

UNIVERSIDADE FEDERAL DE VIÇOSA

HILDA ALTINA RAFAEL GOMES

**EMPREGO DE SAS INTERFEROMÉTRICO E MBES PARA IDENTIFICAÇÃO DE
ÁREAS DE POSSÍVEIS CORAIS EM ÁGUAS PROFUNDAS**

VIÇOSA - MINAS GERAIS

2024

HILDA ALTINA RAFAEL GOMES

**EMPREGO DE SAS INTERFEROMÉTRICO E MBES PARA IDENTIFICAÇÃO DE
ÁREAS DE POSSÍVEIS CORAIS EM ÁGUAS PROFUNDAS EM ÁGUAS
PROFUNDAS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Magister Scientiae*.

Orientadora: Nilcilene das Graças Medeiros

Coorientador: Ítalo Oliveira Ferreira

VIÇOSA - MINAS GERAIS

2024

Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa

T

G633e
2024
Gomes, Hilda Altina Rafael, 1991-
Emprego de SAS interferométrico e MBES para
identificação de áreas de possíveis corais em águas profundas /
Hilda Altina Rafael Gomes. – Viçosa, MG, 2024.
1 dissertação eletrônica (70 f.): il. (algumas color.).

Inclui apêndice.

Orientador: Nilcilene das Graças Medeiros.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Engenharia Civil, 2024.

Referências bibliográficas: f. 60-63.

DOI: <https://doi.org/10.47328/ufvbbt.2024.458>

Modo de acesso: World Wide Web.

1. Veículos autônomos subaquáticos. 2. Sonar.
3. Ecobatímetro. 4. Recifes e ilhas de corais. 5. Levantamentos
hidrográficos. 6. Sombras. I. Medeiros, Nilcilene das Graças,
1977-. II. Universidade Federal de Viçosa. Departamento de
Engenharia Civil. Programa de Pós-Graduação em Engenharia
Civil. III. Título.

CDD 22. ed. 623.8205

Bibliotecário(a) responsável: Bruna Silva CRB-6/2552

HILDA ALTINA RAFAEL GOMES

**EMPREGO DE SAS INTERFEROMÉTRICO E MBES PARA IDENTIFICAÇÃO DE
ÁREAS DE POSSÍVEIS CORAIS EM ÁGUAS PROFUNDAS**


Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Magister Scientiae*.

APROVADA: 23 de fevereiro de 2024.

Assentimento:

Documento assinado digitalmente
 HILDA ALTINA RAFAEL GOMES
Data: 04/08/2024 11:59:31-0300
Verifique em <https://validar.iti.gov.br>

Hilda Altina Rafael Gomes
Autora

Documento assinado digitalmente
 NILCILENE DAS GRACAS MEDEIROS
Data: 06/08/2024 08:56:53-0300
Verifique em <https://validar.iti.gov.br>

Nilcilene das Graças Medeiros
Orientadora

AGRADECIMENTOS

Antes de tudo, agradeço a Deus e Nossa Senhora Aparecida que sempre me sustentaram nas adversidades.

Aos meus pais, Heleno e Maria Altina por todo apoio e incentivo em toda minha vida estudantil, sendo meus exemplos de perseverança e dedicação.

Aos meus irmãos, Heleno Júnior e Manoel, que nunca mediram esforços para me ajudar nessa caminhada.

Ao meu esposo Luiz Paulo, que sempre esteve ao meu lado me ajudando a enfrentar os obstáculos, obrigada por todo amor e paciência.

Ao meu filho Dante, que me impulsiona todos os dias a ser uma pessoa melhor.

As minhas amigas Lara, Natália e Youlia pelo incentivo e acolhimento ao longo desses anos.

A Petrobrás S.A e principalmente seus engenheiros Marksuel Xavier Bastos e Romulo Parma Gonçalves por estarem a disposição em todos os momentos que precisei e também pela concessão dos dados para o desenvolvimento da pesquisa.

A professora Nilcilene por sempre me motivar a seguir em frente, pelo companheirismo e conhecimentos compartilhados.

Ao professor Ítalo, por todas as revisões ao longo da elaboração da pesquisa, sempre contribuindo com o seu conhecimento.

Ao professor Júlio pelo direcionamento nos momentos de dúvidas e pela disponibilidade tempo e interesse em ajudar.

À Universidade Federal de Viçosa, pela oportunidade de realizar a pós-graduação.

Aos funcionários e professores da Universidade Federal de Viçosa em especial ao Programa de Pós-Graduação em Engenharia Civil.

Agradeço igualmente aos que não foram mencionados de forma nominal, mas que contribuíram direta ou indiretamente para a conclusão da pesquisa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

GOMES, Hilda, A. R, M.Sc., Universidade Federal de Viçosa, fevereiro de 2024. **Emprego de SAS interferométrico e MBES para identificação de áreas de possíveis corais em águas profundas.** Orientadora: Nilcilene das Graças Medeiros. Coorientador: Ítalo Oliveira Ferreira.

A exploração de petróleo e gás no Brasil tem um importante papel na economia nacional e dentre as diferentes etapas que compõem a cadeia produtiva para a obtenção de produtos e derivados, o conhecimento do fundo marinho e das feições naturais ou artificiais que o compõem, é essencial para garantir operações seguras aos operadores e ao meio ambiente. Nesse sentido, o levantamento hidrográfico permite conhecer o ambiente marinho e seus constituintes. Além disso, os Veículos Autônomos Subaquáticos (AUVs) acoplados com o Sonar de Abertura Sintética Interferométrico (SAS interferométrico) e Ecobatímetro Multifeixe (MBES) vem sendo bastante utilizados nesses levantamentos, devido aos ganhos na resolução e maior taxa de cobertura das áreas levantadas. Ante o exposto, a pesquisa teve como objetivo realizar a classificação semiautomática de possíveis ocorrências de corais em águas profundas, considerando os dados provenientes dos sensores HISAS 1030 e EM 2040, acoplados a bordo do AUV, através do classificador *Random Forest*, com as abordagens de classificação *pixel a pixel* e por Análise de Imagem Baseada em Objetos (OBIA), bem como uma reclassificação das áreas de sombra com auxílio do parâmetro de índice de posição batimétrica. Os resultados encontrados em termos quantitativos e qualitativos evidenciaram que dentre as metodologias aplicadas a classificação por OBIA apresentou melhor desempenho, com acurácia de 90,87% de acertos. Já os parâmetros empregados no modelo para uma reclassificação dos polígonos inicialmente conhecidos como sombra, conseguiu de forma assertiva classificar 30,84% dos dados. Em síntese, os resultados apontam que as técnicas aplicadas são satisfatórias quando se deseja realizar a classificação semiautomática de possíveis corais e áreas de sombras, visto que possibilitaram a delimitação dos alvos de interesse de forma eficiente e com mais agilidade.

Palavras-chave: AUV; SAS interferométrico; MBES, Recifes de corais, Sombras.

ABSTRACT

GOMES, Hilda, A. R, M.Sc., Universidade Federal de Viçosa, February, 2024. **Use of interferometric SAS and MBES to identify areas of possible corals in deep waters.** Adviser: Nilcilene das Graças Medeiros. Co-adviser: Ítalo Oliveira Ferreira.

Oil and gas exploration in Brazil plays a crucial role in the national economy. Among the various stages in the production chain to obtain products and derivatives, knowledge of the seabed and its natural or artificial features is essential to ensure safe operations for operators and the environment. In this context, hydrographic surveys allow us to understand the marine environment and its constituents. Autonomous Underwater Vehicles (AUVs) equipped with Interferometric Synthetic Aperture Sonar (interferometric SAS) and Multibeam Echo Sounder (MBES) have been widely used in these surveys due to their high resolution and greater coverage rate. This research aimed to conduct a semi-automatic classification of potential coral occurrences in deep waters, using data from the HISAS 1030 and EM 2040 sensors onboard the AUV. The classification was performed using the Random Forest classifier, with both pixel-by-pixel and Object-Based Image Analysis (OBIA) approaches, along with the reclassification of shadow areas using the bathymetric position index parameter. The quantitative and qualitative results showed that among the applied methodologies, OBIA classification performed best, with an accuracy of 90.87%. The parameters used in the model successfully reclassified 30.84% of the initially identified shadow polygons. In summary, the results indicate that the applied techniques are effective for the semi-automatic classification of potential corals and shadow areas, allowing for efficient and agile target delimitation.

Keywords: AUV; interferometric SAS; MBES; Coral reefs; Shadows.

LISTA DE ILUSTRAÇÕES

Figura 1 – Ilustração de um Veículo Subaquático Autônomo (AUV)	18
Figura 2 – Diferença entre a abertura real e abertura sintética	19
Figura 3 – Princípio da interferometria	21
Figura 4 – Geometria imagem SAS baseada em AUV.....	23
Figura 5 – Representação dos valores positivos e negativos de BPI.....	26
Figura 6 – Representação dos valores de BPI próximos ou iguais a zero	26
Figura 7 – Resumo da metodologia aplicada	34
Figura 8 – Mosaico 1, composto por imagens processadas de SAS interferométrico	36
Figura 9 – Mosaico 2, composto por imagens processadas de MBES	37
Figura 10 – Método 1, aplicado para classificação de possíveis corais, com os insumos base Mosaicos 1 e 2	38
Figura 11 – Superfície de inclinação (SI) gerada	39
Figura 12 – Superfície BPI com raio de 5 metros (BPI_{5m}) gerada	40
Figura 13 – Identificação no Mosaico 1, dos temas das três classes.....	41
Figura 14 – Método 2, aplicado para classificação de possíveis corais, com os insumos base Mosaicos 1 e 2	44
Figura 15 – Método 3, empregado a partir da classificação automática do método 2, para determinar a relação entre possíveis corais e sombra.....	47
Figura 16 – Representação parcial da Linha individual 1 (esquerda) e Mosaico 1 (direita) para a mesma região	49
Figura 17 – Classificação final resultante do método 1	53
Figura 18 – Classificação final resultante do método 2	56
Gráfico 1 – Importância das variáveis em porcentagem para o modelo.....	51

LISTA DE TABELAS

Tabela 1 – Matriz confusão ou matriz erro para Classe A.....	32
Tabela 2 – Classes e número de pontos amostrais coletados por classes	41
Tabela 3 – Configuração dos parâmetros aplicados no modelo Random Forest.....	42
Tabela 4 – Configuração dos parâmetros do algoritmo multiresolution segmentation	45
Tabela 5 – Matriz confusão baseada nas amostras de teste	51
Tabela 6 – Matriz confusão, baseada na validação por tabulação cruzada, entre a imagem de referência e a imagem da classificação automática do método 1	52
Tabela 7 – Matriz confusão baseada nas amostras	54
Tabela 8 – Matriz confusão, baseada na validação por tabulação cruzada, entre a imagem de referência e a imagem da classificação automática do método 2	55
Tabela 9 – Distribuição dos objetos por classe com e sem condicionante.....	57

LISTA DE ABREVIATURAS E SIGLAS

ANP	Agência Nacional de Petróleo, Gás Natural e Biocombustíveis
AUV	<i>Autonomous Underwater Vehicle</i> – Veículos Autônomos Subaquáticos
BPI	<i>Bathymetric Position Index</i> – Índice de Posição Batimétrica
E&P	Exploração e Produção
MBES	Multibeam <i>echosounder</i> – Ecobatímetro multifeixe
OBIA	<i>Object-Based Image Analysis</i> – Análise de Imagem Baseada em Objetos
RF	<i>Random Forest</i>
ROV	<i>Remotely Operated Vehicle</i> – Veículo Subaquático Operado Remotamente
SAS	Sonar de Abertura Sintética
SI	Superfície de Inclinação
SNR	Relação Sinal – Ruído
TPI	<i>Topographic Position Index</i> – Índice de Posição Topográfica
TVP	Taxa de Verdadeiros Positivos

SUMÁRIO

RESUMO	16
ABSTRACT	17
1 INTRODUÇÃO.....	11
2 CONTEXTUALIZAÇÃO DO PROBLEMA	14
3 OBJETIVOS	16
3.1 Objetivos gerais.....	16
3.2 Objetivos específicos.....	16
4 REVISÃO DE LITERATURA	17
4.1 Veículos Subaquáticos Autônomos (AUVs - Autonomous Underwater Vehicles).....	17
4.2 Sonar de Abertura Sintética (SAS) e Sonar de Abertura Sintética Interferométrico (SAS interferométrico)	18
4.2.1 Geometria da imagem SAS.....	22
4.2.2 Dificuldades associadas a imagem SAS	23
4.3 Ecobatímetros multifeixe (MBES).....	24
4.3.1 Índice de Posição Batimétrica (BPI)	25
4.3.2 Inclinação	27
4.4 Classificação automática de imagens	27
4.4.1 Análise de Imagem Baseada em Objetos e Segmentação	29
4.4.2 Random Forest.....	30
4.5 Métricas baseadas na matriz confusão para avaliação dos modelos de classificação	31
5 METODOLOGIA.....	34
5.1 Área de estudo	35
5.2 Método 1: Classificação das possíveis áreas de corais	38
5.2.1 Pré-processamento	38
5.2.2 Coleta de amostras	40

5.2.3	Classificação automática.....	42
5.2.4	Avaliação dos resultados.....	43
5.2.5	Pós-processamento.....	43
5.3	Método 2: Classificação das possíveis áreas de corais	43
5.3.1	Segmentação	44
5.3.2	Classificação automática.....	45
5.3.3	Refinamento do modelo	46
5.3.4	Avaliação dos resultados.....	46
5.3.5	Pós-processamento.....	47
5.4	Método 3: Refinamento da classificação	47
5.4.1	Refinamento da classificação.....	48
5.4.2	Avaliação dos resultados.....	48
5.4.3	Pós-processamento.....	50
6	RESULTADOS E DISCUSSÕES	50
6.1	Resultados obtidos com o Método 1	50
6.2	Resultados obtidos com o Método 2	54
6.3	Resultados obtidos com o Método 3	57
7	CONCLUSÕES E RECOMENDAÇÕES.....	58
	REFERENCIAS	60
	APÊNDICE A – Script (método 1)	64

1 INTRODUÇÃO

A indústria do petróleo e gás produz bens que contribuem consideravelmente para o abastecimento da matriz energética do Brasil, ocupando assim lugar de destaque como uma das atividades econômicas mais importantes. Fatores que corroboram isso, são os números apresentados no relatório anual sobre o Balanço Energético Nacional que utilizando como base o ano de 2022, teve como fonte 52,6 % de energia não renovável, sendo 35,7% proveniente do setor de petróleo e gás (Brasil, 2023).

O âmbito do petróleo e gás tem uma longa cadeia produtiva, em que a maior parte das reservas brasileiras estão localizadas em ambiente marítimo. Logo, o conhecimento do fundo marinho para o sucesso das diferentes fases de atuação do petróleo é essencial. A título de exemplo, considerando a etapa de implantação de um novo campo de exploração, o conhecimento das feições naturais da região, em especial as variáveis ambientais, ajudam a reduzir o impacto da exploração em áreas ambientalmente sensíveis.

No caso de regiões em que a exploração do petróleo já está sendo executada, existem estruturas submarinas que exigem manutenção e monitoramento, uma vez que sofrem ações de agentes que afetam a integridade desses dutos e equipamentos. Ainda, quando essas instalações estão no final de sua vida útil a Agência Nacional de Petróleo, Gás Natural e Biocombustíveis - ANP através da resolução nº 817 de 24 de abril de 2020 requisita que essa infraestrutura seja retirada do ambiente (descomissionamento) de forma segura (Brasil, 2020; Neto; Rodrigues; Alvarenga, 2018).

Nota-se que para a execução das diferentes atividades descritas anteriormente é necessário identificar as diversas feições, sejam elas naturais ou artificiais, no ambiente subaquático de forma precisa, a fim de realizar operações seguras para o meio ambiente e operadores, bem como reduzir riscos e falhas.

