, o que é bem comum em estudos morfométricos.

A transformada de Fourier utiliza as séries de Fourier para decompor e analisar sinais

⁴O processo de binarização de uma imagem colorida é conhecido como posterização

periódicos em uma soma ponderada das funções de base sinusoidal, i.e., como soma ou integral de funções sinusoidais multiplicadas por amplitudes, (Claude, 2008). Em processamento de sinais, a transformada de Fourier é tipicamente utilizada para decompor um sinal nas suas componentes em frequência e suas amplitudes.

A expressão geral da função Fourier para uma função periódica $f(t)$ com $t \in \mathbb{R}$ do período T é definida em (3.2)

$$f(t) = \frac{1}{2}a_0 + \sum_{n=1}^{\infty} [a_n \cos(\omega_n t) + b_n \text{sen}(\omega_n t)], \quad (3.2)$$

onde ω_n é o n -ésimo harmônico da função em radianos,

$$\omega_n = n \frac{2\pi}{T},$$

e a_n são os coeficientes pares de Fourier,

$$a_n = \frac{2}{T} \int_{t_1}^{t_2} f(t) \cos(\omega_n t) dt,$$

e b_n são os coeficientes ímpares,

$$b_n = \frac{2}{T} \int_{t_1}^{t_2} f(t) \text{sen}(\omega_n t) dt.$$

É possível ainda escrever $f(t)$ na sua forma exponencial

$$f(t) = \sum_{n=-\infty}^{+\infty} c_n \exp^{i\omega_n t}, \quad (3.3)$$

com

$$c_n = \frac{1}{T} \int_{t_1}^{t_2} f(t) \exp^{-i\omega_n t} dt$$

Como bordas são contornos fechados, não podemos aplicar diretamente a análise de Fourier às imagens uma vez que essas transformadas são definidas em função de coordenadas x e y em duas dimensões. De acordo com Claude (2008), temos algumas possibilidades de tratamento:

- A primeira consiste em representar a borda como uma função de uma variável transformada.
- Outra abordagem é decompor separadamente coordenadas x e y e representá-las como funções da abscissa curvilínea (decomposição de Fourier elíptica).

A primeira abordagem consiste na implementação das técnicas da Transformada Polar ou Análise Fourier de raios igualmente espaçados e Análise de Fourier do ângulo tangente a borda.

3.7.1 Análise Fourier Aplicada à Variação de Raios em Bordas Fechadas

Podemos expressar o raio r como uma função periódica do ângulo θ . A relação corresponde à equação da curva definida pelos harmônicos de 0 a k :

$$r(\theta) = \frac{1}{2}a_0 + \sum_{n=1}^k [a_n \cos(n\theta) + b_n \sin(n\theta)]. \quad (3.4)$$

Não podem existir mais harmônicos que a metade do número p do conjunto de pontos desde que existam dois parâmetros para um harmônico e desde que os dados originais são univariados.

Podemos avaliar esses coeficientes segundo essas equações:

$$a_n = \frac{2}{p} \sum_{i=1}^p r_i \cos n\theta_i,$$

$$b_n = \frac{2}{p} \sum_{i=1}^p r_i \sin n\theta_i,$$

$$a_0 = \sqrt{\frac{2}{p}} \sum_{i=1}^p r_i.$$

A função é calculada com base nas coordenadas de interseção entre os raios igualmente espaçados e a borda. O outro parâmetro é o número de harmônicos que queremos obter. Reconstituímos a borda baseado nos primeiros k harmônicos. Calculamos a posição estimada de n pontos para desenhar a borda das k funções harmônicas.

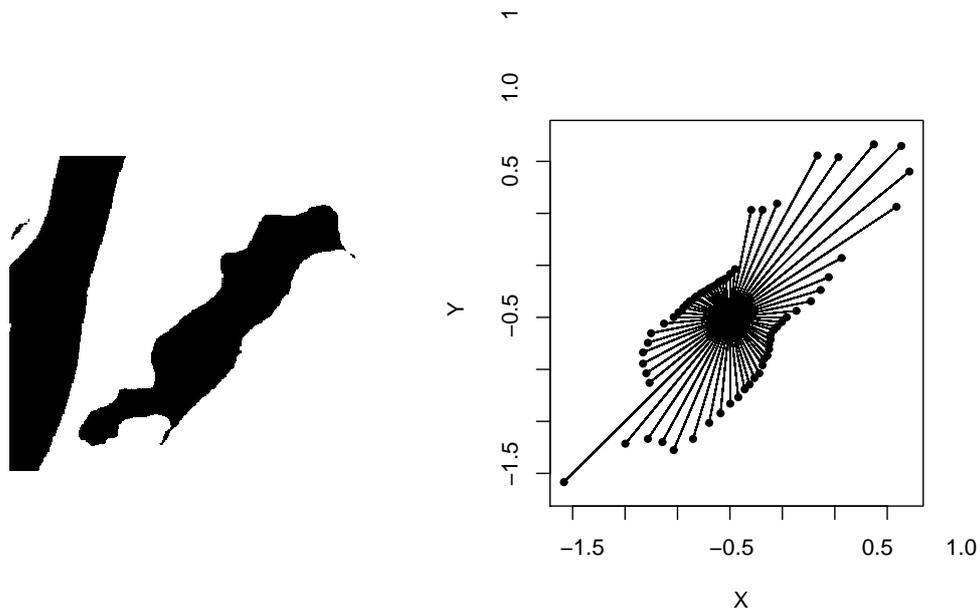


Figura 3.3: Aquisição de dados para Análise de Fourier de Raios igualmente espaçados.

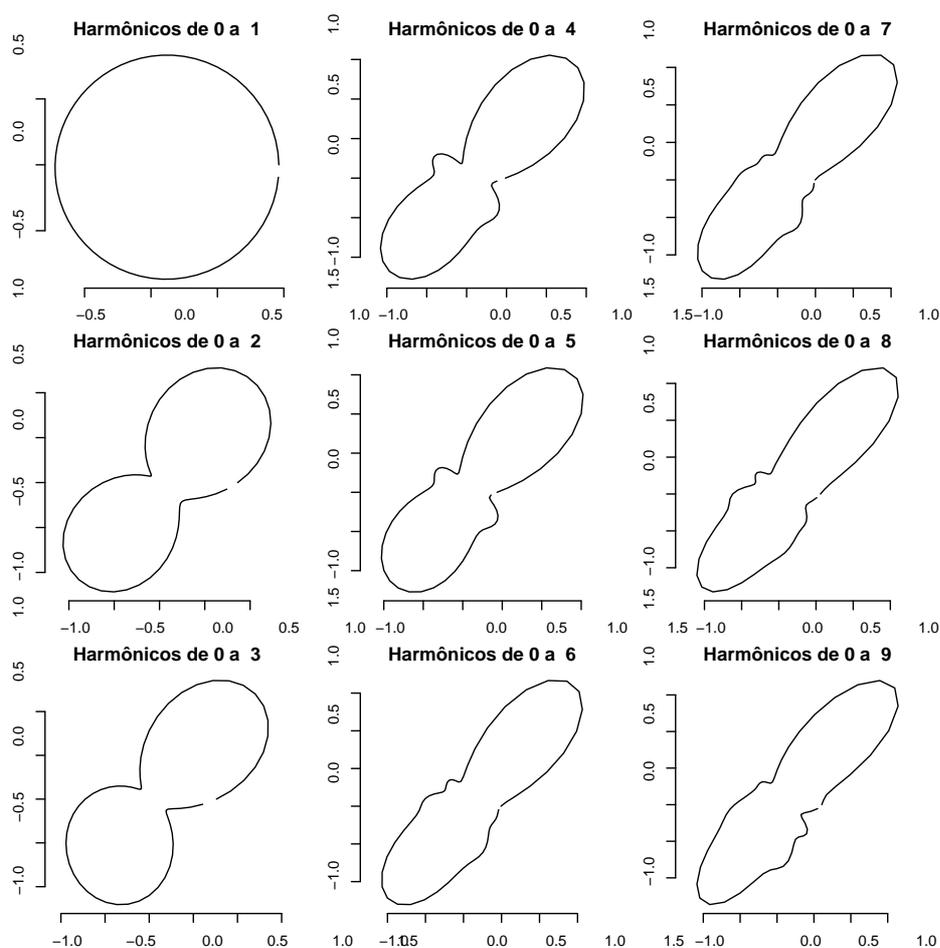


Figura 3.4: Reconstrução de Bordas por Análise de Fourier em Raios igualmente espaçados.

3.7.2 Análise Fourier do Ângulo Tangente

Esse método consiste em descrever a alteração cumulativa no ângulo de um vetor tangente ao contorno $\phi(t)$ como uma função da distância cordal acumulada t ao longo da curva.

A figura 3.5 do lado esquerdo traz a reconstrução da borda, enquanto que a figura da direita traz o ajuste do sinal pela série de Fourier (linha preta) sobre a variação do ângulo da tangente (linha cinza).

3.7.3 Análise Elíptica de Fourier

A Análise Elíptica de Fourier é outro método Fourier para ajustes de curvas a complexos contornos fechados (Giardina & Kuhl, 1977). Nos trabalhos de Crampton (1995); Rohlf & Archie (1984) encontramos uma lista das vantagens do método de análise elíptica de Fourier comparada a outras aplicações de Fourier.

Seja T o perímetro do contorno, esse torna-se o período do sinal. Definimos $\omega = 2\pi/T$

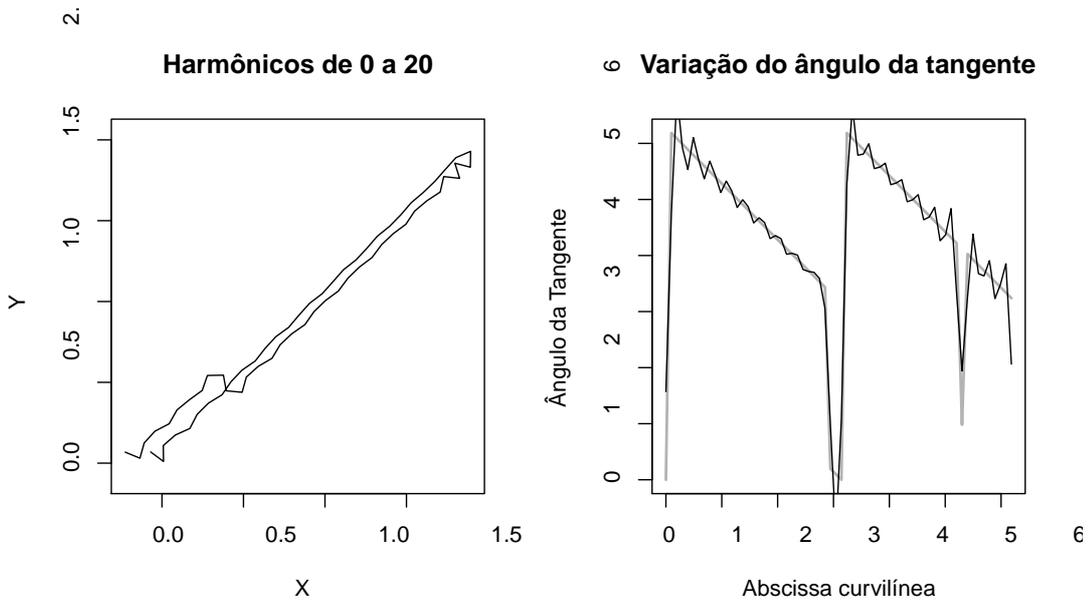


Figura 3.5: Análise de Fourier aplicada ao ângulo da tangente em função do perímetro como o pulso. Logo, a abscissa curvilínea, t varia de 0 a T . Pode-se definir $x(t)$ e $y(t)$ como:

