

**MINISTÉRIO DA DEFESA
EXÉRCITO BRASILEIRO
DEPARTAMENTO DE CIÊNCIA E TECNOLOGIA
INSTITUTO MILITAR DE ENGENHARIA
CURSO DE MESTRADO EM ENGENHARIA DE DEFESA**

CC(T) NADJANE CORRÊA DE ALMEIDA

**DETECÇÃO DE EMBARCAÇÕES EM IMAGENS DE
SENSORES ORBITAIS ÓPTICOS POR MEIO DE UM
MÉTODO BASEADO EM CARACTERÍSTICAS
CONTEXTUAIS E COMPARAÇÃO DE CONTORNO**

Rio de Janeiro

2018

INSTITUTO MILITAR DE ENGENHARIA

CC(T) NADJANE CORRÊA DE ALMEIDA

**DETECÇÃO DE EMBARCAÇÕES EM IMAGENS DE SENSORES
ORBITAIS ÓPTICOS POR MEIO DE UM MÉTODO BASEADO EM
CARACTERÍSTICAS CONTEXTUAIS E COMPARAÇÃO DE
CONTORNO**

Dissertação de Mestrado apresentada ao Curso de Mestrado em Engenharia de Defesa do Instituto Militar de Engenharia, como requisito parcial para a obtenção do título de Mestre em Engenharia de Defesa.

Orientador: Cel Carlos Frederico de Sá Volotão - Doutor

Coorientadora: Karla dos Santos Teixeira - Doutora

Rio de Janeiro

2018

© 2018

INSTITUTO MILITAR DE ENGENHARIA
Praça General Tibúrcio, 80 – Praia Vermelha
Rio de Janeiro – RJ CEP: 22290-270

Este exemplar é de propriedade do Instituto Militar de Engenharia, que poderá incluí-lo em base de dados, armazenar em computador, microfilmar ou adotar qualquer forma de arquivamento.

É permitida a menção, reprodução parcial ou integral e a transmissão entre bibliotecas deste trabalho, sem modificação de seu texto, em qualquer meio que esteja ou venha a ser fixado, para pesquisa acadêmica, comentários e citações, desde que sem finalidade comercial e que seja feita a referência bibliográfica completa.

Os conceitos expressos neste trabalho são de responsabilidade do(s) autor(es) e do(s) orientador(es).

621.3678 A447d	Almeida, Nadjane Corrêa de Detecção de embarcações em imagens de sensores orbitais ópticos por meio de um método baseado em características contextuais e comparação de contorno / Nadjane Corrêa de Almeida; orientada por Carlos Frederico de Sá Volotão; Karla dos Santos Teixeira – Rio de Janeiro: Instituto Militar de Engenharia, 2018. 97p.: il. Dissertação (Mestrado) – Instituto Militar de Engenharia, Rio de Janeiro, 2018. 1. Curso de Engenharia de Defesa – teses e dissertações. 2. Redes neurais. 3. Processamento de imagens I. Volotão, Carlos Frederico de Sá. II. Teixeira, Karla dos Santos. III. Instituto Militar de Engenharia.
-------------------	---

INSTITUTO MILITAR DE ENGENHARIA

CC(T) NADJANE CORRÊA DE ALMEIDA

**DETECÇÃO DE EMBARCAÇÕES EM IMAGENS DE SENSORES ORBITAIS
ÓPTICOS POR MEIO DE UM MÉTODO BASEADO EM CARACTERÍSTICAS
CONTEXTUAIS E COMPARAÇÃO DE CONTOURNO**

Dissertação de Mestrado apresentada ao Curso de Mestrado em Engenharia de Defesa do Instituto Militar de Engenharia, como requisito parcial para a obtenção do título de Mestre em Comunicações e Inteligência em Sistemas de Defesa.

Orientadores: Cel Carlos Frederico de Sá Volotão - Doutor

Karla dos Santos Teixeira - Doutora

Aprovada em 27 de março de 2018 pela seguinte Banca Examinadora:



Cel Carlos Frederico de Sá Volotão - Doutor - Presidente



Karla dos Santos Teixeira - Doutora do IPQM



Raul Queiroz Feitosa – Doutor da PUC-Rio



Paulo Fernando Ferreira Rosa, Doutor do IME



Raquel Aparecida Abrahão Costa e Oliveira, Doutora do IME

Rio de Janeiro

2018

Dedico esta dissertação à minha família, especialmente à minha querida mãe, ao meu companheiro, Cláudio, e ao meu amado filho, João Pedro.

AGRADECIMENTOS

Agradeço a Deus e à Marinha do Brasil, em especial ao Comando de Operações Navais e ao Centro de Guerra Eletrônica da Marinha, por terem me concedido a oportunidade de viver esta experiência em busca de conhecimento e expansão de horizontes.

A minha mãe, pela ajuda e suporte que fizeram a diferença nas ocasiões mais cruciais.

Ao meu companheiro, Cláudio, pela compreensão nos momentos em que precisei direcionar minha atenção aos estudos.

Ao meu filho querido, João Pedro, pelos seus sorrisos e abraços carinhosos que sempre elevam o meu ânimo.

Aos meus orientadores, Cel Volotão e Dra. Karla Teixeira, pela disponibilidade e ensinamentos passados e pela amizade, paciência e atenção com as quais sempre me trataram.

Ao coordenador do Curso de Engenharia de Defesa, Cel Carrilho, pela cordialidade direcionada a mim todas as vezes em que o procurei para solicitar ajuda.

Aos professores da Engenharia de Defesa e da Cartografia pelas experiências e ensinamentos compartilhados.

“O importante é não parar de questionar. A curiosidade tem sua própria razão de existência. Não se pode deixar de ficar admirado quando contempla os mistérios da eternidade, da vida, da maravilhosa estrutura da realidade. Basta que se busque compreender um pouco desse mistério a cada dia. Nunca perca a curiosidade... Não pare de se maravilhar.”

Albert Einstein

SUMÁRIO

LISTA DE ILUSTRAÇÕES	10
LISTA DE TABELAS	13
LISTA DE ABREVIATURAS E SÍMBOLOS.....	15
LISTA DE SIGLAS	16
1. INTRODUÇÃO.....	20
1.1 TERRITÓRIO MARÍTIMO BRASILEIRO.....	20
1.2 CONTEXTUALIZAÇÃO.....	22
1.3 MOTIVAÇÃO	23
1.4 OBJETIVO.....	25
1.4.1 DELIMITAÇÃO DO ESCOPO.....	25
1.4.2 JUSTIFICATIVA.....	25
1.5 TRABALHOS RELACIONADOS.....	26
1.6 ORGANIZAÇÃO DO TRABALHO.....	29
2. CONCEITOS BÁSICOS	30
2.1 INTELIGÊNCIA ARTIFICIAL	30
2.1.1 REDE NEURAL ARTIFICIAL.....	30
2.1.2 REDE <i>PERCEPTRON</i> MULTICAMADAS	32
2.2 PROCESSAMENTO DIGITAL DE IMAGENS	34
2.2.1 VIZINHANÇA.....	34
2.2.2 FILTRAGEM NO DOMÍNIO ESPACIAL	35
2.2.3 FILTRO DE MÉDIA ARITMÉTICA.....	35
2.2.4 FILTRO DE MEDIANA	36
2.2.5 TEXTURA	37
2.2.6 DETECÇÃO DE BORDAS.....	37
2.2.7 LIMIAZIZAÇÃO	38
2.2.8 CÓDIGO DE CADEIA (<i>CHAIN CODE</i>)	39
2.2.9 PERÍMETRO E ÁREA.....	40
2.2.10 FUNÇÃO DE DESVIO	41
2.3 PRECISÃO E ABRANGÊNCIA.....	42

2.4	DISTRIBUIÇÃO <i>T</i> DE <i>STUDENT</i>	44
2.4.1	TESTE <i>T</i> PARA DUAS AMOSTRAS COM VARIÂNCIAS DIFERENTES	44
3.	APRESENTAÇÃO DO MÉTODO	46
3.1	PROCESSOS DO MÉTODO PROPOSTO.....	46
3.2	PREPARAR IMAGEM (I)	46
3.2.1	OBTENÇÃO DA IMAGEM	47
3.2.2	SELEÇÃO DE AMOSTRAS.....	47
3.2.3	DETECÇÃO DE BORDAS.....	47
3.3	OBTER DADOS DE CONTEXTO E DADOS DE COMPARAÇÃO DE FORMATO E GERAR MATRIZ DE DESCRITORES (II).....	49
3.3.1	GERAÇÃO DO CÓDIGO DE CADEIA.....	50
3.3.2	CÁLCULO DA FUNÇÃO DE DESVIO.....	50
3.3.3	COMPARAÇÃO DE CONTORNO	51
3.3.4	OBTENÇÃO DOS DADOS DE CONTEXTO	52
3.3.5	GERAÇÃO DA MATRIZ DE DESCRITORES	56
3.4	CONFIGURAR E TREINAR A RNA (III).....	58
3.4.1	NORMALIZAÇÃO DO CONJUNTO DE DADOS DE TREINAMENTO	58
3.4.2	CONFIGURAÇÃO DA RNA.....	59
3.4.3	TREINAMENTO DA RNA.....	59
3.5	ARMAZENAR PARÂMETROS DE NORMALIZAÇÃO (IV).....	59
3.6	NORMALIZAR MATRIZ DE DESCRITORES DA IMAGEM, CLASSIFICÁ-LA NA RNA E REALIZAR A ANÁLISE POR SEGMENTO (V)	59
3.6.1	NORMALIZAÇÃO DA MATRIZ DE DESCRITORES DA IMAGEM DE CLASSIFICAÇÃO	59
3.6.2	CLASSIFICAÇÃO DA IMAGEM NA RNA.....	60
3.6.3	ANÁLISE DA CLASSIFICAÇÃO POR SEGMENTO	60
3.7	EXIBIR RESULTADO DA DETECÇÃO DAS EMBARCAÇÕES NA IMAGEM (VI)	60
4.	APLICAÇÃO DO MÉTODO	61
4.1	ESTUDO DE CASO	61
4.1.1	FERRAMENTAS E MATERIAIS	63
4.2	CONFIGURAÇÃO DA RNA.....	63
4.3	DADOS DE TREINAMENTO DA RNA	64

4.4	DETECÇÃO DE BORDAS	64
4.5	CORREÇÃO DE PIXEL DE RUÍDO	65
4.6	COMPARAÇÃO DE FORMATO DE CONTORNO	65
4.7	CONFIRMAÇÃO VISUAL DO ALVO.....	66
4.8	CLASSIFICAÇÃO DE IMAGENS	67
4.9	RESULTADOS	86
4.10	AVALIAÇÃO	87
5.	CONCLUSÃO	91
5.1	TRABALHOS FUTUROS	92
6.	REFERÊNCIAS BIBLIOGRÁFICAS	93

LISTA DE ILUSTRAÇÕES

FIG. 1.1:	Território Marítimo Brasileiro. Fonte: Câmara (2018) modificada.	22
FIG. 1.2:	SISGAAZ. Fonte: DEFESA (2018)	24
FIG. 2.1:	Neurônio biológico. Fonte: RUSSELL e NORVIG (2004) modificada	31
FIG. 2.2:	Esquema de unidade do modelo de MCCULLOCH E PITTS (1943)	31
FIG. 2.3:	Rede MLP.....	32
FIG. 2.4:	Função de limiar	33
FIG. 2.5:	Função sigmoide.....	33
FIG. 2.6:	Função tangente hiperbólica.....	33
FIG. 2.7:	Vizinhança-4 e vizinhança-8	34
FIG. 2.8:	Máscara de 3×3 pixels	35
FIG. 2.9:	Filtro de média aritmética.....	36
FIG. 2.10:	Filtros de média e mediana. Fonte: GONZALEZ e WOODS (2014).....	36
FIG. 2.11:	Operadores de Roberts	37
FIG. 2.12:	Operadores de Prewitt	38
FIG. 2.13:	Filtros de Roberts e Sobel	38
FIG. 2.14:	Direções na vizinhança-4 e na vizinhança-8	39
FIG. 2.15:	Código de cadeia	40
FIG. 2.16:	Perímetro	40
FIG. 2.17:	Área	40
FIG. 2.18:	Função de desvio. FONTE: VOLOTÃO <i>et al.</i> (2010).....	42
FIG. 2.19:	Precisão e Abrangência	43
FIG. 3.1:	Fluxograma do método proposto.....	46
FIG. 3.2:	(a) Imagem original. Fonte: RapidEye (b) Roberts (c) Sobel (d) Canny.	48
FIG. 3.3:	Detecção de bordas: (a) imagem original. Fonte: RapidEye (b) filtro Canny (c) máscara baseada na limiarização (d) filtragem por mínimo de pixels consecutivos (e) fechamento e preenchimento (f) representação gráfica do código de cadeia	48
FIG. 3.4:	Conjunto mínimo de pixels	49
FIG. 3.5:	Processo de detecção de bordas.....	49
FIG. 3.6:	Correção de pixel.....	50
FIG. 3.7:	Suavização do código de cadeia.....	50

FIG. 3.8:	Vetores adjacentes	51
FIG. 3.9:	(a) diâmetro (b) vértices mais próximos.....	51
FIG. 3.10:	Processo de comparação de contorno.....	52
FIG. 3.11:	Moldura	53
FIG. 3.12:	Vizinhança 3x3.....	53
FIG. 3.13:	Pixels e segmentos.....	54
FIG. 3.14:	Diferença de compacidade	55
FIG. 3.15:	Dados de contexto	55
FIG. 3.16:	Processo de geração da matriz de descritores	56
FIG. 3.17:	Fluxograma de classificação de imagem.....	57
FIG. 3.18:	Fluxograma de treinamento da RNA.....	58
FIG. 3.19:	Classificação na RNA	60
FIG. 4.1:	Área teste. Fonte: MMA.....	62
FIG. 4.2:	Classificação pelo método SVM. Fonte: RapidEye modificada.	62
FIG. 4.3:	Amostras. Fonte: RapidEye modificada.....	64
FIG. 4.4:	Correção de 1 pixel.....	65
FIG. 4.5:	Características de cor e formato	66
FIG. 4.6:	Embarcação em movimento	66
FIG. 4.7:	Embarcação de grande porte	66
FIG. 4.8:	(a) primeira imagem. Fonte: RapidEye. (b) embarcações destacadas.....	67
FIG. 4.9:	Classificação da primeira imagem: (a) situação 1 (b) situação 2 (c) situação 3 ...	67
FIG. 4.10:	(a) segunda imagem. Fonte: RapidEye. (b) embarcações destacadas	68
FIG. 4.11:	Classificação da imagem 2: (a) situação 1 (b) situação 2 (c) situação 3	69
FIG. 4.12:	(a) terceira imagem. Fonte: RapidEye. (b) segmentos	70
FIG. 4.13:	Classificação da imagem 3: (a) situação 1 (b) situação 2 (c) situação 3	70
FIG. 4.14:	(a) quarta imagem. Fonte: RapidEye. (b) segmentos	71
FIG. 4.15:	Classificação da quarta imagem: (a) situação 1 (b) situação 2 (c) situação 3	71
FIG. 4.16:	(a) quinta imagem. Fonte: RapidEye. (b) segmentos	72
FIG. 4.17:	Classificação da quinta imagem: (a) situação 1 (b) situação 2 (c) situação 3	73
FIG. 4.18:	(a) sexta imagem. Fonte: RapidEye. (b) segmentos	74
FIG. 4.19:	Classificação da sexta imagem: (a) situação 1 (b) situação 2 (c) situação 3.....	74
FIG. 4.20:	(a) sétima imagem. Fonte: RapidEye. (b) segmentos.....	75
FIG. 4.21:	Classificação da imagem 7: (a) situação 1 (b) situação 2 (c) situação 3	75

FIG. 4.22: (a) oitava imagem. Fonte: RapidEye. (b) segmentos	76
FIG. 4.23: Classificação da oitava imagem: (a) situação 1 (b) situação 2 (c) situação 3	77
FIG. 4.24: (a) nona imagem. Fonte: RapidEye. (b) segmentos	77
FIG. 4.25: Classificação da nona imagem: (a) situação 1 (b) situação 2 (c) situação 3	78
FIG. 4.26: (a) décima imagem. Fonte: RapidEye. (b) segmentos.....	78
FIG. 4.27: Classificação da décima imagem: (a) situação 1 (b) situação 2 (c) situação 3	79
FIG. 4.28: (a) imagem 11. Fonte: RapidEye. (b) segmentos	79
FIG. 4.29: Classificação da imagem 11: (a) situação 1 (b) situação 2 (c) situação 3	79
FIG. 4.30: (a) imagem 12. Fonte: RapidEye. (b) segmentos	80
FIG. 4.31: Classificação da imagem 12: (a) situação 1 (b) situação 2 (c) situação 3	81
FIG. 4.32: (a) imagem 13. Fonte: RapidEye. (b) segmentos	81
FIG. 4.33: Classificação da imagem 13: (a) situação 1 (b) situação 2 (c) situação 3	82
FIG. 4.34: (a) imagem 14. Fonte: RapidEye. (b) segmentos	82
FIG. 4.35: Classificação da imagem 14: (a) situação 1 (b) situação 2 (c) situação 3	83
FIG. 4.36: (a) imagem 15. Fonte: RapidEye. (b) segmentos	83
FIG. 4.37: Classificação da imagem 15: (a) situação 1 (b) situação 2 (c) situação 3	84
FIG. 4.38: (a) imagem 16. Fonte: RapidEye. (b) segmentos	85
FIG. 4.39: Classificação da imagem 16: (a) situação 1 (b) situação 2 (c) situação 3	85

LISTA DE TABELAS

TAB. 1.1:	Trabalhos relacionados	28
TAB. 2.1:	Matriz de confusão exemplo	44
TAB. 4.1:	Matriz de confusão da primeira imagem para as situações 1 e 2.....	68
TAB. 4.2:	Matriz de confusão da primeira imagem para a situação 3.....	68
TAB. 4.3:	Matriz de confusão da segunda imagem para as situações 1 e 2.	69
TAB. 4.4:	Matriz de confusão da segunda imagem para a situação 3.	69
TAB. 4.5:	Matriz de confusão da terceira imagem para as situações 1 e 3.	70
TAB. 4.6:	Matriz de confusão da terceira imagem para a situação 2.	71
TAB. 4.7:	Matriz de confusão da quarta imagem para a situação 1.	72
TAB. 4.8:	Matriz de confusão da quarta imagem para as situações 2 e 3.	72
TAB. 4.9:	Matriz de confusão da quinta imagem para a situação 1.	73
TAB. 4.10:	Matriz de confusão da quinta imagem para a situação 2.	73
TAB. 4.11:	Matriz de confusão da quinta imagem para a situação 3.	73
TAB. 4.12:	Matriz de confusão da sexta imagem para as situações 1, 2 e 3.	74
TAB. 4.13:	Matriz de confusão da sétima imagem para as situações 1 e 2.....	76
TAB. 4.14:	Matriz de confusão da sétima imagem para a situação 3.....	76
TAB. 4.15:	Matriz de confusão da oitava imagem para as situações 1 e 2.....	77
TAB. 4.16:	Matriz de confusão da oitava imagem para a situação 3.....	77
TAB. 4.17:	Matriz de confusão da nona imagem para as situações 1, 2 e 3.....	78
TAB. 4.18:	Matriz de confusão da nona imagem para as situações 1, 2 e 3.....	79
TAB. 4.19:	Matriz de confusão da imagem 11 para a situação 1.	80
TAB. 4.20:	Matriz de confusão da imagem 11 para a situação 2.	80
TAB. 4.21:	Matriz de confusão da imagem 11 para a situação 3.	80
TAB. 4.22:	Matriz de confusão da imagem 12 para as situações 1 e 2.	81
TAB. 4.23:	Matriz de confusão da imagem 12 para a situação 3.	81
TAB. 4.24:	Matriz de confusão da imagem 13 para as situações 1 e 2.	82
TAB. 4.25:	Matriz de confusão da imagem 13 para a situação 3.	82
TAB. 4.26:	Matriz de confusão da imagem 14 para as situações 1, 2 e 3.	83
TAB. 4.27:	Matriz de confusão da imagem 15 para as situações 1 e 2.	84
TAB. 4.28:	Matriz de confusão da imagem 15 para a situação 3.	84
TAB. 4.29:	Matriz de confusão da imagem 16 para as situações 1, 2 e 3.	85

TAB. 4.30: Resultados obtidos para a situação 1.....	86
TAB. 4.31: Resultados das imagens classificadas para a situação 2.	86
TAB. 4.32: Resultados das imagens classificadas para a situação 3.	87
TAB. 4.33: Medida- F_1 das imagens classificadas.....	87
TAB. 4.34: Teste- t para os resultados das situações 1 e 2	88
TAB. 4.35: Teste- t para os resultados das situações 1 e 3	89

LISTA DE ABREVIATURAS E SÍMBOLOS

ABREVIATURAS

Hz	Hertz
m	metro
MATLAB	<i>Matrix Laboratory</i>
MaxVer	Máxima Verossimilhança
MinDist	Distância Mínima
mm	Milímetro
nm	Nanômetro

SÍMBOLOS

Å	Angstrom
µm	Micrômetro

LISTA DE SIGLAS

AB	Arqueação Bruta
AIS	<i>Automatic Identification System</i>
AJB	Águas Jurisdicionais Brasileiras
ANTAQ	Agência Nacional de Transportes Aquaviários
CNUDM	Convenção das Nações Unidas sobre o Direito no Mar
EB	Exército Brasileiro
ENVI	<i>Environment for Visualizing Images</i>
FAB	Força Aérea Brasileira
HOG	<i>Histogram of Oriented Gradient</i> (Histograma de Gradiente Orientado)
IA	Inteligência Artificial
IDL	<i>Interface Description Language</i>
IME	Instituto Militar de Engenharia
IMO	<i>International Maritime Organization</i> (Organização Marítima Internacional)
LBP	<i>Local Binary Pattern</i>
LRIT	<i>Long Range Identification and Tracking</i>
MB	Marinha do Brasil
MD	Ministério da Defesa
MLP	Multilayer Perceptron
MMA	Ministério do Meio Ambiente
MN	Milhas Náuticas
MT	Mar Territorial
MSSIS	Maritime Safety and Security Information System
ONU	Organização das Nações Unidas
PC	Plataforma Continental
PESE	Programa Estratégico de Sistemas Espaciais
RNA	Redes Neurais Artificiais
RPB-IMO	Representação Permanente do Brasil junto à Organização Marítima Internacional
SAR	<i>Synthetic Aperture Radar</i> (Radar de Abertura Sintética)
SCI	<i>Synthetic Color Image</i>
SEP	Secretaria Especial de Portos

PREPS	Programa Nacional de Rastreamento de Embarcações Pesqueiras
REM	Radiação Eletromagnética
SISNC2	Sistema Naval de Comando e Controle
SISTRAM	Sistema de Informações sobre o Tráfego Marítimo
SOLAS	<i>Safety of Life at Sea</i>
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machine</i> (Máquina de Vetor Suporte)
SVD	Singular Value Decomposition
VD	Vetor de Descritores
VRMTC	Virtual Regional Maritime Traffic Centre
ZC	Zona Contígua
ZEE	Zona Econômica Exclusiva

RESUMO

A importância econômica da pesca, as reservas de petróleo e gás existentes no subsolo marinho e a utilização das vias marítimas para o comércio, turismo e lazer fazem do território marítimo brasileiro uma das principais fontes de recursos do país. Portanto, é necessário monitorá-lo para protegê-lo. O sensoriamento remoto é indicado para a aquisição de dados de monitoramento de recursos terrestres em áreas extensas por não exigir o contato direto com a região investigada. Esta dissertação apresenta um método para detecção de embarcações em imagens provenientes de sensores ópticos orbitais baseado em características contextuais, relacionadas a dados espectrais, de textura e de formato, como a compacidade e o diâmetro, e características de comparação de formato de contorno dos alvos detectados na imagem a partir da aplicação de filtros de detecção de bordas. Essas características constituem descritores que são submetidos a um processo de classificação por rede neural artificial. O método foi avaliado pelas medidas de precisão e abrangência combinadas pela medida-F. A média dos resultados do método, aplicado a um estudo de caso em que foram utilizadas imagens RapidEye com resolução espacial de 5 metros, foi de 94,94%. A média da abrangência para o método foi de 100%, i. e. todas as embarcações de médio a grande porte presentes nas imagens foram detectadas. As falhas de precisão ocorreram em virtude de falsos positivos provocados por pequenas e médias ilhas. O método conseguiu detectar embarcações juntas e ou atracadas ao cais.

Palavras-chave: Detecção de Embarcações, Sensores Multiespectrais Ópticos, Imagens Multiespectrais Ópticas, Processamento de Imagens, Detecção de Bordas, Características de Contexto, Comparação de Formato de Contorno, Código de Cadeia, Função de Desvio, Redes Neurais Artificiais.

ABSTRACT

Due to the economic importance of fishing such as oil and gas reserves in marine subsoil and the use of sea routes for trade, tourism and recreation, the Brazilian maritime territory is one of the main resources of the country. Therefore, it is necessary to monitor and protect it. Remote sensing is used to monitor and get data from earth resources over large areas because it is not necessary any direct contact with the investigated region. This dissertation presents a method to detect vessels in images from orbital optical receivers that uses contextual characteristics, related to spectral, texture and shape, such as compactness and diameter, and contour shape comparison characteristics of targets detected in image by applying edge detection filters. These characteristics represent descriptors that are submitted to a neural artificial network classification process. The method was evaluated by precision, recall and F-measure and it was applied to RapidEye images with 5 meters spatial resolution. The average method result was 94,94% and the average method recall was 100%. It means that all medium to large sized vessels in images were detected. Precision failures were caused by false positives related to small and medium islands. The method was able to detect vessels beside each other or docked.

Keywords: Ship Detection, Multispectral Optical sensors, Multispectral Optical Image, Image Processing, Edge Detection, Context Characteristics, Shape Comparison, Chain Code, Turning Function, Artificial Neural Network.

1. INTRODUÇÃO

Este capítulo inicia com uma breve explanação sobre a formação e delimitação das áreas que constituem o território marítimo brasileiro, bem como a legislação que o regulamenta. Em seguida, apresenta a contextualização, motivação, objetivo e a justificativa para o desenvolvimento do estudo contido nesta dissertação. Finaliza com a menção e comparação deste estudo com alguns dos principais trabalhos publicados sobre o tema e mostra como esta dissertação está organizada.

1.1 TERRITÓRIO MARÍTIMO BRASILEIRO

O Brasil é um país que possui forte relação de dependência com o mar, pois 17 estados, aproximadamente 63% das suas unidades federativas, são banhados pelo mar, que é uma fonte de riqueza econômica e de biodiversidade.

O território marítimo brasileiro estende-se por uma área de 3,6 milhões de km² (AMAZUL, 2017) e representa uma das principais fontes de recursos do nosso país, devido ao fato de abrigar uma grande diversidade de fauna e flora, da importância econômica da pesca, das reservas de petróleo e gás existentes no subsolo e da utilização das suas vias para o comércio, turismo e lazer.

