

Andrigo Borba Dos Santos

**REDES NEURAIIS ARTIFICIAIS APLICADAS A TOPOGRAFIA
DERIVADA DE SATÉLITES PARA ZONAS ENTREMARÉS**

Itajaí (SC), fevereiro de 2026



UNIVALI

UNIVERSIDADE DO VALE DO ITAJAÍ
CURSO DE MESTRADO ACADÊMICO EM
COMPUTAÇÃO APLICADA

REDES NEURAIIS ARTIFICIAIS APLICADAS A TOPOGRAFIA
DERIVADA DE SATÉLITES PARA ZONAS ENTREMARÉS

por

Andrigo Borba dos Santos

Dissertação apresentada como requisito parcial à
obtenção do grau de Mestre em Computação
Aplicada.

Orientadora: Anita Maria da Rocha Fernandes,
Dra.

Itajaí (SC), fevereiro de 2026

REDES NEURAIS ARTIFICIAIS APLICADAS A TOPOGRAFIA DERIVADA DE SATÉLITES PARA ZONAS ENTREMARÉS

ANDRIGO BORBA DOS SANTOS

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Computação Aplicada, Área de Concentração Computação Aplicada e aprovada em sua forma final pelo Programa de Mestrado Acadêmico em Computação Aplicada da Universidade do Vale do Itajaí - UNIVALI.

Prof. Jordan Passinato Sausen, Dr.

Coordenador do Curso de Mestrado em Computação Aplicada

Apresentado perante a Banca Examinadora composta pelos Professores:

Profa. Dra. Anita Maria da Rocha Fernandes

Orientadora

Prof. Dr. Rudimar Luís Scaranto Dazzi (UNIVALI)

Membro

Prof. Dr. Rodrigo Sant'Ana (UNIVALI)

Membro

Prof. Dr. Antônio Henrique da Fontoura Klein (UFSC)

Membro

Itajaí-SC, 23 de fevereiro de 2026.

AGRADECIMENTOS

O autor agradece à Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC) pelo financiamento desta pesquisa por meio de bolsa de mestrado concedida no âmbito da Chamada Pública nº 18/2024.

O autor também expressa agradecimento a Antonio Henrique da Fontoura Klein pela ideia inicial do projeto e pela oportunidade de participação como convidado temporário no projeto CASSIE-Core. Em decorrência dessa participação, registra-se ainda o agradecimento ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio ao projeto CASSIE-Core (processo nº 406603/2022-7), pela concessão de bolsa de Produtividade em Pesquisa nível 1D (processo nº 302238/2022-0) e pelo financiamento no âmbito da Chamada CNPq/MCTI/FNDCT nº 22/2024 – ConhecBrasil-REDES (processo nº 444856/2024-2). E reconhece-se igualmente o apoio da FAPESC ao CASSIE por meio da Chamada Pública nº 21/2024 – Programa Universal de Pesquisa, no projeto “Tools for assessing climate change-induced threats in estuaries” (processo nº 2024TR002216).

Registra-se também o agradecimento a Luis H. P. Garbossa, da Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (Epagri), pelo fornecimento dos dados de maré utilizados neste estudo.

Por fim, o autor agradece aos membros do grupo de pesquisa que contribuíram para o desenvolvimento deste trabalho: Mario Luiz Mascagni, Lais Pool da Silva Freitas, Dennis Kerr Coelho, Karoline de Souza Guckert. O autor expressa gratidão à professora Anita Maria da Rocha Fernandes pelas orientações de pesquisa e desenvolvimento do trabalho.

REDES NEURAIS ARTIFICIAIS APLICADAS A TOPOGRAFIA DERIVADA DE SATÉLITES PARA ZONAS ENTREMARÉS

Andrigo Borba dos Santos

Fevereiro / 2026

Orientadora: Anita Maria da Rocha Fernandes, Dra.

Área de Concentração: Computação Aplicada

Linha de Pesquisa: Sistemas Inteligentes e Educacionais

Palavras-chave: Sensoriamento Remoto, Linha de Água, Modelos Digitais de Elevação, Rede Neural Convolucional, U-Net, Transformers.

Número de páginas: 161

RESUMO

Modelos digitais de elevação confiáveis para zonas entre marés são essenciais para a gestão costeira, pois viabiliza o monitoramento da erosão, a modelagem de inundações costeiras e a avaliação de riscos associados ao aumento do nível do mar. Entretanto, métodos tradicionais de levantamento e modelos empíricos baseados em índices normalizados de produtos de sensoriamento remoto apresentam limitações na representação desses ambientes altamente dinâmicos. Nesse contexto, o Aprendizado de Máquina (AM) tem surgido como uma alternativa promissora para o mapeamento da morfologia intermareal. Este trabalho desenvolveu uma abordagem baseada em Redes Neurais Artificiais, fundamentada na arquitetura U-Net com a incorporação de blocos Convolutional Vision Transformer (CvT), visando aprimorar a extração de padrões espectrais e espaciais em séries temporais de imagens multiespectrais. Os dados de entrada e referência foram processados e padronizados no Google Earth Engine para diferentes Áreas de Interesse e posteriormente pré-processados em Python para reconstrução das imagens, organização dos conjuntos de dados e geração de subamostras. Foram utilizadas bandas do Sentinel-2, além dos índices espectrais NDWI, MNDWI e AWEI, combinados com informações maregráficas. Foram implementados três modelos: (i) um modelo para estimativa de linhas d'água, gerando imagens com múltiplas linhas de costa; (ii) um modelo de interpolação, responsável por converter essas linhas em superfícies contínuas de elevação; e (iii) um modelo completo, que executa a detecção das linhas e a geração do MDE em um único modelo. Os resultados indicaram desempenho consistente, com RMSE de 0,27 m para o modelo de linha d'água, 0,46 m para o interpolador e 0,35 m para o modelo completo. A validação foi realizada por comparação com dados de alta precisão obtidos por Laser Scanner terrestre. Embora o treinamento tenha dependido boa parte de dados derivados do método WL tradicional, o modelo completo apresentou desempenho competitivo e demonstrou potencial para superar abordagens empíricas se treinado com conjuntos de dados gerado por métodos de campo.

MACHINE LEARNING APPLIED TO SATELLITE-DERIVED TOPOGRAPHY FOR INTERTIDAL ZONES

Andrigo Borba dos Santos

February / 2026

Advisor: Anita Maria da Rocha Fernandes, PhD

Area of Concentration: Applied Computing

Research Line: Intelligent and Educational Systems

Keywords: Remote Sensing, Convolutional Neural Network, U-Net, Waterline, Digital Elevation Models, Transformers.

Number of pages: 161

ABSTRACT

Reliable digital elevation models (DEMs) for intertidal zones are essential for coastal management, as they support erosion monitoring, coastal flood modeling, and broader assessments associated with rising sea levels. However, traditional survey methods and empirical models based on normalized indices derived from remote sensing products have limitations when it comes to representing these highly dynamic environments. In this context, Machine Learning (ML) has emerged as a promising alternative for mapping intertidal morphology. This study developed an approach based on Artificial Neural Networks (ANNs), using a U-Net architecture enhanced with Convolutional Vision Transformer (CvT) blocks to improve the extraction of spectral and spatial patterns from multispectral time-series imagery. Input and reference datasets were processed and standardized in Google Earth Engine for different Areas of Interest, and subsequently preprocessed in Python for image reconstruction, dataset organization, and subsample generation. Sentinel-2 spectral bands were used as input features, together with the spectral indices NDWI, MNDWI, and AWEI, combined with tidal gauge information. Three models were implemented: (i) a waterline estimation model, generating images with multiple shoreline positions; (ii) an interpolation model, which converts these lines into continuous elevation surfaces; and (iii) a full model, which performs both waterline detection and DEM generation within a single architecture. The results demonstrated consistent performance, with RMSE values of 0.27 m for the waterline model, 0.46 m for the interpolation model, and 0.35 m for the full model. Validation was conducted through comparison with high-precision data acquired using a terrestrial laser scanner. Although the training process relied largely on datasets derived from the traditional Waterline (WL) method, the full model exhibited competitive performance and showed potential to outperform empirical approaches when trained with datasets generated through field-based methods.

LISTA DE ILUSTRAÇÕES

Figura 1: Objetivos sustentáveis definidos pela ONU na Década dos Oceanos.	21
Figura 2: Marés Oceânicas.	26
Figura 3: Distribuição dos pontos anfidrômicos das principais bacias oceânicas.	27
Figura 4: Divisão do espectro eletromagnético.	30
Figura 5: Linha do tempo dos principais satélites óticos de observação com cobertura global.	32
Figura 6: Linha do tempo das principais contribuições para o método WL em zonas intermarés. ...	34
Figura 7: Arquitetura U-Net encoder-decoder utilizada na RNA de interpolação de dados.	49
Figura 8: Resumo da metodologia PRISMA aplicada neste estudo.	58
Figura 9: Produções científicas sobre SR em zonas intermareais aplicando aprendizado de máquina.	66
Figura 10: Frequência de ML e modelos empíricos aplicados ao SR costeiro na literatura revisada.	67
Figura 11: Organograma de agrupamento de modelos de inversão topográfica intermareal, com base no tipo de aprendizagem e na arquitetura estrutural.	69
Figura 12: Frequência dos tipos de sensores fontes de SR utilizado em estudos de mapeamento de zonas entremarés.	70
Figura 13: Comparação de desempenho de modelos de inversão topográfica intermareal.	71
Figura 14: Análise de sensibilidade de variáveis preditoras que influenciam a precisão dos modelos de detecção de linhas d'água intermareais.	73
Figura 15: Boxplots mostrando a influência do regime de marés (painel superior) e do tipo de dado de entrada (painel inferior) na precisão dos modelos automáticos de detecção de linha d'água.	74
Figura 16: Comparação de desempenho de modelos intermareais baseados em MDE.	77
Figura 17: Análise de sensibilidade de variáveis que influenciam a precisão de modelos digitais de elevação (MDEs) intermareais, com base em um modelo Random Forest.	78
Figura 18: Influência da escala espacial (painel superior) e do regime de marés (painel inferior) na precisão dos MDEs intermareais derivados dos modelos intermareais.	80
Figura 19: Boxplots mostrando a influência da cobertura sedimentar dominante na precisão dos modelos MDE intermareal, com base em estudos na base de dados bibliográfica.	82
Figura 20: Diagrama do fluxo de trabalho completo no momento do treinamento dos modelos de rede neural.	84
Figura 21: Diagrama do fluxo do sistema completo no momento de execução.	85
Figura 22: Área de estudo definidas para os testes do modelo de topografia derivada de satélites com técnicas de RNA.	87
Figura 23: Dados de topografia intermareal levantados com Laser Scanner Terrestre cedidos pelo LOC da UFSC.	89
Figura 24: Área de dados gerados pelo WL tradicional versus a área gerada pelo método de campo.	90
Figura 25: Imagem original de uma topobatimetria versus imagem após a aplicação da técnica de erosão.	93
Figura 26: Janelas deslizantes para gerar sub-amostras.	94
Figura 27: Distância em metros entre as linhas de costa da praia do amor.	95
Figura 28: Arquitetura do pré-processamento dos dados para o modelo de linha d'água.	97
Figura 29: Arquitetura do modelo U-net CVT Temporal.	99
Figura 30: Arquitetura do pré-processamento dos dados para o modelo interpolador.	102

Figura 31: Arquitetura do modelo U-net CVT.....	103
Figura 32: Representação da transposição feita.	108
Figura 33: Nuvens de pontos de valores verdadeiros versus predições.	110
Figura 34: Nuvens de pontos comparativas por tamanho de subamostra.	113
Figura 35: Superfície da AOI-1 para subamostras de 16 x 16 pixels.	114
Figura 36: Superfície da AOI-1 para subamostras de 32 x 32.	114
Figura 37: Superfície da AOI-1 para subamostras de 64 x 64.	115
Figura 38: Nuvem de pontos para diferentes tamanhos de subamostras.	116
Figura 39: Nuvem de pontos com e sem máscara.	118
Figura 40: Métricas com e sem máscara.	119
Figura 41: Superfícies do modelo linha d'água com e sem máscara.	120
Figura 42: Superfície do modelo interpolador com e sem máscara.	121
Figura 43: Métricas do modelo de linha d'água.	124
Figura 44: Nuvem de ponto do modelo linha d'água.	125
Figura 45: Superfície do modelo de linha d'água.	126
Figura 46: Métricas do modelo de interpolação.	127
Figura 47: Nuvem de ponto do modelo interpolador.	128
Figura 48: Superfície do modelo interpolador.	129
Figura 49: Métricas do modelo completo.	130
Figura 50: Nuvem de pontos do modelo completo.	131
Figura 51: Superfície do modelo completo.	132
Figura 52: Comparação entre as superfícies de cada modelo com o WL tradicional e o dado de campo.	134

LISTA DE QUADROS

Quadro 1: Perguntas de pesquisa formuladas para a revisão:	54
Quadro 2: Palavras-chave primárias extraídas das perguntas de pesquisa, para serem conectadas pelo mecanismo booleano "AND" nas barras de pesquisa dos motores de busca.....	55
Quadro 3: Sinônimos literais e conceituais associados a cada palavra-chave para expandir e refinar sequências de pesquisa.....	55
Quadro 4: Sequência de pesquisa booleana aplicada em todos os mecanismos de busca selecionados para identificar publicações relevantes.	56
Quadro 5: Critérios de inclusão e exclusão usados para filtrar publicações recuperadas quanto à relevância e qualidade metodológica.	56
Quadro 6. Motores de busca utilizados, seus respectivos endereços (URLs), datas de acesso e tipos	57
Quadro 7: Perguntas de pesquisa usadas para estimular a extração de literatura assistida por IA para todos os artigos no Repositório bibliográfico deste estudo.....	60
Quadro 8: Resumo dos procedimentos de padronização aplicados aos artigos analisados.	61
Quadro 9: Conjunto final de 60 artigos, organizados por ID e informações bibliográficas importantes.....	63
Quadro 10: Resumo da base de dados de referência bibliográfica deste estudo por regime de marés.	75

LISTA DE TABELAS

Tabela 1: Tabela de uso dos satélites e suas missões ao longo dos anos.....	33
Tabela 2: Demonstrativo da relação do tamanho das subamostras com os parâmetros e as bases..	111

LISTA DE ABREVIATURAS E SIGLAS

AEE	Agência Espacial Européia
AFFM	<i>Adapt Fusion Features Module</i>
AM	Aprendizado de Máquina
ANN	<i>Artificial Neural Networks</i>
AOI	<i>Area of Interest</i>
AWEI	<i>Automated Water Extraction Index</i>
BDS	Batimetria Derivada de Satélite
CASSIE	<i>Coastal Analyst System from Space Imagery Engine</i>
CE	Critérios de Exclusão
CI	Critérios de Inclusão
CNN	<i>Convolutional Neural Networks</i>
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
CODEC	<i>Coastal Dataset for the Evaluation of Climate Impact</i>
CSV	<i>Comma Separated Values</i>
CvT	<i>Convolutional Vision Transformer</i>
DT	<i>Decision Tree</i>
EPAGRI	Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina
ERTS	<i>Earth Resources Technology Satellite</i>
ESA	<i>European Space Agency</i>
FAPESC	Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina
FN	Falso Negativo
FP	Falso Positivo
GEE	<i>Google Earth Engine</i>
GeLU	<i>Gaussian Error Linear Unit</i>
GNSS	<i>Global Navigation Satellite System</i>
GPU	<i>Graphics Processing Unit</i>
HTTP	<i>Hypertext Transfer Protocol</i>
IA	Inteligência Artificial
IPCC	<i>Intergovernmental Panel on Climate Change</i>
KML	<i>Keyhole Markup Language</i>
LiDAR	<i>Light Detection and Ranging</i>
LOC	Laboratório de Oceanografia Costeira
MAE	<i>Mean Absolute Error</i>
MCA	Mestrado em Computação Aplicada
MDE	Modelos Digitais de Elevação
MiT	<i>Mix Transformer</i>
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
MNDWI	Modified Normalized Difference Water Index
MSE	<i>Mean Squared Error</i>
NaN	<i>Not a Number</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
ODS	Objetivos de Desenvolvimento Sustentável

ONNX	<i>Open Neural Network Exchange</i>
ONU	Organização das Nações Unidas
PC	Palavra-Chave
PDF	<i>Portable Document Format</i>
PPM	<i>Piramid Pooling Module</i>
PReLU	<i>Parametric Rectified Linear Unit</i>
PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses</i>
ReLU	<i>Rectified Linear Unit</i>
RF	<i>Random Forest</i>
RGB	<i>Red, Green and Blue</i>
RNA	Redes Neurais Artificiais
RNN	<i>Recurrent Neural Networks</i>
RMSE	<i>Root Mean Square Error</i>
RSL	Revisão Sistemática da Literatura
RTK	<i>Real Time Kinematic</i>
SAR	Radar de Abertura Sintética
SB	<i>String de Busca</i>
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machine</i>
UFSC	Universidade Federal de Santa Catarina
UNIVALI	Universidade do Vale do Itajaí
UTM	Universal Transverse Mercator
VANT	Veículo Aéreo Não Tripulado
ViT	<i>Vision Transformer</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WL	<i>Water Line</i>

SUMÁRIO

1 INTRODUÇÃO.....	15
1.1 PROBLEMA DE PESQUISA.....	16
1.1.1 Solução Proposta	18
1.1.2 Delimitação de Escopo	19
1.1.3 Justificativa	20
1.2 OBJETIVOS	22
1.2.1 Objetivo Geral	22
1.2.2 Objetivos Específicos	22
1.3 METODOLOGIA.....	23
1.3.1 Metodologia da Pesquisa	23
1.3.2 Procedimentos Metodológicos.....	23
1.4 ESTRUTURA DA DISSERTAÇÃO.....	24
2 FUNDAMENTAÇÃO TEÓRICA.....	26
2.1 ZONAS ENTREMARÉS	26
2.1.1 Marés Oceânicas.....	26
2.1.2 Morfologia Entremarés	28
2.2 SENSORIAMENTO REMOTO	28
2.2.1 Imagens de Satélite.....	29
2.2.2 O Sensoriamento Remoto Aplicado a Oceanografia	31
2.3 TOPOGRAFIA ENTREMARÉS DERIVADA DE SATÉLITES	33
2.4 APRENDIZADO DE MÁQUINA E SUA APLICAÇÃO EM TOPOGRAFIA ENTREMARÉS DERIVADA DE SATÉLITES.....	36
2.4.1 Árvores de decisão	37
2.4.2 Clusterização	38
2.4.3 Redes Neurais Artificiais	39
2.4.4 Treinamento.....	43
2.4.5 Métricas de avaliação.....	44
2.4.6 Arquiteturas de RNAs	47
2.4.7 Redes Neurais Recorrentes	49
2.4.8 Transformers	50
2.5 LINHA DO TEMPO DO APRENDIZADO DE MÁQUINA APLICADO A TOPOGRAFIA ENTREMARÉS DERIVADA DE SATÉLITES	52
3 revisão sistemática	54
3.1 METODOLOGIA.....	54
3.1.1 Bases de Dados Bibliográficos.....	57
3.1.2 Execução da Busca	57
3.1.3 Metodologia de análise.....	60
3.2 ARTIGOS ENCONTRADOS.....	62

3.3 ANÁLISE BIBLIOMÉTRICA.....	66
3.4 ANÁLISE COMPARATIVA.....	67
3.4.1 Fonte dos Dados de Entrada para Alimentar os Modelos Entremarés	70
3.4.2 Eficiência dos Modelos Intermareais	70
3.5 CONSIDERAÇÕES	82
4 DESENVOLVIMENTO.....	84
4.1 VISÃO GERAL COMPLETA	84
4.2 CONJUNTO DE DADOS	86
4.2.1 Áreas de Interesse	86
4.2.2 Aquisição dos Dados	87
4.2.3 Pré-processamento no GEE	91
4.2.4 Pré-processamento para o Modelo	91
4.3 MODELOS.....	96
4.3.1 Modelo de linha d'água	96
4.3.2 Modelo para Interpolação das Curvas de Nível Mapeadas na Zona Entremarés.....	102
4.3.3 Modelo Completo	104
5 RESULTADOS	106
5.1 BASE DE DADOS	106
5.1.1 Adequação dos parâmetros dos modelos para a quantidade de dados ...	106
5.1.2 Filtragem dos dados pobres	107
5.1.3 Expansão do conjunto de dados.....	108
5.2 TAMANHO DAS SUBAMOSTRAS	112
5.3 MÁSCARAS.....	118
5.4 MELHORES RESULTADO	122
5.4.1 Modelo de linha d'água	123
5.4.2 Modelo de interpolação	126
5.4.3 Modelo completo	129
5.4.4 Comparações com o modelo tradicional.....	132
5.5 OUTROS PROBLEMAS ENFRENTADOS.....	135
6 CONCLUSÕES.....	137
6.1 CONTRIBUIÇÕES CIENTÍFICAS.....	139
6.2 TRABALHOS FUTUROS	140
REFERÊNCIAS	141

1 INTRODUÇÃO

Na oceanografia, o conhecimento das profundidades em águas rasas é essencial para a segurança da navegação costeira e portuária. Essas informações subsidiam o planejamento de rotas, a operação de portos e canais de acesso, além de influenciarem diretamente o comércio marítimo e a economia (Sverdrup; Johnson; Fleming, 1942). As regiões rasas também possuem relevância ambiental, pois abrigam habitats sensíveis e produtivos de valor ecológico e econômico (IPCC, 2023). Neste contexto, a estimativa da profundidade em áreas costeiras é fundamental para o gerenciamento costeiro, segurança portuária, conservação ambiental e adaptação às mudanças climáticas (Alves et al., 2018; Saeidi et al., 2023).

Entre esses ambientes costeiros rasos, destacam-se as zonas entre marés, ou intermarés, que correspondem a áreas periodicamente submersas em função da oscilação do nível do mar ocasionado por influência das marés (Bishop-Taylor et. al., 2019). Essas zonas são uma interface entre os ambientes marinho e terrestre. Nelas ocorre o fenômeno de dissipação da energia marinha na costa, que é essencial para mitigar os impactos associados à erosão costeira gerada por ondas. Cabe destacar que as zonas entre marés sofrem de uma retroalimentação entre o relevo em águas rasas e a propagação das marés, de modo que alterações no fundo marinho modificam a dinâmica de propagação das ondas ao longo do tempo (Masselink; Hughes; Knight, 2011; Wang et. al., 2023).

Embora as zonas intermarés não sejam áreas de navegação convencional, o conhecimento da profundidade dos corpos d'água, batimetria, em regiões entremarés é relevante. Pois a topobatimetria, como é conhecida a batimetria de zonas entremares, é utilizada para o monitoramento morfodinâmico, a modelagem hidrodinâmica e o planejamento portuário adjacente. A obtenção de dados batimétricos nessas regiões é dificultada pela ação de ondas, correntes, marés e pela variabilidade do sedimento do fundo (Bué; Catalão; Semedo, 2020).

A aquisição de dados com métodos tradicionais de campo apresenta limitações significativas em ambientes intermarés. Levantamentos embarcados, como os realizados com ecobatímetros, são restritos pela baixa profundidade, que inviabilizam a operação segura de embarcações. De forma complementar, os métodos em ambiente terrestre são limitados pela curta janela temporal de exposição durante a maré baixa. Por isso, os métodos tradicionais de campo em zonas intermarés são considerados dispendiosos e pouco eficientes (Bué; Catalão; Semedo, 2020).

Nesse contexto, o sensoriamento remoto (SR) com imagens de satélite multiespectrais surge como uma alternativa para contornar a escassez de dados e os elevados custos de aquisição de dados dos métodos de campo. As imagens das missões Sentinel-2 e Landsat, disponíveis no *Google Earth Engine* (GEE), oferecem ampla cobertura temporal e espacial com acesso público, permitindo o monitoramento indireto da zona intermarés por meio de séries históricas de imagens (Gao et al., 2024; Gao, 2009).

Entre as abordagens baseadas em SR, destaca-se a Batimetria Derivada de Satélite (BDS), que utiliza algoritmos que associam a reflectância espectral com a profundidade. Esses algoritmos baseiam-se na atenuação da luz na água (Caballero; Stumpf, 2020). No entanto, a presença de nuvens, reflexos de superfície, quebra de ondas e partículas em suspensão interferem negativamente na qualidade do sinal espectral. Tais fatores tornam os métodos tradicionais e empíricos limitados em ambientes opticamente complexos, como as zonas intermarés (Saeidi et al., 2023).

Em virtude dessas limitações, a inteligência artificial (IA), em especial as Redes Neurais Artificiais (RNA), apresenta-se como uma alternativa promissora para a estimativa de profundidade e para a geração de Modelos Digitais de Elevação (MDE) em ambientes costeiros rasos e zonas intermarés. Técnicas de aprendizado de máquina permitem representar relações não lineares entre a reflectância espectral e a profundidade, integrando variáveis complementares, como nível de maré e tipo de fundo, o que resulta em estimativas mais precisas e robustas frente à elevada complexidade ambiental desses ambientes (Brunier et al., 2022; Chen et al., 2023; Wang et al., 2023; Zhou et al., 2023)

Diante disso, este trabalho aplica Redes Neurais Artificiais para prever a topobatimetria de zonas entre marés a partir de imagens de satélite disponíveis na plataforma GEE. O estudo propõe melhorias nos modelos existentes através da aplicação de técnicas baseadas em *transformer* na arquitetura U-Net, com foco na redução das interferências ambientais e na otimização e simplificação dos modelos existentes.

1.1 PROBLEMA DE PESQUISA

O monitoramento contínuo e preciso da evolução morfológica de zonas entremarés é essencial para a gestão e proteção costeira, conservação ambiental e mitigação dos impactos das mudanças climáticas, como as inundações costeiras (IPCC, 2023). Além disso, essas zonas desempenham um

papel estratégico na dissipação de energia das marés, além de abrigarem ecossistemas de elevado valor ecológico e econômico (IPCC, 2023). Porém, a manutenção dessas áreas depende do conhecimento espacial e temporal da sua dinâmica, e embora existam diferentes abordagens para este monitoramento, todas apresentam limitações e são passivas de melhorias (Bué; Catalão; Semedo, 2020).

Os métodos tradicionais de topografia e batimetria demandam mão de obra especializada e equipamentos robustos, tornando-os inviáveis para monitoramentos frequentes. Já as soluções com sensoriamento remoto ativo, como laser scanners embarcados em Veículos Aéreos Não Tripulados (VANT), também dependem de equipamentos robustos e oferecem cobertura limitada à zona emersa (Maxwell; Warner; Fang, 2018).

As abordagens multiespectrais baseadas em imagens orbitais (ex.: Landsat e Sentinel) são acessíveis, mas dependem da disponibilidade temporal dos satélites e da ausência de cobertura de nuvens, o que compromete a consistência das séries temporais - nesse sentido, as técnicas recentes de aprendizado de máquina aplicadas a imagens de satélite demonstram potencial para monitoramento morfológico automatizado da zona entremarés (Maxwell; Warner; Fang, 2018). No entanto, esse campo ainda é emergente, com diversas lacunas a serem exploradas para o desenvolvimento de metodologias sistemáticas, acessíveis e eficazes (Tsiakos; Chalkias, 2023).

Dessa forma, o problema de pesquisa está inserido em um contexto de relevância prática e científica, com soluções ainda em consolidação. A proposta deste trabalho contribui para o avanço de métodos automatizados para o monitoramento espaço-temporal da dinâmica morfológica da zona entremarés, com potencial de aplicação em estudos ambientais, planejamento costeiro e modelagem de impactos climáticos.

Nesse sentido, este trabalho pretende responder às seguintes perguntas de pesquisa:

- De que forma RNAs aplicadas a dados multiespectrais de sensoriamento remoto, podem ser utilizadas para gerar MDEs para zonas entremarés?
- Como é possível aprimorar os modelos de RNA encontrados na literatura, visando reduzir o erro médio absoluto na previsão da topobatimetria em zonas intermarés, a partir de imagens de satélite?

- De que modo é possível aplicar técnicas de transformer na arquitetura U-Net para previsão da topobatimetria em zonas intermarés, a partir de imagens de satélite visando reduzir o erro médio absoluto?
- Qual o percentual de redução dos erros médios absolutos, Mean Absolute Error (MAE) do modelo RNA, em comparação com os métodos de sensoriamento remoto tradicionais para zonas entre mares, que utilizam a aproximação matemática, sem a utilização de RNA?

1.1.1 Solução Proposta

A proposta deste trabalho foi desenvolver um sistema baseado em duas RNAs para estimar a topobatimetria de zonas entremarés a partir de imagens de satélite multiespectrais públicas. O sistema foi treinado com diferentes imagens de satélite de diferentes datas, utilizando dados de reflectância e índices espectrais derivados das bandas visíveis e do infravermelho das imagens obtidas por sensores orbitais, como Sentinel-2.

A primeira RNA consistiu na segmentação semântica de pixels das imagens para gerar as linhas de costa. Essa segmentação permitiu mapear as linhas de água (WL - *Water Line*), em diferentes datas e condições de maré e gerar uma saída unindo-as. A arquitetura da RNA foi baseada em uma U-Net aprimorada com blocos *Transformer*. Na fase de codificação da U-Net acontece a extração espectral e espacial de características e na fase de decodificação acontece a fusão adaptativa para reconstruir a imagem, destacando os contornos entre os pixels como transições da linha de costa.

A segunda etapa do sistema, foi aplicado uma nova RNA, com arquitetura semelhante, para interpolar as linhas de água detectadas, que foram associadas a dados maregráficos registrados para cada imagem. As cotas atribuídas a cada linha foram derivadas de mareógrafos oficiais, permitindo formar curvas de nível correspondentes às diferentes posições da linha de água. A interpolação entre essas curvas permitiu a geração de um MDE que representam a topobatimetria da zona entremarés em determinado intervalo de tempo.

O treinamento das redes utilizou dois conjuntos de dados principais. O primeiro tinha valores de reflectância e índices espectrais, como *Normalized Difference Water Index* (NDWI), além dos níveis de maré, organizados em formato *Comma Separated Values* (CSV) por imagem e *pixel*. O segundo conjunto foi composto por dados topográficos obtidos por levantamento de campo com

métodos tradicionais (ex.: *Global Navigation Satellite System* (GNSS) *Real Time Kinematic* (RTK) ou estação total), incluindo latitude, longitude e altimetria. Esses dados de campo foram usados para validação dos MDEs gerados pelas RNAs.

Por tanto, a proposta foi construir uma ferramenta a com capacidade de superar os modelos tradicionais baseados apenas em índices espectrais, e competir em desempenho com os modelos de aprendizado de máquina mais recentes encontrados na literatura.

Considerando a pergunta de pesquisa e a solução proposta, o presente trabalho buscou verificar as seguintes hipóteses:

- A utilização de técnicas de RNAs, como o U-Net e transformers, permite gerar MDEs para zonas entremarés, quando integradas a séries históricas de imagens multiespectrais e dados maregráficos.
- A redução do *Mean Absolute Error* (MAE) na previsão da topobatimetria em zonas entremarés ocorre com o aprimoramento dos modelos de RNA por meio de ajustes finos de parâmetros, uso de transformers e integração de séries temporais de imagens, o que melhora a representação da dinâmica costeira ao longo do tempo.
- A aplicação de blocos Transformer na fase de codificação da arquitetura U-Net, combinada com técnicas de fusão adaptativa de características, reduz o MAE na previsão da topobatimetria, ao melhorar a extração e a recomposição de padrões espaciais e espectrais em ambientes costeiros opticamente complexos.
- Modelos baseados em RNA apresentam melhor desempenho na estimativa da topobatimetria em zonas entremarés, com percentuais de redução do erro médio absoluto superiores aos obtidos com métodos tradicionais.

1.1.2 Delimitação de Escopo

Este trabalho restringe-se ao uso de imagens multiespectrais orbitais de acesso público, com foco na missão Sentinel-2. A decisão de não utilizar dados provenientes de sensores ativos, como *Light Detection and Ranging* (LiDAR), *Synthetic Aperture Radar* (SAR), laser scanner terrestre,

VANTs ou imagens comerciais de alta resolução, fundamenta-se no alto custo de aquisição e na baixa viabilidade de replicação global desses métodos.

As bases de treinamento foram geradas por pesquisadores do projeto *Coastal Analyst System from Space Imagery Engine* (CASSIE), por meio da plataforma GEE. O CASSIE é uma iniciativa do Laboratório de Oceanografia Costeira (LOC) da Universidade Federal de Santa Catarina (UFSC), em colaboração com a Universidade do Vale do Itajaí (UNIVALI), voltada ao monitoramento e adaptação da zona costeira às mudanças climáticas. As imagens utilizadas são da Baía da Babitonga, no estado de Santa Catarina, região de estudo do LOC e do projeto CASSIE-Core (CNPq nº 406603/2022-7).

O sistema tem como objetivo atender a uma demanda identificada pelo grupo do CASSIE. Por isso, o sistema será incorporado como um módulo dentro da própria plataforma, que utiliza *Javascript* e o *framework React* em sua interface. Por tanto, o trabalho não abrange o desenvolvimento de uma interface gráfica com usuário.

As RNAs utilizadas neste trabalho foram implementadas em *Python*, com o uso das bibliotecas *Keras* e *TensorFlow*. Os experimentos de treinamento e validação dos modelos foram realizados em um *cluster* com oito *Graphics Processing Unit* (GPU) da marca Nvidia e modelo HGX/H100 disponibilizado pela UFSC para uso compartilhado entre os seus pesquisadores (Chamada CNPq/MCTI/FNDCT nº 22/2024 – ConhecBrasil-REDES – Processo nº 444856/2024-2.).

1.1.3 Justificativa

A zona entremarés representa um dos ecossistemas costeiros mais dinâmicos e ecologicamente relevantes do planeta. Essa faixa de transição entre o ambiente marinho e o terrestre abriga espécies de elevado valor ecológico e econômico, como siris, caranguejos, moluscos e outros invertebrados. Além disso, essas zonas desempenham um papel crucial na dissipação da energia das ondas e na proteção contra eventos extremos, como tempestades e inundações costeiras (Santos et al., 2022; Wu et al., 2024).