Diante deste contexto, o levantamento hidrográfico permite conhecer o ambiente do fundo marinho e dentre as variadas tecnologias que podem ser utilizadas tem-se o AUV (*Autonomous Underwater Vehicle – Veículos Autônomos Subaquáticos*) que apresenta vantagens em relação a aquisição de dados, pois

fornece alta resolução em águas profundas e maior mobilidade no mapeamento quando comparado a outras tecnologias como ROV (*Remotely Operated Underwater Vehicle – Veículo Operado Remotamente*) (Sahoo; Dwivedy; Robi, 2019).

Isso porque os ROVs, apesar de conseguirem realizar uma infinidade de tarefas, precisam de conexões por fios para operar, o que acaba limitando o acesso a locais mais profundos, bem como a capacidade de manobra do veículo (Sahoo; Dwivedy; Robi, 2019). Já os AUVs são plataformas subaquáticas também não tripuladas, que podem ser operadas de um navio ou de forma independente e tem a capacidade de atingir até 6000 metros de profundidade (Fernandes, 2018; Sahoo; Dwivedy; Robi, 2019).

Nesse sentido realizando um paralelo entre as duas tecnologias, a ausência de conexão por fios dos AUVs, possibilita um levantamento hidrográfico com maior mobilidade o que resulta em um menor custo de operação. Ainda, devido a maior estabilidade da plataforma na navegação, permite que diversos sensores de alta resolução sejam acoplados a bordo, como o ecobatímetros multifeixe (MBES) e sonar de abertura sintética interferométrico (SAS interferométrico) (Fernandes, 2018; Sahoo; Dwivedy; Robi, 2019).

Belchior et al. (2015) e Mitchell et al. (2018) apontam que o conhecimento e exploração do ambiente oceânico tem ligação direta com a tecnologia do MBES que através do tempo de percurso das ondas sonoras refletidas no fundo marinho, permite a determinação tanto da profundidade da água (batimetria) quanto o retroespalhamento (*backscatter*). Completando tal tecnologia o SAS interferométrico melhora a eficiência do mapeamento, uma vez que entrega alta resolução nas imagens e na batimetria, bem como um aumento na taxa de cobertura de grandes áreas, como consequência a identificação e classificação dos objetos no fundo marinho se torna possível (Callow et al., 2012; Fernandes, 2018).

Diante do exposto, percebe-se que a ampliação na área de cobertura e o conjunto dos sensores que podem estar nos veículos subaquáticos resultam em um grande volume de dados. Assim, o desenvolvimento de soluções que busquem automatizar o processo de extração de informação é de grande importância para o ganho de tempo, e conseqüentemente, torna o processo mais econômico.

Contudo, fica evidente que a exploração e produção (E&P) do petróleo e seus derivados para disponibilizar recursos energéticos ao país é fundamental e impacta diretamente no meio econômico, social e ambiental. Desta maneira, é essencial que as fases de E&P sejam socioambientalmente responsáveis (Brasil, 2014).

2 CONTEXTUALIZAÇÃO DO PROBLEMA

Conforme Fernandes (2018) e Ludvigsen et al. (2014), quando se realiza uma comparação entre as tecnologias disponíveis para os levantamentos hidrográficos na indústria do petróleo e gás, na qual os objetivos são mapeamentos de grandes áreas para pesquisa do fundo marinho, os AUVs são mais adequados que os ROVs dado que apresentam uma velocidade de deslocamento cerca de oito vezes maior e são operados sem contato direto com a embarcação, o que do ponto de vista operacional, é um ganho em relação ao tempo de mapeamento.

Ao passo que o mundo *offshore* começa a utilizar os AUVs devido aos benefícios que oferecem, principalmente em operações realizadas em águas profundas, em função da plataforma estável do veículo que possibilita acoplar sensores de alta frequência (ecobatímetros multifeixe e sonar de abertura sintética), os quais fornecem dados de alta resolução. E por consequência, com o aumento na resolução, alcance e velocidade de deslocamento tem-se um grande volume de dados coletados (Hoggarth; Kenny, 2014; Mitchel et al., 2018).

Outro fator importante nos levantamentos hidrográficos é a geometria das imagens SAS baseadas em AUVs, pois devido a configuração do sensor é formada uma zona de mapeamento sem informações (ou cega) abaixo do veículo (Hansen et al., 2011). No mapeamento de áreas muito extensas e com diversos alvos de interesse (naturais e antrópicos), para cobrir essa lacuna de informação e ao mesmo tempo garantir a necessidade de sobreposição para a produção de mosaicos, a prática adotada é o imageamento da mesma região em direções distintas o que causa um aumento e duplicação no volume de dados (Willians, 2011). Assim, durante a confecção dos mosaicos existe como opção, diferentes linhas individuais que representam a mesma área. Vale destacar ainda que no levantamento, quando existe uma diferença no ângulo de visada horizontal ou na geometria vertical da linha de base, ocorre em passadas repetidas uma diferença no realce e aparecimento de sombras (Hansen, 2022).

Tendo em vista o exposto, durante a definição das linhas individuais que vão compor o mosaico, devido ao grande volume de dados, tal processo geralmente é realizado de forma automática. No entanto, as ferramentas que possibilitam a

automatização, não comparam todas as linhas individuais da mesma região, para a escolha da imagem que apresenta melhor qualidade visual. Com isso, na composição final dos mosaicos de SAS interferométrico, acaba ocorrendo, nos alvos imageados sejam eles naturais ou não, a presença de sombras, as quais não são inerentes ao fundo marinho.

A partir dos mosaicos de SAS interferométricos é possível realizar a inspeção e mapeamento para identificação de possíveis áreas de recifes de corais, os quais segundo Castro e Pires (2001) são considerados muito importantes para a biodiversidade, uma vez que abrigam inúmeros recursos biológicos e econômicos. Dessa forma, o reconhecimento dessas regiões é fundamental na tomada de decisão, principalmente quando um dos objetivos é definir áreas candidatas para implantação de campo de exploração, dutos ou algum equipamento no ambiente marinho. Hodiernamente, a delimitação das prováveis regiões de recifes de corais é feita manualmente por inspeção visual.

Portanto, o desenvolvimento de técnicas que possam realizar a classificação de forma automática dos ambientes sensíveis em águas profundas, representa um ganho no tempo de mapeamento e padronização da informação. Além disso, levando em consideração as áreas de sombras associadas a esses alvos, caso seja possível determinar se a sombra é ou não um provável banco de coral, ao final da classificação, o contorno obtido para feições de interesse, diminuem as chances de serem superestimados ou subestimados.

3 OBJETIVOS

3.1 Objetivos gerais

A pesquisa visa classificar em águas profundas, por meio do aprendizado de máquina, os possíveis recifes de corais e as áreas de sombra associadas a esses alvos.

3.2 Objetivos específicos

- a) Testar os métodos semiautomáticos de classificação *pixel a pixel* e por regiões com o algoritmo *Random Forest* para a identificação de áreas de possíveis corais em dados de SAS interferométrico e MBES;
- b) Analisar a influência dos parâmetros de resposta espectral, profundidade e derivadas batimétricas na identificação das áreas de possíveis corais no processo de classificação;
- c) Analisar a inserção dos parâmetros de inclinação e BPI (*Bathymetric Position Index* – Índice de Posição Batimétrica) na identificação das sombras associadas aos possíveis corais como áreas temáticas;
- d) Analisar quantitativamente e qualitativamente os resultados advindos dos métodos de classificação *pixel a pixel* e por regiões com os dados de SAS interferométrico e MBES.
- e) Identificar um padrão de resposta para as regiões classificadas como sombra.

4 REVISÃO DE LITERATURA

4.1 Veículos Subaquáticos Autônomos (AUVs - Autonomous Underwater Vehicles)

De acordo com Sahoo, Dwivedy e Robi (2019) os sistemas subaquáticos não tripulados apresentam grande destaque quando um dos intuitos é explorar o ambiente marinho, devido a característica de não precisar de humanos a bordo, o que traz ganhos em relação a diminuição dos riscos operacionais.

Em meio as diferentes tecnologias para mapeamento subaquático, o AUV (Veículo Subaquático Autônomo) e o ROV (Veículo Subaquático Operado Remotamente) são duas categorias de plataformas de levantamento não tripuladas. O ROV, opera em velocidade inferior quando comparado ao AUV e é controlado pela superfície por meio de uma conexão com fio. Já o AUV navega de forma autônoma, submergindo para a coleta de dados e retornando a superfície após concluir a missão que foi definida (Sahoo; Dwivedy; Robi, 2019).

No AUV é possível acoplar uma combinação de diversos sensores: SAS interferométrico, multifeixe e câmera fotográfica. Essa característica em conjunto com a maior velocidade de deslocamento do veículo, conferem ao final de cada mergulho, o levantamento de áreas maiores. Como consequência o volume de dados coletados é significativo, a exemplo disso um AUV equipado com os três sensores informados anteriormente, podem coletar até 3 *terabytes* de dados em apenas uma missão de vinte e quatro horas (Carballini; Viana, 2015). Vale destacar ainda que tais sensores também podem ser instalados nos ROVs, entretanto devido a menor estabilidade do veículo os dados apresentam uma qualidade inferior quando comparados. A Figura 1 ilustra um Veículo Subaquático Autônomo após seu recolhimento do mar.

Figura 1 – Ilustração de um Veículo Subaquático Autônomo (AUV)




Fonte: Kongsberg (2024).

4.2 Sonar de Abertura Sintética (SAS) e Sonar de Abertura Sintética Interferométrico (SAS interferométrico)

O Sonar de Abertura Sintética (SAS) é baseado no princípio de que vários pulsos são transmitidos e recebidos repetidamente enquanto o sonar se move. Quando o sinal é recebido ele é sintetizado coerentemente para se obter uma imagem de alta resolução. No momento em que diversos *pings* sucessivos são sintetizados, o sonar consegue operar em uma abertura maior do que sua abertura real, dando origem ao nome “abertura sintética” (Choi; Yang; Seong, 2021; Hansen, 2013). A Figura 2 ilustra a diferença entre a abertura real e a abertura sintética em termos de cobertura da área.

Figura 2 – Diferença entre a abertura real e abertura sintética



Fonte: Adaptado Saebø (2010, p. 14).

No sonar de abertura real (Figura 2) a resolução ao longo da faixa de varredura (*along track*) é limitada, pois depende do alcance (*range*). Assim, para se obter uma alta resolução ao longo da faixa de varredura a frequência deve ser muito alta e alcance curto, como consequência tem-se uma redução na taxa de cobertura da área. Já em abertura sintética uma matriz mais longa é sintetizada através do processamento de *pings* sucessivos combinados de forma coerente (Saebø, 2010).

Amparado por Saebø (2010) a resolução de alcance (*range resolution*) na imagem de abertura real e abertura sintética é a mesma, sendo dada pela Equação 1.

$$\delta_r^{\text{sintética}} = \delta_r^{\text{real}} = \frac{c}{2B} \quad (1)$$

Em que δ_r corresponde à resolução *slant-range* o c a velocidade do som e B a largura da banda do sinal. Porém, a resolução ao longo da faixa de varredura (*along track*) no sonar de abertura sintética é diferente do sonar de abertura real, uma vez que é independente do alcance (Equação 2) (Denny et al., 2015).

$$\delta_x^{sintética} = \frac{\lambda}{2L_{sintética}} r \quad (2)$$

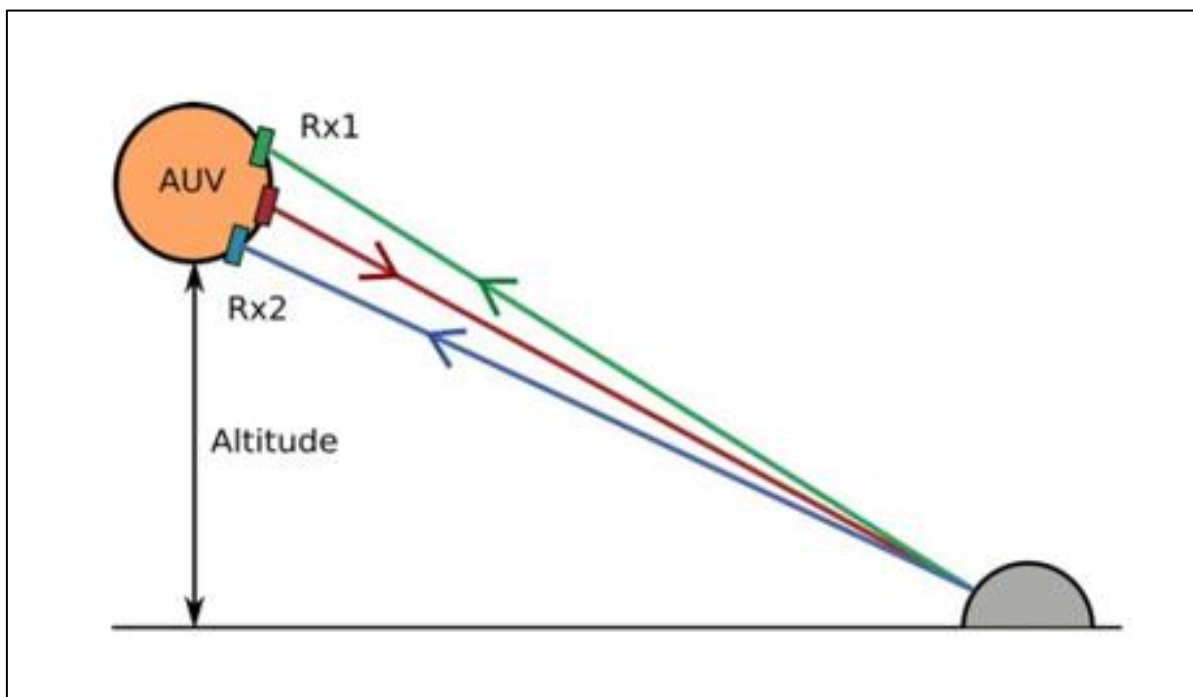
No qual, δ_x é a resolução ao longo da faixa de varredura o fator 2 é causado devido ao movimento do transmissor ao longo da abertura sintética e $L_{sintética}$ refere-se ao comprimento da abertura sintética. Já λ e r são o comprimento de onda e o *slant-range*, respectivamente.

Em resumo, o SAS tem a propriedade única de cobrir uma maior área e simultaneamente fornecer uma resolução alta, através da técnica baseada na combinação coerente de múltiplos pulsos. Além disso, Hansen (2022) também evidência que tal sensor é ideal para os AUVs, por ser um tipo de veículo submerso com plataforma estável.

Sendo assim, quando o SAS é desenvolvido para ser acoplado no AUV, esses sensores são tipicamente interferométricos, ou seja, um SAS interferométrico, o que permite que a imagem acústica e a profundidade estimada sejam obtidas no ambiente submerso (Hansen, 2022). Como resultado o sensor fornece a imagem do fundo marinho e a batimetria interferométrica (Callow et al., 2012).

A capacidade interferométrica do sensor é a técnica que possibilita o mapeamento batimétrico, que se baseia na estimativa do atraso de tempo de chegada de um mesmo ponto da onda em dois ou mais receptores (Figura 3). A diferença de tempo é então transformada em uma direção de chegada, e em seguida em uma estimativa de profundidade. Portanto, é um princípio baseado na aferição da direção com base na diferença de fase, para posteriormente obter um mapa de elevação digital (Hansen, 2013).

Figura 3 – Princípio da interferometria



Fonte: Adaptado Hansen et al. (2010).

A Figura 3 ilustra a representação de um sonar interferométrico que contém dois receptores separados verticalmente (verde e azul) e um único transmissor (vermelho), os quais são empregados para determinar o ângulo de depressão do eco de chegada (Hansen et al., 2010).

