



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS
DEPARTAMENTO DE GEOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOLOGIA

WILLAMYS RANGEL NUNES DE SOUSA

**CRIAÇÃO E AVALIAÇÃO DE MODELOS DE PROGNÓSTICO FUTURO DE
LINHAS DE COSTA, UTILIZANDO REGRESSÃO ESTATÍSTICA E REDES
NEURAS ARTIFICIAIS, A PARTIR DAS SÉRIES TEMPORAIS DE IMAGENS DE
SATÉLITE**

FORTALEZA

2022

WILLAMYS RANGEL NUNES DE SOUSA

CRIAÇÃO E AVALIAÇÃO DE MODELOS DE PROGNÓSTICO FUTURO DE LINHAS
DE COSTA, UTILIZANDO REGRESSÃO ESTATÍSTICA E REDES NEURAI
ARTIFICIAIS, A PARTIR DAS SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITE

Tese apresentada ao Programa de Pós-Graduação em Geologia da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Doutor em Geologia. Área de concentração: Geologia Ambiental e Recursos Hídricos.

Orientador: Prof. Dr. Michael Vandesteem Silva Souto.

Coorientadora: Prof^ª. Dra. Ana Rita Gonçalves Neves Lopes Salgueiro.

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- S698c Sousa, Willamys Rangel Nunes de.
Criação e Avaliação de Modelos de Prognóstico Futuro de Linhas de Costa, utilizando Regressão Estatística e Redes Neurais Artificiais, a partir das Séries Temporais de Imagens de Satélite / Willamys Rangel Nunes de Sousa. – 2022.
98 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Geologia, Fortaleza, 2022.
Orientação: Prof. Dr. Michael Vandesteem Silva Souto.
Coorientação: Prof. Dr. Ana Rita Gonçalves Neves Lopes Salgueiro.
1. Geoprocessamento. 2. Sensoriamento Remoto. 3. Erosao costeira. 4. Regressao Linear. 5. Redes Neurais Artificiais. I. Título.

WILLAMYS RANGEL NUNES DE SOUSA

CRIAÇÃO E AVALIAÇÃO DE MODELOS DE PROGNÓSTICO FUTURO DE LINHAS
DE COSTA, UTILIZANDO REGRESSÃO ESTATÍSTICA E REDES NEURAIIS
ARTIFICIAIS, A PARTIR DAS SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITE

Tese apresentada ao Programa de Pós-Graduação em Geologia da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Doutor em Geologia. Área de concentração: Geologia Ambiental e Recursos Hídricos.

Orientador: Prof. Dr. Michael Vandesteen Silva Souto.

Coorientadora: Prof.^a. Dra. Ana Rita Gonçalves Neves Lopes Salgueiro.

Aprovada em: 26/08/2022.

BANCA EXAMINADORA

Prof. Dr. Michael Vandesteen Silva Souto (Orientador)
Universidade Federal do Rio Grande do Norte

Prof. Dr. Antônio Conceição Paranhos Filho
Universidade Federal do Mato Grosso do Sul

Profa. Dra. Angélica Félix de Castro
Universidade Federal Rural do Semi-Árido

Profa. Dra. Cynthia Romariz Duarte
Universidade Federal do Ceará

Prof. Dr. Marcelino Pereira dos Santos Silva
Universidade do Estado do Rio Grande do Norte

*Aos meus pais: Leci Nunes de Sousa e
Francisco de Sousa Santos (in memoriam), aos
meus filhos: Maria Eduarda e João Lucas, à
minha princesa Amanda e os meus irmãos:
Mychelle e Rafael.*

AGRADECIMENTOS

Foram tantos anos de trabalho, de dedicação, de perdas e de estudo, acompanhadas do convívio com inúmeras pessoas, as quais compartilharam os muitos momentos da elaboração deste trabalho. Assim, gostaria de agradecer:

A Deus, por toda força que tem me dado, no decorrer de todo este período e por sempre me fazer acreditar que tudo é possível e por me dar forças e não me deixar desistir.

Aos meus pais Leci Nunes de Sousa e Francisco de Sousa Santos (*in memoriam*), por me ensinarem as coisas mais importantes da minha vida e por serem sempre importantes nas minhas escolhas.

Aos meus irmãos Mychelle e Rafael, por acreditarem em mim e por fazerem parte da minha vida.

À Amanda, minha companheira de todas as horas, por estar sempre do meu lado, me dando forças, acreditando e sendo o meu alicerce durante todos esses anos.

Ao meu orientador (ou melhor, amigo) Michael Vandesteen Silva Souto por acreditarem em meu potencial, por me motivar, por lutar junto comigo durante toda a pesquisa e, principalmente, por nunca desistir de mim.

À minha coorientadora Ana Rita Gonçalves Neves Lopes Salgueiro por todo o cuidado, atenção, ensinamentos e cuidado que sempre teve comigo.

À minha eterna orientadora e amiga, Angélica Félix de Castro, por sempre acreditar em mim e por não deixar eu nunca desistir de chegar até aqui.

À querida professora Cynthia por ser tão carinhosa comigo e pode ser me ajudar em tudo que estava ao seu alcance.

Aos meus amigos Cláudio e Maykon pela imensa contribuição à pesquisa e pela amizade em todos estes anos. Vocês, literalmente, fazem parte deste trabalho.

A todos os meus colegas de GEOCE que sempre me receberam tão bem, como a Débora, o Eduardo, a Aline, o Mateus, o Cassiano, a Camila, a Stéfane e tantos outros.

Ao meu grande amigo Mailson que, mesmo à distância, sempre me apoiou e me incentivou a seguir em frente com minha pesquisa.

À UFC pela oportunidade de aperfeiçoamento acadêmico e infraestrutura fornecida para o desenvolvimento da pesquisa.

Por fim, a tantos outros que não citei aqui, mas sempre acreditaram em mim.

“Sou do tamanho daquilo que vejo e não do tamanho da minha altura” (Carlos Drummond de Andrade).