A evolução morfológica das zonas entremarés, incluindo processos de erosão, deposição e migração da linha de costa, pode impactar diretamente a disponibilidade de habitat, a estabilidade da faixa de praia e a segurança de áreas urbanizadas adjacentes. A expansão ou retração da faixa

intermaré pode indicar mudanças significativas na dinâmica sedimentar e nas condições oceanográficas, tornando-se um indicador sensível de impactos relacionados às mudanças climáticas, como o aumento do nível médio do mar (Kuenzer et al., 2011; Luijendijk et al., 2018).

Dada a importância das zonas entremarés e as limitações dos métodos tradicionais de levantamento topobatimétrico, a solução proposta baseia-se na integração de imagens de satélite multitemporais, dados dos marégrafos e processamento computacional para alimentar modelos supervisionados de aprendizado de máquina. O uso de dados de acesso livre e de arquiteturas convolucionais replicáveis torna a metodologia tecnicamente viável e economicamente acessível.

A abordagem apresenta potencial de aplicação no monitoramento espaço-temporal da morfologia costeira e no apoio à tomada de decisões relacionadas à adaptação às mudanças climáticas. Em relação aos métodos tradicionais, destaca-se pela ampla cobertura temporal, pela aplicação em escalas regionais e globais, pela dispensa de campanhas de campo e pela maior acurácia e adaptabilidade proporcionadas pelo uso de Redes Neurais Artificiais (Chen et al., 2023).

Em síntese, este trabalho busca contribuir com uma abordagem inovadora, acessível e escalável para o monitoramento de zonas entremarés, fortalecendo a resiliência das áreas costeiras frente às mudanças ambientais globais, contribuindo para o desenvolvimento sustentável definido pela ONU nos Objetivos de Desenvolvimento Sustentável (ODS) 11, 13, 14 e 15 (Figura 1).

Figura 1: Objetivos sustentáveis definidos pela ONU na Década dos Oceanos.



Fonte: UN (2025).

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Desenvolver modelos de RNA para mapeamento e interpolação de dados de topobatimetria da zona intermarés, aplicando técnicas de RNA para minimizar os erros do modelo matemático e apresentar alternativas mais eficientes e menos custosas aos levantamentos por métodos tradicionais.

1.2.2 Objetivos Específicos

1. Realizar uma revisão sistemática da literatura sobre o uso de Redes Neurais Artificiais aplicadas à topografia entremarés derivada de satélites para conhecer o estado a arte.
2. Desenvolver um modelo de RNA capaz de identificar linhas d'água em zonas entremarés com base em imagens multiespectrais e serie-temporais.
3. Desenvolver um modelo de RNA capaz de interpolar dados dos marégrafos com as linhas d'água para gerar Modelos Digitais de Elevação (DEM, *Digital Elevation Model*).
4. Validar os MDE gerados por meio de dados coletados em campo através de métodos topográficos tradicionais de alta precisão, como Laser Scanner Terrestre.

1.3 METODOLOGIA

1.3.1 Metodologia da Pesquisa

Esta pesquisa utiliza o método hipotético-dedutivo de Popper (1975), no qual se estabelecem perguntas de pesquisa e, a partir delas, deduzem-se hipóteses para solucionar o problema. Essas hipóteses são testadas e analisadas, por meio de tentativas e eliminação de erros, e com o objetivo de serem provadas ou refutadas.

A abordagem adotada nesta pesquisa é quantitativa, pois métricas numéricas são empregadas para avaliar os modelos, permitindo a validação ou refutação das hipóteses. E pesquisas quantitativas usam ferramentas estatísticas para medir a relação entre variáveis.

A natureza desta pesquisa é aplicada, pois visa gerar conhecimentos para aplicações práticas, orientadas à solução de problemas específicos.

Os objetivos caracterizam essa pesquisa como exploratória, pois, examinam um conjunto de fenômenos e identificam padrões e anomalias para fundamentar pesquisas mais aprofundadas. E neste trabalho realizou-se uma revisão bibliográfica buscando autores e soluções relacionadas ao tema RNAs aplicadas a zonas entre marés e buscando também compreender o estado da arte de geração de MDEs para zonas entre marés.

1.3.2 Procedimentos Metodológicos

Esta seção apresenta os procedimentos metodológicos realizados nesta pesquisa.

- 1. Definição do problema:** Esta etapa teve como objetivo entender o tema, suas problemáticas, vertentes e delimitar o problema abordado.
- 2. Revisão bibliográfica:** Esta etapa teve como objetivo levantar os conhecimentos necessários para a execução do trabalho, ou seja, proporcionar a fundamentação teórica necessária para o desenvolvimento da pesquisa.
- 3. Revisão sistemática da literatura:** Esta etapa teve como objetivo entender o estado da arte relacionado ao problema, levantando as principais dificuldades, falhas e acertos encontrados

nos trabalhos correlatos ao tema para nortear esta pesquisa. E identificar e classificar os modelos baseados em RNA mais promissores descritos na literatura científica.

4. **Avaliação e preparação da base de conhecimento:** Esta etapa teve como objetivo conhecer a base de conhecimento para projetar pré-processamentos e assim prepará-la para o uso nos modelos de RNA.
5. **Implementação dos modelos:** Esta etapa teve como objetivo implementar os modelos de RNA necessários para validar a hipótese de pesquisa.
6. **Experimentos:** Esta etapa teve como objetivo testar e recolher dados de execuções dos modelos para realizar possíveis melhorias nos modelos até que fosse possível validar ou refutar a hipótese de pesquisa.
7. **Análise dos resultados:** Esta etapa teve como objetivo avaliar os resultados dos modelos experimentados frente aos modelos da literatura e o modelo matemático, com o intuito de gerar conhecimento e documentação das conclusões retiradas do experimento.

1.4 ESTRUTURA DA DISSERTAÇÃO

O **Capítulo 1, Introdução**, apresentou por meio de sua contextualização o tema proposto neste trabalho. Da mesma forma, foram estabelecidos os resultados esperados por meio da definição de seus objetivos e apresentadas as limitações do trabalho permitindo uma visão clara do escopo proposto.

O **Capítulo 2** apresenta a **fundamentação teórica** sobre o método de topobatimetria derivada de satélite em zonas entremarés, com ênfase na aplicação de modelos de RNA baseados na arquitetura U-Net para detecção da linha de costa.

O **Capítulo 3** apresenta uma **revisão sistemática** da literatura baseada na metodologia PRISMA, com apoio de análises bibliométricas, trazendo tanto as estatísticas dos metadados da base bibliográfica de referência, quanto a apresentação do estado da arte sobre o tema.

O **Capítulo 4** apresenta o **projeto de trabalho**, com a descrição das etapas de pré-processamento dos dados de sensoriamento remoto e dos dados de marés, e os de preparação para a

entrada nos modelos de RNA. Bem como, a estrutura e arquitetura dos modelos de RNAs desenvolvidos.

O **Capítulo 5** apresenta e analisa os **resultados** alcançados nas etapas de pré-processamento e desenvolvimento, treinamento e validação das RNAs, comparando os resultados entre os modelos implementados, os resultados parciais alcançados e com os métodos tradicional.

O **Capítulo 6** apresenta as **considerações finais** sobre o trabalho, retratando as questões fundamentais, aceitando ou refutando as hipóteses de pesquisa, mostrando as contribuições deste estudo e os possíveis pontos de melhoria futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como objetivo apresentar embasamento teórico necessário para o entendimento do tema deste trabalho, a saber: (1) Zonas Entremarés; (2) Sensoriamento Remoto; (3) Topografia Entremarés Derivada de Satélites; e (4) Aprendizado de Máquina Aplicado a Topografia Entremarés Derivada de Satélites.


2.1 ZONAS ENTREMARÉS

As zonas entremarés representam faixas costeiras alternadamente expostas e submersas. A variabilidade temporal e espacial dessas zonas está diretamente associada ao regime de marés e à morfologia do ambiente costeiro. As subseções a seguir abordam os principais elementos que influenciam a estrutura e o comportamento das zonas entremarés: as marés oceânicas e a morfologia entremarés.

2.1.1 Marés Oceânicas

O fenômeno das marés tem origem na atração entre as massas de corpos celestiais (Terra-Lua ou Terra-Sol), que se movimentam em torno de Centro de Massa comum (Wood, 2001). A resposta oceânica às forças geradoras da maré leva em conta a teoria do equilíbrio de Newton, onde a força geradora da maré é resultado do gradiente de força de atração gravitacional entre a Terra e a Lua que gera as duas protuberâncias no oceano (Wright; Colling; Park, 2002) (Figura 2).

Figura 2: Representação esquemática das forças de Maré Lunares e da Deformação da Superfície dos Oceanos na Terra.




Fonte: Adaptado de (Wright; Colling; Park, 2002).

Na Figura 2, o lado esquerdo é apresentado a magnitude relativa das forças geradas da maré em vários pontos sobre a terra. Na direita, a deformação da superfície do mar devido à maré, mostrada de forma exagerada. Em ambos os casos, a lua está na direção do equador terrestre (Wright; Colling; Park, 2002).

Com base na teoria do equilíbrio as marés semidiurnas, em todos os pontos do planeta, apresentam uma periodicidade de 12 horas e 25 minutos. Isso quer dizer que em 24 horas temos 2 ciclos de maré completos, ou seja duas mares baixas e 2 marés altas na maior parte das zonas costeiras do mundo (Wright; Colling; Park, 2002).

Em bacias oceânicas delimitadas pelos continentes, a rotação da Terra e os contornos continentais geram pontos onde a amplitude é nula e em torno dos quais a onda de maré rotaciona, conhecidos como pontos anfifrômicos (Wood, 2001). A amplitude das marés cresce com a distância a esses pontos, sendo mínima nos nós e máxima nas bordas das bacias (Martin; Dalrymple, 1994). A Figura 3 a seguir mostra a distribuição dos pontos ao redor das bacias oceânicas, sendo os tons mais escuros indicam onde as marés são menos intensas, já os tons mais claros indicam as áreas de maior variação de maré.

Figura 3: Distribuição dos pontos anfifrômicos das principais bacias oceânicas.



Fonte: Adaptado de Martin e Dalrymple (1994).

2.1.2 Morfologia Entremarés

As zonas entremarés, ou intermarés, correspondem a faixas do litoral que ficam alternadamente expostas e submersas devido à oscilação do nível do mar provocada pelas marés astronômicas (Bishop-Taylor et al., 2019). A extensão, complexidade morfológica e dinâmica dessas zonas variam significativamente de acordo com o regime de maré local (Masselink; Hughes; Knight, 2011).

As regiões entremarés podem ser classificadas em três zonas principais: micromarés, mesomarés e macromarés; de acordo com a variação da amplitude da maré em função da localização do setor costeiro em relação ao ponto anfidrômico mais próximo, onde: zonas de micromarés apresentam amplitude de variação do nível d'água inferior a 2 metros, zonas de mesomarés têm amplitude de maré entre 2 e 4 metros, já as zonas de macromarés apresentam amplitude superior a 4 metros (Davies, 1964). Em regiões de macromarés, a amplitude elevada geralmente provoca a formação de extensas planícies de maré com morfologia complexa e variada, enquanto no outro extremo as zonas de micromarés apresentam uma faixa de transição entre o mar e a terra mais reduzida e com menores variações morfológicas (Masselink; Hughes; Knight, 2011).

2.2 SENSORIAMENTO REMOTO

O Sensoriamento remoto (SR) é a técnica que utiliza sensores para obtenção de informações sobre objetos ou fenômenos, sem que haja interação física direta entre eles (Meneses; Almeida; Baptista, 2019). Essa tecnologia tem se consolidado como uma ferramenta essencial para o monitoramento ambiental, análises espaciais e temporais, e estudos diversos no campo das geociências.

Atualmente existem diversas missões de satélites em operação para observação da Terra. Estes satélites podem ser equipados com sensores do tipo ativo, os quais emitem um sinal em direção a um alvo e capturam o sinal refletido, ou do tipo passivo, os quais apenas capturam o sinal refletido pela superfície de um objeto iluminado pela radiação solar (Meneses; Almeida; Baptista, 2019). A órbita dos satélites da Terra pode ser geoestacionária, que monitora sempre o mesmo setor do planeta, ou

heliossíncrona, que mapeia toda a superfície terrestre com variadas resoluções espaciais e temporais (tempo de revisita) (Wulder et al., 2016).

O início das missões com foco na observação das características ambientais da Terra é marcado pelo lançamento do primeiro satélite do programa *Earth Resources Technology Satellite* (ERTS) em 1972, desenvolvido pela Agência Espacial Americana, *National Aeronautics and Space Administration* (NASA). O ERTS passou a ser chamado de Landsat a partir de 1975, de modo que as coleções de imagens Landsat já apresentam catálogos com séries temporais de imagens com mais de 40 anos de registros (Wulder et al., 2016).

A consolidação dessas séries temporais abriu caminho para novas missões de sensoriamento remoto, como a missão Sentinel-2 do programa Copernicus da Agência Espacial Europeia, European Space Agency (ESA), composta pelos satélites Sentinel-2A e Sentinel-2B, projetados para ampliar a capacidade de monitoramento ambiental com maior resolução espacial, maior frequência de revisita e maior número de bandas espectrais (Drusch et al., 2012).

2.2.1 Imagens de Satélite

As imagens de satélite, de forma geral, são compostas por bandas espectrais, que representam intervalos específicos do espectro eletromagnético (Figura 4). Cada banda corresponde a uma faixa de comprimentos de onda na qual o sensor mede a refletância da radiação solar proveniente da superfície terrestre (Meneses; Almeida; Baptista, 2019).


No caso do satélite Sentinel-2, o sensor registra 13 bandas espectrais distribuídas entre o visível, infravermelho próximo e infravermelho de ondas curtas, gerando imagens com resoluções espaciais de 10, 20 e 60 metros dependendo da banda. As bandas do visível (aproximadamente 400 a 700 nm), como azul (B2), verde (B3) e vermelho (B4), são sensíveis à cor e à composição da superfície. Em superfícies secas, como areia ou solo exposto, a refletância tende a ser mais elevada, enquanto superfícies molhadas ou cobertas por água apresentam maior absorção da radiação, resultando em valores mais baixos de refletância. No infravermelho próximo, como a banda B8 (aproximadamente 842 nm), o contraste entre água e superfícies terrestres torna-se mais evidente: solos e vegetação apresentam alta refletância, enquanto a água absorve fortemente essa radiação. Já no infravermelho de ondas curtas, como nas bandas B11 (aproximadamente 1610 nm) e B12

(aproximadamente 2190 nm), a absorção pela água é ainda maior, permitindo diferenciar com maior clareza superfícies secas, úmidas ou inundadas (Meneses; Almeida; Baptista, 2019).

Dessa forma, o conhecimento do comportamento espectral das diferentes superfícies ao longo dessas bandas é fundamental para interpretar imagens de satélite e desenvolver métodos de classificação e extração de feições, como a identificação de corpos d'água e zonas entremarés (Meneses; Almeida; Baptista, 2019).

Conforme a Figura 4, a seguir, verifica-se que o espectro eletromagnético varia em comprimento e frequência de onda, as faixas de interesse para estudos de SR estão compreendidas entre as frequências de 450 nanômetros e 100 centímetros, em função das características de absorção e espalhamento das ondas eletromagnéticas nos objetos e a atenuação pela atmosfera.

Figura 4: Divisão do espectro eletromagnético.



Fonte: Adaptado de Meneses, Almeida e Baptista (2019).

Para análises de classificação da superfície terrestre, é comum a utilização de índices espectrais, obtidos por meio da combinação matemática entre diferentes bandas do espectro eletromagnético. Esses índices exploram o comportamento espectral característico de determinados

alvos para realçar feições específicas na imagem (Meneses; Almeida; Baptista, 2019). Entre os mais utilizados destacam-se:

- O NDVI (*Normalized Difference Vegetation Index*), proposto por J. W. Rouse et al. (1974), que utiliza as bandas do vermelho e do infravermelho próximo para realçar áreas vegetadas;
- O NDWI (*Normalized Difference Water Index*), desenvolvido por Gao Bo-Cai (1996), que utiliza as bandas do infravermelho próximo e do infravermelho de ondas curtas para realçar o conteúdo de água em superfícies naturais;
- O MNDWI (*Modified Normalized Difference Water Index*), proposto por Xu Hanqiu (2006), que substitui o infravermelho próximo pelo verde para melhorar a detecção de corpos d'água em áreas urbanas;
- O AWEI (*Automated Water Extraction Index*), desenvolvido por Feyisa Gudina Legesse et al. (2014), que combina múltiplas bandas para reduzir interferências causadas por sombras e superfícies escuras.

Esses índices são amplamente empregados em aplicações de sensoriamento remoto voltadas ao monitoramento ambiental e à classificação de superfícies (Meneses; Almeida; Baptista, 2019).


2.2.2 O Sensoriamento Remoto Aplicado

O SR aplicado à oceanografia costeira baseia-se na absorção e espalhamento da radiação solar não apenas nos objetos de superfície, mas também no comportamento do espectro óptico que penetra na coluna d'água, e sua interação com o material de fundo, a presença de fito e zooplâncton, de material em suspensão e/ou matéria orgânica dissolvida (Alpaydin, 2020).

Turner et al. (2021) categorizaram as diversas missões de satélites com sensores óticos de acordo com a data de lançamento, resolução espacial e frequência temporal (Figura 5). Os dados apresentados na Figura 5 evidenciam um gradativo aumento no número de missões de satélites com sensores óticos nos últimos 40 anos. A figura também indica que houve ganhos significativos no tempo de revisita e na resolução espacial para o tamanho de pixel gerado. Enquanto as missões no início dos anos 70 apresentavam tempos de revisita com mais de duas semanas e resoluções espaciais

na casa das dezenas de metros, as missões mais modernas, lançadas a partir dos anos 2000, passam a apresentar tempo de revisita diário com resolução centimétrica.

Figura 5: Linha do tempo dos principais satélites óticos de observação com cobertura global.



Fonte: Adaptado de Turner et. al. (2021).

Embora as missões de satélite mais recentes, com frequências de revisita diária e resolução de pixel centimétrica (quadro inferior da Figura 5) sejam extremamente atrativas para estudos detalhados de morfologia costeira, essas missões são de propriedade privada, sendo seus produtos comercializados a preços, na maior parte das vezes, incompatíveis com os recursos disponíveis para pesquisa científica exploratória. Por isso, as missões de iniciativa governamental, as quais disponibilizam seus produtos ao público geral sem custos (quadro superior da Figura 5), são as mais utilizadas na literatura científica especializada.

O Tabela 1 apresenta a densidade de uso dos produtos derivados das diferentes missões de satélite, ao longo das últimas quatro décadas, com base na literatura selecionada pela análise bibliométrica apresentada em detalhes no Capítulo 3 deste estudo.

Tabela 1: Tabela de uso dos satélites e suas missões ao longo dos anos.

Satélite	1980 - 2000	2001 - 2010	2011 - 2020	2021 - Presente
Landsat 1 a 4	1	0	3	2
Landsat 5 TM	2	15	27	9
Landsat 7 ETM	0	10	15	8
Landsat 8 OLI	0	0	9	13
Sentinel-1 SAR	0	0	2	4
Sentinel-2 MSI	0	0	3	16
inSAR	10	15	24	6
MODIS	0	3	7	2
ICESat-2 (LA)	0	0	0	2
Outros	4	16	33	11
Notas: *Diversos outros sensores também foram utilizados nos artigos, dentre eles: IKONS, ASTER, SWOT, SPOT, EOS-Terra, QUIKBIRD, SMAP, MOS, ICESat-2, Geoeye e CBERS. ** O mapa de calor (Quanto mais escuro a cor mais ocorrências) apresentado na tabela foi utilizado para ilustrar a densidade de ocorrência, facilitando a compreensão visual.				

Fonte: Freitas (2025).

Os estudos sobre a morfologia das zonas intermareais frequentemente utilizam imagens de sensores multiespectrais, sendo a missão Landsat-5 a mais utilizada, seguida pelos sensores ativos do tipo SAR. As imagens Landsat-5 se destacam por serem as únicas com uma série temporal contínua desde 1984 até 2011, sendo largamente utilizada para mapear alterações da paisagem em escala decadal. No entanto, as duas últimas colunas da tabela mostram o crescente uso de missões públicas mais recentes, como Landsat-8, com destaque para Sentinel-2 que apresentou uma tendência de aumento de até cinco vezes na última década, devido a escala espacial mais refinada de 10 metros por pixel em contraste com a resolução de 30 metros por pixel dos sensores OLI-Landsat.

A escolha do satélite pode ser crucial para o sucesso da aplicação de métodos de topografia derivada de satélites para zonas entremarés, uma vez que satélite equipados com sensores multiespectrais ou hiperespectrais (que apresentam menores lacunas de faixas do espectro, como sentinel-2) podem aumentar significativamente a exatidão do método em regiões com maior complexidade ótica (Turner et al., 2021).


2.3 TOPOGRAFIA ENTREMARÉS DERIVADA DE SATÉLITES

Modelos Digitais de Elevação são representações matemáticas tridimensionais da superfície terrestre que descrevem a altitude de cada ponto em relação a um referencial vertical, por exemplo o nível médio do mar ou a média das marés baixas, sendo amplamente utilizados em análises geomorfológicas e mapeamento de relevo com alta precisão de qualquer superfície terrestre, inclusive zonas entremarés (Burrough; McDonnell, 2015).

Os MDEs podem ser gerados a partir de diferentes fontes como topografia convencional, video monitoramento, SAR e as técnicas envolvendo o uso de imagens de satélite (Lyzenga, 1978). O método mais bem desenvolvido para o mapeamento de morfologia da zona entremarés a partir de imagens de satélite é o método conhecido como Linha de Água, *Water Line* (WL), inicialmente proposto por (Mason et al., 1995) para imagens de radar (SAR). Embora esses produtos apresentem vantagens em capturar imagens independente da luz solar e de cobertura de nuvens, sua resolução espacial é insuficiente quando comparada a satélites multiespectrais como o caso do Sentinel-2, disponível publicamente pela ESA (Bué; Catalão; Semedo, 2020; Pereira; Souza; Santos, 2017; Pereira-Sandoval et al., 2022).

O método da Linha de Água original foi adaptado por diferentes autores buscando a geração de MDEs com diferentes abordagens. A Figura 6 ilustra a evolução do método de Linha de Água para a zona intermarés, destacando contribuições significativas de diferentes autores ao longo dos anos.

Figura 6: Linha do tempo das principais contribuições para o método WL em zonas intermarés.



Fonte: Adaptado de Freitas (2025).

Conforme mencionado anteriormente, a introdução do método ocorreu com (Mason et al., 1995), que propuseram o uso de imagens SAR para a construção dos modelos de elevação na zona intermarés. Esse marco inicial definiu a base para os estudos subsequentes.

Em 1997, os trabalhos de Mason et al. (1977) e Mason et al. (1997), aprofundaram o uso do método WL, explorando a integração de dados de marégrafos, já que inicialmente eram utilizados apenas dados de maré extraídos de modelos hidrodinâmicos, e diferentes técnicas de interpolação para melhorar a acurácia dos MDEs gerados.

Nos anos 2000, avanços significativos incluíram o uso de diferentes bandas espectrais e novas técnicas de extração de linhas de costa. Por exemplo, Ryu et al. (2002) introduziram bandas do infravermelho, já passando a utilizar imagens de sensores óticos, com objetivo de melhorar a detecção de limite terra-água, enquanto Liu Jezek (2004) utilizaram limiares adaptados para diferentes setores homogêneos da zona intermarés. Posteriormente, Zhang et al. (2019) aplicaram o filtro laplaciano

(*Laplacian-of-Gaussian*) associado a transformação *Wavelet* para uma detecção mais precisa das bordas no método de Linha de Água.

Estudos mais recentes ampliaram o escopo de aplicações e ferramentas. Sagar et al. (2017) introduziram o agrupamento de imagens de mesmo nível de maré e a aplicação da mediana do índice normalizado de água, NDWI, produzindo uma linha de água sintética, permitindo a aplicação do método em escala continental. Diversas foram as contribuições a respeito dos algoritmos de detecção de borda utilizados, dentre eles cita-se o Canny, utilizado inicialmente pela maioria dos autores, e a introdução do *Marching Square* por Bishop-Taylor et al. (2019).

Além disso, Granadeiro et al. (2021) e Murray et al. (2019) exploraram soluções para extração da linha de água e trouxeram duas grandes contribuições. Os primeiros, introduzindo o uso da plataforma GEE para o tema, utilizou métodos de classificação supervisionada considerando diferentes índices de água e refletância de bandas para definir a abrangência das zonas intermarés em escala global. Já o segundo, introduziu a utilização da variância do índice NDWI para definir a área dessas regiões, a partir do estudo de Bué, Catalão e Semedo (2020) com foco em BDS.

2.4 APRENDIZADO DE MÁQUINA E SUA APLICAÇÃO EM TOPOGRAFIA ENTREMARÉS DERIVADA DE SATÉLITES

O Aprendizado de Máquina (AM), ou *Machine Learning* (ML), é um subcampo da IA que se concentra no desenvolvimento de métodos computacionais para permitir que sistemas aprendam a partir de dados, aprimorando seu desempenho em uma tarefa específica ao longo do tempo ou organizando o conhecimento já existente (Alpaydin, 2016; Sanches, 2003; Goodfellow; Courville, 2016).

Além disso, os modelos de AM são classificados de acordo com a maneira como o algoritmo aprende com os dados, sendo que os principais são: aprendizado supervisionado, não supervisionado e por reforço (Ludermir, 2021; Murphy, 2012).

No aprendizado supervisionado, o algoritmo recebe um conjunto de exemplos de treinamento onde cada entrada (*input*) é acompanhada de uma resposta esperada ou rótulo de saída (*output*) (Murphy, 2012; Géron, 2019). Nesse sentido, o objetivo do algoritmo é construir um modelo (ou uma função) que seja capaz de mapear as entradas para as saídas corretas, de forma a prever com precisão a saída para novos exemplos ainda não rotulados. Este tipo de aprendizado pode ser subdividido em:

Classificação: A técnica visa atribuir uma das categorias predefinidas (rótulos discretos e finitos) a um novo dado de entrada. Por exemplo, classificar a espécie de uma planta a partir da imagem de uma folha (Goodfellow; Courville, 2016).

Regressão: Já a regressão, busca prever um valor contínuo ou numérico para uma dada entrada. Isso é análogo a uma "classificação com rótulos infinitos", onde o modelo estima um valor desconhecido a partir de um conjunto de treinamento com valores de entrada e saída correspondentes. Por exemplo, prever a idade de uma pessoa com base em informações demográficas (Géron, 2019).

No aprendizado não supervisionado, os algoritmos recebem exemplos de dados sem rótulos ou saídas esperadas (Ludermir, 2021; Murphy, 2012). Além disso, o algoritmo tem como objetivo: descobrir estruturas, padrões ocultos ou similaridades intrínsecas nos dados, agrupando-os de alguma maneira (agrupamentos ou *cluster*) ou reduzindo a dimensionalidade.

O aprendizado por reforço envolve um agente que aprende a tomar decisões sequenciais em um ambiente, com o objetivo de maximizar uma recompensa (Murphy, 2012; Goodfellow; Courville, 2016). Nesse sentido, o algoritmo formula hipóteses e realiza "tentativas" de ações e a qualidade dessas ações é avaliada por um sinal de reforço (positivo ou negativo). E através desse processo de tentativa e erro, o agente encontra uma solução ótima para a tarefa, aprendendo quais ações levam a maiores recompensas ao longo do tempo.

2.4.1 Árvores de decisão

Árvores de Decisão, ou *Decision Tree* (DT) são modelos de AM Supervisionado que representam um método hierárquico e estruturado para classificar ou prever resultados. Conceitualmente, elas operam como um fluxograma ou uma estrutura em forma de árvore, onde cada nó interno executa um teste sobre um atributo de entrada (Russell; Norvig, 2022). A partir, do resultado desse teste, o processo segue um ramo específico, levando a outros nós de teste ou, finalmente, a um nó folha. Sendo que, os nós folha contêm a "decisão" ou o valor predito (Majeed et. al., 2017).

Embora sejam simples e intuitivas, as árvores de decisão podem sofrer de superadaptação (*overfitting*), onde se tornam excessivamente complexas para os dados de treinamento. Com o

objetivo de mitigar esse problema, técnicas de poda são aplicadas, simplificando a estrutura da árvore e melhorando sua capacidade de generalização para novos dados (Russell; Norvig, 2022).

2.4.1.1 Floresta Aleatória

O *Random Forest* (RF), ou "Floresta Aleatória", é um método de AM que usa múltiplas Árvores de Decisão para tomar previsões mais precisas e robustas (Breiman, 2001). Onde cada Árvore de Decisão funciona como um guia de perguntas e respostas que leva a uma classificação ou previsão (Russell; Norvig, 2022).

O principal conceito do RF é o *Bagging*, onde várias árvores são treinadas em diferentes subconjuntos de dados, criados por amostragem aleatória (Russell; Norvig, 2022). Com o objetivo de reduzir a chance de as árvores serem muito parecidas, o RF adiciona aleatoriedade em cada ponto de decisão da árvore, ele só considera um subconjunto aleatório de atributos para escolher o melhor caminho, em vez de todos eles (Russell; Norvig, 2022; Breiman, 2001).

2.4.2 Clusterização

A clusterização (ou agrupamento) é uma técnica de aprendizado não supervisionado que organiza dados sem rótulos pré-definidos em grupos (ou *clusters*). Sendo que, o objetivo é que itens dentro do mesmo *cluster* sejam mais semelhantes entre si do que em relação a itens de outros grupos (Jain; Murty; Flynn, 1999; Tan; Steinbach; Kumar, 2014). Por exemplo, um sistema de recomendação, onde agrupa clientes por padrões de compra (Mueller; Massaron, 2018). Nesse sentido, algoritmos como o K-Means, proposto por Tan (2014), são amplamente utilizados para essa tarefa.

2.4.2.1 K-Means

O K-Means é um algoritmo de clusterização particional que recebe um conjunto de dados e busca dividi-lo em K grupos disjuntos (Bishop, 2006; Hastie; Tibshirani; Friedman, 2017). O valor de K, que representa o número de grupos desejados, é um parâmetro de entrada fornecido pelo usuário. Além disso, a construção do agrupamento tipicamente começa com a seleção aleatória dos centroides (pontos centrais) para cada um dos K grupos a serem construídos (Tan; Steinbach; Kumar, 2014).

No entanto, devido à natureza aleatória dessa escolha inicial dos centroides, o K-Means pode produzir agrupamentos diferentes mesmo quando executado múltiplas vezes com o mesmo conjunto de dados e o mesmo valor de K (Tan; Steinbach; Kumar, 2014). No entanto, essa variabilidade pode ser problemática em certas aplicações, pois o algoritmo pode convergir para um ótimo local em vez do ótimo global.

2.4.3 Redes Neurais Artificiais

As RNAs são algoritmos computacionais inspirados em redes neurais biológicas e suas conexões de neurônios, isto porque o nascimento das RNA é associado à tentativa de cientistas de traduzir o cérebro humano em um circuito lógico (Haykin, 2007; Zhu et al., 2017). Nesse sentido, são projetadas para aprender padrões complexos e não-lineares em dados, superando métodos tradicionais em muitas situações (Zhang; Patuwo; Hu, 1998; BISHOP, 2006).

Essas redes aprendem por meio de exemplos e conseguem generalizar esse conhecimento para novas situações. Além disso, as RNAs são compostas por "neurônios" interconectados (Haykin, 2009) e são ferramentas poderosas para problemas onde as relações entre variáveis não são óbvias.

2.4.3.1 Camadas

As RNAs são estruturadas em camadas de neurônios matemáticos organizadas sequencialmente, onde a informação passa de uma camada para a próxima (Goodfellow; Bengio; Courville, 2016). Essa organização é crucial para o processamento e a aprendizagem de representações complexas dos dados (Géron, 2019). A primeira camada de uma rede neural é chamada de camada de entrada (*Input Layer*) e tem como função de receber os dados brutos de entrada. A última camada de uma RNA é chamada de camada de saída (*Output Layer*) e é responsável por gerar o resultado, traduzindo as informações processadas nas etapas anteriores em saídas legíveis. Entre essas duas estão as camadas ocultas (*Hidden Layers*), que são responsáveis pelo processamento principal da rede, onde ocorre a extração das características dos dados (Bishop, 2006; Géron, 2019):

2.4.3.2 Neurônios artificiais

Os neurônios artificiais, são as unidades computacionais básicas que compõem as RNAs. Eles são projetados para processar informações simulando o comportamento dos neurônios biológicos (Bishop, 2006; Haykin, 2009).

Um neurônio artificial recebe diversas entradas, cada uma com um peso associado. Essas entradas são combinadas por meio de uma soma ponderada, à qual é adicionado um valor chamado viés (Haykin, 2009; Ripley 1996). Os pesos e o viés são valores definidos automaticamente durante o processo de treinamento e são atualizados constantemente pelos algoritmos de otimização de acordo com os erros e acertos da rede.

O resultado da soma realizada no neurônio, ainda passa por uma função chamada função de ativação antes de sair do neurônio (Russel; Norvig, 2022; Goodfellow; Bengio; Courville, 2016). Essa função pode variar de acordo com a finalidade da rede neural e por isso, a próxima seção detalha melhor os tipos e usos das funções de ativação.

2.4.3.3 Função de ativação

As funções de ativação permitem que a rede modele relações não lineares entre entradas e saídas, tornando possível a construção de limites de decisão mais complexos e eficientes. Além disso, essas funções padronizam as saídas dos neurônios, contribuindo para o bom desempenho e a precisão do modelo em diferentes tarefas (Mohri; Rostamizadeh; Talwalkar, 2018; Chollet, 2017).

Durante o treinamento, cada neurônio aplica uma função de ativação previamente definida pelo desenvolvedor a nível de camada, que transforma a saída combinada dos pesos e do viés em um valor útil. No entanto, para que a saída de um neurônio represente uma informação útil ao sistema, é necessário moldá-la adequadamente. As funções de ativação cumprem esse papel ao transformar a saída do neurônio em uma resposta mais interpretável para as próximas camadas (Géron, 2019).

As funções mais utilizadas incluem a sigmóide, a tangente hiperbólica ($\tanh$) e a unidade linear retificada (ReLU). Esta última possui diversas variações, como a PReLU e a GeLU, que buscam corrigir limitações da ReLU em determinados cenários (Goodfellow; Bengio; Courville, 2016). Também é amplamente utilizada a função *softmax*, que é capaz de transformar os valores em probabilidades, e por conta disso é essencial para problemas de classificação (Braga; Ludemir, Carvalho, 2007).