Hansen et al. (2011) reitera o significado de interferometria como sendo a determinação da direção angular de um sinal de chegada, através do atraso de tempo entre a chegada do sinal em receptores separados espacialmente.

A distância entre os receptores interferométricos é chamada de linha de base. No geral, as frentes de onda de chegada podem ser consideradas paralelas, visto que se assume que a linha de base é pequena em relação ao intervalo. Como informado anteriormente, a partir do tempo de atraso entre as ondas de chegada, a profundidade relativa pode ser estimada pela Equação 3 (Saebø, 2010).

$$z = r \left(\frac{ct}{D} \right) \quad (3)$$

Assim, o z equivale a profundidade relativa, o t refere-se ao atraso de tempo interferométrico entre os sinais de chegada, o r alcance inclinado, o c corresponde a velocidade do som e o D a distância entre os receptores. Usualmente, o tempo de atraso é determinado por meio da diferença de fase entre os sinais.


Por fim, Hansen (2022) destaca que a resolução horizontal da imagem SAS é superior à da batimetria SAS, isso porque na estimativa da direção vertical se utiliza muitos *pixels* e a profundidade acaba variando ao longo de uma cena, devido ao fato da precisão estimada da profundidade ser dependente da relação sinal – ruído (SNR) e logo da intensidade do eco.

4.2.1 Geometria da imagem SAS

Segundo Hansen et al. (2011) quando o SAS é utilizado em um AUV, normalmente são montados dois sensores no veículo, sendo um posicionado a bombordo e outro a estibordo. Como consequência, se forma uma zona cega (*blind zone*) abaixo da plataforma, isto significa que entre as duas faixas de sonar não há cobertura de dados. Neto (2016) ressalta que a largura dessa lacuna é “aparentemente” duas vezes a altitude de voo. Isso ocorre porque o tempo de chegada do primeiro ponto da frente de onda é igual a altura do equipamento. Entretanto na prática essa faixa é de aproximadamente de 10% da altura

Hansen et al. (2011) ainda destaca que o alcance (*range*) do sonar usualmente é dez vezes a altitude do veículo e a faixa (*swath*) devido ao modo de funcionamento do sistema SAS apresenta largura quase semelhante ao alcance máximo, conforme ilustra a Figura 4.

Figura 4 – Geometria imagem SAS baseada em AUV



Fonte: Adaptado Hansen et al. (2011).

A Figura 4 representa a geometria da imagem SAS em um sistema de dois sensores acoplados no AUV o que confere uma visão cega debaixo do veículo.

Desse modo, por causa da geometria das imagens, o planejamento padrão de levantamento com AUV considera as linhas de voo do modelo cortador de grama (*lawnmower pattern*), em que as faixas de varredura consecutivas do sonar se sobrepõem. Na sequência, considerando o mesmo modelo é realizada uma revisitação da área, no entanto, a direção das linhas de voo é ortogonal ao primeiro levantamento o que garante que as regiões imageadas sejam observadas em pelo menos duas vezes (Williams, 2011). Portanto, existem linhas individuais sobrepostas que correspondem à mesma área do fundo marinho.

4.2.2 Dificuldades associadas a imagem SAS

Apesar do princípio SAS ser conhecido a mais de 30 anos, ainda existem desafios que precisam ser superados em relação ao fundo marinho (Hansen, 2011). Dentre os diferentes fatores que afetam a qualidade da imagem SAS, vale ressaltar o erro associado a coleta de dados que se refere a geometria vertical e o *crabbing* (movimento lateral do veículo) (Hansen, 2022).

Neste caso, quando existe uma diferença entre o ângulo de visada horizontal e/ou a geometria vertical, para passagens repetidas, aumentam as chances de se formarem sombras e diferentes regiões de realce nas imagens SAS (Hansen, 2022).

4.3 Ecobatímetros multifeixe (MBES)

De acordo com Mitchell et al. (2018), os avanços na tecnologia dos ecobatímetros multifeixe (MBES – *multibeam echosounder*) estão diretamente ligados ao conhecimento e exploração do ambiente de águas profundas, bem como os processos geomorfológicos e biofísicos que os moldam. Através das ondas acústicas emitidas pelo sensor se torna possível obter tanto a batimetria do fundo marinho quanto a refletividade acústica (retroespalhamento ou *backscatter*) (Mitchell et al., 2018).

Diante disso, ressalta-se que o princípio de funcionamento do MBES, geralmente, consiste em matrizes de transmissão e recepção que estão direcionadas de forma perpendicular entre si e o cruzamento das ondas acústicas é capaz de fornecer a batimetria (Parnum; Gavrilov, 2011; Pimentel, 2018). Os feixes são resultado de ambas as frentes de ondas que se cruzam. Com isso, para o cálculo da profundidade, a detecção do sinal é dada por fase e amplitude (Pimentel, 2018).

Complementando, os dados batimétricos provenientes do MBES fornecem uma superfície com valores de profundidade para área ensonificada. Em termos de classificação do ambiente oceânico existem outras superfícies que são derivadas da batimetria que podem auxiliar no processo de identificação das feições de interesse, a título de exemplo se tem a inclinação, aspecto e o índice de posição batimétrica (BPI) (Koop; Snellen; Simons, 2021).

Como mencionado anteriormente embora sejam realizadas comparações entre o SAS interferométrico e MBES, tais sensores são tecnologias completares (Saebø; Hansen; Lorentzen, 2015).

4.3.1 Índice de Posição Batimétrica (BPI)

O índice de posição batimétrica (BPI - *Bathymetric Position Index*) é derivado dos dados batimétricos, sendo equivalente no ambiente marinho ao Índice de Posição Topográfica (TPI - *Topographic Position Index*) que é um parâmetro usualmente utilizado para a classificação do terreno (Koop; Snellen; Simons, 2021).

Mogstad et al. (2022) define que:

“Enquanto a profundidade corresponde a posição vertical de uma célula no grid em relação a superfície do mar, os BPIs são calculados com base em análise de vizinhança e indicam a posição batimétrica de uma célula no grid em relação ao seu entorno” (Mogstad et al., 2022, p. 5).

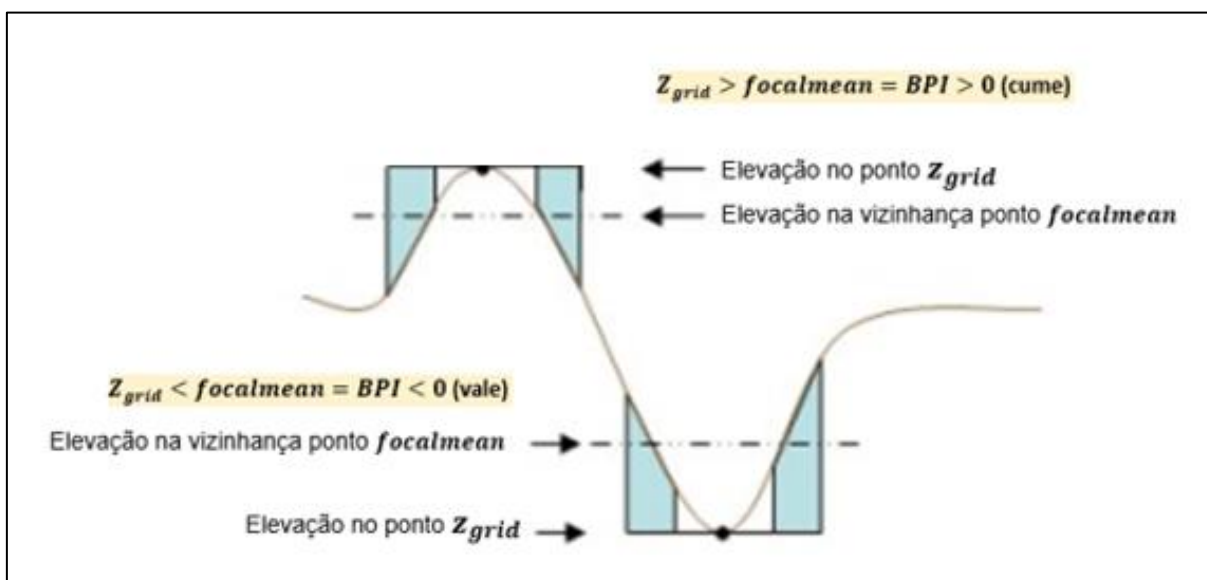
O índice de posição batimétrica, conforme indicado por Summers, Lim e Wheeler (2023), pode ser calculado através da Equação 4.

$$BPI = Z_{grid} - focalmean(Z_{grid}, circle, r) \quad (4)$$

Assim, a variável Z_{grid} corresponde aos valores batimétricos e a $focalmean$ se refere a média focal, que calcula dentro de uma região $circle$, definida por um raio r a média dos dados batimétricos (Summers; Lim; Wheeler, 2023). A camada BPI resultante depende fortemente do raio, quanto maior o valor de r , maior é a vizinhança de análise, sendo as características regionais acentuadas e quanto menor o valor de r , menor é a vizinhança de análise, como consequência as características locais que serão acentuadas (Koop; Snellen; Simons, 2021).

Outra particularidade de destaque apontada por Mogstad et al. (2022) para a superfície do BPI, se refere ao valor das células, em que os valores positivos e negativos indicam, nessa ordem, que são altos e baixos batimétricos, ou seja, denotam as regiões que são mais altas (cristas) e mais baixas (depressões) que seu entorno (Figura 5).

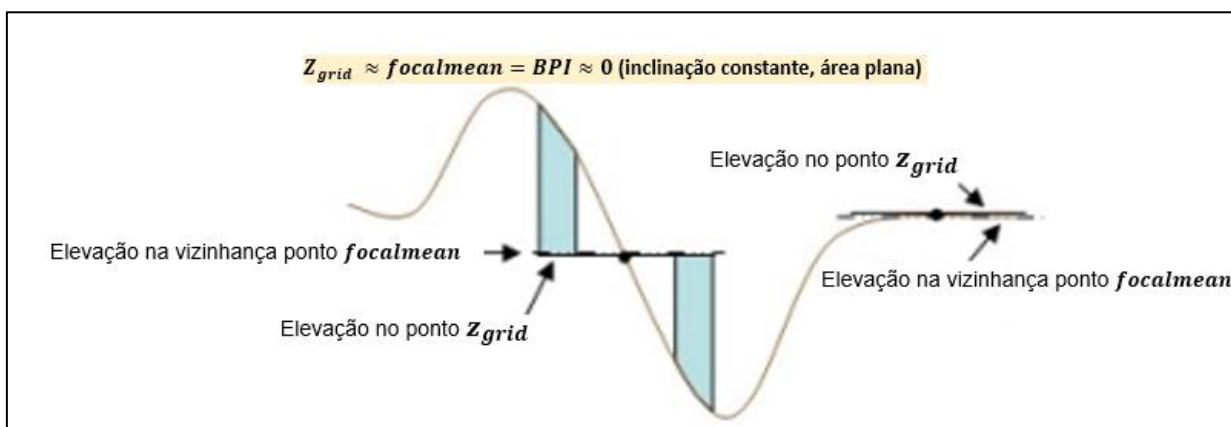
Figura 5 – Representação dos valores positivos e negativos de BPI



Fonte: Adaptado (Weiss, 2001).

Já os valores próximos a zero descrevem as áreas do fundo marinho planas ou áreas constantemente inclinadas, conforme ilustrado na Figura 6.

Figura 6 – Representação dos valores de BPI próximos ou iguais a zero



Fonte: Adaptado (Weiss, 2001).

4.3.2 Inclinação

O parâmetro inclinação, que também é derivado dos dados batimétricos, representa o gradiente de mudança batimétrica de uma célula do *grid*¹ e seus adjacentes em graus (Mogstad et al., 2022).

Segundo Koop, Snellen e Simons (2021) a inclinação pode ser calculada por meio da Equação 5.

$$s = \frac{180}{\pi} \tan^{-1} \left(\sqrt{\left(\frac{dz}{dx}\right)^2 + \left(\frac{dz}{dy}\right)^2} \right) \quad (5)$$

Em que π corresponde ao valor de π e os termos $\left(\frac{dz}{dx}\right)$ e $\left(\frac{dz}{dy}\right)$ se referem respectivamente, a taxa de mudança na superfície das direções na horizontal e vertical, o que determinam a inclinação s , com base na célula central do *grid* (Koop; Snellen; Simons, 2021).

4.4 Classificação automática de imagens

Ramos (2013) salienta que os algoritmos de classificação contribuem de modo direto no processo de classificação, podendo ser definidos simplesmente, como métodos matemáticos. Dentre as diferentes propriedades que são capazes de auxiliar no processo de classificação, as mais empregadas pelos classificadores são a textura dos alvos, tonalidade e cor. Ainda, quando os classificadores dependem do fornecimento de amostras rotuladas por categorias, os resultados da classificação são melhores (Ramos, 2013).

Segundo Oliveira (2011) as técnicas de classificação automática apresentam as seguintes divisões: supervisionada ou não supervisionada, rígidas ou *fuzzy*,

¹ Grid: é um espaço geográfico como uma malha de células quadradas de tamanho idêntico. Cada célula contém um valor numérico que mede um atributo geográfico (como elevação) para aquela unidade de espaço (Câmara, 2001).

paramétricas ou não paramétricas, *pixel a pixel* ou *sub-pixel* e orientada a objetos ou com base no contexto espacial.

A seguir, serão descritos apenas os métodos de classificação de interesse para a pesquisa, caso o intuito seja se aprofundar nesse assunto, consultar os trabalhos de Crósta (1992), Duda, Hart e Stork (1995), Rosa (2013) e Oliveira (2011).

De acordo com Crósta (1992), Duda, Hart e Stork (1995), Rosa (2013) e Oliveira (2011) a definição das classificações supervisionada e não supervisionada estão diretamente ligadas a coleta de amostras, em que no primeiro caso o classificador necessita de amostras rotuladas por categoria pelo especialista sobre a imagem, a partir das quais serão identificados padrões por meio do algoritmo de treinamento de classificação. Crósta (1992), Duda, Hart e Stork (1995), Rosa (2013) e Oliveira (2011) destacam ainda que para definir as amostras de treinamento é necessário o conhecimento prévio por parte do especialista, seja ele teórico ou prático da região de interesse. Já o segundo método, as amostras não são rotuladas, ou seja, a categoria não é informada, e o algoritmo classificador por si só tem a capacidade de realizar o agrupamento dos pixels e identificação das classes. Tal classificação é geralmente empregada quando a coleta e rotulagem de um grande conjunto de dados, torna o processo extremamente caro (Duda; Hart; Stork, 1995).

Diante do exposto, a classificação *pixel a pixel*, emprega somente as informações espectrais de cada célula, pode ser supervisionada ou não supervisionada e além disso, paramétrica ou não paramétrica. Em relação aos últimos métodos, como exemplo se tem os classificadores de máxima verossimilhança e as árvores de decisão (Ramos, 2013; Oliveira, 2011).

Em paralelo, a classificação por objetos, não somente aplica a informação espectral, mas também a relação espacial entre o *pixel* e sua vizinhança. Outro ponto de destaque para a classificação orientada a objetos é que podem ser empregadas outras características da imagem, na decisão de classificação como por exemplo o tamanho, a forma, entre outras. Diferentemente, do classificador anterior, primeiramente é preciso aplicar uma outra técnica para segmentar os dados para depois realizar a classificação (Ramos, 2013; Oliveira, 2011).

4.4.1 Análise de Imagem Baseada em Objetos e Segmentação

A abordagem da Análise de Imagem Baseada em Objetos (OBIA, em inglês) é um tipo de classificador por objetos que, como descrito anteriormente, se baseia em regiões, que são agrupamentos de *pixels* (Koop; Snellen; Simons, 2021). Assim sendo, o primeiro passo para aplicar o OBIA é a segmentação, a qual subdivide a imagem em objetos constituintes, recomenda-se que a divisão dos polígonos ocorra até que sejam isolados os objetos de interesse (Wiggers; Ribeiro, 2015).