RESUMO

A erosão costeira é o processo de remoção de material na linha de costa que resulta na perda da terra à medida que ela recua em direção ao território. Este processo causa perda de propriedades, infraestrutura, biodiversidade, além de gerar, anualmente, grandes impactos econômicos. Ele tem se tornado um problema global e, portanto, a análise e o monitoramento de tais impactos é uma questão que merece atenção adequada. Para esta finalidade, os dados de Sensoriamento Remoto têm sido amplamente utilizados em vários estudos que avaliam a mudança espacial e temporal do uso e cobertura da terra. Ademais, o uso de séries temporais de imagens de satélite aplicadas na investigação da mudança na cobertura da terra e seu padrão espaço-temporal, tem sido comprovado como uma abordagem extremamente eficiente para estudos sobre monitoramentos costeiros. Nesse contexto, o objetivo principal desse trabalho foi criar e avaliar modelos de prognóstico para geração de cenários futuros, a partir da análise das mudanças espaço-temporal das linhas de costa extraídas a partir de imagens orbitais de forma automatizada, do período de 1985 a 2018. Para atingir esse objetivo, foram propostos dois modelos, sendo o primeiro utilizando técnicas de regressão linear e o segundo aplicando redes neurais artificiais para a criação de um modelo de prognóstico de cenários futuros, implementados na linguagem Python, com a utilização das bibliotecas *Numpy*, *OpenCV*, *Sklearn* e *Keras*. Além destas, foram utilizadas técnicas de Processamento Digital de Imagem e a extração do *Modified Normalized Difference Water Index* (MNDWI) em imagens de Sensoriamento Remoto. Como resultado, foi implementado um algoritmo para extração automática de linhas de costa, a partir de imagens MNDWI. Além disso, gerou-se um modelo de prognóstico de erosão costeira para o ano de 2021, baseado na série temporal dos anos de 1985 a 2015. Por fim, foi proposta uma arquitetura híbrida de redes neurais artificiais, composta de uma camada de rede neural convolucional e outra camada *Long Short-Term Memory*, para estimar cenários futuros de setores da linha de costa, no município de Icapuí-CE. Para isto, foi utilizada uma série temporal do período de 1988 a 2018 e foram gerados MNDWI para os anos de 2003, 2008, 2013 e 2018, além da geração do prognóstico para o ano de 2023. Ademais, foi realizada a comparação entre as linhas de costa geradas automaticamente e as linhas extraídas por um fotointérprete, utilizando o Sistema de Informações Geográficas.

Palavras-chave: geoprocessamento; sensoriamento remoto; erosão costeira; regressão linear; aprendizado de máquina; prognóstico; linhas de costa; redes neurais artificiais; redes neurais convolucionais; redes neurais recorrentes. *Istm*.

ABSTRACT

Coastal erosion is the process of material removal from the shoreline that results in the loss of land as it recedes towards the territory. This process causes loss of properties, infrastructure, biodiversity, in addition to generating, annually, great economic impacts. It has become a global problem and therefore the analysis and monitoring of such impacts is an issue that deserves adequate attention. For this purpose, Remote Sensing data have been widely used in various studies that assess spatial and temporal change in land use and land cover. Furthermore, the use of time series of satellite images applied to the investigation of land cover change and its spatio-temporal pattern has been proven to be an extremely efficient approach for studies on coastal monitoring. In this context, the main objective of this work was to create and evaluate prognostic models to generate future scenarios, based on the analysis of spatio-temporal changes of coastlines extracted from orbital images in an automated way, from 1985 to 2018. To achieve this goal, two models were proposed, the first using linear regression techniques and the second applying artificial neural networks to create a predictive model of future scenarios, implemented in Python language, using the Numpy, OpenCV, Sklearn and Keras libraries. In addition to these, Digital Image Processing techniques and the extraction of the Modified Normalized Difference Water Index (MNDWI) were used in Remote Sensing images. As a result, an algorithm for automatic extraction of shorelines from MNDWI images was implemented. In addition, a coastal erosion prognosis model was generated for the year 2021, based on the time series from 1985 to 2015. Finally, a hybrid architecture of artificial neural networks was proposed, composed of a convolutional neural network layer and another Long Short-Term Memory layer, to estimate future scenarios of sectors of the coastline, in the city of Icapuí-CE. For this, a time series from 1988 to 2018 was used and MNDWIs were generated for the years 2003, 2008, 2013 and 2018, in addition to the generation of the prognosis for the year 2023. In addition, a comparison was made between the lines automatically generated coastlines and the lines extracted by a photo interpreter, using the Geographic Information System.

Keywords: geoprocessing; remote sensing; coastal erosion; linear regression; machine learning; prognostic; shoreline; artificial neural networks; convolutional neural networks; recurrent neural networks; lstm.

LISTA DE ILUSTRAÇÕES

Figura 1 - Imagens de diferentes sensores e resoluções espaciais	22
Figura 2 - Diferença de resolução radiométrica em área urbana.....	23
Figura 3 - Mudanças nas linhas de costa nos anos de 1984, 2011 e 2013	24
Figura 4 – Processo de classificação aplicado nas imagens: (a) Árvore de decisão usada para classificar as imagens, (b) Exemplo da aplicação com NDWI e (c) Exemplo com a média VIS + NIR	25
Figura 5 - Mapas de detecção de mudanças for áreas de deposição de sedimentos e erosão, na baía	25
Figura 6 - Imagens NDWI classificadas de: (a) 1985, (b) 1995, (c) 2005 e (d) 2015 na baía de Tampa	27
Figura 7 - Imagens NDWI classificadas de: (a) 1985, (b) 1995, (c) 2005 e (d) 2014 no porto de Xiangshan	28
Figura 8 – Mudanças na linha de costa: (a) Baía de Tampa de 1985 a 2015 e (b) porto de Xiangshan de 1985 a 2014.....	29
Figura 9 – Predição e validação do modelo de predição de posições de linha de costa em 28 de julho de 2015.....	31
Figura 10 - Arquitetura do Perceptron	34
Figura 11 - Representação de uma Rede Neural feedforward de múltiplas camadas	34
Figura 12 - Arquitetura de uma CNN.....	36
Figura 13 – Exemplo do processo de convolução.....	37
Figura 14 - Representação da camada de <i>max pooling</i> com <i>kernel 2 x 2</i>	38
Figura 15 - Representação do processo de Dropout.....	39
Figura 16 - Arquitetura CNN com camadas totalmente conectadas	40
Figura 17 - Neurônio recorrente desenrolado através do tempo	41
Figura 18 - Camada de neurônios recorrentes desenrolados através do tempo	42
Figura 19 - Arquitetura de uma RNN.....	42
Figura 20 - Célula de memória LSTM	43
Figura 21 - Localização da área de estudo	48
Figura 22 - Geração de prognóstico com regressão linear	50
Figura 23 - Arquitetura híbrida CRNN	50
Figura 24 – Geração das imagens MNDWI para os anos de 1985 e 2015: (a) Banda 2 (<i>green</i>) do ano de 1985, (b) Banda 5 (<i>Swir 1</i>) do ano de 1985, (c) MNDWI do ano de 1985	