A navegação marítima, por sua vez, representa mais de 95% do comércio exterior do país (DEFENSEA, 2017), em função do reduzido custo para o transporte de grandes cargas para longas distâncias. Além disso, após as descobertas de petróleo no Pré-Sal, a produção diária de petróleo nessa região, que era de cerca de 41 mil barris por dia em 2010, aumentou para um milhão de barris por dia em 2016 e posicionou estrategicamente o Brasil em relação à demanda mundial de energia (PETROBRAS, 2017).

Portanto, é imprescindível a implementação de soluções que minimizem os riscos e as vulnerabilidades relacionadas ao meio marítimo. Também é necessário atender aos compromissos nacionais e internacionais relativos à segurança do tráfego aquaviário, assistência, busca e salvamento de embarcações e de vida humana em perigo no mar, combate à pesca ilegal e proteção contra os ataques de pirataria nas Águas Jurisdicionais Brasileiras (AJB).

Em 1982, a Organização das Nações Unidas (ONU) promoveu a assinatura de uma convenção com a finalidade de promover a paz e a segurança, fortalecer relações de amizade e

estabelecer uma ordem jurídica para proteção, preservação e uso pacífico dos mares e oceanos, a Convenção das Nações Unidas sobre o Direito no Mar (CNUDM), ratificada pelo Governo Brasileiro em 1988 (BRASIL-1, 1995).

Portanto, o território marítimo brasileiro é uma área de soberania nacional formada pelas Águas Interiores, o Mar Territorial – MT, a Zona Contígua – ZC, a Zona Econômica Exclusiva – ZEE e a Plataforma Continental – PC (MARTINS, 2010). Esta soberania estende-se ao espaço aéreo sobrejacente ao mar territorial, bem como ao leito e ao subsolo deste mar (MORE, 2013).

O MT refere-se à faixa de mar, cuja largura não ultrapasse o limite de 12 milhas náuticas (MN), contadas a partir das linhas de base do litoral. A área que se estende das 12 às 24 MN seguintes, corresponde à ZC. Nela poderão ser tomadas as medidas de fiscalização necessárias para o cumprimento das leis e regulamentos aduaneiros, fiscais, de imigração ou sanitários. A ZEE compreende a faixa marítima de 188 MN situada além do MT sobre a qual o Estado costeiro exerce direito de soberania, para fins de exploração, aproveitamento, conservação e gestão dos recursos naturais, vivos ou não vivos, das águas sobrejacentes ao leito do mar, do leito do mar e seu subsolo e outras atividades com vista à exploração e ao aproveitamento para fins econômicos. Além disso, o Estado costeiro também exerce jurisdição, no que se refere à colocação e utilização de ilhas artificiais, instalações e estruturas, investigação científica marinha e proteção e preservação do meio marinho (AMAZUL, 2017).

Por último, a PC compreende o leito e o subsolo das áreas marítimas que se estendem até o bordo exterior da margem continental, ou até uma distância limite de 200 MN das linhas de base, nos casos em que o bordo exterior da margem continental não atinja essa distância. Caso a margem continental ultrapasse as 200 MN, o Estado costeiro poderá pleitear junto à ONU o prolongamento da PC, até um limite de 350 MN, o que necessita ser comprovado, mediante levantamento técnico apropriado. Em setembro de 2004, o Brasil apresentou à ONU um pleito de extensão da PC em cerca de 960 mil km², conforme mostra a FIG. 1.1 (AMAZUL, 2017).

A área da ZEE brasileira somada aos 960 mil km² de extensão reivindicados pelo Brasil junto à ONU, perfazem o total aproximado de 4,5 milhões de km², cinquenta e dois por cento da área continental. Devido à vastidão e riqueza da ZEE, a Marinha do Brasil (MB) passou a denominá-la Amazônia Azul, a fim de enfatizar a importância estratégica dessa área (AMAZUL, 2018).

Tendo em vista a extensão do território marítimo e a significativa participação no comércio marítimo mundial, o Brasil é membro da Organização Marítima Internacional (IMO) e possui

uma Representação Permanente junto à Organização Marítima Internacional (RPB-IMO). A IMO foi criada pela necessidade de adoção de regulamentos internacionais, a serem cumpridos por todas as nações envolvidas com o transporte marítimo, e “tem por missão implementar regulamentação adequada à garantia do transporte marítimo seguro, protegido e eficiente sobre oceanos limpos” (CCA-IMO, 2017).

A IMO atualizou a Convenção Internacional para a Salvaguarda da Vida Humana no Mar (Convenção SOLAS), tratado internacional que trata da segurança marítima. Em seguida, foram criados outros instrumentos, como convenções destinadas a evitar abalroamentos no mar, padronização da formação de marítimos, regulamentação do serviço de busca e salvamento, regulamentação do transporte de mercadorias perigosas, determinação das linhas de carga e estabelecimento da medida de arqueação bruta (AB) dos navios (CCA-IMO, 2017).



FIG. 1.1: Território Marítimo Brasileiro. Fonte: Câmara (2018) modificada.

1.2 CONTEXTUALIZAÇÃO

O Sensoriamento Remoto (SR) é muito utilizado na coleta automática de dados para o levantamento e a monitoração de recursos terrestres em escala global porque não exige o

contato direto com a área sob investigação (IBGE, 2001). As imagens provenientes de sensores remotos vêm sendo utilizadas em atividades diversas, como mapeamento e inventário florestal (ESPÍRITO-SANTO, 2003), mapeamento de vegetação aquática (GRACIANI, 2002), apoio à estimativas de safras agrícolas (ADAMI *et al.*, 2005), mapeamento topográfico (MACHADO E SILVA *et al.*, 2003), mapeamento do uso do solo (DEMARCHI *et al.*, 2011), estudos urbanos para a execução de obras de engenharia rodoviária (MELO, 2002), entre outras atividades.

Os dados obtidos por sensoriamento remoto devem passar por um processo de análise e classificação. Existem os métodos de classificação supervisionados que, a partir de um conjunto de amostras das classes de interesse, identificam padrões de respostas espectrais para separar os pixels da imagem dentro das classes previamente informadas, enquanto os métodos não-supervisionados fazem um processamento inverso, agrupam pixels com padrões de respostas espectrais semelhantes, retornando as classes distintas encontradas.

O reconhecimento de padrões é aplicado às mais variadas áreas, como comércio, finanças, medicina, educação, segurança, telecomunicações, indústria e esporte. Especificamente em imagens de sensores remotos, o reconhecimento de padrões vem sendo empregado em estudos na área de defesa e vigilância de áreas marítimas, como o sistema inteligente para detecção de óleo de SOUZA (2006), o estudo do sensoriamento remoto como ferramenta de entrada e validação para modelagem de derramamento de óleo de BASCHEK *et al.* (2011) e o estudo de implementação de uma diretiva padrão de estratégia marítima europeia de YANG *et al.* (2015).

1.3 MOTIVAÇÃO

Diversos órgãos, como a Marinha do Brasil (MB), Marinhas Estrangeiras, Agência Nacional de Transportes Aquaviários (ANTAQ), Secretaria Especial de Portos (SEP), praticos e proprietários de embarcações, interagem entre si, a fim de implementar mecanismos que garantam o controle e a segurança do tráfego marítimo brasileiro.

Variados são os sistemas computacionais que dão suporte às atividades de controle do tráfego marítimo, a mencionar: Sistema Naval de Comando e Controle (SISNC2), Sistema de Informações sobre o Tráfego Marítimo (SISTRAM), Programa Nacional de Rastreamento de Embarcações Pesqueiras (PREPS), *Automatic Identification System* (AIS), *Virtual Regional Maritime Traffic Centre* (VRMTC), *Maritime Safety and Security Information System* (MSSIS), *Long Range Identification and Tracking* (LRIT).

Cada sistema é responsável por obter dados dentro de sua esfera de atuação. Por exemplo, o PREPS possui dados apenas de embarcações pesqueiras e o AIS, conforme regulamentação da Convenção SOLAS (*Safety Of Life At Sea*) da IMO, é de adesão obrigatória para navios a partir de 300 AB (Arqueação Bruta) ou que tenham finalidade de transporte de passageiros ou que realizem viagens internacionais (AIS, 2017). Além disso, os dados gerados pelos sistemas não são fusionados e, em alguns casos, encontram-se até defasados.

A Marinha do Brasil e o Ministério da Defesa perceberam a necessidade de criar um Sistema de Gerenciamento da Amazônia Azul (SISGAAZ) que fornecesse informações completas, precisas e atualizadas para o monitoramento da AJB e das regiões de busca e salvamento sob responsabilidade do Brasil. O SISGAAZ prevê a integração de todos os sistemas relacionados a embarcações, monitoramento da área do Pré-Sal, controle das atividades de pesquisa científica no mar, combate ao tráfico de entorpecentes, monitoramento e prevenção de poluição hídrica e interligação com dados de satélites e radares (DEFESA, 2018).



FIG. 1.2: SISGAAZ. Fonte: DEFESA (2018)

A importância do uso do sensoriamento remoto aplicado às atividades de defesa do País é percebida pela MB já que esta participa ativamente do Programa Estratégico de Sistemas Espaciais (PESE), sob a coordenação da Força Aérea Brasileira (FAB), em conjunto com o Exército Brasileiro (EB) e o Ministério da Defesa – MD (LEMOS JUNIOR, 2014).

Embora o PESE tenha iniciado seu processo de implantação, previsto para estender-se até 2030, a Marinha não possui militares e servidores civis capacitados em número suficiente para usufruir dos benefícios possíveis de serem alcançados com as imagens advindas dos sensores

remotos. Na esfera da MB, as imagens multiespectrais de sensores remotos são utilizadas em atividades cartográficas e de previsão meteorológica. Tendo em vista a previsão de fornecimento de imagens multiespectrais ópticas por intermédio do PESE, esta dissertação representa um estudo inicial para explorar o uso dessas imagens em tarefas de monitoramento marítimo.

1.4 OBJETIVO

O objetivo deste trabalho é propor um método para detectar embarcações em imagens ópticas multiespectrais de satélite utilizando características de contexto, formato e textura e dados de comparação de contorno. O reconhecimento de padrões será feito por rede neural artificial (RNA) do tipo *perceptron* multicamadas (MLP).

1.4.1 DELIMITAÇÃO DO ESCOPO

O método proposto aplica-se a imagens de sensores ópticos multiespectrais orbitais. Portanto, sua aplicação em imagens provenientes de outros tipos de sensores está condicionada à adaptação dos processos de acordo com as características e particularidades do tipo de sensor.

O método proposto não realiza correções geométricas ou radiométricas. Logo, as imagens obtidas devem ter passado pelos devidos ajustes antes da utilização do método.

O menor porte das embarcações detectadas pelo método proposto é definido pela resolução espacial da imagem, sendo que, além de considerar o comprimento da embarcação, deve-se observar uma largura mínima correspondente a pelo menos duas vezes o tamanho do pixel.

1.4.2 JUSTIFICATIVA

O sensoriamento remoto aplica-se como solução ao problema de monitoramento da AJB devido ao fato de possibilitar a monitoração de recursos terrestres em escala global sem necessidade de contato direto com a área de interesse. A escolha pelo uso de imagens oriundas de satélites deve-se ao fato da previsão de fornecimento de imagens multiespectrais ópticas por intermédio do PESE, conforme mencionado na seção 1.3, e pela maior facilidade de cobertura de áreas extensas em relação às imagens aerotransportadas.

A combinação de dados de contexto com os dados obtidos pela comparação da forma por meio de função de desvio e com a utilização de uma RNA do tipo MLP representam o diferencial do método proposto em relação aos trabalhos relacionados. Os dados de contexto

são aqueles relacionados às características dos alvos de interesse e ao ambiente onde se encontram e a RNA é utilizada para o reconhecimento de padrões e classificação dos segmentos detectados na imagem.

A Rede Neural Artificial (RNA) foi escolhida por ser flexível, robusta, capaz de aprender por experiência, fazer associações entre padrões de natureza distinta, extrair informação mesmo de padrões ruidosos (abstração) e realizar generalizações a partir de exemplos anteriores, destacando-se entre os demais métodos classificadores. Além disso, o MLP é simples de ser implementado e possibilita resolver problemas não-lineares.

1.5 TRABALHOS RELACIONADOS

Tomando-se por base a similaridade de objetivos, foram selecionados alguns artigos recentes, relacionados ao tema desta dissertação, julgados mais relevantes e publicados nos últimos oito anos.

GAMBA (2010) testou técnicas de processamento de imagens, como contrastes, filtros morfológicos e transformadores por realce e composição de imagens de Radar de Abertura Sintética (SAR) de baixa correlação. Testou classificadores não-supervisionados, como isodata e k-médias, e supervisionados, como Distância *Mahalanobis*, Máxima Verossimilhança (MaxVer) e Máquina de Vetor Suporte (SVM), em busca do melhor resultado para detecção de embarcações em imagens SAR, obtendo índice Kappa de 0,9 para o melhor classificador, o SVM. Também analisou estatisticamente as tonalidades e os tamanhos dos alvos detectados para conseguir diferenciar os navios militares e os mercantes, com margem de erro de aproximadamente 16 metros. Obteve resultados mais confiáveis quando as embarcações estavam em alto-mar, por não sofrerem influência do cais.

ZHU *et al.* (2010) desenvolveu um método para detecção de navios baseado na extração de características de textura, e. g. média, variância, momento, entropia, e de formato, e.g. compacidade, convexidade, retangularidade, excentricidade e momento invariante. O método introduziu um novo operador de textura: *Local Multiple Patterns* (LMP) e utilizou o SVM como classificador. O método registrou melhor acurácia (razão entre o número de navios detectados corretamente e o número real de navios) de 96,4%. As perdas na detecção de alvos candidatos ocorreram em casos de navios parcialmente cobertos por nuvem ou próximos a ilhas e situação em que o nível de cinza se assemelhava ao da vizinhança. Logo, nuvens e espuma do mar geraram falsos candidatos.

QI *et al.* (2015) propuseram um método não-supervisionado de detecção de navios por meio da extração de regiões candidatas, que apresentem alguma saliência visualmente percebida, aplicaram um filtro de homogeneização de áreas similares e utilizaram um descritor Histograma de Gradiente Orientado para navios (S-HOG), baseado em características de simetria. O método mostrou-se robusto em cenas com presença de nuvens, ondas e cristas. Os melhores resultados apresentados foram 93,4% de precisão e 92,8% de abrangência para navios grandes e 87,8% para navios pequenos.

LI *et al.* (2016) criaram um método para detecção de navios costeiros por meio da classificação da proa do navio e determinação das bordas do corpo, que utiliza um detector de bordas, transpõe os pixels em uma janela circular para o domínio do sistema de coordenada polar e aplica filtros de convolução para localizar proas pontudas e em forma de “V”. O método utilizou o SVM como classificador e registrou 94,3% para precisão e 91,7% para abrangência.

ZOU *et al.* (2016) propuseram um novo método de detecção de navios que utiliza uma Rede de Descompensação de Valor Singular (SVDNet), baseada em rede neural convolucional, na fase de detecção dos navios candidatos e o SVM na fase de verificação. Atingiu resultado superior a 98% para precisão e abrangência. Embora o método seja bastante otimizado, ainda exige recurso computacional diferenciado por apresentar alto consumo de memória.

YANG *et al.* (2017) publicaram um método de detecção de navios em imagens de satélites ópticos baseado na segmentação de saliência e no descritor padrão local binário (LBP *descriptor*). Em seu processo, emprega características de formato, como área, razão entre comprimento e largura e compacidade. Os melhores resultados obtidos são 92,6% de precisão e 98,6% de abrangência.

Em termos das resoluções espaciais dos sensores utilizados, ZHU *et al.* (2010) utilizou imagens com resoluções de 5, 10 e 20m, GAMBA (2010) utilizou imagens com resoluções de 3 m e os demais autores utilizaram imagens com resoluções de 2m ou resoluções superiores. O método desta dissertação foi aplicado a imagens de resolução de 5m.

No que diz respeito às técnicas utilizadas para a seleção dos navios candidatos, GAMBA (2010), ZHU *et al.* (2010), QI *et al.* (2015) e YANG *et al.* (2017) realizaram detecções de bordas para a seleção dos alvos candidatos, analisando-os posteriormente por suas características de textura e de formato, LI *et al.* (2016) utiliza um detector de bordas e aplica filtros de convolução para localizar formatos de “V” e ZOU *et al.* (2016) utilizou seu classificador próprio, o SVDNet para selecionar os navios candidatos.

Para a detecção de navios candidatos nas imagens, o método proposto nesta dissertação baseia-se na combinação de duas abordagens: o uso de características contextuais de vizinhança e de formato (o uso de dados contextuais foi sugerido por ZHU *et al.* (2010) e YANG *et al.* (2017)), e a comparação de contorno dos navios candidatos com padrões de contorno desejáveis (pré-estabelecidos), por meio de função de desvio, com o intuito de localizar proa e popa de navios (a proposta de LI *et al.* (2016) baseia-se na busca de formato de proa de navio nas imagens).

Quanto ao classificador utilizado na verificação dos navios candidatos, GAMBA (2010), ZHU *et al.* (2010), LI *et al.* (2016) e ZOU *et al.* (2016) utilizaram o SVM e o método proposto nesta dissertação utiliza uma rede neural artificial MLP, conforme aplicação do método no estudo de caso apresentado no capítulo 4.

TAB. 1.1: Trabalhos relacionados

Pesquisa	Sensor	Objetivo	Técnica Utilizada	Resultados e Observações
GAMBA (2010)	SAR	Testar métodos de processamento e classificação de imagem para detecção de embarcações e identificar navios (militares e mercantes)	SVM e um método próprio de medição automática de embarcação.	Índice Kappa 0,9 para a classificação com SVM. Erro \approx 16 metros para identificação. Resultados mais confiáveis para embarcações em alto-mar.
ZHU <i>et al.</i> (2010)	Óptico	Detecção de navios.	Extração de características de textura e de formato e SVM.	Acurácia de 96,4%. Perdas na detecção de navios parcialmente cobertos por nuvem, próximos a ilhas ou atracados. Falsos candidatos em nuvens e agitação do mar.
QI <i>et al.</i> (2015)	Óptico	Detectar embarcações.	Extração de saliência, filtro de homogeneização e descritor S-HOG.	Robustez em cenas com presença de nuvens, ondas e cristas. Melhores resultados: 93,4% de precisão e 92,8% de abrangência.

Pesquisa	Sensor	Objetivo	Técnica Utilizada	Resultados e Observações
LI <i>et al.</i> (2016)	Óptico	Detectar navios costeiros.	Classificação da proa, determinação de bordas do corpo do navio e SVM	Registrou 94,3% para precisão e 91,7% para abrangência.
ZOU <i>et al.</i> (2016)	Óptico	Detectar navios.	Rede neural convolucional e SVM	Precisão e abrangência superiores a 98%. Porém, exige alto custo computacional.
YANG <i>et al.</i> (2017)	Óptico	Detecção de navios.	Segmentação de saliência, características de formato, descritor LBP e algoritmo AdaBoost.	92,6% de precisão e 98,6% de abrangência.
Método desta dissertação	Óptico	Detectar embarcações	Detecção de bordas, características contextuais, comparação de formato de contorno e rede neural artificial MLP	92,19% de precisão, 100% de abrangência e 94,94% para medida-F ₁ .

1.6 ORGANIZAÇÃO DO TRABALHO

No capítulo 2, são fornecidos conceitos básicos e breves explicações sobre as técnicas e funções utilizados nesta dissertação, a fim de fornecer ao leitor o entendimento necessário para familiarizá-lo aos tópicos abordados nos capítulos seguintes.

O capítulo 3 apresenta detalhadamente o método proposto nesta dissertação, abordando sua estrutura e os processos utilizados.

No capítulo 4, o método é aplicado em um estudo de caso e são demonstrados os correspondentes resultados e avaliações.

O capítulo 5 apresenta as conclusões sobre o método e sugere possíveis trabalhos futuros.

2. CONCEITOS BÁSICOS

Esta seção destina-se a explicar as principais técnicas e funções empregadas na execução do método apresentado. Inicia abordando conceitos sobre inteligência artificial e rede neural artificial, segue demonstrando exemplos de filtros de média, mediana e de detecção de bordas, limiarização, código de cadeia, perímetro, área e função de desvio e finaliza apresentando o método de avaliação pelas medidas de precisão e abrangência e a distribuição *t* de *Student*.

2.1 INTELIGÊNCIA ARTIFICIAL

IA é uma área da ciência da computação que trata do desenvolvimento de sistemas capazes de realizar atividades ligadas ao raciocínio, percepção, dedução lógica, aprendizado, evolução e adaptação (características da inteligência humana). IA é “o estudo das computações que tornam possível perceber, raciocinar e agir” (WINSTON, 1992).

O comportamento inteligente de um sistema resulta de decisões múltiplas e encadeadas, onde as tomadas de decisões são sequenciais, sincronizadas, inter-relacionadas e baseadas em critérios de desempenho, duração e risco (REZENDE *et al.*, 2005).

A IA é uma área ampla que utiliza diversas técnicas, como Aprendizado de Máquina, Computação Evolutiva, Lógica Nebulosa (*Fuzzy*), Redes Neurais Artificiais, Sistemas de Agentes Inteligentes, Sistemas Especialistas, Comitê de Classificadores, entre outras.

2.1.1 REDE NEURAL ARTIFICIAL

RNA é uma especialidade da IA baseada em modelos matemáticos que simulam estruturas neurais humanas, por meio da capacidade de aprendizado, generalização e reconhecimento de padrões (REZENDE *et al.*, 2005).

O processamento da informação em uma RNA é feito por meio de estruturas neurais artificiais, de maneira paralela e distribuída, sendo que cada elemento processador corresponde a um neurônio artificial (REZENDE *et al.*, 2005).

Os neurônios biológicos são formados principalmente pelos dendritos, que são conjuntos de terminais de entrada, pelo corpo central e pelos axônios, longos terminais de saída. A comunicação entre neurônios é feita através das sinapses. conforme representação da FIG. 2.1.

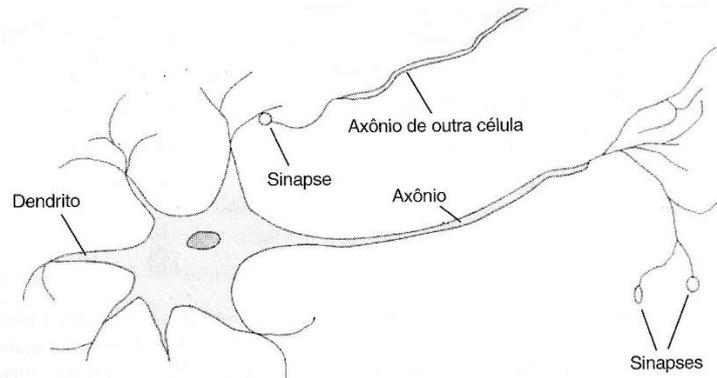


FIG. 2.1: Neurônio biológico. Fonte: RUSSELL e NORVIG (2004) modificada

O esquema proposto por MCCULLOCH E PITTS (1943) representa um modelo matemático para um neurônio artificial que, suficientemente estimulado, permite a passagem de sinal em uma rede de neurônios, através dos estados “ligado” ou “desligado”. A FIG. 2.2 representa o funcionamento do modelo, onde os sinais de entrada x são multiplicados pelos pesos w correspondentes e é aplicada uma função de saída $\varphi(v)$ sobre a soma ponderada dos sinais de entrada.

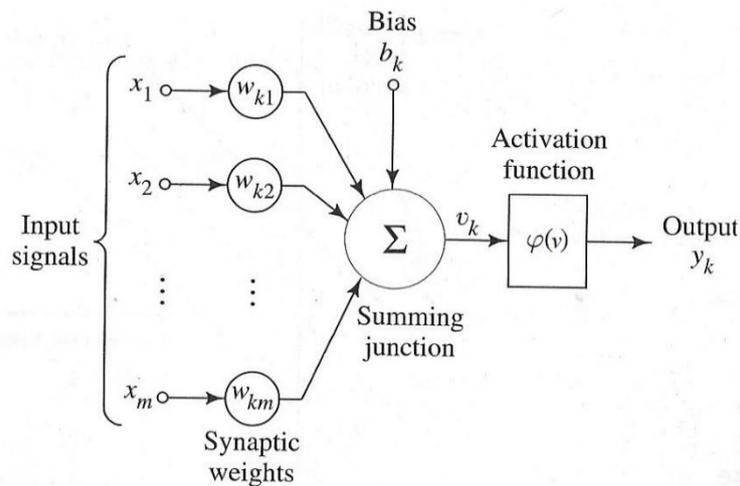


FIG. 2.2: Esquema de unidade do modelo de MCCULLOCH E PITTS (1943)

Se o resultado de $\varphi(v)$ for igual ou superior ao limiar de ativação, haverá sinal na saída do neurônio, conforme função da EQ. 2.1 de REZENDE *et al.* (2005).

$$\varphi(v) = \begin{cases} 0, & \text{se } v < \theta \\ 1, & \text{se } v \geq \theta, \end{cases} \quad \text{EQ. 2.1}$$

onde $\varphi(v)$ é a função de saída e θ corresponde ao limiar de ativação.

A RNA apresenta uma fase de aprendizado e uma fase de reconhecimento. No aprendizado (ou treinamento) ocorre o ajuste dos pesos das conexões em decorrência do estímulo gerado na

rede. No reconhecimento a rede responde a um estímulo de entrada sem que sua estrutura seja modificada (OLIVEIRA JR *et al.*, 2007).

Uma RNA pode resolver problemas de predição, generalização, reconhecimento de padrões ruidosos ou incompletos, classificação, categorização e aproximação (e.g. predição de séries temporais, aproximação de funções ou regressão, reconhecimento de caracteres, de voz ou de faces).

2.1.2 REDE *PERCEPTRON* MULTICAMADAS

O surgimento da rede *Multilayer Perceptron* (MLP) teve origem nos *Perceptrons*, de Rosenblatt, e nos *Madalines* de Widrow (CABRAL JR, 2003). O algoritmo de aprendizado *backpropagation* foi inventado e popularizado por Rummelhart, Hinton e Williams, resolvendo uma das limitações fundamentais para o treinamento de redes complexas (KOVÁCS, 1996).

A arquitetura de uma MLP é formada por neurônios dispostos em várias camadas. Os neurônios que recebem diretamente as entradas da rede representam a camada de entrada, os que recebem a saída da camada de entrada constituem a segunda camada e segue sucessivamente até a camada de saída (KOVÁCS, 1996). As camadas intermediárias são conhecidas como camadas ocultas.

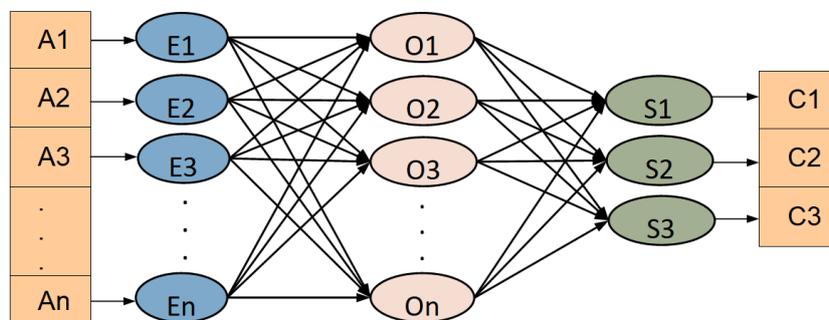


FIG. 2.3: Rede MLP

A FIG. 2.3 mostra uma rede MLP completamente conectada, ou seja, um neurônio em qualquer camada é conectado a todos os neurônios da camada anterior, onde os atributos de entrada são ($A_1, A_2, A_3, \dots, A_n$), a camada de entrada é composta por ($E_1, E_2, E_3, \dots, E_n$), possui uma camada oculta composta por ($O_1, O_2, O_3, \dots, O_n$), uma camada de saída com três neurônios (S_1, S_2 e S_3) e três classes de saída representadas por (C_1, C_2 e C_3).