De acordo com Koop, Snellen e Simons (2021) em OBIA um algoritmo de segmentação comumente empregado é o *multiresolution segmentation*, o qual considera inicialmente um objeto de imagem, como sendo cada *pixel* da imagem. Assim, de forma iterativa, os objetos de imagem vizinhos são mesclados resultando em objetos de imagem maiores, com base no critério de homogeneidade. Essa homogeneidade é considerada sinônimo de heterogeneidade minimizada e leva em consideração os critérios espectrais e de forma, sendo dada pela Equação 6.

$$\Delta h = W_c \Delta h_c + W_s \Delta h_s \quad (6)$$

A Equação 6 demonstra que a mudança de heterogeneidade Δh é obtida por meio da cor c e a forma s , uma vez que $W_c \Delta h_c$ se refere aos pesos especificados pelo usuário ($W_c + W_s = 1$ ou $0 \leq W_c, W_s \leq 1$) e a variação de mudança de heterogeneidade de cor e forma, respectivamente (Benz et al., 2004; Koop; Snellen; Simons, 2021).

Em síntese, para cada *loop*² do algoritmo os objetos imagem criados são inspecionados uma vez. A partir disso, os objetos imagem e seus vizinhos só são mesclados se o Δh for mínimo, o que é indicado como parâmetro de melhor ajuste. Tal busca para mesclar os objetos se encerra quando nenhum outro objeto pode ser mesclado, considerando o Δh que é limitado por um valor mínimo determinado pelo usuário, através do parâmetro de escala (SP) (Benz et al., 2004; Trimble, 2014; Koop; Snellen; Simons, 2021).

² Loop: é um conjunto de instruções que se repetem até que uma condição encerre o processo.

Diante disso, o parâmetro de escala determina a heterogeneidade máxima permitida para os objetos de imagem resultantes, em que valores mais altos e mais baixos para o SP resultam em objetos maiores e menores, respectivamente (Trimble, 2014). Outros parâmetros são aplicados no algoritmo de segmentação *multiresolution segmentation*, sendo eles o peso (*weights*), a forma (*shape*) e a compactidade (*compactness*). O primeiro deles permite uma ponderação nas camadas de uma imagem, ou seja, quanto maior o peso atribuído a uma camada da imagem, maior relevância terá as informações dos *pixels* dessa camada durante o processo de segmentação. Já o segundo, altera a relação entre os critérios de forma e cor, isso porque ao diminuir ou aumentar o campo forma é definida proporcionalmente a porcentagem dos valores espectrais da camada imagem que vão contribuir para a homogeneidade. E por último a compactidade que se refere a otimização da compactação dos objetos da imagem (Trimble, 2014).

4.4.2 *Random Forest*

Devido à grande quantidade de dados produzidos nos levantamentos hidrográficos, tem-se utilizado do emprego de algoritmos de classificação para a extração de informações do fundo marinho que auxiliem na tomada de decisão. O *Random Forest (RF)* é um dos algoritmos de aprendizado de máquina que vem cada vez mais sendo utilizado por apresentar características que facilitam a sua aplicação, como a configuração de poucos parâmetros e boa acurácia (Paiva, 2020).

O *Random Forest* se baseia no método de árvores de decisão para realizar a classificação dos alvos de interesse. A árvore de decisão é uma estrutura de dados em que um nó de decisão contém algum teste sobre determinado atributo e para cada resultado existe um ramo, ao final são obtidas as distribuições das classes (Fernandes, 2018).

Mogstad et al. (2022) explica que a partir de amostras aleatórias pertencentes a base de dados e definidas como dados de treinamento são criadas as árvores de decisão. Usualmente os dados de treinamento contém uma variável categórica (classe) e as variáveis explicativas (preditores) na classificação. Assim, com o modelo RF treinado é possível classificar toda a base de dados, em que as árvores

de decisão de forma individual votam na classe mais provável de uma amostra se baseando nos valores dos preditores. Ao final a amostra pode receber a classificação de duas formas a partir do agrupamento dos votos e o resultado é a classe que obteve maior valor ou pelo usuário que define um valor probabilístico de corte.

James et al. (2013) reforça que no *Random Forest* são construídas diversas árvores de decisão com base nas amostras de treinamento. Assim, cada vez que a divisão em uma árvore é considerada, uma amostra aleatória de m preditores é escolhido como candidato, dentre um conjunto de p preditores. O número de m preditores é aproximadamente igual a raiz quadrada do número total de preditores. Ainda ao selecionar os preditores de forma aleatória se tem uma menor correlação entre as árvores o que torna a média das árvores resultantes menos variável e, portanto, mais confiável.

Assim, por meio de amostras representativas dos fenômenos de interesses, após o treinamento do classificador, o algoritmo identifica uma ou várias classes.

Mogstad et al. (2022) evidencia que na identificação de estruturas de corais o algoritmo RF é uma escolha viável por fornecer resultados satisfatórios em outras pesquisas do mesmo seguimento, além de ter a capacidade de criar o modelo proveniente de variáveis com distribuição irregular e preditores correlacionados.

4.5 Métricas baseadas na matriz confusão para avaliação dos modelos de classificação

Avaliar o modelo empregado para aferir a qualidade dos resultados encontrados é de extrema importância, e dentre os diferentes métodos que podem ser aplicados para a avaliação da qualidade preditiva de um classificador na identificação de corais em imagens de SAS, podem ser consideradas as medidas de sensibilidade, especificidade e acurácia (Sture et al., 2018).

Franceschi (2019) pontua que normalmente a acurácia temática é a métrica aplicada para avaliar e selecionar modelos de classificação, por meio da estimativa

de um conjunto de teste, pelo fato de que esse critério busca a probabilidade de erro global menor.

Entretanto, a distinção dos erros ou acertos encontrados em cada classe é uma das formas mais eficazes de avaliação. Para isso se tem a matriz confusão ou matriz erro que indica a relação entre os dados reais e os valores preditos pelo modelo.

Pagano et al. (2023) explica que de forma geral a matriz confusão indica as predições corretas do modelo que são os verdadeiros positivos (VP) e verdadeiros negativos (VN). E os erros cometidos pelo modelo são representados pelos falsos positivos e negativos (FP e FN), respectivamente. Tais valores são obtidos, considerando os acertos e erros da previsão do modelo em relação a referência.

Pagano et al. (2023) também evidencia que quando a intenção é avaliar multiclass, são considerados os valores de cada classe individualmente (Tabela 1).

Tabela 1 – Matriz confusão ou matriz erro para Classe A

		Classes de referência		
		Classe A	Classe B	Classe C
Classes preditas	Classe A	Verdadeiro Positivo (VP)	Falso Positivo (FP)	Falso Positivo (FP)
	Classe B	Falso Negativo (FN)	Verdadeiro Negativo (VN)	Verdadeiro Negativo (VN)
	Classe C	Falso Negativo (FN)	Verdadeiro Negativo (VN)	Verdadeiro Negativo (VN)

Fonte: Adaptado Pagano et al. (2023).

A Tabela 1 ilustra os valores calculados para a Classe A, em que VP corresponde a predição correta, VN se refere a soma das classes sem a Classe A tanto na predição quanto na referência. Já o FN representa a soma das classes que deveriam ser previstas como Classe A, mas foram previstas como outras classes e o

FP indica as classes previstas erroneamente como Classe A. Tal processo é repetido para as demais classes (Pagano et al., 2023).

Diante do exposto, as métricas estatísticas também são definidas de acordo com as medidas descritas anteriormente. Sendo assim, para as classes (A, B e C), cada métrica é calculada individualmente, as quais fornecem através da média, as métricas de desempenho do modelo Pagano et al. (2023).

A primeira métrica a ser descrita é a sensibilidade, ou Taxa de Verdadeiros Positivos (TVP) que corresponde a proporção dos resultados corretamente classificados como positivos no modelo, ou seja, de todos os padrões que são positivos qual percentual é identificado corretamente pelo modelo (Equação 7) (Fahmy, 2023).

$$Sensibilidade_A \text{ ou } TVP_A = \frac{VP_{classe A}}{VP_{classe A} + FN_{classe A}} \quad (7)$$

Já a especificidade ou Taxa de Verdadeiros Negativos (TVN), representa a proporção de negativos corretamente classificados (Equação 8) (Fahmy, 2023).

$$Especificidade_A \text{ ou } TVN_A = \frac{VN_{classe A}}{VN_{classe A} + FP_{classe A}} \quad (8)$$

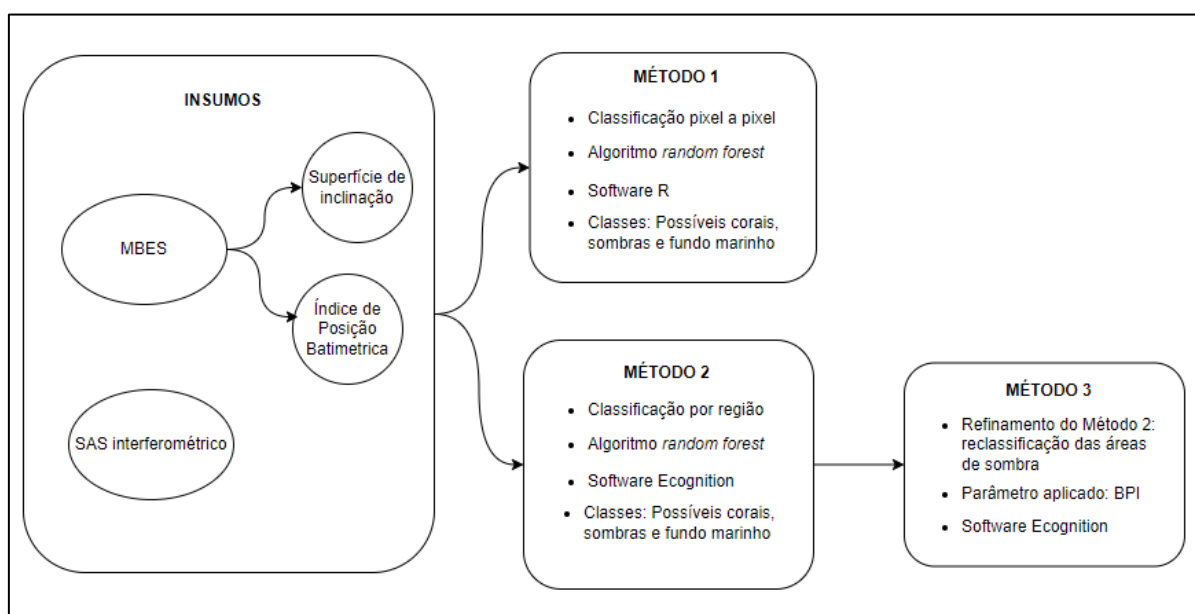
Por fim, a acurácia corresponde a habilidade do modelo de calcular o percentual de classificação correta (Equação 9), em que o termo N se refere ao número total de amostras (Fahmy, 2023).

$$Acurácia \text{ ou } ACC = \frac{VP_{classe A} + VP_{classe B} + VP_{classe C}}{N} \quad (9)$$

5 METODOLOGIA

A metodologia empregada na pesquisa é apresentada no fluxograma da Figura 7. Em resumo para a classificação dos alvos de interesse (possíveis corais, sombra e fundo marinho) com os dados de MBES são obtidas as derivadas batimétricas por meio do *ArcGis* versão 10.5 que em conjunto com o SAS interferométrico, correspondem aos insumos de entrada nas rotinas de processamento. Sendo que o método 1 aplica a abordagem de classificação *pixel a pixel* no *software* estatístico *R* versão 1.4.1717 e os métodos 2 e 3 a Análise de Imagem Baseada em Objetos (OBIA, em inglês) no *eCoginiton* versão 9.0.1. Ressalta-se que nos três métodos mencionados o algoritmo utilizado é o *Random Forest*.

Figura 7 – Resumo da metodologia aplicada



Fonte: Elaboração própria.

Adiante são detalhadas a área de estudo e as principais regras e procedimentos executados no decorrer da pesquisa.


5.1 Área de estudo

Para o presente estudo, todos os dados utilizados, foram fornecidos pela companhia brasileira PETROBRÁS S.A. Os insumos são provenientes de um levantamento hidrográfico com AUV, realizado em território nacional, com os sensores HISAS 1030 (SAS interferométrico) e EM 2040 (Ecobatímetro multifeixe).

Dentre os diferentes produtos que podem ser obtidos com os sensores mencionados anteriormente, optou-se por usar as imagens SAS que permite uma interpretação visual dos alvos de interesse e a batimetria multifeixe, visto que comparada a batimetria interferométrica apresenta melhor desempenho.

Diante do exposto, para a aplicação das três metodologias propostas os insumos base empregados foram os mesmos: mosaico de SAS interferométrico e mosaico de batimetria multifeixe. A Figura 8, que será denominada de Mosaico 1, ilustra os dados provenientes do sensor HISAS 1030, imagem (RGB), dimensões de (500 x 500 metros) e resolução (0,65 x 0,65 metros).


Figura 8 – Mosaico 1, composto por imagens processadas de SAS interferométrico



Fonte: Companhia brasileira PETROBRÁS S.A.

Em seguida, a Figura 9 representa a mesma região do Mosaico 1, mas referente aos dados batimétricos, nomeado como Mosaico 2, com dimensões (500 x 500 metros) e resolução de 1 x 1 metro.

Figura 9 – Mosaico 2, composto por imagens processadas de MBES



Fonte: Companhia brasileira PETROBRÁS S.A.

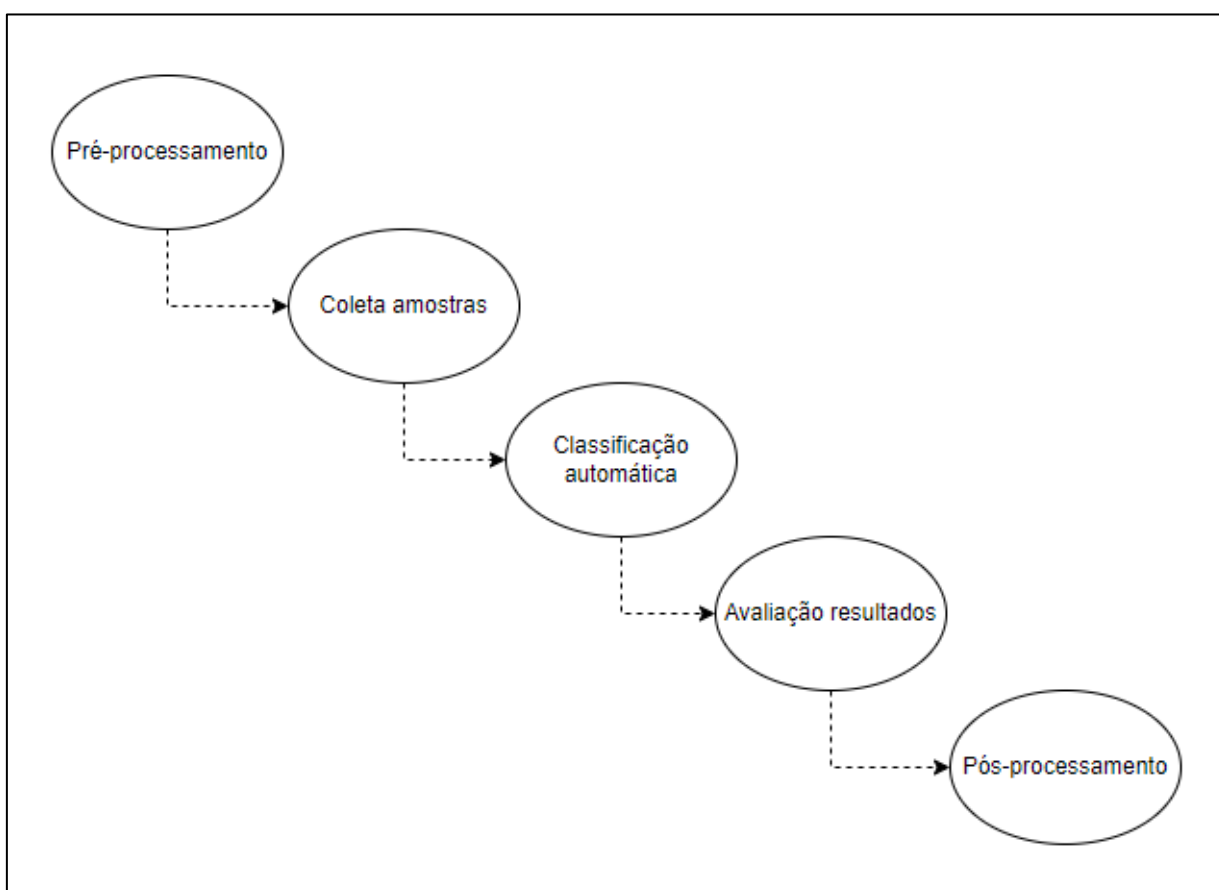
Em suma, o Mosaico 1 permite claramente uma interpretação visual das feições e o Mosaico 2 fornece informações sobre as características batimétricas do fundo marinho.