gerado a partir da aplicação da Equação 6, (d) Banda 3 (<i>green</i>) do ano de 2015, (e) Banda 6 (<i>Swir 1</i>) do ano de 2015 e (f) MNDWI do ano de 2015 gerado a partir da Equação 6.....	52
Figura 25 – Geração das imagens MNDWI para os anos de 1997, 2003, 2009 e 2015 pelo método de regressão linear: (a) Extrapolação do MNDWI para o ano 1997, (b) Extrapolação do MNDWI para o ano de 2003, (c) Extrapolação do MNDWI para o ano de 2009 e (d) Extrapolação do MNDWI para o ano de 2015	53
Figura 26 – Geração do MNDWI do ano de 2021 a partir dos anos de 2009 e 2015, através do modelo de Regressão Linear: (a) MNDWI do ano de 2009, (b) MNDWI do ano de 2015 e (c) MNDWI gerado para o ano de 2021.....	54
Figura 27 – Técnicas de Processamento Digital de Imagens aplicadas no MNDWI de 2021: (a) MNDWI gerado para o ano de 2021, (b) MNDWI de 2021 após a aplicação do filtro Gaussiano, (c) MNDWI de 2021 após a etapa de binarização, (d) MNDWI de 2021 depois da aplicação da técnica de preenchimento (<i>flood fill</i>)	55
Figura 28 – Linha de Costa do ano de 2021: (a) Linha de costa do ano de 2021, após a aplicação do algoritmo de detecção de bordas e (b) Linha de costa do ano 2021 em formato <i>shapefile</i>	56
Figura 29 - Localização dos quatro setores utilizados no estudo	57
Figura 30 - Divisão da sequência de imagens em entradas e saída.....	58
Figura 31 - Porção CNN do modelo proposto	59
Figura 32 - Porção LSTM da arquitetura proposta	61
Figura 33 - Resultado da geração e extração de linha de costa para o ano de 2021: (a) MNDWI gerado para 2021, (b) MNDWI de 2021 após a aplicação do filtro Gaussiano, (c) MNDWI de 2021 após a binarização, (d) MNDWI de 2021 após a técnica de <i>Flood Fill</i> , (e) Linha de costa de 2021 em formato TIFF e (f) Linha de costa em formato vetorial	64
Figura 34 - Linhas de costa dos anos de 1991, 1997, 2003, 2009, 2015 e 2021, sobrepondo a cena do ano de 1985, com ênfase nas regiões com maiores mudanças	65
Figura 35 - Linhas de costa dos anos de 1985, 2015 e 2021, com ênfase nas regiões com maiores mudanças.....	66
Figura 36 - Extrapolação da cena de 2003 utilizando a arquitetura CNN-LSTM, com duas e três sequências de imagens	67
Figura 37 - Avaliação dos erros de treinamento, com o setor da linha de costa: (a) MAE e RMSE para o setor Leste; (b) MAE e RMSE para o setor Central-Leste; (c) MAE	

e RMSE para o setor Central-Oeste-A; (d) MAE e RMSE para o setor Central-Oeste-B; (e) MAE e RMSE para o setor Oeste.	68
Figura 38 – MNDWIs gerados para todos os setores da costa de Icapuí: (a) MNDWI de 2023 do setor Leste; (b) MNDWI de 2023 do setor Central-Leste; (c) MNDWI de 2023 do setor Central-Oeste-A; (d) MNDWI de 2023 do setor Central-Oeste-B; e (e) MNDWI de 2023 do setor Oeste.	70
Figura 39 - Linhas de costa do setor Leste: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018.	72
Figura 40 - Linhas de costa do setor Central-Leste: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018.	74
Figura 41 - Linhas de costa do setor Central-Oeste porção A: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018.	77
Figura 42 - Linhas de costa do setor Central-Oeste porção B: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018.	79
Figura 43 - Linhas de costa do setor Oeste sobrepondo a imagem MNDWI do ano em questão: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo	

<p>fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-RNN para o ano de 2018.....</p>	82
<p>Figura 44 – Linhas de costa do setor Leste dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.</p>	84
<p>Figura 45 - Linhas de costa do setor Central-Leste dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.</p>	85
<p>Figura 46 - Linhas de costa do setor Central-Oeste porção A dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.</p>	86
<p>Figura 47 - Linhas de costa do setor Central-Oeste porção B dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.</p>	87
<p>Figura 48 - Linhas de costa do setor Oeste dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.</p>	88

LISTA DE TABELAS

Tabela 1 – Quantificação de mudanças em erosão e acreção na baía de Marajó	26
Tabela 2 – Detecção de mudanças no uso da terra durante o período de 2003 a 2011	30
Tabela 3 - Imagens Landsat 5-TM e Landsat 8-OLI utilizadas no estudo	51
Tabela 4 - Parâmetros utilizados na porção CNN da arquitetura	58
Tabela 5 - Dimensões de cada setor em <i>pixels</i>	59
Tabela 6 - Parâmetros da porção LSTM.....	61
Tabela 7 - Porcentagens de similaridades e diferenças calculadas pelo MAE, para os anos de 1997, 2003, 2009 e 2015.....	64
Tabela 8 - Performance do modelo CNN-LSTM	69

LISTA DE ABREVIATURAS E SIGLAS

CNN	<i>Convolutional Neural Network</i>
DSAS	<i>Digital Shoreline Analysis System</i>
IA	Inteligência Artificial
IPCC	<i>Intergovernmental Panel on Climate Change</i>
LEDAPS	<i>Landsat Ecosystem Disturbance Adaptive Processing System</i>
LRCN	<i>Long-Term Recurrent Convolutional Network</i>
LSTM	<i>Long Short-Term Memory</i>
ML	<i>Machine Learning</i>
MSAVI	<i>Modified Soil Adjusted Vegetation Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
PLN	Processamento de Linguagem Natural
PNGC	Plano Nacional de Gerenciamento Costeiro
PVI	<i>Perpendicular Vegetation Index</i>
RDVI	<i>Renormalized Difference Vegetation Index</i>
RNA	Redes Neurais Artificiais
RNN	<i>Recurrent Neural Network</i>
RVI	<i>Ratio Vegetation Index</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
SIG	Sistemas de Informação Geográfica
SVMs	<i>Support Vector Machines</i>
TNDVI	<i>Transform Normalized Difference Vegetation Index</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	17
1.2	Organização do documento	17
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Erosão costeira	19
2.2	Fatores responsáveis pelos processos de erosão costeira	20
2.3	Estudos sobre erosão costeira	21
2.4	Sensoriamento remoto	21
2.5	Uso do sensoriamento remoto nos estudos de erosão costeira	23
2.6	Geração de prognósticos de linhas de costa utilizando regressão linear	32
2.7	Redes neurais artificiais	33
2.7.1	<i>Redes Neurais Convolucionais</i>	35
2.7.1.1	<i>Camada Convolucional</i>	36
2.7.1.2	<i>Função de Ativação</i>	37
2.7.1.3	<i>Camada de Pooling</i>	37
2.7.1.4	<i>Dropout</i>	38
2.7.1.5	<i>Camada Totalmente conectada</i>	39
2.7.2	<i>Redes Neurais Recorrentes</i>	40
2.7.3	<i>Long Short-Term Memory</i>	42
2.7.4	<i>ConvLSTM e Redes CNN-LSTM</i>	44
2.8	Métodos de Redes Neurais Artificiais usados em estudos de dinâmica costeira	45
3	METODOLOGIA	48
3.1	Caracterização da área de estudo	48
3.2	Procedimentos metodológicos	49
3.2.1	<i>Geração de prognóstico utilizando Regressão Linear</i>	51
3.2.1.1	<i>Aquisição de imagens</i>	51
3.2.1.2	<i>Pré-processamento de imagens</i>	51
3.2.1.3	<i>Geração de Prognóstico Futuro</i>	53
3.2.1.4	<i>Processamento Digital de Imagens</i>	54
3.2.1.5	<i>Extração de linha de costa</i>	55
3.2.2	<i>Geração de prognóstico utilizando Redes Neurais</i>	56

3.2.2.1	<i>Divisão dos setores da linha de costa</i>	56
3.2.2.2	<i>Aquisição e pré-processamento de imagens</i>	57
3.2.2.3	<i>Divisão da sequência de imagens em entradas e saída</i>	57
3.2.2.4	<i>Aplicação da camada de rede neural convolucional</i>	58
3.2.2.5	<i>Aplicação da camada de rede neural recorrente</i>	60
3.2.2.6	<i>Rede Neural Densa</i>	61
4	RESULTADOS E DISCUSSÕES	62
4.1	Avaliação dos resultados	62
4.2	Resultados do método de extrapolação por regressão linear	63
4.3	Resultados do método de extrapolação através de redes neurais	67
5	CONCLUSÕES E RECOMENDAÇÕES	89
	REFERÊNCIAS	91

1 INTRODUÇÃO

A maioria dos temas que têm recebido atenção nas últimas décadas envolve questões relacionadas ao meio ambiente. A poluição nos seus vários tipos, o desmatamento indiscriminado, a degradação do solo e o aquecimento global refletem um estado de alerta que permeia toda a sociedade mundial (ABRAHAM; TORRES, 2007).