O número de entradas e saídas é definido pela dimensionalidade dos dados e o número de camadas ocultas e suas quantidades de neurônios dependem da complexidade do problema. Contudo, o excesso de neurônios intermediários pode gerar resultados indesejáveis (REZENDE

et al., 2005). Entre as camadas são definidas matrizes de pesos que correspondem às conexões entre elas.

2.1.2.1 FUNÇÕES DE ATIVAÇÃO

As funções neurais, conhecidas como funções de ativação dos neurônios, são definidas para cada camada. HAYKIN (2008) define dois tipos básicos de funções de ativação:

- a) Função de limiar → apresenta valores de saída 0 ou 1, conforme EQ. 2.1 e FIG. 2.4.

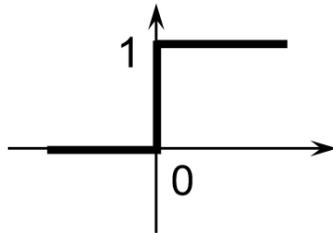


FIG. 2.4: Função de limiar

- b) Função sigmoide → assume valores contínuos de 0 a 1, conforme EQ. 2.2 e FIG. 2.5.

$$\varphi(v) = \frac{1}{1 + e^{(-av)}}, \quad \text{EQ. 2.2}$$

onde a corresponde ao parâmetro de inclinação.

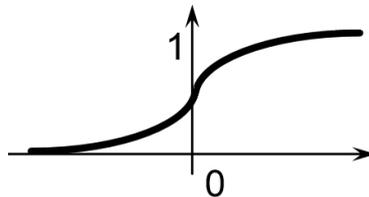


FIG. 2.5: Função sigmoide

A função tangente hiperbólica é uma função sigmoide que assume valores negativos, conforme EQ. 2.3 e FIG. 2.6.

$$\varphi(v) = \tanh(v) \quad \text{EQ. 2.3}$$

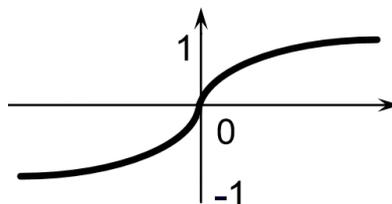


FIG. 2.6: Função tangente hiperbólica

2.1.2.2 ALGORITMO BACKPROPAGATION

O algoritmo *error-backpropagation* consiste dos passos *forward* e *backward*. No *forward*, “um padrão de entrada é apresentado à camada de entrada da rede e seu efeito é propagado camada por camada” até que atinja a camada de saída (CABRAL JR, 2003). Durante esta fase, os parâmetros da rede são fixos.

No *backward-step*, “os pesos e os demais parâmetros são ajustados por uma regra baseada no erro cometido, medindo a diferença entre a saída da rede e o valor de saída desejado.” A regra de atualização e aprendizado propaga o sinal de erro no sentido contrário ao *forward-step* (CABRAL JR, 2003), ou seja, da camada de saída até a primeira camada oculta. Este processo é repetido diversas vezes, de forma que a função de custo, baseada no erro entre a saída da rede e a saída esperada, seja minimizada.

2.2 PROCESSAMENTO DIGITAL DE IMAGENS

Imagem é uma função bidimensional $f(x, y)$, onde x e y são coordenadas espaciais e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto. Quando x , y e a intensidade de f são finitos e discretos, a imagem é denominada digital (GONZALEZ e WOODS, 2014).

Nas seções 2.2.1 a 2.2.10 são apresentados conceitos de processamento digital de imagens, como vizinhança, filtragem no domínio espacial, filtros de média aritmética e mediana, textura, detecção de bordas, limiarização, código de cadeia, perímetro, área e função de desvio.

2.2.1 VIZINHANÇA

Um pixel p de coordenada (x, y) possui dois vizinhos na horizontal e dois na vertical, de coordenadas $(x - 1, y)$, $(x + 1, y)$, $(x, y - 1)$ e $(x, y + 1)$, correspondentes à vizinhança-4, que é representada por $N_4(p)$. Na vizinhança-8, representada por $N_8(p)$, também são considerados os quatro vizinhos diagonais de p , $(x - 1, y - 1)$, $(x + 1, y - 1)$, $(x - 1, y + 1)$ e $(x + 1, y + 1)$, conforme demonstra a FIG. 2.7 (PEDRINI e SCHWARTZ, 2008).

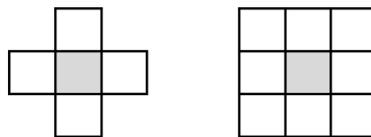


FIG. 2.7: Vizinhança-4 e vizinhança-8

2.2.2 FILTRAGEM NO DOMÍNIO ESPACIAL

As transformações no domínio espacial atuam diretamente no conjunto de pixels que compõem a imagem. Em geral, são computacionalmente eficientes e requerem poucos recursos de processamento em sua execução. O operador de filtragem calcula o valor resultante para o pixel pela combinação dos níveis de cinza em uma matriz aplicada sobre a imagem. A cada posição da matriz, conhecida como máscara, representada na FIG. 2.8, é atribuído um valor numérico. O resultado do processo de filtragem para um ponto (x, y) depende do nível de cinza deste ponto e de outros pontos da sua vizinhança, sendo que os vizinhos mais próximos tendem a contribuir mais significativamente para o novo valor calculado de nível de cinza (PEDRINI e SCHWARTZ, 2008).

O valor do nível de cinza do pixel (x, y) , correspondente no centro da máscara, é substituído pelo resultado da aplicação do filtro sobre a imagem. A máscara é movida para o pixel da posição seguinte e o processo é repetido até que todos os pixels da imagem tenham sido percorridos (PEDRINI e SCHWARTZ, 2008).

W1	W2	W3
W4	W5	W6
W7	W8	W9

FIG. 2.8: Máscara de 3×3 pixels

2.2.3 FILTRO DE MÉDIA ARITMÉTICA

O filtro espacial de média aritmética consiste em substituir o valor de cada pixel da imagem pela média dos níveis de intensidade da vizinhança definida pela máscara. A média é um filtro de suavização para redução de ruído aleatório. Contudo, resulta em perda de nitidez da imagem devido ao borramento de bordas, que são transições abruptas nas intensidades, uma característica comum também nos ruídos aleatórios. Na FIG. 2.9, (a) corresponde à imagem original e (b) a (d) são os resultados das aplicações dos filtros de média 3×3, 5×5 e 7×7, respectivamente. Nota-se que a imagem resultante do processo de filtragem fica mais borrada, conforme o tamanho da máscara é aumentado (GONZALEZ e WOODS, 2014).

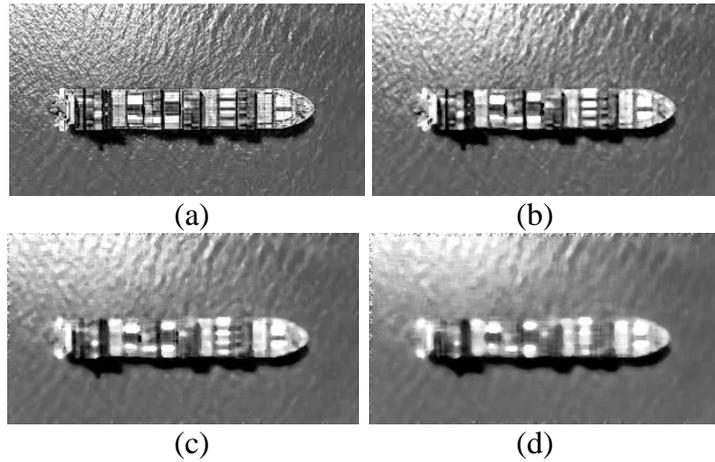


FIG. 2.9: Filtro de média aritmética

2.2.4 FILTRO DE MEDIANA

A mediana é um filtro de estatística de ordem, cuja resposta baseia-se na ordenação dos pixels da máscara pelos valores dos níveis de cinza e na substituição do pixel central pela mediana dessa classificação. Por exemplo, em uma vizinhança 3×3 , a mediana é o quinto maior valor e corresponde ao elemento central na ordenação. A EQ. 2.4 define o cálculo da mediana para uma vizinhança $n \times n$, sendo n ímpar (GONZALEZ e WOODS, 2014).

$$\text{Mediana} = x_{\left(\frac{n^2+1}{2}\right)}, \quad \text{EQ. 2.4}$$

onde n é a vizinhança e x é o elemento do vetor ordenado de posição $\left(\frac{n^2+1}{2}\right)$.

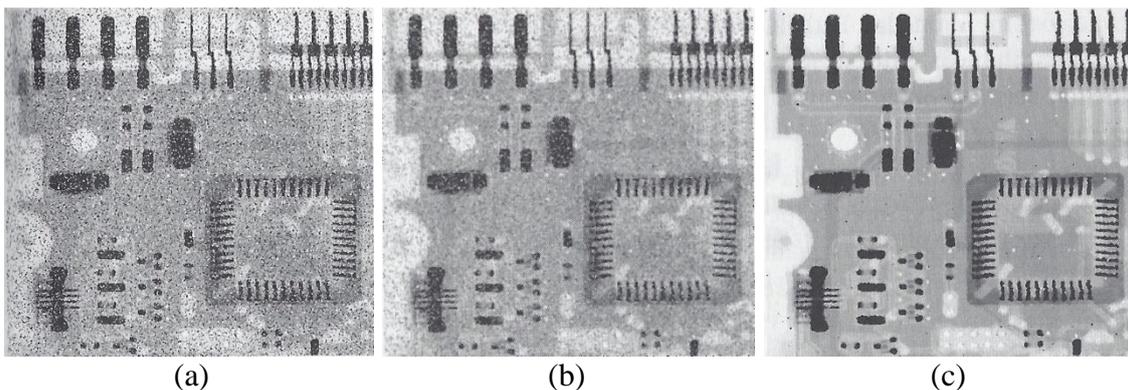


FIG. 2.10: Filtros de média e mediana. Fonte: GONZALEZ e WOODS (2014)

Este filtro é bastante eficaz em situações de presença de ruído impulsivo, conhecido também por ruído sal e pimenta, devido à aparência caracterizada por pontos brancos e pretos sobrepostos na imagem. A FIG. 2.10 (a) é a imagem de raio X de uma placa de circuito corrompida por ruído sal e pimenta, (b) é a redução de ruído com o filtro de média 3×3 e (c) é

a redução de ruído com o filtro de mediana 3×3. O filtro de média teve desempenho baixo na remoção de ruídos e borrou a imagem. O filtro de mediana proporcionou resultado superior na remoção de ruído do tipo sal e pimenta (GONZALEZ e WOODS, 2014).

2.2.5 TEXTURA

A textura pode ser descrita pela interação entre as primitivas tonais que a compõem, estas ocorrendo em diferente número e formas (HARALICK, 1979). Texturas finas são decorrentes de grandes variações nos níveis de cinza das primitivas, enquanto texturas ásperas são caracterizadas por interações mais homogêneas. As características de textura são bastante utilizadas para fins de classificação, segmentação e síntese de textura em imagens. Na tentativa de extrair medidas que representem indiretamente a textura, abordagens estatísticas são utilizadas para obter propriedades que definam a distribuição e o relacionamento entre os níveis de cinza da imagem. Uma das medidas mais básicas de textura é o desvio-padrão, descrito na EQ. 2.5, que descreve a dispersão dos valores de nível de cinza em relação à média (PEDRINI e SCHWARTZ, 2008).

$$\delta = \frac{1}{n} \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}, \quad \text{EQ. 2.5}$$

onde δ é o desvio-padrão, n é a quantidade de elementos, X_i é um elemento da matriz e \bar{X} é a média dos elementos da matriz.

2.2.6 DETECÇÃO DE BORDAS

A detecção de bordas é um método muito usado na segmentação de imagens baseada em detecção de discontinuidades, variações abruptas de intensidade de nível de cinza. Uma borda é o limite ou a fronteira entre duas regiões com propriedades relativamente distintas de nível de cinza. Os métodos mais conhecidos e empregados na detecção de bordas são os operadores de Roberts, Prewitt, Sobel e Canny. O filtro de Roberts usa duas máscaras 2×2, chamadas de operadores cruzados de gradiente de Roberts, onde o resultado é dado pela soma das respostas das máscaras horizontal e vertical, conforme representado na FIG. 2.11 (PEDRINI e SCHWARTZ, 2008).

1	0
0	-1

0	-1
1	0

FIG. 2.11: Operadores de Roberts

O filtro de Prewitt utiliza duas máscaras de 3×3 pixels para fazer o cálculo do valor da aproximação da derivada na direção x (horizontal) e na direção y (vertical), conforme mostra a FIG. 2.12 (CHAPLE *et al.*, 2015). A máscara de Sobel é parecida com a de Prewitt, sendo que sua variação de maior peso aumenta a intensidade nas bordas perpendiculares ao eixo y , para a máscara G_x , e nas bordas perpendiculares ao eixo x , para G_y (PEDRINI e SCHWARTZ, 2008).

-1	0	1
-1	0	1
-1	0	1

-1	-1	-1
0	0	0
1	1	1

FIG. 2.12: Operadores de Prewitt

Na FIG. 2.13, (a) corresponde à imagem original, (b) e (c) correspondem às detecções de bordas utilizando os operadores de Roberts e Sobel respectivamente e (d) mostra um exemplo da aplicação do filtro de Canny.

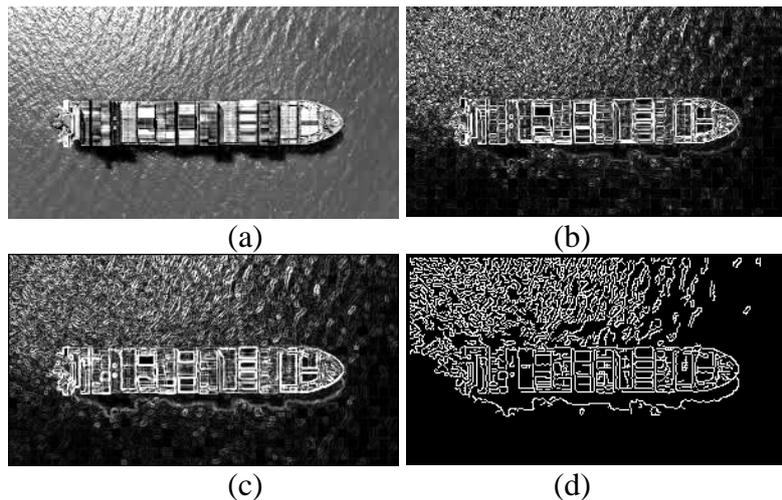


FIG. 2.13: Filtros de Roberts e Sobel

O filtro de Canny propõe uma melhor detecção de bordas por meio da otimização na identificação dos pontos pertencentes à borda, em imagens com ruído, e utiliza uma técnica denominada supressão não-máxima, que gera a redução da espessura das bordas (PEDRINI e SCHWARTZ, 2008).

2.2.7 LIMIAZIZAÇÃO

A limiarização é bastante utilizada em aplicações de segmentação de imagens com o objetivo de reduzir falsos pontos de borda. É uma técnica simples e de rápida implementação



FIG. 2.15: Código de cadeia

2.2.9 PERÍMETRO E ÁREA

Representa o comprimento da linha de contorno de um objeto, obtido pela simples contagem dos pixels. Na FIG. 2.16, o perímetro é igual a 12 e os pixels estão destacados na cor cinza. Em uma borda representada por código de cadeia de vizinhança-8, o perímetro pode ser calculado pelo número de códigos que, nas direções vertical e horizontal, contam 1 unidade e, nas direções diagonais, $\sqrt{2}$ unidades com resultado em pixels, conforme EQ. 2.6 (PEDRINI e SCHWARTZ, 2008).

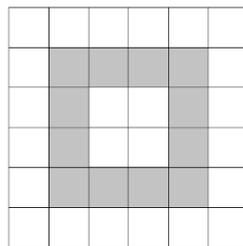


FIG. 2.16: Perímetro

$$\text{Perímetro} = N_p + \sqrt{2} \cdot N_i, \quad \text{EQ. 2.6}$$

onde N_p representa a quantidade de códigos pares (direção horizontal e vertical) e N_i representa os ímpares (direções diagonais).

A área é obtida pela quantidade de pixels da borda e do interior de um objeto. A FIG. 2.17 mostra um exemplo de área. O cálculo da área para um polígono de contorno fechado com n vértices, $(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)$, onde $(x_0, y_0) = (x_n, y_n)$, é dado pela EQ. 2.7 (PEDRINI e SCHWARTZ, 2008) com resultado em pixels.

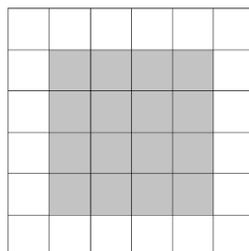


FIG. 2.17: Área

$$\text{Área} = \frac{1}{2} \left| \sum_{k=0}^{n-1} (x_k y_{k+1} - x_{k+1} y_k) \right| \quad \text{EQ. 2.7}$$

2.2.10 FUNÇÃO DE DESVIO

A função de desvio (*turning function* ou *turning angle function*) é utilizada para gerar a descrição do formato de um objeto, fornecendo sua assinatura. Qualquer polígono bidimensional finito pode ser convertido em *turning function* (VOLOTÃO *et al.*, 2010). Na função de desvio, os ângulos variam de 0 a 360°, i. e. o espaço transformado é uma projeção cilíndrica (CAKMAKOV e CELAKOSKA, 2004). Semelhante à codificação em cadeia, a função de desvio baseia-se na amostragem da borda de um polígono projetado sobre uma grade, cujo espaçamento define a resolução adotada. A função de desvio pode ser convertida em código de cadeia e vice-versa (VOLOTÃO *et al.*, 2010).

A partir de um ponto inicial do polígono, a função de desvio é gerada registrando-se os pares de dados: distância, tamanho do segmento contínuo na mesma direção, e ângulo de desvio, curva entre o segmento atual e o segmento adjacente anterior. A FIG. 2.18 apresenta a imagem binária de um objeto, o seu contorno vetorizado e a representação gráfica da sua função de desvio.

Na função de desvio, as direções do código de cadeia são convertidas em ângulos e distâncias. A conversão em ângulo inicia em 0° para a direção 0 e varia em 45°, seguindo a vizinhança-8, no sentido anti-horário. Cada pixel na direção horizontal ou vertical (direções 0, 2, 4 e 6) corresponde à 1 unidade de distância e os pixels das direções diagonais (direções 1, 3, 5 e 7) correspondem à $\sqrt{2}$ unidades de distância.

O código de cadeia exibido na seção 2.2.8, referente à FIG. 2.15, pode ser convertido na função de desvio abaixo, onde os pares de valores são, respectivamente, o ângulo e a distância.

[(225°, 1); (180°, 1); (270°, 2); (180°, 1); (270°, 3); (180°, 1); (270°, 3); (180°, 1); (270°, 3); (180°, 1); (270°, 3); (180°, 1); (270°, 4); (180°, 1); (270°, 2); (180°, 1); (270°, 3); (180°, 1); (270°, 4); (180°, 1); (270°, 4); (180°, 1); (270°, 3); (315°, 1); (0°, 3); (45°, 2); (90°, 2); (0°, 1); (90°, 2); (0°, 1); (90°, 2); (0°, 1); (90°, 4); (0°, 1); (90°, 2); (45°, 1); (90°, 3); (0°, 1); (90°, 2); (45°, 1); (90°, 3); (0°, 1); (90°, 4); (0°, 1); (90°, 2); (135°, 1); (180°, 2)]

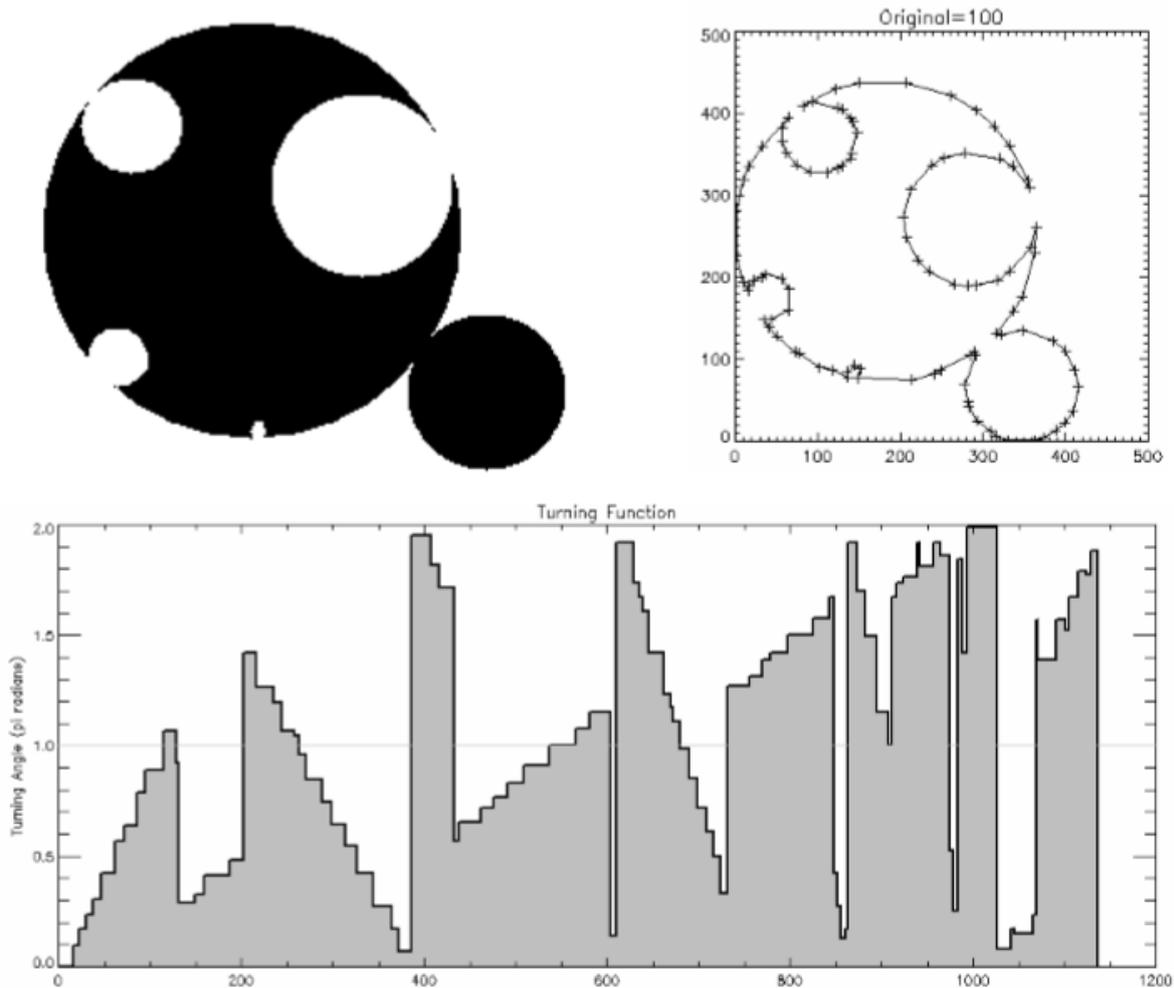


FIG. 2.18: Função de desvio. FONTE: VOLOTÃO *et al.* (2010)

A comparação de formato entre dois polígonos A e B é obtida por meio do cálculo da distância entre as funções de desvio de A e B , mostrada na EQ. 2.8 (ARKIN *et al.*, 1991). Quanto mais próximo de 0 for o valor da distância, maior é a semelhança entre os polígonos, conforme indicado pelas propriedades: $d(A,B) \geq 0$ e $d(A,B) = 0$, se e somente se $A=B$.

$$D_P(A,B) = \left(\min_{\substack{t \in [0,1] \\ \theta \in [0,2\pi]}} \left[\int_0^1 |\theta_A(s+t) - \theta_B(s) + \theta|^P ds \right] \right)^{\frac{1}{P}} \quad \text{EQ. 2.8}$$

2.3 PRECISÃO E ABRANGÊNCIA

Precisão e abrangência (*precision and recall*) são medidas de desempenho utilizadas para avaliar sistemas ou modelos. A precisão refere-se à capacidade de retornar os resultados relevantes e a abrangência consiste em, a partir de um conjunto de dados, encontrar aqueles que são relevantes. A precisão é dada pela fração das instâncias relevantes recuperadas entre as

instâncias recuperadas, conforme EQ. 2.9. A abrangência é a fração das instâncias relevantes recuperadas sobre a quantidade total de instâncias relevantes, conforme EQ. 2.10. A acurácia é dada pela média harmônica entre a precisão e a abrangência do modelo. A medida-F (*F-Measure*) combina precisão e abrangência. Na EQ. 2.11, para $\beta = 1$, a medida-F corresponde à média harmônica entre precisão e abrangência.

$$\text{Precisão} = \frac{(\text{instâncias relevantes}) \cap (\text{instâncias recuperados})}{\text{instâncias recuperados}} \quad \text{EQ. 2.9}$$

$$\text{Abrangência} = \frac{(\text{instâncias relevantes}) \cap (\text{instâncias recuperados})}{\text{quantidade total de instâncias relevantes}} \quad \text{EQ. 2.10}$$

$$F\beta = (1 + \beta^2) \frac{\text{Precisão} * \text{Abrangência}}{\beta^2 * \text{Precisão} + \text{Abrangência}} \quad \text{EQ. 2.11}$$

Em classificações e reconhecimento de padrões, a precisão e a abrangência são obtidas a partir da matriz de confusão, tabela onde as colunas representam a quantidade de classificações do modelo por classe e as linhas, a quantidade correta de exemplos por classe. A precisão corresponde à fração dos exemplos classificados de uma classe, *positivos verdadeiros*, dentre os que foram classificados nessa classe, *positivos verdadeiros + positivos falsos*. A abrangência corresponde à fração dos exemplos classificados de uma classe, positivos verdadeiros, dentre aqueles que são da classe, *positivos verdadeiros + negativos falsos* (FIG. 2.19).

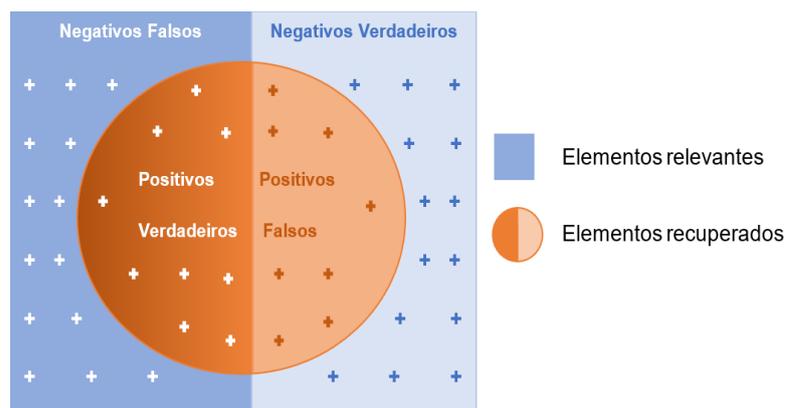


FIG. 2.19: Precisão e Abrangência

No exemplo da matriz de confusão da TAB. 2.1, para a classe embarcação, a precisão da classificação foi de 100%, a abrangência foi de 96,15% e a medida F, com $\beta = 1$, foi de 98,04%.