Além das informações destacadas anteriormente, vale frisar que para determinar se uma feição natural do fundo marinho é um recife de coral é necessário o conhecimento biológico das espécies. Diante disso, o trabalho propõe a identificação das possíveis áreas de corais, ou seja, a determinação das feições naturais do ambiente marinho, que visualmente apresentam características (alta refletividade, contorno levemente arredondado e textura semelhante a uma couve flor) de áreas sensíveis. A partir da delimitação dessas áreas os especialistas podem realizar as análises biológicas e determinar se de fato são corais ou não.

5.2 Método 1: Classificação das possíveis áreas de corais

O método 1 consiste em classificar as possíveis áreas de corais em águas profundas, por meio do classificador *Random Forest* em uma classificação do tipo *pixel a pixel* e supervisionada. A fim de elucidar as diferentes etapas aplicadas no método 1, um fluxograma de rotina é apresentado na Figura 10.

Figura 10 – Método 1, aplicado para classificação de possíveis corais, com os insumos base Mosaicos 1 e 2



Fonte: Elaboração própria.

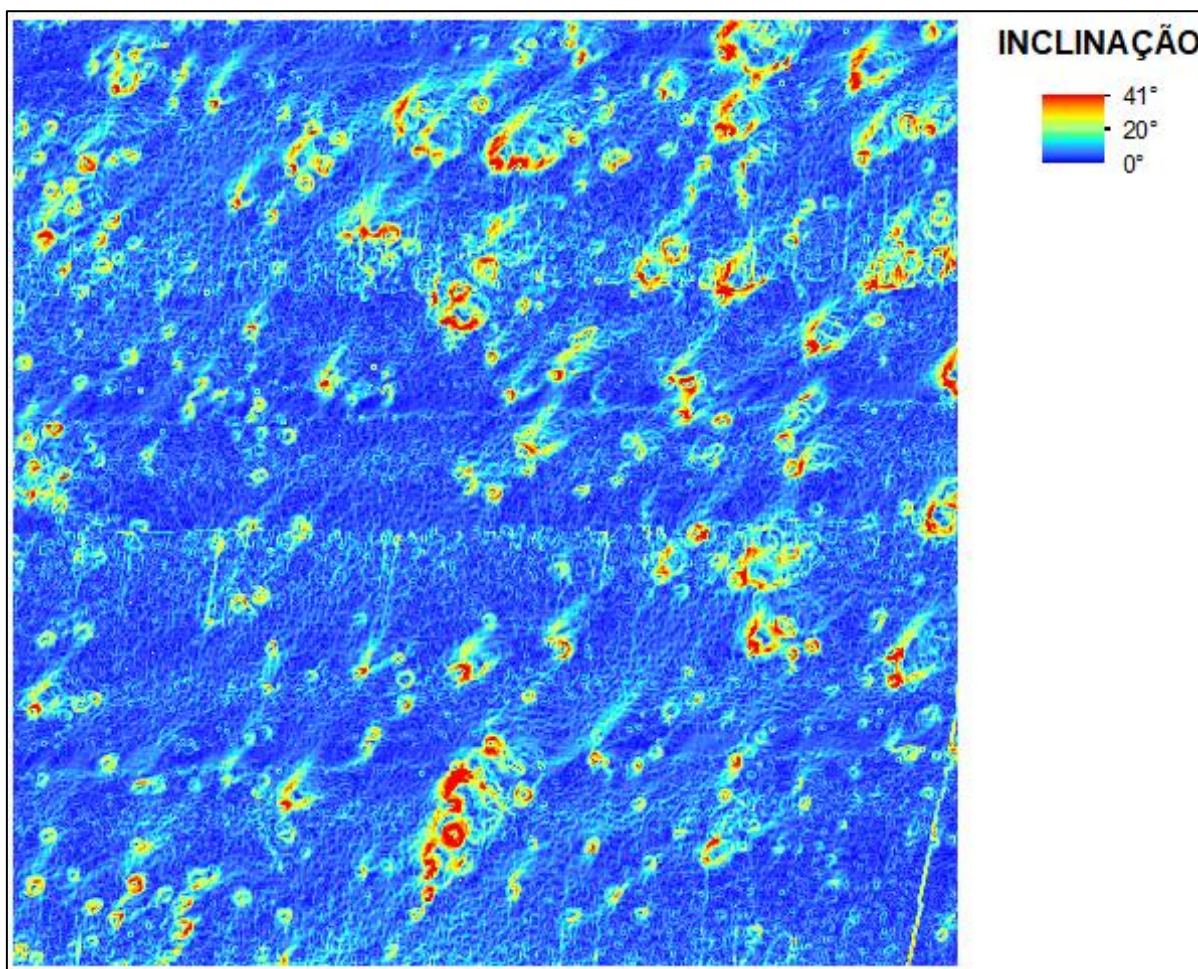
5.2.1 Pré-processamento

Nesta etapa, executou-se alguns procedimentos que auxiliaram no processo de classificação, sendo o primeiro deles o georreferenciamento entre o Mosaico 1 e

Mosaico 2, uma vez que possíveis deslocamentos espaciais dentre os dados influenciam diretamente na distinção dos alvos.

Prosseguindo, gerou-se as derivadas batimétricas, ou seja, as superfícies de inclinação e o Índice de Posição Batimétrica (BPI, em inglês). Para obtenção do modelo de inclinação (SI), a ferramenta *Slope* foi aplicada e configurada para unidade graus (Figura 11).

Figura 11 – Superfície de inclinação (SI) gerada




Fonte: Elaboração própria.

Já para a superfície BPI se empregou a função estatística *Focalmean* para determinar a média focal dos dados batimétricos, tendo como entrada o Mosaico 2 e o raio adotado de 5 metros. Isso porque, após inspeção visual dos alvos de interesse no Mosaico 1, notou-se que para a região de estudo, os possíveis corais em sua maioria apresentam dimensões menores que 5 metros e como exposto

anteriormente raios pequenos acentuam as características locais de uma área. A partir disso, se realizou uma subtração entre o Mosaico 2 e a superfície BPI criada, com a ferramenta *Minus* para a obtenção do modelo final BPI_{5m} (Figura 12).

Figura 12 – Superfície BPI com raio de 5 metros (BPI_{5m}) gerada



Fonte: Elaboração própria.

5.2.2 Coleta de amostras

A definição das classes temáticas empregadas, teve como referência a interpretação visual do Mosaico 1, sendo possível identificar três tipos diferentes de classes: fundo marinho, possíveis corais e áreas de sombra. O número de pontos amostrais coletados em relação ao insumo disponível está descrito na Tabela 2.

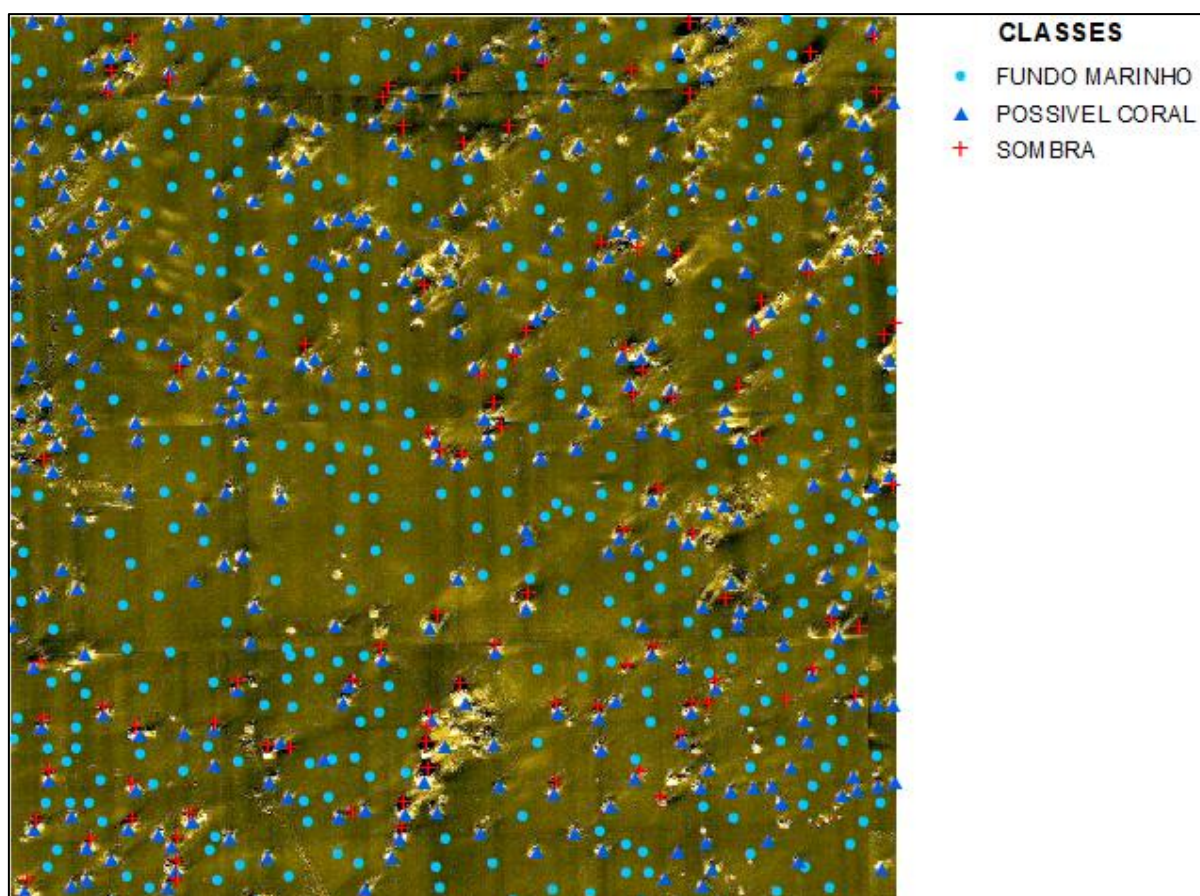
Tabela 2 – Classes e número de pontos amostrais coletados por classes

Classe	Nº amostras coletadas
Fundo marinho	350
Possível coral	350
Sombra	99

Fonte: Elaboração própria.

A Figura 13 indica as classes amostrais identificadas no Mosaico 1 com base no conhecimento do analista. Para isso, criou-se um arquivo *shapefile* no formato de ponto, com a descrição das classes na tabela de atributos: fundo marinho, possível coral e sombra, bem como os identificadores numéricos únicos 1, 2 e 3 para cada classe respectivamente.

Figura 13 – Identificação no Mosaico 1, dos temas das três classes



Fonte: Elaboração própria.

Salienta-se que o Mosaico 1 foi escolhido para a coleta das amostras, porque é o insumo que permite a identificação e interpretação das feições de forma mais clara.

5.2.3 Classificação automática

Após a execução das etapas anteriores foram obtidos os insumos: Mosaico 1, Mosaico 2, a superfície de inclinação, a superfície BPI e o *shapefile* amostral. Com isso, a partir do *software estatístico R* um modelo de aplicação para o classificador *Random Forest* é desenvolvido no formato de *script*. O parâmetro *mtry* que se refere ao número de variáveis foi definido através da função *tuneRF* que fornece a porcentagem de erro para as combinações possíveis das variáveis, associado ao número de árvores *ntree*. A base de dados teve o particionamento dividido em 70% para treinamento e 30% para teste. A síntese de todos os parâmetros aplicados no modelo, são descritos na Tabela 3.

Tabela 3 – Configuração dos parâmetros aplicados no modelo *Random Forest*

Modelo	mtry	ntree	importance	base dados
Classes				
Mosaico 1 (Banda 1)				
Mosaico 1 (Banda 2)				
Mosaico 1 (Banda 3)	2	1000	<i>true</i>	70%
Mosaico 2 (Profundidade)				treinamento
Superfície de inclinação (SI)				
Superfície BPI _{5m}				

Fonte: Elaboração própria.

Prosseguindo, sobre os dados de treinamento é executado o classificador *Random Forest*. Com o algoritmo treinado, o modelo é aplicado no conjunto de dados separados para teste, em cima dos quais a análise preditiva é realizada. Por fim, o algoritmo é empregado sobre toda a imagem, fornecendo assim o resultado da classificação.

5.2.4 Avaliação dos resultados

Houve duas abordagens aplicadas para a avaliação dos resultados. A primeira começa com a aplicação do modelo treinado sobre os dados de teste (30% da base de dados) por meio da função *predict*. Com o resultado é obtida a matriz confusão para avaliação da acurácia temática e demais parâmetros.

A segunda abordagem aplicada refere-se à tabulação cruzada, em que é realizada uma comparação *pixel a pixel* entre uma imagem de referência (interpretação e vetorização das classes de forma manual, baseada no conhecimento do especialista) e a imagem resultante da classificação automática. Para isso, aplicou-se a ferramenta *tabulate area* fornecida no pacote *Spatial Analyst* do *ArcGis*. Destaque-se que a região onde ocorreu a comparação apresenta dimensões (100 x 150) metros.