$$x(t) = \frac{a_0}{2} + \sum_{n=1}^{+\infty} a_n \cos n\omega t + b_n \text{sen } n\omega t,$$

com

$$a_n = \frac{2}{T} \int_0^T x(t) \cos(n\omega t) dt,$$

e

$$b_n = \frac{2}{T} \int_0^T x(t) \text{sen}(n\omega t) dt;$$

da mesma forma que,

$$y(t) = \frac{c_0}{2} + \sum_{n=1}^{+\infty} c_n \cos n\omega t + d_n \text{sen } n\omega t,$$

com

$$c_n = \frac{2}{T} \int_0^T y(t) \cos(n\omega t) dt,$$

e

$$d_n = \frac{2}{T} \int_0^T y(t) \text{sen}(n\omega t) dt.$$

A borda contém um número finito k de pontos. Calculamos estimadores discretos para cada coeficiente do n -ésimo harmônico:

$$a_n = \frac{T}{2\pi^2 n^2} \sum_{p=1}^k \frac{\Delta x_p}{\Delta t_p} \left(\cos \frac{2\pi n t_p}{T} - \cos \frac{2\pi n t_{p-1}}{T} \right),$$

com

$$\Delta x_1 = x_1 - x_k;$$

e

$$b_n = \frac{T}{2\pi^2 n^2} \sum_{p=1}^k \frac{\Delta x_p}{\Delta t_p} \left(\text{sen} \frac{2\pi n t_p}{T} - \text{sen} \frac{2\pi n t_{p-1}}{T} \right),$$

c_n e d_n são calculadas similarmente. a_0 e c_0 corresponde as estimativas das coordenadas do centróide. Estimadas por:

$$a_0 = \frac{2}{T} \sum_{i=1}^p x_i$$

e

$$c_0 = \frac{2}{T} \sum_{i=1}^p y_i.$$

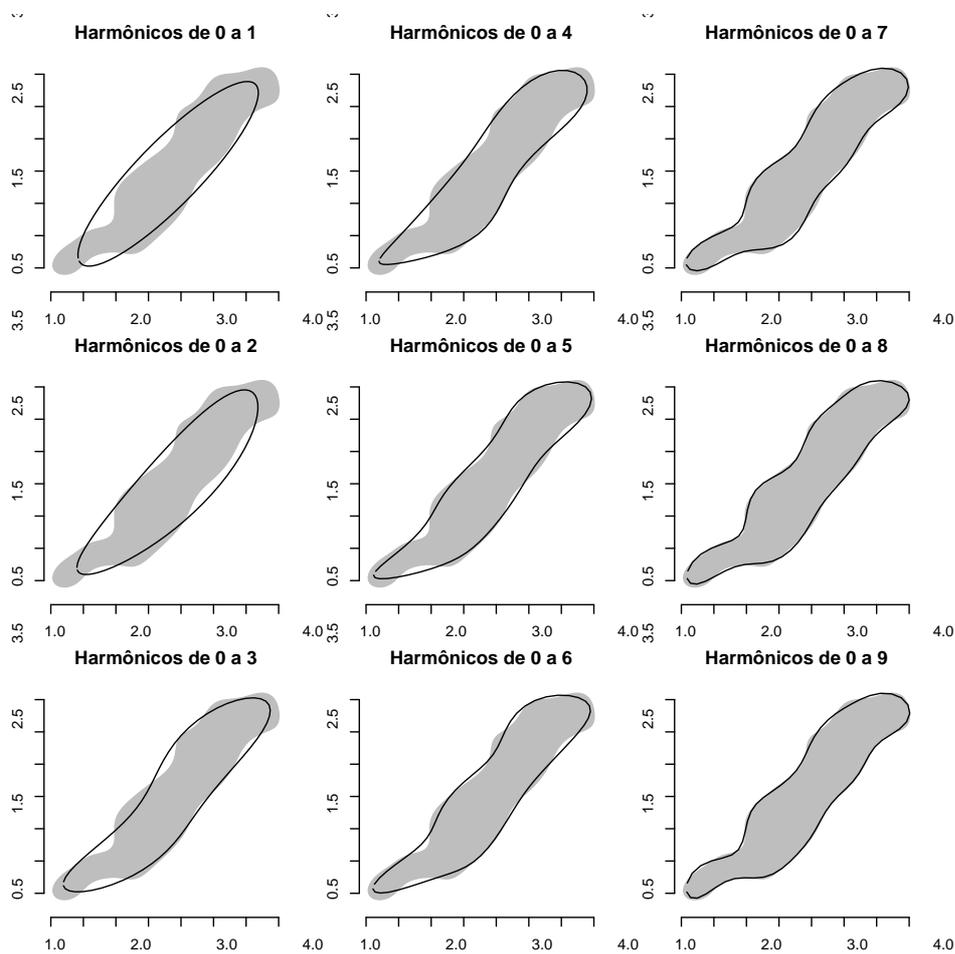


Figura 3.6: Reconstrução de borda a partir de Análise Elíptica de Fourier

Na figura 3.6 temos a Análise Elíptica de Fourier aplicada às coordenadas de borda do lago. A borda original corresponde à forma cinza enquanto que os lagos reconstruídos são os finos contornos em preto, a partir do sexto harmônico a reconstrução é quase perfeita.

3.8 Sistema de Classificação

Para desenvolver um classificador ótimo é necessário ter conhecimento da probabilidade “a priori” $\Pr(\omega_i)$ e a probabilidade condicional $p(x | \omega_i)$ de um elemento x pertencer a classe ω_i . Infelizmente, em reconhecimento de padrões raramente possuímos todas essas informações a respeito da estrutura probabilística do problema. O que temos em geral é algum conhecimento vago sobre a situação, junto com um número de amostras dados de treinamento, representações particulares dos padrões que desejamos classificar. O problema então consiste em encontrar uma maneira de usar essa informação para desenvolver ou treinar nosso classificador, (Duda et al., 2001).

Um abordagem interessante consiste em usar as amostras para estimar as probabilidades e densidades de probabilidades desconhecidas, e então usar os resultados estimados como se fossem valores verdadeiros. Podemos supor, por exemplo, que por alguma razão $p(x | \omega_i)$ é uma densidade normal com média μ e matriz de covariância Σ . Uma vez que não sabemos os valores exatos desses quantificadores, o problema agora consiste em estimar a função desconhecida $p(x | \omega_i)$ através dos seus parâmetros μ e Σ , também desconhecidos.

Consideramos o método de estimação por máxima verossimilhança por possuir um grande número de vantagens, pois possui sempre boas propriedades de convergência quando o número de amostras de treinamento cresce.

3.8.1 Média e Covariância Desconhecidas

A situação mais comum em um modelo de reconhecimento de padrões é que tanto a média μ e a matriz de covariância Σ sejam desconhecidas. Esses parâmetros formam o vetor de parâmetros θ . Consideraremos primeiro o caso univariado com $\theta_1 = \mu$ e $\theta_2 = \sigma^2$. A log-verossimilhança de um único ponto é

$$\ln p(x_k | \theta) = -\frac{1}{2} \ln 2\pi\theta_2 - \frac{1}{2\theta_2} (x_k - \theta_1)^2$$

e sua derivada é

$$\nabla_{\theta} \ell = \nabla_{\theta} \ln p(x_k | \theta) = \begin{bmatrix} \frac{1}{\theta_2} (x_k - \theta_1) \\ -\frac{1}{2\theta_2} + \frac{(x_k - \theta_1)^2}{2\theta_2^2} \end{bmatrix}.$$

Aplicando a igualdade

$$\nabla_{\theta} \ell = 0$$

à log-verossimilhança temos as condições

$$\sum_{k=1}^n \frac{1}{\hat{\theta}_2} (x_k - \hat{\theta}_1) = 0$$

e

$$-\sum_{k=1}^n \frac{1}{\hat{\theta}_2} + \sum_{k=1}^n \frac{(x_k - \hat{\theta}_1)^2}{\hat{\theta}_2^2}$$

onde $\hat{\theta}_1$ e $\hat{\theta}_2$ são os estimadores de máxima verossimilhança para θ_1 e θ_2 respectivamente.

Fazendo $\hat{\mu} = \hat{\omega}_1$ e $\hat{\sigma}^2 = \hat{\omega}_2$ obtemos os seguintes estimadores de máxima verossimilhança para μ e σ^2 :

$$\hat{\mu} = \frac{1}{n} \sum_{k=1}^n x_k$$

e

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \hat{\mu})^2$$

Logo os estimadores de máxima verossimilhança para μ e Σ são dados por

$$\hat{\mu} = \frac{1}{n} \sum_{k=1}^n x_k \quad (3.5)$$

$$\hat{\Sigma} = \frac{1}{n} \sum_{k=1}^n (x_k - \hat{\mu})(x_k - \hat{\mu})^t \quad (3.6)$$

3.8.2 Classificador de Máxima Verossimilhança

O classificador de máxima verossimilhança consiste em uma regra de decisão estatística que examina a função de probabilidade de um pixel para cada uma das classes, e atribui o pixel à classe com a maior verossimilhança.

O vetor que caracteriza perfeitamente um objeto, no nosso caso um lago, pode ser descrito por um vetor x :

$$x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_N \end{bmatrix}$$

onde $x_1, x_2, x_3, \dots, x_N$ são seus atributos.

A escolha dos atributos é de fundamental importância para um bom desempenho do classificador. Nesta etapa de extração de atributos, deve-se ter como objetivo a redução da dimensionalidade do vetor de atributos, sem que isso implique em perda de informação que possa ser relevante para a classificação, para que assim reduza-se também o esforço computacional e a seleção dos atributos significativos para a tarefa de classificação.

Classificação de Bayes

Temos a classe $\omega_i, i = 1 \dots M$ com M sendo o número total de classes de lagos. Tentamos determinar a classe de cada lago através da seguinte probabilidade condicional

$$p(\omega_i | x), i = \dots M,$$

essa probabilidade $p(\omega_i | x)$ dá a verossimilhança de que a classe correta é ω_i para dado lago x . A classificação é executada de acordo com

$$x \in \omega_i, \text{ se } p(\omega_i | x) > p(\omega_j | x) \text{ para todo } j \neq i$$

ou seja o lago x pertence a classe ω_i se $p(\omega_i | x)$ for a maior.

Regra de decisão Máxima Verossimilhança

Apesar de sua simplicidade, $p(\omega_i | x)$ é desconhecido. Contudo, supomos que temos disponível conjuntos de treinamento para cada tipo de lago, que podem ser usados para estimarmos uma distribuição de probabilidade para cada tipo de lago descrevendo a chance de encontrar um lago pertencente à classe ω_i .