TAB. 2.1: Matriz de confusão exemplo

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	25	0
	Não-embarcação	1	0

2.4 DISTRIBUIÇÃO *T* DE *STUDENT*

O nome dessa distribuição deve-se ao pseudônimo *Student* utilizado por William Sealy Gosset como condição imposta pela cervejaria de Arthur Guinness e Cia Ltda de Dublin - Irlanda, onde trabalhava como cervejeiro, para publicar o artigo, *The Probable Error of a Mean*, em 1908 em que apresentou a distribuição *t* (VIALI *et al.*, 2016).

A distribuição *t* de *Student* é um modelo contínuo que se assemelha à distribuição normal padrão e é utilizada para inferências estatísticas, particularmente, quando o tamanho das amostras é inferior à 30 elementos (FONSECA *et at*, 2010). A distribuição é simétrica em relação à média, que é igual a 0, e sua variância é dada pela EQ. 2.12.

$$\text{Var} [t\varphi] = \frac{\varphi}{\varphi - 2} \quad (\varphi > 2) \quad \text{EQ. 2.12}$$

2.4.1 TESTE *T* PARA DUAS AMOSTRAS COM VARIÂNCIAS DIFERENTES

Presumindo-se que as amostras são diferentes, foram selecionadas aleatoriamente a partir de populações distribuídas nos moldes da distribuição normal e as variâncias das populações são iguais, é possível utilizar um teste *t* de variância agrupada para verificar se as médias aritméticas das duas populações são significativamente diferentes (LEVINE *et al.*, 2008).

Para testar a hipótese de que não existe diferença entre as médias aritméticas de duas populações independentes, $H_0: \mu_1 = \mu_2$ ou $\mu_1 - \mu_2 = 0$, contra a hipótese de que as médias não são iguais, utiliza-se a estatística do teste *t* de variância agrupada conforme EQ. 2.13 (LEVINE *at al.* , 2008).

$$t = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{S_p^2 \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \quad \text{EQ. 2.13}$$

$$S_p^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{(n_1 - 1) + (n_2 - 1)}, \quad \text{EQ. 2.14}$$

onde S_p^2 = variância agrupada e é calculada conforme EQ. 2.14, \bar{X}_1 = média aritmética da amostra da população 1, S_1^2 = variância da amostra da população 1, n_1 = tamanho da amostra da população 1, \bar{X}_2 = média aritmética da amostra da população 2, S_2^2 = variância da amostra da população 2 e n_2 = tamanho da amostra da população 2.

3. APRESENTAÇÃO DO MÉTODO

Este capítulo apresenta detalhadamente a sequência de execução de processos do método.

3.1 PROCESSOS DO MÉTODO PROPOSTO

A execução do método compreende um conjunto de processos, conforme demonstra o fluxograma da FIG. 3.1. Os processos I, II, III, IV, V e VI do fluxograma estão representados em uma visão macro e são devidamente detalhados nas seções seguintes.

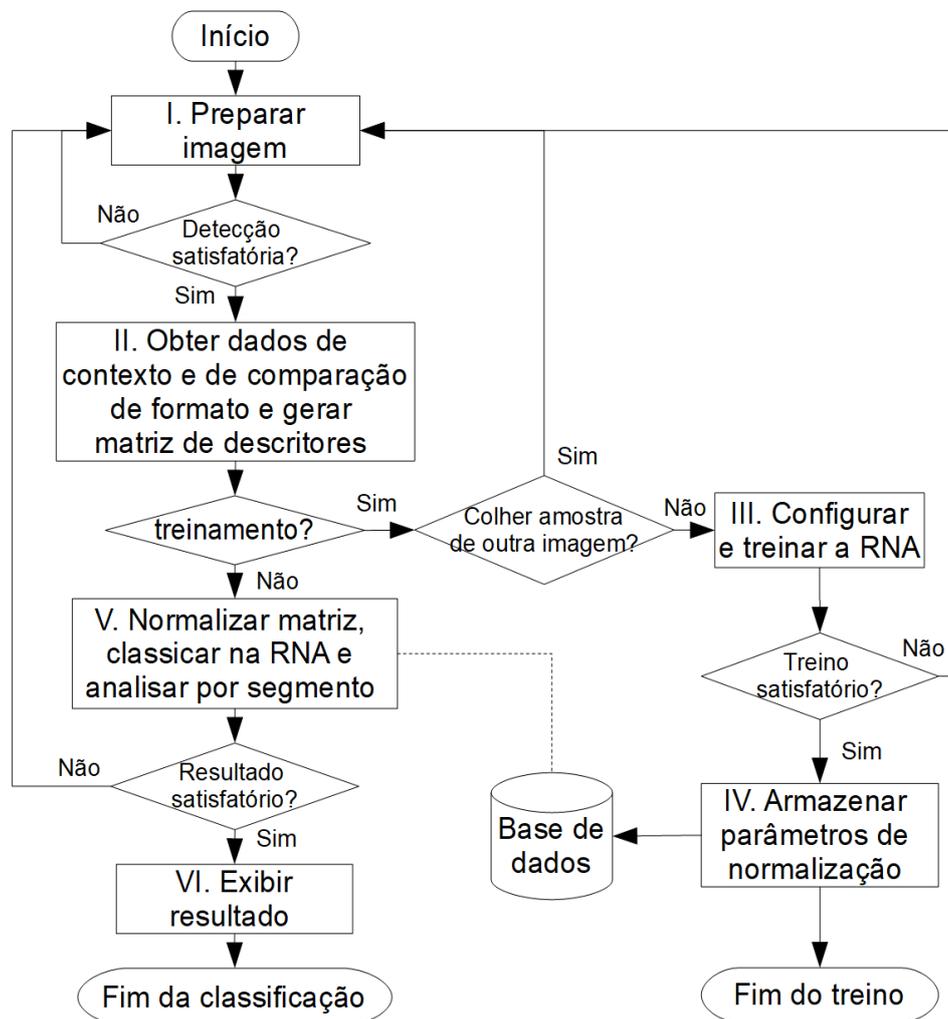


FIG. 3.1: Fluxograma do método proposto

3.2 PREPARAR IMAGEM (I)

O processo I da Fig. 3.1 compreende a obtenção da imagem, a seleção das amostras e a detecção de bordas.

3.2.1 OBTENÇÃO DA IMAGEM

Este processo corresponde à obtenção das imagens para a execução do método. Dentre os fatores que devem ser considerados para a obtenção das imagens estão: o tipo de sensor, a resolução espacial e sua correlação com o pixel da imagem e as correções atmosférica e geométrica.

Quanto ao tipo de sensor, o método proposto foi descrito para ser aplicado em imagens multiespectrais de sensores ópticos. Logo, sua aplicação em imagens provenientes de outros tipos de sensores estará condicionada à realização dos ajustes necessários em função das características do tipo do sensor.

No que diz respeito à resolução, a eficácia da detecção é definida pela relação entre o tamanho da embarcação e a resolução espacial da imagem, sendo que a largura mínima da embarcação deve corresponder a, no mínimo, duas vezes o tamanho do pixel.

Por último, cabe ressaltar que, caso não estejam corrigidas, as imagens obtidas devem passar pelo devido processo de correção geométrica e atmosférica antes de serem submetidas à execução do método.

3.2.2 SELEÇÃO DE AMOSTRAS

A seleção de amostras consiste primeiramente em selecionar, dentre as imagens obtidas, aquelas das quais serão obtidos os dados para o treinamento da rede neural artificial. Em cada imagem, são selecionadas amostras para cada classe de saída da RNA, i. e. amostras de embarcações e de outros elementos, como mar, ilha, ponte e continente, registrando as coordenadas (x, y) dos pixels dessas amostras para a obtenção dos dados de contexto e de comparação de formato no processo seguinte.

3.2.3 DETECÇÃO DE BORDAS

O processo de detecção de bordas é empregado com o objetivo de realizar a segmentação da imagem. Os segmentos encontrados na imagem são analisados para a seleção dos navios candidatos.

Para a escolha do filtro a ser utilizado no método, foram testados três operadores de detecção de bordas: Roberts, Sobel e Canny. O filtro de Canny mostrou-se mais adequado ao objetivo do método porque gera linhas de representação de bordas mais finas e mais fiéis à posição dos pixels na imagem original, conforme demonstra a FIG. 3.5. Além disso, esse filtro

gera uma imagem binária, que é o tipo de imagem apropriada para a geração do código de cadeia.

Na FIG. 3.2 (a) é apresentada a imagem original e em (b), (c) e (d) são apresentados os resultados das aplicações dos filtros de Roberts, Sobel e Canny respectivamente.

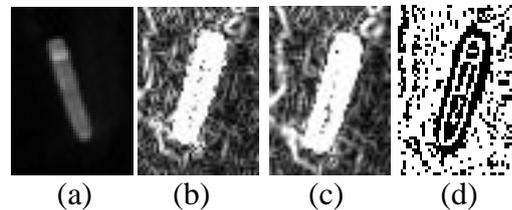


FIG. 3.2: (a) Imagem original. Fonte: RapidEye (b) Roberts (c) Sobel (d) Canny.

Na FIG. 3.2, verifica-se que os filtros de detecção de bordas geram resultados com muito ruído. Em diversos casos é necessário aplicar, sobre a imagem resultante da detecção de bordas, uma máscara baseada na filtragem de limiarização sobre a imagem original com um valor de limiar definido entre o maior número digital assumido para a água do mar e o menor número digital assumido pelos alvos (segmentos) da imagem. A FIG. 3.3 (c) apresenta a aplicação da máscara baseada na limiarização sobre a detecção de bordas da figura (b).

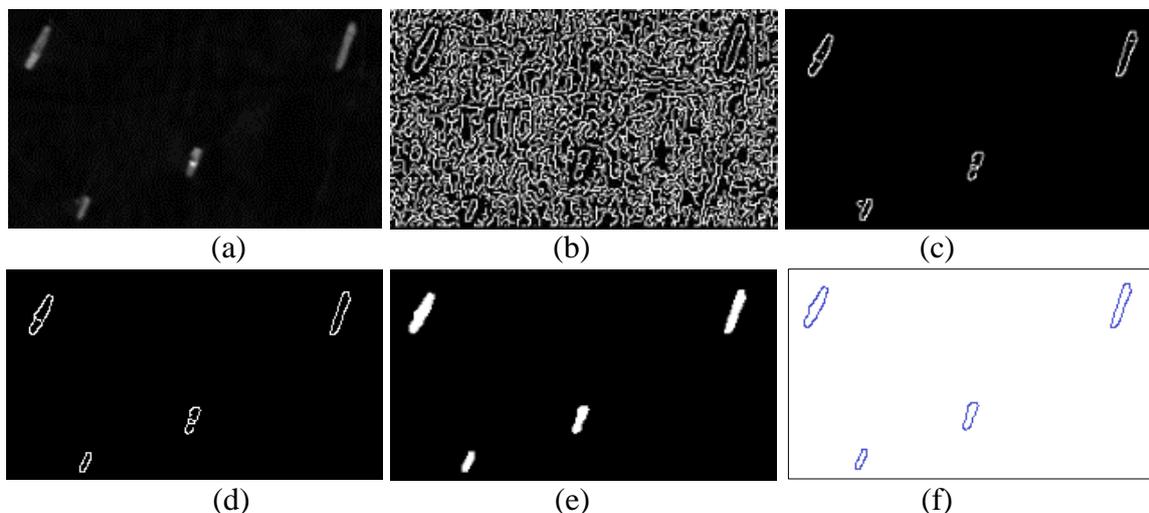


FIG. 3.3: Detecção de bordas: (a) imagem original. Fonte: RapidEye (b) filtro Canny (c) máscara baseada na limiarização (d) filtragem por mínimo de pixels consecutivos (e) fechamento e preenchimento (f) representação gráfica do código de cadeia

Com o intuito de eliminar ruídos residuais, o último passo da detecção de bordas consiste em filtrar a imagem binária em função do tamanho mínimo do conjunto de pixels consecutivos, de valor igual a um, capaz de representar uma embarcação, variando conforme a resolução espacial, como mostra a FIG. 3.3 (d). Na FIG. 3.4 (a) é apresentado um exemplo de conjunto

de pixels a ser eliminado, enquanto em (b) é apresentado um exemplo de conjunto de pixels consecutivos capaz de corresponder a uma embarcação.

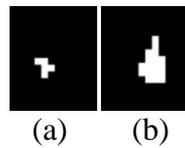


FIG. 3.4: Conjunto mínimo de pixels

Também podem ser realizados processamentos complementares como processamentos morfológicos de fechamento e de preenchimento de região, conforme mostra a FIG. 3.3 (e).

A sequência dos passos realizados no processo de detecção de bordas é representada na FIG. 3.5.

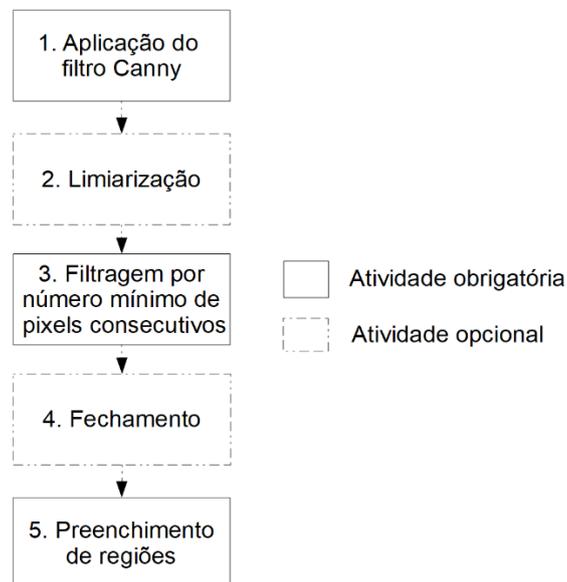


FIG. 3.5: Processo de detecção de bordas

3.3 OBTER DADOS DE CONTEXTO E DADOS DE COMPARAÇÃO DE FORMATO E GERAR MATRIZ DE DESCRITORES (II)

O processo II da FIG. 3.1 compreende a geração do código de cadeia, o cálculo da função de desvio, a comparação de contorno, a obtenção dos dados de contexto e a geração da matriz de descritores.

3.3.1 GERAÇÃO DO CÓDIGO DE CADEIA

Antes de gerar o código de cadeia, o método prevê a correção de pixels com ruído na imagem binária resultante do processo de detecção de bordas, por meio do uso de máscaras, conforme mostra a FIG. 3.6.

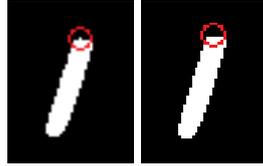


FIG. 3.6: Correção de pixel

Na imagem resultante, os pixels de fundo são desconsiderados e é gerado um código de cadeia de contorno para cada conjunto válido de pixels consecutivos de valor igual a 1 encontrado na imagem, gerando uma matriz de códigos de cadeia de contorno de segmentos da imagem, representada graficamente na FIG. 3.3 (f).

3.3.2 CÁLCULO DA FUNÇÃO DE DESVIO

O código de cadeia dos pixels de contorno do segmento pode ser diretamente convertido em uma função de desvio. Mas, para obter uma função de desvio de contorno mais regular, o código de cadeia obtido anteriormente foi analisado de forma a determinar pequenos segmentos de reta, de modo a suavizar as irregularidades do contorno. Os segmentos de reta identificados no código de cadeia iniciam no mesmo ponto (x, y) em que terminam os segmentos anteriores, marcando, assim, o vértice entre eles. A FIG. 3.7 representa graficamente o código de cadeia de contorno de um segmento, sendo que os segmentos de reta estão identificados na cor verde e os vértices na cor vermelha.

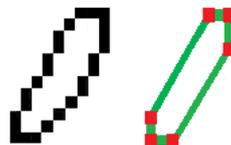


FIG. 3.7: Suavização do código de cadeia

Os ângulos e as distâncias da função de desvio foram calculados a partir dos vértices e segmentos de reta. Os ângulos dos vértices foram obtidos pela projeção das coordenadas (x, y) de início e fim dos pares de segmentos de reta adjacentes sob um plano cartesiano, conforme

representação da FIG. 3.8, e pelo uso da função de cálculo de ângulo entre vetores, conforme EQ. 3.1.

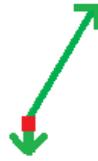


FIG. 3.8: Vetores adjacentes

$$\cos\theta = \frac{\langle v, u \rangle}{|v| \cdot |u|}, \quad \text{EQ. 3.1}$$

onde $\cos\theta$ é o cosseno do ângulo do vértice, $\langle v, u \rangle$ é o produto escalar dos vetores v e u , calculado conforme EQ. 3.2, e $|v| \cdot |u|$ é o produto dos módulos dos vetores v e u , cujo cálculo é exibido na EQ. 3.3, onde x e y são as coordenadas.

$$\langle v, u \rangle = x_1 \cdot x_2 + y_1 \cdot y_2 \quad \text{EQ. 3.2}$$

$$|v| = \sqrt{x^2 + y^2} \quad \text{EQ. 3.3}$$

3.3.3 COMPARAÇÃO DE CONTORNO

As embarcações geralmente possuem aparência fina, alongada e simétrica e podem ser divididas em três partes principais: proa, popa e laterais. A proa corresponde à parte dianteira da embarcação, normalmente, com aspecto pontiagudo ou arredondado. A popa, parte traseira, pode possuir formato reto ou semelhante ao da proa. O foco da comparação de contornos está em reconhecer essas características de formato nos segmentos detectados nas imagens. Em cada segmento, foram encontrados os pontos do diâmetro e os vértices mais próximos para realizar a comparação pela função de desvio. A FIG. 3.9 (a) mostra os pontos do diâmetro sobre o contorno do segmento, em cor vermelha, e a imagem (b) mostra os vértices mais próximos, em cor verde.

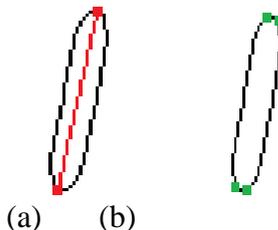


FIG. 3.9: (a) diâmetro (b) vértices mais próximos

Para adequar-se a embarcações de quaisquer tamanhos, o parâmetro de distância utilizado para a comparação de formato baseou-se em uma distância mínima, definida conforme a resolução da imagem. Quanto ao ângulo, foram definidos parâmetros válidos, possíveis de ocorrerem na proa ou popa de uma embarcação, e inválidos, que não representam partes de interesse da embarcação, considerando a resolução espacial da imagem.

A comparação dos segmentos detectados na imagem com os parâmetros válidos e inválidos é realizada por meio do cálculo da distância entre duas funções de desvio, conforme abordado na seção 2.2.10, sendo que, para a obtenção dos dados de comparação de contorno que compõem a matriz de descritores, foram consideradas apenas as comparações válidas encontradas nos vértices mais próximos aos pontos de diâmetro dos segmentos.

A sequência dos passos realizados no processo de comparação de contorno é representada na FIG. 3.10.

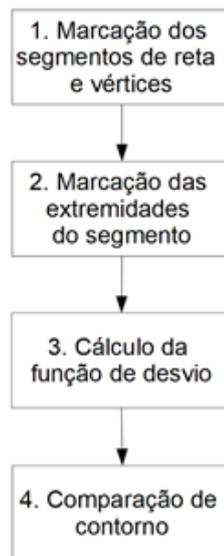


FIG. 3.10: Processo de comparação de contorno

Como resultado do processo de comparação dos segmentos da imagem, foram geradas:

- a) Matriz binária da comparação de contorno das extremidades, onde 1 indica que a extremidade apresentou um dos formatos desejáveis; e
- b) Imagem com a marcação das extremidades dos segmentos que apresentaram um dos formatos desejáveis.

3.3.4 OBTENÇÃO DOS DADOS DE CONTEXTO

Os dados contextuais referem-se às características relacionadas aos alvos de interesse, que são as embarcações, e ao ambiente onde se encontram. Considerando primeiramente o meio

onde estão as embarcações, a água do mar, cuja resposta espectral é muito baixa, é um dado contextual utilizado no método de acordo com a EQ. 3.4.

- 1) Terceira menor resposta espectral numa moldura, estabelecida a partir do pixel analisado, conforme mostra a FIG. 3.11, com dimensão em que caiba a maior embarcação e, no mínimo, 5 pixels em volta da mesma.

$$\text{Mínimo}_3 = x_3(x_1, x_2, x_3, \dots, x_n), \quad \text{EQ. 3.4}$$

onde $(x_1, x_2, x_3, \dots, x_n)$ corresponde ao vetor dos elementos ordenados e sem repetição.

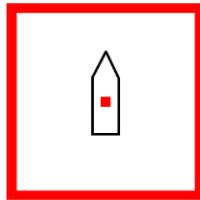


FIG. 3.11: Moldura

A utilização da terceira menor resposta espectral diferente justifica-se para evitar que ruídos ou outros valores baixos inseridos na imagem em função de configurações próprias do sensor, como bordas ou linhas pretas, venham a influenciar negativamente neste dado contextual.

Outro dado de contexto importante diz respeito à diferenciação dos tipos de materiais em função de suas respostas espectrais. No método, o valor da resposta espectral dos segmentos detectados na imagem é obtido por:

- 2) mediana da vizinhança 3×3 (FIG. 3.12), estabelecida a partir do pixel analisado, considerando apenas os pixels que pertencem ao mesmo segmento que o pixel central, conforme exemplo demonstrado na FIG. 3.13.

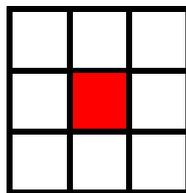


FIG. 3.12: Vizinhança 3x3

Na FIG. 3.13, é representada uma vizinhança 3×3 , onde os pixels de cor amarela pertencem ao fundo e os pixels de cor azul fazem parte do segmento I . Para o cálculo da mediana, foram excluídos os pixels x_1 e x_4 , por não fazerem parte do mesmo segmento do pixel em análise x_5 . Neste caso, o conjunto ordenado dos elementos $x_2, x_3, x_5, x_6, x_7, x_8$ e x_9 , pertencentes ao mesmo

segmento de x_5 , será $(x_1Seg, x_2Seg, x_3Seg, x_4Seg, x_5Seg, x_6Seg, x_7Seg)$. Conforme EQ. 2.4, a mediana é dada pelo valor de $xSeg_4$.

x1	x2	x3
x4	x5	x6
x7	x8	x9

FIG. 3.13: Pixels e segmentos

Para uma vizinhança $n \times n$, onde n é par, a mediana é dada pela soma dos valores dos elementos (x) das posições centrais do vetor ordenado dividida por 2, conforme EQ. 3.5.

$$Mediana = \frac{x_{\left(\frac{n^2}{2}\right)} + x_{\left(\frac{n^2}{2} + 1\right)}}{2}, \quad \text{EQ. 3.5}$$

A textura é uma característica importante e muito utilizada na criação de descritores em processos de classificação. Em geral, a resposta espectral das embarcações possui textura homogênea. Comparativamente, continentes e ilhas com construções tendem a gerar respostas espectrais com textura heterogênea. Em uma representação muito básica, a média representa o valor da distribuição dos níveis de cinza presentes em uma textura e o desvio-padrão, descreve a dispersão dos valores em torno da média. Estes dois dados contextuais são utilizados conforme descrito abaixo:

- 3) A média dos pixels na vizinhança 9×9 , estabelecida a partir do analisado, considerando apenas os pixels do mesmo segmento que o pixel central, de acordo com a EQ. 3.6.

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n xSeg_i \quad \text{EQ. 3.6}$$

- 4) O desvio-padrão na vizinhança 9×9 , estabelecida a partir do pixel analisado, considerando apenas os pixels do mesmo segmento que o pixel central, de acordo com a EQ. 3.7.

$$\delta = \frac{1}{n} \sqrt{\sum_{i=1}^n (xSeg_i - \bar{xSeg})^2} \quad \text{EQ. 3.7}$$

Em relação às características de contexto de formato, a aparência fina, alongada e simétrica, normalmente encontrada nas embarcações, será representada por:

- 5) Compacidade, que é a razão entre o perímetro e a área, calculada conforme EQ. 3.8.

$$C = \frac{P^2}{A}, \quad \text{EQ. 3.8}$$

onde C é a compacidade, P é o perímetro e A é a área do segmento.

Na FIG. 3.14, a compacidade do objeto de cor verde é 22,64 e a compacidade o objeto de cor azul é 9,88. Verifica-se que valores mais baixos correspondem a formatos mais compactos enquanto formatos compridos e afinados possuem valores de compacidade mais elevados.

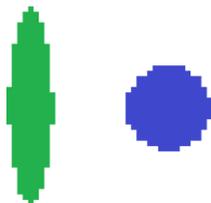


FIG. 3.14: Diferença de compacidade

A última característica contextual utilizada pelo método é o diâmetro dos segmentos detectados na imagem. Este dado ajudará a diferenciar, por exemplo, as embarcações das grandes ilhas e porções de continente.

6) O diâmetro do segmento foi calculado conforme EQ. 3.9.

$$D = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}, \quad \text{EQ. 3.9}$$

onde D é o diâmetro do segmento, x_1 e x_2 são as coordenadas do ponto P_1 e y_1 e y_2 são as coordenadas do ponto P_2 .

A FIG. 3.15 mostra os dados de contexto. Os quatro primeiros são obtidos para o pixel. A compacidade e o diâmetro estão relacionados ao segmento ao qual o pixel pertence.

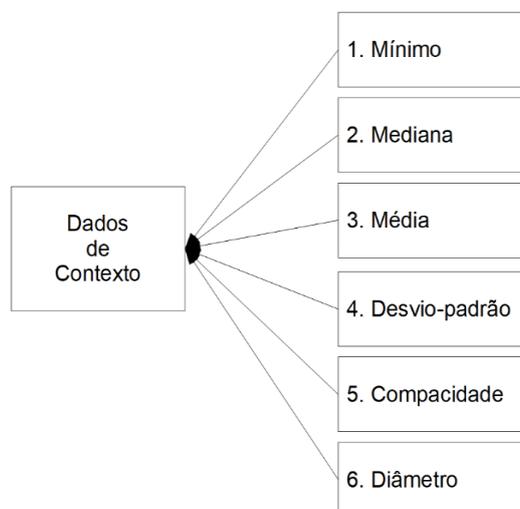


FIG. 3.15: Dados de contexto

Cabe ressaltar que as imagens apresentarão grande variação de amplitude nos valores de nível de cinza, em decorrência, por exemplo, de correções geométricas e radiométricas. Portanto, para permitir a comparação dos dados contextuais extraídos a partir de valores de nível de cinza de imagens diferentes, o método sugere que os dados de valor mínimo, mediana, média e desvio-padrão passem por um processo de normalização linear, baseado na EQ. 3.10.

$$f(x) = \frac{x - Min}{Max - Min}, \quad \text{EQ. 3.10}$$

onde $f(x)$ é a função de normalização, Min é o valor mínimo obtido a partir da mediana de vizinhança 10×10 de um ponto central selecionado em porção de mar na imagem, e Max é o valor máximo obtido a partir da mediana em uma vizinhança 3×3 de um ponto central selecionado no interior da embarcação que apresentar a maior resposta espectral.