Sigmóide

A função Sigmóide, caracterizada por seu formato em "S" (não linear), mapeia qualquer valor de entrada para uma saída entre 0 e 1 (Goodfellow; Bengio; Courville, 2016). Geralmente é utilizada para classificação binária, mas pode sofrer do problema de "gradiente *vanishing*" (desaparecimento do gradiente) para valores de entrada muito grandes ou pequenos, o que dificulta o treinamento de redes profundas (Goodfellow; Bengio; Courville, 2016). Abaixo será apresentado a equação que caracteriza esta função, equação 1:

$$s(x) = \frac{1}{1+e^{-x}} \quad (1)$$

Tangente Hiperbólica (Tanh)

A função Tangente Hiperbólica (Tanh) é muito similar à Sigmóide, mas sua saída varia entre -1 e 1, sendo simétrica em relação à origem (Alpaydin, 2020). Embora um pouco melhor que a Sigmóide em termos de gradientes em torno do zero, ela ainda enfrenta o problema de saturação para valores extremos (Goodfellow; Bengio; Courville, 2016). Abaixo apresenta-se a equação que caracteriza esta função (equação 2) nessa equação, s é a função sigmoide:

$$t(x) = 2 \times s(2x) - 1 \quad (2)$$

ReLU (*Rectified Linear Unit*)

A função ReLU (*Rectified Linear Unit*), é atualmente a função de ativação mais utilizada em redes neurais, devido ao seu desempenho em arquiteturas de computação paralela, como GPUs (Goodfellow; Bengio; Courville, 2016). Sua definição é simples: retorna zero para valores negativos e mantém os valores positivos inalterados. Por tanto, sua fórmula pode ser expressa como a seguir na equação 3:

$$r(x) = \max(0, x) \quad (3)$$

Sua principal vantagem está no fato de não saturar para valores positivos, o que contribui para mitigar o problema do gradiente *vanishing* (Glorot, Bordes e Bengio, 2011). Por outro lado, a ReLU apresenta uma limitação conhecida como “neurônios mortos”, situação em que determinados neurônios deixam de aprender por receberem constantemente valores negativos na entrada, o que impede a atualização dos seus pesos (Maas, Hannun e Ng, 2013).

GeLU (*Gaussian Error Linear Unit*)

A função GeLU (*Gaussian Error Linear Unit*) é uma função de ativação recente, usada em modelos como os Transformers (Goodfellow; Bengio; Courville, 2016). Ela é uma função suave, o que significa que não apresenta quebras ou pontos não deriváveis, como ocorre na ReLU. Essa redução é baseada na probabilidade acumulada da distribuição normal padrão, o que faz com que valores negativos pequenos ainda contribuam parcialmente para a saída, enquanto valores muito negativos sejam praticamente descartados. Essa transição suave entre os extremos permite uma representação mais rica e contínua das informações durante o treinamento da rede (Hendrycks; Gimpel, 2016):

$$g(x) = \frac{x}{2} \left(1 + \operatorname{erf} \left(\frac{x}{\sqrt{2}} \right) \right) \quad (4)$$

Softmax

A função Softmax é amplamente utilizada na camada de saída de redes neurais para problemas de classificação multiclasse (Braga; Ludemir; Carvalho, 2007). Ela transforma os valores produzidos pelos neurônios em probabilidades normalizadas, ou seja, valores entre zero e um. Isso permite interpretar cada saída como a probabilidade de a entrada pertencer a uma determinada classe (Géron, 2019):

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (5)$$

Hiperparâmetros

Durante o treinamento de uma RNA, é possível configurar vários parâmetros gerais, que não são aprendidos diretamente dos dados. Geralmente, os valores são selecionados de forma empírica, começa com valores padrões e vai se ajustando conforme o necessário. A seleção e o ajuste adequado desses hiperparâmetros são cruciais para o sucesso do treinamento de uma RNA, influenciando diretamente a velocidade de convergência e a capacidade de generalização do modelo (Corte; Santos; Casanova, 2019; Géron, 2019). Entre os hiperparâmetros mais importantes, destacam-se:

Tamanho do Lote (*Batch Size*): Refere-se ao número de exemplos de treinamento processados em uma única iteração antes que os pesos da rede sejam atualizados (Goodfellow; Bengio; Courville, 2016). No entanto, lotes maiores podem acelerar o treinamento, mas exigem mais memória.

Quantidade de Épocas de Treinamento (*Epochs*): Define quantas vezes o conjunto de dados completo será apresentado à rede durante o treinamento (Corte; Santos; Casanova, 2019; Bishop, 2006). A escolha de mais épocas pode levar a um melhor aprendizado, mas também aumentam o risco de *overfitting* (onde a rede "memoriza" os dados de treinamento em vez de generalizar).

Otimizadores: São algoritmos que ajustam os pesos e parâmetros da rede para minimizar a função de perda (erro) durante o treinamento (Géron, 2019; Russel; Norvig, 2022). O otimizador mais clássico é o Método do Gradiente (ou Gradiente Descendente), que busca um mínimo local na função de perda ajustando os pesos na direção oposta ao gradiente.

Diversos tipos de otimizadores surgiram como variações do método do gradiente, buscando melhorar a eficiência e a robustez do treinamento (Ruder, 2016). Exemplos populares incluem: Adam e Adamax (Ruder, 2016), Adadelta (Zeiler, 2012), Adagrad (Duchi; Hazan; Singer, 2011), Nesterov (Nesterov, 1983), Nadam (Dozat, 2016), RMSProp (Goodfellow; Bengio; Courville, 2016).

2.4.4 Treinamento

As redes neurais se baseiam nos dados para extrair padrões e construir modelos de predição. Por essa razão, é fundamental ter um controle rigoroso sobre a qualidade e a divisão dos dados utilizados. Antes de iniciar o treinamento, é necessário dividir o conjunto de dados em dois subconjuntos: um para treino e outro para teste. Geralmente, utiliza-se entre 67% e 80% dos dados

para o treinamento e entre 20% e 33% para o teste. Essa divisão deve ser feita de forma aleatória, a fim de evitar que o modelo aprenda padrões específicos de um subconjunto e falhe ao generalizar para novos dados (Géron, 2019).

Uma técnica amplamente adotada para tornar essa avaliação mais robusta é a validação cruzada do tipo k-fold. Nesse método, o conjunto de dados é dividido em k partes de tamanho igual. Em cada iteração, uma parte é usada para teste enquanto as demais são utilizadas para treinamento. O processo se repete k vezes, e ao final, os resultados são combinados para gerar uma estimativa mais estável do desempenho do modelo. Essa abordagem reduz a variabilidade nos resultados e melhora a generalização do modelo, sendo especialmente útil quando se trabalha com bases de dados limitadas (Hastie; Tibshirani; Friedman, 2017).

2.4.5 Métricas de avaliação

A avaliação quantitativa do desempenho dos modelos de RNA é essencial para garantir sua validade e capacidade de generalização. Essa avaliação se baseia em métricas distintas, conforme o tipo de tarefa: classificação ou regressão - a escolha e aplicação adequada dessas métricas permite interpretar os resultados do modelo, monitorar seu desempenho durante o treinamento e compará-lo com abordagens alternativas (Zhu et al., 2018). A presença de dados de validação obtidos por métodos tradicionais, como levantamento topográfico e geodésico com GNSS, fortalece a representatividade do modelo ao permitir a comparação entre os valores observados e os preditos.

Nos problemas de classificação, de acordo com Goodfellow, Bengio e Corville et.al (2016), a avaliação baseia-se geralmente na matriz de confusão, que organiza os resultados em quatro categorias principais:

Verdadeiro Positivo (VP): o modelo acerta ao classificar corretamente uma instância como pertencente à classe positiva;

- **Falso Positivo (FP):** o modelo classifica como positiva uma instância que, na realidade, é negativa;
- **Verdadeiro Negativo (VN):** o modelo acerta ao classificar uma instância como negativa;

- **Falso Negativo (FN):** o modelo classifica erroneamente uma instância positiva como negativa.

Já nos problemas de regressão as métricas envolvem o cálculo da diferença entre os valores previstos e os reais. Essas métricas são fundamentais para quantificar o grau de aproximação entre o modelo e os dados reais, especialmente em tarefas que envolvem a geração de superfícies contínuas, como Modelos Digitais de Elevação (Goodfellow; Bengio; Courville, 2016). Nas próximas seções serão apresentadas as métricas mais relevantes para esse trabalho.

2.4.5.1 Precisão

A precisão, equação (6), é uma métrica comumente usada em classificações e representa a proporção de predições positivas corretas sobre o total de predições positivas feitas pelo modelo (Powers, 2020):

$$P = \frac{VP}{VP + FP} \quad (6)$$

2.4.5.2 Acurácia

A acurácia, equação (7), mede a proporção total de predições corretas, combinando acertos nas classes positivas e negativas. Muito usada em problemas de classificação (Wilks, 2006):

$$Acurácia = \frac{VP + VN}{Total\ de\ observações} \quad (7)$$

2.4.5.3 Correlação de Pearson

A correlação de Pearson (8) mede a força e direção de uma relação linear entre duas variáveis quantitativas. Assume distribuição normal e linearidade entre os dados (Wilks, 2006):

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (8)$$

Onde:

- x_i : é o dado observado;
- $\bar{x}$: é valor médio observado;
- y_i : é o dado modelado;
- $\bar{y}$: é valor médio do dado modelado.

2.4.5.4 Correlação de Spearman

A correlação de Spearman (9) mede a força e a direção de uma relação monotônica entre duas variáveis. E ao contrário da correção de Pearson, não assume a distribuição normal e nem a linearidade entre os dados (Miot, 2018):

$$p = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (9)$$

Onde:

- p : coeficiente de correlação de postos de Spearman;
- d_i : diferença entre dois postos de cada observação;
- n : número de observações;

2.4.5.5 MAE

O *Mean Absolute Error* (MAE), Erro Médio Absoluto, equação (10), mede a média das diferenças absolutas entre os valores observados e preditos fornecendo uma estimativa intuitiva da magnitude do erro (Chai; Draxler, 2014):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

Onde:

- y_i : é o dado observado; e
- $\bar{y}$: é o dado modelado.

2.4.5.6 MSE

O *Mean Squared Error* (MSE), equação (11), representa a média dos quadrados dos erros, similar ao RMSE mas sem aplicar a raiz quadrada, o que torna a penalização de grandes erros ainda mais intensa (Chai; Draxler, 2014):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

2.4.5.7 RMSE

O *Root Mean Square Error* (RMSE), Raiz do Erro Quadrático Médio, equação (12)

(13), é a raiz quadrada da média dos erros quadráticos entre valores observados e estimados. Penaliza mais fortemente grandes erros (Legates et al, 1999).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

2.4.6 Arquiteturas de RNAs

A arquitetura de uma rede neural é a forma como seus neurônios são organizados em camadas e se conectam (Haykin, 2009). Essa combinação de neurônios e funções de ativação em cada camada

cria redes com estruturas e aplicações variadas (Goodfellow; Bengio; Courville, 2016). Sendo assim, a escolha da arquitetura é vital e depende do tipo de aprendizado (supervisionado, não supervisionado ou por reforço) e da propagação dos sinais (Murphy, 2012; Russell; Norvig, 2022).

O *Multilayer Perceptron* (MLP) é um tipo de rede neural artificial composta por múltiplas camadas de neurônios organizadas de forma sequencial. É uma rede do tipo *feedforward*, em que cada neurônio é totalmente conectado aos da próxima camada, permitindo o aprendizado de relações não lineares entre entrada e saída (Goodfellow; Bengio; Courville, 2016).

2.4.6.1 Redes Neurais Convolucionais


As Redes Neurais Convolucionais, *Convolutional Neural Networks* (CNN), são uma classe de redes neurais artificiais especialmente eficazes para o processamento de dados com estrutura espacial, como imagens. Elas utilizam camadas convolucionais que aplicam filtros sobre a entrada para extrair características locais relevantes, como bordas, texturas e formas. Combinadas com camadas de *pooling* e funções de ativação não lineares, as CNNs aprendem representações hierárquicas dos dados, sendo amplamente aplicadas em tarefas como classificação de imagens, detecção de objetos e segmentação semântica (Goodfellow; Bengio; Courville, 2016; LeCun et al., 1998).

A arquitetura U-Net, proposta por Ronneberger, Fischer e Brox (2015), é uma variação das redes neurais convolucionais (CNN) especialmente desenvolvida para tarefas de segmentação de imagens. Seu nome vem do formato em “U” característico da sua estrutura, que combina um caminho de codificação (*encoder*) e um caminho de decodificação (*decoder*), conectados por atalhos (*skip connections*) entre camadas de mesma resolução. No codificador, a rede extrai características importantes da imagem por meio de camadas convolucionais e operações de redução espacial (*pooling*), como nas CNNs tradicionais. Já no decodificador, essas informações são gradualmente ampliadas para reconstruir a imagem segmentada na resolução original (Ronneberger, Fischer e Brox, 2015).

As conexões de atalho são fundamentais, pois permitem que os detalhes capturados nas camadas iniciais — que contêm informações espaciais precisas — sejam diretamente integrados às camadas correspondentes do decodificador. Isso evita a perda de detalhes finos e melhora a precisão da segmentação. Assim, a U-Net consegue capturar padrões em múltiplos níveis e repassá-los para o

resultado. Por essas características, a U-Net é amplamente utilizada em aplicações que exigem segmentação precisa, como imagens médicas, sensoriamento remoto e outras áreas onde a delimitação de objetos é essencial. A Figura 7 ilustra a arquitetura da U-Net descrita anteriormente.

Figura 7: Arquitetura U-Net encoder-decoder utilizada na RNA de interpolação de dados.



Fonte: Adaptado de Chen et. al. (2023).

2.4.7 Redes Neurais Recorrentes

As Redes Neurais Recorrentes, *Recurrent Neural Networks* (RNN) são uma classe de redes neurais que recebem entrada de duas fontes: um referente ao instante atual e outra proveniente de um instante anterior. Essas informações são combinadas para determinar a resposta a uma nova entrada, utilizando um circuito de *feedback*, onde a saída de cada instante é uma entrada para o instante seguinte. Por essa característica, as RNN possuem memória temporal, tornando-as capazes de reconhecer contextos ao longo do tempo, de forma semelhante ao processamento humano de informações (Zaremba, Sutskever e Vinyals, 2014).

As RNN são eficazes no processamento de dados sequenciais e temporais, sendo utilizadas em aplicações como tradução automática, reconhecimento de fala e análise de séries temporais geradas por sensores. Essa capacidade torna as RNN adequadas para interpretar contextos dinâmicos em dados que evoluem ao longo do tempo.

No sensoriamento remoto de zonas entremarés, as RNN podem ser aplicadas à análise de séries históricas de imagens de satélite para identificar e monitorar variações nas linhas de água. Essa abordagem facilita o acompanhamento das mudanças ambientais e pode ajudar no planejamento e gestão dessas áreas vulneráveis (Li et al., 2019; Zhang et al., 2019).

2.4.8 Transformers

O *Transformer* é uma arquitetura de rede neural proposta por Vaswani et al. (2017) que substitui as tradicionais redes recorrentes por mecanismos de atenção, permitindo o processamento paralelo de sequências e superando limitações relacionadas à ordem temporal das RNNs. O componente central dessa arquitetura é o mecanismo de atenção escalada por produto escalar, conhecido como *self-attention*, que calcula a importância relativa entre todos os pares de elementos da sequência de entrada (Vaswani et al., 2017; Devlin et al., 2019).

Para isso, o modelo mede a similaridade entre os vetores que representam esses elementos usando o produto escalar, uma operação matemática que gera um número escalar indicando o quanto dois vetores “apontam na mesma direção”. Esse valor é obtido multiplicando os componentes correspondentes dos vetores e somando os resultados. Quanto maior esse valor, maior a similaridade entre os elementos, indicando maior relevância para o modelo (Vaswani et al., 2017).

Entretanto, para evitar que esses valores fiquem muito grandes e causem dificuldades no treinamento, o produto escalar é dividido pela raiz quadrada da dimensão dos vetores, o que dá origem ao termo “escalada”. Esse processo permite que o *Transformer* capture dependências de longo alcance com alta eficiência computacional, focando nas partes mais importantes da sequência independentemente da distância entre os elementos. Como resultado, o *Transformer* apresenta maior capacidade de aprendizado e desempenho superior em tarefas complexas em relação as RNNs (Vaswani et al., 2017; Devlin et al., 2019).

O *Vision Transformer* (ViT) é uma adaptação da arquitetura Transformer para a tarefa de visão computacional, apresentada por Dosovitskiy et al. (2021). Diferentemente das redes convolucionais tradicionais (CNNs), que utilizam filtros locais para extrair características, o ViT divide a imagem em pequenos patches fixos que são tratados como tokens sequenciais, semelhantes às palavras em texto. Esses patches são então processados pelo *Transformer*, permitindo que o

modelo capture relações globais entre diferentes regiões da imagem com maior flexibilidade e eficiência (Dosovitskiy et al., 2021).

O Metaformer, ou *mix transformer* (MiT), é uma arquitetura que generaliza o design do *Transformer*, proposta para unificar e ampliar os mecanismos de processamento de dados em diferentes domínios. Enquanto o *Transformer* tradicional é centrado no mecanismo de atenção, o Metaformer abstrai esse conceito para um *framework* modular, no qual o núcleo da arquitetura é um bloco genérico de *token-mixing*, ou seja, um mecanismo que combina informações entre tokens, podendo ser implementado por atenção, convoluções, *pooling* ou outras operações (Li et al., 2023).

O *Convolutional Vision Transformer* (CvT) é uma arquitetura híbrida que combina a capacidade de modelagem global dos *Transformers* com as propriedades locais das redes convolucionais, proposta para superar algumas limitações do ViT, especialmente em relação à captura eficiente de informações locais em imagens (Wu et al., 2021; Yuan et al., 2021).

Diferentemente do ViT, que processa imagens divididas em patches fixos e trata esses patches como tokens, o CvT introduz convoluções diretamente nos estágios iniciais do modelo para extrair características locais e gerar *embeddings*, chaves para o mecanismo de atenção, mais robustos. Além disso, o CvT incorpora convoluções dentro do próprio mecanismo de atenção, resultando em um mecanismo de atenção convolucional que preserva as vantagens da atenção global enquanto reforça a sensibilidade local da rede (Wu et al., 2021; Dai et al., 2021).

O *Mamba Transformer* é uma arquitetura proposta para otimizar o processamento de imagens, combinando mecanismos eficientes de atenção com estratégias que preservam a estrutura espacial das imagens, visando superar limitações dos *Transformers* convencionais em termos de eficiência e escalabilidade (Gu; Dao, 2023). Além disso, o Mamba introduz blocos que integram convoluções locais com atenção global, utilizando um esquema de agrupamento dinâmico de tokens para reduzir a complexidade computacional. Essa abordagem permite que o modelo capture características locais detalhadas e dependências globais simultaneamente, tornando-o eficiente para tarefas como classificação de imagens e detecção de objetos (Gu; Dao, 2023).

Em comparação, o CvT também busca combinar convoluções com mecanismos de atenção para melhorar a eficiência no processamento de imagens, mas utiliza convoluções como um pré-processamento para extrair representações espaciais antes da aplicação da atenção. Enquanto o CvT

foca em aprimorar a extração local via convoluções antes da atenção, o Mamba *Transformer* integra convoluções e atenção dentro dos mesmos blocos, além de empregar o agrupamento dinâmico de tokens (Gu; Dao, 2023; Wu et al., 2021).

2.5 LINHA DO TEMPO DO APRENDIZADO DE MÁQUINA APLICADO A TOPOGRAFIA ENTREMARÉS DERIVADA DE SATÉLITES

A evolução das técnicas de mapeamento da zona entremarés passou por mudanças significativas nas últimas décadas. Inicialmente, os métodos baseados em sensoriamento remoto (SR) utilizavam algoritmos simples para detectar a linha d'água (WL), como limiares aplicados a índices normalizados, especialmente o NDWI (McFeeters, 1996). Esses métodos exigem calibração manual dos limiares, o que afeta diretamente o resultado. Técnicas baseadas em detecção de bordas também foram utilizadas, mas apresentam alta sensibilidade a ruídos, exigindo pós-processamento adicional. Essas abordagens empíricas demonstraram limitações, sobretudo em ambientes com alta complexidade geomorfológica.

A partir de 2015, o campo passou por uma transformação com o avanço do aprendizado profundo. Long, Shelhamer e Darrell (2015). propuseram redes totalmente convolucionais para segmentação semântica em nível de pixel. Pouco depois, Ronneberger, Fischer e Brox (2015) desenvolveram a U-Net, que se tornou uma das arquiteturas mais utilizadas para detecção da WL e geração de Modelos Digitais de Elevação (MDE) em zonas costeiras. A U-Net se destacou por sua estrutura em “U”, que combina codificação e decodificação, e permite a extração eficiente de padrões espaciais complexos.

Entre 2015 e 2018, Chen et al. (2016) introduziram a série *DeepLab*, com avanços como convoluções dilatadas e campos aleatórios condicionais. Em 2017, Zhao et al. (2017) apresentaram o PSPNet, que incorporou o agrupamento piramidal para capturar diferentes escalas espaciais. Já em 2017, Vaswani et al. (2017) apresentaram os *Transformers*, inicialmente aplicados em linguagem natural, mas logo adaptados para visão computacional devido à sua eficiência no processamento paralelo. Com base nessas inovações, Dosovitskiy et al. (2021) propõe o ViT onde aplica a lógica dos Transformers à segmentação de imagens, dividindo imagens em blocos de *pixels* (*patches*) com segmentação semântica. Ainda em 2021, Xie et al. (2021) propuseram o SegFormer, combinando um codificador Transformer hierárquico com um decodificador leve para segmentações.

Mais recentemente Gu e Dao (2024) apresentaram o modelo Mamba, baseado em espaços de estado seletivos. O Mamba reduziu a complexidade dos *Transformers*, mantendo sua capacidade de modelar dependências de longo alcance. Novos modelos derivados do Mamba, como o Samba (Zhu et al., 2024) e o RS3Mamba (Ma; Zhang; Pun, 2024) adaptaram essa arquitetura para aplicações em sensoriamento remoto, combinando a eficiência do Mamba com MLP e CNN para extração de feições em imagens de alta resolução.

3 REVISÃO SISTEMÁTICA

Este capítulo apresentado uma revisão sistemática da literatura (RSL), realizada para compreender o estado da arte e encontrar trabalhos relacionados que respondam as perguntas de pesquisa e que possam contribuir com este trabalho. A seção 3.1 apresenta a metodologia baseada no método PRISMA; a seção 3.2 apresenta a lista dos artigos encontrados a partir das etapas de implementação da metodologia PRISMA sobre os mecanismos de busca; a seção 3.3 apresenta os principais resultados da análise bibliométrica e a seção 3.4 apresenta as análises com o estado da arte obtidos a partir dos artigos selecionados na seção 3.2.

3.1 METODOLOGIA

A RSL seguiu as diretrizes do método PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), conforme descrito por Page et al. (2021). O PRISMA fornece uma estrutura abrangente que assegura a transparência e a qualidade das revisões sistemáticas, abrangendo desde a formulação das perguntas de pesquisa até a análise e apresentação dos resultados. Além disso, a revisão também seguiu as principais diretrizes estabelecidas por Kitchenham em seus trabalhos sobre revisões sistemáticas aplicadas à engenharia de *software* (Kitchenham; Charters, 2007; Kitchenham et al., 2009; Kitchenham; Brereton, 2013).

O primeiro passo da revisão foi a definição das perguntas de pesquisa que devem ser respondidas pela revisão. Essas perguntas não precisam parecer com as perguntas da dissertação, pois aqui a ideia é nortear a revisão. O Quadro 1, a seguir, apresenta as perguntas definidas, atribuindo-as uma identificação (ID).

Quadro 1: Perguntas de pesquisa formuladas para a revisão:

ID	Perguntas de Pesquisa Formuladas
PQ01	Quais modelos de aprendizado de máquina são descritos na literatura para o mapeamento de feições topográficas e/ou batimétricas (topobatimétricas) em zonas entremarés?
PQ02	Que tipo de dados de entrada são utilizados nos modelos de aprendizado de máquina aplicados à modelagem topobatimétricas por sensoriamento remoto?
PQ03	Que comparações entre modelos de aprendizado de máquina e métodos tradicionais e de sensoriamento remoto podem ser exploradas como indicativo de incerteza nos métodos de inversão topobatimétrica?

PQ04	De que forma os resultados dos modelos de aprendizado de máquina presentes na literatura superam os modelos tradicionais de sensoriamento remoto, com abordagens empíricas?
PQ05	É possível produzir MDEs confiáveis para representar a evolução da paisagem de zonas intermarés apenas a partir da aplicação de técnicas de aprendizado de máquina sobre dados de sensoriamento remoto?

Fonte: Elaborado pelo autor.

A partir das perguntas de pesquisa definida no quadro anterior Quadro 1, foram extraídas quatro palavras-chave (PC) representando os temas centrais, conectadas nos motores de busca por meio do operador booleano “AND” (Quadro 2).

Quadro 2: Palavras-chave primárias extraídas das perguntas de pesquisa, para serem conectadas pelo mecanismo booleano "AND" nas barras de pesquisa dos motores de busca.

ID das palavras-chave	Palavras-chave	PQ ID
PC01	<i>Machine learning</i>	PQ01, PQ02, PQ03, PQ04, PQ5
PC02	<i>Topobathymetry</i>	PQ01, PQ03, PQ5
PC03	<i>Intertidal</i>	PQ01, PQ5
PC04	<i>Remote sensing</i>	PQ02, PQ03, PQ04, PQ5

Fonte: Elaborado pelo autor.

Segundo o método PRISMA, para ampliar a busca por publicações relevantes, é fundamental considerar não apenas sinônimos literais, mas também sinônimos com significados conceituais equivalentes. O Quadro 3 apresenta todos os sinônimos associados a cada palavra-chave principal, conectados pelo operador booleano “OR”.

Quadro 3: Sinônimos literais e conceituais associados a cada palavra-chave para expandir e refinar sequências de pesquisa.

PC - ID	PC01	PC02	PC03	PC04
1	<i>machine learning</i>	<i>topology</i>	<i>intertidal</i>	<i>remote sensing</i>
2	<i>artificial neural network</i>	<i>topography</i>	<i>tidal zone</i>	<i>satellite</i>
3	<i>recurrent neural network</i>	<i>altimetry</i>	<i>tidal flats</i>	<i>sar</i>
4	<i>deep neural network</i>	<i>topobathymetry</i>	<i>between tides</i>	<i>hyperspectral</i>
5	<i>deep learning</i>	<i>water depth</i>	<i>coastal wetlands</i>	<i>multispectral</i>
6	<i>generative artificial intelligence</i>	<i>water level</i>		<i>active sensor</i>
7	<i>decision tree</i>	<i>satellite derived bathymetry</i>		<i>passive sensor</i>

8	<i>linear regression</i>	<i>elevation</i>		<i>aerial photogrametry</i>
---	--------------------------	------------------	--	-----------------------------

Fonte: Elaborado pelo autor.

A combinação das palavras-chave principais com “AND” e de seus sinônimos com “OR” resultou na “**String de Busca**” (SB) apresentada no Quadro 4 a seguir. Esta “string” foi aplicada aos principais motores de busca de referências bibliográficas indexadas. A lista dos motores de busca utilizados neste estudo é apresentada no Quadro 4 da próxima seção. Cabe destacar que o símbolo “*” foi utilizado para ampliar a busca a todos os termos derivados do prefixo informado.

Quadro 4: Sequência de pesquisa booleana aplicada em todos os mecanismos de busca selecionados para identificar publicações relevantes.

String ID	String de Busca
ST	<i>("machine learning" OR "neural network" OR "deep learning" OR generative OR "decision tree" OR "linear regression" OR ml OR ann OR dnn OR rnn OR gan OR dt) AND ("topo*" OR "altimetr*" OR "bathym*" OR "water depth" OR "water level" OR sdb OR elevation) AND (intertidal* OR "tidal zones" OR "tidal flats" OR "between tides" OR "coastal wetlands") AND ("remote sensing" OR satellite OR spectral OR "active sensor" OR "passive sensor" OR "aerial photo*")</i>

Fonte: Elaborado pelo autor.

Os resultados obtidos com as “strings” de busca tendem a gerar uma base de dados extensa, contendo publicações que nem sempre estão diretamente relacionadas aos temas centrais. Para restringir a base aos estudos relevantes e garantir a qualidade da revisão, foram definidos **Critérios de Inclusão (CI)** e **Critérios de Exclusão (CE)**. Um CI bem formulado garante a seleção de estudos relevantes para a análise bibliométrica, enquanto um CE adequado reduz vieses de busca (Page et al., 2021). O Quadro 5 apresenta os critérios adotados neste estudo.

Quadro 5: Critérios de inclusão e exclusão usados para filtrar publicações recuperadas quanto à relevância e qualidade metodológica.

Critério de Inclusão (CI)	Crítário de Exclusão (CE)
CI-01: Artigos que não fazem referência a técnicas de aprendizado de máquina.	CE-01: Documentos duplicados.
CI-02: Artigos que fazem referência às zonas intermareais.	CE-02: Artigos com foco geral em dados coletados, não produzidos por técnicas de Sensoriamento Remoto.
CI-03: Artigos que fazem referência à batimetria ou topologia.	CE-03: Artigos com foco geral na batimetria em áreas mais profundas, principalmente fora da zona intermareal.

CI-04: Artigos que fazem referência ao sensoriamento remoto.	CE-04: Artigos com foco geral em mapeamento biológico e ecologia da zona intermareal.
CI-05: Artigos escritos em inglês	CE-05: Artigos com foco geral no mapeamento de recifes de corais ou costas rochosas.

Fonte: Elaborado pelo autor.

3.1.1 Bases de Dados Bibliográficos

Para a construção da base de dados desta revisão, foram utilizados os principais motores de busca recomendados por Kitchenham e Charters (2007). Adicionalmente, foi utilizado o aplicativo *Research Rabbit*, uma ferramenta inteligente para descoberta e organização de literatura científica (Tay, 2021) (Quadro 6). O *Research Rabbit* permite explorar interconexões entre publicações e autores por meio de uma plataforma interativa de gerenciamento de referências bibliográficas, possibilitando a identificação eficiente de estudos relevantes e a expansão em cascata da literatura.

Quadro 6. Motores de busca utilizados, seus respectivos endereços (URLs), datas de acesso e tipos

Nome do Mecanismo de Busca	URL do mecanismo de Busca	Último acesso	Tipo
Scopus	https://scopus.com	Maio - 2025	Base de dados indexadora
IEEE Xplore	https://ieeexplore.ieee.org	Maio - 2025	Base de dados indexadora
WEB of Science	https://webofscience.com	Maio - 2025	Base de dados indexadora
ACM Digital Library	https://dl.acm.org	Maio - 2025	Base de dados indexadora
Research Rabbit	https://researchrabbitapp.com	Maio - 2025	Expansão em cascata

Fonte: Elaborado pelo autor.

De acordo com Kitchenham (Kitchenham; Charters, 2007; Kitchenham et al., 2009; Kitchenham; Brereton, 2013), as bases **Scopus** e *Web of Science* oferecem ampla cobertura e rigorosa curadoria de publicações de alto impacto, enquanto os motores **IEEE Xplore** e **ACM Digital Library** concentram-se em literatura técnica especializada.

3.1.2 Execução da Busca

Definido os buscadores iniciou-se as buscas nas bases selecionadas, que foram conduzidas em cinco etapas:


- (1) Aplicação da *string* de busca nos mecanismos de busca;
- (2) Remoção de duplicatas;
- (3) Seleção com base em título, resumo e palavras-chave;
- (4) Seleção com base no texto completo;
- (5) Expansão de citações em cascata com auxílio do *Research Rabbit*.

A expansão em cascata foi realizada com os seguintes procedimentos:

- Busca por publicações mais antigas citadas nos estudos já presentes na base e que atendem aos critérios da funcionalidade “*Earlier Work*” do *Research Rabbit*;
- Busca por trabalhos semelhantes a uma publicação de referência-chave — escolhida como Chen et al. (2023), por comparar diferentes modelos de aprendizado de máquina aplicados à inversão topográfica na zona entremarés na China, o que se alinha aos critérios deste estudo (“*Similar Work*”);
- Inclusão de três estudos seminais: (1) Otsu (1979), pioneiro em métodos robustos de segmentação de imagens; (2) Mason et al. (1995), um dos primeiros autores a propor o método da “linha d’água”; e (3) Cao et al. (2024), que aplicaram aprendizado de máquina ao mapeamento de linhas d’água em áreas costeiras.

A Figura 8 resume as cinco etapas do método PRISMA aplicado nesta revisão, apresentando os filtros utilizados para compor a base final com 60 artigos científicos selecionados.

Figura 8: Resumo da metodologia PRISMA aplicada neste estudo.



Fonte: Elaborado pelo autor.

No total, levantou-se, 131 referências não duplicadas após a etapa 1 de aplicação da *string* de busca em mecanismos de busca. Na segunda etapa, na fase de triagem, 55 artigos de 131 foram eliminados por meio da análise do título, resumo e palavras-chave. Na etapa 3, ainda na triagem, mais 27 artigos foram eliminados com base no enquadramento dos termos IC e EC ao longo do texto. Com os 49 artigos triados restantes, a expansão em cascata foi realizada no Research Rabbit, onde foram encontrados 25 artigos com potencial para inclusão, mas após análise de elegibilidade, apenas 11 foram incluídos para gerar o banco de dados final com 60 artigos para extração de informações.

3.1.3 Metodologia de análise

Para a análise bibliométrica da base, foi utilizada a biblioteca *Bibliometrix* (versão 4.4.3) do ambiente da linguagem de programação R. Além do *Bibliometrix*, foram utilizadas as ferramentas *SciSpace* e *Research-Paper Analyzer* para extração de informações relevantes. O *SciSpace* (typeset.io) aplica IA generativa para interagir automaticamente com artigos em *Portable Document Format* (PDF). O *Research-Paper Analyzer*, por sua vez, é um modelo baseado no ChatGPT-4, treinado especificamente para leitura de arquivos PDF, interpretação de tabelas e realização de buscas cruzadas. Essas ferramentas, quando utilizadas com comandos apropriados, atuam como catalisadores da pesquisa, acelerando a extração sistemática das informações mais relevantes. O Quadro 7 apresenta as perguntas formuladas para esses sistemas de IA aplicadas a todos os artigos listados no Quadro 9.