Posteriormente a forma dessa distribuição se tornará mais específica, mas aqui basta apenas representá-la como $p(x | \omega_i)$

Podemos relacioná-las com o teorema de Bayes

$$p(\omega_i | x) = \frac{p(x | \omega_i)p(\omega_i)}{p(x)} \quad (3.7)$$

onde $p(\omega_i)$ é a probabilidade de que a classe ω_i ocorra na imagem, $p(x)$ é a probabilidade de encontrar um lago de qualquer classe na imagem.

$$p(x) = \sum_{i=1}^M p(x | \omega_i)p(\omega_i)$$

Aqui $p(x)$ não tem tanta importância no que segue. Chamamos $p(\omega_i)$ de probabilidade a priori, uma vez que são as probabilidades com que a associação de classe de um lago pode ser inferidas antes da classificação. Em comparação, $p(\omega_i | x)$ são probabilidades posteriores. Com base em (3.7) nossa regra de classificação é:

$$x \in \omega_i \text{ se } p(x | \omega_i)p(\omega_i) > p(x | \omega_j)p(\omega_j) \text{ para todo } j \neq i$$

essa forma é mais aceita uma vez que $p(x | \omega_i)$ é conhecido a partir do conjunto de treina-

mento. Por convenção usa-se:

$$\begin{aligned} g_i(x) &= \ln\{p(x | \omega_i)p(\omega_i)\} \\ &= \ln p(x | \omega_i) + \ln p(\omega_i). \end{aligned}$$

Com isso temos

$$x \in \omega_i \text{ se } g_i(x) > g_j(x) \text{ para todo } j \neq i \quad (3.8)$$

com mais uma modificação vamos ter a regra de classificação utilizada no classificador.

Assumindo que a distribuição de probabilidade é a Gaussiana, sua função máxima verossimilhança é dada como segue:

$$g_i(x) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (x - \mu)^t \Sigma^{-1} (x - \mu) \right] \quad (3.9)$$

onde x é um n -ésimo vetor, μ é a média do n -ésimo vetor, Σ é a matriz $n \times n$ de covariância, $|\Sigma|$ e Σ^{-1} são suas determinantes e inversas respectivamente, e ainda $(x - \mu)^t$ denota a transposta de $x - \mu$.

Para uma melhor computação dos resultados devemos converter a função acima para uma função discriminante, que em sua forma logarítmica é denotada por

$$g_i(x) = \ln |\Sigma| + (x - \mu)^t \Sigma^{-1} (x - \mu),$$

onde μ e Σ são o vetor de média e a matriz de covariância dos dados na classe ω_i .

O processo de classificação um lago se dá como vemos no algoritmo 3.2.

Algoritmo 3.2 Algoritmo de Classificação por Máxima Verossimilhança

Require: Lago x com atributos extraídos

- 1: **for** $i = 1, \dots, n$ **do** Calcular g_i do lago para cada classe C_i
 - 2: $g_i \leftarrow \ln |\Sigma| + (x - \mu)^t \Sigma^{-1} (x - \mu)$
 - 3: **end for**
 - 4: Associe o lago x à classe onde $g_i(x)$ for maior.
 - 5: **return** Lago x , Classe C_i
-

3.9 Métricas de Qualidade do Classificador

3.9.1 Matriz de Confusão

Uma matriz de confusão contém informações sobre dados classificados e dados reais geradas por um sistema de classificação. O desempenho de tais sistemas é comumente avaliado utilizando os dados na matriz (Kohavi & Provost, 1998).

A tabela 3.9.1 mostra a matriz de confusão para um classificador de duas classes. Aqui a_{11} é o número correto de classificações de uma instância que pertence à classe $C1$, a_{12} é o número incorreto de classificações de objetos que pertencem à classe $C1$ e foram classificados na classe $C2$, a_{21} é o número incorreto de classificações de objetos que pertencem à classe $C2$ e foram classificados na classe $C1$, e por último, a_{22} é o número correto de classificações de uma instância que pertence à classe $C2$.

		Classificadas	
		C1	C2
Reais	C1	a_{11}	a_{12}
	C2	a_{21}	a_{22}

Tabela 3.6: Matriz de Confusão para Sistema com duas Classes

A partir dessa matriz pode-se calcular algumas medidas de qualidade do classificador para uma matriz de confusão 2×2 :

Acurácia: É a proporção do número total de classificações que estavam corretas.

$$AC = \frac{a_{11} + a_{22}}{a_{11} + a_{12} + a_{21} + a_{22}} \quad (3.10)$$

Sensibilidade: É a proporção de casos da classe C_i que foram corretamente classificados

$$TC1 = \frac{a_{11}}{a_{11} + a_{12}} \quad (3.11)$$

Especificidade: É a proporção de casos de $C2$ que foram corretamente classificados

$$TC2 = \frac{d}{c + d} \quad (3.12)$$

Precisão:

$$P = \frac{d}{b + d} \quad (3.13)$$

Taxa de erro de $C1$: É a proporção de casos de $C1$ que foram incorretamente classificados

$$\frac{c}{c + d} \quad (3.14)$$

Taxa de erro de $C2$: É a proporção de casos de $C2$ que foram incorretamente classificados

$$\frac{b}{a + b} \quad (3.15)$$

Neste capítulo foram apresentadas as metodologias empregadas no decorrer desta pesquisa. Foi demonstrado conceitos importantes como: Morfometria, Sensoriamento Remoto, Extração de Atributos de Lagos. As especificações do satélite CBERS também foram listadas. Uma tabela contendo as características paisagísticas por tipo de lago foi citada apenas como referência. A etapa de Extração de Atributos foi detalhada e por fim o classificador por Máxima Verossimilhança foi implementado.

4

RESULTADOS E ANÁLISES

TODOS os algoritmos foram executados em um ambiente Linux de 64 bits, sob as seguintes configurações:

Computador	Notebook ®Dell Inspiron N5010
OS	Ubuntu 11.10
Memoria	2.8 GiB
Processador	®Intel TM Core i3 CPU M 350 @ 2.37 GHz ×4
Placa gráfica	®Intel Ironlake Mobile
Plataforma	64-bit
Disco rígido	320 GiB

4.1 Comentários sobre a qualidade do treinamento

A respeito da qualidade do treinamento do classificador, devemos levar em consideração os problemas enfrentados para que a classificação fosse realizada pelo especialista. Inicialmente, o trabalho seria desenvolvido em conjunto com pesquisadores da área de biologia, ou seja, nossos especialistas seriam experientes em classificação de lagos.

Devido a alguns contratemplos o suporte esperado pela equipe da biologia foi insatisfatório, ficando a classificação por especialista a cargo de uma equipe menos experiente com esse trabalho. O que se fez na prática, foi exibir as imagens para um grupo de três pesquisadores, onde para cada uma associava o lago x à classe y . No final todos os dados eram unificados e prevalecia a classificação mais frequente para cada lago.

Ao observar o processo de classificação pelo especialista, podemos perceber que o mesmo está sujeito a falhas humanas, porém, nada disso interfere no processo de desenvolvimento dessa metodologia.

É muito importante ressaltar também que o número de amostras utilizadas tanto para treinar quanto para testar o classificador foi bastante reduzido, devido a dificuldade de encontrar e classificar essas imagens.

4.2 Eficácia do Classificador

Neste trabalho, optamos por medir a eficácia do classificador através da matriz de confusão. A partir da medida de acurácia extraída das matrizes de confusão temos para a análise univariada o gráfico 4.1. Aqui percebemos que o melhor classificador é o coeficiente a_n da análise de Fourier aplicada a variação de raios, no ponto em que $n = 9$.

As tabelas 4.1 e 4.2 mostram as melhores classificações obtidas com atributos univariados. A primeira deve-se ao uso de a_9 , isto é, a nona componente dos coeficientes pares de Fourier aplicada a variação de raios; já a segunda é o resultado de usar $r = 1$, isto é, a primeira coordenada do raio, outro componente de Fourier aplicado a variação de raios.

As classificações são muito parecidas quando comparadas pelo índice de acurácia ($AC = 0,588$, e $AC = 0,588$), sendo que nenhuma delas pode ser considerada uma ótima classificação. A primeira produz excelentes resultados para as classes C1 e C2, mas falha com a classe C3 e é inaceitável para a classe C4. Esse comportamento pode ser corroborado na Figura 4.2. Nesta figura mostramos nas cores azul, vermelho, laranja e verde as amostras e modelos para as classes C1, C2, C3 e C4, respectivamente. As curvas são as densidades estimadas usando as amostras de treinamento que, por sua vez, estão representadas por símbolos “oculos”. As amostras de teste estão representadas por símbolos “cheios”. A confusão entre classes é evidente ao verificar que as amostras de treinamento não se separam naturalmente. Um comportamento similar é observado na classificação pelo atributo $r = 1$.

Tabela 4.1: Matriz de Confusão Atributo a_n , $n = 9$, $AC = 0.588$

	C1	C2	C3	C4
C1	91,67%	8,33%	0%	0%
C2	16,67%	66,67%	0%	16,67%
C3	12,50%	50,00%	12,50%	25,00%
C4	0%	50,00%	0%	50,00%

A Tabela 4.1 apresenta a matriz de confusão para o melhor atributo encontrado, permite observar as seguintes informações:

- Para esse atributo a classe C2 teve um desempenho aceitável, enquanto que a classe C1 obteve um ótimo resultado.

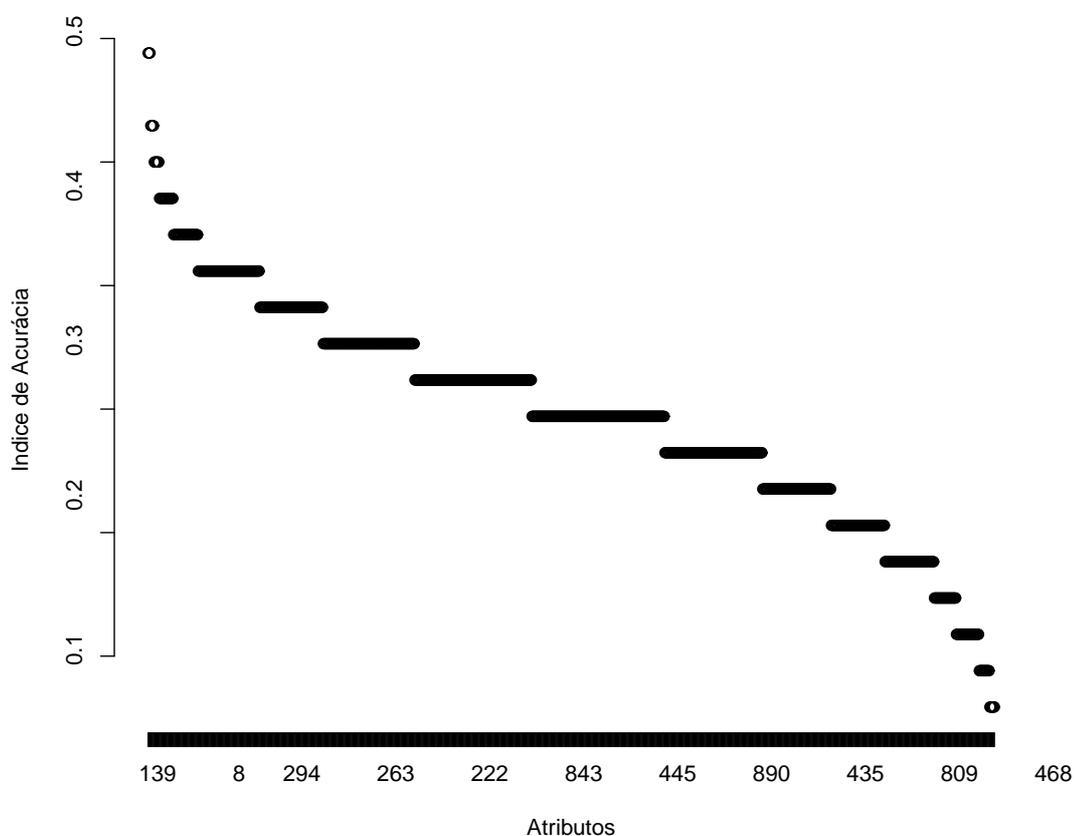


Figura 4.1: Índice de Acurácia por Atributo para a Análise Univariada

- A classe C3 confunde-se com as demais, além da maioria das amostras para essa classe (50,00%) ter sido incorretamente classificada.
- A classe C4 teve um desempenho ruim, não possuindo a grande maioria das amostras corretamente classificada.