Neste contexto, o processo de erosão costeira também é reconhecido como uma questão de preocupação global, principalmente quando se trata dos efeitos lesivos sobre as atividades antrópicas instaladas nas zonas costeiras (BOORI; AMARO, 2010, 2011; SOUTO, 2009).

A zona costeira é reconhecida por ser um ambiente fortemente dinâmico e um dos agentes dessa dinâmica é a erosão costeira que pode provocar o recuo da linha de costa. Essa erosão pode ser causada tanto por fatores naturais quanto antrópicos. Ela ocorre em várias partes do mundo (CELLONE; CAROL; TOSI, 2016; FITTON; HANSOM; RENNIE, 2016; LEATHERMAN, 2018; NGUYEN; TAKEWAKA, 2020) e em algumas regiões do Brasil (GONÇALVES *et al.*, 2019; MARTINS; PEREIRA, 2014; VENANCIO *et al.*, 2020). A estimativa mundial é de que a erosão costeira afete aproximadamente 70% dos ambientes de praias arenosas da Terra (WEN *et al.*, 2016).

Os impactos causados por tais processos tendem a acarretar no declínio na biodiversidade, na fragmentação de habitats, no branqueamento dos recifes de coral, na introdução de novas doenças entre os organismos, na hipóxia, na proliferação de algas nocivas, na redução na qualidade de água e, conseqüentemente, na ameaça à saúde humana (FOLEY *et al.*, 2005; SOUTO, 2009).

Assim, a aplicação de técnicas de detecção de mudanças em ambientes costeiros é extremamente importante para o conhecimento da dinâmica do ambiente físico (ondas, marés, ventos, tempestades, correntes etc.), de modo que a delimitação das escalas temporal (dias, semanas, meses e anos) e espacial de avaliação é imprescindível para a compreensão das relações entre os processos físicos e antrópicos (GUIMARÃES *et al.*, 2014).

O estudo da erosão costeira envolve o procedimento de monitoramento com base em um conjunto de informações confiáveis. Assim, os métodos convencionais de levantamento e mapeamento baseados em pesquisas de campo ainda são vitais, mas, frequentemente, possuem uma logística complicada (SUWANPRASIT, 2015).

Portanto, a análise e o monitoramento de tais impactos é uma questão que precisa ser resolvida. Para esta finalidade, dados de Sensoriamento Remoto têm sido amplamente

utilizados em vários estudos que avaliam a mudança espacial e temporal do uso e cobertura da terra. Ademais, o Sensoriamento Remoto apresenta elevada potencialidade para as pesquisas voltadas ao monitoramento ambiental multitemporal, pois permite a obtenção de informações de extensas áreas da superfície terrestre, facilitando o entendimento das inter-relações entre as unidades geoambientais, em intervalos de tempo regulares (AMARO; SANTOS; SOUTO, 2012).

1.1 Objetivos

Este trabalho tem como objetivo principal desenvolver e avaliar modelos computacionais, através da implementação de algoritmo de regressão linear e de uma arquitetura híbrida de Redes Neurais Artificiais, para gerar o prognóstico futuro da linha de costa, considerando a resposta espectral dos diferentes elementos presentes em imagens de Sensoriamento remoto.

O objetivo principal deste trabalho demanda os seguintes objetivos específicos:

- Compreender as principais causas responsáveis pelos processos erosivos das áreas costeiras;
- Efetuar levantamento dos estudos nacionais e internacionais referentes à identificação e monitoramento dos processos de degradação de regiões costeiras;
- Avaliar as técnicas e índices utilizados para identificar e monitorar tais processos;
- Desenvolver uma ferramenta computacional para extração automatizada da linha de costa a partir de imagens orbitais processadas;
- Propor um método suportado por ferramenta computacional que auxilie na análise de áreas reconhecidamente afetadas por erosão costeira;
- Prototipar os componentes de *software* essenciais à aplicação da metodologia.

1.2 Organização do documento

Os capítulos deste documento estão organizados da seguinte forma: o Capítulo 2 apresenta uma contextualização sobre erosão costeira, apontando os principais fatores responsáveis pela ocorrência deste tipo de processo. Além disso, apresenta uma série de estudos sobre o tema. Aborda o conceito de Sensoriamento Remoto e sua aplicação nos estudos de erosão costeira. Introduce o conceito de redes neurais artificiais e as suas principais aplicações, nesta área de pesquisa. No Capítulo 3 são apresentados os materiais e os métodos aplicados

durante o desenvolvimento do trabalho. No Capítulo 4 são apresentados e discutidos os resultados obtidos com as implementações dos modelos propostos. No Capítulo 5 são apontadas as considerações finais, as contribuições identificadas bem como as sugestões de trabalhos futuros decorrentes desta pesquisa. Por fim, são apresentadas as Referências Bibliográficas.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo aborda os principais conceitos relacionados ao processo de erosão costeira, Sensoriamento Remoto, Redes Neurais Artificiais, Redes Neurais Convolucionais, Redes Neurais Recorrentes, *Long Short-Term Memory* e arquiteturas híbridas ConvLSTM e CNN-LSTM, os quais são necessários para o entendimento da pesquisa apresentada neste trabalho. A Seção 2.1 apresenta conceitos relacionados com erosão costeira. A Seção 2.2, por sua vez, discute os principais fatores responsáveis pelos processos erosivos em zonas costeiras. Na Seção 2.3, são discutidas as principais estratégias utilizadas para a realização de estudos sobre este tema. Já a Seção 2.4 apresenta os conceitos relacionados com Sensoriamento Remoto. A Seção 2.5 aborda trabalhos que utilizam técnicas de Sensoriamento Remoto para se monitorar zonas costeiras. A Seção 2.6 apresenta os conceitos de Redes Neurais Artificiais. E, por fim, a Seção 2.7 aponta algumas pesquisas que utilizaram Redes Neurais Artificiais em estudos de dinâmica costeira.