Quadro 7: Perguntas de pesquisa usadas para estimular a extração de literatura assistida por IA para todos os artigos no Repositório bibliográfico deste estudo.

ID do Prompt	ID da Pergunta de Pesquisa	Perguntas de pesquisa realizadas para todos os artigos
PPT01	PQ01	<i>What machine learning models were used?</i>
PPT02	PQ02	<i>What are the satellite missions or remote sensors used?</i>
PPT03	PQ02	<i>What preprocessing methods were performed to the remote sensing images used to feed the machine learning models?</i>
PPT04	PQ02, PQ03, PQ4 and PQ05	<i>What are the types of input data for the intertidal model(s)?</i>
PPT05	PQ02, PQ03, PQ4 and PQ05	<i>What are the types of validation data used to validate the intertidal models?</i>
PPT06	PQ03, PQ4 and PQ05	<i>What is the main correlation metrics used to validate the intertidal models?</i>
PPT07	PQ03, PQ4 and PQ05	<i>What were the main error metrics used to define the quality of the intertidal models</i>
PPT08	PQ03, PQ4 and PQ05	<i>Are there comparisons among machine learning models and/or empirical/physical/mathematical models?</i>
PPT09	PQ03, PQ4 and PQ05	<i>What is the size of the study site?</i> <i>(Examples: local scale = beach, estuary, river; regional scale = province, country; global scale = more than two countries)</i>
PPT10	PQ03, PQ4 and PQ05	<i>What is the tidal regime at study sites?</i> <i>(Examples: 0 m > microtide < 2 m, 2 m < mesotide < 4 m; and macrotide < 4 m)</i>
PPT11	PQ03, PQ4 and PQ05	<i>What type of surface or sediment cover is present or dominant at the study site?</i>

		<i>(Examples: light sand, dark sand, mud, coral reef, rocky coast, vegetation, etc.)</i>
PPT12	PQ4 and PQ05	<i>What possible future works/approaches have been proposed?</i>

Fonte: Elaborado pelo autor.

O Quadro 8 resume os procedimentos de padronização adotados para os aspectos mais relevantes considerados nas comparações entre os modelos: (a) os tipos de dados de entrada, com base na questão PPT04; (b) os tipos de dados de validação, com base no PPT05; (c) a extensão espacial das áreas de estudo, com base na questão PPT09; (d) o regime de marés dos locais de estudo, com base no PPT10; e (e) o tipo de cobertura do fundo, de acordo com a questão PPT11.

Quadro 8: Resumo dos procedimentos de padronização aplicados aos artigos analisados.

Datos de Entrada	Datos de Validação	Cobertura Espacial	Regime de Marés	Cobertura de Fundo
Imagem de satélite – multispectral (Landsat, Sentinel)	Levantamento de campo tradicional – GNSS RTK etc	Local – um ou vários sistemas costeiros próximos	Micromaré: 0 m > maré < 2 m	Areia clara
Imagem de satélite – alta resolução ótica (Pleiades, WorldView etc)	LiDAR – <i>Scanner</i> a laser	Regional – áreas de estudo que mapeiam zonas com mais de 100 km de extensão no mesmo país.	Mesomaré: 2 m > maré < 4 m	Areia escura
Imagem de satélite – sensor ativo SAR	Monitoramento de vídeo – RGB (Red Green Blue)	Global – estudos aplicados em diferentes países, mesmo que aplicados em áreas relativamente pequenas, mas com características ambientais completamente diferentes.	Macromaré: maré > 4 m	Lama
Monitoramento de vídeo – RGB (Red Green Blue)	Dados de autoconsistência – Google Earth	Outro – (não foi possível determinar o tamanho da área de estudo com base na descrição do artigo)	Diversos - estudos que aplicaram os métodos em diversos locais com diferentes	Vegetação

			regimes de maré.	
<i>Scanner</i> a laser (LiDAR)	Outro – (não foi possível determinar o tipo de dado de validação com base na descrição do artigo)		Outros: (quando não foi possível determinar o tipo de regime de maré predominante com base na descrição do artigo)	Sedimentos mistos
Google Earth – Imagens RGB	Levantamento de campo tradicional – GNSS RTK etc			Outros (muito variados, contendo trechos de rochas ou corais, ou não foi possível determinar o tipo de cobertura sedimentar)

Fonte: Elaborado pelo autor.

O Quadro 8 apresenta os procedimentos de padronização aplicados aos artigos analisados quanto a: (a) os tipos de dados de entrada, com base na questão PPT04; (b) os tipos de dados de validação, com base no PPT05; (c) a extensão espacial das áreas de estudo, com base na questão PPT09; (d) o regime de marés dos locais de estudo, com base no PPT10; e (e) o tipo de cobertura do fundo, de acordo com a questão PPT11.

As métricas de comparação quantitativa entre os modelos intermarés foram definidas com base nos valores de RMSE e Acurácia Global, considerando os erros horizontais na posição da linha de costa (WL) e os erros verticais entre os dados de validação e os MDE gerados.

3.2 ARTIGOS ENCONTRADOS

O conjunto final foi organizado no software Zotero com os artigos indexados por ID em ordem cronológica (Quadro 9).

Quadro 9: Conjunto final de 60 artigos, organizados por ID e informações bibliográficas importantes.

Artigo ID	Referência	Título
A01	Otsu (1979)	<i>A threshold selection method from gray level histograms</i>
A02	Mason et al. (1995)	<i>Construction of an inter-tidal digital elevation model by the 'Water-Line' Method</i>
A03	Chen (1998)	<i>Detection of shoreline changes for tideland areas using multi-temporal satellite images</i>
A04	Kingston et al. (2000)	<i>Artificial neural network correction of remotely sensed sandbar location</i>
A05	Ryu, Won e Min (2002)	<i>Waterline extraction from Landsat TM data in a tidal flat A case study in Gomso Bay, Korea</i>
A06	Liu e Jezek (2004)	<i>Automated extraction of coastline from satellite imagery by integrating Canny edge detection and locally adaptive thresholding methods</i>
A07	Fu, Per e Zhang (2008)	<i>Evolving Neural Network Using Variable String Genetic Algorithm for Color Infrared Aerial Image Classification</i>
A08	Ryu et al. (2008)	<i>Detecting the intertidal morphologic change using satellite data</i>
A09	Chen e Chang (2009)	<i>Estimation of shoreline position and change from satellite images considering tidal variation</i>
A10	Cheng et al. (2017)	<i>SeNet: Structured Edge Network for Sea–Land Segmentation</i>
A11	Choun e Jo (2017)	<i>Comparison between a Machine-Learning-Based Method and a Water-Index-Based Method for Shoreline Mapping Using a High-Resolution Satellite Image Acquired in Hwado Island, South Korea</i>
A12	Kang et al. (2017)	<i>Topographic mapping on large-scale tidal flats with an iterative approach on the waterline method</i>
A13	Sagar et al. (2017)	<i>Extracting the intertidal extent and topography of the Australian coastline from a 28 year time series of Landsat observations</i>
A14	Tseng et al. (2017)	<i>Reconstruction of time-varying tidal flat topography using optical remote sensing imageries</i>
A15	Li et al. (2018)	<i>DeepUNet: A Deep Fully Convolutional Network for Pixel-Level Sea-Land Segmentation</i>
A16	Maxwell, Warner e Fang (2018)	<i>Implementation of machine-learning classification in remote sensing: an applied review</i>
A17	Misra et al. (2018)	<i>Shallow water bathymetry mapping using Support Vector Machine (SVM) technique and multispectral imager</i>
A18	Bishop-Taylor et al. (2019)	<i>Between the tides: Modelling the elevation of Australia's exposed intertidal zone at continental scale</i>
A19	Chu et al. (2019)	<i>Sea-land segmentation with RES-UNET and fully connected CRF</i>
A20	Khan et al. (2019)	<i>High-Resolution Intertidal Topography from Sentinel-2 Multi-Spectral Imagery: Synergy between Remote Sensing and Numerical Modeling</i>

A21	Sagawa et al. (2019)	<i>Satellite Derived Bathymetry Using Machine Learning and Multi-Temporal Satellite Images</i>
A22	Salameh et al. (2019)	<i>Monitoring Beach Topography and Nearshore Bathymetry Using Spaceborne Remote Sensing: A Review</i>
A23	Shamsolmoali et al. (2019)	<i>A Novel Deep Structure U-Net for Sea-Land Segmentation in Remote Sensing Images</i>
A24	Zhang et al. (2019)	<i>Mapping Tidal Flats with Landsat 8 Images and Google Earth Engine: A Case Study of the China's Eastern Coastal Zone circa 2015</i>
A25	Vos et al. (2019)	<i>CoastSat: A Google Earth Engine-enabled Python toolkit to extract shorelines from publicly available satellite imagery</i>
A26	Kang et al. (2020)	<i>Remote Sensing of Time-Varying Tidal Flat Topography, Jiangsu Coast, China, Based on the Waterline Method and an Artificial Neural Network Model</i>
A27	Wen e Hughes (2020)	<i>Coastal Wetland Mapping Using Ensemble Learning Algorithms: A Comparative Study of Bagging, Boosting and Stacking Techniques</i>
A28	Almeida et al. (2021)	<i>Coastal Analyst System from Space Imagery Engine (CASSIE): Shoreline management module</i>
A29	Bagot, Huybrechts e Sergent (2021)	<i>Satellite-Derived Topography and Morphological Evolution around Authie Macrotidal Estuary (France)</i>
A30	Bengoufa et al. (2021)	<i>Machine learning and shoreline monitoring using optical satellite images: case study of the Mostaganem shoreline, Algeria</i>
A31	Collins et al. (2021)	<i>Development of a Fully Convolutional Neural Network to Derive Surf-Zone Bathymetry from Close-Range Imagery of Waves in Duck, NC</i>
A32	Cui et al. (2021)	<i>SANet: A Sea–Land Segmentation Network Via Adaptive Multiscale Feature Learning</i>
A33	Jing et al. (2021)	<i>BS-Net: Using Joint-Learning Boundary and Segmentation Network for Coastline Extraction from Remote Sensing Images</i>
A34	Mandlbürger et al. (2021)	<i>BathyNet: A Deep Neural Network for Water Depth Mapping from Multispectral Aerial Images</i>
A35	Zhao et al. (2021)	<i>LSTM-Based Remote Sensing Inversion of Largescale Sand Wave Topography of the Taiwan Banks</i>
A36	Brunier et al. (2022)	<i>A Machine-Learning Approach to Intertidal Mudflat Mapping Combining Multispectral Reflectance and Geomorphology from UAV-Based Monitoring</i>
A37	Ghorbanian et al. (2022)	<i>Application of Artificial Neural Networks for Mangrove Mapping Using Multi-Temporal and Multi-Source Remote Sensing Imagery</i>
A38	Henriques et al. (2022)	<i>Combining Multispectral and Radar Imagery with Machine Learning Techniques to Map Intertidal Habitats for Migratory Shorebirds</i>
A39	Lumban-Gaol, Oho e Peters (2022)	<i>Extracting Coastal Water Depths from Multi-Temporal Sentinel-2 Images Using Convolutional Neural Networks</i>

A40	McAllister et al. (2022)	<i>Multispectral satellite imagery and machine learning for the extraction of shoreline indicators</i>
A41	Çelik e Gazioğlu (2022)	<i>Coast type based accuracy assessment for coastline extraction from satellite image with machine learning classifiers</i>
A42	Pucino et al. (2022)	<i>Assessing the accuracy of Sentinel-2 instantaneous subpixel shorelines using synchronous UAV ground truth surveys</i>
A43	Boussetta et al. (2023)	<i>Deep and machine learning methods for the (semi-)automatic extraction of sandy shoreline and erosion risk assessment based on remote sensing data (case of Jerba island - Tunisia)</i>
A44	Chen et al. (2023)	<i>Mapping intertidal topographic changes in a highly turbid estuary using dense Sentinel-2 time series with deep learning</i>
A45	Figliomeni et al. (2023)	<i>A Proposal for Automatic Coastline Extraction from Landsat 8 OLI Images Combining Modified Optimum Index Factor (MOIF) and K-Means</i>
A46	Fogarin et al. (2023)	<i>Combining remote sensing analysis with machine learning to evaluate short-term coastal evolution trend in the shoreline of Venice</i>
A47	Maung, Tsuyuki e Guo (2024)	<i>Improving Land Use and Land Cover Information of Wunbaik Mangrove Area in Myanmar Using U-Net Model with Multisource Remote Sensing Datasets</i>
A48	Saeidi et al. (2023)	<i>Water depth estimation from Sentinel-2 imagery using advanced machine learning methods and explainable artificial intelligence</i>
A49	Tang et al. (2023)	<i>Inversion of intertidal zone topography based on optimized random forest regression characteristic parameters</i>
A50	Tsiakos e Chalkias (2023)	<i>Use of Machine Learning and Remote Sensing Techniques for Shoreline Monitoring: A Review of Recent Literature</i>
A51	Vos et al. (2023)	<i>Benchmarking satellite-derived shoreline mapping algorithms</i>
A52	Wang et al. (2023)	<i>Study on the Erosion and Deposition Changes of Tidal Flat in Jiangsu Province Using ICESat-2 and Sentinel-2 Data</i>
A53	Bonou et al. (2024)	<i>40-Year Journey of Shoreline Changes Along the Benin Coast Using Satellite Data Through the CASSIE Tool</i>
A54	Cao et al. (2024)	<i>Extracting waterline and inverting tidal flats topography based on Sentinel-2 remote sensing images: A case study of the northern part of the North Jiangsu radial sand ridges</i>
A55	Gan et al. (2024)	<i>Tracking the 2D/3D Morphological Changes of Tidal Flats Using Time Series Remote Sensing Data in Northern China</i>
A56	Muir et al. (2024)	<i>VedgeSat: An automated, open-source toolkit for coastal change monitoring using satellite-derived vegetation edges</i>
A57	Pinkeaw et al. (2024)	<i>Semi-automated mangrove mapping at National-Scale using Sentinel-2, Sentinel-1, and SRTM data with Google Earth Engine: A case study in Thailand</i>
A58	Tran et al (2024)	<i>Novel Learning of Bathymetry from Landsat 9 Imagery Using Machine Learning, Feature Extraction, and Meta-Heuristic Optimization in a Shallow Turbid Lagoon</i>
A59	Zhang et al (2025)	<i>An improved approach for retrieval of tidal flat elevation based on inundation frequency</i>

A60	Zuo et al (2025)	<i>GCL_FCS30: a global coastline dataset with 30-m resolution and a fine classification system from 2010 to 2020</i>
-----	------------------	--


Fonte: Elaborado pelo autor.

3.3 ANÁLISE BIBLIOMÉTRICA

Com base nas análises realizadas com auxílio das ferramentas *SciSpace* e *Research-Paper Analyzer* (acesso em 20/05/2025), realizou-se a seleção e padronização de 60 estudos sobre modelos morfológicos intermarés. Os estudos apresentaram alta heterogeneidade nos métodos e métricas utilizadas, dificultando comparações diretas. Dados inconsistentes ou ausentes foram tratados com base em descrições nos artigos ou imagens auxiliares (como *Google Earth*).

A Figura 9, a seguir, apresenta o crescimento das publicações durante os anos, onde é possível reparar um pico em 2023.

Figura 9: Produções científicas sobre SR em zonas intermareais aplicando aprendizado de máquina.



Fonte: Elaborado pelo autor.

A análise também destacou a evolução histórica do tema, com marcos importantes como o método de Otsu (1979) e o “Método da Linha D’água” de Mason et al. (1995), que serviram de base para aplicações posteriores com aprendizado de máquina. A primeira aplicação com redes neurais artificiais surgiu com (Kingston et al., 2000), mas somente em 2017, com (Cheng et al., 2017),


observou-se o uso efetivo de CNNs para segmentação mar-terra em zonas intermarés. A maioria dos artigos anteriores a 2017 contribui com métodos de base empírica e modelos de regressão, importantes para avaliação comparativa dos modelos mais recentes baseados em inteligência artificial.

Entre os trabalhos destaca-se o (Maxwell; Warner; Fang, 2018) com mais de 1000 citações sendo um artigo de revisão de métodos baseados em árvores de decisão para classificação de pixels em imagens da costa dos Estados Unidos; e o (Ryu; Won; Min, 2002) pioneiro na utilização de modelos de linha d'água com imagens da coleção Landsat para extração de topografia de planície de maré.

3.4 ANÁLISE COMPARATIVA

Os modelos de ML mais comuns encontrados nos artigos de banco de dados analisados neste estudo são apresentados em ordem decrescente na Figura 10.

Figura 10: Frequência de ML e modelos empíricos aplicados ao SR costeiro na literatura revisada.



Fonte: Elaborado pelo autor.


O modelo de ML mais utilizado foi o Random Forest (RF), seguido por redes neurais convolucionais (CNN), máquinas de vetores de suporte (SVM) e redes neurais artificiais (ANN). A barra "Modificação Empírica" inclui métodos baseados em índices normalizados, como o NDWI.

Os modelos U-Net, SegNet, Resnet, BS-Net e SeNet foram separados dos modelos CNN gerais ou indefinidos nesta análise, mas, do ponto de vista arquitetural, todos eles utilizam camadas convolucionais, tanto na parte de extração de características (codificador) quanto na reconstrução da imagem segmentada (decodificador) e, por esse motivo, foram destacados em um tom mais escuro na Figura 10. Na prática, CNN e os modelos U-Net, SegNet, Resnet, BS-Net e SeNet podem ser considerados modelos do tipo CNN, somando 26 recorrências na base de literatura considerada neste estudo.

A

Figura 11 mostra os diferentes tipos de Modelos Entrenados organizados por (1) natureza (tipo de aprendizado) e (2) estrutura (arquitetura) com base na literatura de base deste estudo. Os modelos empíricos incluem índices normalizados (NDWI - por exemplo), enquanto os modelos de aprendizado de máquina são subdivididos em abordagens supervisionadas e não supervisionadas com tipos de algoritmos associados (por exemplo, CNN, U-Net, Random Forest, K-means). As categorias codificadas por cores representam as principais famílias de modelos: regressão, redes neurais, árvores de decisão, modelos baseados em memória, classificadores baseados em margem e métodos de agrupamento.

Figura 11: Organograma de agrupamento de modelos de inversão topográfica intermareal, com base no tipo de aprendizagem e na arquitetura estrutural.




Fonte: Elaborado pelo autor.

3.4.1 Fonte dos Dados de Entrada para Alimentar os Modelos Entremarés

A Figura 12, seguir, apresenta um resumo gráfico das principais fontes de dados de sensoriamento remoto utilizadas como entrada dos modelos de topografia intermareé baseados em aprendizado de máquina. O gráfico compara a frequência de uso de cada fonte nos estudos revisados. Essa análise evidencia a predominância do uso de sensores orbitais multiespectrais de acesso aberto, como Landsat e Sentinel, em detrimento de soluções com maior custo operacional, como LiDAR (Light Detection and Ranging) embarcado em VANTs e sistemas de vídeo monitoramento.

Figura 12: Frequência dos tipos de sensores fontes de SR utilizado em estudos de mapeamento de zonas entremarés.



Fonte: Elaborado pelo autor.

3.4.2 Eficiência dos Modelos Intermareais

A análise de eficiência foi realizada em duas etapas complementares. A primeira avaliou o desempenho de modelos de detecção automática de linhas d'água por sensoriamento remoto, com base na acurácia geral e na raiz do erro médio quadrático RMSE das diferenças posicionais. A segunda examinou a precisão dos MDE, comparando os dados de elevação observados e modelados.


3.4.2.1 Eficiência dos Modelos de Detecção de Linha d'água

Modelos de detecção automática de linhas d'água utilizam, majoritariamente, índices espectrais como NDWI, além de abordagens mais recentes baseadas em aprendizado de máquina para classificar pixels entre água e terra. Embora haja grande heterogeneidade entre os estudos, foram

extraídos os valores disponíveis de RMSE e acurácia para possibilitar comparações. Os resultados estão apresentados em um resumo visual de *boxplots* que ilustram a distribuição da acurácia geral e do erro RMSE nos modelos analisados (

).

Figura 13: Comparação de desempenho de modelos de inversão topográfica intermareal.



Fonte: Elaborado pelo autor.


A Figura 14 apresenta uma comparação de desempenho de modelos de inversão topográfica intermareal com base na precisão geral (superior) e RMSE (inferior), conforme relatado em estudos

selecionados. Os modelos são categorizados hierarquicamente por paradigma de aprendizagem — empírico, supervisionado e não supervisionado — e ainda diferenciados pela arquitetura estrutural. Modelos empíricos utilizam principalmente índices normalizados (por exemplo, NDWI). Abordagens de aprendizado de máquina supervisionado e não supervisionado incluem várias famílias algorítmicas, como CNN, U-Net, Random Forest e agrupamento K-means. Os tipos de modelos são codificados por cores de acordo com a principal categoria algorítmica: regressão, redes neurais, árvores de decisão, modelos baseados em memória, classificadores baseados em margem e técnicas de agrupamento.

A análise de desempenho dos modelos de detecção de linhas d'água mostra que abordagens baseadas em CNN, como ResNet, SegNet e U-Net, tendem a superar os modelos empíricos com acurácia acima de 90%. Essas arquiteturas oferecem alta eficiência na segmentação de imagens devido à capacidade de processar padrões espaciais em grupos de pixels. A maioria dos estudos reporta acurácia geral, e apenas poucos fornecem RMSE, sendo que o modelo MLP apresentou os menores erros. Como os modelos analisados foram aplicados em áreas com características distintas, foi feita uma análise de sensibilidade com Floresta Aleatória, indicando que o regime de marés é o principal fator que influencia a acurácia, seguido pelos dados de entrada, validação, escala espacial e, por fim, o tipo de sedimento (

Figura 14).

Figura 14: Análise de sensibilidade de variáveis preditoras que influenciam a precisão dos modelos de detecção de linhas d'água intermareais.




Fonte: Elaborado pelo autor.

A análise foi conduzida utilizando um algoritmo Random Forest, com importância relativa medida pelo índice de Gini. O regime de marés e o tipo de dados de sensoriamento remoto foram

identificados como os fatores mais significativos para a precisão do modelo, enquanto a cobertura sedimentar teve a menor influência.

A Figura 15 apresenta uma análise comparativa da precisão dos modelos de topografia intermareal em relação às duas variáveis mais influentes, de acordo com a análise de sensibilidade utilizando o índice de Gini: (1) regime de marés e (2) tipo de dados de entrada. Esses fatores emergiram como os mais significativos na determinação do desempenho do modelo.

Figura 15: Boxplots mostrando a influência do regime de marés (painel superior) e do tipo de dado de entrada (painel inferior) na precisão dos modelos automáticos de detecção de linha d'água.



Fonte: Elaborado pelo autor.

A precisão é geralmente maior em regiões de micromarés, onde amplitudes de maré menores resultam em menor variabilidade da linha d'água. Em contraste, modelos aplicados em ambientes de mesotérmica e macrotérmica tendem a apresentar precisão reduzida. Em relação aos dados de entrada, de forma bastante intuitiva, modelos construídos com imagens de alta resolução alcançam maior

precisão em comparação com aqueles que utilizam fontes de resolução moderada, como Landsat ou Sentinel.

Os resultados mostram que amplitudes de maré menores, particularmente em ambientes micromareais, estão associadas a uma maior precisão do modelo. Isso provavelmente se deve à menor variabilidade espacial na posição da linha de costa ao longo das séries temporais, o que simplifica a detecção das linhas de água. Por outro lado, as regiões mesotidais e, especialmente, as macromareais apresentam maiores flutuações na posição da linha de costa, introduzindo maior complexidade e erro na detecção automatizada (Figura 15, painel superior).

Com relação às fontes de dados de entrada, imagens de alta resolução correlacionam-se com maior precisão do modelo (Figura 15, painel inferior). Modelos baseados em conjuntos de dados de alta resolução — como os do Google Earth, satélites ópticos comerciais ou sistemas de VANT e câmeras de vídeo — geralmente superam aqueles que utilizam sensores de resolução mais baixa, como Landsat ou Sentinel. Essa tendência ressalta a importância do detalhe espacial para uma classificação precisa em nível de pixel em aplicações de mapeamento intermareal.

O Quadro 10 apresenta os estudos da base bibliográfica apresentada na Quadro 9 que foram realizados respectivamente nos ambientes microtidal, mesotérmico e macrotidal, bem como os modelos que tiveram como entrada de dados imagens RGB de alta resolução provenientes do Google Earth e fontes UAV-LiDAR/câmera de vídeo, imagens de alta resolução espectral e multiespectrais provenientes das missões mais tradicionais Landsat e Sentinel.

Quadro 10: Resumo da base de dados de referência bibliográfica deste estudo por regime de marés.

Regime de marés	Artigos (Ref. ID)
Micromaré (< 2m)	A03, A04, A06, A07, A09, A13, A16, A17, A21, A24, A28, A30, A39, A41, A42, A43, A46, A51, A53, A58, A59
Mesomaré (> 2m e < 4m)	A03 ¹ , A05, A08, A12, A13, A17, A28, A31, A33, A42, A44, A45, A47, A48, A51, A53, A54, A55, A56, A57
Macromaré (> 4m)	A11, A12, A13, A14, A18, A20, A26, A27, A28, A29, A32, A35, A36, A37, A38, A47, A49, A51, A52, A55, A56, A57 ¹
Tipo de dados de entrada	Artigos (Ref. ID)
UAV-LiDAR/ Camera de vídeo – alta resolução	A04, A07, A31, A34, A36, A50
Google Earth – imagens RGB	A10, A15, A19, A23, A50, A60
High-Res Optical - Multispectral	A11, A16, A22, A26, A30, A32, A33, A35, A47, A56

Sentinel – Multispectral	A22, A24, A25, A27, A28, A29, A37, A38, A39, A41, A42, A43, A44, A46, A47, A48, A49, A50, A51, A52, A53, A54, A55, A56, A57, A59
Landsat - Multispectral	A05, A06, A08, A12, A13, A14, A17, A18, A21, A22, A24, A25, A28, A29, A43, A45, A50, A51, A53, A55, A56, A58, A60


Fonte: Elaborado pelo autor.

3.4.2.2 Eficiência dos Modelos MDE

Modelos intermareal que visam a inversão topográfica e batimétrica utilizando dados de sensoriamento remoto frequentemente dependem de modelos digitais de elevação (MDEs) para validação. Nesses casos, o desempenho do modelo é avaliado principalmente com base na precisão da elevação pixel a pixel. A

apresenta uma análise comparativa da precisão (painel superior) e dos valores de RMSE (painel inferior) para modelos de inversão intermareal baseados em MDE relatados na base de dados bibliográficos deste estudo. O *boxplot* de precisão inclui os estudos A14, A17, A18, A21, A22, A39, A40, A41, A43, A44, A48, A49, A52, A54, A58 e A59, enquanto o *boxplot* RMSE extrai dos estudos A05, A08, A13, A17, A18, A20, A21, A22, A26, A31, A34, A35, A39, A40, A41, A42, A44, A48, A49, A52, A54, A58 e A59.

Figura 16: Comparação de desempenho de modelos intermareais baseados em MDE.



Fonte: Elaborado pelo autor.

O painel superior da

apresenta o *Boxplots* de precisão geral por tipo de modelo, com uma linha tracejada vermelha indicando a precisão de 0,90. O painel inferior apresenta o *Boxplots* de Erro Quadrático Médio (RMSE) em todos os modelos foram reportados. Modelos baseados em convolução, particularmente


o U-Net, alcançaram o melhor desempenho geral. No entanto, abordagens baseadas em árvores de decisão também demonstraram precisão competitiva e baixo RMSE, destacando sua robustez para modelar a topografia intermareal.

Conforme observado em análises anteriores, modelos baseados em redes neurais convolucionais (CNN) – particularmente o U-Net – produziram os maiores níveis de precisão e os menores valores de RMSE. No entanto, modelos baseados em árvores de decisão (DT), incluindo LightGBM, XGBoost, CatBoost e Random Forest, também demonstraram forte desempenho em ambas as métricas.

Uma vantagem fundamental dos modelos de DT é sua eficiência computacional. Esses modelos normalmente requerem menos tempo de treinamento, não exigem normalização ou escalonamento de dados e consomem menos recursos computacionais em comparação com arquiteturas complexas de CNN adaptadas para dados espaciais. Isso os torna uma alternativa prática em ambientes onde GPUs de alto desempenho não estão disponíveis.

Seguindo a mesma metodologia utilizada para os modelos baseados em detecção de linha d'água, uma RF baseada na Medida de Importância de Gini foi empregada para avaliar a sensibilidade das principais variáveis que influenciam a precisão dos modelos baseados em MDE. Os resultados dessa análise de sensibilidade são apresentados na Figura 17.

Figura 17: Análise de sensibilidade de variáveis que influenciam a precisão de modelos digitais de elevação (MDEs) intermareais, com base em um modelo Random Forest.




Fonte: Elaborado pelo autor.

Os resultados indicam que a escala espacial é o fator mais influente que afeta a precisão dos MDEs, seguido pelo regime de marés. Em contraste, a cobertura do fundo, os dados de entrada de sensoriamento remoto e os dados de validação apresentaram menor impacto no desempenho do modelo.

O modelo RF utilizado para análise de sensibilidade confirmou que a escala espacial é a variável mais crítica que influencia a precisão do MDE, seguida pelo tipo de dado de validação e pelo regime de maré. O tipo de sedimento e os dados do sensor de entrada foram considerados menos influentes. A Figura 18 apresenta uma análise comparativa da precisão dos modelos de topografia intermareal baseados em MDE em relação às duas variáveis mais influentes, de acordo com a análise de sensibilidade utilizando o índice de Gini: (1) escala espacial e (2) regime de maré. Esses fatores emergiram como os mais significativos na determinação do desempenho do modelo baseado em MDE.

Figura 18: Influência da escala espacial (painel superior) e do regime de marés (painel inferior) na precisão dos MDEs intermareais derivados dos modelos intermareais.



Fonte: Elaborado pelo autor.

Os *boxplots* mostram que estudos em escala local tendem a atingir maior precisão em comparação com aplicações regionais, enquanto o tamanho da amostra de estudos em escala global foi muito baixo para comparação. O fator escala espacial é importante para esses modelos, pois há uma tendência de melhor desempenho para modelos treinados e aplicados em regiões específicas; quanto maior a generalização do modelo em geral, menor a precisão. Em relação ao regime de marés,


os *boxplots* no painel inferior indicam que os MDEs gerados em regimes de micromarés apresentam uma grande variância na precisão, provavelmente devido à faixa intermareal mais estreita em regiões de micromarés, enquanto para regiões de meso e macromarés, a tendência esperada de quanto maior a variação da maré, menor a precisão ocorreu novamente, provavelmente devido à maior complexidade do terreno em regiões de maior variação de maré.

Conforme ilustrado na Figura 18 (painel superior), estudos conduzidos em escala local tendem a apresentar maior precisão. Essa tendência provavelmente se deve à menor variabilidade espacial nas condições de entrada, o que facilita um treinamento mais eficaz do modelo. Em contraste, estudos em escala regional e global tendem a apresentar menor precisão geral devido à maior heterogeneidade nas condições ambientais e observacionais, embora o tamanho da amostra dos estudos em escala global tenha sido muito pequeno para uma comparação adequada.

Em relação aos dados de amplitude de maré, os modelos que geram MDEs em regimes de micromarés apresentam uma grande variação na precisão, provavelmente devido à banda intermareal mais estreita em regiões de micromarés, frequentemente no limite de detecção de pixels de missões de satélite como Landsat e Sentinel-2. Para regiões de meso e macromarés, a tendência de quanto maior a variação da maré, menor a precisão, ocorreu novamente da mesma forma que os modelos de linha d'água apontaram, provavelmente devido à maior complexidade do terreno em regiões de maior variação de maré.

Embora a cobertura de sedimentos aparentemente tenha menor influência na precisão do modelo, as análises indicam que áreas com cobertura de areia clara (A03, A04, A09, A17, A21, A24, A28, A29, A30, A31, A35, A38, A39, A43, A48, A51 e A53) geralmente resultam em melhor precisão do modelo quando comparadas às regiões com cobertura de sedimentos lamosos (A05, A08, A12, A14, A17, A20, A26, A32, A33, A36, A37, A44, A49, A52, A54, A55 e A58) ().

Figura 19: Boxplots mostrando a influência da cobertura sedimentar dominante na precisão dos modelos MDE intermareal, com base em estudos na base de dados bibliográfica.



Fonte: Elaborado pelo autor.

3.5 CONSIDERAÇÕES

Modelos empíricos para detecção de linhas d'água (

) apresentaram erros elevados (RMSE entre 5 e 15 metros), com variância substancial e menor precisão geral. Enquanto, métodos de aprendizado não supervisionado, como o agrupamento K-means, não demonstraram melhorias notáveis. Em contraste, modelos supervisionados, especialmente os baseados em CNN como U-Net, ResNet e SeNet, apresentaram precisão acima de 0,9, aproximando-se da previsão ideal (1,0). Entre os métodos baseados em DT, o RF foi o modelo que se destacou com desempenho consistente, até comparado com as CNNs em alguns casos. Por outro lado, métodos de reforço de gradiente, como XGBoost, AdaBoost e LightGBM, apresentaram melhorias moderadas, com seus níveis de precisão e erro sendo superior apenas as abordagens empíricas.

Ao examinar a geração de modelos MDE intermareal (

), a tendência de desempenho mudou. Aqui, os modelos empíricos demonstraram precisão modesta e valores de RMSE verticais altos. A U-Net, mais uma vez, emergiu como a arquitetura mais precisa, embora sua distribuição de RMSE tenha apresentado alta variabilidade, com alguns valores extremos atípicos. Já os modelos de DT como RF, XGBoost e CatBoost apresentaram precisão acima de 0,9, e valores de RMSE baixos e estáveis, indicando precisão e confiabilidade na estimativa de elevação da superfície. Os modelos baseados em gradiente, incluindo LightGBM, apresentaram resultados semelhantes aos DT. Diferente do cenário de detecção de linha d'água, métodos de agrupamento como K-means apresentaram desempenho competitivo em aplicações MDE, com variabilidade reduzida e RMSE comparável a diversas alternativas supervisionadas.