Tabela 4.2: Matriz de Confusão Atributo $r = 1$, $AC = 0.588$

	C1	C2	C3	C4
C1	91,67%	0%	0%	8,33%
C2	0%	100,00%	0%	0%
C3	25,00%	25,00%	37,50%	12,50%
C4	37,50%	62,50%	0%	0%

A Tabela 4.2 que apresenta a matriz de confusão para o segundo melhor atributo encontrado, permite inferir as seguintes informações:

- A classe C3 apresenta o mesmo comportamento, confundindo-se muito com as de-

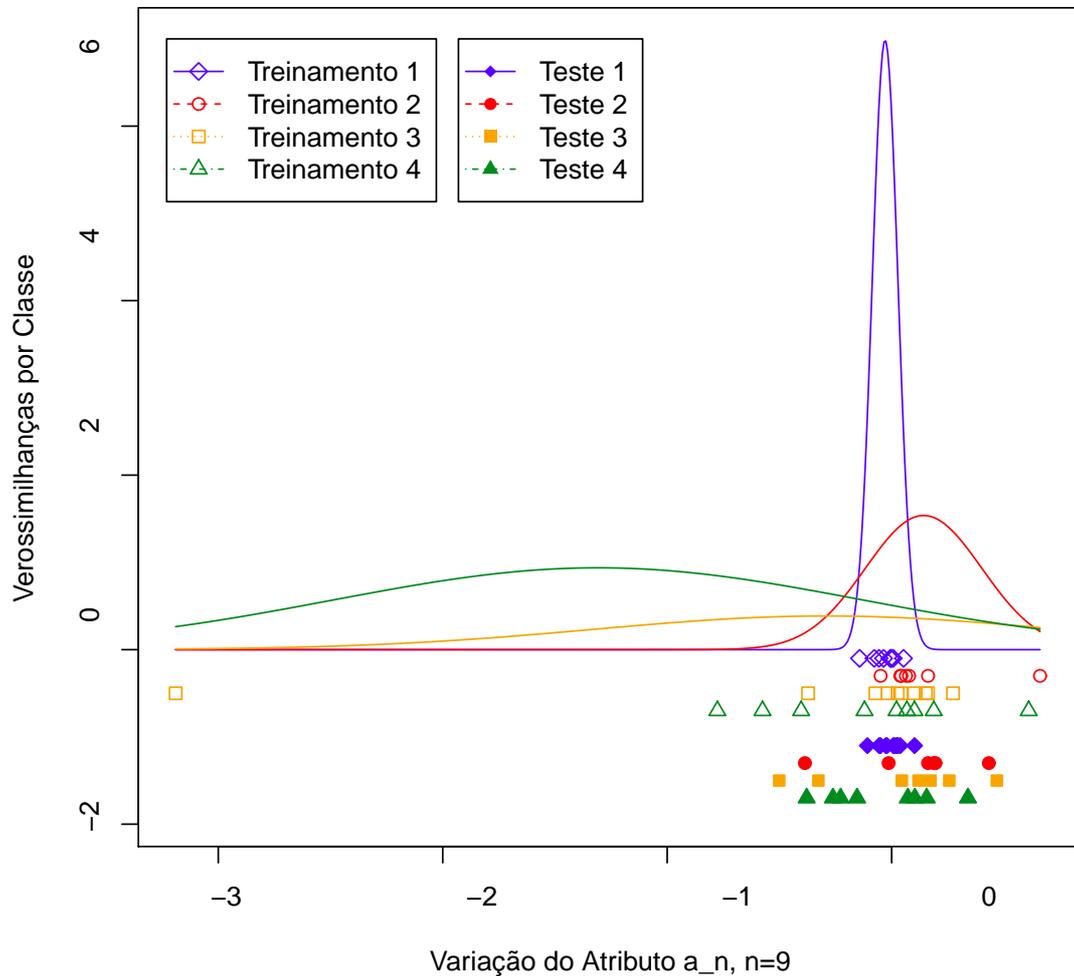


Figura 4.2: Verossimilhanças para cada classe segundo o melhor atributo univariado

mais, contudo a maioria das amostras para essa classe (37,50%) foi corretamente classificada

- A classe C4 teve um péssimo desempenho, não possuindo nenhuma amostra corretamente classificada.
- Para esse atributo a classe C2 teve um excelente desempenho, enquanto que a classe C1 obteve também um ótimo resultado.

Esse capítulo apresentou as principais abordagens para aferir a proposta apresentada. Dando ênfase em medidas quantitativas para avaliar a qualidade de imagens aplicadas aos dados. Finalizamos com o próximo capítulo, onde serão relatados os principais impactos e contribuições deste trabalho e os passos futuros.

5

CONCLUSÕES

NESTE trabalho, optamos por desenvolver uma técnica de análise de imagens que categorizou lagos da bacia do rio Amazonas.

A análise dos dados permitiu gerar conhecimento no que diz respeito a área de reconhecimento de padrões em lagos amazônicos. A classificação foi feita por máxima verossimilhança gaussiana.

Como conclusões dessa pesquisa pode-se concluir que:

- A Análise de Fourier pode ser empregada na extração de atributos morfométricos em sistemas lacustres.
- Alguns atributos extraídos foram excluídos do classificador por não apresentarem valores aceitáveis de variância ou covariância.
- O classificador funciona muito bem para certos tipos de classes e não tão bem para outras.
- De acordo com o número de amostras utilizados por classe, a acurácia do classificador aumenta ou diminui.
- A Categorização de Lagos quanto a forma é um processo que se dá de forma supervisionada, e sofre alterações de acordo com o tipo de sensor que fornece a imagem.
- Todos os resultados aqui apresentados foram realizados a partir de imagens satelitais da banda infravermelha.
- As técnicas para detecção de bordas utilizando Lógica Difusa representa um caminho de pesquisa que será desenvolvido em trabalhos futuros.

Todo o trabalho desenvolvido nessa pesquisa deu origem a um roteiro que deve ser utilizado por biólogos com o intuito de classificar e obter dados morfométricos de lagos. A pesquisa utilizou principalmente lagos da bacia amazônica, mas pode facilmente ser adaptado a outros tipos de sistemas lênticos, respeitando o número de classes observado em cada ambiente.

A classificação de lagos pela sua forma se mostrou um problema desafiador e não ficou completamente resolvido. Dentre os problemas que conspiraram contra a qualidade dos resultados desta proposta elencamos dois principais:

1. A nossa abordagem incorporou o conhecimento dos especialistas sem criticá-lo. Em particular, o número de classes não foi verificado pelos dados. Talvez uma análise de agrupamento seja capaz de detectar esse problema.
2. A distância do lago ao rio foi reputada pelos especialistas como muito importante, mas não foi levada em conta por não ser um atributo morfométrico intrínseco aos lagos e por ele não estar nem bem definido nem disponível para os dados aqui tratados.

Não podemos considerar os resultados definitivos, mas eles apontam uma direção de trabalho. Este trabalho pode ser facilmente estendido, já que o código foi desenvolvido seguindo preceitos de Engenharia de Software e de Reproducible Research.

Apêndice A

AMBIENTE REPRODUTÍVEL E COMPUTACIONAL

A seguir temos alguns exemplos de dados utilizados para análise. Esses exemplos, ilustram algumas falhas na classificação por parte do especialista

A.1 Amostras

As Figuras [A.1](#), [A.3](#), [A.5](#) e [A.7](#) são as amostras utilizadas no treinamento do classificador. Enquanto que as Figuras [A.2](#), [A.4](#), [A.6](#) e [A.8](#) são as amostras de teste.

Podemos claramente observar pela Figura [A.1\(h\)](#) que essa amostra foi incorretamente associada à classe *C1* pelo especialista. O mesmo comportamento pode ser observado na Figura [A.2\(j\)](#).

Ainda a respeito de erros de classificação pode-se observar pelas Figuras [A.3\(f\)](#) e [A.4\(a\)](#) que as amostras parecem pertencer à classe *C3* e no entanto o especialista as categorizou como pertencendo à classe *C2*.