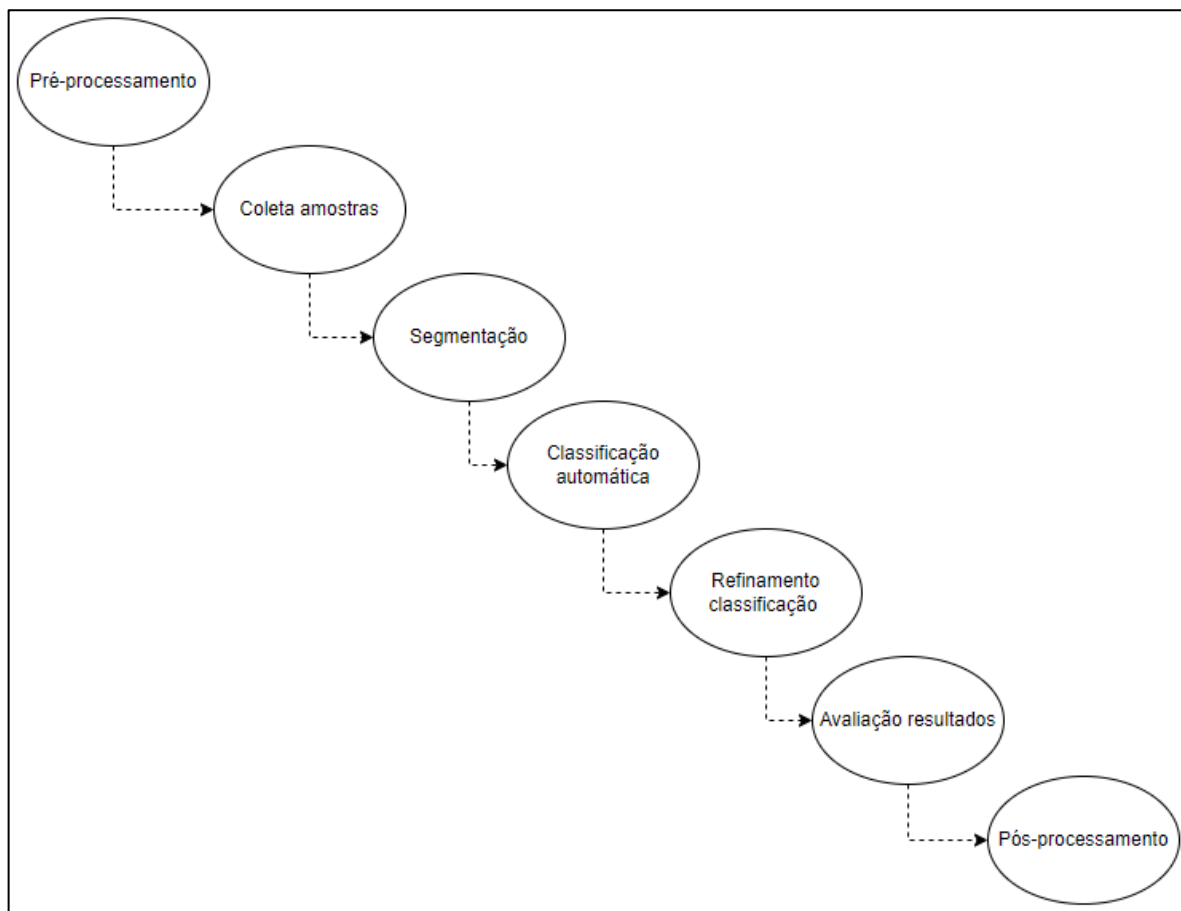
5.2.5 Pós-processamento

A fim de aprimorar o resultado da classificação, através do *software ArcGis*, a imagem *raster* final com as três classes é transformada em polígonos no formato *shapefile*, por meio da ferramenta *raster to polygon*, na sequência as geometrias são mescladas por classes através da função *dissolve*. Prosseguindo com a suavização dos contornos para a classe de possíveis corais.

5.3 Método 2: Classificação das possíveis áreas de corais

O método 2, consiste em classificar as possíveis áreas de corais em águas profundas, por meio dos *softwares ArcGis* versão 10.5 e *eCognition* versão 9.0.1, com auxílio do classificador *Random Forest* em abordagem supervisionada e por objetos (OBIA, em inglês). Na Figura 14 são indicados os passos aplicados no desenvolvimento dessa metodologia.

Figura 14 – Método 2, aplicado para classificação de possíveis corais, com os insumos base Mosaicos 1 e 2



Fonte: Elaboração própria.

De acordo com a Figura 14 percebe-se que para o método 2 mais etapas foram empregadas. No entanto, a metodologia aplicada no método 1 para as fases de pré-processamento e coleta de amostras é a mesma que a do método 2. Por esse motivo, a exposição do método 2 começa no item segmentação. Salienta-se ainda, que todos os processos descritos em sequência foram realizados no *software eCognition*.

5.3.1 Segmentação

Para o processo de segmentação, o algoritmo *multiresolution segmentation* foi aplicado considerando apenas as três bandas do Mosaico 1, visto que é o mesmo insumo utilizado no método 1 para a coleta das amostras, isso porque permite a

identificação e interpretação visual das classes. A Tabela 4, indica os valores dos parâmetros empregados.

Tabela 4 – Configuração dos parâmetros do algoritmo *multiresolution segmentation*

Insumos	Weights	Sp	Shape	Compactness
Mosaico 1 (Banda 1)	1			
Mosaico 1 (Banda 2)	1			
Mosaico 1 (Banda 3)	1	8	0,1	0,9
Mosaico 2 (Profundidade)	0			
Superfície de inclinação (SI)	0			
Superfície BPI _{5m}	0			

Fonte: Elaboração própria.

Conforme Tabela 4, todas as bandas do Mosaico 1 receberam o mesmo peso (weights). A definição dos valores de parâmetro de escala (Sp), Forma (*Shape*) e compactidade (*Compactness*) conseguiram isolar os objetos de interesse, possíveis corais, sombra e fundo marinho.

5.3.2 Classificação automática

Cada amostra coletada (*shapefile* das amostras), bem como sua descrição são associadas aos objetos correspondentes da segmentação com a função *assign class by thematic layer*. Na sequência, todos os objetos que receberam a identificação são transformados em amostras com a ferramenta *classified image object to samples*. Após esses processos se tem as amostras em formato de objetos.

Em seguida o modelo é treinado com o algoritmo *classifier* através do classificador *Random Trees*, operação *train*, sendo a entrada de dados todos os insumos disponíveis (Mosaico 1, Mosaico 2, a superfície de inclinação e a superfície BPI), conforme o modelo do método 1. Na sequência, o modelo é aplicado para toda imagem com a ferramenta *classifier* e operação do tipo *apply*.

5.3.3 Refinamento do modelo

A análise de imagem baseada em objetos (OBIA, em inglês) possibilita que outras características das imagens sejam aplicadas no processo de classificação. Dentre elas uma medida fornecida pelo software empregado é o brilho, que é obtido através da distribuição de intensidade dos valores positivos médios fornecidos pelas camadas RGB de uma imagem. Posto isto, com a intenção de remover a confusão entre as classes de possíveis corais (alta refletividade) e fundo marinho o preditor (brilho) é adicionado ao modelo *Random Trees* para um novo treinamento do classificador.

Ao reclassificar a imagem com o modelo alterado, através da função *select features to display*, as estatísticas de cada objeto são geradas: os valores médios de todos os insumos. A partir disso, com a função *assign class* se estabelece a condição que todos os objetos classificados como sombra e que possuem valor de brilho maior ou igual a 50 se tornam fundo marinho. Isso porque ao avaliar as estatísticas encontradas para cada objeto notou-se que os polígonos classificados como fundo marinho em sua maioria apresentaram valor de brilho superior a 50.

5.3.4 Avaliação dos resultados

A avaliação dos resultados foi obtida a partir da matriz confusão baseada nas amostras, através da função *accuracy assessment*. Para complementar a verificação dos resultados conforme o método 1, a validação de comparação entre os *pixels* de uma imagem de referência (interpretação e vetorização manual) e imagem resultante da classificação automática também é empregada, com auxílio da ferramenta *tabule área* do *ArcGis*. Vale frisar que a região verificada corresponde ao mesmo local do método 1.

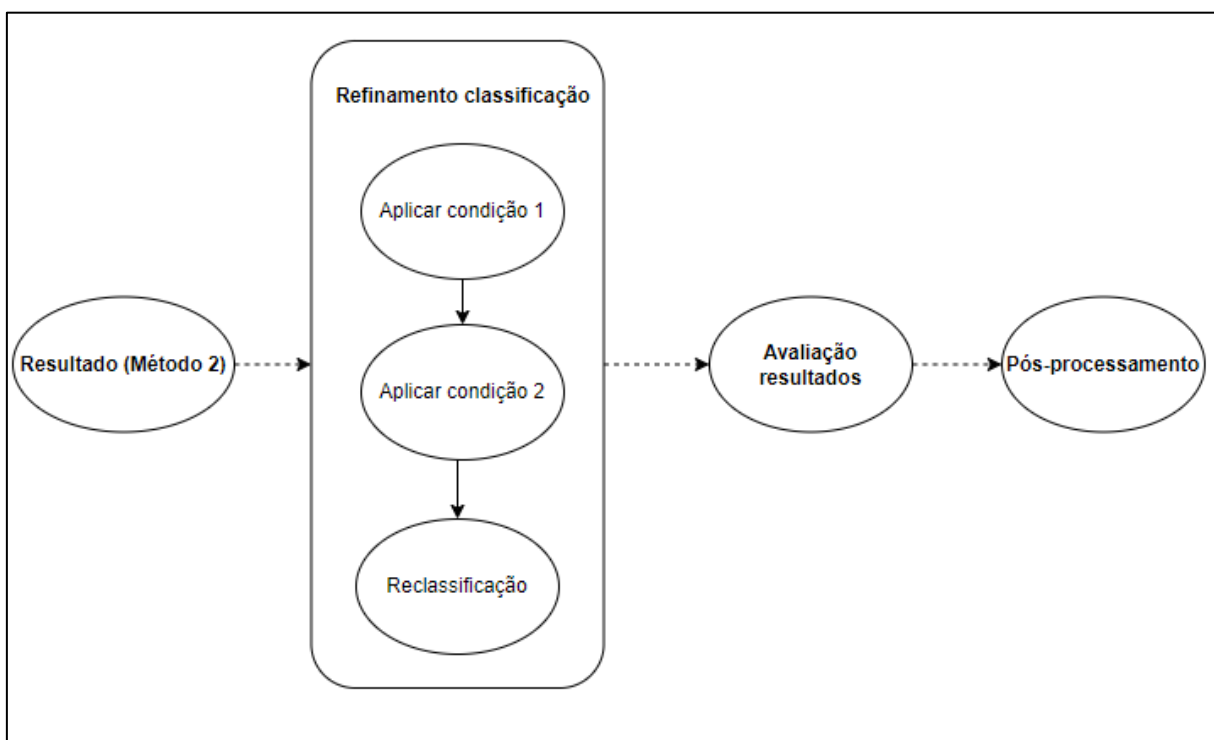
5.3.5 Pós-processamento

Com o resultado da classificação automática são acrescentadas as operações de união dos polígonos que são vizinhos e possuem a mesma classe com a função *merge region*, bem como a suavização do contorno das feições com o algoritmo *pixel-based object resizing*, ambos processos realizados no *eCognition*.

5.4 Método 3: Refinamento da classificação

O método 3 corresponde ao refinamento do método 2, em que é estabelecida uma relação entre as áreas de possíveis corais e sombra, com ajuda do parâmetro de inclinação batimétrica, através dos *softwares ArcGis* versão 10.5 e *eCognition* versão 9.0.1. Abaixo, o fluxograma (Figura 15) indica as etapas desenvolvidas no método 3.

Figura 15 – Método 3, empregado a partir da classificação automática do método 2, para determinar a relação entre possíveis corais e sombra



Fonte: Elaboração própria.

5.4.1 Refinamento da classificação

A partir do resultado da classificação do método 2, conforme esperado são encontradas as três classes: possíveis corais, fundo marinho e sombra. Entretanto, a classe sombra é uma particularidade visualizada no Mosaico 1 devido alguns parâmetros comumente inexatos do levantamento, a qual não é inerente ao fundo marinho.

Considerando o panorama de classificação das possíveis áreas de corais de forma manual sobre o Mosaico 1, o especialista ao delimitar o polígono dessa classe deve tomar uma decisão de incluir ou remover as sombras associadas aos alvos. Tanto incluir como excluir a área de sombra dos polígonos referentes aos possíveis corais acaba superestimando ou subestimando as dimensões da classe.

Assim, a partir da definição do Índice de Posição Batimétrica tem-se que $BPI > 0$, corresponde a altos batimétricos. Portanto, os polígonos que apresentam valores de BPI maiores que 0, representam as cristas. Diante disso, a hipótese inferida é que os polígonos classificados como sombra que tem o valor de $BPI > 0$ e são vizinhos dos polígonos de possíveis corais com $BPI > 0$, são na verdade fortes candidatos a serem regiões de possíveis corais.

Perante o exposto, com o algoritmo *assign class* foram delimitadas as duas condições para os alvos de interesse da reclassificação. A primeira delas foi separar todos os objetos classificados com possível coral com valores de $BPI > 0$ e a segunda condição buscou todos os objetos da classe sombra com $BPI > 0$ e vizinhos (polígonos que estavam lado a lado tendo pelo menos 1 *pixel* adjacente) dos alvos identificados na condição 1. Tais objetos resultantes das premissas estabelecidas na etapa anterior foram reclassificados, passando da classe sombra para a classe possível coral.

5.4.2 Avaliação dos resultados


Neste caso em específico a avaliação dos resultados, se concentra em determinar se os objetos que passaram da classe sombra para possível coral, com a

definição das condicionantes, apresentam potencial, ou seja, se são positivos/confiáveis para serem empregues.

Conforme descrito anteriormente devido a geometria das imagens de SAS interferométrico a bordo do AUV, ocorrem passadas repetidas. Sendo assim, na confecção do mosaico existem imagens em diferentes sentidos que correspondem a mesma região. E para a composição do mosaico, é escolhida apenas uma passada para o recobrimento da área. As imagens escolhidas, nem sempre são as de melhor qualidade, tal fato está associado ao grande volume de dados. Portanto, é comum mosaicos, que representam grandes áreas, com a presença de artefatos que não são inerentes ao fundo marinho, como ruído ou sombra.

Considerando o cenário descrito, constatou-se que o Mosaico 1 contém regiões de sombra. Entretanto, ao avaliar individualmente todo o pacote de imagens que foram coletadas para área (em diferentes sentidos) encontrou-se uma imagem que não foi utilizada na composição do mosaico, em que especificamente naquela região, os possíveis alvos de corais, não estão associados a sombras, essa imagem será denominada de Linha individual 1. A Figura 16 evidência a diferença entre a Linha individual 1 e Mosaico 1, para os alvos em relação a sombras.

Figura 16 – Representação parcial da Linha individual 1 (esquerda) e Mosaico 1 (direita) para a mesma região



Fonte: Companhia brasileira PETROBRÁS S.A.

Diante do exposto, a validação dos resultados também se baseou na tabulação cruzada, as únicas diferenças entre as rotinas anteriores, se concentram

na imagem de referência que passa a ser a Linha individual 1 e não mais o Mosaico 1, para a interpretação e vetorização manual, bem como a classe de interesse que fica sendo apenas os possíveis corais. Mais especificamente foi comparado, os possíveis corais visualizados na Linha individual 1 com os objetos que tinham a classificação de sombra e passaram a ser identificados como possíveis corais com o emprego das condicionantes.

5.4.3 Pós-processamento

Nesta etapa, se aplica as ferramentas *merge region* e *pixel-based object resizing*, cuja funcionalidade corresponde unificar os objetos de mesma classe e suavizar a borda dos polígonos, respectivamente.

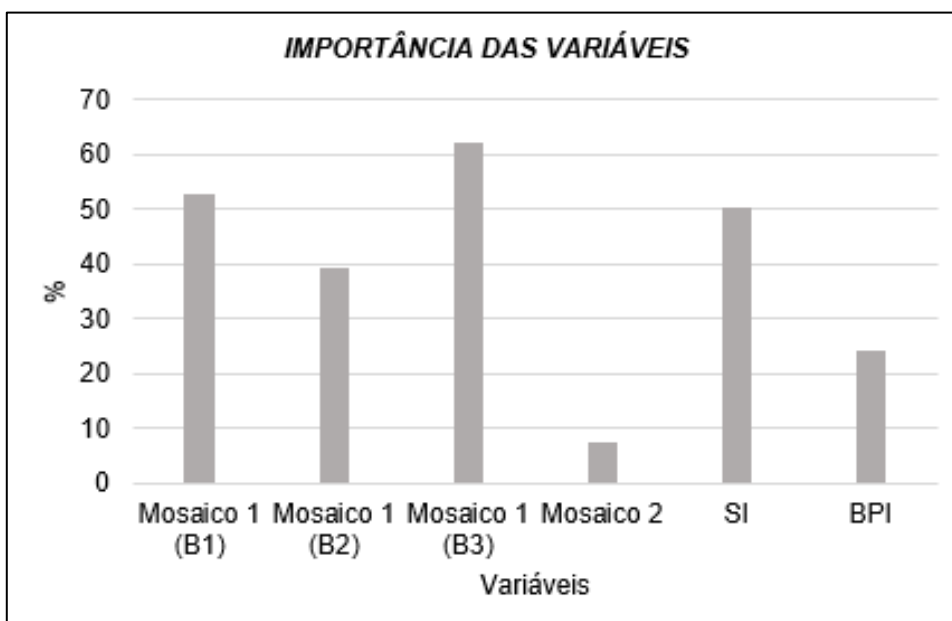
6 RESULTADOS E DISCUSSÕES

Dos resultados apresentados neste capítulo, vale salientar que apenas os mais significativos são ilustrados, tendo em vista que foram realizados diversos testes em cada metodologia proposta, através da alteração no arranjo dos parâmetros utilizados na configuração dos modelos, a fim de avaliar sua influência no processo de classificação, bem como o desempenho em termos de resultado de cada método.