2.1 Erosão Costeira

Dentre os diversos conceitos existentes, o Decreto nº 5.300, de 07 de dezembro de 2004, que regulamenta o Plano Nacional de Gerenciamento Costeiro (PNGC), definiu zona costeira como o espaço geográfico de interação entre o continente, o oceano e a atmosfera, incluindo seus recursos ambientais, abrangendo uma faixa marítima, até 12 milhas (22,2 km) das linhas de base estabelecidas na Convenção das Nações Unidas sobre o Direito do Mar, compreendendo a totalidade do Mar Territorial e uma faixa terrestre formada pelos municípios que sofrem influência direta dos fenômenos costeiros (BRASIL, 2004).

Por sua vez, Rodriguez e Windevoxhel (1998), conforme citado por Amaro, Santos e Souto (2012), definem zona costeira como o espaço delimitado pela interface entre o oceano e a terra, ou seja, a faixa terrestre que recebe influência marítima e a faixa marítima que recebe influência terrestre.

Já a erosão costeira é o processo de remoção de material na linha de costa que leva à perda da terra à medida que ela recua em direção ao território (WEN *et al.*, 2016).

Devido aos inúmeros benefícios socioeconômicos, como o fácil acesso à navegação oceânica, à pesca costeira, ao turismo e ao lazer, os assentamentos humanos estão mais concentrados nestas áreas. Assim, de acordo com Cohen *et al.* (1997), aproximadamente 20%

da população mundial vive em uma faixa de 30 quilômetros do mar e quase o dobro desse número vive em até 100 quilômetros de distância da costa.

Além disso, estima-se que os bens e serviços produzidos a partir dos ecossistemas marinhos representem uma receita em torno de 14 bilhões de dólares anuais, o que torna cada vez mais importante o monitoramento de tais impactos (GUO *et al.*, 2016).

2.2 Fatores Responsáveis pelos Processos de Erosão Costeira

Segundo Bijlsma, Ehler e Klein (1996), na faixa costeira as populações estão crescendo o dobro da média global, o que torna os potenciais impactos da subida do nível do mar um foco importante nas avaliações de gestão costeira.

Por sua vez, Nicholls, Hoozemans e Marchand (1999) estimaram que 600 milhões de pessoas ocuparão as terras da planície de inundação costeira até o ano 2100, tornando cada vez mais intensa a pressão sobre os ecossistemas costeiros.

Os estudos conduzidos pelo *Intergovernmental Panel on Climate Change* (IPCC) apontaram que, no século 21, o nível do mar deverá aumentar de 18 a 66 cm (MAULUD; RAFAR, 2015). Porém, segundo Rowley *et al.* (2007) esse aumento poderá variar de 1,0 a 6,0 m, regional e localmente, para diferentes regiões costeiras no mundo, devido aos fatores como a subsidência de terrenos geológicos, às induções antropogênicas e as alterações no fluxo hidrodinâmico dos oceanos.

Estas características e as alterações climáticas, consequências do aquecimento global, e a decorrente elevação do nível do mar aumentarão ainda mais os riscos de inundações das zonas costeiras e, por isso, são identificados como um dos fatores mais importantes da erosão costeira (MAULUD; RAFAR, 2015).

Atualmente, sabe-se que diversos fatores influenciam na conformação da zona costeira, tais como: as características da Geologia das faixas litorâneas e da plataforma continental adjacente, a geometria predominante das discontinuidades, incluindo a influência da geometria dos lineamentos topográficos e geológicos, dos planos de acamamento e ângulos de mergulhos das camadas das unidades sedimentares que alcançam a costa, além de outros fatores tais como os níveis do lençol freático, os processos sedimentares recentes e os impactos de uso e ocupação da zona costeira (AMARO, 1998; AMARO; ARAÚJO, 2008).

Além disso, os fatores hidrodinâmicos e meteorológicos são fatores que influenciam as constantes mudanças observadas nas zonas costeiras (AMARO, 1998; AMARO; ARAÚJO, 2008).

2.3 Estudos sobre Erosão Costeira

Tradicionalmente, tomadas de decisão em processos de monitoramento são realizadas considerando aspectos econômicos, utilizando uma abordagem de análise de custo-benefício (COOPER; MCKENNA, 2008).

O monitoramento de zonas costeiras é uma tarefa importante para o desenvolvimento sustentável e para a proteção ambiental (CUI *et al.*, 2010). Assim, a extração e a análise das mudanças nas linhas de costa são atividades importantes, uma vez que mudanças na sua forma podem afetar fundamentalmente o ambiente costeiro (WANG *et al.*, 2006).

Entretanto, as linhas de costa são difíceis de capturar, pois o nível da água sempre muda, em função das marés (CUI *et al.*, 2010). Além disso, é difícil monitorar e mensurar a dinâmica costeira de forma exaustiva usando apenas dados de levantamento no solo, dada a grande extensão espacial da região costeira (GE *et al.*, 2013).

Em virtude disso, para dar suporte a estudos que visam analisar e monitorar os processos de erosão costeira, faz-se necessário uma base de dados eficiente que torne possível quantificar e calcular a taxa de erosão ou acreção em um dado período de tempo (GE *et al.*, 2013).

Neste contexto, o uso de produtos de Sensoriamento Remoto é um aliado importante nos estudos voltados ao gerenciamento de ecossistemas costeiros, no intuito de auxiliar o monitoramento dos impactos ambientais gerados pelos processos erosivos da linha de costa com base na análise de dados multifonte.

Assim, os produtos de Sensoriamento Remoto são utilizados para a investigação das alterações em regiões costeiras, devido às suas propriedades favoráveis, tais como o seu baixo custo e sua alta eficiência. Além disso, a aquisição repetitiva de sistemas de imagens orbitais pode ser explorada para fornecer dados espaciais em escala mais rápida para Sistemas de Informação Geográfica (SIG) (LIU, 2011).

2.4 Sensoriamento Remoto

O Sensoriamento Remoto é um campo de ciência aplicada para aquisição de informações da superfície da Terra por meio de dispositivos que executam o sensoriamento e o registro da energia refletida ou emitida, seguido pelo processamento, análise e aplicação dessas informações (SILVA; CÂMARA; ESCADA, 2009).

Os satélites de sensoriamento remoto são, atualmente, as fontes mais significativas de novos dados sobre o nosso planeta e, além disso, os bancos de dados de produtos de sensores remotos com informações espaciais são os que mais crescem (SILVA *et al.*, 2005).

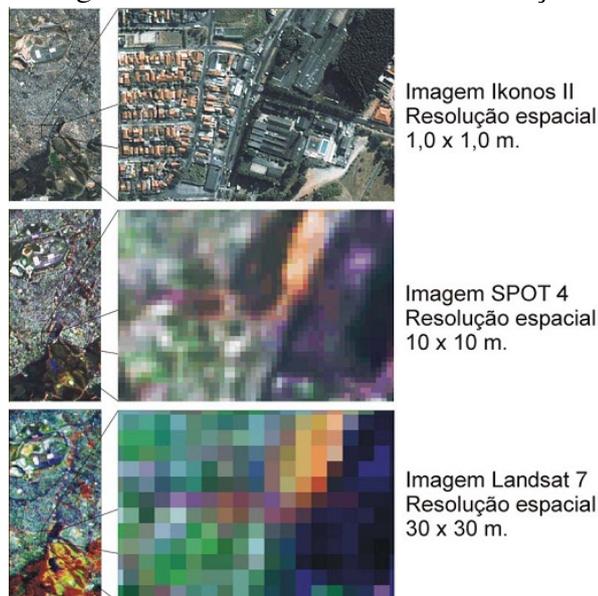
O primeiro satélite de Sensoriamento Remoto operacional foi o Landsat 1. Ele foi lançado em 1972, desde então, tem havido uma grande experiência em nível mundial na coleta, processamento e análise dos dados de Sensoriamento Remoto (SILVA; CÂMARA; ESCADA, 2009). Atualmente, a série de satélites Landsat já se encontra no nono satélite, lançado no dia 27 de setembro de 2021, a partir da evolução e implementação de novos sensores (OLI e TIRS).