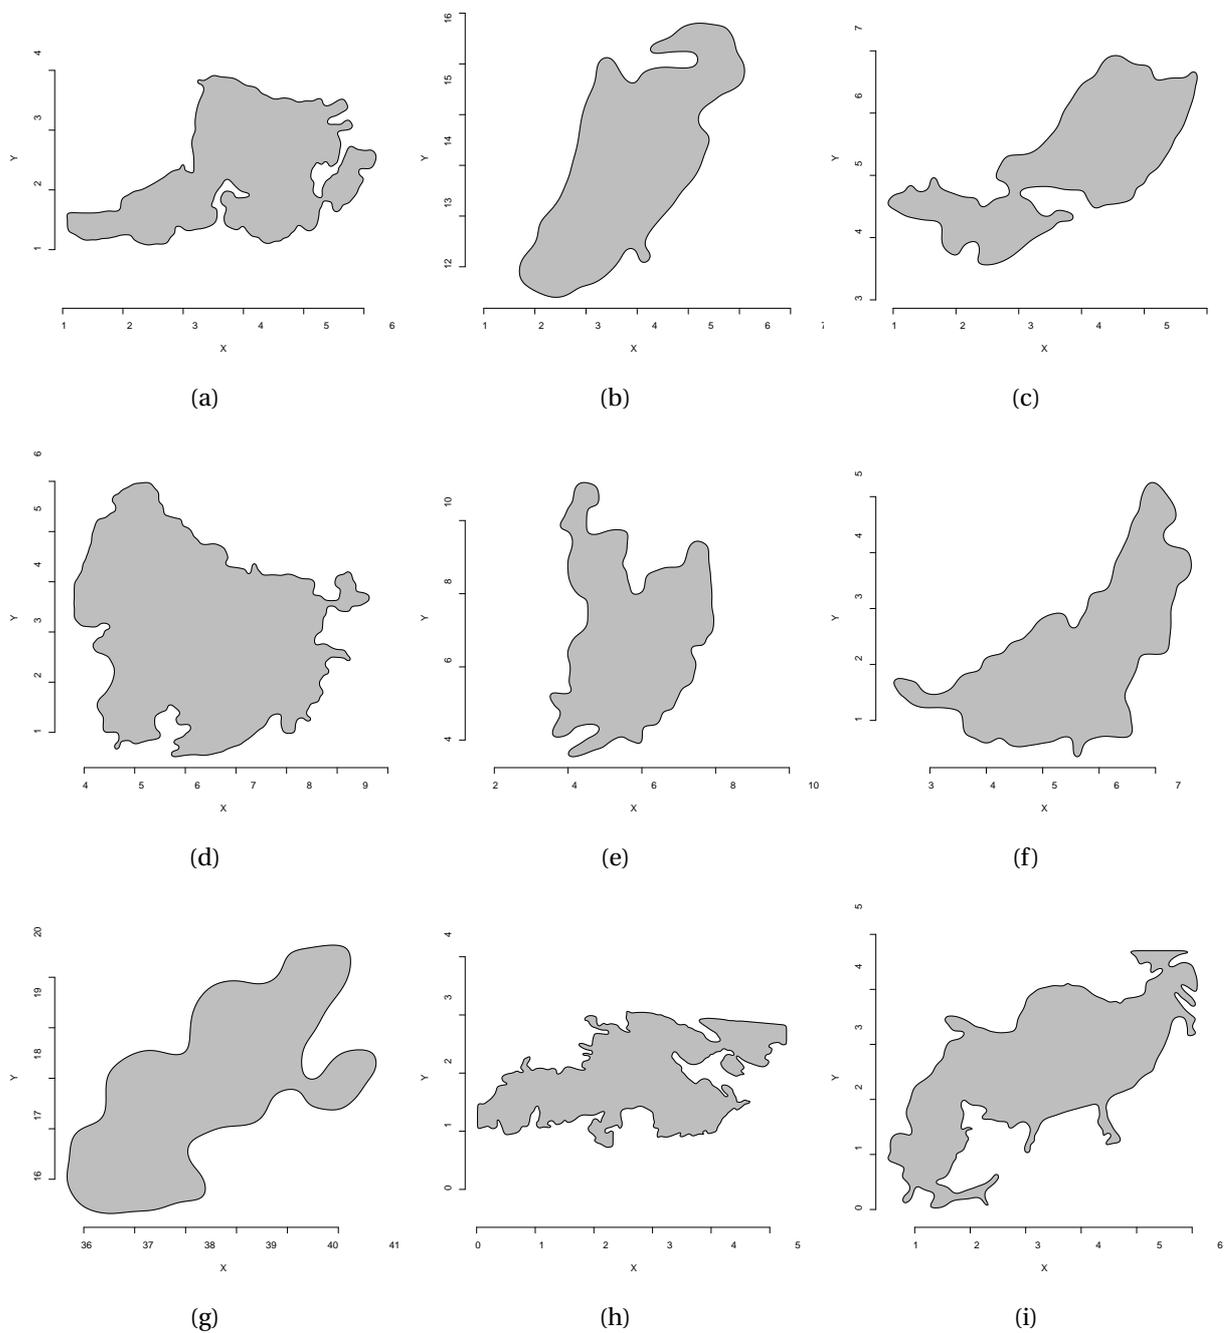


Figura A.1: Amostras da Classe C1 utilizadas no conjunto de Treinamento

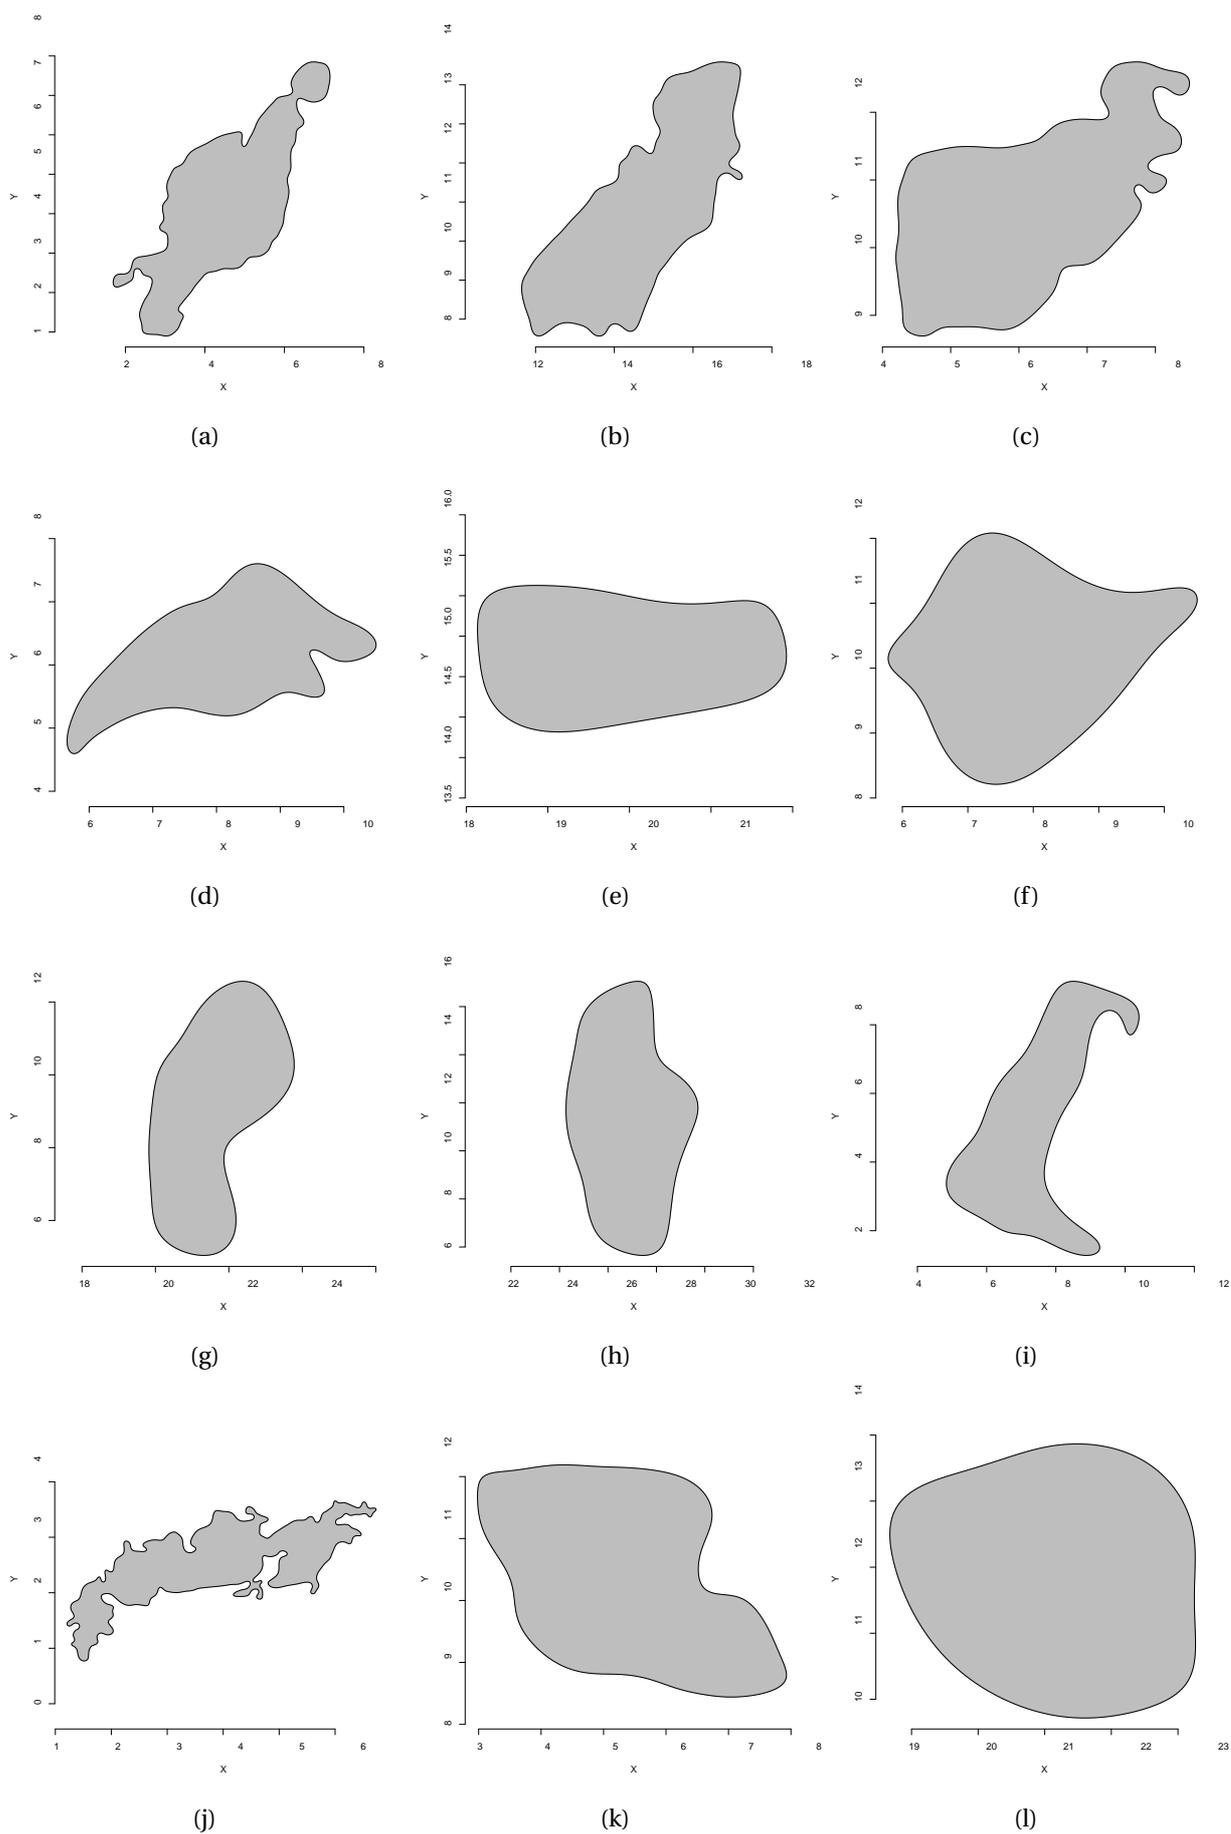


Figura A.2: Amostras da Classe C1 utilizadas no conjunto de Teste

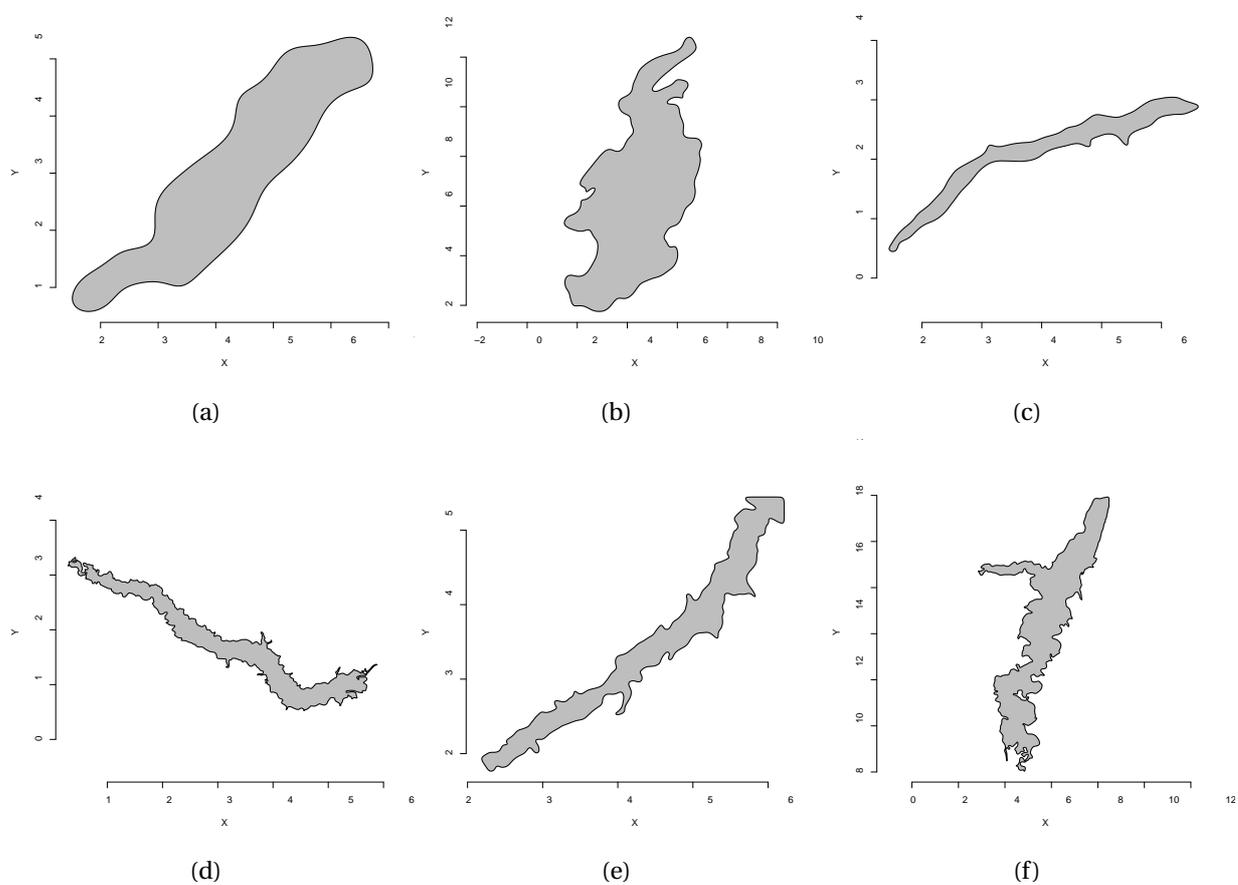


Figura A.3: Amostras da Classe 2 utilizadas no conjunto de Treinamento

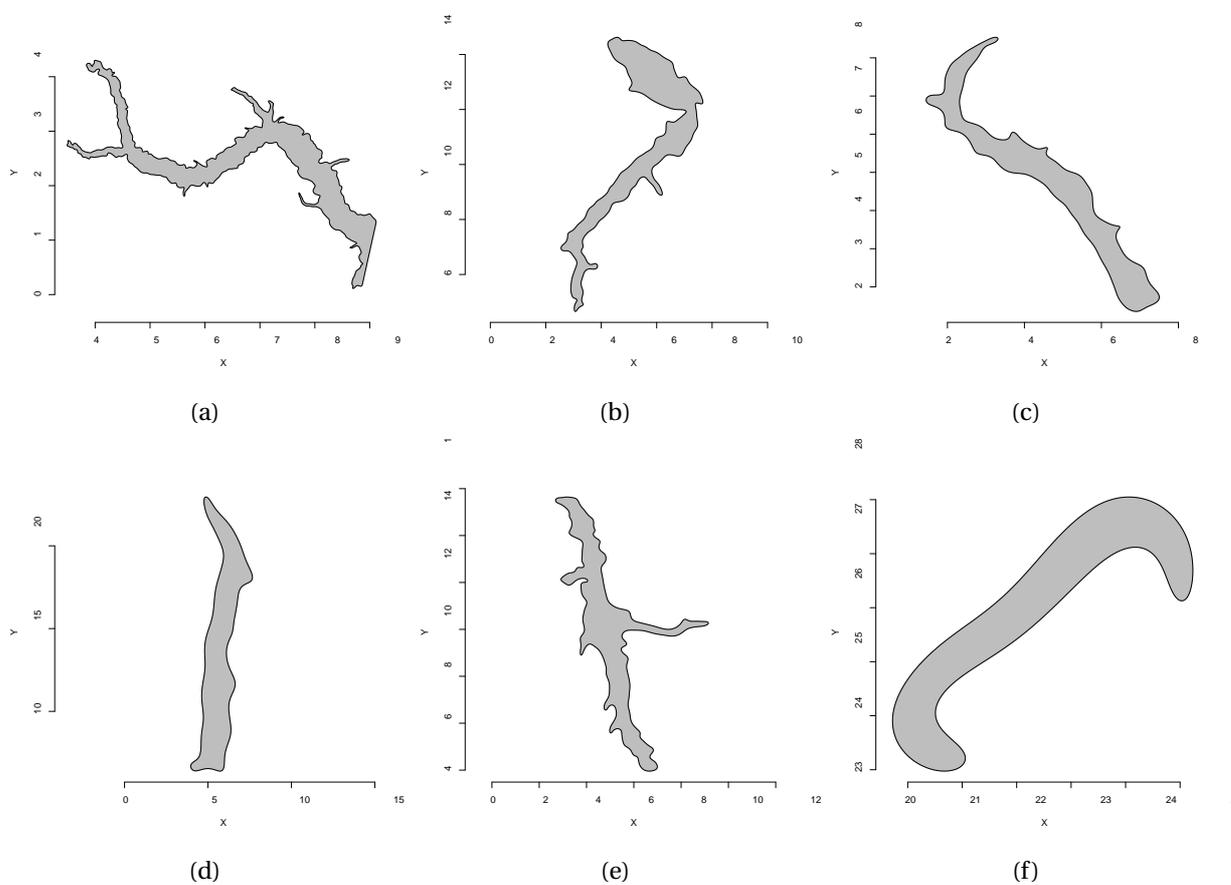


Figura A.4: Amostras da Classe C2 utilizadas no conjunto de Teste

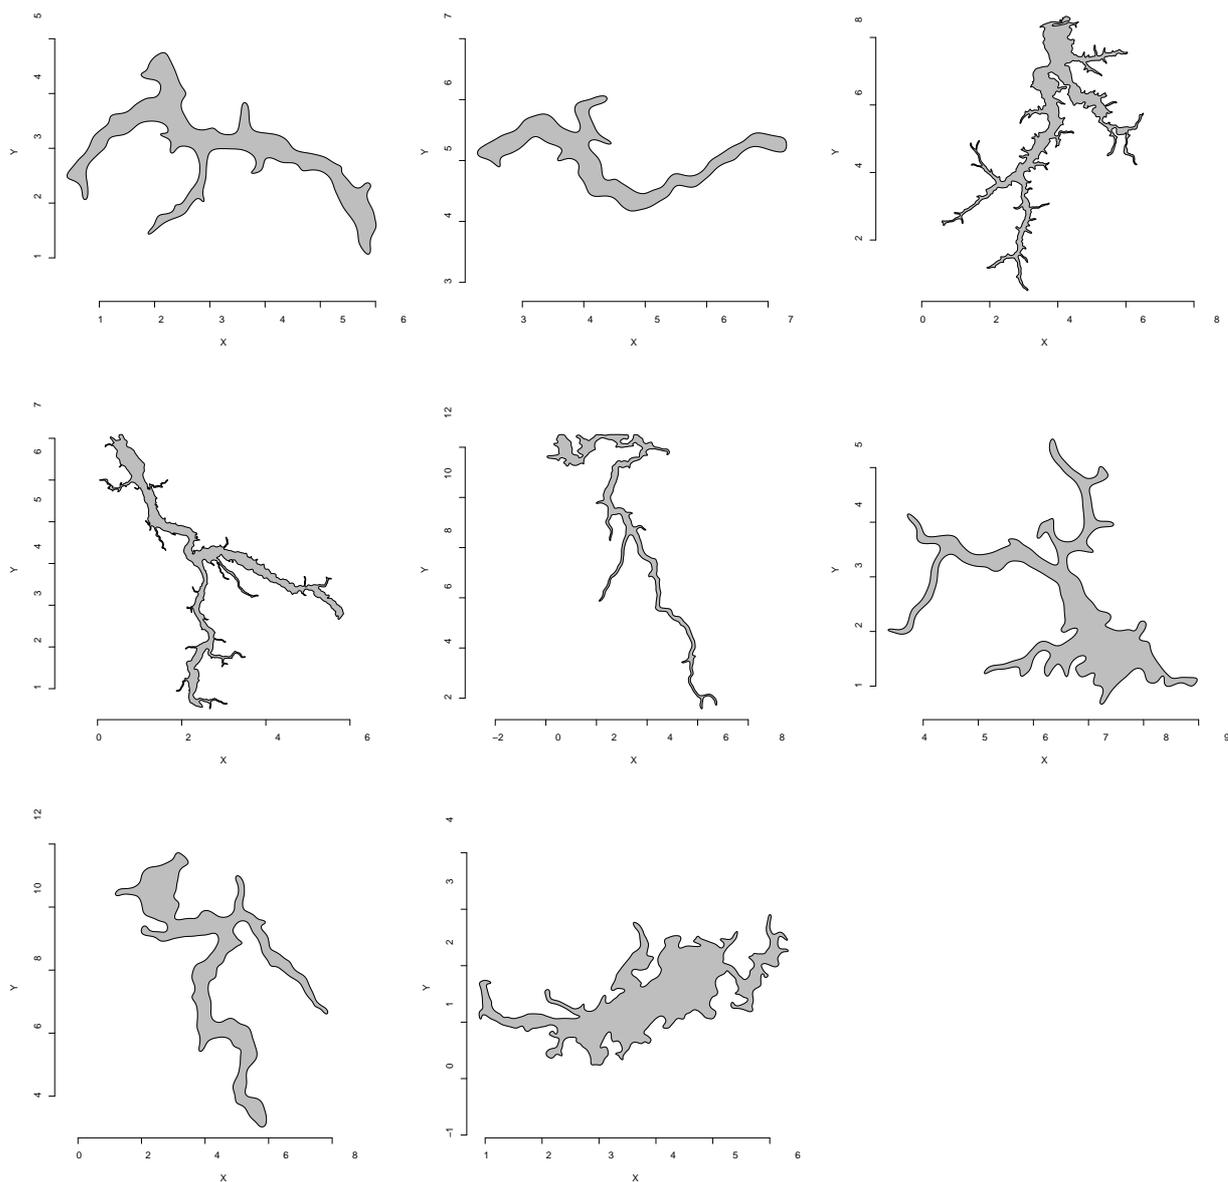


Figura A.5: Amostras da Classe C3 utilizadas no conjunto de Treinamento

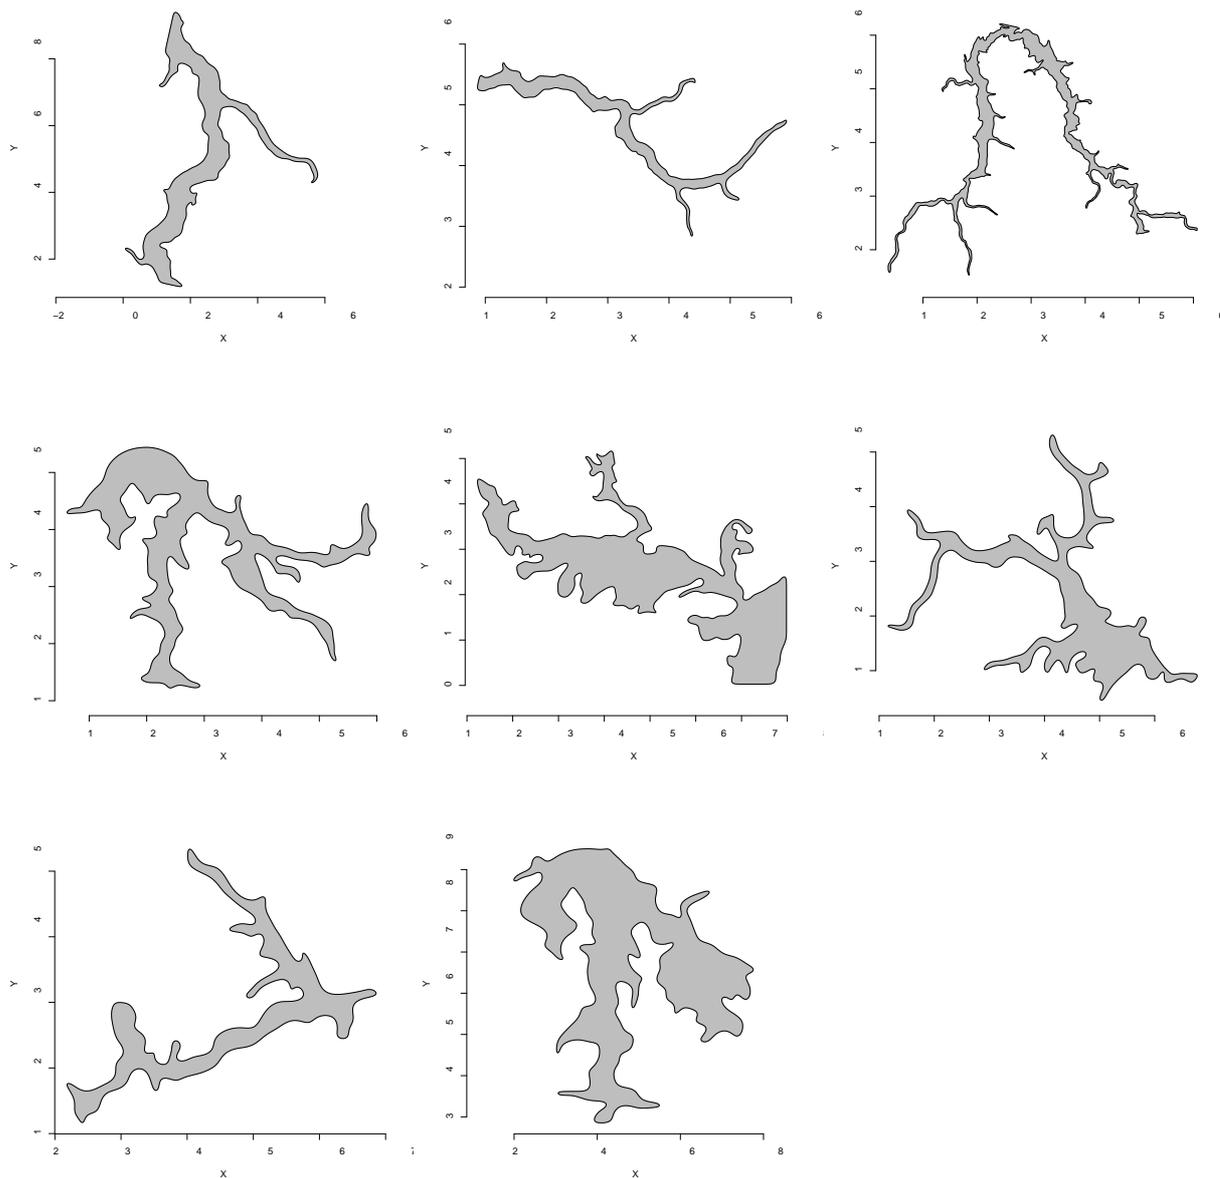


Figura A.6: Amostras da Classe C3 utilizadas no conjunto de Teste

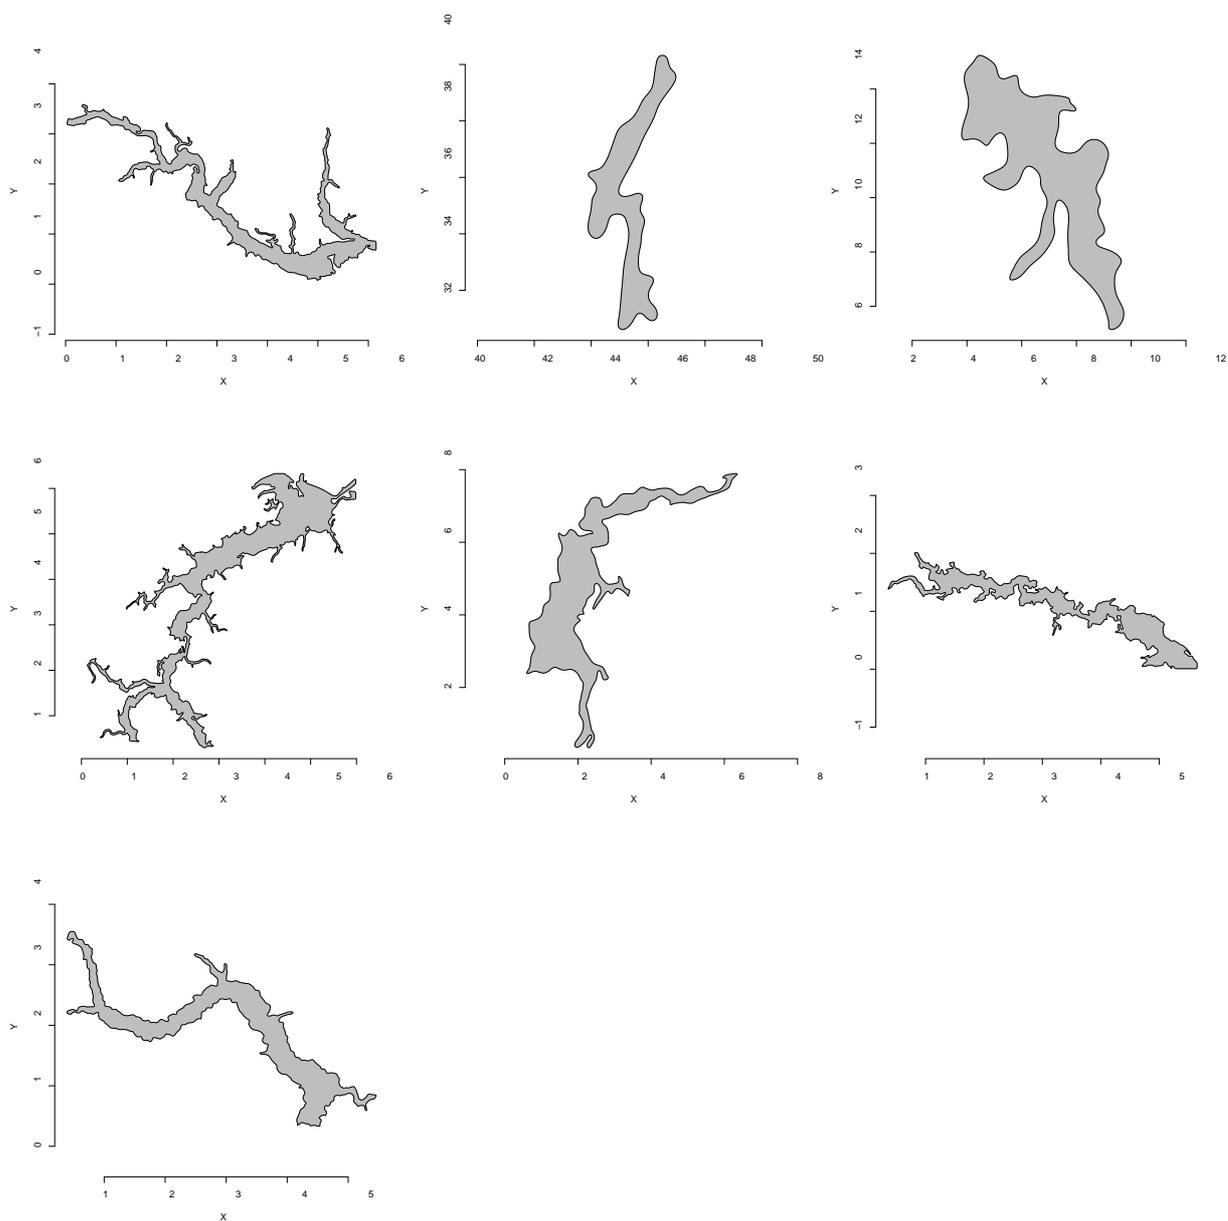


Figura A.7: Amostras da Classe C4 utilizadas no conjunto de Treinamento

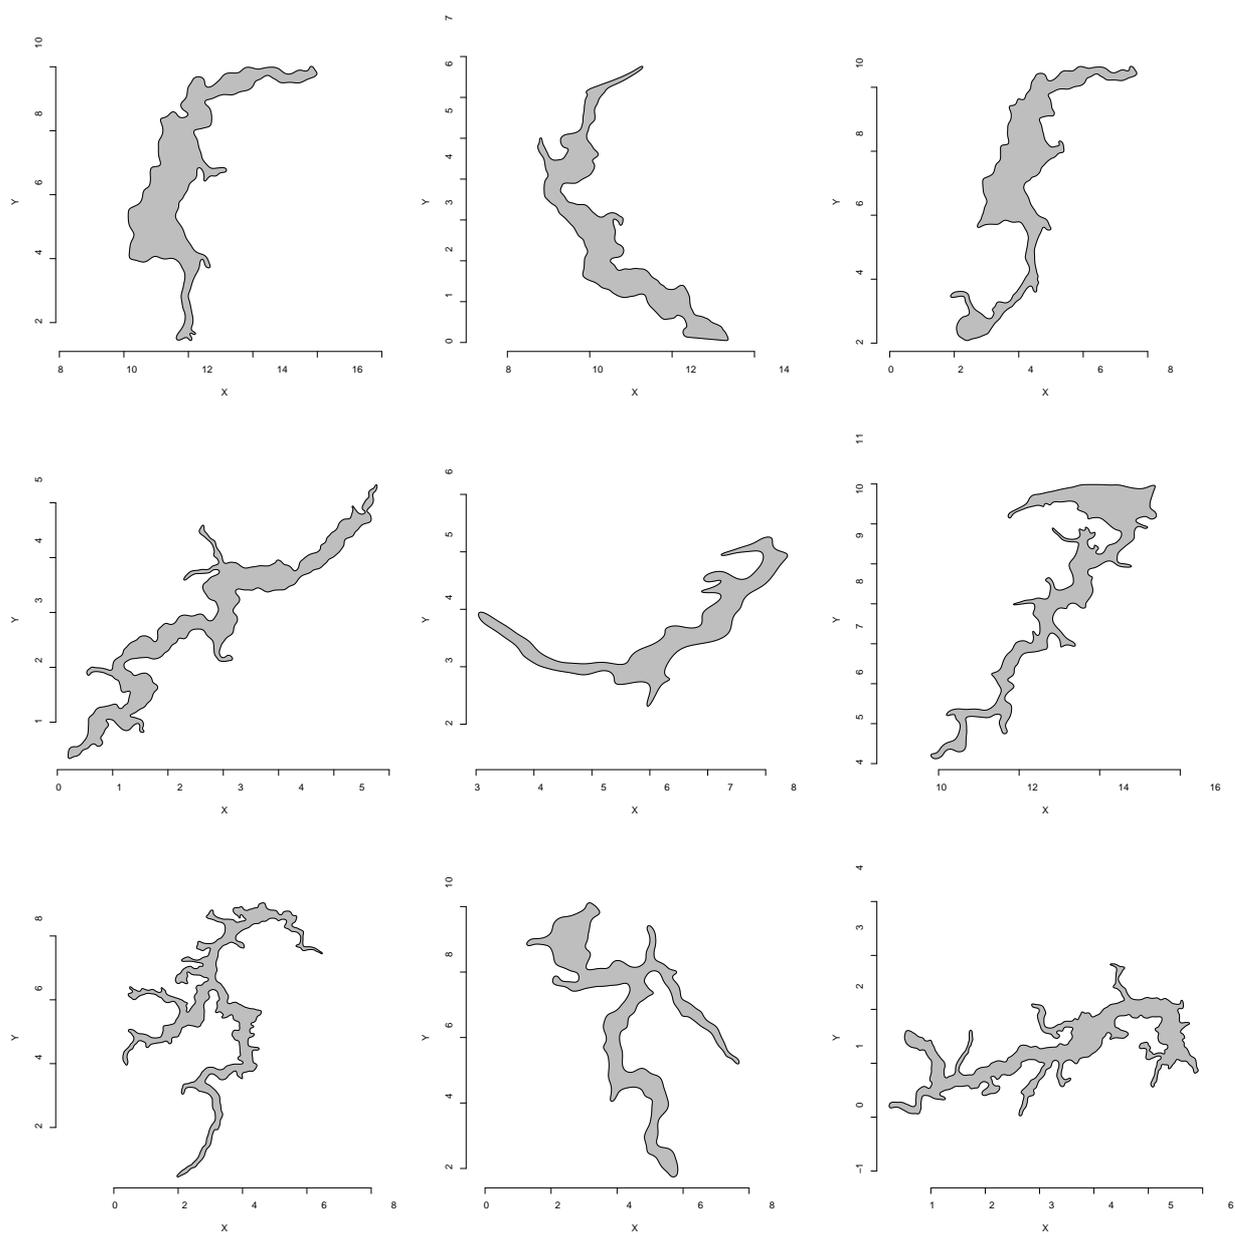


Figura A.8: Amostras da Classe C4 utilizadas no conjunto de Teste

REFERÊNCIAS BIBLIOGRÁFICAS

- Amaral, G. J. A. (2004), Bootstrap and Empirical Likelihood Methods in Statistical Shape Analysis, PhD thesis, University of Nottingham.
- Barbosa, C., J., H. L. M. & M., N. E. M. L. (2000), 'Mapping amazon basin wetlands through region growing segmentation and segmented-based classification jers-1 data', *IX Simpósio Latino Americano de Percepção Remota y Sistemas de Información Espacial Anais*, 1165–1176.
- Bayley, P. B. (1981), 'Fish yield from the amazon in brazil - comparison with african river yields and management possibilities', *Transactions of The American Fisheries Society* **110**(3), 351–359.
- Bayley, P. B. & Petrere, M. (1989), 'Amazon fisheries: assessment methods, current status and management options', *Canadian Special of Fisheries and Aquatic Sciences*. **n.d.**(106), 385–398.
- Bins, L. S., Fonseca, L. M. G., Erthal, G. J. & II, F. M. (1996), 'Satellite imagery segmentation: A region growing approach.', *VII Simposio Brasileiro de Sensoriamento Remoto Anais*, Anais.
- Bookstein, F. L. (1986), 'Size and shape spaces for landmark data in two dimensions (with discussion)', *Statistical Science* **1**, 181–242.
- Bookstein, F. L. (1989), 'Size and shape - a comment on semantics', *Systematic Zoologic* **38**, 173–180.
- BR, F., CARM, A. L., LA, M., RL, V., JA, B. et al. (1993), 'Autotrophic carbon-sources for fish of the central amazon', *Ecology* **74**(3), 643–652.
- Burrough, P. A. (1986), *Principles of Geographical Information Systems dor Land Resources Assessment*, Oxford: Calderon Press.
- Canny, J. F. (1986), 'A computational approach to edge detection', *IEEE Transactions on Pattern Analysis and Machine Intelligence* **8**, 679–698.