6.1 Resultados obtidos com o Método 1

No processo de classificação foram consideradas seis variáveis (mosaico de SAS interferométrico em três bandas, mosaico MBES, superfície de inclinação e a superfície do índice de posição batimétrica) para compor as árvores de decisão. A importância de cada uma, em porcentagem, consta no Gráfico 1.

Gráfico 1 – Importância das variáveis em porcentagem para o modelo



Fonte: Elaboração própria.

Nota-se no Gráfico 1 que a variável Mosaico 1 (B3) no processo de predição apresentou maior relevância e que os valores de profundidade tiveram uma menor contribuição. Ainda, para avaliar a acurácia do modelo obteve-se outras métricas, através da matriz confusão, Tabela 5.

Tabela 5 – Matriz confusão baseada nas amostras de teste

		Referência			
		Fundo marinho	Possível coral	Sombra	Total
Predição	Fundo marinho	101	2	2	105
	Possível coral	1	102	1	104
	Sombra	3	1	26	30
	Total	105	105	29	239
Sensibilidade _{modelo}					94,33%
Especificidade _{modelo}					97,87%
Acurácia _{modelo}					95,82%

Fonte: Elaboração própria.

Considerando a Tabela 5 o valor total de 239 corresponde a 30% das 799 amostras da base de dados que foram destinadas para teste. A sensibilidade de 94,33 % indica os *pixels* das classes de interesse identificados corretamente e a especificidade de 97,87% destaca o contrário, ou seja, os valores não positivos classificados de forma correta. Percebe-se ainda que o modelo em geral apresenta uma acurácia de 95,82% o que representa a porcentagem de acertos do modelo. Outra informação relevante se concentra no erro de predição na classe possível coral, que se confundiu com fundo marinho e sombra. Isso é um ponto negativo do modelo, uma vez que áreas de corais serem identificadas como fundo marinho, influenciam na tomada de decisão, direcionando para a possível exploração de áreas que na verdade deveriam ser preservadas.

Além das estatísticas apresentadas anteriormente, a seguir são destacados os resultados da tabulação cruzada que indica o quantitativo de objetos em comum entre a imagem de referência e da classificação automática (Tabela 6).

Tabela 6 – Matriz confusão, baseada na validação por tabulação cruzada, entre a imagem de referência e a imagem da classificação automática do método 1


		Referência			
		Fundo marinho	Possível coral	Sombra	Total
C. automática	Fundo marinho	11352	450	709	12510
	Possível coral	380	1570	112	2063
	Sombra	94	80	398	572
	Total	11826	2100	1218	15145
Sensibilidade _{modelo}					67,80%
Especificidade _{modelo}					86,67%
Acurácia _{modelo}					87,95%

Fonte: Elaboração própria.

De acordo com a Tabela 6, também ocorreram confusão entre a classe possível coral e fundo marinho, o que é desfavorável, pois sugere a exploração de áreas sensíveis. O fato da classe sombra se confundir muito com o fundo marinho, pode estar associado as respostas espectrais dos alvos, que são próximas. A sensibilidade de 67,80% e a especificidade 86,67% aponta os valores positivos e negativos classificados corretamente. Apesar de tudo, a acurácia final do modelo

aponta que 87,95% das classes foram classificadas corretamente. Por fim, a Figura 17 representa a classificação final da área encontrada, após a conclusão do método 1.

Figura 17 – Classificação final resultante do método 1



Fonte: Elaboração própria.

Tendo como referência as classes encontradas na Figura 17, a quantificação dos resultados por classe mapeada está distribuída em 83,00% (205605,80 m²) como fundo marinho, 9,91% (24556,52 m²) possível coral e 7,09% (17558,17 m²) sombra.

O resultado mais expressivo encontrado se refere a delimitação das áreas de possíveis corais e sombras, que em termos práticos auxiliam de forma semiautomática a identificação rápida dessas classes, quando comparada com a classificação manual. O ponto de dificuldade encontrado foi incluir uma variável explicativa no modelo que conseguisse remover os ruídos da classe de sombra.

6.2 Resultados obtidos com o Método 2

Os resultados encontrados para o método 2 que diferentemente do método 1, considera a variável explicativa brilho no modelo, são apresentados na Tabela 7.

Tabela 7 – Matriz confusão baseada nas amostras

		<i>Referência</i>			
		Fundo marinho	Possível coral	Sombra	<i>Total</i>
Predição	Fundo marinho	327	4	12	331
	Possível coral	0	328	3	329
	Sombra	0	1	81	96
	<i>Total</i>	327	333	96	756
Sensibilidade <small>modelo</small>					94,29%
Especificidade <small>modelo</small>					98,47%
Acurácia <small>modelo</small>					97,35%

Fonte: Elaboração própria.

Na Tabela 7 o total de 756 corresponde ao número de segmentos amostrais. Além disso, a taxa de 94,29% referente a sensibilidade aponta a proporção das classes positivas que foram corretamente previstas e o valor de 98,47% da especificidade mostra a proporção das classes negativas preditas corretamente como negativas no modelo. Já a acurácia indica que 97,35% das classes foram classificadas de forma certa.

Outra observação relevante, é que com a variável explicativa “brilho” incorporada ao modelo, houve uma redução na confusão entre a classe possível coral e fundo marinho, o que é positivo, visto que a identificação mais assertiva dessa classe auxilia na determinação de áreas que não devem ser exploradas. Uma confusão também minimizada com esse preditor se refere as classes de sombra e fundo marinho, que apesar das respostas espectrais próximas, teve uma melhor distribuição.

O resultado da tabulação cruzada, é indicado na Tabela 8 evidenciando que 90,87% das classes foram determinadas de forma correta, quando comparadas as classes determinadas na vetorização manual (imagem de referência). Complementando as métricas de destaque, a especificidade (90,71%) e

sensibilidade (71,92%) encontradas demonstram que houve uma maior porcentagem de classes negativas identificadas corretamente como negativa pelo modelo, do que as classes positivas.


Tabela 8 – Matriz confusão, baseada na validação por tabulação cruzada, entre a imagem de referência e a imagem da classificação automática do método 2

		Referência			
		Fundo marinho	Possível coral	Sombra	Total
C. automática	Fundo marinho	11810	263	437	12510
	Possível coral	217	1502	343	2063
	Sombra	42	81	449	572
	Total	12069	1847	1229	15145
Sensibilidade _{modelo}					71,92%
Especificidade _{modelo}					90,71%
Acurácia _{modelo}					90,87%

Fonte: Elaboração própria.

Novamente, o processo de classificação aplicado apresentou dificuldades em distinguir entre as classes sombra e fundo marinho. Entretanto, incorporar o preditor brilho, diminuiu o erro de predição. A confusão entre as classes possível coral e fundo marinho é um ponto de atenção para o modelo proposto, conforme destacado anteriormente. A classificação final obtida pelo método 2 é apresentada na Figura 18.

Figura 18 – Classificação final resultante do método 2



Fonte: Elaboração própria.

De acordo com a Figura 18, tem-se a distribuição quantitativa das classes, sendo 86,84% (215134,30 m²) identificados como fundo marinho, 8,45% (20934,54 m²) possível coral e 4,70% (11651,63 m²) sombra. Uma análise qualitativa da classificação, indica que na parte superior central da Figura 18 uma grande extensão é classificada como sombra, sendo na verdade fundo marinho. Uma explicação para esse resultado seria que, por se tratar de uma região de união entre imagens individuais para composição do mosaico, as bordas acabam tendo uma perda de qualidade, o que influencia na resposta dos parâmetros de cada classe.

6.3 Resultados obtidos com o Método 3

Para ilustrar em termos numéricos, a seguir na Tabela 9 se tem a distribuição em porcentagem dos objetos resultantes do método 2 e 3, ou seja, antes e após a determinação das condicionantes que possibilitaram a classificação das áreas de sombra como possíveis corais.

Tabela 9 – Distribuição dos objetos por classe com e sem condicionante

Classes	Sem condicionante	Com condicionante
Fundo marinho	59,95%	59,95%
Possíveis corais	33,87%	34,87%
Sombra	6,18%	5,19%

Fonte: Elaboração própria.

A Tabela 9 destaca que 0,99 % dos polígonos que anteriormente eram identificados como sombra pelo método 2 (sem condicionantes) passaram para a classe possíveis corais no método 3 (com condicionantes).

Fornecendo uma visão complementar do método aplicado, os resultados provenientes da validação por tabulação cruzada que realizou uma comparação *pixel a pixel* entre a classificação manual na imagem individual (referência) e a classificação automática no Mosaico 1, indicou que os objetos que estavam classificados como sombra e foram alterados para a classe possível coral, a partir das condicionantes propostas para a reclassificação, resultou em uma taxa de acerto de 30,84% o que é uma concordância razoável. Tal resultado também aponta que existe a necessidade de novos testes, na exploração dos dados em busca de padrões.

Embora, a acurácia temática encontrada em termos quantitativos não seja tão expressiva, quando comparada aos demais métodos, a indicação de algumas regiões de sombra como possíveis corais é relevante, visto que são regiões que através da interpretação visual, não possibilitam nenhuma resposta temática.

7 CONCLUSÕES E RECOMENDAÇÕES

Em virtude da importância da identificação das possíveis áreas de corais em águas profundas, principalmente nas atividades de exploração e produção (E&P) do petróleo e seus derivados, foram propostos três métodos, sendo dois referentes a classificação semiautomática para a delimitação dessas regiões e o outro correspondendo ao refinamento da classificação nas regiões temáticas de sombra.

De forma ampla, considerando os resultados encontrados, conclui-se que os objetivos da pesquisa foram alcançados, uma vez que conseguiu-se delimitar de forma semiautomática tanto as áreas de possíveis corais quanto reclassificar os polígonos delimitados como sombra.

Realizando uma comparação quantitativa entre os Métodos 1 (95,82 % e 87,95%) e Método 2 (97,35% e 90,87%) para as taxas de acertos na matriz confusão das amostras e validação por tabulação cruzada, respectivamente, percebe-se que ambos apresentam uma concordância satisfatória. Embora o Método 2 tenha obtido maior percentual de acertos. O que pode ter influenciado essa melhora no classificador é a inclusão da variável explicativa brilho, permitida na classificação por OBIA.

Uma avaliação qualitativa para a classificação final obtida com os Métodos 1 e 2, através da análise visual, percebe-se que na junção entre as linhas individuais para composição do Mosaico 1, mais especificamente na região das bordas (parte superior), houve grande confusão entre a classe fundo marinho e sombra nos dois métodos, tal resultado pode ter ocorrido devido à perda de qualidade das imagens nessa área de borda, o que pode causar alta diferenciação espectral em uma mesma classe. Entretanto, comparando a delimitação dos objetos resultantes das duas classificações, nota-se que a classificação com OBIA, conseguiu delimitar de forma mais nítida os polígonos de possíveis corais e sombra.

Dentre os pontos de dificuldade encontrados para o desenvolvimento dos Métodos 1 e 2, destaca-se os erros de classificação para a classe possíveis corais, que se confundiu com as regiões de sombra, o que é um ponto de atenção, visto que tal resultado pode sugerir a exploração de áreas sensíveis. Portanto, recomenda-se a continuidade do trabalho em busca de outros parâmetros que

possam distinguir mais claramente essas classes, bem como uma verificação manual dos alvos, por um interprete, para refinar a classificação semiautomática.

Em relação ao Método 3 o percentual de acerto dos alvos classificados como sombra (associadas aos possíveis corais) e que passaram para a classe possíveis corais, por meio das condicionantes propostas, foi de 30,84%, que se mostra como um resultado razoável. Isso porque, a sombra não é inerente ao fundo marinho, ou seja, quando elas aparecem no processo de interpretação e vetorização manual com os insumos disponíveis, as mesmas devem ser descartadas ou incluídas no polígono de possíveis corais, o que desencadeia a subestimação ou superestimação das áreas sensíveis. Logo, é positivo conseguir definir de forma semiautomática mesmo que minimamente as áreas de sombra que possam ser classificadas como possíveis corais.

Em relação a minimização das incertezas do Método 3 sugere-se que novos testes sejam realizados, principalmente em relação aos atributos de índice de posição batimétrica, visto que conseguem auxiliar no processo de classificação.

Em suma, as técnicas de classificação *pixel a pixel* e por região são valiosas ferramentas para classificação semiautomática e determinação das características de possíveis corais, em dados de SAS interferométrico, MBES e seus derivados, visto que possibilitaram a delimitação das áreas de interesse de uma forma eficiente e rápida. Sendo que a OBIA possibilitou um melhor desempenho quantitativo, além de permitir a reclassificação das áreas identificadas como sombra.

REFERENCIAS

BELCHIOR, F. V. S. *et al.* **Padrões de retroespalhamento (backscatter) no vale Inciso do Rio Açu (Plataforma Externa) com ênfase em ambientes recifais (NE Brasil)**. Sociedade Brasileira de Geofísica (SBGf), Copyright, Rio de Janeiro, RJ, 2015.

BENZ, U.C. *et al.* **Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information**. ISPRS J. Photogramm. Remote Sens. 2004.

BRASIL. Ministério de Minas e Energia. Nota Técnica Dea 29/14: **Abordagem socioambiental da expansão da Produção de Petróleo e Gás Natural**. Empresa de Pesquisa Energética. Rio de Janeiro, RJ, 2014.

BRASIL. Ministério de Minas e Energia/Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. **Resolução nº 817, de 24 de abril de 2020**. Diário Oficial da União, Brasília, DF, 2020.

BRASIL. Ministério de Minas e Energia. **Balço Energético Nacional. Relatório Síntese 2023 (Ano Base 2022)**. Brasília, DF: Ministério de Minas e Energia, 2023.

CALLOW, H. J. *et al.* **A New High-Resolution Seafloor Mapping**. Copyright Journal of Ocean Technology 2012. Ocean, Vol. 7, No. 2, 2012.

CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à Ciência da Geoinformação**. Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 2001.

CARBALLINI, J.; VIANA, F. **Using Synthetic Aperture Sonar as an Effective Tool for Pipeline Inspection Survey Projects**. RIO Acoustics 2015 IEEE/OES acoustics in underwater geosciences symposium cprm, Urca, Rio de Janeiro, Brasil, jul. 2015, p. 29-31.

CASTRO, C. B.; PIRES, D. O. **Brazilian Coral Reefs: whats we already know and what is still missing**. Bull. Mar. Sci., vol. 69, n. 2, p. 357-371, 2001.

CHOI, H.; YANG, H.; SEONG, W. **Compressive Underwater Sonar Imaging with Synthetic Aperture Processing**. Remote Sensing. 2021. 13(10), 1924; Disponível em: <https://doi.org/10.3390/rs13101924>. Acesso em: 05 nov. 2021.

CRÓSTA, A.P. **Processamento Digital de Imagens de Sensoriamento Remoto...** Departamento de Metalogênese e Geoquímica. Instituto de Geociência. Universidade Estadual de Campinas, 1992.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification and Scene Analysis: Part 1 Pattern Classification**. pre-publication print of material to appear in Duda, Hart and Stork: Pattern Classification and Scene Analysis: Part I Pattern Classification, 1995.