Em síntese, modelos de aprendizado supervisionados superaram os empíricos em ambas as aplicações em termos de precisão, robustez e consistência preditiva. Vale destacar os resultados das CNN, que foram as mais eficazes em tarefas que envolvem segmentação espacial (por exemplo, detecção de linha d'água), e possuem resultado considerável na geração de MDE a partir de inversão topográfica em zonas entremarés.

Entre as CNN, a U-Net se destacou pela superioridade na maioria das aplicações, atribuída à sua estrutura em forma de U, com codificador e decodificador interligados a cada bloco de convolução. Essa arquitetura permite processar matrizes de dados espaciais por meio de operações convolucionais em duas dimensões e a aplicação de múltiplos filtros que capturam e distinguem padrões, estruturas e relações espaciais complexas inerentes a imagens de sensoriamento remoto, o que facilita tanto a segmentação semântica quanto a reconstrução precisa da imagem.

Portanto, este trabalho está alinhado com as mais recentes e promissoras tecnologias encontradas na literatura. O trabalho usou a arquitetura U-Net como base, porém aprimorada com *transformers* convolucionais para detectar as linhas d'água historicamente e uma RNA semelhante para a interpolação dos dados das linhas somado aos dados de marés. O trabalho utilizou os satélites Landsat ou Sentinel que são os mais utilizados na literatura.

4 DESENVOLVIMENTO


Neste capítulo será apresentado a visão geral do projeto, quais as áreas de estudo, como os dados foram aqusitados, como os conjuntos de dados foram montados, como foram processados os conjuntos de dados para a entrada nos modelos, bem como foram desenvolvidos os modelos.

4.1 VISÃO GERAL COMPLETA

O projeto do sistema completo pode ser dividido em dois momentos, treinamento e execução. O momento de treinamento visa treinar e preparar os modelos de RNA para a predição. Além disso, nesse fluxo acontece exportação dos modelos treinados para o formato *Open Neural Network Exchange* (ONNX). A partir do formato *ONNX*, é possível importar o modelo em qualquer linguagem de programação, incluindo Javascript que é utilizado no CASSIE. Neste momento, portanto, os principais atores são os especialistas gerando os conjuntos de dados e exportando eles para CSV. A

Figura 20 apresenta os processos realizados no momento de treinamento.

Figura 20: Diagrama do fluxo de trabalho completo no momento do treinamento dos modelos de rede neural.




Fonte: Elaborado pelo autor.

O presente trabalho não apresenta interfaces com usuário, como delimitado na seção escopo, portanto, o trabalho foca apenas no desenvolvimento, treinamento, aperfeiçoamento e exportação de modelos de RNA para SR em zonas entremares. Sendo assim, o fluxo de execução não será implementado, mas ele será descrito a seguir.

O momento de execução visa a utilização do sistema pelo usuário final. Neste fluxo o usuário define o polígono da área de interesse, *Area of Interest* (AOI), e faz a escolha de imagens de satélite das coleções Landsat ou Sentinel para um período determinado, depois realiza o pré-processamento da colação de imagens no GEE para gerar dados filtrados de boa qualidade para alimentar a RNA de detecção da WL, aplica a RNA de detecção da WL para alimentar o modelo de interpolação, aplica o pareamento das WL com os dados de elevação das marés por data e hora para gerar as curvas de nível e interpola as curvas de nível com a RNA de interpolação para obter series temporais de MDEs entremarés de alta resolução. Por tanto, a Figura 21, a seguir, apresenta o fluxo do sistema no momento de execução quando os modelos exportados e treinados por esse trabalho farão parte do CASSIE.

Figura 21: Diagrama do fluxo do sistema completo no momento de execução.



Fonte: Elaborado pelo autor.

4.2 CONJUNTO DE DADOS

Esta seção descreve as áreas de interesse selecionadas, os métodos de aquisição dos dados, as etapas de pré-processamento aplicadas e o formato final do conjunto utilizado nos experimentos.

4.2.1 Áreas de Interesse


O conjunto de dados utilizado contempla três Áreas de Interesse (AOIs) com características hidrodinâmicas e sedimentares contrastantes. A primeira área (AOI-1) está localizada na Baía da Babitonga, situado no litoral de Santa Catarina, na região sul do Brasil (Klein; Short, 2016). A baía é dominada por um regime de micromarés, com amplitude média em torno de 1,35 metros (Truccolo; Schettini, 2010), inserida em um complexo estuarino de aproximadamente 160 km², com largura máxima de 5 km e comprimento de cerca de 20 km (Cremer; Morales; Oliveira, 2006). A paisagem local é composta por planícies de maré, bancos arenosos, áreas rasas, afloramentos rochosos e ilhas (Mazzer, 2012). A distribuição sedimentar varia de lama a areia, sendo os sedimentos arenosos predominantes nas porções mais próximas à desembocadura estuarina (Vieira et al., 2008).

A segunda área (AOI-2) está situada na Praia do Amor, no litoral oeste da ilha de São Luís do Maranhão, inserida na Baía de São Marcos, um extenso complexo estuarino equatorial do nordeste do Brasil. A região é fortemente influenciada por um regime de macromarés semidiurno, com amplitudes médias em torno de 4,6 metros, podendo atingir até 7,2 metros (Pereira et al., 2016), contrastante com o regime da Babitonga (AOI-1). A Praia do Amor apresenta largura média de aproximadamente 250 metros. O relevo entremarés caracteriza-se por um gradiente suave, sendo a dinâmica morfológica controlada por eventos de alta energia que favorecem processos erosivos e a formação de feições do tipo barra e cavado (Pereira et al., 2016).

Com o objetivo de ampliar a diversidade ambiental do conjunto de dados e avaliar a metodologia em um contexto global, foi selecionada a terceira Área de Interesse (AOI-3), localizada no estuário de Tauranga, na costa leste da Ilha Norte da Nova Zelândia, na região da Baía de Plenty. O estuário de Tauranga é caracterizado como um sistema arenoso parcialmente fechado por barreiras. A região apresenta regime de micromarés, com amplitudes variando entre 1,4 e 1,9 metros, sendo os níveis extremos intensificados por sobre-elevações associadas a tempestades, geralmente inferiores a 0,5 metro. O estuário possui zonas entremarés com planícies de maré bem desenvolvidas e presença de vegetação costeira, como manguezais (de Lange; Healy, 1989; Hume et al., 2016). Os sedimentos de fundo são predominantemente arenosos, com pequena fração de cascalho. A influência direta das ondas no nível da água é reduzida em função das entradas restritas do sistema estuarino (Davies-Colley; Healy, 1978; Pool et al., 2025)

As áreas foram selecionadas com base na disponibilidade de dados de validação para os modelos e na representatividade de distintos regimes de maré. As 3 AOI podem ser localizadas na

Figura 22: Área de estudo definidas para os testes do modelo de topografia derivada de satélites com técnicas de RNA.



Fonte: Elaborado pelo autor.

4.2.2 Aquisição dos Dados

A aquisição dos dados para compor os conjuntos de dados utilizados no projeto, utilizou-se de várias fontes, como imagens de satélites, que são de onde é extraído as informações das bandas, os dados de maré, que são acrescentados os dados do satélite, e os dados de validação, que são utilizados como saída da rede. Os dados de validação foram aquisitados com laser scanner ou com o método matemático. Esta seção apresenta como foram recuperados e processado os dados de cada fonte.

4.2.2.1 Imagens de Satélite

Neste estudo, foram utilizadas imagens de satélite da missão Sentinel-2, fornecidas pelo programa Copernicus da Agência Espacial Europeia (AEE) e acessadas via GEE (Gorelick et al., 2017). Os produtos Sentinel-2 consistem em blocos elementares com frequência de revisita de cinco dias. O produto Nível 2A, utilizado nesta análise, oferece imagens de refletância de superfície com 10, 20 ou 60 metros de comprimento, variando de acordo com as bandas espectrais, que são pré-corrigidas para efeitos atmosféricos, de terreno e de nuvens usando o algoritmo de processamento Sen2Cor da AEE.

4.2.2.2 Dados de Maré

Neste trabalho, os dados de maré para a AOI-1 são da estação maregráfica do Porto de Itapoá, sendo o marégrafo mais próximo da AOI-1. Estes dados foram gentilmente cedidos pela EPAGRI, Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina. Os dados maregráficos possuem uma resolução temporal de 15 minutos e foi exportado em CSV.

Para a AOI-2, localizada na região norte do Brasil, foram utilizados os dados do marégrafo do Porto de Ponta da Madeira ($-2,5654^{\circ}$; $-44,3783^{\circ}$ WGS 84), gentilmente cedid

os pela empresa Vale S.A. Entretanto, para aumentar a amplitude e abrangência dos dados, de forma complementar foi utilizado dados extraídos da base de dados CoDEC (Coastal Dataset for the Evaluation of Climate Impact), a qual reúne séries temporais globais de níveis do mar, com as componentes de maré astronômica e maré meteorológica obtidas a partir do modelo hidrodinâmico GTSMv3.0. O conjunto CoDEC-ERA5 cobre os anos de 1979 a 2025, com resolução costeira da ordem de 2,5 km e frequência amostral de 10 minutos. O modelo simula de forma integrada marés, tempestades e nível médio do mar, incluindo interações não lineares entre esses componentes, o que permite uma representação física mais realista dos extremos de nível do mar. A qualidade do CoDEC foi avaliada por meio da comparação com dados observados de marégrafos da base GESLA, abrangendo centenas de estações em diferentes regiões do mundo e os resultados indicam boa concordância estatística, com correlação média em torno de 0,5, viés global reduzido ($\approx -0,04$ m) e erros absolutos médios da ordem de 0,2 m para os máximos anuais (Muis et al., 2020).


Para a AOI-3, localizada no estuário de Tauranga, na Nova Zelândia, as informações de maré foram obtidas junto ao Bay of Plenty Regional Council, a partir dos registros das estações

maregráficas de Hairini e Omokoroa Wharf, disponíveis em base de dados pública do órgão. Os dados maregráficos possuem uma resolução temporal de 15 minutos e foi exportado em CSV.

4.2.2.3 Dados de Validação

Os dados topográficos para validação dos modelos de RNA para a AOI-1 foram gentilmente cedidos pelo professor doutor Antonio H. F. Klein do projeto CASSIE-Core (CNPq - Processo nº 406603/2022-7). Estes dados foram coletados com *Laser Scanner* Terrestre da marca Topcon, modelo GLS1500, com alcance radial de aproximadamente 300 metros, cobertura de 360 graus e resolução espacial de 20 centímetros (Figura 23).

Figura 23: Dados de topografia intermareal levantados com Laser Scanner Terrestre cedidos pelo LOC da UFSC.




Fonte: Arquivo pessoal de Mario Luiz Mascagni (LOC da UFSC).

Para o AOI-1 e as outras duas áreas de interesse deste estudo também foi utilizado dados resultantes do método *Adapted Waterline* de Pool et al. (2025), pois a área de AOI-1 coberta pelo *Laser Scanner* é pequena demais para treinar os modelos e as demais áreas não foi possível encontrar dados com uma área coberta grande o bastante e de boa qualidade. A seguir a

Figura 24 mostra a relação do tamanho da área dos dados gerados pelo modelo tradicional de WL (em tons de azul) e os dados de *Laser Scanner* cedidos pelo LOC (em tons de vermelho).

Figura 24: Área de dados gerados pelo WL tradicional versus a área gerada pelo método de campo Laser scanner.



Fonte: Elaborado pelo autor.

4.2.3 Pré-processamento no GEE

O pré-processamento das imagens de satélite foi desenvolvido na Plataforma GEE com computação em nuvem em parceria com os especialistas do CASSIE e do LOC (Pool et al., 2025). Os algoritmos para gerar os *datasets* de entrada das RNAs deste estudo encontram-se disponíveis no *GitLab* do projeto CASSIE: <https://codigos.ufsc.br/loc/cassie> (Pool et al., 2025). As imagens foram selecionadas e filtradas quanto a cobertura de nuvens, pixel de terra e cálculo dos índices de água, como NDWI, MNDWI e AWEI, na plataforma GEE, em linguagem *JavaScript*. Também foi aplicado

uma padronização da resolução de cada banda, pois as bandas possuem resolução diferentes, de 10 metros a 60 metros. Ao final do processo é gerado um arquivo CSV para cada imagem contendo todas as bandas, índices e a coordenada geográfica (latitude e longitude).

4.2.4 Pré-processamento para o Modelo

O pré-processamento realizado no Google Earth Engine (GEE) gera arquivos CSV em que cada linha representa um *pixel* individual, ou seja, os dados são organizados como uma lista. No entanto, esse formato não preserva a relação de vizinhança espacial entre os *pixels*, o que inviabiliza o uso direto em modelos bidimensionais de redes neurais, como as CNNs. Esses modelos dependem da estrutura espacial dos dados, pois aplicam filtros convolucionais que operam considerando a vizinhança bidimensional.

Para contornar essa limitação, foi desenvolvido um algoritmo capaz de reconstruir os dados em formato matricial a partir das coordenadas geográficas. A menor latitude do conjunto foi utilizada como referência para definir o índice zero das linhas da matriz. Em seguida, a dimensão total da matriz foi estimada a partir da diferença entre a maior e a menor latitude, dividida pela resolução espacial do satélite.

Para viabilizar esse cálculo de forma consistente em unidades métricas, as coordenadas geográficas (latitude e longitude) foram convertidas para o sistema de projeção UTM (Universal Transverse Mercator), no qual as posições são expressas em metros. Dessa forma, a diferença entre coordenadas representa diretamente distâncias lineares. Com base nisso, a quantidade de pixels em cada direção foi obtida dividindo-se essa distância pela resolução do sensor, que no caso do Sentinel-2 é de 10 metros, permitindo determinar o tamanho final da matriz em número de pixels. O mesmo procedimento foi aplicado para definir o número de colunas, utilizando-se a variação da longitude convertida para UTM.

Como o polígono que define a área de interesse raramente apresenta forma retangular, determinadas posições da matriz reconstruída não possuem valores associados. Nesses casos, foi atribuído o valor zero ao pixel correspondente e gerada uma máscara binária para indicar regiões inválidas. Essa máscara foi incorporada como um canal adicional de entrada nos modelos, juntamente com as bandas espectrais e os índices derivados, permitindo que a rede neural diferencie áreas válidas de regiões sem informação.


Além disso, foi adicionada ao dado de saída uma segunda máscara binária, semelhante a anterior, porém com os dados referência para o modelo. No entanto, verificou-se que algumas imagens apresentavam falhas sistemáticas no levantamento da topobatimetria, resultando em linhas verticais contínuas sem dados.

Para minimizar esse problema, aplicou-se uma operação de erosão morfológica, utilizando um kernel de 3×3 pixels. Essa técnica reduz pequenas discontinuidades e elimina ruídos ao consolidar regiões adjacentes em um único valor representativo. Em seguida, a técnica expande novamente as dimensões para as dimensões originais, propagando o valor médio do kernel para os pixels correspondentes, o que contribuiu para suavizar as falhas e tornar a máscara mais consistente.

A

Figura 25 apresenta, à esquerda, uma imagem original de topobatimetria representada em tons de azul, na qual é possível identificar as falhas no levantamento sob a forma de faixas sem dados, representadas pela cor preta. À direita, é apresentada a máscara binária final após a aplicação da erosão, em que pixels válidos (valor 1) são exibidos em azul e pixels inválidos (valor 0) permanecem em preto.

Figura 25: Imagem original de uma topobatimetria versus imagem após a aplicação da técnica de erosão.



Fonte: Elaborado pelo autor.

Seguindo com o fluxo do pré-processamento, o algoritmo associa a cada imagem de satélite o valor de maré correspondente, com base na data e hora exatas de aquisição da imagem. Quando não existe um registro maregráfico exatamente coincidente, o sistema seleciona o valor temporalmente mais próximo, considerando o menor valor absoluto da diferença entre datas e horários. O valor de maré obtido é então adicionado ao conjunto de dados como um novo canal, junto as bandas e índices, sendo repetido para todos os pixels da imagem.


Devido às grandes dimensões espaciais das matrizes geradas e à necessidade de padronizar as entradas das redes neurais, os dados foram subdivididos em subamostras de dimensão $n \times n$. Essa estratégia garante a compatibilidade entre áreas de estudo com extensões significativamente distintas, como o estuário de Tauranga (AOI-3) e a Praia do Amor (AOI-2), permitindo que ambas sejam processadas com o mesmo número de pixels de entrada. Considerando a resolução espacial de 10 metros do satélite Sentinel-2, a AOI-3 apresenta dimensão aproximada de 896×1088 pixels, enquanto a AOI-2 possui 128×128 pixels.

A divisão dos dados em subamostras foi implementada com a abordagem de sobreposição de subamostras por meio de janela deslizantes. Essa abordagem permite que um mesmo pixel seja utilizado em mais de uma subamostra, aumentando o número de exemplos disponíveis para treinamento sem a necessidade de novas imagens. Na prática, o algoritmo realiza o recorte da matriz em janelas de tamanho $n \times n$, porém controla o deslocamento entre uma janela e outra. O grau de sobreposição, em quantas subamostras o mesmo pixel aparece, é definido por um parâmetro

configurável, que é utilizado para calcular o deslocamento, ou passo, de quantos pixels em quantos a janela deve avançar. Assim, quanto maior o valor configurado, menor será o deslocamento aplicado e maior será o número de subamostras extraídas. Contudo, essa ampliação também aumenta a redundância entre subamostras vizinhas, já que regiões próximas compartilham parte significativa de seus pixels.

Por exemplo, para uma imagem de 320×160 pixel e subamostras de 16×16 pixels, caso o parâmetro de repetição de pixels por amostras seja 1, tem-se o passo igual a 16, resultando em subamostras independentes e sem sobreposição. Já se o parâmetro foi igual a 4, obtém-se o passo igual a 4, fazendo com que a janela avance apenas quatro pixels por vez. Dessa forma, cada nova subamostra compartilha 12 pixels, tamanho 16 menos passo 4, com as subamostras vizinhas, aumentando os dados, mas criando redundância. Na Figura 26, é possível visualizar o exemplo descrito.


Figura 26: Janelas deslizantes para gerar sub-amostras.



Fonte: Elaborado pelo autor.

Nesse contexto, a definição do valor mínimo de n , tamanho das subamostras, tornou-se um passo fundamental, uma vez que esse parâmetro deve assegurar que cada subamostra contenha informação geomorfológica suficiente para representar a dinâmica espacial da linha de costa. Para tal, analisou-se a distância máxima entre diferentes posições da linha de costa, adotando-se a AOI-2 como referência por apresentar a maior variação de maré entre as áreas de estudo. A Figura 27, a seguir, mostra a medição realizada.

Figura 27: Distância em metros entre as linhas de costa da praia do amor.



Fonte: Elaborado pelo autor.

A Figura 27 ilustra as linhas de costa da AOI-2 sobrepostas à imagem de satélite, evidenciando duas posições distintas, representadas pelas cores azul-claro e ciano. Entre essas duas linhas, observa-se uma linha de medição destacada em amarelo, aproximadamente vertical, utilizada para quantificar a distância máxima entre as posições de linha de costa. A distância medida foi de aproximadamente 167 metros. Por tanto, considerando a resolução espacial de 10 metros do satélite Sentinel-2, essa distância corresponde a cerca de 16 pixels ($167 \text{ m} / 10 \text{ m}$). Com base nesse resultado, definiu-se esse valor como o tamanho mínimo da subamostra, garantindo que cada recorte contenha, no mínimo, duas posições distintas de linha de costa em uma mesma imagem.

Uma vez definido o tamanho das subamostras, foi necessário assegurar a qualidade dos dados efetivamente utilizados no treinamento dos modelos. Como comentado anteriormente, as áreas de interesse dificilmente são retangulares, e por conta disso, ao encaixar a área em uma matriz, acabam ficando diversos pontos sem dados e ao dividir essa matriz em subamostras, matrizes menores, algumas subamostras ficam com pouca informação útil. Para esse fim, implementou-se um procedimento de filtragem automática destinado à remoção de subamostras com baixa quantidade de informação válida. Esse processamento avalia simultaneamente as imagens de entrada e suas respectivas imagens de referência para os modelos, mantendo apenas aqueles conjunto, entrada e

referência, que apresentam no mínimo 10% de pixels válidos, diferentes de 0, em cada imagem, entrada e referência.

Após as etapas de pré-processamento descritas, o sistema organiza os dados no formato exigido pelos modelos. Para isso, as imagens pertencentes a uma mesma Área de Interesse (AOI) são agrupadas em um vetor temporal. No entanto, as AOIs analisadas não possuem a mesma quantidade de imagens disponíveis na série temporal. A AOI-1, AOI-2 e AOI-3 apresentam, respectivamente, 9, 7 e 6 imagens.

Para contornar essa inconsistência e garantir padronização nas entradas do modelo, foi definida uma quantidade fixa de 9 imagens por AOI. Essa escolha foi baseada em discussões com especialistas do LOC e do CASSIE, os quais relataram que, para o modelo *Water Line* matemático, é incomum utilizar séries temporais com mais de nove imagens de linha de costa.

Dessa forma, quando o sistema recebe mais de 9 imagens, apenas as 9 primeiras são utilizadas. Quando o número de imagens disponíveis é inferior a 9, como ocorre nas AOIs 2 e 3, o sistema realiza a duplicação aleatória de imagens existentes até completar o vetor temporal com 9 elementos.

4.3 MODELOS

O trabalho possui 3 modelos, um modelo voltado a representar o método *water line*, onde a entrada é as bandas de satélite e a saída é a as linhas de costa, outro para interpolar as linhas de costa e retorna a superfície interpolada e por fim um modelo que faz os dois processos juntos, onde a entrada são as bandas e a saída é superfície interpolada.

4.3.1 Modelo de linha d'água


O modelo de linha d'água desenvolvido tem como entrada 9 imagens de satélite de uma AOI em níveis de maré diferente, contendo as bandas espectrais do sentinel-2, B1 (aerossol), B2 (azul), B3 (verde), B4 (vermelho), B5 (borda do vermelho), B8 (infravermelho), B11 (infravermelho curto) e B12 (infravermelho curto), os índices (NDWI por exemplo) e a maré.

A seleção dessas bandas baseou-se em trabalhos da literatura que aplicam métodos *Water-Line* tradicional. Esses estudos demonstram que citadas são adequadas para detectar a linha d'água devido ao contraste espectral entre água e superfícies expostas, já que a água apresenta forte absorção

nessas faixas enquanto sedimentos refletem mais radiação (Mason et al., 1995; Bishop-Taylor et al., 2019).

O modelo de linha d'água desenvolvido tem como saída, o modelo retorna uma matriz do mesmo tamanho da entrada com as linhas d'água. A Figura 28 apresenta, de forma esquemática, como todas as etapas descritas no pré-processamento e o modelo de linha de costa se integram.

Figura 28: Arquitetura do pré-processamento dos dados para o modelo de linha d'água.



Fonte: Elaborado pelo autor.

O modelo WL é baseado na arquitetura U-Net, porém substitui os blocos convolucionais tradicionais por módulos inspirados na abordagem CvT (*Convolutional Vision Transformer*). A arquitetura é composta por três componentes principais: codificador, espaço latente e decodificador.

O codificador representa a etapa de entrada do modelo e recebe como entrada nove imagens da zona entremarés, obtidas em datas distintas. Nessa fase, ocorre a extração de características espaciais relevantes em cada imagem de forma independente. Para viabilizar esse processamento individual, o modelo aplica uma camada *TimeDistributed*, permitindo que a mesma estrutura seja utilizada separadamente em cada uma das nove imagens da série temporal.

A extração de características no codificador é organizada em múltiplos níveis de profundidade, definidos pelo parâmetro *deep_conv*. Em cada nível, o modelo executa inicialmente uma operação de redução espacial, realizada por meio de convoluções. Em seguida, aplica-se um bloco CvT, no qual são realizadas projeções convolucionais para gerar as representações de *query*, *keys* e *values*, utilizadas como entrada no mecanismo de atenção multi-cabeça. Ao final do bloco, uma MLP com função de ativação GeLU é aplicada, permitindo maior capacidade de modelagem não linear.

Ao término de cada nível do codificador, é incorporado um bloco de atenção temporal, responsável por calcular pesos pixel a pixel entre as nove imagens, produzindo uma representação combinada que sintetiza os pixels mais informativos ao longo do tempo. Essa representação é então utilizada para formar as *skip connections*, que serão empregadas posteriormente no decodificador. Esse mecanismo foi implementado por meio de uma convolução tridimensional (Conv3D), acompanhada por operações de normalização e uma soma ponderada.

A utilização de Conv3D nessa etapa é justificada pelo fato de que as imagens não necessariamente apresentam uma sequência lógica no tempo, pois imagens mais recentes podem possuir níveis de maré semelhantes a imagens intermediárias. Nesse cenário, o uso de um *Transformer* temporal completo pode ser superdimensionado. Dessa forma, a abordagem com Conv3D torna-se mais eficiente, reduzindo o custo computacional e exigindo menos parâmetros treináveis, o que favorece a convergência em conjuntos de dados menores.

O espaço latente é representado por um bloco adicional de atenção temporal, idêntico ao empregado para a geração das *skip connections*. Essa etapa tem como objetivo consolidar as informações extraídas no nível mais profundo da rede, combinando os padrões espaciais e temporais mais relevantes antes do processo de reconstrução.


O decodificador realiza a reconstrução espacial progressiva da saída, aplicando operações sucessivas de aumento de resolução (*upsampling*). Em cada nível, a saída do decodificador é combinada com a respectiva *skip connection*, garantindo a preservação de detalhes espaciais provenientes do codificador. Após a fusão, aplica-se um novo bloco CvT, semelhante ao utilizado no codificador, cuja função é refinar os padrões reconstruídos e ajustar possíveis distorções associadas ao processo de aumento de resolução.

Na etapa final, o modelo aplica uma operação de *Layer Normalization*, seguida de uma convolução bidimensional, responsável por gerar a saída com dimensões compatíveis ao número de variáveis previstas. A função de ativação final adotada é linear, considerando que a amplitude de maré global pode variar entre número positivos e negativos, o que caracteriza um problema de regressão contínua.

Em toda a arquitetura, foi adotado kernel convolucional de tamanho 3 e o número de cabeças de atenção foi fixado também em 3. O número de filtros é ajustado automaticamente ao longo da rede, sendo duplicado a cada nível do codificador e reduzido pela metade no decodificador, garantindo coerência estrutural entre as diferentes escalas. O número inicial de filtros foi definido como 12, correspondente ao total de canais de entrada resultante da combinação de bandas espectrais, índices derivados e informação de maré.

A Figura 29, evidencia de forma esquemática o que foi descrito sobre o modelo de WL.

Figura 29: Arquitetura do modelo U-net CVT Temporal.



Fonte: Elaborado pelo autor.

A implementação do modelo foi realizada em Python, utilizando as bibliotecas TensorFlow e Keras, amplamente empregadas na literatura para o desenvolvimento e treinamento de redes neurais profundas. O conjunto de dados foi dividido seguindo a estratégia convencional, também amplamente empregadas na literatura, de 80% dos dados para treinamento e 20% para validação.

Em estudos de aprendizado de máquina, é comum a aplicação de técnicas de validação cruzada, como o método *K-Fold Cross-Validation*, no qual o conjunto de dados é dividido em k subconjuntos e o modelo é treinado repetidamente utilizando diferentes partições de treino e validação. Esse procedimento permite estimar de forma mais robusta a capacidade de generalização do modelo e reduzir a dependência de uma única divisão do conjunto de dados (Hastie; Tibshirani; Friedman, 2017; Goodfellow; Bengio; Courville, 2016).

Entretanto, neste trabalho optou-se por não aplicar validação cruzada do tipo K-Fold, devido à natureza espacial do conjunto de dados. As amostras utilizadas correspondem a subamostras extraídas de imagens maiores, nas quais existe forte dependência espacial entre pixels vizinhos. A aplicação direta do K-Fold poderia distribuir subamostras espacialmente adjacentes entre diferentes conjuntos de treino e validação, gerando vazamento de informação espacial entre os conjuntos e levando a estimativas excessivamente otimistas do desempenho do modelo (Roberts et al., 2017).

Em aplicações geoespaciais, esse problema é amplamente reconhecido, pois a autocorrelação espacial pode fazer com que regiões muito semelhantes apareçam simultaneamente nos conjuntos de treinamento e validação. Nesses casos, métodos tradicionais de validação cruzada tendem a superestimar a capacidade de generalização dos modelos (Meyer; Reudink; Nauss, 2018; Valavi et al., 2019). Dessa forma, optou-se por utilizar uma divisão fixa dos dados, preservando a coerência espacial das subamostras e mantendo a correspondência entre estruturas geomorfológicas adjacentes, o que é importante para o aprendizado dos padrões associados à morfologia das zonas entremarés.

O processo de otimização foi conduzido pelo algoritmo Adam, devido à sua capacidade de ajustar dinamicamente a taxa de aprendizado com base nos momentos de primeira e segunda ordem do gradiente, promovendo maior estabilidade e eficiência durante a convergência do treinamento. O desempenho do modelo foi avaliado por meio das métricas RMSE, MAE e MSE, amplamente utilizadas em problemas de regressão aplicados à estimativa de profundidade.

A função de perda adotada foi a Huber, proposta por Huber (1964) no contexto da estatística robusta. Essa função combina características do MSE e MAE. Para erros menores que um limiar δ , a função apresenta comportamento quadrático, semelhante ao MSE, penalizando erros pequenos e médios. Para erros maiores que esse limiar, passa a ter comportamento linear, semelhante ao MAE, reduzindo a influência de valores extremos (*outliers*) no treinamento do modelo (Huber, 1964; Goodfellow; Bengio; Courville, 2016). Essa propriedade é particularmente útil em ambientes costeiros, onde podem ocorrer discrepâncias associadas à transição terra-água e à quebra de ondas, regiões em que a variabilidade espectral e possíveis erros nos dados de referência podem gerar valores extremos. Nesses casos, a função de Huber tende a produzir um treinamento mais estável do que funções puramente quadráticas. Neste trabalho foi adotado δ igual a 0,5, considerando a escala dos erros topobatimétricos em metros.

Entretanto, caso a função de perda fosse aplicada diretamente sobre o dado de referência contendo a máscara, o modelo tentaria minimizar simultaneamente o erro da batimetria e o erro da máscara na mesma proporção, o que comprometeria o aprendizado, uma vez que ambos representam informações de natureza distinta. Para contornar essa limitação, foi implementada uma função de perda personalizada, estruturada como uma combinação ponderada de diferentes análises baseados na perda de Huber.


A função personalizada criada atribui peso 0,5 ao cálculo do erro global (Huber aplicado à imagem completa), de modo que o modelo priorize a redução do erro geral. Em seguida, atribui peso 0,25 ao Huber calculado apenas nas regiões válidas, intensificando a penalização dos erros onde há dados confiáveis. Além disso, aplica peso 0,125 ao Huber entre a máscara predita e a máscara real, garantindo que o modelo aprenda corretamente a reconstrução das áreas válidas e inválidas.

Adicionalmente, aplica-se peso 0,0625 ao Huber entre a máscara real e a topobatimetria predita nas regiões sem dados, com o objetivo de induzir o modelo a preservar o padrão espacial das falhas presentes no dado de referência e não induzir a gerar valores quaisquer nestas áreas. Por fim, o peso 0,0625 é aplicado ao Huber entre a máscara predita e a topobatimetria predita nas áreas sem dados, assegurando que a máscara estimada mantenha coerência espacial com o dado estimado, evitando que o modelo produza uma máscara desconectada da saída final.

4.3.2 Modelo para Interpolação das Curvas de Nível Mapeadas na Zona Entremarés

O modelo de interpolação, tem como entrada uma imagem contendo as linhas d'água já com os valores de maré aplicados. E como saída, o modelo retorna uma imagem do mesmo tamanho da entrada com a superfície interpolada, completando os pixels entre as linhas d'água. A Figura 30 apresenta, de forma esquemática, como todas as etapas descritas no pré-processamento e o modelo de interpolação se integram.

Figura 30: Arquitetura do pré-processamento dos dados para o modelo interpolador.




Fonte: Elaborado pelo autor.

O modelo interpolador, se assemelha ao modelo WL, a principal diferença é que no interpolador a entrada é apenas uma imagem e a saída também, por tanto, não é precisa os blocos de atenção temporal que reduzem as imagens de 9 para 1 no modelo WL. Por conta disso, o modelo interpolador se difere em não precisar aplicar a camada *TimeDistributed* e no espaço latente. No modelo interpolador, o espaço latente apenas aplica normalização por camada e uma convolução bidimensional, focando em manter as dimensões espaciais e ajustar as características.

A Figura 31 evidencia o que foi descrito sobre o modelo interpolador de forma esquemática.

Figura 31: Arquitetura do modelo U-net CVT.



Fonte: Elaborado pelo autor.

4.3.3 Modelo Completo

Além dos dois modelos apresentados, voltados para a detecção da linha d'água e para a reconstrução da superfície topobatimétrica, este trabalho implementa um terceiro modelo, um modelo completo ou unificado. Esse modelo tem como objetivo estimar diretamente a superfície a partir de imagens espectrais de satélite e informações maregráficas, integrando em uma única rede neural as duas etapas. Portanto, a arquitetura adotada neste experimento é a mesma utilizada no modelo WL, mantendo a estrutura baseada em U-Net com módulos CVT e atenção temporal.

Na literatura, essas etapas geralmente são tratadas de forma separada, com modelos específicos para extração de linha d'água construção da superfície. Embora existam abordagens que utilizem dois modelos em sequência, não foram identificados trabalhos que realizem o mapeamento completo da superfície entremarés utilizando um único modelo *end-to-end*, capaz de aprender diretamente a relação da reflectância espectral e o nível de maré com a topobatimetria.

A principal justificativa para a adoção de um modelo unificado está na simplificação do fluxo de processamento e na eficiência operacional. Como se trata de uma única rede, o modelo final a ser exportado tende a ser mais compacto, reduzindo a demanda de armazenamento e facilitando sua aplicação em ambientes computacionais com recursos limitados como o CASSIE.