- Claude, J. (2008), *Morphometrics with R*, Use R, Springer Science+Business Media, LLC, New York, NY, 10013, USA.
- Cole, G. A. (1979), *Textbook of Limnology*, 2d ed., Mosby.
- Crampton, J. S. (1995), 'Elliptic fourier shape analyses of fossil bivalves: some practical considerations', *Lethaia* **13**, 361–366.

- Câmara, G., Souza, R. C. M., Freitas, U. M. & Garrido, J. (1996), 'Spring: Integrating remote sensing and gis by object-oriented data modelling', *Computers & Graphics* **20**, 395–403.
- dos Santos, A. R., de Oliveira Peluzio, T. M. & Saito, N. S. (2010), *SPRING 5.1.2 : passo a passo : aplicações práticas*, P.O. Box 515, 12201-010 São José dos Campos, Brazil. URL <http://www.dpi.inpe.br/spring/>.
- Duda, R. O., Hart, P. E. & Stork, D. G. (2001), *Pattern Classification*, 2 ed., John Wiley & Sons, New York.
- Esteves, F. A. (1988), *Fundamentos de Limnologia*, Editora Interciência, Rio de Janeiro.
- Forsberg, B. R., Devol, A. H., Richey, J. R., Martinelli, L. A. & Dossantos, H. (1988), 'Factors controlling nutrient concentrations in amazon floodplain lakes', *Limnology and Oceanography* **33**(1), 41–56.
- França, A. M. d. S. (2005), Aplicação de sensoriamento remoto no estudo da influência da dinâmica sazonal do rio amazonas sobre a morfologia dos sistemas lacustres, Master's thesis, INPE - Instituto Nacional de Pesquisas Espaciais.
- Frery, A. C. & Perciano, T. (2009), *Atualizações em Informática*, PUC-Rio, Rio de Janeiro, chapter Processamento de Imagens usando R, pp. 67–111.
- Giardina, C. R. & Kuhl, F. P. (1977), 'Accuracy of curve approximation by harmonically related vectors with elliptical loci.', *Computers Graphics and Image Processing*. **6**, 277–285.
- Gonzalez, R. C. (2002), *Digital Image Processing*, Prentice Hall.
- Goodall, C. R. (1991), 'Procrustes methods in the statistical analysis of shape (with discussion)', *Journal of the Royal Statistical Society, Series B* **53**, 285–339.
- Goulding, M., Smith, N., Mahar, D. et al. (1995), *Floods of fortune: ecology and economy along the Amazon*, Columbia University Press.
- Hannay, M. V. B. . J. H. (1978), 'Topography of random surfaces', *Nature* **273**, 573.
- Hutchinson, G. E. (1975), *A Treatise on Limnology, Vol. 3: Limnological Botany*, Vol. 3, John Wiley & Sons Inc.
- INPE (2007a), 'Câmeras imageadoras', Ministério da Ciência e Tecnologia. URL <http://www.cbears.inpe.br/?content=cameras1e2e2b>.
- INPE (2007b), 'Descrição do cbers 1, 2 e 2b', Ministério da Ciência e Tecnologia. URL <http://www.cbears.inpe.br/?content=descricao1e2e2b>.