As imagens obtidas por meio da aquisição e processamento de sensores remotos são usadas em muitos campos da pesquisa, uma vez que as informações fornecidas por elas são fortemente exigidas em muitas áreas, incluindo governo, economia, infraestrutura e hidrologia. Existem exemplos de uso em segurança, previsão de safras, planejamento urbano e monitoramento de recursos hídricos (SILVA; CÂMARA; ESCADA, 2009).

No processo de aquisição de imagem, quatro conceitos são fundamentais: resolução espacial, espectral, radiométrica e temporal (SILVA; CÂMARA; ESCADA, 2009).

A resolução espacial define o nível de detalhe de uma imagem, ou seja, se um sensor tem uma resolução espacial de vinte metros, então cada *pixel* representa uma área de 20 m x 20 m. A Figura 1 ilustra o contraste visual entre diferentes resoluções em áreas urbanas (SILVA; CÂMARA; ESCADA, 2009).

Figura 1 - Imagens de diferentes sensores e resoluções espaciais



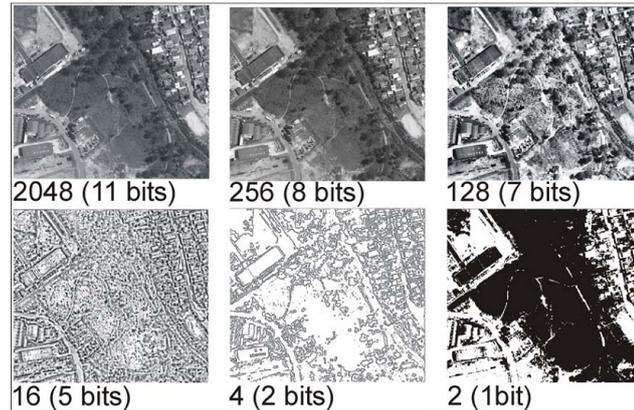
Fonte: Melo (2015).

A resolução espectral, por sua vez, é uma medida do número e do tamanho do intervalo do comprimento de onda (denominado de bandas) no espectro eletromagnético ao qual o sensor é sensível. Portanto, quanto maior o número de bandas e menor o tamanho do intervalo do

comprimento de onda, maior será a resolução espectral do sensor (JENSEN, 2011).

A resolução radiométrica pode ser expressa pela quantidade de níveis de cinza usados para representar os dados coletados pelo sensor. Quanto maior a resolução radiométrica de uma imagem, maior quantidade de informação presente na mesma (Figura 2) (MATHER; KOCH, 2010).

Figura 2 - Diferença de resolução radiométrica em área urbana



Fonte: Melo (2015).

A resolução temporal se refere ao intervalo de tempo em dias ou horas, que o sistema demora em obter duas imagens consecutivas da mesma região sobre a Terra. Assim, se um sensor é capaz de obter uma imagem de uma área a cada 16 (dezesesseis) dias, então a sua resolução temporal é este período (SILVA; CÂMARA; ESCADA, 2009).

2.5 Uso do Sensoriamento Remoto nos Estudos de Erosão Costeira

Os estudos sobre o mapeamento e o monitoramento do ambiente costeiro com base em dados de Sensoriamento Remoto multitemporais têm sido amplamente conduzidos em várias partes do mundo (GUO *et al.*, 2016).

Neste sentido, a maioria dos trabalhos existentes segue três vertentes principais. A primeira utiliza métodos relacionados com a identificação e avaliação dos processos de erosão costeira. A segunda, por sua vez, aborda métodos para monitorar a evolução de tais processos. Já a terceira vertente de trabalhos, procura utilizar modelos de estimativas de processos de erosão costeira através de métodos que visam gerar prognósticos sobre a tendência de evolução de tais processos.

Dentre os trabalhos que apresentam métodos de identificação de zonas costeiras afetadas por processos erosivos, encontra-se o trabalho de Maulud e Rafar (2015).

Neste estudo, os autores buscaram identificar as mudanças na linha de costa e o impacto do aumento do nível do mar, através do uso de mapas cartográficos e imagens do satélite SPOT 5 para avaliar as mudanças ocorridas no período de 1984 a 2013 em *Batu Pahat*, na Malásia. Além disso, os *softwares* ArcGIS e MIKE21 foram utilizados para gerar um modelo espacial capaz de identificar as mudanças na linha costa e projetar a elevação do nível do mar nos anos de 2020 e 2040, sendo capaz de identificar as áreas que futuramente serão inundadas.

A Figura 3 apresenta as mudanças nas linhas de costa, encontradas no trabalho. A partir dos resultados, contabilizou-se que as mudanças entre 1984 e 2013 foram de 50 a 200 metros. Além disso, a média de mudança anual foi de 1,5 a 7 metros. Por outro lado, as mudanças entre os anos de 2011 e 2013 foram de 1 a 25 metros, dependendo da região.

Figura 3 - Mudanças nas linhas de costa nos anos de 1984, 2011 e 2013



Fonte: Maulud e Rafar (2015).

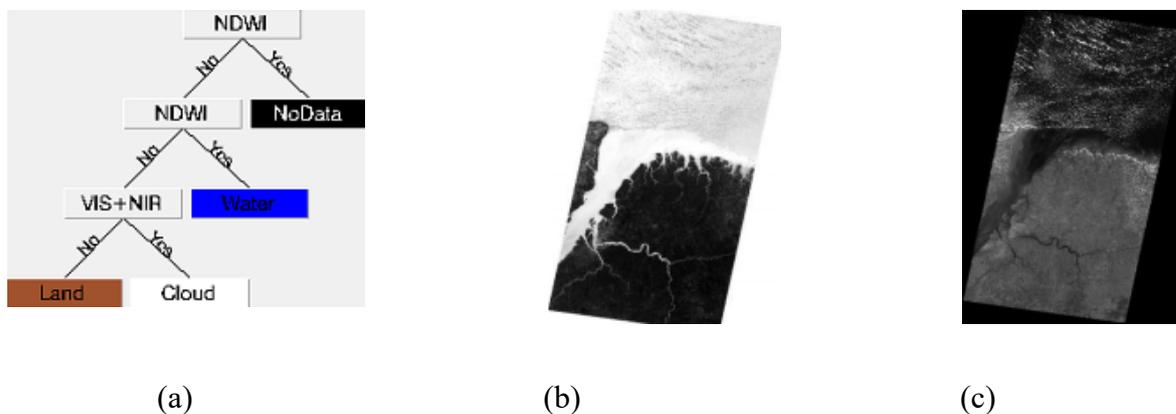
Tais alterações na linha de costa incluíram processos de acresção e erosão. A área erodida foi em torno de 415,47 hectares, enquanto o total de acresção detectada foi em torno de 68,53 hectares.