DENNY, A. R. *et al.* **The use of synthetic aperture sonar to survey seafloor massive sulfide deposits.** University of Bergen Centre for Geobiology Bergen, Norway and Norwegian Defence Research Establishment (FFI), Kjeller, Norway IEEE Journal of Oceanic Engineering, Vol. 10, n.1, jan. 2015.

FAHMY, Mahmoud M. **Confusion Matrix in Three-class Classification Problems: A Step-by-Step Tutorial.** Journal of Engineering Research (ERJ), Faculty of Engineering, Tanta University, Tanta, Egypt. 2023.

FERNANDES, Victor Hugo. **Mapeamento de estruturas submarinas associadas ao Transporte de óleo e gás com veículo autônomo subaquático.** 2018. Tese de Doutorado (Programa de Pós-Graduação em Engenharia Civil) – Universidade Federal de Viçosa, Viçosa, 2018.

FRANCESCHI, Pietro R. **Modelagens preditivas de churn: o caso do Banco do Brasil.** 2019. Dissertação de Mestrado (Programa de Pós-graduação em gestão de Negócios) – Universidade do Vale do Rio dos Sinos, Porto Alegre, 2019.

HANSEN, R. E. *et al.* **Interferometric Synthetic Aperture Sonar in Pipeline Inspection.** Norwegian Defense Research Establishment (FFI). Noruega, P O Box 25, NO-2027, mai./out. 2010.

HANSEN, R. E. *et al.* **Challenges in Seafloor Imaging and Mapping With Synthetic Aperture Sonar.** IEEE transactions on geoscience and remote sensing. Noruega, Vol. 49, 10 out. 2011.

HANSEN, Roy Edgar. **Synthetic Aperture Sonar Technology Review.** Norwegian Defence Research Establishment (FFI) and University of Oslo, Norway. Paper, Vol. 47, n.5. set/out. 2013.

HANSEN, Roy Edgar. **Change detection on shipwrecks using synthetic aperture sonar – North Sea Wrecks Task 3.5 Deep Water Case Study.** Norwegian Defence Research Establishment (FFI). 16 dez. 2022.

HOGGARTH, A.; KENNY, K. **Using synthetic aperture sonar as an effective hydrographic survey tool.** In: Oceans-St. John's, 2014. IEEE, 2014. p. 1-12.

JAMES, G. *et al.* **An Introduction to Statistical Learning.** Springer New York Heidelberg Dordrecht London. Ed. 1, 2013.

KONGSBERG. **Autonomous Underwater Vehicle (AUV), Hugin. 2024.** Disponível em: <https://www.kongsberg.com/maritime/products/marine-robotics/autonomous-underwater-vehicles/AUV-hugin/>. Acesso em 23 jan. 2024.

KOOP, L.; SNELLEN, M.; SIMONS, D. G. **An Object-Based Image Analysis Approach Using Bathymetry and Bathymetric Derivatives to Classify the Seafloor.** Geosciences 2021,11, 45. Disponível em: <https://doi.org/10.3390/geosciences11020045>. Acesso em: 07 nov. 2021.

LUDVIGSEN, M. *et al.* **Scientific Operations Combining ROV and AUV in the Thondheim Fjord.** Marine Technology Society Journal. Volume 48, Number 2, mar. 2014.

MITCHELL, G. A. *et al.* **Improved detection and mapping of deepwater hydrocarbon seeps: optimizing multibeam echosounder seafloor backscatter acquisition and processing techniques.** Marine Geophysical Research. February 2018.

MOGSTAD, A. A. *et al.* **Remote Sensing of the Tautra Ridge: An Overview of the World's Shallowest Cold-Water Coral Reefs.** Original Research. March, 2022.

NETO, A. A.; RODRIGUES, G. P.; ALVARENGA, I.D. **Mapeamento submarino utilizando sonar interferométrico de abertura sintética para projetos de descomissionamento de plataformas de petróleo offshore.** Universidade Federal Fluminense, Niterói, 2018.

OLIVEIRA, Filipe Augusto. V. **Análise Comparativa de Classificadores para a Cartografia de Ocupação do Solo no Alentejo, com Imagens Intra-Anuais AWiFS.** Faculdade de Ciências Sociais e Humanas, Universidade Nova de Lisboa, 2011.

PAGANO, T. P.; LOUREIRO, R. B. **Bias and Unfairness in Machine Learning Models: A Systematic Review on Datasets, Tools, Fairness Metrics, and Identification and Mitigation Methods.** Systematic Review on Datasets, Tools, Fairness Metrics, and Identification and Mitigation Methods. Big Data Cogn. Comput. 2023.

PAIVA, Roberto U. **Análise de metacaracterísticas para classificação de uso e cobertura do solo utilizando Random Forest.** Trabalho de Pesquisa do Instituto de Informática da Universidade Federal de Goiás (UFG), Goiânia, 2020.

PARNUM, I. M.; GAVRILOV, A. N. **High-frequency multibeam echo-sounder measurements of seafloor backscatter in shallow water: Part 1 – Data acquisition and processing.** International Journal of the Society for Underwater Technology, 2011.

PIMENTEL, Vitor B. **Comparação entre dados batimétricos adquiridos com ecobatímetro multifeixe e dados batimétricos adquiridos com sonar de varredura lateral interferométrico.** Dissertação (Programa de Pós-Graduação em Dinâmica dos Oceanos e da Terra) - Universidade Federal Fluminense, Rio de Janeiro, 2018.

RAMOS, José A. **Classificação avançada de imagens com orientação a objetos no eCognition.** Universidade Estadual do Rio de Janeiro (Sistema Labgis), Rio de Janeiro, 2013. Disponível em: <https://www.youtube.com/watch?v=-K78SchMpio&t=2177s>. Acesso em: 05 nov. 2023.

ROSA, Roberto. **Introdução ao Geoprocessamento**. Universidade Federal de Uberlândia Instituto de Geografia (Laboratório de Geoprocessamento), Minas Gerais, 2013.

SAEBØ, Torstein O. **Seafloor Depth Estimation by means of Interferometric Synthetic Aperture Sonar**. University Of Tromsø. Faculty Of Science And Technology. Department Of Physics And Technology. Norway, 2010.

SAEBØ, T. O.; HANSEN, R. E.; LORENTZEN, O. J. **Using an Interferometric Synthetic Aperture Sonar to Inspect the Skagerrak World War II Chemical Munitions Dump Site**. Norwegian Defence Research Establishment (FFI). Norway, 2015.

SAHOO, A.; DWIVEDY, S. K.; ROBI, P. S. **Advancements in the field of autonomous underwater vehicle**. Ocean Engineering. Vol. 181, n.1, jun. 2019, p. 145-160.

SUMMERS, G.; LIM, A.; WHEELER, A. J. **Multi resolution appraisal of Cork Harbour estuary: An object based image analysis approach**. A School of Biological, Earth and Environmental Sciences, Environmental Research Institute, University College Cork, Distillery Fields, North Mall, T23 TK30 Cork, Ireland. 2023.

STURE, Ø. *et al.* **Recognition of Cold-Water Corals in Synthetic Aperture Sonar Imagery**. Department of Marine Technology Norwegian University of Science and Technology (NTNU) Trondheim, Norway, 2018.

TRIMBLE. **Trimble Documentation: Ecognition Developer Reference Book**. Trimble Germany GmbH, Arnulfstrasse 126, D-80636 Munich, Germany. 2014.

WEISS, Andrew D. **Topographic Positions and Landforms Analysis (poster), ESRI International User Conference**. San Diego, EUA, 2001.

WIGGERS, K. L.; RIBEIRO, S. R. A. **GEOBIA em imagem Rapideye para classificação do uso e cobertura da terra mediante *Self-Organizing Maps* em uma área da Bacia do Pitangui – PR**. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa, 2015.

WILLIAMS, David P. **AUV-enabled adaptive underwater surveying for optimal data collection**. Intel Serv Robotics (2011). 05 out. 2011, p. 33-54.

APÊNDICE A – Script (método 1)

```
## Classificação de possíveis áreas de corais em imagens HISAS e MBES  
## por meio do classificador Random Forest
```

```
set.seed(1234)
```

```
## Bibliotecas
```

```
library(raster)
```

```
library(rgdal)
```

```
library(sp)
```

```
library(caret)
```

```
library(dplyr)
```

```
library(maptools)
```

```
library(rpart.plot)
```

```
# =====
```

```
# ENTRADA DE DADOS
```

```
# =====
```

```
# Importando imagem HISAS por meio do comando raster::stack
```

```
img_hisas <- stack("AUTO_MSON_A09_208_1401.tif")
```

```
# Visualizando os atributos da imagem
```

```
img_hisas
```

```
# Visualizando os atributos de cada banda
```

```
img_hisas@layers
```

```
# Plotando a imagem em cor verdadeira RGB123 e contraste linear
```

```
plotRGB(img_hisas, r=1, g=2, b=3, stretch='lin')
```

```
# Transformando a imagem HISAS em dataframe
```

```
tab_hisas <- data.frame(getValues(img_hisas))
```

```
# Definindo os atributos de cada coluna do dataframe
```

```
colnames(tab_hisas) <- c("b1", "b2", "b3")
```

```
# Importando a batimetria
img_mbes <- raster::raster("MBES_VA_A09_208_140.tif")

# Plotando a batimetria
plot(img_mbes,col=grey(1:100/100), legend=T,axes=FALSE)

# Transformando a imagem em dataframe
tab_mbes <-data.frame(getValues(img_mbes))

# Definindo o atributo da coluna do dataframe
colnames(tab_mbes) <- c("profundidade")

# Importando a declividade por meio do comando raster::stack
decli <- stack("DECLIVIDADE")

# Visualizando os atributos da imagem
decli

# Visualizando os atributos de cada banda
decli@layers

#Plotando a imagem em cor verdadeira RGB123 e contraste linear
plot(decli, col=grey(1:100/100), legend=T,axes=FALSE)

# Transformando a imagem declividade em dataframe
tab_decli <-data.frame(getValues(decli))

# Definindo os atributos de cada coluna do dataframe
colnames(tab_decli) <- c("declividade")

# Importando a bpi 5 metros
img_bpi5m <- raster::raster("BPI_5M_MINUS")

# Plotando a bpi 5m
plot(img_bpi5m,col=grey(1:100/100), legend=T,axes=FALSE)
```

```
# Transformando a imagem em dataframe
tab_bpi5m <- data.frame(getValues(img_bpi5m))

# Definindo o atributo da coluna do dataframe
colnames(tab_bpi5m) <- c("bpi")

# Referência para treinar e testar o modelo
# Foram lançados 799 pontos sobre a imagem
# Os pontos de referência possuem as seguintes classes de uso:
# valor = 1 - fundo marinho
# valor = 2 - possível coral
# valor = 3 - sombra

# Importando as amostras
pts <- shapefile("amostras_1000_bpi.shp")

# Visualizando as amostras
pts

# Plotando os pontos sobre a imagem
plotRGB(img_hisas, r=1, g=2, b=3, stretch='lin') + points(pts, col=c(4,6,8), pch=c(1,2,3))
legend("bottom", title="Classes de Uso", legend = c("fundo marinho", "possível
coral", "sombra"), pch=c(1,2,3), col=c(4,6,8), horiz=TRUE, cex=0.8)

# Plotando somente os pontos
plot(pts, col=c(4,6,8), pch=c(1,2,3)) +
legend("bottom", title="Classes de Uso", legend = c("fundo marinho", "possível
coral", "sombra"), pch=c(1,2,3), col=c(4,6,8), horiz=TRUE, cex=0.8)

# Gerando um dataframe dos pontos de referência para a amostragem
# contendo os valores de cada banda (B1, B2, B3) + profundidade + classe de uso
tab_hisas_mbes_decli_bpi <-
as.data.frame(cbind(img_hisas[pts], img_mbes[pts], decli[pts], img_bpi5m[pts],
as.factor(pts$ID)))

# Omitindo as observações NA
#na.omit(tab_hisas_mbes_decli_bpi)
```

```

# Definindo os atributos de cada coluna do dataframe
colnames(tab_hisas_mbes_decli_bpi) <-
c("b1","b2","b3","profundidade","declividade","bpi","uso")

#Transformando o atributo uso em fator
tab_hisas_mbes_decli_bpi$uso <- as.factor(tab_hisas_mbes_decli_bpi$uso)

# =====
# AMOSTRAGEM
# =====

# A base de dados é particionada em treinamento (70%) e teste (30%), sendo
# selecionados aleatoriamente os pontos de treinamento e de teste

part <- createDataPartition(tab_hisas_mbes_decli_bpi$uso, p = 0.7,list = F)

trei <- tab_hisas_mbes_decli_bpi[part,] # amostras de treinamento
test <- tab_hisas_mbes_decli_bpi[-part,] # amostras de teste

# =====
# DEFINIÇÃO DO MODELO
# =====

# Definição do modelo em que as classes de uso serão obtidas com base nos valores
# das bandas, profundidade e coordenadas

myFormula <- uso ~ b1+b2+b3+profundidade+declividade+bpi

# =====
# TREINANDO O CLASSIFICADOR - RANDOM FOREST
# =====

# Embora o modelo faça o cálculo para definir a quantidade de variáveis de nossa
# base que será usada em cada árvore, vamos fazer o cálculo do % de erro que
# cada combinação gera ao final de uma execução

```

```

mtry =
  tuneRF(
    trei %>% select(-uso),
    trei$uso,
    ntreeTry= 1000,
    stepFactor=1.5,
    improve=0.01)

print (mtry)

# Aplicar o modelo Random Forest para a classificação, considerando:
# 1) Usar a base de dados trein;
# 2) Usar a função randomForest::randomForest();
# 3) Definir como 2 o número de variáveis a serem selecionada aleatoriamente
# 4) Calcular a importância dos preditores
# 5) Definir como 1000 o número de arvores a serem analisadas

library(randomForest)
r_forest <- randomForest(uso ~ ., data=trei, mtry=2,
                        importance=TRUE, ntree=1000, set.seed(123))

# Importância das variáveis nas 1000 combinações realizadas
varImpPlot(r_forest, sort = T)

# Visualizando a random forest gerada
print(r_forest)

# Obtendo a importância das variáveis
round(importance(r_forest), 2)

#=====
# ANÁLISE PREDITIVA
#=====

# Aplicando o modelo Random Forest treinado sobre os dados de teste
uso_estimado <- predict(r_forest , test)

```

```

#=====
# AVALIAÇÃO ACURÁCIA
#=====

##Obtendo a Matriz de Confusão e Acurácia
confusionMatrix(as.factor(uso_estimado), as.factor(test$uso))

#=====
# CLASSIFICANDO TODA A IMAGEM
#=====

tab_hisas2 <- data.frame(as.data.frame(coordinates(img_hisas[[1]])), getValues(img_hisas),
extract(img_mbes,as.data.frame(coordinates(img_hisas[[1]]),method ='simple'))

tab_hisas3 <- data.frame(tab_hisas2,extract(decli,
as.data.frame(coordinates(img_hisas[[1]])))

tab_hisas4 <- data.frame(tab_hisas3, extract(img_bpi5m,
as.data.frame(coordinates(img_hisas[[1]])))

colnames(tab_hisas4) <- c("x", "y", "b1","b2","b3","profundidade","declividade", "bpi")

# Aplicando o modelo na tabela contendo todos os pixels
uso <- predict(r_forest, tab_hisas4,type = "class")

# Criando uma imagem (rasterLayer) com as informações da imagem original
uso_img <- img_hisas[[1]]
print(uso_img)

# Alterando os valores da imagem criada para o resultado da classificação
values(uso_img) <- NA
values(uso_img) <- uso

# Plotando a imagem classificada
plot(uso_img)

```

```
#=====
```

```
# EXPORTANDO A CLASSIFICAÇÃO
```

```
#=====
```

```
writeRaster(uso_img, filename =
```

```
"img_class_3amos_hisas_mbes_decli_bpi5m_amos_1000_mtr2.tif")
```