- INPE (2007c), 'Usos e aplicações', Ministério da Ciência e Tecnologia. URL <http://www.cbbers.inpe.br/?content=aplicacoes>.
- Junk, W. (1984), 'Aquatic habitats in amazônia', *The Environmentalist* **3**, 24–34.
- Junk, W. (1985), 'Temporary fat storage, an adaptation of some fish species to the waterlevel fluctuatiions and related envirommental-changes of the amazon river', *Amazoniana-Limnologia Et Oecologia Regionalis Systemae Fluminis Amazonas* **9**(3), 315–351.
- Junk, W. & Piedade, M. (1993), 'Herbaceous plants of the amazon floodplain near manaus - species-divesity and adaptacions to the flood pulse', *Amazoniana-Limnologia Et Oecologia Regionalis Systemae Fluminis Amazonas* **12**(3-4), 467–484.
- Junk, W. J. (1989), 'The use of amazonian floodplains under an ecological perspective', *Interciencia* **14**(6), 317–322.
- Junk, W. J., Piedade, M. T. F. & P, L. S. (1997), 'Nutrient dynamics of the highly productive c-4 macrophyte echinochloa polystachya on the amazon floodplain', *Functional Ecology* **11**(1), 60–65.
- Kendall, D. G. (1984), 'Shape manifolds, procrustean metric and complex projective spaces', *Bulletin of the London Mathematical Society* **16**, 81–121.
- Kern, J., Darwich, A., Furch, K. & Junk, W. J. (1996), 'Seasonal denitrification in flooded and exposed sediments from the amazon floodplain at lago camaleao', *Microbial Ecology* **32**(1), 47–57.
- Kohavi, R. & Provost, F. (1998), 'Glossary of terms. editorial for the special issue on applications of machine learning and the knowledge discovery process', *Machine Learning* **30**, 271–274.
- Lehner, B. & Döll, P. (2004), 'Development and validation of a global database of lakes, reservoirs and wetlands.', *Journal of Hydrology* **296**, 1–22.
- Melack, J. M. & Setaro, F. V. (1984), 'Responses of phytoplankton to experimental nutrient enrichment in an amazon floodplain lake', *Limnology and Oceanography* **29**(5), 972–984.
- Nobre, A. D. (2004), 'Desvendando as complexidades do ciclo do carbono na amazonia', *Conferência Científica do LBA* **3**, n.d.
- Nolan, K. S. (2000), O rendimento pesqueiro em sistemas lacustres da amazônia central, Master's thesis, Manaus, INPA/FUA.

- Nolan, K. S. (2004), A Pesca Profissional de Sistemas de Lagos do Eixo Fluvial Solimões-Amazônia e Principais Tributários do Estado da Amazônia, PhD thesis, UFAM.
- Nolan, K. S., Fabré, N. N. & Batista, V. S. (2009), 'Landscape variables affecting fishery yield in lake systems of the central amazon region, brazil', *Journal of Applied Ichthyology* **25**, 294–298.