Dentre os trabalhos que utilizam métodos para monitorar a evolução de tais processos, destaca-se a pesquisa de Guimarães *et al.* (2014).

Os autores buscaram detectar as mudanças na linha de costa ao longo da costa na Baía de Marajó, no período de 1984 a 2013. Para esta finalidade, foi utilizada uma série temporal de imagens do satélite Landsat. Além disso, os autores definiram critérios para melhorar a consistência dos resultados da análise temporal, utilizando os seguintes parâmetros: cobertura de nuvem inferior a 10%, imagens ortorretificadas e condições de maré e fase lunar conforme dados fornecidos pela Diretoria de Hidrografia e Navegação da Marinha do Brasil.

As imagens da sequência temporal foram pré-processadas e classificadas, aplicando a técnica de árvore de decisão em dois tipos de produtos de sensoriamento remoto diferentes. Para isso, utilizou-se o *Normalized Difference Water Index* (NDWI) e a imagem resultante do cálculo da média entre as bandas do visível e do infravermelho próximo. A primeira para identificar melhor os corpos d'água e a última para separar as nuvens. A árvore de decisão aplicada na técnica de classificação está ilustrada na Figura 4.

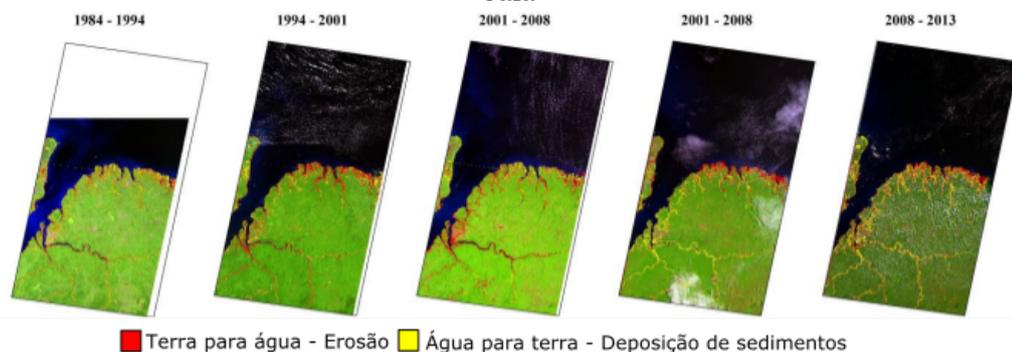
Figura 4 – Processo de classificação aplicado nas imagens: (a) Árvore de decisão usada para classificar as imagens, (b) Exemplo da aplicação com NDWI e (c) Exemplo com a média VIS + NIR



Fonte: Guimarães *et al.* (2014).

Por último, para que se fosse possível detectar as mudanças entre os anos, foi realizada a comparação entre as imagens pós-classificadas, aplicando a técnica de subtração entre as imagens iniciais e finais. Como resultado, foram produzidos mapas de detecção de mudanças para áreas com deposição de sedimentos e erosão, em intervalos, a partir do ano de 1984 até 2013 (Figura 5).

Figura 5 - Mapas de detecção de mudanças para áreas de deposição de sedimentos e erosão, na baía



Fonte: Guimarães *et al.* (2014).

Além disso, como pode ser visualizado na Tabela 1, foi possível identificar através da distribuição espacial e quantificação de áreas de deposição de sedimentos, que neste período houve um equilíbrio entre os processos de sedimentação e erosão, apesar de nos últimos anos os processos erosivos terem se intensificados.

Tabela 1 – Quantificação de mudanças em erosão e acreção na baía de Marajó

Classe / Período	Água para Terra (Km ²)	Terra para Água (Km ²)	Balanço (Km ²)
1984-1994	179,53	80,67	98,87
1994-2001	73,94	119,54	-45,60
2001-2008	99,03	83,11	15,92
2008-2013	73,09	144,67	-71,78
Total	425,60	427,99	-2,39

Fonte: Guimarães *et al.* (2014).

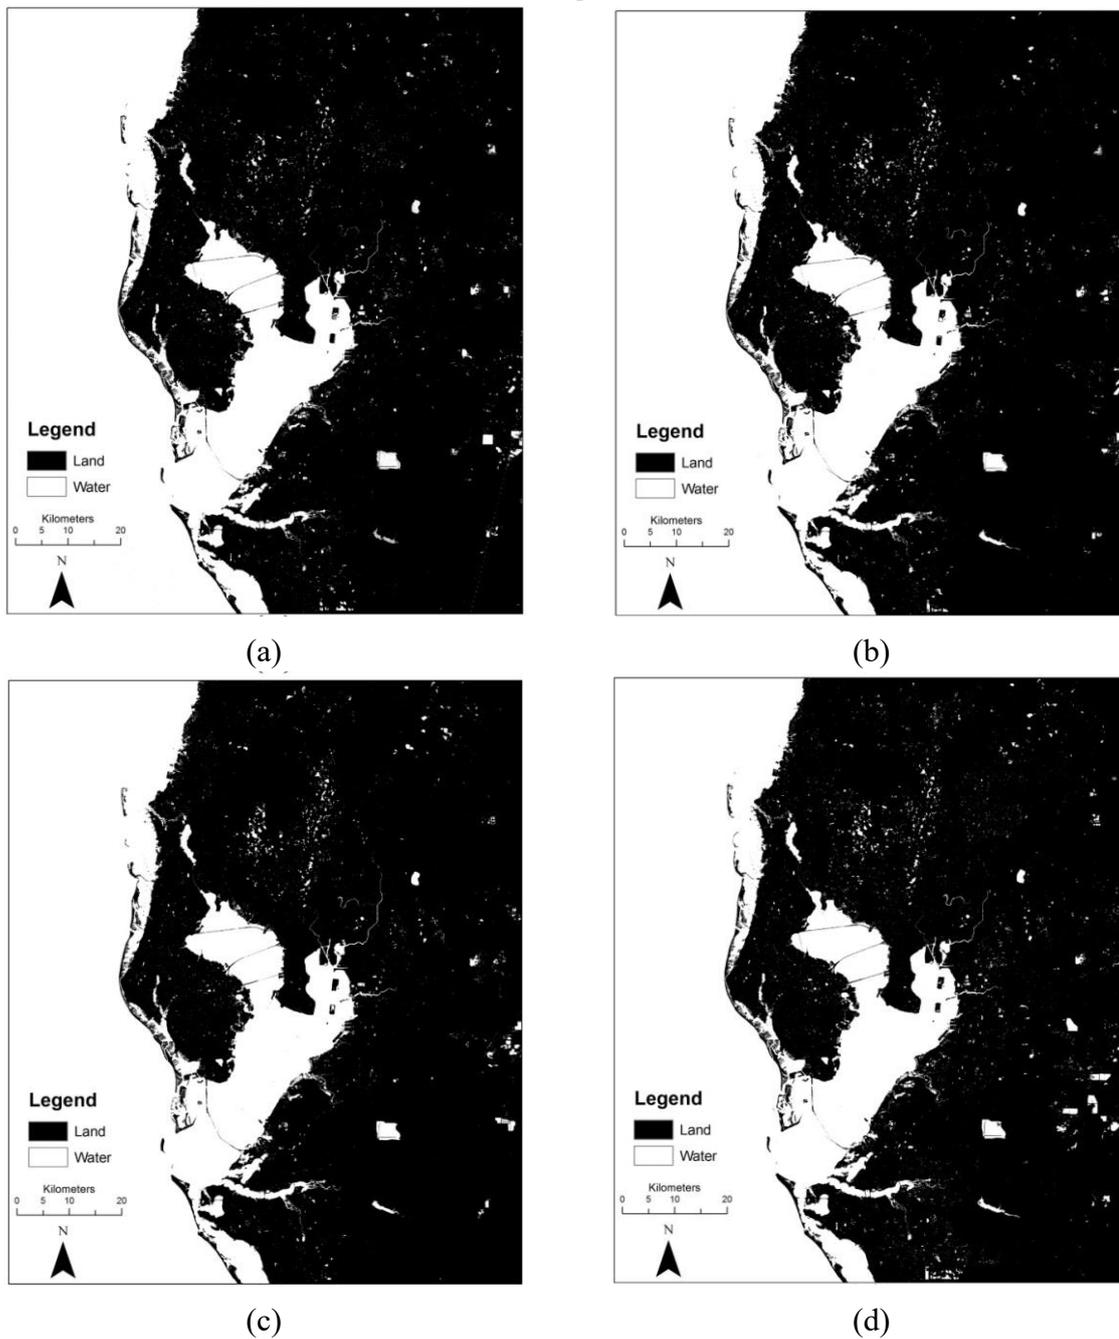
Em outro trabalho, Guo *et al.* (2016) avaliaram as mudanças na região costeira de duas baías, durante as últimas três décadas, através de técnicas e dados multitemporais de Sensoriamento Remoto. Para isso, foram utilizadas imagens do satélite Landsat adquiridas entre os anos de 1985 e 2015. O principal objetivo do estudo era delinear as mudanças da linha de costa na baía de *Tampa*, na Flórida, EUA e no porto de *Xiangshan*, *Zhejiang*, China. Além disso, buscava-se analisar os fatores antrópicos responsáveis por tais mudanças.