3.3.5 GERAÇÃO DA MATRIZ DE DESCRITORES

A matriz é composta pelos oito descritores, dos quais seis correspondem aos dados de contexto da imagem: mínimo, mediana, média, desvio-padrão, compacidade e diâmetro e dois correspondem às comparações de formato das extremidades do segmento, descritos nas seções 3.3.4 e 3.3.3 respectivamente.

A sequência das atividades realizadas no processo de geração da matriz de descritores é representada na FIG. 3.16.

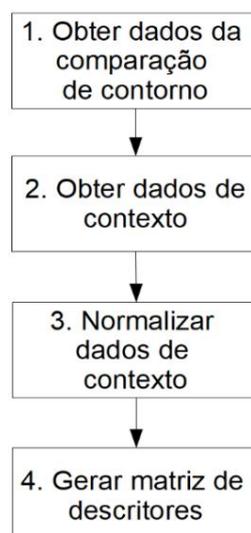


FIG. 3.16: Processo de geração da matriz de descritores

No processo de classificação é gerada uma matriz de descritores para cada imagem a ser classificada, conforme mostra o fluxograma de classificação de imagens da FIG. 3.17.

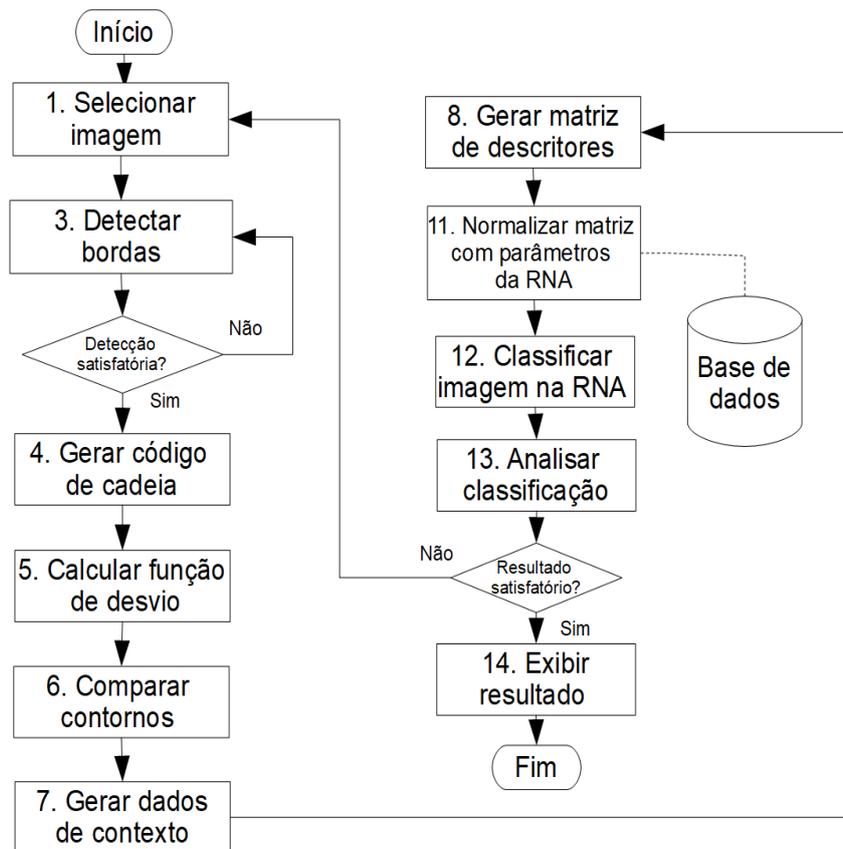


FIG. 3.17: Fluxograma de classificação de imagem

Na obtenção dos exemplos de treinamento da RNA, o processo foi realizado para todas as imagens nas quais foram extraídas amostras. Para cada imagem foi gerada uma matriz de descritores, cujo número de linhas está associado à quantidade de pixels de amostra obtidos na imagem. Essa iteração pode ser visualizada no fluxograma de treinamento da RNA apresentado na FIG. 3.18. Em seguida, as matrizes de todas as imagens de amostras foram concatenadas, gerando uma matriz única a ser utilizada como conjunto de dados de treinamento da RNA.

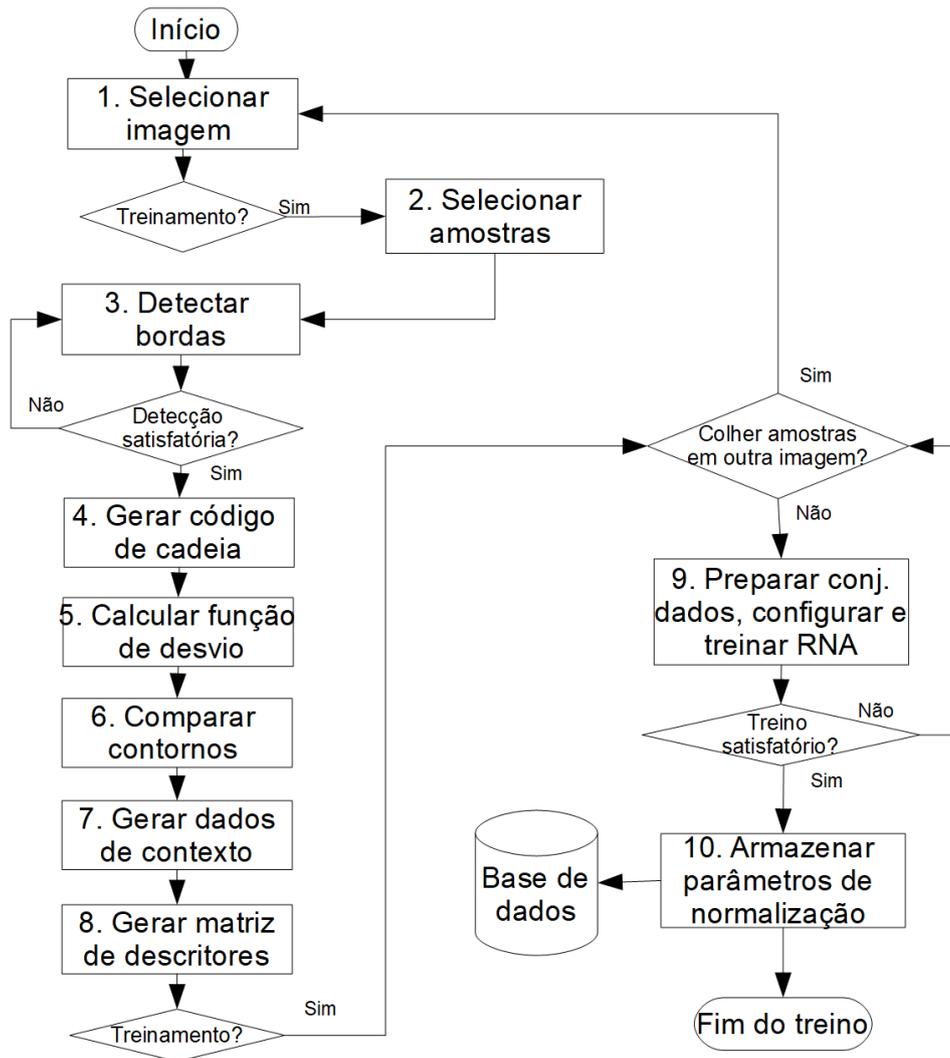


FIG. 3.18: Fluxograma de treinamento da RNA

3.4 CONFIGURAR E TREINAR A RNA (III)

O processo III da FIG. 3.1 compreende a normalização do conjunto de dados de treinamento e a configuração e treinamento da RNA.

3.4.1 NORMALIZAÇÃO DO CONJUNTO DE DADOS DE TREINAMENTO

O conjunto de dados de treinamento, que é a matriz de descritores das amostras, precisa passar por um processo de normalização, cujo objetivo é ajustar as escalas de valores dos atributos dentro de um mesmo intervalo. Antes de ser submetida como entrada para treinamento da RNA, cada coluna da matriz de descritores será normalizada pelo seu desvio-padrão, conforme EQ. 2.5.

3.4.2 CONFIGURAÇÃO DA RNA

Na configuração da rede neural artificial são definidos parâmetros como quantidade de entradas, número de camadas ocultas e quantidade de neurônios para cada uma delas, quantidade de classes de saída, funções de ativação, distribuição (percentual) do conjunto de dados para o treinamento, teste e validação da RNA e modos de seleção das amostras (aleatório, em bloco).

3.4.3 TREINAMENTO DA RNA

Antes de ser usada como classificador, a RNA passa por uma fase de treinamento, na qual o conjunto de dados de amostras é fornecido à rede para que esta obtenha a melhor combinação dos pesos sinápticos das conexões entre os neurônios artificiais. A métrica de avaliação do treinamento é o erro quadrático médio.

3.5 ARMAZENAR PARÂMETROS DE NORMALIZAÇÃO (IV)

A média e o desvio-padrão utilizados para normalizar o conjunto de dados de treinamento da rede neural artificial devem ser armazenados, pois serão utilizados posteriormente como parâmetros de normalização das matrizes de descritores das imagens a serem classificadas pela RNA. Corresponde ao processo IV da FIG. 3.1.

3.6 NORMALIZAR MATRIZ DE DESCRITORES DA IMAGEM, CLASSIFICÁ-LA NA RNA E REALIZAR A ANÁLISE POR SEGMENTO (V)

O processo V da FIG. 3.1 compreende a normalização da matriz de descritores da imagem a ser classificada pela RNA, a classificação da imagem e a análise da classificação por segmento.

3.6.1 NORMALIZAÇÃO DA MATRIZ DE DESCRITORES DA IMAGEM DE CLASSIFICAÇÃO

É o ajuste das escalas dos dados da matriz de descritores dos segmentos da imagem a ser classificada pela RNA, dentro de um mesmo intervalo, realizado por uma normalização utilizando os mesmos parâmetros de média e desvio-padrão empregados na normalização do conjunto de dados de treinamento da RNA.

3.6.2 CLASSIFICAÇÃO DA IMAGEM NA RNA

Consiste em submeter a matriz de descritores dos segmentos da imagem ao processo de classificação da RNA. Na FIG. 3.19, cada linha da matriz é uma entrada da RNA, que gera uma matriz de saída onde cada linha corresponde ao resultado referente à cada classe.

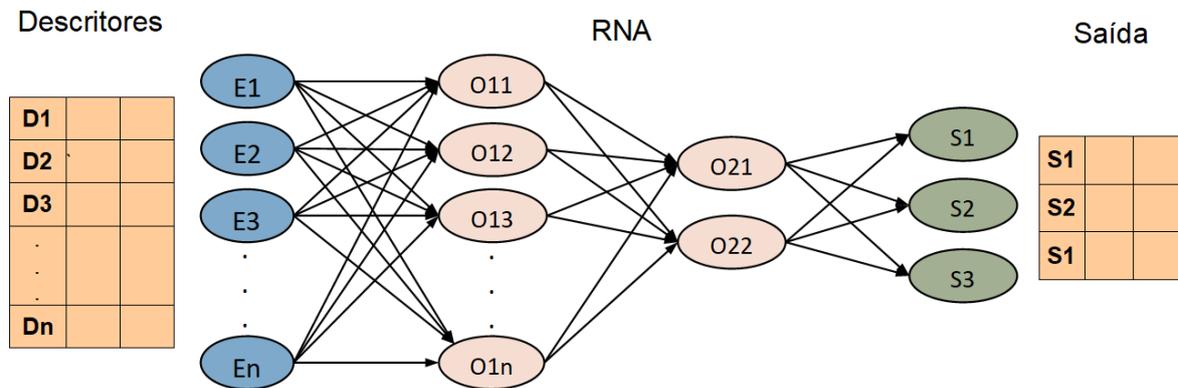


FIG. 3.19: Classificação na RNA

3.6.3 ANÁLISE DA CLASSIFICAÇÃO POR SEGMENTO

A RNA gera a classificação para o pixel. O resultado da classificação da imagem pode ser melhorado por meio de uma análise que considere a classificação para o segmento. Essa análise considera a classificação majoritária do segmento, i. e. a moda das classificações de todos os pixels que formam o segmento.

3.7 EXIBIR RESULTADO DA DETECÇÃO DAS EMBARCAÇÕES NA IMAGEM (VI)

O resultado da detecção realizada pelo método é exibido em uma imagem gerada a partir de destaques por marcações coloridas sobre a imagem original submetida ao método proposto. Corresponde ao processo VI da FIG. 3.1.

4. APLICAÇÃO DO MÉTODO

Este capítulo apresenta a aplicação dos processos definidos para o método em um estudo de caso. A classificação das imagens considera as situações:

- a) Situação 1 → utilização dos oito descritores, formados pelas características espectrais, de textura e de formato e pelos dados de comparação de contorno;
- b) Situação 2 → utilização de seis descritores, formados pelas características espectrais, de textura e de formato; e
- c) Situação 3 → classificação das imagens pelo método SVM aplicado sobre as 5 bandas e com a análise de resultado descrita na seção 3.6.3.

São apresentados 16 recortes de imagens classificados nas três situações descritas acima. Os resultados obtidos para as três situações são avaliados em relação à precisão, abrangência e medida-F e comparados pelo teste *t* de *Student*.

4.1 ESTUDO DE CASO

A Baía de Guanabara foi a área teste selecionada para este estudo de caso, tendo em vista o seu intenso tráfego marítimo, a existência dos portos do Rio de Janeiro e de Niterói e o fato de abrigar a sede da Esquadra Brasileira. A FIG. 4.1 mostra a área teste destacada em amarelo, cujas coordenadas dos pontos *A*, *B*, *C* e *D* são, respectivamente, 22°46'28.83"S e 43°22'6.28"W, 22°46'19.20"S e 43°7'30.12"W, 23°0'1.35"S e 43°21'56.55"W, 22°59'51.62"S e 43°7'18.94"W.

Neste estudo de caso foram utilizadas imagens de satélite RapidEye do catálogo do Ministério do Meio Ambiente (MMA), disponibilizadas ao IME. As imagens multiespectrais RapidEye possuem 12 bits, resolução de 5 metros e estão disponíveis em 5 bandas, onde as bandas 3, 2, 1 formam a composição RGB, a banda 4 corresponde à faixa do *red-edge* e a 5 corresponde ao infravermelho próximo (MMA, 2017). Este capítulo não trata de correções radiométricas e geométricas porque as imagens RapidEye já passaram pelos devidos processos de correção.

Neste estudo de caso, o método propõe-se a detectar embarcações de médio a grande porte tendo em vista sua aplicação em imagens de resolução espacial de 5 m. Conforme BRASIL-3 (2011), embarcações de médio porte são aquelas que possuem comprimento maior que cinco e menor que 24 metros e as de grande porte têm comprimento a partir de 24 metros ou arqueação

bruta (AB) maior que 100. A arqueação bruta é um valor adimensional calculado com base no volume dos espaços internos do navio (BRASIL-3, 2011).



FIG. 4.1: Área teste. Fonte: MMA

Neste capítulo são comparados os resultados obtidos com o uso das características de contexto, formato, textura e dados de contorno dos segmentos (situação 1) com os resultados obtidos com o uso apenas das características de contexto, formato e textura (situação 2) e com os resultados gerados pelo método SVM (situação 3) com amostras para as classes embarcação, mar e outros, utilizando os dados das cinco bandas da imagem e a análise da classificação por segmento descrita na seção 3.6.3, conforme mostra a FIG. 4.2.

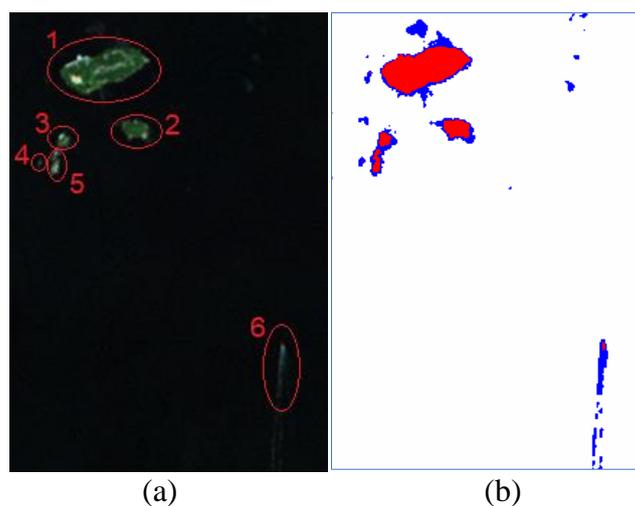


FIG. 4.2: Classificação pelo método SVM. Fonte: RapidEye modificada.

A FIG. 4.2 (b) mostra uma classificação pelo método SVM, onde os pixels em azul representam a classe embarcação, os de cor vermelha representam a classe outros e os de cor branca representam a classe mar. Aplicando-se a análise por segmento, os segmentos identificados em (a) pelos números 1, 2, 3 e 5 serão classificados como *outro* (ilha, continente, ponte, etc), os segmentos 4 e 6 serão classificados como *embarcação* e os pixels na cor branca (fundo) serão classificados como *mar*.

4.1.1 FERRAMENTAS E MATERIAIS

Para a visualização e coleta de amostras foi utilizado o *software* de análise de imagens ENVI (*Environment for Visualizing Images*). Os processos de detecção de bordas, geração de código de cadeia, comparação de contorno, geração da matriz de descritores, normalização da matriz de descritores e análise da classificação foram implementados no ambiente de desenvolvimento IDL (*Interface Description Language*), que faz parte do pacote de software ENVI. Para a rede neural artificial foi utilizado o *Neural Network Toolbox* do MATLAB (*Matrix Laboratory*) R2017b, licença estudante.

O método proposto foi implementado em um microcomputador com processador Core i7, 2.30 GHz, 8GB de memória RAM, sistema operacional Windows 10 Pro, 64 bits.

Foram utilizados 32 recortes de imagens RapidEye, geradas no primeiro semestre de 2011 e 2013 e no segundo semestre de 2014, com dimensões variando entre 200×200 a 400×400 pixels.

4.2 CONFIGURAÇÃO DA RNA

Foram utilizadas duas redes:

a) A primeira com oito entradas e duas camadas ocultas com, respectivamente, oito e dois neurônios para a aplicação do método na situação 1, onde são utilizados os oito descritores; e

b) A segunda com seis entradas e duas camadas ocultas com, respectivamente, seis e dois neurônios para a aplicação do método na situação 2, onde são utilizados os seis descritores relacionados com as características de contexto, textura e formato.

Embora a classificação seja embarcação ou não-embarcação, as redes foram configuradas com três saídas (embarcação, mar e outros), pois dessa forma foi possível fornecer um

quantitativo de amostras de treinamento mais balanceado, dividindo os exemplos de não-embarcação nas classes mar e outros.

As redes usaram função de ativação do tipo sigmoide e tiveram o conjunto de dados dividido em 70% para treinamento, 15% para validação e 15% para teste com seleção aleatória.

4.3 DADOS DE TREINAMENTO DA RNA

Os dados para treinamento, teste e validação da RNA foram obtidos de exemplos de embarcações, mar, ilha, continente e ponte. Foram utilizadas 875 amostras de 134 embarcações, 593 amostras de mar e 702 de outros (ilhas, ponte, continente), totalizando 2.170 dados de amostras, obtidos em 16 imagens de 400×400 pixels, utilizando o software ENVI.

A FIG. 4.3 mostra uma das imagens da qual foram colhidos exemplos de embarcação, mar, ilha e continente, destacados nas cores azul, branca, vermelha e lilás respectivamente.

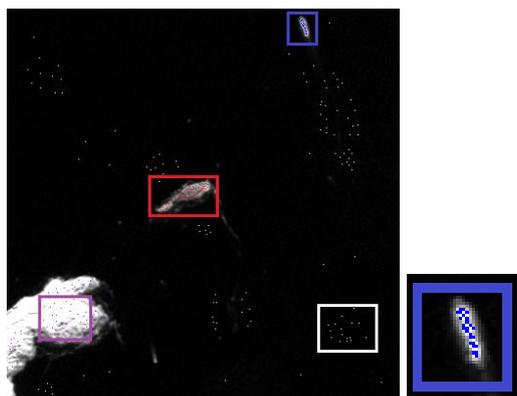


FIG. 4.3: Amostras. Fonte: RapidEye modificada.

4.4 DETECÇÃO DE BORDAS

A banda 5 (infravermelho próximo) foi utilizada nas detecções de bordas de todas as imagens, tendo em vista o melhor resultado apresentado em relação aos testes realizados utilizando as demais bandas isoladamente e à composição das bandas 321 (RGB).

No processo de detecção de bordas, foram realizados processamentos de fechamento com elemento estruturante $[[1, 1, 1], [1, 1, 1], [1, 1, 1]]$ e processamentos de preenchimento de região com elemento estruturante $[[0, 1, 0], [1, 1, 1], [0, 1, 0]]$.

4.5 CORREÇÃO DE PIXEL DE RUÍDO

Antes de gerar o código de cadeia, o método realizou correções de 1 pixel na imagem binária resultante do processo de detecção de bordas, conforme mostra a FIG. 4.4, utilizando quatro máscaras aplicadas a uma vizinhança 3×3, discriminadas a seguir:

- a) $[[1, 1, 1], [1, 7, 1], [7, 7, 7]]$ igual a 28 e $(y-2, x+1)$ igual a um ou $(y+2, x+1)$ igual a um para a suavização de pixel na horizontal superior do segmento.
- b) $[[7, 7, 7], [1, 7, 1], [1, 1, 1]]$ igual a 28 e $(y-2, x-1)$ igual a um ou $(y+2, x-1)$ igual a um para a suavização de pixel na horizontal inferior do segmento.

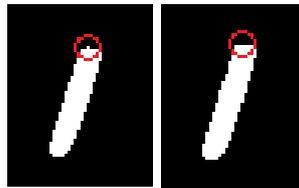


FIG. 4.4: Correção de 1 pixel

- c) $[[1, 1, 7], [1, 7, 7], [1, 1, 7]]$ igual a 28 e $(y+1, x-2)$ igual a um ou $(y+1, x+2)$ igual a um para a suavização de pixel na lateral direita do segmento.
- d) $[[7, 1, 1], [7, 7, 1], [7, 1, 1]]$ igual a 28 e $(y-1, x-2)$ igual a um ou $(y-1, x+2)$ igual a um para a suavização de pixel na lateral esquerda do segmento.

4.6 COMPARAÇÃO DE FORMATO DE CONTORNO

Para a comparação de contorno, a distância mínima utilizada foi de dois pixels e os formatos válidos, possíveis de ocorrerem na proa ou popa de uma embarcação, compreenderam formatos em 'V' com ângulos variando de 55 a 90°, conforme discriminado:

- a) Formato 1 = [70.0, distância mínima].
- b) Formato 2 = [[135.0, distância mínima], [90.0, distância mínima], [135.0, distância mínima]].
- c) Formato 3 = [55.0, distância mínima].
- d) Formato 4 = [90.0, distância mínima].

Os Padrões de comparação inválidos, que não representam as partes de interesse da embarcação, corresponderam a desvios com ângulos agudos menores de 40° e ângulos obtusos maiores de 100°, conforme discriminado:

- a) Formato 5 = [27.3, distância mínima].

b) Formato 6 = [115.3, distância mínima].

c) Formato 7 = [160.0, distância mínima].

4.7 CONFIRMAÇÃO VISUAL DO ALVO

A verdade presumida para a afirmação de que os alvos detectados nas imagens representam embarcações foi qualitativa e baseou-se em:

a) Características de cor e formato das embarcações, compatíveis com a resolução de 5 metros. A FIG. 4.5 mostra os formatos mais comuns das embarcações captadas nas imagens. Nesta imagem, percebe-se a perda de detalhe de formato nas embarcações de menor porte;

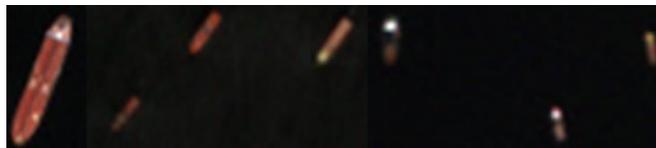


FIG. 4.5: Características de cor e formato

b) Resposta espectral de embarcações em movimento. A agitação do mar pelo deslocamento da embarcação gera respostas espectrais mais altas que permitem perceber embarcações de menor porte. Na FIG. 4.6, é possível visualizar o destaque da embarcação em cor vermelha seguida pela agitação da água do mar em cor clara, que é uma característica da alta resposta espectral; e

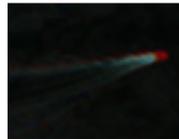


FIG. 4.6: Embarcação em movimento

c) Embarcações de grande porte. Neste caso, as embarcações podem ser identificadas visualmente com facilidade, conforme mostra a FIG. 4.7. O Rio de Janeiro é uma cidade turística e o seu porto recebe navios de cruzeiro durante todo o ano, com maior concentração nos meses de dezembro a fevereiro, devido aos eventos festivos de final de ano e o carnaval, períodos nos quais a movimentação de turistas é maior.

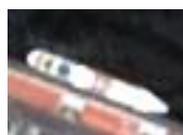


FIG. 4.7: Embarcação de grande porte

4.8 CLASSIFICAÇÃO DE IMAGENS

Dezesseis imagens com dimensões variando entre 200×200 a 400×400 pixels foram classificadas e os resultados para cada uma das três situações previstas anteriormente na seção 4.1 foram exibidos com as embarcações detectadas marcadas em magenta sobre as imagens originais, as embarcações não detectadas ou falsos positivos foram marcados por retângulos vermelhos. Na primeira imagem, exibida na FIG. 4.8 (a), existem 26 embarcações, que estão destacadas em (b).

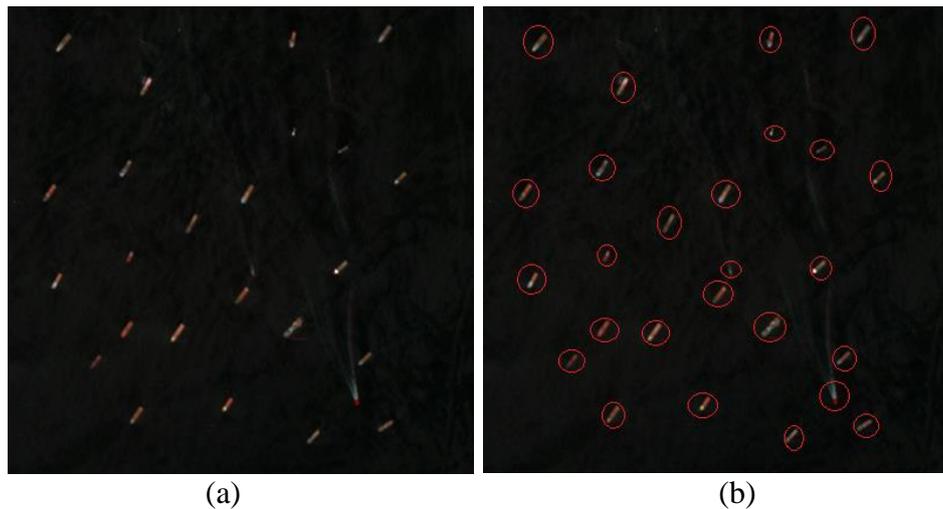


FIG. 4.8: (a) primeira imagem. Fonte: RapidEye. (b) embarcações destacadas

Os resultados das classificações da primeira imagem são mostrados na FIG. 4.9. Nas situações 1 (8 descritores) e 2 (6 descritores), exibidas respectivamente em (a) e (b), as respostas foram iguais. Na situação 3 (SVM), exibida em (c) percebe-se que a embarcação marcada pelo retângulo vermelho, não foi detectada.