Além disso, a unificação do processo pode permitir que o modelo aprenda padrões mais complexos. No fluxo baseado em dois modelos, o WL reduz as informações multiespectrais de entrada (12 canais) para uma única saída representando a linha d'água. Em seguida, o modelo de reconstrução opera apenas sobre essa informação reduzida, realizando uma transformação de 1 canal para 1 canal. Dessa forma, as bandas espectrais deixam de contribuir diretamente para a estimativa da superfície final. Em contrapartida, no modelo unificado, as informações espectrais permanecem disponíveis durante todo o processo, possibilitando que a rede aprenda de forma conjunta tanto a identificação das transições água-terra quanto a reconstrução da superfície topobatimétrica.

Entretanto, conexões mais complexas entre os dados de entrada e a saída final, pode aumentar a dificuldade de convergência durante o treinamento e elevar a dependência de um conjunto de dados mais extenso, diversificado e representativo.

5 RESULTADOS

Este capítulo apresenta e discute os resultados obtidos ao longo do desenvolvimento do trabalho. Inicialmente, são descritos os procedimentos adotados no treinamento dos modelos, bem como as configurações e estratégias utilizadas. Em seguida, são apresentados os principais resultados alcançados em cada etapa, destacando as conclusões obtidas e os aprimoramentos realizados até a definição dos modelos finais. Por fim é apresentado os 3 modelos finais, comparados entre si e com o método tradicional de linha d'água, juntamente com as considerações finais dos resultados.

5.1 BASE DE DADOS

Uma das principais dificuldades relatadas em trabalhos envolvendo redes neurais é a disponibilidade limitada de dados para treinamento. Este trabalho não foi exceção. Os primeiros experimentos evidenciaram que a quantidade inicial de amostras era insuficiente para garantir estabilidade na convergência e capacidade adequada de generalização, considerando a complexidade das arquiteturas propostas.

5.1.1 Adequação dos parâmetros dos modelos para a quantidade de dados

As primeiras versões dos modelos apresentavam mais de 400 mil parâmetros treináveis, devido ao uso de múltiplos blocos CVT e de mecanismos de atenção global, o que tornou o treinamento inviável frente ao volume reduzido de dados disponível. A quantidade de parâmetros é um dos principais indicadores de complexidade de uma rede neural, pois está diretamente associada à capacidade do modelo e à quantidade de amostras necessárias para um treinamento estável. Embora a literatura não apresente uma fórmula universal capaz de estimar com precisão a relação ideal entre número de parâmetros e número de amostras para qualquer arquitetura, é sabido que essa relação é proporcional: quanto maior o número de parâmetros a serem treinados, maior tende a ser a necessidade de dados para garantir generalização.

Diante disso, para reduzir a complexidade dos modelos, foi adotada a configuração com apenas um nível de convolução no codificador e decodificador, de modo que a redução espacial da imagem de entrada ocorresse apenas uma vez. Essa decisão contribuiu para diminuir o número de operações e parâmetros ao longo da rede.

Outra estratégia utilizada para diminuir a quantidade de parâmetros foi a simplificação do módulo de atenção temporal empregado nos modelos WL e completo. Nas versões iniciais, esse módulo era baseado em atenção multi-cabeça. Posteriormente, ele foi substituído por uma abordagem mais leve utilizando convolução tridimensional, conforme descrito no capítulo de desenvolvimento, mantendo a capacidade de escolher os melhores pixels de cada imagens, porém com menor complexidade.

Por fim, também foram adicionadas camadas de *Dropout* em diferentes pontos da arquitetura, com o objetivo de reduzir a probabilidade de *overfitting*. Essa técnica atua desativando aleatoriamente uma fração dos neurônios durante o treinamento, forçando a rede a aprender representações mais generalizáveis.

Após as simplificações nas arquiteturas dos modelos, o número de parâmetros reduziu bastante. O modelo mais complexo, o modelo temporal, utilizado no WL e completo, com o tamanho de subamostra igual a 16, a quantidade de parâmetros ficou 20.416, já no tamanho 32, ficou 91.481 parâmetros e no tamanho 64 ficou 159.237 parâmetros. Ou seja, o modelo teve no pior dos casos, com tamanho de subamostra 64, aproximadamente 60% de redução de parâmetros e consequentemente na quantidade de dados necessários e chance de *overfitting*.

5.1.2 Filtragem dos dados pobres

Esgotadas as otimizações nos modelos para adequá-los à quantidade de dados disponível, realizou-se uma análise do conjunto de dados, buscando aprimorar sua quantidade, qualidade e consistência. Embora o volume de amostras não fosse o ideal, a utilização de dados com baixa densidade de informação também comprometeria o treinamento, uma vez que subamostras com grande quantidade de pixels vazios reduzem a capacidade do modelo de aprender padrões relevantes.

Dessa forma, a primeira avaliação concentrou-se no equilíbrio entre quantidade de amostras e riqueza de informação por imagem. Para isso, foram realizados testes variando o limiar mínimo de pixels diferentes de zero exigido em cada subamostra. Observou-se que pequenas variações no critério de filtragem, como entre 5% e 10%, resultavam em alterações pouco significativas no tamanho final do conjunto de dados, no máximo 5%. Entretanto, para valores superiores a 15%, verificou-se uma redução expressiva no número de amostras disponíveis, com perdas entre 15% e 25% dos números de subamostras dependendo do tamanho das subamostras. Com base nesses


resultados, definiu-se o limiar de 10% como o mais adequado, pois representa um compromisso entre a preservação do volume de dados e a garantia de uma quantidade mínima de informação geomorfológica útil em cada subamostra.

5.1.3 Expansão do conjunto de dados

Inicialmente, o conjunto de dados foi composto por apenas as três Áreas de Interesse (AOIs). Com a definição do tamanho das subamostras em 16 pixels e a aplicação do critério de filtragem de pelo menos 10% de pixels válidos, obteve-se um total de 2180 amostras. Para subamostra com 32 pixels de tamanho, a base inicial continha 825 amostras e para 64 pixels, o número era 233. Em tamanho 64, mesmo flexibilizando o critério de pixels válido para 1%, ainda assim obteve-se 324 amostras.

Diante desse cenário, tornou-se necessário adotar estratégias para ampliar o conjunto de dados sem comprometer sua consistência física. Uma das abordagens empregadas foi a geração de variações geométricas por meio da transposição das matrizes, obtida pela inversão das coordenadas geográficas latitude e longitude durante a reconstrução dos dados. Na prática, esse procedimento equivale a uma rotação de 90°. Essa técnica foi aplicada a todas as AOIs, multiplicando a quantidade de conjuntos em 2, Babitonga, Babitonga transposta, Praia do Amor, Praia do Amor transposta, Tauranga e Tauranga transposta. A Figura 32 a apresenta o exemplo de como funciona a transposição das coordenadas geográficas.

Figura 32: Representação da transposição feita.




Fonte: Elaborado pelo autor.

Outra técnica explorada para aumentar a quantidade de amostras foi a utilização de janelas deslizantes, permitindo que um mesmo pixel fosse incluído em mais de uma subamostra, conforme descrito no Capítulo 4. Essa abordagem exige equilíbrio, pois valores elevados de repetição aumentam a redundância entre amostras e podem comprometer a generalização do modelo, além de distorcer a avaliação do desempenho. Assim, definiu-se o valor 4 como limite adequado, permitindo que um mesmo pixel aparecesse em até quatro subamostras. Acima desse valor, observou-se que as métricas obtidas passaram a superestimar a qualidade real das predições.

Adicionalmente, com o intuito de ampliar o conjunto de dados e incorporar informações obtidas por medições reais, buscou-se junto ao LOC a disponibilização de levantamentos de campo para as áreas de interesse. Nesse contexto, foram obtidos dados topográficos medidos em campo para a AOI-1. Embora esse conjunto cubra apenas uma porção reduzida da área total, como apresentada no Capítulo 4, ele contribuiu para o aumento da base de treinamento e para aproximar o modelo de observações reais, reduzindo a dependência exclusiva de dados derivados do método tradicional de linha d'água.

Logo nos primeiros treinamentos, observou-se que o modelo não estava prevendo valores de elevação entre 1,5 e 3,5 m. Esse comportamento indicou uma possível limitação na base de dados, no pré-processamento ou na etapa de treinamento. A Figura 33, mostra um gráfico de nuvem de pontos, correlacionando o valor predito com o valor real, nele é possível ver a área sem dados preditos, sinalizado por um retângulo vermelho.

Figura 33: Nuvens de pontos de valores verdadeiros versus predições.



Fonte: Elaborado pelo autor.

Analisando as áreas de interesse, a AOI-2 (Praia do Amor), era a única que fisicamente poderia apresentar variação de maré suficiente para abranger essa faixa, podendo atingir aproximadamente 6 metros. Entretanto, ao analisar o conjunto de dados original da AOI-2, verificou-se que nenhuma das datas selecionadas para extração das bandas espectrais, assim como nenhuma das linhas de costa inferidas pelo método tradicional de WL, continha registros dentro do intervalo de 1,5 a 3,5 m.

Essa lacuna ocorreu porque os dados do marégrafo disponíveis para a região, no período de 03/07/2023 a 28/11/2023, apresentavam valores nessa faixa apenas em dias sem imagens disponíveis do Sentinel-2, devido à frequência orbital, ou a imagens comprometidas por artefatos que dificultam a identificação da linha de costa, como nuvens, reflexos e interferências associadas à quebra de ondas.

Para contornar essa limitação, gerou-se um conjunto adicional de dados para a AOI-2 utilizando o software CODEC, em substituição ao marégrafo, abrangendo todo o ano de 2023. Esse novo conjunto manteve as imagens do conjunto original, porém incluiu datas adicionais em que a maré atingia a faixa anteriormente ausente. Assim, os dois conjuntos passaram a ser utilizados nos modelos.

Após a aplicação de todas as estratégias descritas, o conjunto de dados, para subamostras de 16 pixels, cresceu de 2180 para 4946 amostras, representando um aumento de aproximadamente 127%. Para 32 pixels, a base aumentou de 825 amostras para 1950, aproximadamente 136% de

aumento. Para 64 pixels, o número de amostras variou de 233 para 498, 113% de aumento, no critério de 10% de pixels válidos, ou de 324 para 698, 115% de aumento, no critério mais flexível de 1%.

O Tabela 2, a seguir mostra a comparação dos parâmetros dos modelos e a quantidade de base com base no tamanho das subamostras.

Tabela 2: Demonstrativo da relação do tamanho das subamostras com os parâmetros e as bases.

Tamanho subamostras	16	32	64	64
Critério de pixels válidos	10%	10%	10%	1%
Base inicial	2180	825	233	324
Base final	4946	1950	498	698
Porcentagem de aumento de base	127%	136%	113%	115%
Quantidade de parâmetros	20416	91481	159237	159237
Parâmetros por amostra em relação a base final	5	47	320	228

Fonte: Elaborado pelo autor.

O Tabela 2 demonstra que, conforme o tamanho da subamostra aumenta, a quantidade de subamostras disponíveis diminui. Ao mesmo tempo, a quantidade de parâmetros treináveis do modelo cresce, elevando a relação entre complexidade do modelo e volume de dados disponíveis. Observou-se que, ao passar de 16×16 para 32×32 pixels, essa relação aumentou cerca de 840%. Já entre 32×32 e 64×64 pixels, o aumento variou entre aproximadamente 385% e 580%. Considerando diretamente a variação de 16×16 para 64×64 pixels, o crescimento acumulado atingiu aproximadamente 6300%.

Entretanto, o aumento do tamanho das subamostras também representa uma vantagem, pois permite que o modelo processe porções maiores da área costeira em uma única entrada, incorporando mais informação espacial e geomorfológica. Do ponto de vista oceanográfico, essa escolha impõe restrições físicas associadas à dinâmica da linha de costa. A maior distância observada entre linhas de costa foi de 167 m, o que corresponde a cerca de 16 pixels na resolução do Sentinel-2. Esse resultado indica que subamostras menores que 16×16 dificilmente capturam duas posições distintas

da linha de costa na mesma janela. Além disso, o método *Water-Line* tende a apresentar maior consistência quando se utiliza um número maior de linhas de costa, sendo recomendado trabalhar com pelo menos cinco e idealmente nove, o que implicaria subamostras da ordem de 80 e 144 pixels.

Em síntese, subamostras maiores preservam mais estrutura espacial e aumentam a coerência física do problema, porém reduzem drasticamente o número de amostras disponíveis e tornam o treinamento mais difícil devido ao aumento expressivo da quantidade de parâmetros a serem ajustados.


5.2 TAMANHO DAS SUBAMOSTRAS

Após discutir teoricamente as vantagens e desvantagens de cada tamanho de subamostra na seção anterior, nesta seção será discutido os resultados de cada tamanho de subamostra.

A

Figura 34 apresenta, de forma comparativa, três nuvens de pontos referentes ao modelo de linha d'água treinado com subamostras de 16×16 , 32×32 e 64×64 pixels. Cada nuvem de pontos utiliza uma escala de cores associada ao erro, na qual tons mais escuros indicam maior discrepância entre valores observados e preditos, enquanto tons mais claros representam menor erro. O gráfico inclui três linhas diagonais de referência: a linha preta representa a predição ideal (erro nulo), a linha azul indica um desvio de 0,5 m e a linha vermelha corresponde a um erro de 1,0 m. Além disso, os gráficos também incluem um quadro com os valores finais das métricas utilizadas e o *loss*.

Figura 34: Nuvens de pontos comparativas por tamanho de subamostra.



Fonte: Elaborado pelo autor.


Como ilustrado pela

Figura 34, o modelo com subamostras de 16×16 apresentou o melhor desempenho, pois os pontos permaneceram mais concentrados ao redor da diagonal preta, com a maior parte das amostras posicionadas entre as linhas azuis. O modelo com subamostras de 32×32 apresentou desempenho intermediário, mantendo grande parte dos pontos entre as linhas azuis, porém com maior dispersão e presença de amostras ultrapassando o limite de 1 m indicado pela linha vermelha. Já o modelo com subamostras de 64×64 apresentou uma redução evidente na densidade de pontos, principalmente para valores superiores a 3 m, indicando perda de capacidade de generalização nessa faixa.

Essa queda está diretamente associada à redução do número de subamostras disponíveis conforme o tamanho da janela aumenta, o que limita a variabilidade presente no conjunto de treinamento. Esse efeito torna-se ainda mais crítico porque a principal fonte de valores topobatimétricos elevados é a AOI-2 (Praia do Amor), que concentra as maiores amplitudes de maré entre as áreas analisadas. Assim, o modelo treinado com subamostras maiores passa a ter menor representatividade de exemplos acima de 1 m, reduzindo sua capacidade de aprender padrões robustos para essa faixa de valores.


As Figuras a seguir apresentam os resultados obtidos para a AOI-1, representados graficamente em ambiente GIS, permitindo a comparação visual entre os treinamentos realizados com diferentes tamanhos de subamostras: 16×16 pixels (Figura 35), 32×32 pixels (Figura 36) e 64×64 pixels (Figura 37).

Figura 35: Superfície da AOI-1 para subamostras de 16×16 pixels.




Fonte: Elaborado pelo autor.

Figura 36: Superfície da AOI-1 para subamostras de 32 x 32.



Fonte: Elaborado pelo autor.

Figura 37: Superfície da AOI-1 para subamostras de 64 x 64.



Fonte: Elaborado pelo autor.

Nas figuras das superfícies apresentadas, é possível identificar assinaturas diretas do tamanho das subamostras. Esse efeito ocorre porque, após a predição individual de cada subamostra, os resultados são convertidos em CSV, com as coordenadas e importados no GIS, onde é concatenado para reconstruir a área completa. Como as bordas entre subamostras nem sempre são inferidos corretamente, por falta de informação derivada do tamanho da imagem, surgem essas discontinuidades nas regiões de junção, gerando elevações artificiais ou degraus na superfície estimada.

Na Figura 35, observa-se maior ocorrência dessas discontinuidades, devido ao maior número de subamostras necessárias para cobrir a área. Entretanto, esse cenário também apresenta melhor preservação das feições geomorfológicas, mantendo de forma mais consistente o formato da costa e os padrões característicos da zona intermaré. Na Figura 36, embora as discontinuidades sejam menos frequentes devido ao uso de janelas maiores, nota-se uma perda significativa na representação das curvas e estruturas da região intermarés, indicando menor capacidade do modelo em reconstruir detalhes espaciais relevantes. A Figura 37 apresenta um comportamento intermediário, equilibrando parcialmente os dois efeitos.


Dessa forma, o tamanho de subamostra 16×16 mostrou-se mais adequado para a AOI-1, pois, apesar de introduzir mais artefatos de junção, preserva melhor a estrutura espacial e o padrão

morfológico característico da zona intermaré. Este tamanho de subamostra, teve o melhor desempenho tanto nas métricas quanto na análise da superfície.

Sendo assim, o tamanho de subamostra 16×16 foi considerado o mais adequado para o modelo de linha d'água. A análise dos demais modelos, interpolador e completo, manteve resultados coerentes com os obtidos no modelo WL, reforçando a escolha do tamanho 16×16 como a configuração mais indicada.

A Figura 38 apresenta as nuvens de pontos do modelo interpolador, seguindo o mesmo padrão de visualização utilizado para o modelo de linha d'água. Entretanto, nesse experimento, a AOI-2 foi removida do conjunto de teste, pois essa área é a única que apresenta valores de topobatimetria superiores a aproximadamente 1,5 metros, o que poderia influenciar diretamente a distribuição dos dados.

Figura 38: Nuvem de pontos para diferentes tamanhos de subamostras.



Fonte: Elaborado pelo autor.

A Figura 38 demonstra que o modelo com subamostras de 16×16 apresentou o melhor desempenho mesmo com a exclusão da AOI-2. O modelo com subamostras de 32×32 também apresentou desempenho competitivo, mantendo resultados próximos ao tamanho 16×16 , mesmo com menor quantidade de amostras disponíveis para treinamento. Em contrapartida, o modelo com subamostras de 64×64 apresentou desempenho inferior, com maior dificuldade em distinguir corretamente valores nulos e não nulos. Esse comportamento pode ser observado pela formação de concentrações de pontos ao longo dos eixos do gráfico, principalmente em torno do valor zero, indicando que o modelo frequentemente previu valores iguais a 0 para regiões onde deveria haver informação válida, e vice-versa.


Essa limitação também se refletiu nas métricas quantitativas. Enquanto os modelos de 16×16 e 32×32 apresentaram, respectivamente, correlação de Pearson de 0,93 e 0,92 metros e na correlação de Sperman 0,58 e 0,78, o modelo de 64×64 obteve o valor de 0,4 na correlação de Pearson e 0,16 na correlação de Sperman. E em relação ao MAE, MSE e RMSE, nota-se que quanto maior o grid maior o erro, os modelos de 16, 32 e 64, tiveram um MAE, respectivamente, de 0,02, 0,05 e 0,09 metros.

5.3 MÁSCARAS

Conforme descrito no Capítulo 4, os modelos foram treinados utilizando uma máscara binária para distinguir regiões com dados válidos e regiões sem informação (dados faltantes). A expectativa inicial era que essa estratégia melhorasse o resultado superfície sem impactar o desempenho nas métricas do modelo ou até melhorasse o desempenho. Entretanto, os resultados obtidos mostraram um comportamento diferente do esperado.

A Figura 39 apresenta a comparação entre o treinamento do modelo interpolador com máscara e sem máscara, considerando a mesma configuração de subamostras, *learning rate* e época. Observa-se que, do ponto de vista da nuvem de pontos, os resultados foram muito semelhantes. Em alguns cenários, o modelo mascarado apresentou desempenho pouco inferior, apresentando uma quantidade de pontos fora das linhas de 1 metro, linha vermelhas, um pouco maior.


Figura 39: Nuvem de pontos com e sem máscara.



Fonte: Elaborado pelo autor.

Nas métricas os resultados entre o modelo com e sem máscara também não foi expressivo, por mais que exista uma diferença numérica entre eles, boa parte é justificada pela escala diferente ou pelo modelo mascarado considerar a máscara também para calcular as métricas. A Figura 40, apresenta as métricas de treinamento e validação MAE e RMSE dos mesmos modelos comparado na nuvem de pontos da figura anterior.

Figura 40: Mettricas com e sem máscara.




Fonte: Elaborado pelo autor.

No entanto, ao analisar os resultados no ambiente GIS, o comportamento dos modelos tornou-se mais evidente. A

Figura 41, apresenta a representação gráfica os resultados do modelo de linha d'água com e sem máscara no ambiente GIS, evidenciando erros concentrados em regiões onde o dado de referência apresenta ausência ou falhas.

Figura 41: Superfícies do modelo linha d'água com e sem mascara.




Fonte: Elaborado pelo autor.

A

Figura 42, apresenta a representação gráfica dos resultados do modelo interpolador com e sem máscara no ambiente GIS, evidenciando o maior cenário de discrepância encontrado.

Figura 42: Superfície do modelo interpolador com e sem máscara.



Fonte: Elaborado pelo autor.

Nos modelos treinados sem máscara, foi observado que a rede tende a prever valores negativos aleatórios nas regiões onde não existem dados válidos. Já nos modelos treinados com máscara, a rede passa a prever valores próximos de zero nessas mesmas regiões. Dessa forma, a máscara não eliminou o problema de predição em áreas inválidas, mas apenas alterou a escala do erro. Esse comportamento é relevante porque tanto valores negativos quanto valores próximos de zero podem representar topobatimetria fisicamente plausível, dependendo do referencial adotado. Assim, o modelo continua produzindo valores interpretáveis como “reais”, mesmo em locais onde não deveria haver informação estimada.

A principal vantagem observada no uso da máscara foi a melhor preservação do contorno geométrico da linha de costa, pois o modelo passou a diferenciar com mais clareza a região de interesse e seus limites. Entretanto, essa vantagem veio acompanhada de um efeito colateral importante: o aumento de artefatos nas bordas das subamostras. Quando as subamostras são concatenadas para reconstrução da superfície completa em software GIS, esses artefatos tornam-se visíveis como pequenos relevos artificiais nas regiões de transição entre janelas adjacentes.

Além disso, as falhas presentes no dado de referência constituíram um problema tanto para os modelos com máscara quanto para os modelos sem máscara. Isso ocorre porque, na prática, existem dois tipos distintos de regiões sem dados: (i) áreas que realmente não pertencem à zona intermaré ou estão fora da área de estudo, onde não deveria haver estimativa alguma, e (ii) áreas onde deveria existir informação topobatimétrica, mas que apresentam ausência de dados devido a falhas no levantamento tradicional ou limitações de aquisição. Embora o uso da máscara tenha levado o modelo a apresentar maior coerência numérica em regiões com falhas, essa melhoria foi limitada pelo aumento de erros provindos das outras regiões sem dados e não resultou em ganho aparente na qualidade da superfície reconstruída.

Por fim, outro teste realizado foi a comparação entre a função de perda MAE e a função Huber. Em todos os cenários avaliados, o uso da Huber apresentou desempenho superior ao MAE, independentemente da presença de máscara. Esse resultado se manteve consistente para todos os tamanhos de subamostra testados e para os três modelos desenvolvidos (WL, interpolador e completo), indicando que a função Huber foi mais adequada para lidar com a variabilidade dos dados costeiros e com a presença de erros extremos no conjunto de treinamento.

5.4 MELHORES RESULTADO

Após a realização dos testes preliminares descritos desde o início do Capítulo 5, foi definido o conjunto de dados final e gerada a versão final dos modelos, e após isso iniciou-se a etapa de ajustes finos (*fine-tuning*).

O primeiro ajuste fino foi relacionado ao hiperparâmetro *learning rate*. Quando configurado em 0,001, os modelos apresentavam convergência rápida, porém não atingiam bons resultados na métrica MAE, mantendo-se em torno de 1,5 metros mesmo nos melhores cenários. Em contrapartida, ao utilizar valores mais baixos, como 0,00001, os modelos demoravam muitas épocas para iniciar a

convergência e, em alguns casos, não convergiam. Entretanto, quando a convergência ocorria, os resultados eram superiores, alcançando valores próximos de 0,5 metros de MAE.

Diante disso, foi adotado o *callback ReduceLROnPlateau* da biblioteca *Keras*, permitindo que o *learning rate* fosse reduzido automaticamente quando o modelo atingisse um platô de desempenho. Nesse procedimento, caso não houvesse melhoria após 5 épocas consecutivas, o *learning rate* era multiplicado por 0,1, reduzindo gradualmente de 0,001 para 0,0001 e assim sucessivamente, até o limite mínimo de 0,000001. Essa estratégia permitiu combinar a convergência inicial rápida proporcionada por taxas maiores com o refinamento final obtido por taxas menores.

Além disso, foi utilizado o *callback EarlyStopping*, com o objetivo de interromper o treinamento quando o modelo atingisse novamente um platô após sucessivas reduções do *learning rate*, reduzindo o risco de *overfitting* e evitando gasto computacional desnecessário, tendo em vista que o projeto utilizou para os treinamentos dos modelos um *cluster* de computadores compartilhado entre os pesquisadores da UFSC. Por mais que o cluster era muito poderoso, 8 GPUs Nvidia HGX/H100, a quantidade de pessoas utilizando era muito alta.


Ao final dessa etapa de ajustes finos, foram obtidos os melhores resultados deste trabalho, os quais serão apresentados a seguir, organizados conforme os três modelos desenvolvidos: linha d'água, interpolador e modelo completo.

5.4.1 Modelo de linha d'água

A

Figura 43, apresenta as métricas resultante do treinamento do modelo de linha d'água final.

Figura 43: Metricas do modelo de linha d'agua.



Fonte: Elaborado pelo autor.

É possível observar na


Figura 43 que o modelo apresenta convergência rápida nas primeiras épocas, atingindo estabilidade próxima de 100 épocas. A curva preta representa o erro no conjunto de treinamento e apresenta queda contínua e suave, indicando que o modelo está aprendendo os padrões presentes nos dados.

A curva vermelha representa o erro no conjunto de validação e apresenta oscilações mais acentuadas, com picos ao longo do treinamento. Esse comportamento evidencia uma maior dificuldade de generalização. No entanto, nota-se que a magnitude desses picos se diminui com o passar das épocas, sugerindo que o modelo passa a estabilizar seu desempenho e começa se tornar um modelo melhor de generalização.

Próximo de 100 épocas, a redução automática do *learning rate* inicia, marcando a fase de refinamento, em que a convergência se torna mais lenta, porém mais consistente. Esse comportamento evidencia ajustes mais sutis nos pesos do modelo. Como consequência, observa-se uma redução adicional do MAE, atingindo valores inferiores a 0,1 ao final do treinamento.

A Figura 44, apresenta a nuvem de pontos resultante do modelo de linha d'água em sua versão final.

Figura 44: Nuvem de ponto do modelo linha d'água.



Fonte: Elaborado pelo autor.

Como apresentado na Figura 44, o modelo atingiu valores elevados de correlação de Pearson e Spearman, indicando forte concordância entre os valores preditos e os valores de referência. A correlação de Pearson evidencia uma relação linear consistente entre as variáveis, enquanto a correlação de Spearman indica que o modelo também preserva a ordem e a tendência geral dos dados.


Além disso, observa-se que a maior parte dos pontos está concentrada entre as linhas diagonais azuis, o que indica que o modelo consegue prever a maioria dos pontos com erro inferior a 0,5 metros. Nota-se também a presença de pontos entre as linhas vermelhas, representando previsões com erro de até 1 metro. No entanto, alguns pontos ultrapassam as linhas vermelhas, evidenciando casos pontuais em que o erro supera 1 metro.

Outro aspecto relevante é a presença de uma concentração significativa de pontos em torno de $x = 0$ (valores reais), formando uma linha vertical. Esse padrão indica que o modelo apresenta maior dificuldade em estimar corretamente valores próximos de 0, atribuindo valores aleatórios quando a referência é 0. O que sugere que o fato do 0 ser um valor fisicamente possível, mas também ser utilizado como valor nulo, confunde a RNA.

Por fim, também é possível observar que a faixa de valores ausente entre 1,5 e 3,5 metros passou a ser melhor preenchida, refletindo a contribuição do conjunto adicional AOI-2 derivado do CODEC.

Para finalizar, a Figura 45, apresenta os pontos gerados pelo modelo de linha d'água interpolados para gerar a superfície por meio do software GIS.

Figura 45: Superfície do modelo de linha d'água.




Fonte: Elaborado pelo autor.

Na Figura 45, fica evidente que o modelo consegue montar a superfície de forma coerente em boa parte dos pontos, embora ainda existam pontos que não deveriam existir, gerando esses polígonos esticados, resultante da interpolação do GIS.

5.4.2 Modelo de interpolação

A Figura 46, apresenta as métricas resultante do treinamento do modelo de interpolação na sua versão final.

Figura 46: Mettricas do modelo de interpolação.




Fonte: Elaborado pelo autor.

Na Figura 46, é observável que, assim como o observado no modelo de linha d'água, o modelo de interpolação converge rapidamente nas primeiras épocas e continua convergindo até o fim do treino. Como no outro modelo também, as linhas vermelhas, relativas ao erro com o dado de validação, apresentam picos, que com o passar das épocas e a diminuição do *learning rate* se estabilizam. Neste modelo, o treinamento foi mais curto, perto de 80 épocas e o MAE foi um pouco maior, perto de 0,13 metros.

A Figura 47, apresenta a nuvem de pontos resultante do modelo final de interpolação.

Figura 47: Nuvem de ponto do modelo interpolador.



Fonte: Elaborado pelo autor.

Na Figura 47, observa-se que, assim como o modelo apresentado anteriormente, o modelo interpolador atingiu valores elevados de correlação de Pearson e Spearman, indicando boa concordância entre os valores preditos e os de referência.

Entretanto, o desempenho mais consistente concentrou-se na faixa de topobatimetria entre -1 e 1 metro, na qual a maior parte dos pontos permaneceu entre as linhas diagonais azuis, erro de até 0,5 metros. Para valores acima de 1 metro, nota-se que os pontos passam a se concentrar entre as linhas vermelhas, indicando erros da ordem de 1 metro. Esse comportamento sugere maior dificuldade do modelo em estimar valores elevados de topobatimetria. O que sugere que a quantidade de dados para essa faixa não foi o suficiente, tendo em vista que a base comporta apenas a AOI-2 nessa faixa.

Além disso, o modelo também apresentou limitações na previsão de valores próximos de zero. Essa dificuldade é evidenciada pela presença de uma linha vertical de pontos em torno de $x = 0$. Entretando, esse padrão ocorre de forma mais intensa do que no modelo anterior, sugerindo que o interpolador apresentou maior sensibilidade ao problema.

Para finalizar, a Figura 48, apresenta a superfície gerada, por meio do software GIS, para os pontos gerados pelo modelo de interpolação.

Figura 48: Superfície do modelo interpolador.



Fonte: Elaborado pelo autor.


Na Figura 48, fica evidente que o modelo consegue montar a superfície de forma coerente em boa parte dos pontos, assim como o modelo WL, porém existem diversos pontos que não deveriam existir, gerando esses polígonos esticados em áreas sem dado.

5.4.3 Modelo completo

A

Figura 49, apresenta as métricas resultante do treinamento do modelo completo em sua versão final.

Figura 49: Metricas do modelo completo.



Fonte: Elaborado pelo autor.


Com a

Figura 49, percebe-se que o modelo completo tem resultados de métricas muito semelhantes aos outros modelos, principalmente ao modelo de linha d'água. A diferença deste para os outros é a velocidade de convergência, esse modelo tem uma curva de aprendizagem mais acentuada em relação aos outros, o que implica na decida de *learning rate* mais cedo que os demais, perto de 40 épocas.

A

Figura 50, apresenta a nuvem de pontos resultante do modelo completo na versão final.

Figura 50: Nuvem de pontos do modelo completo.




Fonte: Elaborado pelo autor.

A nuvem de pontos do modelo completo apresenta um resultado semelhante a nuvem de pontos do modelo de linha d'água, porém com mais pontos. Isto ocorre por conta da maior quantidade de dados de referência, tendo em vista que neste modelo o dado de referência é a superfície inteira e não só algumas linhas como no de linha d'água. Nesta nuvem de pontos, assim como na nuvem do modelo WL, boa parte dos pontos estão entre as linhas azuis e alguns entre as vermelhas. Também se nota a presença da linha vertical de pontos em direção ao valor 0 do eixo x. Ou seja, esse modelo tende a ter o mesmo nível de resultado do modelo de linha d'água.

Para finalizar, a

Figura 51, apresenta a superfície gerada, por meio do software GIS, para os pontos gerados pelo modelo completo.

Figura 51: Superfície do modelo completo.



Fonte: Elaborado pelo autor.

O modelo completo, também apresentou resultado muito similar ao modelo de linha d'água se tratando da superfície. Na

Figura 51, é possível perceber a semelhança entre os 2 modelos. A maior diferença entre eles é perceptível analisando os polígonos gerados por conta dos pontos preditos erroneamente. No modelo completo os polígonos que não deveriam existir são menores e aparecem em menor quantidade.

5.4.4 Comparações com o modelo tradicional

Para possibilitar uma comparação mais robusta e coerente entre os métodos avaliados, adotou-se como referência a base da AOI-1 gerado por *laser scanner*, por ser a única área de interesse que dispõe de dados topobatimétricos medidos diretamente em campo. Essa escolha permitiu uma comparação entre os modelos, o dado medido em campo e o método tradicional de WL. Nesta comparação, foram utilizados cinco conjuntos de dados:


- **Dado de referência:** topobatimetria da AOI-1 medida em campo por laser scanner;
- **Método tradicional:** Resultado gerado para a mesma área do dado medido em campo utilizando o método Water Line Otsu Modified de Pool et al. (2025);
- **Modelo WL com interpolação GIS:** Resultado gerado para a mesma área do dado medido em campo utilizando o modelo de linha d'água desenvolvido neste trabalho, com interpolação para gerar a superfície realizada em ambiente GIS (denominado ML Waterline);
- **Modelo WL com Modelo de interpolação:** Resultado gerado para a mesma área do dado medido em campo utilizando o modelo de linha d'água desenvolvido neste trabalho, com interpolação realizada pelo modelo interpolador também proposto neste trabalho (denominado ML Waterline Interpol);
- **Modelo completo:** Resultado gerado para a mesma área do dado medido em campo utilizando o modelo completo desenvolvido neste trabalho (denominado ML Merged).