- Novo, E. M. L. M., Shimabukuro, Y. E. & Mertes, L. (1998), *O rio Amazonas em mosaico*, number 144, Ciência hoje.
- Novo, E. M., Leite, F. A., Ávila, J., Ballester, V. & Melack, J. (1997), 'Assessment of amazo floodplain habitats using tm/landsat data.', *Ciência e Cultura Journal of the Brazilian Association for the Advancement of Science*, **49**, 280–284.
- Petrere, M., Vaz, M. M., Martinelli, L. A. & Mozeto, A. A. (1999), 'The dietary regime of detritivorous fish from the river jacare pepira brazil', *Fisheries Management and Ecology* **6**(2), 121–132.
- R Development Core Team (2009), *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org>, ISBN 3-900051-07-0.
- Rohlf, J. F. & Archie, A. W. (1984), 'A comparasion of fourier methods for the description of wing shape in mosquitoes (diptera:cuculidae)', *Systematic Zoologic* **33**, 302–317.
- Rustum, R., A., A. & Aurore, S. (2005), "'kohonen self-organising map (ksom) extracted features for enhancing mlp-ann prediction models of bod5'", *Conférence : Symposium on Water Quality and Sediment Behaviour of the Future* **314**, 181–187.
- Sieppel, S. J., Hamilton, S. K. & Melack, J. M. (1992), 'Inundation area and morphometry of lakes on the amazon river floodplain brazil', *Archiv fur Hydrobiologie* **123**(4), 385–400.
- Sioli, H. (1982), 'The relation between tropical rivers and the terrestrial environment and the effect on both of human interference', *Archiv fur Hydrobiologie* **95**, 463–485.
- Sperling, E. V. (1999), *Morfologia de lagos e represas*, Desa/UFMG.
- Tarbuck, E. J. & Lutgens, F. K. (1999), *EARTH An Introduction to Physical Geology*, 6 ed., Prentice Hall.
- Welcomme, R. L. (1976), 'Some general and theoretical considerations on fish yield of african rivers', *Journal of Fish Biology* **8**(5), 351–364.
- Welcomme, R. L. (1990), 'Status of fisheries in south-american rivers', *Interciencia* **15**(6), 337–345.

Welcomme, R. L. (1992), 'The conservation and environmental-management of fisheries in inland and coastal waters', *Netherlands Journal of Zoology* **42**(2-3), 176–189.

Wetzel, R. G. (1976), *Limnology*, Philadelphia: W. B. Saunders Company.

Este trabalho foi redigido em \LaTeX utilizando uma modificação do estilo IC-UFAL. As referências bibliográficas foram preparadas no JabRef e administradas pelo \BIBTeX com o estilo LaCCAN. O texto utiliza fonte Fourier-GUTenberg e os elementos matemáticos a família tipográfica Euler Virtual Math, ambas em corpo de 12 pontos.