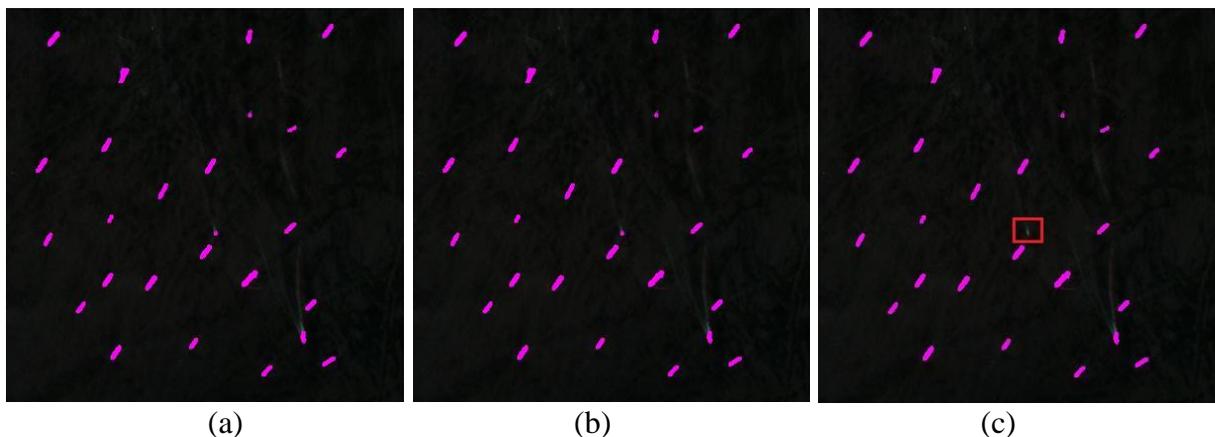


FIG. 4.9: Classificação da primeira imagem: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da primeira imagem nas três situações previstas são apresentadas nas TAB. 4.1 e TAB. 4.2.

TAB. 4.1: Matriz de confusão da primeira imagem para as situações 1 e 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	26	0
	Não-embarcação	0	0

TAB. 4.2: Matriz de confusão da primeira imagem para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	25	0
	Não-embarcação	1	0

Na segunda imagem, exibida na FIG. 4.10 (a), existem 8 segmentos, sendo que 7 são embarcações e estão destacadas em (b).

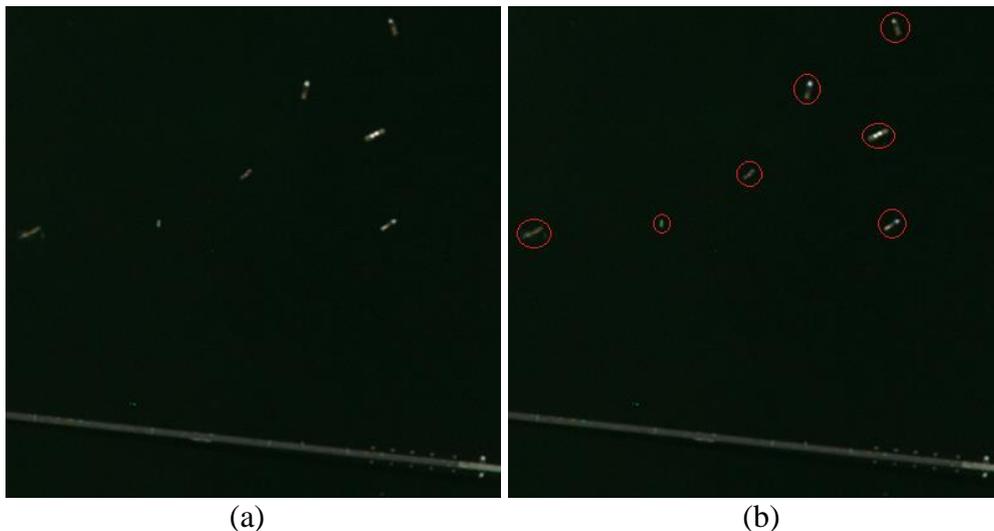


FIG. 4.10: (a) segunda imagem. Fonte: RapidEye. (b) embarcações destacadas

Os resultados das classificações da segunda imagem são mostrados na FIG. 4.11. Nas situações 1 (8 descritores) e 2 (6 descritores), exibidas respectivamente em (a) e (b), as respostas foram iguais. Na situação 3 (SVM), exibida em (c), as embarcações marcadas por retângulos vermelhos não foram detectadas.

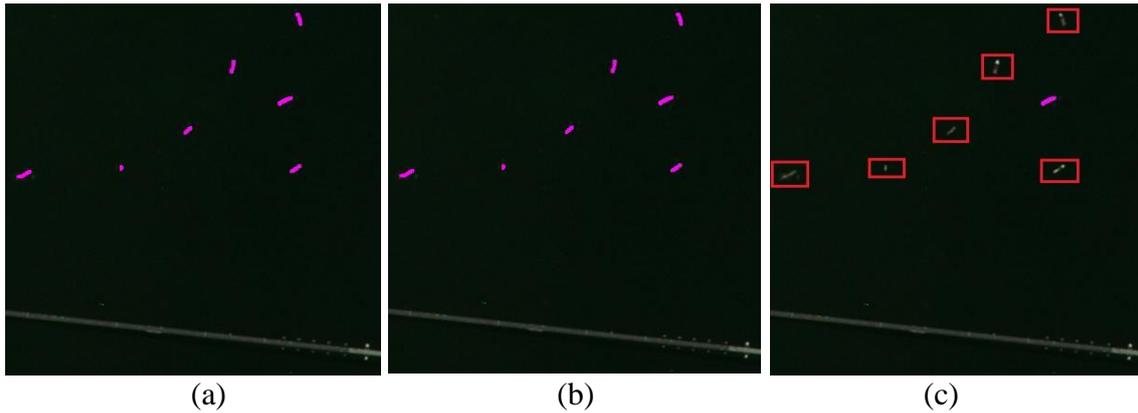


FIG. 4.11: Classificação da imagem 2: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da segunda imagem nas três situações previstas são apresentadas nas TAB. 4.3 e TAB. 4.4.

TAB. 4.3: Matriz de confusão da segunda imagem para as situações 1 e 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	7	0
	Não-embarcação	0	1

TAB. 4.4: Matriz de confusão da segunda imagem para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	1	0
	Não-embarcação	6	1

Na terceira imagem classificada, exibida na FIG. 4.12 (a), existem seis segmentos dos quais apenas um é embarcação, conforme exibido em (b).

As classificações da terceira imagem são mostradas na FIG. 4.14. Na situação 1 (a), percebe-se que a embarcação foi detectada, mas houve um falso positivo marcado pelo retângulo vermelho. Na situação 2 (b), a embarcação foi detectada e houve 3 falsos positivos marcados pelos retângulos vermelhos. Na classificação pelo SVM (c), a embarcação foi detectada e houve 1 falso positivo marcado pelo retângulo vermelho.

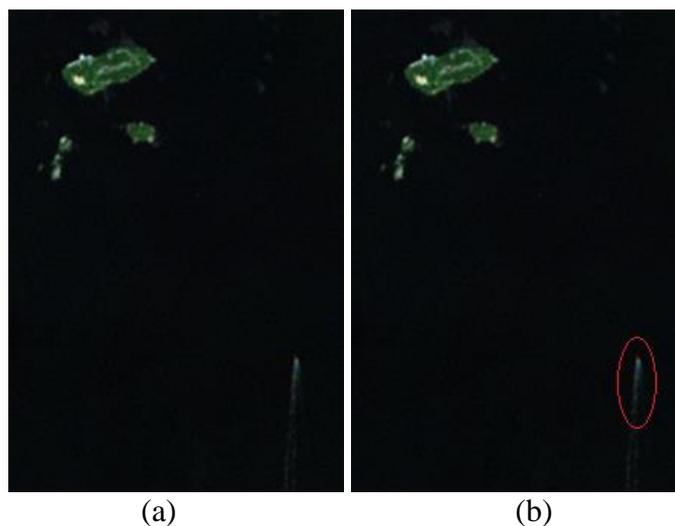


FIG. 4.12: (a) terceira imagem. Fonte: RapidEye. (b) segmentos

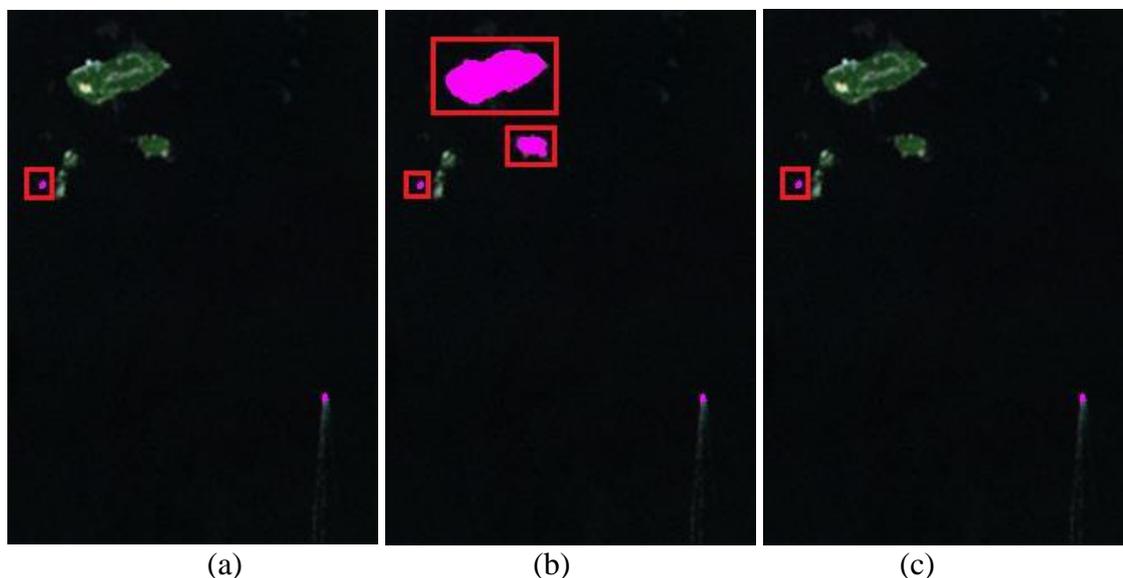


FIG. 4.13: Classificação da imagem 3: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da terceira imagem nas três situações previstas são apresentadas nas TAB. 4.5 e TAB. 4.6.

TAB. 4.5: Matriz de confusão da terceira imagem para as situações 1 e 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	1	1
	Não-embarcação	0	4

TAB. 4.6: Matriz de confusão da terceira imagem para a situação 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	1	3
	Não-embarcação	0	2

Na quarta imagem, exibida na FIG. 4.14 (a), existem duas embarcações, conforme destaques da figura (b).

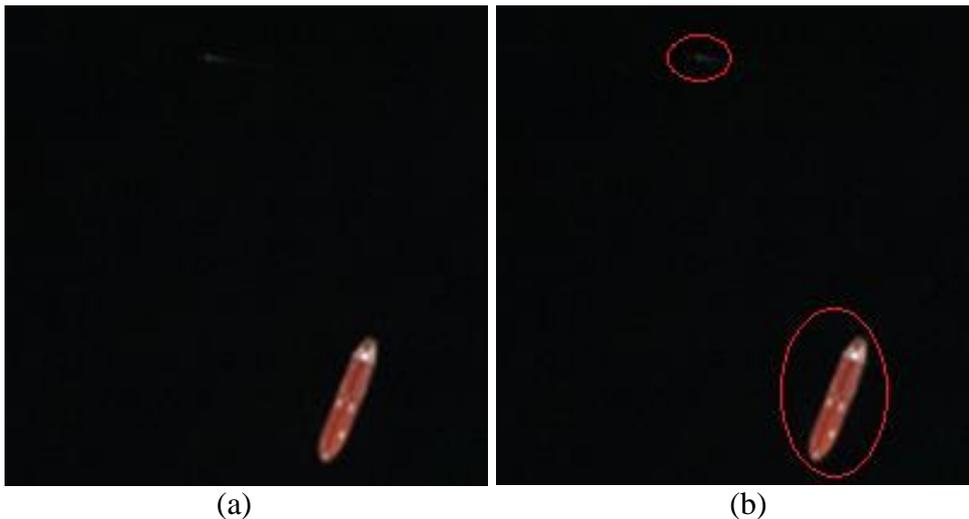


FIG. 4.14: (a) quarta imagem. Fonte: RapidEye. (b) segmentos

As classificações da quarta imagem são mostradas na FIG. 4.16. Na situação 1 (a), as duas embarcações foram detectadas. Tanto na situação 2 (b) quanto na situação 3 (c), a embarcação maior foi detectada, mas a menor, marcada pelo retângulo vermelho, não foi detectada.

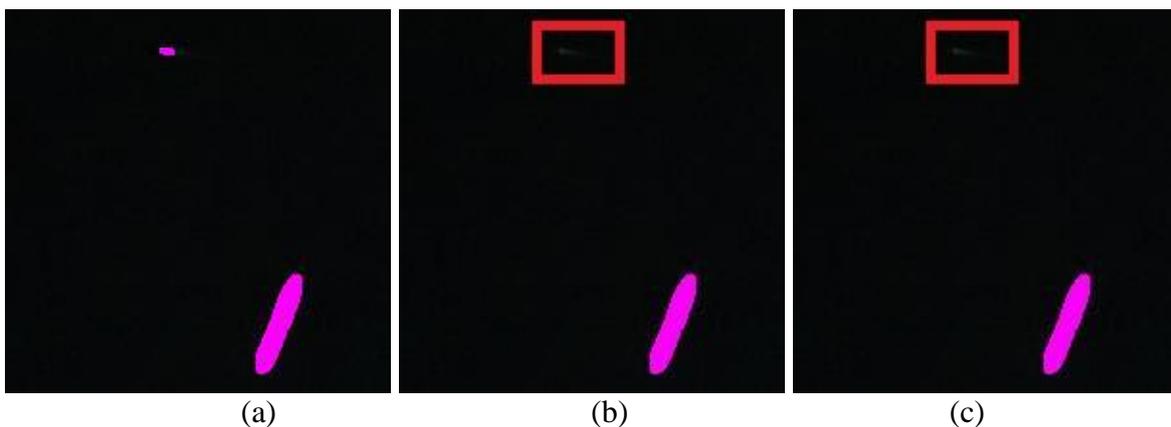


FIG. 4.15: Classificação da quarta imagem: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da quarta imagem nas três situações previstas são apresentadas nas TAB. 4.7 e TAB. 4.8.

TAB. 4.7: Matriz de confusão da quarta imagem para a situação 1.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	2	0
	Não-embarcação	0	0

TAB. 4.8: Matriz de confusão da quarta imagem para as situações 2 e 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	1	0
	Não-embarcação	1	0

Na quinta imagem classificada, exibida na FIG. 4.16 (a), existem quatro embarcações, que estão marcadas na figura (b).

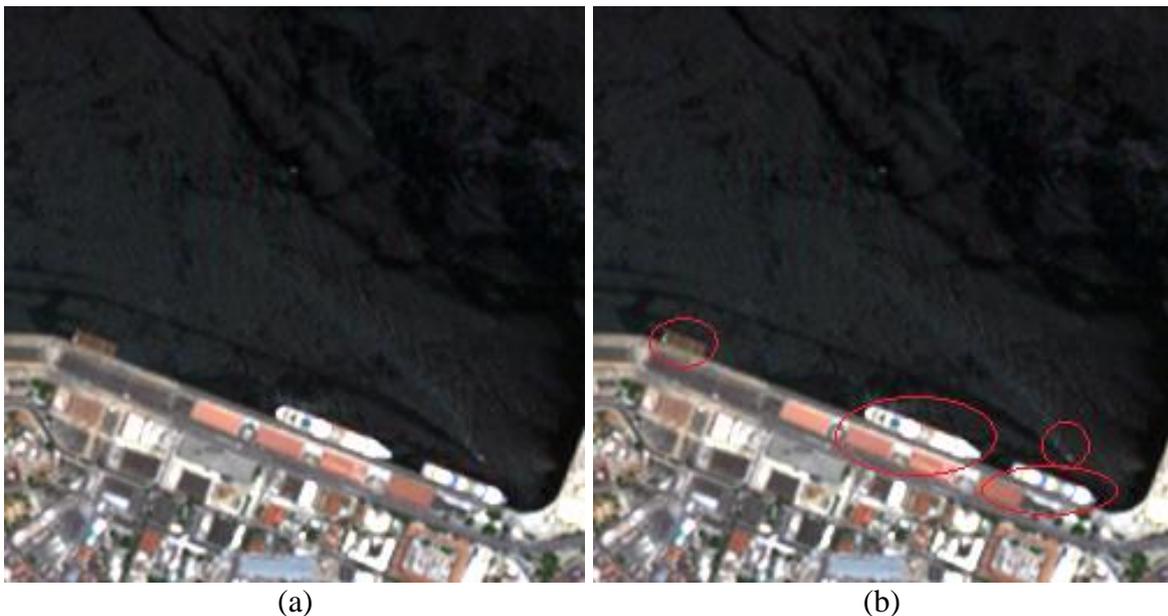


FIG. 4.16: (a) quinta imagem. Fonte: RapidEye. (b) segmentos

As classificações da quinta imagem são mostradas na FIG. 4.17. As quatro embarcações foram detectadas na situação 1, representada em (a), e nas situações 2 e 3, representadas em (b) e (c) respectivamente, as embarcações marcadas pelos retângulos vermelhos não foram detectadas.

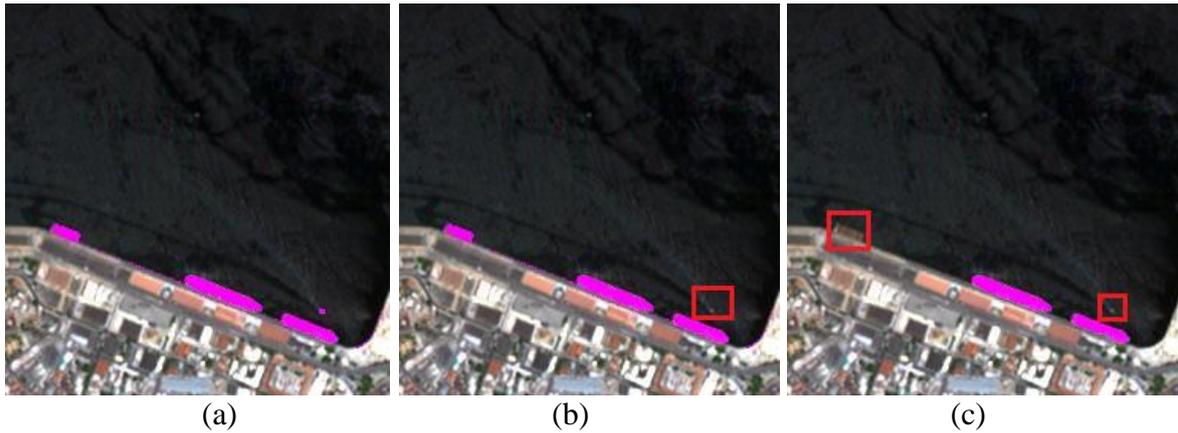


FIG. 4.17: Classificação da quinta imagem: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da quinta imagem nas três situações previstas são apresentadas nas TAB. 4.9, TAB. 4.10 e TAB. 4.11.

TAB. 4.9: Matriz de confusão da quinta imagem para a situação 1.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	4	0
	Não-embarcação	0	1

TAB. 4.10: Matriz de confusão da quinta imagem para a situação 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	3	0
	Não-embarcação	1	1

TAB. 4.11: Matriz de confusão da quinta imagem para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	2	0
	Não-embarcação	2	1

Na sexta imagem, exibida na FIG. 4.18 (a), existem quatro embarcações, que estão destacadas na FIG. 4.18 (b).

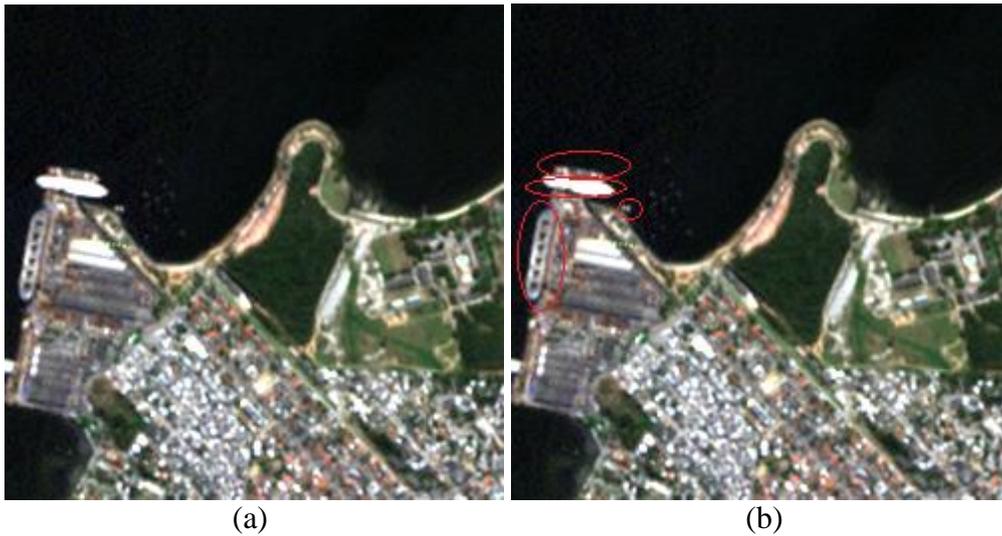


FIG. 4.18: (a) sexta imagem. Fonte: RapidEye. (b) segmentos

As classificações da sexta imagem são mostradas na FIG. 4.19. Percebe-se que nas 3 situações todas as embarcações foram detectadas.

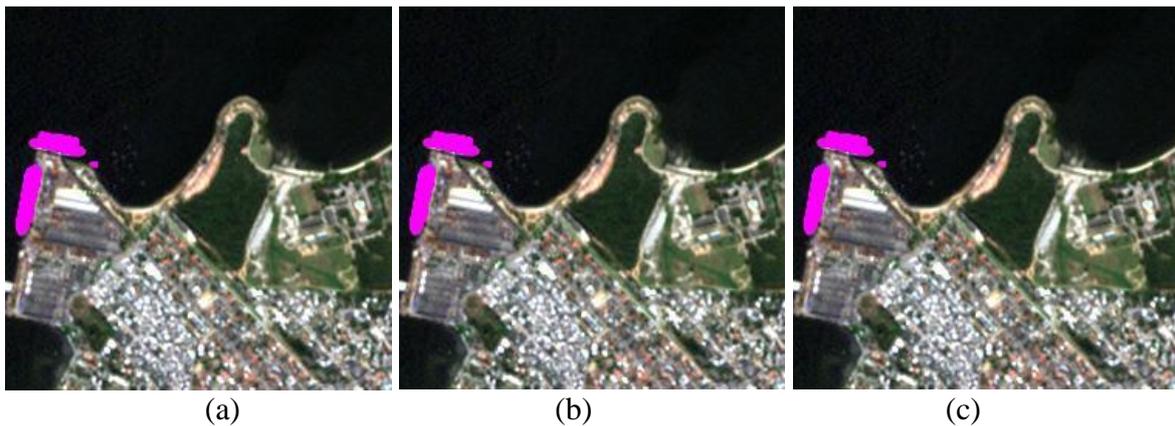


FIG. 4.19: Classificação da sexta imagem: (a) situação 1 (b) situação 2 (c) situação 3

A matriz de confusão das classificações da sexta imagem nas três situações previstas é apresentada na TAB. 4.12

TAB. 4.12: Matriz de confusão da sexta imagem para as situações 1, 2 e 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	4	0
	Não-embarcação	0	1

Na sétima imagem, exibida na FIG. 4.20 (a), existem 11 embarcações, que estão destacadas em (b).

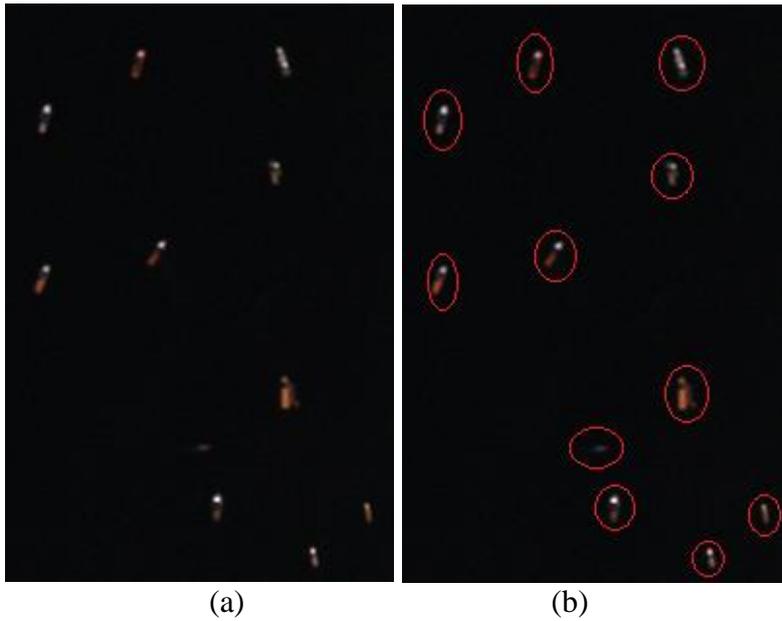


FIG. 4.20: (a) sétima imagem. Fonte: RapidEye. (b) segmentos

As classificações da sétima imagem são mostradas na FIG. 4.21. Nas situações 1 e 2, exibidas em (a) e (b) respectivamente, as respostas foram iguais. Na situação 3, exibida em (c), a embarcação marcada pelo retângulo vermelho não foi detectada.