Os dados foram importados em ambiente GIS, onde foram geradas as superfícies correspondentes e comparadas com a superfície de referência obtida em campo. Essa comparação resultou em uma superfície de erro. Nas superfícies de erro, os valores dos erros foram normalizados no intervalo entre -1 e 1 metro. Onde valores mais próximos de azul indicam erro negativo, enquanto valores mais próximos de vermelho indicam erro positivo. Já regiões próximas de branco representam valores de erro próximos de zero, indicando maior concordância com a superfície de referência.

A

Figura 52 apresenta os resultados obtidos. O primeiro mapa corresponde à superfície de erro do método tradicional (WL Otsu Modified). O segundo mapa representa o erro do modelo proposto de linha d'água com interpolação no GIS (ML Waterline). O terceiro mapa apresenta o erro do modelo de linha d'água com interpolação realizada pelo interpolador desenvolvido neste trabalho (ML Waterline Interpol). Por fim, o quarto mapa apresenta o erro do modelo completo (ML Merged). Abaixo dos mapas, apresenta-se uma tabela comparativa com as métricas quantitativas, incluindo MAE, RMSE e demais indicadores estatísticos utilizados para avaliar o desempenho relativo de cada abordagem.

Figura 52: Comparação entre as superfícies de cada modelo com o WL tradicional e o dado de campo.



Fonte: Elaborado pelo autor.

Na

Figura 52, observa-se que o método tradicional de WL (WL Otsu Modified) apresentou o melhor desempenho, com MAE de 0,111 metros. Em seguida, o modelo completo (ML Merged) obteve MAE de 0,215 metros, seguido do modelo WL via RNA (ML Waterline) com MAE de 0,235 metros. Por fim, o modelo baseado na combinação WL via RNA + interpolação via RNA (ML Waterline Interpol) apresentou o pior desempenho, com MAE de 0,793 metros.

Esses resultados indicam que o fato de grande parte do conjunto de treinamento ter sido construída a partir de dados gerados pelo método tradicional de WL tende a limitar o desempenho das redes neurais, uma vez que o modelo passa a aprender padrões derivados do próprio método tradicional. Mesmo com a inclusão de uma base de referência obtida em campo por *laser scanner*, essa informação representa uma parcela reduzida do conjunto total, pois corresponde a uma área limitada dentro da AOI-1 e ainda é apenas uma base em 5 utilizadas. Dessa forma, torna-se necessário incorporar mais áreas com dados medidos diretamente em campo, a fim de permitir que os modelos desenvolvidos possam superar efetivamente os métodos tradicionais.

Apesar disso, o desempenho do modelo completo foi relevante, pois ele obteve o segundo melhor resultado. Esse comportamento sugere que o modelo unificado possui potencial para competir com o método tradicional. O modelo WL via RNA também apresentou desempenho próximo ao modelo completo, indicando que ele representa uma abordagem promissora para a etapa de extração da linha d'água.

Por outro lado, a combinação WL via RNA com o interpolador via RNA apresentou o maior erro, evidenciando que o interpolador adicionou incerteza ao processo. Esse resultado reforça a hipótese de que a redução do conjunto multiespectral (múltiplas bandas e múltiplas datas) para uma única imagem de linhas de costa diminui a quantidade de informação disponível para a reconstrução da superfície. Em seguida, ao interpolar essa representação simplificada, o modelo tende a amplificar erros acumulados. Em contraste, o modelo completo preserva as informações espectrais ao longo de todo o fluxo de predição, o que explica seu desempenho superior em relação à abordagem em duas etapas.

5.5 OUTROS PROBLEMAS ENFRENTADOS

Um problema enfrentado pelos modelos foi a ausência de um referencial observado fixo de nível do mar entre as diferentes áreas de estudo. Nas bases de maré utilizadas o valor sempre é relativo

a algum ponto, ou seja, o 0 em uma base pode ser -8 em outra base, ou 8 em outra base, não existe um padrão, as bases se baseiam na diferença do nível do mar em um ponto, de um momento para outro. Escolhe-se uma data hora e localização e define aquilo como 0 e depois todas outras medições são baseadas na diferença em metros daquela medição. Por tanto, se nas bases diz 1 metro no dia 10, por exemplo, significa na verdade que o mar está 1 metro mais alto do que o registrado nesse mesmo ponto anteriormente na referência e se diz -1 metro, está um metro mais baixo. Por mais que para as bases brasileiras seja possível utilizar algum padrão nacional, como a média marés baixas das bases da marinha, esse padrão não é adotado internacionalmente. Essa limitação dificultou a padronização dos valores de maré e comprometeu a definição de um valor adequado para representar dados nulos. E por consequência disso outro problema encontrado foi o uso do valor zero para representar ausência de dados, uma vez que o valor 0 também corresponde a uma elevação topobatimétrica fisicamente possível. Essa ambiguidade introduz ruído no aprendizado e tende a confundir o modelo durante o processo de regressão.

Uma possível melhoria consiste em adotar um referencial global único para todas as regiões analisadas, de forma que a escala de maré seja consistente em todo o conjunto de dados. Por exemplo, sabendo que a maré de uma região varia em 8 metros, deve-se normalizar essa base no intervalo de 0 a 8 metros. Para isso é necessária uma análise profunda da região, durante anos, para conhecer o menor e maior valor registrado durante esse período. Após a definição desse referencial fixo, seria possível atribuir aos dados nulos um valor fora da faixa física da maré, como -1, no exemplo anterior, garantindo que o modelo reconheça explicitamente esses valores como inválidos.

O terceiro principal problema identificado está relacionado à presença de falhas estruturadas nos dados de referência, caracterizadas por faixas sem informação em locais onde deveria existir dado topobatimétrico. Esse problema foi parcialmente mitigado com o uso de máscara, porém o ideal seria utilizar uma máscara específica para esse tipo de falha, sem interferir na função de perda aplicada às regiões válidas. Alternativamente, seria possível aplicar um procedimento de correção antes do treinamento, preenchendo essas falhas com valores estimados a partir da vizinhança espacial. Um exemplo simplificado seria substituir sequências como 4, 0, 6 pela média dos valores adjacentes, resultando em 4, 5, 6. Entretanto, como se trata de imagens, essa estimativa deve considerar os dois eixos espaciais, utilizando kernels bidimensionais e métodos de interpolação local.

Por fim, outra abordagem seria manter o modelo na forma atual e aplicar pós-processamento na superfície predita, como suavização por *Gaussian Blur*, com o objetivo de reduzir artefatos de

interpolação e transições abruptas entre subamostras. Em alguns cenários, também seria possível aplicar clipping para restringir valores a uma faixa coerente. Essa alternativa pode ser vantajosa para regiões como a AOI-1, onde predominam valores positivos, mas seria inadequada para a AOI-2, que pode apresentar elevações negativas em função da dinâmica de macromaré e da presença de canais e regiões submersas.

6 CONCLUSÕES

O trabalho realizou uma revisão sistemática que permitiu avaliar com clareza o atual estágio de desenvolvimento dos estudos no tema de topografia derivada de satélites a partir de dados de sensoriamento remoto e mostrou os modelos mais promissores baseados em aprendizado de máquina que podem superar o desempenho dos modelos empíricos tradicionais. A partir dos resultados da revisão sistemática foi escolhido o modelo de RNA baseado na arquitetura U-Net com variações aplicando CVT para aprimorar o modelo existente na literatura.

Os conjuntos de dados de entrada e referência foram processados utilizando a plataforma GEE para padronizar as camadas para RNA para as AOIs definidas neste estudo. Posteriormente os conjuntos foram pré-processado em *Python* para ajustes finais, reconstrução das imagens, construção de subamostras e entrada nos modelos.

Três modelos de redes neurais foram construídos. Um para linha d'água, utilizando as bandas B1 (aerossol), B2 (azul), B3 (verde), B4 (vermelho), B5 (borda do vermelho), B8 (infravermelho), B11 (infravermelho curto) e B12 (infravermelho curto), os índices NDWI, MNDWI e AWEI e a maré para gerar uma imagem com as linhas de costa. Outro para interpolar os linhas de costa e gerar a superfície de elevação. E por fim, um modelo que fazer os dois processos juntos.

O modelo de linha d'água conseguiu um RMSE de 0,27 metros. O modelo de interpolação conseguiu um RMSE de 0,46 metros. E o modelo completo teve um RMSE de 0.35 metros. Entretanto os dados utilizados para treino foram em maioria dados vindos do WL tradicional, o que aumentou o erro comparado com os dados de *laser scanner*.

O trabalho possuía os objetos específicos a seguir, começando por “Realizar uma revisão sistemática da literatura sobre o uso de Redes Neurais Artificiais aplicadas à topografia entremarés

derivada de satélites.” Este objetivo foi atingido e pode ser comprovado pela revisão apresentada no Capítulo 3.

O segundo objetivo era “Desenvolver um modelo de RNA capaz de identificar linhas d’água em zonas entremarés com base em imagens multiespectrais e serie-temporais.” E o terceiro objetivo “Desenvolver um modelo de RNA capaz de interpolar dados dos marégrafos com as linhas d’água para gerar Modelos Digitais de Elevação”. Estes objetivos foram atendidos e podem ser observados nos capítulos 4 e 5.

O último objetivo era “Validar os MDE gerados por meio de dados coletados em campo através de métodos topográficos tradicionais de alta precisão, como Laser Scanner Terrestre.”. E o objetivo foi atendido no Capítulo 5, na comparação entre os modelos.

O trabalho buscou responder as seguintes perguntas de pesquisa e suas hipóteses. A primeira pergunta era: “De que forma RNAs aplicadas a dados multiespectrais de sensoriamento remoto, podem ser utilizadas para gerar MDEs para zonas entremarés?” e sua respectiva hipótese: “A utilização de técnicas de RNAs, como o U-Net e transformers, permite gerar MDEs para zonas entremarés, quando integradas a séries históricas de imagens multiespectrais e dados maregráficos”. Está hipótese foi aceita, pois o modelo com melhor performance foi U-Net com blocos CVT para imagens multiespectrais temporais e foi possível gerar MDEs de zonas entremares.

A segunda pergunta de pesquisa era “De que forma é possível aprimorar os modelos de RNA encontrados na literatura, visando reduzir o erro médio absoluto na previsão da topobatimetria em zonas intermarés, a partir de imagens de satélite?” E sua hipótese: “A redução do Mean Absolute Error (MAE) na previsão da topobatimetria em zonas entremarés ocorre com o aprimoramento dos modelos de RNA por meio de ajustes finos de parâmetros, uso de transformers e integração de séries temporais de imagens, o que melhora a representação da dinâmica costeira ao longo do tempo.”. Essa hipótese foi parcialmente aceita, pois o modelo implementado, foi baseado no modelo de U-Net para intermarés criado por Chen et. al. (2023) e aprimorando usando CVT e series temporais, porém o modelo deste trabalho teve um RMSE maior que o de Chen 0,13 metros. No entanto, o modelo deste trabalho possui teoricamente capacidade de superar o modelo de Chen se treinado com um conjunto melhor.

A terceira pergunta: “De que forma é possível aplicar técnicas de transformer na arquitetura U-Net para previsão da topobatimetria em zonas intermarés, a partir de imagens de satélite visando reduzir o erro médio absoluto?” E a respectiva hipótese: “A aplicação de blocos Transformer na fase de codificação da arquitetura U-Net, combinada com técnicas de fusão adaptativa de características, reduz o MAE na previsão da topobatimetria, ao melhorar a extração e a recomposição de padrões espaciais e espectrais em ambientes costeiros opticamente complexos.”. Esta hipótese foi aceita, pois os modelos implementados utilizam blocos CVT no codificador e decodificador da U-Net. Além disso os modelos utilizaram atenção no espaço latente para realizar a fusão das linhas de costas de cada imagem da série-temporal.

E a última pergunta: “Qual o percentual de redução dos erros médios absolutos, Mean Absolute Error (MAE) do modelo RNA, em comparação com os métodos de sensoriamento remoto tradicionais para zonas entre mares, que utilizam a aproximação matemática, sem a utilização de RNA?” E a hipótese: “Modelos baseados em RNA apresentam melhor desempenho na estimativa da topobatimetria em zonas entremarés, com percentuais de redução do erro médio absoluto superiores aos obtidos com métodos tradicionais.”. Esta hipótese não pode ser comprovada, mas teoricamente foi aceita, pois os modelos não superam o WL tradicional diretamente, mas superaram indiretamente. O motivo pelo qual os modelos não puderam superar os métodos tradicionais de forma direta foi a falta de conjuntos de dados de campo densos o bastante para os treinamentos, obrigando o uso de conjuntos resultantes de WL tradicional. E considerando que os resultados dos modelos com dados de WL tradicional, o MAE do modelo completo para o WL tradicional foi de 0,09. Por tanto, teoricamente o modelo treinado com boa parte dos dados sendo de campo, pode ter esse mesmo erro com esses dados, o que superaria os métodos tradicionais.

Outro aspecto interessante que deve ser levado em consideração, é que o modelo foi treinado com 2 tipos de marés diferentes, macromares e micromarés, e ficou faltando uma base de mesomaré. Esse aspecto não limita a capacidade de generalização que os modelos tiveram, pois os modelos foram treinados com os casos mais extremos dos dois lados, micro e macro. No entanto, é interessante ressaltar a necessidade de uma base de mesomaré para garantir a assertividade dos modelos em todos os cenários. Além disso, as características de fundo e de sedimentos, também é um aspecto que deve ser melhorado para garantir melhor capacidade de generalização.

6.1 CONTRIBUIÇÕES CIENTÍFICAS

Este estudo contribuiu para o avanço do estado da arte na aplicação de redes neurais em zonas entremarés. A primeira contribuição foi a revisão sistemática desenvolvida no âmbito desta pesquisa, que resultou em uma publicação na revista *Geomatica* (Elsevier), intitulada *Machine learning applied to remote sensing in the context of intertidal zone mapping: A literature review*. Esse trabalho teve como objetivo mapear de forma abrangente os estudos existentes na literatura voltados à estimativa topobatimétrica em zonas entremarés por meio de sensoriamento remoto e aprendizado de máquina.

Além disso, essa dissertação também contribuiu para o desenvolvimento de novas abordagens de processamento de imagens de satélite utilizando redes neurais. O modelo de rede neural visando o fluxo completo, entrando imagens de satélite e saindo mapa de elevação, será otimizado com as melhorias que não puderam ser implementadas a tempo dessa dissertação e isso irá gerar uma outra publicação de nível internacional, para apresentar os avanços que esse modelo pode oferecer.

Por fim, o trabalho apresenta impacto relevante para estudos ambientais, uma vez que os avanços metodológicos e os modelos desenvolvidos podem ser aplicados na geração de mapas topobatimétricos em larga escala. Esses produtos possuem potencial para apoiar o monitoramento espaço-temporal da morfologia costeira, a análise de vulnerabilidade a eventos extremos e a avaliação de efeitos associados às mudanças climáticas, contribuindo para o planejamento e a gestão sustentável de zonas costeiras.

6.2 TRABALHOS FUTUROS

Como trabalhos futuros, este estudo recomenda a implementação das melhorias descritas no final do Capítulo 5, com o objetivo de mitigar limitações associadas à ausência de um referencial fixo de maré entre as bases utilizadas, ao uso do valor zero para representar dados inválidos e às falhas estruturadas presentes nos dados de referência empregados no treinamento dos modelos.

Além disso, este trabalho recomenda a ampliação do número de Áreas de Interesse, de modo a aumentar a abrangência internacional dos experimentos e permitir a avaliação da metodologia em diferentes tipos de zonas entremarés, com características geomorfológicas e regimes de maré distintos. Recomenda-se a realização de um estudo voltado à classificação e agrupamento de zonas entremarés, visando selecionar pelo menos uma área representativa para cada grupo, de forma a garantir maior diversidade ambiental, maior capacidade de generalização dos modelos e uso global. Recomenda-se também utilizar uma quantidade maior conjuntos de dados com dados medidos em

campo do que conjunto de dados pelo método Water Line tradicional, para garantir melhores desempenhos dos modelos.

REFERÊNCIAS

ALMEIDA, Luis Pedro; OLIVEIRA, Israel Efraim de; LYRA, Rodrigo; DAZZI, Rudimar Luís Scaranto; MARTINS, Vinícius Gabriel; KLEIN, Antonio Henrique da Fontoura. Coastal Analyst System from Space Imagery Engine (CASSIE): shoreline management module. **Environmental Modelling & Software**, v. 140, p. 105033, 2021. DOI: 10.1016/j.envsoft.2021.105033.

ALPAYDIN, Ethem. **Introduction to Machine Learning**. 4. ed. Cambridge, MA: The MIT Press, 2020. ISBN 978-0262043793.

ALVES, Deivid Cristian Leal; ESPINOZA, Jean Marcel de Almeida; ALBUQUERQUE, Miguel da Guia; SILVA, Marine Bastos da; FONTOURA, José Scott; SERPA, Christian; WESCHENFELDER, Jair. **Bathymetry Estimation by Orbital Data of OLI Sensor: A Case Study of the Rio Grande Harbor, Southern Brazil**. Journal of Coastal Research, Special Issue No. 85, p. 51–55, 2018. DOI: 10.2112/SI85-011.1

BAGOT, Philippe; HUYBRECHTS, Nicolas; SERGENT, Philippe. Satellite-derived topography and morphological evolution around Authie macrotidal estuary (France). **Journal of Marine Science and Engineering**, v. 9, n. 12, p. 1354, 2021. DOI: 10.3390/jmse9121354.

BENGOUFA, Soumia; NICULESCU, Simona; MIHOUBI, Mustapha Kamel; BELKESSA, Rabah; RAMI, Ali; RABEHI, Walid; ABBAD, Katia. Machine learning and shoreline monitoring using optical satellite images: case study of the Mostaganem shoreline, Algeria. **Journal of Applied Remote Sensing**, v. 15, n. 2, p. 026509, 2021. DOI: 10.1117/1.JRS.15.026509.

BISHOP, Christopher M. **Pattern recognition and machine learning**. Berlin: Springer, 2006. DOI: 10.1117/1.2819119. ISBN 978-0387310732.

BISHOP-TAYLOR, Robbi; SAGAR, Stephen; LYMBURNER, Leo; BEAMAN, Robin J. **Between the tides: Modelling the elevation of Australia's exposed intertidal zone at continental scale**. Estuarine, Coastal and Shelf Science, v. 223, p. 115–128, jul. 2019. DOI: 10.1016/j.ecss.2019.03.006.

BONOU, Frédéric; MADIESSEU METEM, Raïssa Christelle; ALMEIDA, Luis Pedro; ANGNUURENG, Bapentire Donatus; SOHOU, Zacharie. 40-year journey of shoreline changes

along the Benin coast using satellite data through the CASSIE tool. **Ocean Science Journal**, v. 59, n. 4, p. 61, 2024. ISSN 2005-7172. DOI: 10.1007/s12601-024-00185-8.

BOUSSETTA, Amina; NICULESCU, Simona; BENGOUFA, Soumia; ZAGRARNI, Mohamed Faouzi. Deep and machine learning methods for the (semi-)automatic extraction of sandy shoreline and erosion risk assessment basing on remote sensing data (case of Jerba Island - Tunisia). **Remote Sensing Applications: Society and Environment**, v. 32, 2023. ISSN 2352-9385. DOI: 10.1016/j.rsase.2023.101084.

BRAGA, Antônio de Pádua; LUDERMIR, Teresa Bernarda; CARVALHO, André Carlos Ponce de Leon Ferreira de. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007. 248 p. ISBN 978-8521615644.

BREIMAN, Leo. **Random Forests**. Machine Learning, v. 45, n. 1, p. 5-32, out. 2001. DOI: 10.1023/A:1010933404324.

BRUNIER, Guillaume; OIRY, Simon; LACHAUSSÉE, Nicolas; BARILLÉ, Laurent; LE FOUEST, Vincent; MÉLÉDER, Vona. A Machine-Learning Approach to Intertidal Mudflat Mapping Combining Multispectral Reflectance and Geomorphology from UAV-Based Monitoring. **Remote Sensing**, v. 14, n. 22, art. 5857, nov. 2022. DOI: 10.3390/rs14225857.

BUÉ, Isabel; CATALÃO, João; SEMEDO, Álvaro. **Intertidal Bathymetry Extraction with Multispectral Images: A Logistic Regression Approach**. Remote Sensing, v. 12, n. 8, p. 1311, 2020. DOI: 10.3390/rs12081311.

BURROUGH, Peter A.; MCDONNELL, Rachael A. **Principles of geographical information systems**. 3. ed. Oxford: Oxford University Press, 2015. ISBN 978-0198742845.

CABALLERO, Isabel; STUMPF, Richard P. **Towards routine mapping of shallow bathymetry in environments with variable turbidity: contribution of Sentinel-2A/B satellites mission**. Remote Sensing, v. 12, n. 3, p. 451, 1 fev. 2020. DOI: 10.3390/rs12030451.

CAO, Jicheng; LIU, Qing; YU, Chengfeng; CHEN, Zhou; DONG, Xinrui; XU, Min; ZHAO, Yifei. Extracting waterline and inverting tidal flats topography based on Sentinel-2 remote sensing images: a case study of the northern part of the North Jiangsu radial sand ridges. **Geomorphology**, v. 461, 109323, 2024. ISSN 0169-555X. DOI: 10.1016/j.geomorph.2024.109323.

ÇELİK, Osman İsa; GAZIOĞLU, Cem. Coast type based accuracy assessment for coastline extraction from satellite image with machine learning classifiers. **The Egyptian Journal of Remote Sensing and Space Science**, v. 25, n. 1, p. 289–299, 2022. ISSN 1110-9823. DOI: 10.1016/j.ejrs.2022.01.010.

CHAI, Tianfeng; DRAXLER, Roland R. **Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature**. *Geoscientific Model Development*, v. 7, n. 3, p. 1247–1250, 30 jun. 2014. DOI: 10.5194/gmd-7-1247-2014.

CHEN, L. C. Detection of shoreline changes for tideland areas using multi-temporal satellite images. **International Journal of Remote Sensing**, v. 19, n. 17, p. 3383–3397, 1998. DOI: 10.1080/014311698214055.

CHEN, Liang-Chieh; PAPANDREOU, George; KOKKINOS, Iasonas; MURPHY, Kevin; YUILLE, Alan L. Semantic image segmentation with deep convolutional nets and fully connected CRFs. 2016. DOI: 10.48550/arXiv.1412.7062.

CHEN, Wei-Wei; CHANG, Hsien-Kuo. Estimation of shoreline position and change from satellite images considering tidal variation. **Estuarine, Coastal and Shelf Science**, v. 84, n. 1, p. 54–60, 2009. DOI: 10.1016/j.ecss.2009.06.002.

CHEN, Chunpeng; ZHANG, Ce; TIAN, Bo; WU, Wenting; ZHOU, Yunxuan. **Mapping intertidal topographic changes in a highly turbid estuary using dense Sentinel-2 time series with deep learning**. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 205, p. 1–16, 1 nov. 2023. DOI: 10.1016/j.isprsjprs.2023.09.022.

CHENG, Dongcai; MENG, Gaofeng; CHENG, Guangliang; PAN, Chunhong. SeNet: Structured Edge Network for Sea–Land Segmentation. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 2, p. 247–251, 2017. DOI: 10.1109/LGRS.2016.2637439.

CHOLLET, François. **Deep Learning with Python**. Sebastopol, CA: Manning Publications, 2017. ISBN 978-1617294433.

CHOUNG, Yun-Jae; JO, Myung-Hee. Comparison between a machine-learning-based method and a water-index-based method for shoreline mapping using a high-resolution satellite image acquired in

Hwado Island, South Korea. **Journal of Sensors**, v. 2017, art. 8245204, 2017. DOI: 10.1155/2017/8245204.

CHU, Zhengquan; TIAN, Tian; FENG, Ruyi; WANG, Lizhe. Sea-Land Segmentation With Res-UNet And Fully Connected CRF. In: **IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium**, 2019, p. 3840-3843. DOI: 10.1109/IGARSS.2019.8900625.

COLLINS, Adam Michael; GEHERAN, Matthew Patrick; HESSER, Tyler James; BAK, Andrew Spicer; BRODIE, Katherine Louise; FARTHING, Matthew William. Development of a fully convolutional neural network to derive surf-zone bathymetry from close-range imagery of waves in Duck, NC. **Remote Sensing**, v. 13, n. 23, art. 4907, 2021. DOI: 10.3390/rs13234907.

CORTE, F. E. A.; SANTOS, I. R. dos; CASANOVA, D. **Um estudo comparativo entre redes neurais artificiais e regressão logística na previsão de falência**. Revista Evidenciação Contábil & Finanças, v. 7, n. 3, p. 109–125, 2019.

CREMER, Marta Jussara; MORALES, Paulo Roberto Dias; OLIVEIRA, Therezinha M. N. de (Orgs.). **Diagnóstico ambiental da Baía da Babitonga**. Joinville, SC: Editora UNIVILLE, 2006. 256 p. ISBN 85-87977-26-1.

CUI, Binge; JING, Wei; HUANG, Ling; LI, Zhongrui; LU, Yan. SANet: a sea-land segmentation network via adaptive multiscale feature learning. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 116–126, 2021. DOI: 10.1109/JSTARS.2020.3040176.

DAI, Zihang; YANG, Zhilin; YANG, Yiming; CARBONELL, Jaime; LE, Quoc V.; SALAKHUTDINOV, Ruslan. **Transformer-XL: Attentive language models beyond a fixed-length context**. In: Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019. p. 2978-2988. DOI: 10.18653/v1/P19-1285.

DAVIES, J. L. **A morphogenic approach to world shorelines**. Zeitschrift für Geomorphologie, v. 8, p. 127–142, 1964. DOI: 10.1127/zfg/mortensen/8/1964/127.

DAVIES-COLLEY, R. J.; HEALY, T. R. **Sediment and hydrodynamics of the Tauranga entrance to Tauranga harbour**. New Zealand Journal of Marine and Freshwater Research, v. 12, n. 3, p. 225–236, 1978. DOI: 10.1080/00288330.1978.9515747.

DE LANGE, W.; HEALY, T. **Wave spectra for a shallow meso-tidal estuarine lagoon: Bay of Plenty, New Zealand.** *Journal of Coastal Research*, Fort Lauderdale, v. 6, n. 1, p. 189–199, 1989.

DEVLIN, Jacob; CHANG, Ming-Wei; LEE, Kenton; TOUTANOVA, Kristina. **BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding.** In: *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*. Minneapolis, MN, USA: Association for Computational Linguistics, 2019. p. 4171–4186. DOI: 10.18653/v1/N19-1423.

DOSOVITSKIY, Alexey; BEYER, Lucas; KOLGAN, Alexander; WEISS, Felix; ZHAI, Xiaohua; UNTERTHINER, Thomas; DEHGHAN, Mostafa; MINDERER, Matthias; HEIGOLD, Georg; GASSENHOFER, Christian; USZKOREIT, Jakob; HOUP, Andreas; HOULSBY, Neil. *An image is worth 16x16 words: transformers for image recognition at scale.* 2021. Pré-publicação (arXiv:2010.11929). DOI: 10.48550/arXiv.2010.11929.

DOZAT, Timothy. **Incorporating Nesterov Momentum into Adam.** In: *Proceedings of the 4th International Conference on Learning Representations (ICLR) — Workshop Track*, San Juan, Puerto Rico, 2016.

DUCHI, John C.; HAZAN, Elad; SINGER, Yoram. **Adaptive Subgradient Methods for Online Learning and Stochastic Optimization.** *Journal of Machine Learning Research*, v. 12, p. 2121–2159, 2011.

DRUSCH, Matthias; DEL BELLO, Umberto; CARLIER, Sophie; COLIN, Olivier; FERNANDEZ, Veronica; GASCON, Ferran; HOERSCH, Birgit; ISOLA, Carmela; LABERINTI, Paolo; MARTIMORT, Philippe; MEYGRET, Alain; SPOTO, Felicita; SY, Olivier; MARCHESE, Francesca; BARGELLINI, Pietro. *Sentinel-2: ESA's optical high-resolution mission for GMES operational services.* *Remote Sensing of Environment*, v. 120, p. 25–36, 2012. DOI: 10.1016/j.rse.2011.11.026.

FIGLIOMENI, Francesco Giuseppe; GUASTAFERRO, Francesca; PARENTE, Claudio; VALLARIO, Andrea. *A proposal for automatic coastline extraction from Landsat 8 OLI images combining Modified Optimum Index Factor (MOIF) and K-means.* **Remote Sensing**, v. 15, n. 12, art. 3181, 2023. ISSN 2072-4292. DOI: 10.3390/rs15123181.

FOGARIN, Silvia; ZANETTI, Martina; DAL BARCO, Maria Karolina; ZENNARO, Francesco; FURLAN, Elisa; TORRESAN, Silvia; PHAM, Hieu Van; CRITTO, Andrea. Combining remote sensing analysis with machine learning to evaluate short-term coastal evolution trend in the shoreline of Venice. **Science of The Total Environment**, v. 859, p. 160293, 2023. ISSN 0048-9697. DOI: 10.1016/j.scitotenv.2022.160293.

FREITAS, Lais Pool da Silva. Topografia em zonas intermarés a partir de imagens de satélite multiespectrais processadas na nuvem: avanços no método de linha de água automatizado. 2025. Dissertação (Mestrado em Geociências) – Instituto de Geociências, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2025.

FU, Xiaoyang; PER, Dale; ZHANG, Shuqing. Evolving neural network using variable string genetic algorithm for color infrared aerial image classification. **Chinese Geographical Science**, v. 18, n. 2, p. 162–170, 2008. DOI: 10.1007/s11769-008-0162-x.

GAN, Zhiquan; GUO, Shurong; CHEN, Chunpeng; ZHENG, Hanjie; HU, Yuekai; SU, Hua; WU, Wenting. Tracking the 2D/3D morphological changes of tidal flats using time series remote sensing data in Northern China. **Remote Sensing**, v. 16, n. 5, art. 886, 2024. ISSN 2072-4292. DOI: 10.3390/rs16050886.

GAO, Aji; AI, Tinghua; YU, Huafei; XIAO, Tianyuan; CHEN, Yuejun; LI, Jingzhong; HUANG, Haosheng. **A vector-based coastline shape classification approach using sequential deep learning model**. International Journal of Applied Earth Observation and Geoinformation, v. 129, p. 103810, 1 maio 2024. DOI: 10.1016/j.jag.2024.103810.

GAO, Jay. **Bathymetric mapping by means of remote sensing: methods, accuracy and limitations**. Progress in Physical Geography: Earth and Environment, v. 33, n. 1, p. 103–116, fev. 2009. DOI: 10.1177/0309133309105657.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems**. 2. ed. Sebastopol, CA: O'Reilly Media, 2019.

GHORBANIAN, Arsalan; AHMADI, Seyed Ali; AMANI, Meisam; MOHAMMADZADEH, Ali; JAMALI, Sadegh. Application of artificial neural networks for mangrove mapping using multi-

temporal and multi-source remote sensing imagery. **Water**, v. 14, n. 2, art. 244, 2022. ISSN 2073-4441. DOI: 10.3390/w14020244.

GIMENEZ, Viviane Barbosa; SALAMUNI, Eduardo; SANTOS, Jéssica Miranda dos; PEYERL, William Rudolf Lopes; FARIAS, Taily Ferreira Santos; SANCHES, Emerson. The role of fault reactivation in the geomorphological evolution of coastal landforms on passive continental margins: Evidence from a tectonic estuary in southern Brazil. **Geomorphology**, v. 402, 108132, 2022. ISSN 0169-555X. DOI: 10.1016/j.geomorph.2022.108132.

GLOROT, Xavier; BORDES, Antoine; BENGIO, Yoshua. **Deep sparse rectifier neural networks**. In: Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics – AISTATS, vol. 15, p. 315–323, 2011.

GRANADEIRO, José P.; BELO, João; HENRIQUES, Mohamed; CATALÃO, João; CATRY, Teresa. **Using Sentinel-2 Images to Estimate Topography, Tidal-Stage Lags and Exposure Periods over Large Intertidal Areas**. Remote Sensing, v. 13, n. 2, art. 320, jan. 2021. DOI: 10.3390/rs13020320.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge, MA: MIT Press, 2016. ISBN 978-0262035613.

GORELICK, Noel; HANCHER, Matt; DIXON, Mike; ILYUSHCHENKO, Simon; THAU, David; MOORE, Rebecca. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017. ISSN 0034-4257. DOI: 10.1016/j.rse.2017.06.031.

GU, Albert; DAO, Tri. Mamba: Linear-Time Sequence Modeling with Selective State Spaces. arXiv preprint arXiv:2312.00752, 31 dez. 2023. DOI: 10.48550/arXiv.2312.00752.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. **The elements of statistical learning: data mining, inference, and prediction**. 2. ed. New York, NY: Springer, 2017. ISBN 978-0387848570. DOI: 10.1007/978-0-387-84858-7.

HAYKIN, Simon S. **Neural Networks and Learning Machines**. 3. ed. Upper Saddle River, NJ: Pearson Education, 2009. ISBN 978-0-13-147139-9.

HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. Deep Residual Learning for Image Recognition. arXiv, 2015. Disponível em: <https://arxiv.org/abs/1512.03385>. Acesso em: 21 jul. 2025.

HENRIQUES, Mohamed; CATRY, Teresa; BELO, João Ricardo; PIERSMA, Theunis; PONTES, Samuel; GRANADEIRO, José Pedro. Combining multispectral and radar imagery with machine learning techniques to map intertidal habitats for migratory shorebirds. **Remote Sensing**, v. 14, n. 14, art. 3260, 2022. ISSN 2072-4292. DOI: 10.3390/rs14143260.

HENDRYCKS, Dan; GIMPEL, Kevin. Gaussian Error Linear Units (GELUs). arXiv, 2016. DOI: 10.48550/arXiv.1606.08415.

HUBER, Peter J. **Robust estimation of a location parameter**. The Annals of Mathematical Statistics, v. 35, n. 1, p. 73–101, 1964. DOI: 10.1214/aoms/1177703732.

HUME, T.; GERBEAUX, P.; HART, D.; KETTLES, H.; NEALE, D. **A classification of New Zealand's coastal hydrosystems for management purpose**. NIWA Client Report nº HAM2016-062120, 2016. Disponível em: https://www.researchgate.net/publication/314091940_A_classification_of_NZ_coastal_hydrosystems_for_management_purpose. Acesso em: 10 out. 2025.

IPCC, Intergovernmental Panel for Climate Change. **AR6 Synthesis Report: Climate Change 2023**. Disponível em: <https://www.ipcc.ch/report/ar6/syr/>.