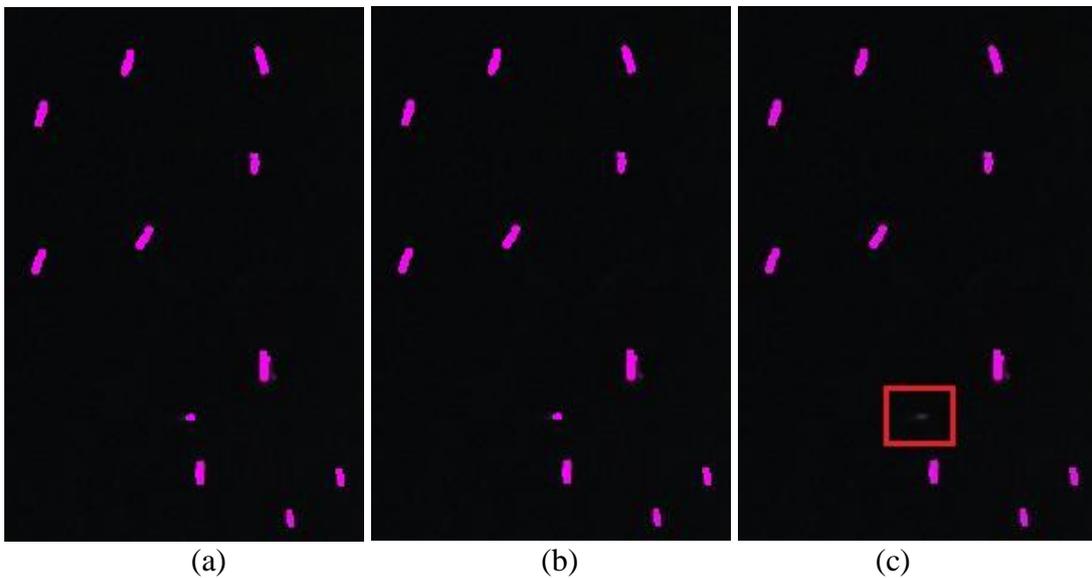


FIG. 4.21: Classificação da imagem 7: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da sétima imagem nas três situações previstas são apresentadas nas TAB. 4.31 e TAB. 4.32.

TAB. 4.13: Matriz de confusão da sétima imagem para as situações 1 e 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	11	0
	Não-embarcação	0	0

TAB. 4.14: Matriz de confusão da sétima imagem para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	10	0
	Não-embarcação	1	0

Na oitava imagem classificada, exibida na FIG. 4.22 (a), existem três embarcações, que estão marcadas em (b).

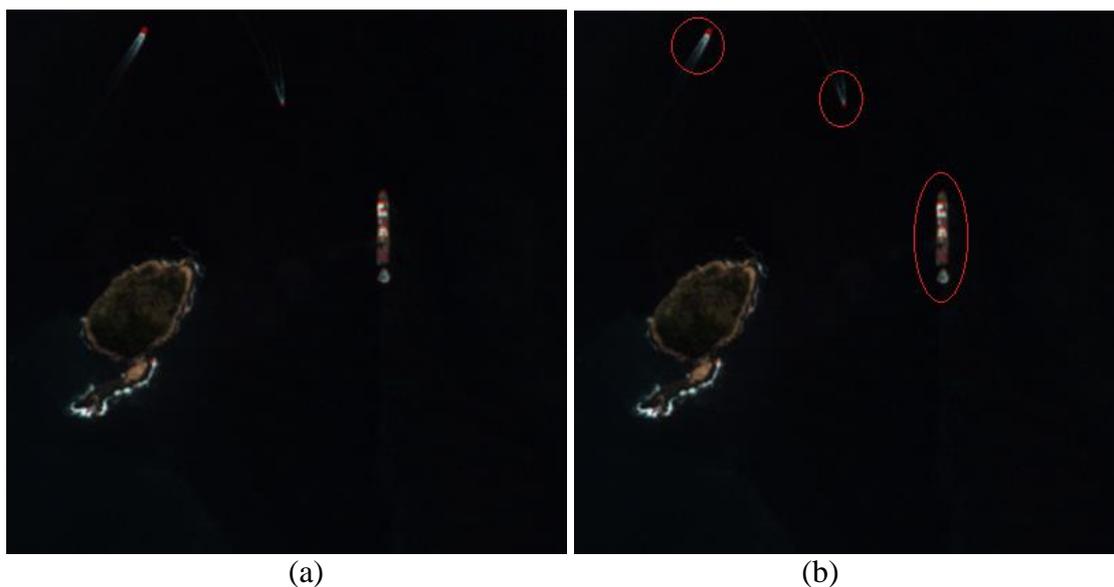


FIG. 4.22: (a) oitava imagem. Fonte: RapidEye. (b) segmentos

As classificações da oitava imagem são mostradas na FIG. 4.23. Nas situações 1 e 2, exibidas em (a) e (b) respectivamente, percebe-se que as três embarcações foram detectadas, mas houve um falso positivo destacado pelo retângulo vermelho. Na situação 3, exibida em (c), as três embarcações foram detectadas e não houve falso positivo.

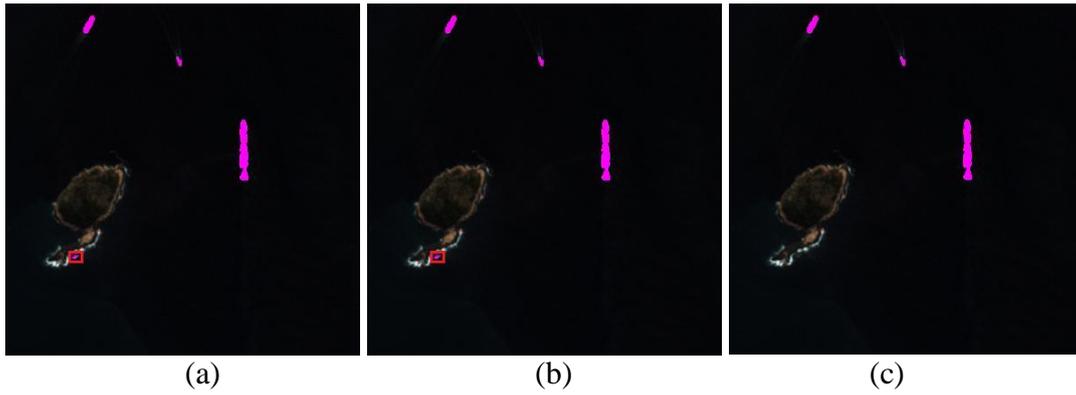


FIG. 4.23: Classificação da oitava imagem: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da oitava imagem nas três situações previstas são apresentadas nas TAB. 4.33 e TAB. 4.34.

TAB. 4.15: Matriz de confusão da oitava imagem para as situações 1 e 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	3	1
	Não-embarcação	0	1

TAB. 4.16: Matriz de confusão da oitava imagem para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	3	0
	Não-embarcação	0	2

Na nona imagem, exibida na FIG. 4.24 (a), existem 2 embarcações, que estão destacadas em (b).

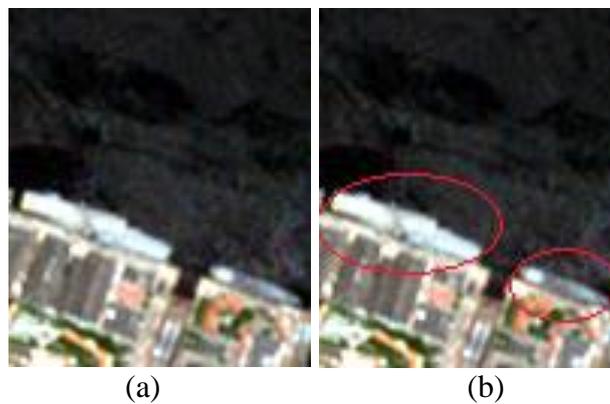


FIG. 4.24: (a) nona imagem. Fonte: RapidEye. (b) segmentos

As classificações da nona imagem são mostradas na FIG. 4.25. Nas três situações, as duas embarcações foram detectadas.

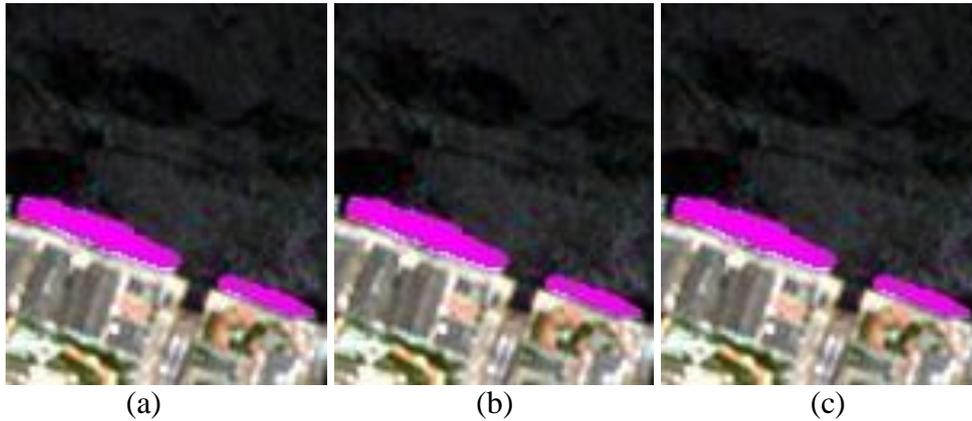


FIG. 4.25: Classificação da nona imagem: (a) situação 1 (b) situação 2 (c) situação 3

A matriz de confusão das classificações da nona imagem nas três situações previstas é apresentada na TAB. 4.35.

TAB. 4.17: Matriz de confusão da nona imagem para as situações 1, 2 e 3.

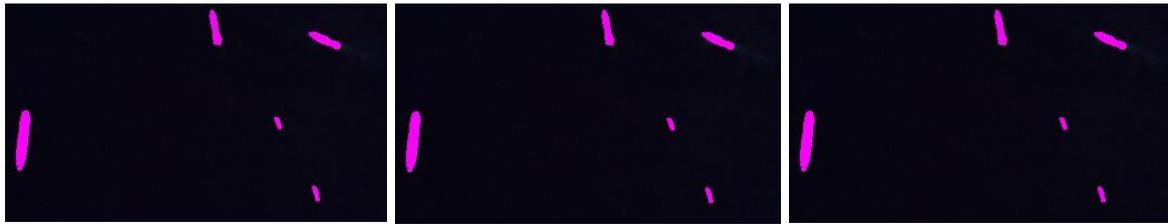
		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	2	0
	Não-embarcação	0	1

Na décima imagem, exibida na FIG. 4.26 (a), existem cinco embarcações, conforme mostra a FIG. 4.26 (b).



FIG. 4.26: (a) décima imagem. Fonte: RapidEye. (b) segmentos

As classificações da décima imagem são mostradas na FIG. 4.27. Nas três situações, as cinco embarcações foram detectadas.



(a) (b) (c)

FIG. 4.27: Classificação da décima imagem: (a) situação 1 (b) situação 2 (c) situação 3

A matriz de confusão das classificações da décima imagem nas três situações previstas é apresentada na TAB. 4.18.

TAB. 4.18: Matriz de confusão da nona imagem para as situações 1, 2 e 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	5	0
	Não-embarcação	0	0

Na imagem 11, exibida na FIG. 4.28 (a), existem três embarcações, conforme mostra a FIG. 4.28 (b).



(a) (b)

FIG. 4.28: (a) imagem 11. Fonte: RapidEye. (b) segmentos

As classificações da imagem 11 são mostradas na FIG. 4.29. As três embarcações foram detectadas na situação 1, exibida em (a). Na situação 2, exibida em (b), uma embarcação não foi detectada e na situação 3, exibida em (c), duas embarcações não foram detectadas.



(a) (b) (c)

FIG. 4.29: Classificação da imagem 11: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da imagem 11 nas três situações previstas são apresentadas nas TAB. 4.19, TAB. 4.20 e TAB. 4.21.

TAB. 4.19: Matriz de confusão da imagem 11 para a situação 1.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	3	0
	Não-embarcação	0	1

TAB. 4.20: Matriz de confusão da imagem 11 para a situação 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	2	0
	Não-embarcação	1	1

TAB. 4.21: Matriz de confusão da imagem 11 para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	1	0
	Não-embarcação	2	1

Na imagem 12, exibida na FIG. 4.30 (a), existem seis segmentos, dos quais quatro são embarcações e estão destacadas na FIG. 4.30 (b).

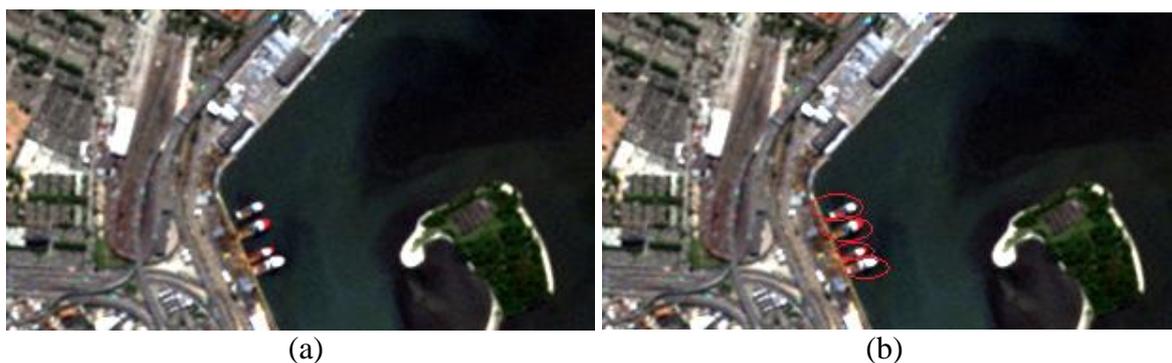


FIG. 4.30: (a) imagem 12. Fonte: RapidEye. (b) segmentos

As classificações da imagem 12 são mostradas na FIG. 4.31. Nas situações 1 e 2, exibidas em (a) e (b) respectivamente, as respostas foram iguais. Na situação 3, exibida em (c), apenas uma embarcação foi detectada.

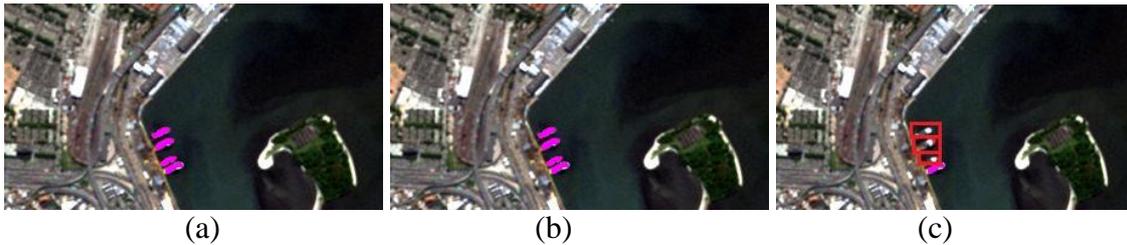


FIG. 4.31: Classificação da imagem 12: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da imagem 12 nas três situações previstas são apresentadas nas TAB. 4.22 e TAB. 4.23.

TAB. 4.22: Matriz de confusão da imagem 12 para as situações 1 e 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	4	0
	Não-embarcação	0	2

TAB. 4.23: Matriz de confusão da imagem 12 para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	1	0
	Não-embarcação	3	2

Na imagem 13, exibida na FIG. 4.32 (a), existe apenas uma embarcação, conforme destaque na FIG. 4.32 (b).



FIG. 4.32: (a) imagem 13. Fonte: RapidEye. (b) segmentos

As classificações da imagem 13 são mostradas na FIG. 4.33. Nas situações 1 e 2, exibidas em (a) e (b) respectivamente, as respostas foram iguais, sendo que a embarcação foi detectada,

mas houve 1 falso positivo. Na situação 3, exibida em (c), não houve falso positivo, mas a embarcação não foi detectada.

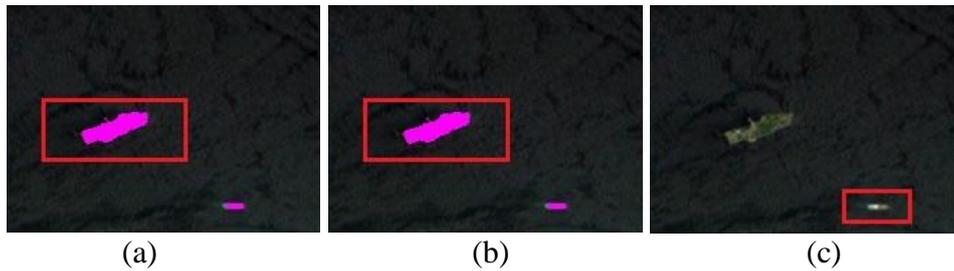


FIG. 4.33: Classificação da imagem 13: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da imagem 13 nas três situações previstas são apresentadas nas TAB. 4.24 e TAB. 4.25.

TAB. 4.24: Matriz de confusão da imagem 13 para as situações 1 e 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	1	1
	Não-embarcação	0	0

TAB. 4.25: Matriz de confusão da imagem 13 para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	0	0
	Não-embarcação	1	1

Na imagem 14, exibida na FIG. 4.34 (a), existem duas embarcações, conforme mostram os destaques na FIG. 4.34 (b).

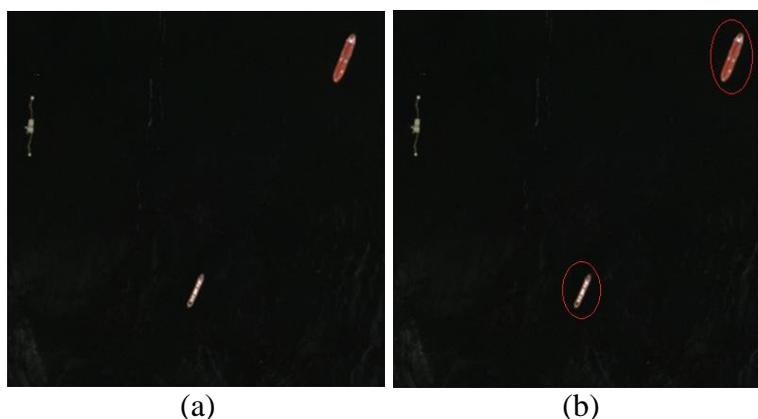


FIG. 4.34: (a) imagem 14. Fonte: RapidEye. (b) segmentos

As classificações da imagem 14 são mostradas na FIG. 4.35. Nas situações 1, 2 e 3, exibidas respectivamente em (a), (b) e (c), as respostas foram iguais, sendo que as duas embarcações foram detectadas.

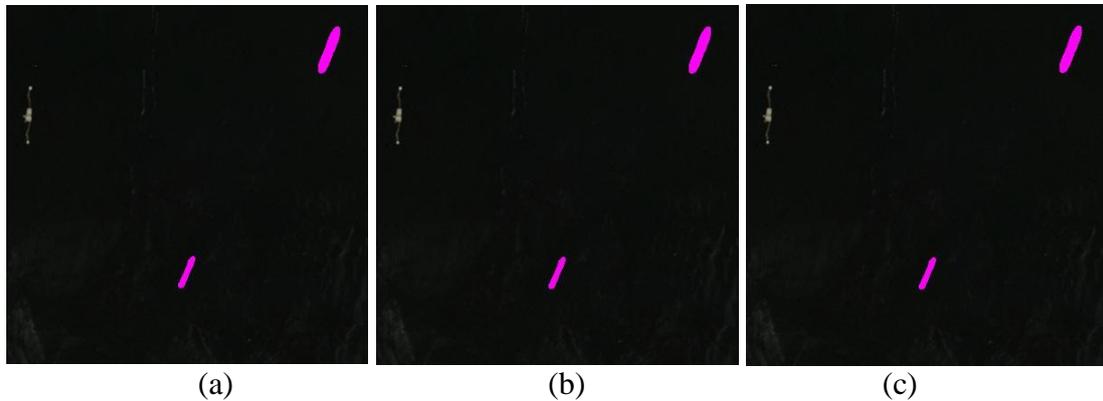


FIG. 4.35: Classificação da imagem 14: (a) situação 1 (b) situação 2 (c) situação 3

A matriz de confusão das classificações da imagem 14 nas três situações previstas é apresentada na TAB. 4.26.

TAB. 4.26: Matriz de confusão da imagem 14 para as situações 1, 2 e 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	2	0
	Não-embarcação	0	1

Na imagem 15, exibida na FIG. 4.36 (a), existem 9 segmentos, dos quais 8 são embarcações, conforme destaques na FIG. 4.36 (b).

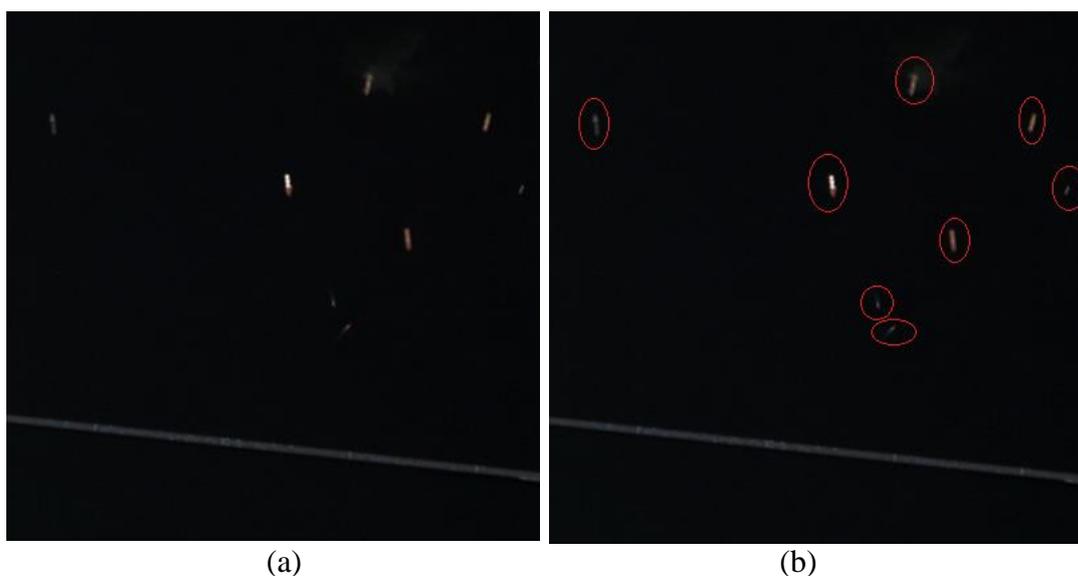


FIG. 4.36: (a) imagem 15. Fonte: RapidEye. (b) segmentos

As classificações da imagem 15 são mostradas na FIG. 4.38. Nas situações 1 e 2, exibidas em (a) e (b) respectivamente, os resultados foram iguais, sendo que as 8 embarcações foram detectadas. Na situação 3, mostrada em (c), apenas três embarcações foram detectadas.

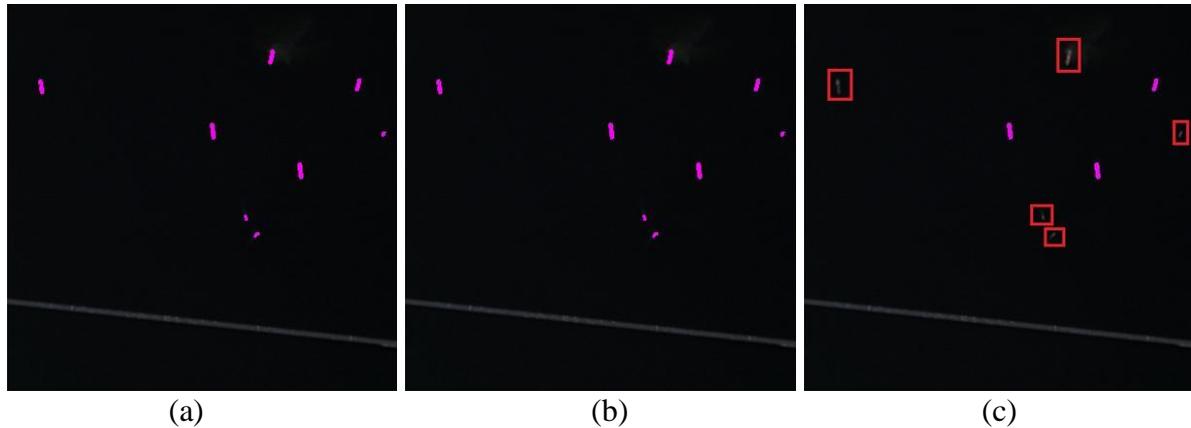


FIG. 4.37: Classificação da imagem 15: (a) situação 1 (b) situação 2 (c) situação 3

As matrizes de confusão das classificações da imagem 15 nas três situações previstas são apresentadas nas TAB. 4.27 e TAB. 4.28.

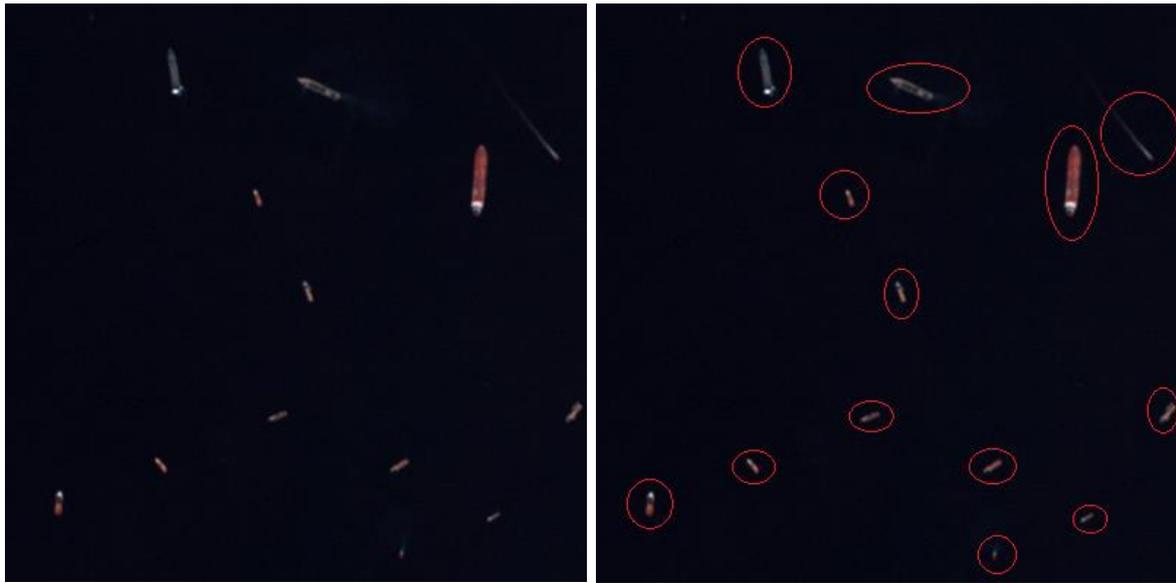
TAB. 4.27: Matriz de confusão da imagem 15 para as situações 1 e 2.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Resultado	Classe Embarcação	8	0
	Classe Não-embarcação	0	1

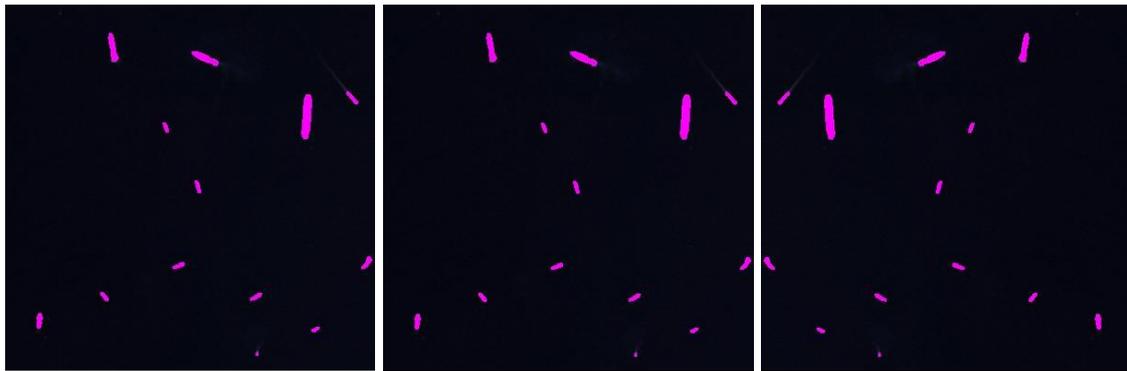
TAB. 4.28: Matriz de confusão da imagem 15 para a situação 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Resultado	Classe Embarcação	3	0
	Classe Não-embarcação	5	1

Na imagem 16, exibida na FIG. 4.38 (a), existem 13 embarcações, conforme mostra a FIG. 4.38 (b). As classificações da imagem 16 são mostradas na FIG. 4.39. Nas situações 1, 2 e 3 exibidas em (a), (b) e (c) respectivamente, as respostas foram iguais, sendo que todas as embarcações foram detectadas.