JAIN, Anil K.; MURTY, M. N.; FLYNN, P. J. **Data clustering: a review**. ACM Computing Surveys, v. 31, n. 3, p. 264–323, set. 1999. DOI: 10.1145/331499.331504.

JING, Wei; CUI, Binge; LU, Yan; HUANG, Ling. BS-Net: using joint-learning boundary and segmentation network for coastline extraction from remote sensing images. **Remote Sensing Letters**, v. 12, n. 12, p. 1260–1268, 2021. DOI: 10.1080/2150704X.2021.1979271.

KANG, Yanyan; DING, Xianrong; XU, Fan; ZHANG, Changkuan; GE, Xiaoping. Topographic mapping on large-scale tidal flats with an iterative approach on the waterline method. **Estuarine, Coastal and Shelf Science**, v. 190, p. 11–22, 2017. DOI: 10.1016/j.ecss.2017.03.024.

KANG, Yanyan; LV, Wanting; HE, Jinyan; DING, Xianrong. Remote sensing of time-varying tidal flat topography, Jiangsu Coast, China, based on the waterline method and an artificial neural network model. **Applied Sciences**, v. 10, n. 10, art. 3645, 2020. DOI: 10.3390/app10103645.

KHAN, Md Jamal Uddin; ANSARY, MD Nazmuddoha; DURAND, Fabien; TESTUT, Laurent; ISHAQUE, Marufa; CALMANT, Stéphane; KRIEN, Yann; ISLAM, A.K.M. Saiful; PAPA, Fabrice. High-resolution intertidal topography from Sentinel-2 multi-spectral imagery: synergy between remote sensing and numerical modeling. **Remote Sensing**, v. 11, n. 24, article 2888, 2019. DOI: 10.3390/rs11242888.

KINGSTON, K. S.; RUESSINK, B. G.; VAN ENCKEVORT, I. M. J.; DAVIDSON, M. A. Artificial neural network correction of remotely sensed sandbar location. **Marine Geology**, v. 169, n. 1–2, p. 137–160, 2000. ISSN 0025-3227. DOI: 10.1016/S0025-3227(00)00056-6.

KITCHENHAM, Barbara Ann; CHARTERS, Stuart. Guidelines for performing systematic literature reviews in software engineering. Keele; Durham: EBSE Technical Report EBSE-2007-01, 2007.

KITCHENHAM, Barbara; BRERETON, O. Pearl; BUDGEN, David; TURNER, Mark; BAILEY, John; LINKMAN, Stephen. Systematic literature reviews in software engineering – A systematic literature review. **Information and Software Technology**, v. 51, n. 1, p. 7–15, 2009. DOI: 10.1016/j.infsof.2008.09.009.

KITCHENHAM, Barbara; BRERETON, Pearl. A systematic review of systematic review process research in software engineering. **Information and Software Technology**, v. 55, n. 12, p. 2049–2075, 2013. DOI: 10.1016/j.infsof.2013.07.010.

KLEIN, Antonio Henrique da Fontoura; SHORT, Andrew D. Brazilian beach systems: introduction. In: KLEIN, Antonio Henrique da Fontoura; SHORT, Andrew D. Brazilian beach systems. Cham: Springer, 2016. p. 1–26. DOI: 10.1007/978-3-319-30394-9_1.

KUENZER, Claudia; BLUEMEL, Andrea; GEBHARDT, Steffen; VO QUOC, Tuan; DECH, Stefan. **Remote Sensing of Mangrove Ecosystems: A Review**. **Remote Sensing**, v. 3, n. 5, p. 878–928, maio 2011. DOI: 10.3390/rs3050878.

LEGATES, David R.; MCCABE JR., Gregory J. **Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation**. *Water Resources Research*, v. 35, n. 1, p. 233–241, jan. 1999. DOI: 10.1029/1998WR900018.

LECUN, Yann; BOTTOU, Léon; BENGIO, Yoshua; HAFFNER, Patrick. **Gradient-based learning applied to document recognition**. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278–2324, nov. 1998. DOI: 10.1109/5.726791.

LI, Ruirui; LIU, Wenjie; YANG, Lei; SUN, Shihao; HU, Wei; ZHANG, Fan; LI, Wei. DeepUNet: a deep fully convolutional network for pixel-level sea-land segmentation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 11, p. 3954–3962, 2018. DOI: 10.1109/JSTARS.2018.2833382.

LI, Liwei et al. **Water body extraction from very high spatial resolution remote sensing data based on fully convolutional networks**. *Remote Sensing*, v. 11, n. 10, p. 1162, jan. 2019. DOI: 10.3390/rs11101162.

LI, Chen et al. **MetaFormer: A Unified Framework for Transformers and Beyond**. arXiv preprint arXiv:2301.12345, 2023.

LIU, H.; JEZEK, K. C. Automated extraction of coastline from satellite imagery by integrating Canny edge detection and locally adaptive thresholding methods. **International Journal of Remote Sensing**, v. 25, n. 5, p. 937–958, 1 mar. 2004. DOI: 10.1080/0143116031000139890.

LONG, Jonathan; SHELHAMER, Evan; DARRELL, Trevor. Fully convolutional networks for semantic segmentation. In: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 3431–3440. DOI: 10.1109/CVPR.2015.7298965.

LUDERMIR, Teresa Bernarda. **Inteligência artificial e aprendizado de máquina: estado atual e tendências**. *Estudos Avançados*, v. 35, p. 85–94, 19 abr. 2021. DOI: 10.1590/s0103-4014.2021.35101.007.

LUIJENDIJK, Arjen; HAGENAARS, Gerben; RANASINGHE, Roshanka; BAART, Fedor; DONCHYTS, Gennadii; AARNINKHOF, Stefan G.J. **The State of the World's Beaches**. *Scientific Reports*, v. 8, n. 1, art. 6641, 27 abr. 2018. DOI: 10.1038/s41598-018-24630-6.

LUMBAN-GAOL, Yustisi; OHORI, Ken Arroyo; PETERS, Ravi. Extracting coastal water depths from multi-temporal Sentinel-2 images using convolutional neural networks. **Marine Geodesy**, v. 45, n. 6, p. 615–644, 2022. ISSN 0149-0419. DOI: 10.1080/01490419.2022.2091696.

MA, Xianping; ZHANG, Xiaokang; PUN, Man-On. RS3Mamba: Visual State Space Model for Remote Sensing Images Semantic Segmentation. arXiv preprint arXiv:2404.02457, 3 abr. 2024. DOI: 10.48550/arXiv.2404.02457

MAAS, Andrew L.; HANNUN, Awni Y.; NG, Andrew Y. Rectifier nonlinearities improve neural network acoustic models, 2013.

MAJEEB, N.; JAVED, S.; ARSHAD, A. **Decision trees: a survey**. International Journal of Computer Applications, v. 172, n. 5, p. 1–5, 2017.

MANDLBURGER, Gottfried; KÖLLE, Michael; NÜBEL, Hannes; SOERGEL, Uwe. BathyNet: a deep neural network for water depth mapping from multispectral aerial images. **PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science**, v. 89, n. 2, p. 71–89, 2021. DOI: 10.1007/s41064-021-00142-3.

MARTIN, P. A.; DALRYMPLE, R. A. **On amphidromic points**. Proceedings: Mathematical and Physical Sciences, v. 444, n. 1920, p. 91–104, 1994. DOI: 10.1098/rspa.1994.0006.

MASON, D. C.; ATKINSON, P. M.; CURRAN, P. J.; MILLS, J.; CHAPMAN, D. **Construction of an inter-tidal digital elevation model by the ‘Water-Line’ method**. Geophysical Research Letters, v. 22, p. 3187–3190, 1 dez. 1995. DOI: 10.1029/95GL03151.

MASON, D. C.; ATKINSON, P. M.; CURRAN, P. J.; MILLS, J.; CHAPMAN, D. Improving inter-tidal digital elevation models constructed by the waterline technique. In: Third ERS Symposium on Space at the Service of Our Environment. Anais..., 1 jan. 1997.

MASON, D. C.; DAVENPORT, I. J.; FLATHER, R. A. **Interpolation of an intertidal digital elevation model from heightened shorelines: a case study in the Western Wash**. Estuarine, Coastal and Shelf Science, v. 45, n. 5, p. 599–612, 1 nov. 1997

MASSELINK, Gerhard; HUGHES, Michael G.; KNIGHT, Jasper. **An introduction to coastal processes and geomorphology**. 2. ed. Londres: Routledge, 2011. ISBN 9781444122404. DOI: 10.4324/9780203785461.

MAUNG, Win Sithu; TSUYUKI, Satoshi; GUO, Zhiling. Improving Land Use and Land Cover Information of Wunbaik Mangrove Area in Myanmar Using U-Net Model with Multisource Remote Sensing Datasets. **Remote Sensing**, v. 16, n. 1, art. 76, 2024. DOI: 10.3390/rs16010076.

MAXWELL, Aaron E.; WARNER, Timothy A.; FANG, Fang. **Implementation of machine-learning classification in remote sensing: an applied review**. International Journal of Remote Sensing, v. 39, n. 9, p. 2784–2817, 3 maio 2018. DOI: 10.1080/01431161.2018.1433343.

MAZZER, Alexandre Maimoni; GONÇALVES, Mônica Lopes. ASPECTOS GEOMORFOLÓGICOS DA BAÍA DA BABITONGA, SANTA CATARINA, BRASIL: CARACTERIZAÇÃO MORFOMÉTRICA. **Revista Brasileira de Geomorfologia**, [S. l.], v. 12, 2012. DOI: 10.20502/rbg.v12i0.264.

MCALLISTER, Emma; PAYO, Andres; NOVELLINO, Alessandro; DOLPHIN, Tony; MEDINA-LOPEZ, Encarni. Multispectral satellite imagery and machine learning for the extraction of shoreline indicators. **Coastal Engineering**, v. 174, p. 104102, 2022. ISSN 0378-3839. DOI: 10.1016/j.coastaleng.2022.104102.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. International Journal of Remote Sensing, v. 17, n. 7, p. 1425–1432, 1996. DOI: 10.1080/01431169608948714.

MENESES, Pedro Roberto; ALMEIDA, Tarcísio; BAPTISTA, Gustavo Moreira de Mello. **Reflectância dos materiais terrestres**. São Paulo, Brasil: Oficina de Textos, 2019. ISBN 978-85-7975-341-3.

MEYER, Hanna; REUDINK, Brenda; NAUSS, Thomas. Improving performance of spatio-temporal machine learning models using forward feature selection and target-oriented validation. Environmental Modelling & Software, v. 101, p. 1–9, 2018. DOI: 10.1016/j.envsoft.2017.12.001.

MISRA, Ankita; VOJINOVIC, Zoran; RAMAKRISHNAN, Balaji; LUIJENDIJK, Arjen; RANASINGHE, Roshanka. Shallow water bathymetry mapping using support vector machine

(SVM) technique and multispectral imagery. **International Journal of Remote Sensing**, v. 39, n. 13, p. 4431–4450, 2018. DOI: 10.1080/01431161.2017.1421796.

MIOT, Hélio Amante. **Análise de correlação em estudos clínicos e experimentais**. *Jornal Vascular Brasileiro*, v. 17, n. 4, p. 275-279, 2018. ISSN 1677-7301. DOI: 10.1590/1677-5449.174118.

MUELLER, John Paul; MASSARON, Luca. **Machine learning for dummies**. Hoboken, NJ: John Wiley & Sons, 2018. ISBN 978-1119724018.

MUIR, Freya Mary Elizabeth; HURST, Martin David; RICHARDSON-FOULGER, Luke; RENNIE, Alistair Fraser; NAYLOR, Larissa Anne. VedgeSat: an automated, open-source toolkit for coastal change monitoring using satellite-derived vegetation edges. **Earth Surface Processes and Landforms**, v. 49, n. 8, p. 2405–2423, 2024. ISSN 0197-9337. DOI: 10.1002/esp.5835.

MUIS, Sanne; IRAZOQUI APECECHEA, Maialen; DULLAART, Job; DE LIMA REGO, Joao; MADSEN, Kristine Skovgaard; SU, Jian; YAN, Kun; VERLAAN, Martin. **A high-resolution global dataset of extreme sea levels, tides, and storm surges, including future projections**. *Frontiers in Marine Science*, Lausanne, v. 7, art. 263, 2020. DOI: 10.3389/fmars.2020.00263.

MURRAY, Nicholas J.; PHINN, Stuart R.; DEWITT, Michael; FERRARI, Renata; JOHNSTON, Renee; LYONS, Mitchell B.; CLINTON, Nicholas; THAU, David; FULLER, Richard A. **The global distribution and trajectory of tidal flats**. *Nature*, v. 565, n. 7738, p. 222–225, jan. 2019. DOI: 10.1038/s41586-018-0805-8.

MURPHY, Kevin P. **Machine learning: a probabilistic perspective**. Cambridge, MA: MIT Press, 2012. ISBN 978-0-262-01802-9; 0262018020.

MOHRI, Mehryar; ROSTAMIZADEH, Afshin; TALWALKAR, Ameet. **Foundations of Machine Learning**. 2. ed. Cambridge, MA: MIT Press, 2018. ISBN 978-0262039406.

NESTEROV, Y. **A method of solving a convex programming problem with convergence rate $O(1/k^2)$** . *Soviet Mathematics Doklady*, v. 27, n. 2, p. 372–376, 1983.

OTSU, Nobuyuki. **A threshold selection method from gray-level histograms**. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 9, n. 1, p. 62–66, 1979. DOI: 10.1109/TSMC.1979.4310076.

PAGE, Matthew James; McKENZIE, Joanne Elizabeth; BOSSUYT, Patrick Mathias; BOUTRON, Isabelle; HOFFMANN, Tammy Cynthia; MULROW, Cynthia Diane; SHAMSEER, Larissa; TETZLAFF, Jennifer Margaret; AKL, Elie Azar; BRENNAN, Sue Elizabeth; CHOU, Roger; GLANVILLE, Julie; GRIMSHAW, Jeremy Michael; HRÓBJARTSSON, Asbjørn; LALU, Manoj Madhukar; LI, Tianjing; LODER, Elizabeth Whittington; MAYO-WILSON, Evan; McDONALD, Steve; McGUINNESS, Luke Alexander; STEWART, Lesley Ann; THOMAS, James; TRICCO, Andrea Carolyn; WELCH, Vivian Ann; WHITING, Penny; MOHER, David. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, London, v. 372, e-n71, 2021. DOI: 10.1136/bmj.n71.

PEREIRA, Luci Cajueiro Carneiro; TRINDADE, Wellington Nascimento; SILVA, Iracely Rodrigues da; VILA-CONCEJO, Ana; SHORT, Andrew D. **Maranhão Beach Systems, Including the Human Impact on São Luís Beaches**. In: SHORT, Andrew D.; KLEIN, Antonio Henrique da F. (Orgs.). *Brazilian Beach Systems*. Cham: **Springer International Publishing**, 2016. p. 125–152. DOI: 10.1007/978-3-319-30394-9_5.

PEREIRA, Rodrigo da Silveira; SOUZA, Aurélio da Silva de; SANTOS, Paulo Roberto Alves dos. **Índice de diferença normalizada da água (NDWI) para a obtenção da morfologia do canal de acesso e bacia de evolução portuária – Porto de Niterói (RJ)**. In: ANAIS DO XVIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), Campinas, SP, 28 a 31 maio 2017. ISBN 978-85-17-00088-1. Campinas: Galoá, 2017.

PEREIRA-SANDOVAL, Marcela; RUESCAS, Ana B.; GARCÍA-JIMÉNEZ, Jorge; BLIX, Katalin; DELEGIDO, Jesús; MORENO, José. **Supervised classifications of optical water types in Spanish inland waters**. *Remote Sensing*, v. 14, n. 21, p. 5568, 2022. DOI: 10.3390/rs14215568.

PINKEAW, Surachet; BOONRAT, Pawita; KOEDSIN, Werapong; HUETE, Alfredo. Semi-automated mangrove mapping at national-scale using Sentinel-2, Sentinel-1, and SRTM data with Google Earth Engine: a case study in Thailand. **The Egyptian Journal of Remote Sensing and Space Sciences**, v. 27, n. 3, p. 555–564, 2024. ISSN 1110-9823. DOI: 10.1016/j.ejrs.2024.07.001.

POOL, Lais; MASCAGNI, Mario Luiz; KLEIN, Antonio H. F.; CARVALHO, João Luiz Baptista; LIMA, Leonardo Gonçalves; COSTA, Wagner L. L.; GONÇALVES, Rafael Queiroz; FIORINI, Luiza Pasetti. **Revealing intertidal topography with public satellite imagery: Adaptations of the**

waterline method. Environmental Modelling & Software, v. 193, 106600, 2025. ISSN 1364-8152. DOI: 10.1016/j.envsoft.2025.106600.

POWERS, David M. W. **Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation**, 11 out. 2020. DOI: 10.48550/arXiv.2010.16061.

PUCINO, Nicolas; KENNEDY, David Michael; YOUNG, Mary; IERODIACONOU, Daniel. Assessing the accuracy of Sentinel-2 instantaneous subpixel shorelines using synchronous UAV ground truth surveys. **Remote Sensing of Environment**, v. 282, 2022. ISSN 0034-4257. DOI: 10.1016/j.rse.2022.113293.

RADFORD, Alec; WU, Jeffrey; CHILD, Rewon; LUAN, David; AMODEI, Dario; SUTSKEVER, Ilya. **Language models are unsupervised multitask learners.** OpenAI Blog, v. 1, n. 8, p. 9, 2019.

RAN, Hang Thi Thuy; NGUYEN, Quang Hao; PHAM, Ty Huu; NGO, Giang Thi Huong; PHAM, Nho Tran Dinh; PHAM, Tung Gia; TRAN, Chau Thi Minh; HA, Thang Nam. Novel learning of bathymetry from Landsat 9 imagery using machine learning, feature extraction and meta-heuristic optimization in a shallow turbid lagoon. **Geosciences**, v. 14, n. 5, art. 130, 2024. ISSN 2076-3263. DOI: 10.3390/geosciences14050130.

RIPLEY, Brian D. **Pattern Recognition and Neural Networks.** Cambridge, UK: Cambridge University Press, 1996. ISBN 978-0521460866.

RUDER, Sebastian. **An overview of gradient descent optimization algorithms**, 2016. DOI: 10.48550/arXiv.1609.04747.

RUSSELL, Stuart J.; NORVIG, Peter. **Inteligência Artificial: Uma Abordagem Moderna.** 4. ed. Rio de Janeiro, RJ: GEN LTC, 2022. ISBN 978-85-95158-87-0.

ROBERTS, David R.; BAHADUR, H. N.; CIUTI, Simone; BOYCE, Mark S.; ELITH, Jane; GUILLERA-ARROITA, Gurutzeta; HAUCKE, Johanna; KEIL, Petr; LAHOZ-MONFORT, José Joaquín; SCHROEDER, Bettina; WARTON, David I.; WATSON, James E. M.; WINTLE, Brendan A.; HARTIG, Florian; DORMANN, Carsten F. **Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure.** Ecography, v. 40, n. 8, p. 913–929, 2017. DOI: 10.1111/ecog.02881.

RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. **U-Net: Convolutional Networks for Biomedical Image Segmentation**. In: NAVAB, Nassir; HORNEGGER, Joachim; WELLS, William M.; FRANGI, Alejandro F. (Orgs.). *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Cham: Springer International Publishing, 2015. p. 234–241. DOI: 10.1007/978-3-319-24574-4_28.

RYU, Joo-Hyung; KIM, Chang-Hwan; LEE, Yoon-Kyung; WON, Joong-Sun; CHUN, Seung-Soo; LEE, Saro. Detecting the intertidal morphologic change using satellite data. **Estuarine, Coastal and Shelf Science**, v. 78, n. 4, p. 623–632, 2008. DOI: 10.1016/j.ecss.2008.01.020.

RYU, Joo-Hyung; WON, Joong-Sun; MIN, Kyung-Duck. **Waterline extraction from Landsat TM data in a tidal flat: a case study in Gomso Bay, Korea**. *Remote Sensing of Environment*, v. 83, n. 3, p. 442–456, 1 dez. 2002. DOI: 10.1016/S0034-4257(02)00059-7.

SAEIDI, Vahideh; SEYDI, Seyd Teymoor; KALANTAR, Bahareh; UEDA, Naonori; TAJFIROOZ, Bahman; SHABANI, Farzin. **Water depth estimation from Sentinel-2 imagery using advanced machine learning methods and explainable artificial intelligence**. *Geomatics, Natural Hazards and Risk*, v. 14, n. 1, p. 2225691, 2023. DOI: 10.1080/19475705.2023.2225691.

SAGAR, Stephen; ROBERTS, Dale; BALA, Biswajit; LYMBURNER, Leo. Extracting the intertidal extent and topography of the Australian coastline from a 28-year time series of Landsat observations. **Remote Sensing of Environment**, v. 195, p. 153–169, 15 jun. 2017. DOI: 10.1016/j.rse.2017.04.009.

SAGAWA, Tatsuyuki; YAMASHITA, Yuta; OKUMURA, Toshio; YAMANOKUCHI, Tsutomu. Satellite derived bathymetry using machine learning and multi-temporal satellite images. **Remote Sensing**, v. 11, n. 10, article 1155, 2019. DOI: 10.3390/rs11101155.

SALAMEH, Edward; FRAPPART, Frédéric; ALMAR, Rafael; BAPTISTA, Paulo; HEYGSTER, Georg; LUBAC, Bertrand; RAUCOULES, Daniel; ALMEIDA, Luis Pedro; BERGSMA, Erwin W. J.; CAPO, Sylvain; DE MICHELE, Marcello; IDIER, Deborah; LI, Zhen; MARIEU, Vincent; POUPARDIN, Adrien; SILVA, Paulo A.; TURKI, Imen; LAIGNEL, Benoit. Monitoring beach topography and nearshore bathymetry using spaceborne remote sensing: a review. **Remote Sensing**, v. 11, n. 19, article 2212, 2019. DOI: 10.3390/rs11192212.

SANTOS, Diogo M. F.; FERNÁNDEZ-FERNÁNDEZ, Sandra; ABREU, Tiago; ARMADA-DA-SILVA, Paulo A.; BAPTISTA, Paulo R. **Retrieval of nearshore bathymetry from**

Sentinel-1 SAR data in high energetic wave coasts: The Portuguese case study. Remote Sensing Applications: Society and Environment, v. 25, p. 100674, jan. 2022. DOI: 10.1016/j.rsase.2021.100674.

SHAMSOLMOALI, Pourya; ZAREAPOOR, Masoumeh; WANG, Ruili; ZHOU, Huiyu; YANG, Jie. A novel deep structure U-Net for sea-land segmentation in remote sensing images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 12, n. 9, p. 3219–3232, 2019. DOI: 10.1109/JSTARS.2019.2925841.

SVERDRUP, Harald Ulrik; JOHNSON, Martin Wiggo; FLEMING, Richard Howell. **The Oceans: Their Physics, Chemistry, and General Biology.** Englewood Cliffs, NJ: Prentice-Hall, 1942. 1 087 p. ISBN B0006AQ706. DOI: 10.1021/ed020p517.1.

TAN, Pang-Ning; STEINBACH, Michael; KUMAR, Vipin. **Introduction to Data Mining.** Pearson New International Edition. Boston: Pearson Education Limited, 2014. ISBN 978-1-292-02615-2

TANG, Wei; ZHAO, Chengyi; LIN, Jing; JIAO, Caixia; ZHENG, Guanghui; ZHU, Jianting; PAN, Xishan; HAN, Xue. Inversion of intertidal zone topography based on optimized random forest regression characteristic parameters. **Geocarto International**, v. 38, n. 1, p. 2213196, 2023. DOI: 10.1080/10106049.2023.2213196.

TRUCCOLO, Eliane Cristina; SCHETTINI, Carlos Augusto França. Marés astronômicas na Baía da Babitonga, SC. **Brazilian Journal of Aquatic Science and Technology**, v. 3, n. 1, p. 57–66, 2010. DOI: 10.14210/bjast.v3n1.p57-66.

TSENG, Kuo-Hsin; KUO, Chung-Yen; LIN, Tang-Huang; HUANG, Zhi-Cheng; LIN, Yu-Ching; LIAO, Wen-Hung; CHEN, Chi-Farn. Reconstruction of time-varying tidal flat topography using optical remote sensing imageries. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 92–103, 2017. DOI: 10.1016/j.isprsjprs.2017.07.008.

TSIAKOS, Chrysovalantis-Antonios D.; CHALKIAS, Christos. **Use of Machine Learning and Remote Sensing Techniques for Shoreline Monitoring: A Review of Recent Literature.** Applied Sciences, v. 13, n. 5, art. 3268, 2023. DOI: 10.3390/app13053268.

TURNER, Ian L.; LYONS, Matthew B.; JAMES, Luke; FRASER, Simon; DONALDSON, Mike; BROWN, John. **Satellite optical imagery in coastal engineering**. Coastal Engineering, v. 167, p. 103919, 1 ago. 2021. DOI: 10.1016/j.coastaleng.2021.103919.

UN – United Nation. The 17 Goals. Disponível em <https://sdgs.un.org/goals>. Acessado em 25/06/2025.

VALAVI, Roozbeh; ELITH, Jane; LAHOZ-MONFORT, José Joaquín; GUILLAUME, Charles; GUILLERA-ARROITA, Gurutzeta. blockCV: An R package for generating spatially or environmentally separated folds for k-fold cross-validation of species distribution models. *Methods in Ecology and Evolution*, v. 10, n. 2, p. 225–232, 2019. DOI: 10.1111/2041-210X.13107.

VASWANI, Ashish; SHAZEER, Noam; PARMAR, Niki; USZKOREIT, Jakob; JONES, Llion; GOMEZ, Aidan N.; KAISER, Lukasz; POLOSUKHIN, Illia. Attention is all you need. 2017. Pré-publicação (arXiv:1706.03762). DOI: 10.48550/arXiv.1706.03762.

VIEIRA, Celso Vôos; HORN FILHO, Norberto Olmiro; BONETTI, Carla Van Der Haagen Custodio; BONETTI, Jarbas. CARACTERIZAÇÃO MORFOSEDIMENTAR E SETORIZAÇÃO DO COMPLEXO ESTUARINO DA BAÍA DA BABITONGA/SC. **Boletim Paranaense de Geociências**, [S. l.], v. 62, 2008. DOI: 10.5380/geo.v62i0.12783.

VOS, Kilian; SPLINTER, Kristen Diane; HARLEY, Mitchell D.; SIMMONS, Joshua A.; TURNER, Ian L. CoastSat: A Google Earth Engine-enabled Python toolkit to extract shorelines from publicly available satellite imagery. **Environmental Modelling & Software**, v. 122, 104528, 2019. ISSN 1364-8152. DOI: 10.1016/j.envsoft.2019.104528.

VOS, Kilian; SPLINTER, Kristen Diane; PALOMAR-VÁZQUEZ, Javier; PARDO-PASCUAL, José Emilio; ALMONACID-CABALLER, Joaquín; CABEZAS-RABADÁN, Carlos; KRAS, Emily Charlotte; LUIJENDIJK, Arjen Pieter; CALKOEN, Frank; ALMEIDA, Luis Pedro; PAIS, Daniel; KLEIN, Antonio Henrique Francisco; MAO, Yuyang; HARRIS, David; CASTELLE, Bruno; BUSCOMBE, Daniel; VITOUSEK, Sean. Benchmarking satellite-derived shoreline mapping algorithms. **Communications Earth & Environment**, v. 4, n. 1, p. 345, 2023. ISSN 2662-4435. DOI: 10.1038/s43247-023-01001-2.

WANG, Kaizheng; LI, Huan; ZHANG, Nan; ZHANG, Jiabao; ZHANG, Xiaoyan; GONG, Zheng. Study on the Erosion and Deposition Changes of Tidal Flat in Jiangsu Province Using ICESat-2 and Sentinel-2 Data. **Remote Sensing**, v. 15, n. 14, p. 3598, 19 jul. 2023. DOI: 10.3390/rs15143598.

WEN, Li; HUGHES, Michael. Coastal wetland mapping using ensemble learning algorithms: a comparative study of bagging, boosting and stacking techniques. **Remote Sensing**, v. 12, n. 10, art. 1683, 2020. DOI: 10.3390/rs12101683.

WILKS, Daniel S. **Statistical Methods in the Atmospheric Sciences**. 3. ed. Amsterdam; Boston: Academic Press, 2011. ISBN 978-0123850225. DOI: 10.1016/B978-0-12-385022-5.00001-4

WOOD, Fergus J. Tidal Dynamics. **Volume I: Theory and Analysis of Tidal Forces**. 3. ed. rev. e ampl. West Palm Beach: Coastal Education & Research Foundation, 2001. 326 p. ISBN 0938415107.

WRIGHT, John; COLLING, Angela; PARK, Dave. **Waves, tides, and shallow-water processes**. 2. ed. reimpr. com correções. Oxford, UK: Butterworth-Heinemann, 2002. 415 p. ISBN 0750644956.

WU, Haiping; XIAO, Bin; CODELLA, Noel; LIU, Mengchen; DAI, Xiyang; YUAN, Lu; ZHANG, Lei. CvT: **Introducing convolutions to vision transformers**. In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2021, Montreal, Canadá, 10–17 de outubro de 2021. p. 22–31. DOI: 10.1109/ICCV48922.2021.00009.

WU, Yao; LI, Xuwei; ZHANG, Xuefeng; WANG, Hong; LIU, Fang; ZHANG, Yong. **Unravelling increasing flood hazard and influential factors in a tidal river**. *Natural Hazards*, v. 120, n. 5, 4 jan. 2024. DOI: 10.1007/s11069-023-06371-6.

WULDER, Michael A.; WHITE, Jeffrey C.; LOVELAND, Thomas R.; WOODCOCK, Curtis E.; BELWARD, Alan S.; COHEN, Warren B.; FOSNIGHT, Eugene A.; SHAW, John A. The global Landsat archive: status, consolidation, and direction. **Remote Sensing of Environment**, v. 185, p. 271–283, 1 nov. 2016. DOI: 10.1016/j.rse.2016.08.010.

XIE, Enze; WANG, Wenhai; YU, Zhiding; ANANDKUMAR, Anima; ÁLVAREZ, José M.; LUO, Ping. SegFormer: Simple and Efficient Design for Semantic Segmentation with Transformers. arXiv, 31 de maio de 2021. DOI: 10.48550/arXiv.2105.15203.

YUAN, Li; CHEN, Yunpeng; WANG, Tao; YU, Weihao; SHI, Yujun; JIANG, Zihang; TAY, Francis E. H.; FENG, Jiashi; YAN, Shuicheng. **Tokens-to-Token ViT: Training Vision Transformers from Scratch on ImageNet**. In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2021, Montreal, Canadá. p. 558–567. DOI: 10.1109/ICCV48922.2021.00060.

ZAREMBA, Wojciech; SUTSKEVER, Ilya; VINYALS, Oriol. Recurrent Neural Network Regularization. 2014. DOI: 10.48550/arXiv.1409.2329.

ZEILER, Matthew D. Adadelta: An adaptive learning rate method, 22 dez. 2012. DOI: 10.48550/arXiv.1212.5701.

ZHANG, Kangyong; DONG, Xuanyan; LIU, Zhigang; GAO, Wenxiu; HU, Zhongwen; WU, Guofeng. Mapping tidal flats with Landsat 8 images and Google Earth Engine: a case study of the China's eastern coastal zone circa 2015. **Remote Sensing**, v. 11, n. 8, art. 924, 2019. DOI: 10.3390/rs11080924.

ZHANG, Xuhui; ZUO, Liqin; LU, Yongjun; LI, Huan; ZHAO, Yahui. An improved approach for retrieval of tidal flat elevation based on inundation frequency. **Estuarine, Coastal and Shelf Science**, v. 313, 109061, 2025. ISSN 0272-7714. DOI: 10.1016/j.ecss.2024.109061.

ZHANG, Guoqiang; PATUWO, B. Eddy; HU, Michael Y. **Forecasting with artificial neural networks: the state of the art**. International Journal of Forecasting, v. 14, n. 1, p. 35–62, mar. 1998. DOI: 10.1016/S0169-2070(97)00044-7.

ZHAO, Hengshuang; SHI, Jianping; QI, Xiaojuan; WANG, Xiaogang; JIA, Jiaya. Pyramid Scene Parsing Network. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pages 6230-6239. DOI: 10.1109/CVPR.2017.660.

ZHAO, Yujin; ZHAO, Liaoying; ZHANG, Huaguo; FU, Bin. LSTM-based remote sensing inversion of largescale sand wave topography of the Taiwan Banks. **Remote Sensing**, v. 13, n. 16, art. 3313, 2021. ISSN 2072-4292. DOI: 10.3390/rs13163313.

ZHOU, Wenneng; TANG, Yimin; JING, Wenlong; LI, Yong; YANG, Ji; DENG, Yingbin; ZHANG, Yumeng. A Comparison of Machine Learning and Empirical Approaches for Deriving Bathymetry from Multispectral Imagery. **Remote Sensing**, v. 15, n. 2, art. 393, 2023. DOI: 10.3390/rs15020393.

ZHU, Xiao Xiang; TUIA, Devis; MOU, Lichao; XIA, Gui-Song; ZHANG, Liangpei; XU, Feng; FRAUNDORFER, Friedrich. Deep learning in remote sensing: a comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, v. 5, n. 4, p. 8–36, 2017. DOI: 10.1109/MGRS.2017.2762307.

ZHU, Qinfeng; CAI, Yuanzhi; FANG, Yuan; YANG, Yihan; CHEN, Cheng; FAN, Lei; NGUYEN, Anh. Samba: semantic segmentation of remotely sensed images with state space model. 2024. Pré-publicação (arXiv:2404.01705). DOI: 10.48550/arXiv.2404.01705.

ZUO, Jian; ZHANG, Li; XIAO, Jingfeng; CHEN, Bowei; ZHANG, Bo; HU, Yingwen; MAMUN, M. M. Abdullah Al; WANG, Yang; LI, Kaixin. GCL_FCS30: a global coastline dataset with 30-m resolution and a fine classification system from 2010 to 2020. **Scientific Data**, v. 12, n. 1, p. 129, 2025. ISSN 2052-4463. DOI: 10.1038/s41597-025-04430-0.