(a) (b)
 FIG. 4.38: (a) imagem 16. Fonte: RapidEye. (b) segmentos



(a) (b) (c)
 FIG. 4.39: Classificação da imagem 16: (a) situação 1 (b) situação 2 (c) situação 3

A matriz de confusão das classificações da imagem 16 nas três situações previstas é apresentada na TAB. 4.29.

TAB. 4.29: Matriz de confusão da imagem 16 para as situações 1, 2 e 3.

		Classe Verdadeira	
		Embarcação	Não-Embarcação
Classe Resultado	Embarcação	13	0
	Não-embarcação	0	0

4.9 RESULTADOS

Os resultados foram obtidos a partir das matrizes de confusão, por meio do cálculo da precisão, abrangência e medida-F (com β igual a um) para a classe embarcação. Os resultados das detecções nas 16 imagens para a situação 1 é apresentado na TAB. 4.30.

TAB. 4.30: Resultados obtidos para a situação 1.

Imagem	Precisão (%)	Abrangência (%)	Medida-F₁ (%)
Imagem 1	100	100	100
Imagem 2	100	100	100
Imagem 3	50	100	66,67
Imagem 4	100	100	100
Imagem 5	100	100	100
Imagem 6	100	100	100
Imagem 7	100	100	100
Imagem 8	75	100	85,71
Imagem 9	100	100	100
Imagem 10	100	100	100
Imagem 11	100	100	100
Imagem 12	100	100	100
Imagem 13	50	100	66,67
Imagem 14	100	100	100
Imagem 15	100	100	100
Imagem 16	100	100	100
Média	92,19	100	94,94

A TAB. 4.31 apresenta os resultados das detecções nas 16 imagens para a situação 2.

TAB. 4.31: Resultados das imagens classificadas para a situação 2.

Imagem	Precisão (%)	Abrangência (%)	Medida-F₁ (%)
Imagem 1	100	100	100
Imagem 2	100	100	100
Imagem 3	25	100	40
Imagem 4	100	50	66,67
Imagem 5	100	75	85,71
Imagem 6	100	100	100
Imagem 7	100	100	100
Imagem 8	75	100	85,71
Imagem 9	100	100	100
Imagem 10	100	100	100
Imagem 11	100	66,67	80

Imagem	Precisão (%)	Abrangência (%)	Medida-F₁ (%)
Imagem 12	100	100	100
Imagem 13	50	100	66,67
Imagem 14	100	100	100
Imagem 15	100	100	100
Imagem 16	100	100	100
Média	90,63	93,23	89,05

A TAB. 4.32 apresenta os resultados das detecções nas 16 imagens para a situação 3.

TAB. 4.32: Resultados das imagens classificadas para a situação 3.

Imagem	Precisão (%)	Abrangência (%)	Medida-F₁ (%)
Imagem 1	100	96,15	98,04
Imagem 2	100	14,29	25
Imagem 3	50	100	66,67
Imagem 4	100	50	66,67
Imagem 5	100	50	66,67
Imagem 6	100	100	100
Imagem 7	100	90,91	95,24
Imagem 8	100	100	100
Imagem 9	100	100	100
Imagem 10	100	100	100
Imagem 11	100	33,33	50
Imagem 12	100	25	40
Imagem 13	0	0	0
Imagem 14	100	100	100
Imagem 15	100	37,5	54,55
Imagem 16	100	100	100
Média	90,63	68,57	72,68

4.10 AVALIAÇÃO

A TAB. 4.33 apresenta os percentuais da medida-F₁ para as situações 1, 2 e 3.

TAB. 4.33: Medida-F₁ das imagens classificadas

Imagem (%)	Situação 1 (%)	Situação 2 (%)	Situação 3 (%)
Imagem 1	100	100	98,04
Imagem 2	100	100	25
Imagem 3	66,67	40	66,67
Imagem 4	100	66,67	66,67
Imagem 5	100	85,71	66,67

Imagem (%)	Situação 1 (%)	Situação 2 (%)	Situação 3 (%)
Imagem 6	100	100	100
Imagem 7	100	100	95,24
Imagem 8	85,71	85,71	100
Imagem 9	100	100	100
Imagem 10	100	100	100
Imagem 11	100	80	50
Imagem 12	100	100	40
Imagem 13	66,67	66,67	0,00
Imagem 14	100	100	100
Imagem 15	100	100	54,55
Imagem 16	100	100	100
Média	94,94	89,05	72,68

Os resultados das detecções nas 16 imagens foram comparados pelo teste t para duas amostras, considerando médias aritméticas com variâncias diferentes. Foram comparados os resultados das situações 1 e 2, conforme mostra a TAB. 4.34. $P(T \leq t)$ uni-caudal e $P(T \leq t)$ bi-caudal foram maiores que 5%, logo não se pode afirmar que o método aplicado na situação 1 foi melhor que o método aplicado na situação 2.

TAB. 4.34: Teste- t para os resultados das situações 1 e 2

	Situação 1	Situação 2
Média	0,949404762	0,8904762
Variância	0,013444822	0,0314074
Observações	16	16
Hipótese da diferença de média	0	
gl	26	
$Stat t$	1,112996721	
$P(T \leq t)$ uni-caudal	0,137947288	
t crítico uni-caudal	1,70561792	
$P(T \leq t)$ bi-caudal	0,275894576	
t crítico bi-caudal	2,055529439	

Em seguida, foram comparados os resultados das situações 1 e 3, conforme mostra a TAB. 4.35. $P(T \leq t)$ uni-caudal e $P(T \leq t)$ bi-caudal foram menores que 5%, logo pode-se afirmar que o método aplicado na situação 1 foi melhor que o método SVM aplicado na situação 3.

TAB. 4.35: Teste-*t* para os resultados das situações 1 e 3

	Situação 1	Situação 3
Média	0,942460317	0,726764228
Variância	0,013466868	0,10137149
Observações	16	16
Hipótese da diferença de média	0	
<i>gl</i>	19	
<i>Stat t</i>	2,628224307	
$P(T \leq t)$ uni-caudal	0,0082779	
<i>t</i> crítico uni-caudal	1,729132812	
$P(T \leq t)$ bi-caudal	0,016555799	
<i>t</i> crítico bi-caudal	2,093024054	

O método aplicado no estudo de caso com imagens de resolução espacial de 5 metros, utilizando apenas a banda 5 (infravermelho próximo), conforme a situação 1, onde foram utilizados os oito descritores, características contextuais (espectrais, de textura e de formato) e dados de comparação de contorno, obteve precisão média de 92,19%, abrangência média de 100% e medida- F_1 média de 94,94%. A abrangência média de 100% indica que o método detectou todas as embarcações presentes nas 16 imagens. A precisão média de 92,19% indica que houve falsos positivos na detecção de embarcações. Esses falsos positivos foram causados por pequenas ilhas que, na resolução espacial de 5 metros, apresentaram formato similar ao esperado para as embarcações. Portanto, não foi possível diferenciá-las.

O método aplicado em imagens de resolução espacial de 5 metros, utilizando apenas a banda 5 da imagem, conforme a situação 2, onde foram utilizados seis descritores, características contextuais (espectrais, de textura e de formato), obteve precisão média de 90,63%, abrangência média de 93,23% e medida- F_1 média de 89,05%. A abrangência média de 93,23% indica que, sem os dados de comparação de contorno, não foi possível detectar todas as embarcações nas 16 imagens. A precisão média de 90,63% indica que, sem os dados de comparação de contorno, houve maior número de falsos positivos, que foram causados pelas pequenas ilhas que causaram falsos positivos na situação 1 e por ilhas maiores.

O SVM aplicado em imagens de resolução espacial de 5 metros, conforme a situação 3 (sobre as 5 bandas das imagens e com a análise de resultado descrita na seção 3.6.3) obteve precisão média de 90,63%, abrangência média de 68,57% e medida- F_1 de 72,68%. A abrangência média de 68,57% em relação às abrangências do método na situação 1 (100%) e na situação 2 (93,23%) foi significativamente menor.

Na comparação entre o método aplicado na situação 1 e o SVM (situação 3), o resultado do teste t foi menor que 5%, permitindo afirmar que o método proposto nesta dissertação foi melhor. Na comparação entre o método aplicado na situação 1 e o método aplicado na situação 2, o resultado do teste t foi maior que 5%, não permitindo afirmar que o método na situação 1 foi melhor que na situação 2, i.e. a análise com teste t não permite afirmar que o uso dos dados de comparação tenha gerado melhor resultado no estudo de caso com imagens de resolução espacial de 5 metros.

Quanto maior for a quantidade de pixels do contorno mais preciso será o formato da embarcação e menor será a influência dos pixels de vizinhança, permitindo uma melhor caracterização do problema. Em resolução de 5 metros, uma embarcação de médio porte, com largura a partir de 8 metros, possui poucos pixels de contorno em sua proa e popa. Por isso, em imagens de alta resolução espacial, onde a quantidade de pixels é muito maior e os contornos possuem maior riqueza de detalhe, é possível que o desempenho do método desta dissertação seja superior.

Percebe-se que o método proposto nesta dissertação e o SVM discordaram em seus resultados. Essa discordância pode representar uma sinalização para a necessidade de confirmar as detecções a fim de realizar a eliminação dos falsos positivos ocorridos no método. Além disso, considera-se válida a criação de um sistema multiclassificador, como o Comitê de Classificadores, que é formado por um conjunto de classificadores base, organizados paralelamente, de forma a recebem as entradas e produzirem as saídas que serão processadas por um método de combinação, cujo resultado é melhor que os resultados obtidos isoladamente em cada classificador (KUNCHEVA, 2004).

5. CONCLUSÃO

O método proposto nesta dissertação realiza a detecção de embarcações em imagens de sensores remotos ópticos utilizando características contextuais (espectrais, de textura e de formato) e comparação de contorno, por meio do cálculo da distância entre funções de desvio. Aplica filtro Canny, filtros de limiarização, fechamento e preenchimento de região para realizar a detecção de bordas nas imagens. Para os segmentos encontrados nas imagens, gera o código de cadeia e a função de desvio que é utilizada para a comparação dos contornos das extremidades dos segmentos, com os valores de referência definidos para proa e popa. A classificação dos descritores dos segmentos das imagens é realizada por rede neural artificial MLP com *backpropagation*. Pelo fato do método basear-se nos segmentos encontrados na imagem, o seu resultado depende diretamente da qualidade da detecção de bordas realizada.

No estudo de caso, o método é aplicado em duas situações, a primeira utiliza os oito descritores definidos no método, formados pelos dados contextuais e os dados de comparação de contorno, e a segunda utiliza seis descritores, formados apenas pelos dados contextuais. Na terceira situação apresentada é utilizado o SVM com a análise da classificação por segmento.

O método aplicado na situação 1 obteve precisão média de 92,19%, abrangência média de 100% e medida- F_1 de 94,94%, o que indica que todas as embarcações presentes nas 16 imagens foram detectadas, que houve falsos positivos na detecção, causados por pequenas ilhas que, na resolução espacial de 5 metros apresentaram formato similar ao das embarcações.

O método aplicado na situação 2 obteve precisão média de 90,63%, abrangência média de 93,23% e medida- F_1 de 89,05%, o que indica que sem os dados de comparação de contorno, não foi possível detectar todas as embarcações nas 16 imagens e houve maior número de falsos positivos, causados por pequenas ilhas e por ilhas maiores.

O SVM aplicado na situação 3 obteve precisão média de 90,63%, abrangência média de 68,57% e medida- F_1 de 72,68%. A abrangência média foi significativamente menor que a do método na situação 1 e na situação 2. Na comparação do método aplicado na situação 1 e o SVM na situação 3, o resultado do teste t foi menor que 5%, permitindo afirmar que, nas condições testadas, o método foi melhor que o SVM. O resultado do teste t para a comparação entre o método aplicado na situação 1 e na situação 2 foi maior que 5%, não permitindo afirmar que o uso dos dados de comparação tenha gerado melhor resultado no estudo de caso com imagens de resolução espacial de 5 metros.

Tendo em vista que no estudo de caso apresentado as imagens utilizadas possuem resolução espacial de 5 metros, o método detectou embarcações de médio a grande porte, inclusive em situação de embarcações juntas e/ou atracadas ao cais.

Em imagens com resolução espacial de 5 metros, embarcações de médio porte possuem poucos pixels de contorno na proa e na popa. Logo, espera-se que em imagens de alta resolução espacial, onde a quantidade de pixels é muito maior e os contornos possuem maior riqueza de detalhe, o desempenho do método proposto nesta dissertação seja superior.

Tendo em vista que o método não necessita de grandes recursos computacionais, conforme descrito na seção 4.1.1, e que foi bem-sucedido na detecção de embarcações em imagens multiespectrais de sensores remotos orbitais, considera-se exequível a sua utilização em apoio às tarefas de monitoramento e controle de área marítima, realizadas pela Marinha do Brasil e outras autoridades marítimas.

5.1 TRABALHOS FUTUROS

Como trabalhos futuros a serem implementados com base no método desta dissertação, espera-se o aprimoramento do mesmo se este for adaptado para aplicação em imagens de outros tipos de sensores remotos, como Radar de Abertura Sintética (SAR). Também poderá ser avaliado o resultado da aplicação do método em imagens de melhor resolução.

Se for aplicado em imagens de alta resolução espacial e obtiver acesso a um banco de dados contendo informações das embarcações, como dimensões, características estruturais e de formato, pode-se aperfeiçoar o método proposto de modo que identifique os tipos de embarcações detectadas nas imagens.

O uso de múltiplas bandas espectrais, de bandas pancromáticas, de imageamento com maior resolução espacial e de comitê de classificadores também são sugestões de aperfeiçoamento do método proposto para trabalhos futuros.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMI, M.; MOREIRA, M. A.; RUDORFF, B. F. T.; FREITAS, C. da C.; FARIA, R. T. Expansão direta na estimativa de culturas agrícolas por meio de segmentos regulares. 2005. *Revista Brasileira de Cartografia*. 57(1): 22-27, 2005b.
- AMAZUL. A Amazônia Azul. [online]. <https://www.marinha.mil.br/content/amazonia-azul-1> [acessado em 22 jan. 2018]
- AIS. *Automatic Identification System: Integrating and Identifying Marine Communication Channels*. [online]. <http://www.marineinsight.com/marine-navigation/automatic-identification-system-ais-integrating-and-identifying-marine-communication-channels/> [acessado em 19 abr. 2017]
- ARKIN, E.M.; CHEW, L.P.; HUTTENLOCHER, D.P.; KEDEM, K.; MITCHELL, J.S.B. *An Efficiently Computable Metric for Comparing Polygonal Shapes*, *IEEE Transaction on PAMI*, 13(3) (1991), 209-215.
- BASCHEK, Bjoern; DICK, Stephan ; JANSSEN, Frank ; KUEBERT, Carina ; MASSMANN, Silvia ; PAPE, Marlon ; ROERS, Michael Baschek. *Remote sensing as input and validation tool for oil spill drift modeling. 2011. Proceedings of SPIE - The International Society for Optical Engineering, Vol.8175*.
- BRASIL-1. Decreto nº 1.530, de 22 de junho de 1995. Declara a entrada em vigor da Convenção das Nações Unidas sobre o Direito do Mar, concluída em Montego Bay, Jamaica, em 10 de dezembro de 1982. *Diário Oficial da República Federativa do Brasil*, Brasília, ano 133, n. 119, p. 9199, 23 jun. 1995. Seção 1.
- BRASIL-3. Marinha Do Brasil - Diretoria de Hidrografia e Navegação (DHN). NORMAM-28. Normas da Autoridade Marítima para Navegação e Cartas Náuticas. Estabelece normas, orientações, procedimentos, e divulga informações sobre a atividade de navegação, para aplicação no mar territorial e nas vias navegáveis interiores brasileiras. 1ª edição. 2011.
- CABRAL JR, Euvaldo. **Redes Neurais Artificiais: modelos em C**. ReNeArt. 2003. 342 p.
- CAKMAKOV, Dusan, CELAKOSKA, Emilija. "*Estimation of Curve Similarity Using Turning Functions*". [online]. (2004). https://www.researchgate.net/publication/250720635_Estimation_of_curve_similarity_using_turning_functions [acessado em 24 abr. 2017]

- CÂMARA. Câmara Notícias. [online]. <http://www2.camara.leg.br/camaranoticias/noticias/economia/532920-deputados-apoiam-comissao-mista-para-acompanhar-acoes-na-amazonia-azul.html> [acessado em 22 jan. 2018]
- CCA-IMO. Comissão Coordenadora dos Assuntos da Organização Marítima Internacional (CCA-IMO). [online]. <https://www.ccaimo.mar.mil.br/sec-imo-estrutura/ccaimo> [acessado em 27 set. 2017]
- CHAPLE, Girish N.; DARUWALA, R.D.; GOFANE, Manoj S. *Comparisons of Roberts, Prewitt, Sobel operator based edge detection methods for real time uses on FPGA. 2015 International Conference on Technologies for Sustainable Development (ICTSD-2015), Feb. 04 – 06, 2015, Mumbai, Índia.*
- CRISTINA, Sónia; ICELY, John; COSTA GOELA, Priscila; ANGEL DELVALLS, Tomás; NEWTON, Alice. *Using remote sensing as a support to the implementation of the European Marine Strategy Framework Directive in SW Portugal. 2015. Continental Shelf Research. Oct 1st, 2015, Vol.108, pp.169-177.*
- DEFENSEA. Defense Sea Consultoria. A situação portuária no Brasil: Implementação de sistemas de controle de tráfego marítimo e de melhorias na segurança física das instalações. [online]. (2015). <http://www.Defensea.com.br/noticias/a-situacao-portuaria-no-brasil-implementacao-de-sistemas-de-controle-de-trafego-maritimo-e-de-melhorias-na-seguranca-fisica-das-instalacoes/> [acessado em 19 abr. 2017]
- DEFESA. Ministério da Defesa. Projeto SISGAAZ. [online]. <http://www.defesa.gov.br/infograficos/14789-projeto-sisgaaz> [acessado em 22 mar. 2018]
- DEMARCHI, Julio Cesar; SARTORI, Anderson Antonio da Conceição; ZIMBACK, Célia Regina Lopes. Métodos de classificação de imagens orbitais para o mapeamento do uso do solo: estudo de caso na Sub-Bacia do Córrego das Três Barras. Simpósio Brasileiro de Sensoriamento Remoto – SBSR. Anais XV. Abr. 30 – Mai. 05, 2011. INPE p. 2644.
- ESPÍRITO-SANTO, F. D. B. **Caracterização e mapeamento da vegetação da região da floresta nacional de Tapajós através de dados óticos, de radar e inventários florestais.** 2003. 277 p. INPE-10133-TDI/898. Dissertação de mestado em sensoriamento remoto – Instituto Nacional de Pesquisas Espaciais, São José do Campos.
- FONSECA, Jairo Simon da; MARTINS, Gilberto de Andrade. **Curso de Estatística.** Editora Atlas. 2010. 320 p

- FREEMAN, H. *On the Encoding Arbitrary Geometric Configurations. IRE Transactions on Electronic Computers EC-10*. 1961.
- GAMBA, Sérgio Roberto Horst. **Identificação de embarcações em imagens aerotransportadas de radar de abertura sintética na área marítima do Brasil**. 2010. 154 f. Dissertação submetida à comissão examinadora do programa de pós-graduação em Geociências Aplicadas do Instituto de Geociências como requisito parcial para obtenção do título de Mestre em Geociências Aplicadas pela Universidade de Brasília.
- GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento digital de imagens**. 3ª ed. Editora Pearson. 2014. 624 p
- GRACIANI, S. D. **Distribuição espacial e temporal de macrófitas aquáticas em reservatórios tropicais**. 2002. Monografia de conclusão do XV Curso Internacional de Especialização em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos.
- HARALICK, R. M. *Statistical and structural approaches to texture*. 1979. *IEEE Proceedings* 67(5): 786 – 804.
- HAYKIN, Simon. *Neural Networks and Learning Machines*. Pearson – Prentice Hall. 2008. *Third edition*. 906 p.
- IBGE. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Manual técnico em geociências número 9. Diretoria de Geociências. Departamento de Recursos Naturais e Estudos Ambientais. Primeira Divisão de Geociências do Nordeste. 2001. 91 p.
- KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. Edição Acadêmica. São Paulo. 1996. 163 p.
- KUNCHEVA, L. I. *Combining pattern classifiers – methods and algorithms*. 2004. 1ª ed. Editora Wiley.
- LEMOS JUNIOR, Adilson da Silva. **Implantação do programa estratégico dos sistemas espaciais brasileiro: uma proposta de investimento contínuo**. 2014. 66 f. Monografia apresentada ao Departamento de Estudos da Escola Superior de Guerra como requisito à obtenção do diploma do Curso de Altos Estudos de Política e Estratégia.
- LEVINE, David M., STEPHAN, David F., KREHBIEL, Timothy C., BERENSON, Mark L. **Estatística – Teoria e Aplicações**. 5ª ed. Rio de Janeiro: LTC, 2008.
- LI, Sun; ZHOU, Zhiqiang; WANG, Bo; WU, Fei. *A Novel Inshore Ship Detection via Ship Head Classification and Body Boundary Determination. IEEE Geoscience and Remote Sensing Letters*. Vol 13, Nr 12, December 2016.

- MACHADO E SILVA, A. J. F.; SILVA, M. V. D. da; SANTINI, D. Mapeamento topográfico usando imagens Ikonos. 2003. Simpósio Brasileiro de Sensoriamento Remoto. 5-10 abr 2003. p 297-302. Belo Horizonte.
- MARTINS, Eliane Octaviano. Amazônia azul, pré-sal, soberania e jurisdição marítima. **Revista Centro de Estudos Judiciários (CEJ)**, Brasília, Ano XIV, n. 50, p. 83 – 88, jul./set. 2010.
- MCCULLOCH, W.; PITTS, W. *A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics. Vol 5*, p. 115 - 133. Dec 1943.
- MELO, D. H. C. T. B. **Uso de dados Ikonos II na análise urbana: testes operacionais na zona leste de São Paulo**. 2002. 146 p. INPE-9865-TDI/870. Dissertação de mestrado em sensoriamento remoto – Instituto Nacional de Pesquisas Espaciais. São José dos Campos.
- MMA. Geocatálogo do Ministério do Meio Ambiente. [online]. <http://geocatalogo.mma.gov.br> [acessado em 09 mai. 2017]
- MORE, Rodrigo F. Regime jurídico do mar: a regulação das águas e da plataforma continental do Brasil. **Revista da Escola de Guerra Naval**, Rio de Janeiro, v. 19, n.1, p. 79 – 109, jan – jun 2013.
- OLIVEIRA JR, Hime A. e; CLADEIRA, A. M.; MACHADO, M. A. S.; SOUZA, R. C.; TANSCHKEIT, R. **Inteligência Computacional Aplicada à Administração, Economia e Engenharia em MatLab**. 1ª ed. São Paulo. Thomson Learning, 2007.
- PEDRINI, Hélio; SCHWARTZ, William Robson. **Análise de Imagens Digitais – Princípios, Algoritmos e Aplicações**. Editora Thomson. 2008. 508 p.
- PETROBRAS. Pré-Sal. [online]. <http://www.petrobras.com.br/pt/nossas-atividades/areas-de-atuacao/exploracao-e-producao-de-petroleo-e-gas/pre-sal/> [acessado em 07 ago. 2017]
- QI, Shengxiang, MA, Jie, LIN, Jin, LI, Yansheng, TIAN, Jinwen. *Unsupervised ship detection based on saliency and s-hog descriptor from optical satellite images. IEEE Geoscience and Remote Sensing Letters*. Vol 12, Nr 7, July 2015.
- REZENDE, Solange Oliveira; EVSUKOFF, Alexandre Gonçalves; GARCIA, Ana Cristina Bicharra; CARVALHO, André Carlos P. de L. F. de; BRAGA, Antônio de Pádua; MONARD, Maria Carolina; EBECKEN, Nelson Francisco F.; JÚNIOR, Orides Morandin; ALMEIDA, Paulo Eduardo M. de; LUDERMIR, Teresa Bernarda. **Sistemas Inteligentes – Fundamentos e Aplicações**. Editora Manole. 2003. 525 p.
- RUSSELL, Stuart Jonathan; NORVIG, Peter. **Inteligência Artificial**. Editora Elsevier. 2004. 1021 p.

- SOUZA, D. L. de. **Sistema inteligente para detecção de manchas de óleo na superfície marinha através de imagens SAR**. 2006. 103 f. Dissertação de mestrado em Engenharia Elétrica na Universidade Federal do Rio Grande do Norte.
- VIALI, Lori; BERLIKOWSKY, Márcia Elisa. Cerveja e estatística: vida e obra de um mestre cervejeiro. **Vidya**, v. 36, n. 2, p. 507-522, jul./dez., 2016 - Santa Maria, 2016. ISSN 2176-4603.
- VOLOTÃO, Carlos F. S., SANTOS, Rafael D. C., ERTHAL, Guaraci J., DUTRA, Luciano V. *Shape characterization with turning functions*. IWSSIP 2010 – 17th International Conference on Systems, Signals and Image Processing. [online]. http://plutao.dpi.inpe.br/col/dpi.inpe.br/plutao/2010/11.11.17.36.41/doc/Shape_Volotao.pdf [acessado em 19 abr. 2017]
- WINSTON, P. H. **Artificial Intelligence**. 3ª ed. Editoria Pearson.1992.
- YANG, Feng; XU, Qizhi; LI, Bo. *Ship Detection From Optical Satellite Images Based on Saliency Segmentation and Structure-LBP Feature*. **IEEE Geoscience and Remote Sensing Letters**. Vol 14, Nr 5, May 2017.
- ZHU, Changren; ZHOU, Hui; WANG, Runsheng; GUO, Jun. *A Novel Hierarchical Method of Ship Detection from Spaceborne Optical Image Based on Shape and Texture Features*. **IEEE Transactions on Geoscience and Remote Sensing**. Vol 48, Nr 9, September 2010.
- ZOU, Zhengxia; SHI, Zhenwei. *Ship Detection in Spaceborne Optical Image With SVD Networks*. **IEEE Transactions on Geoscience and Remote Sensing**. Vol 54, Nr 10, October 2016.