As informações de reflectância de todas as imagens foram coletadas e processadas para extrair as informações de linha de costa, utilizando o *software* especializado chamado *Landsat Ecosystem Disturbance Adaptive Processing System* (LEDAPS).

Em seguida, o NDWI foi extraído a partir da sequência de imagens. Por fim, as linhas de costa foram extraídas, através de interpretação visual, usando SIG. Também foi utilizada a técnica de conversão de *raster* para polígonos para reduzir o esforço.

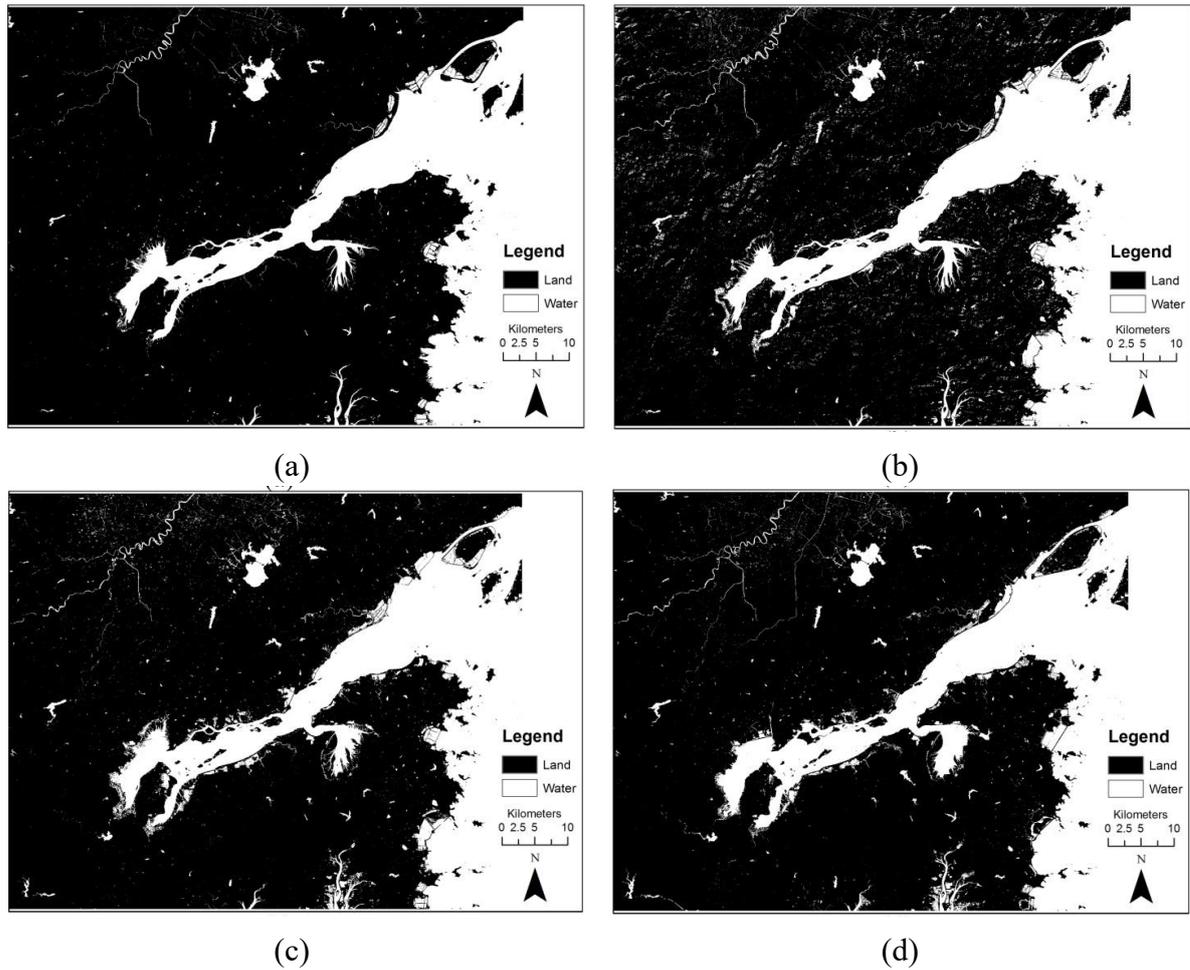
As Figuras 6, 7 e 8 apresentam as imagens NDWI classificadas para cada ano e mapas das mudanças na linha de costa, respectivamente.

Figura 6 - Imagens NDWI classificadas de: (a) 1985, (b) 1995, (c) 2005 e (d) 2015 na baía de Tampa



Fonte: Guo *et al.* (2016).

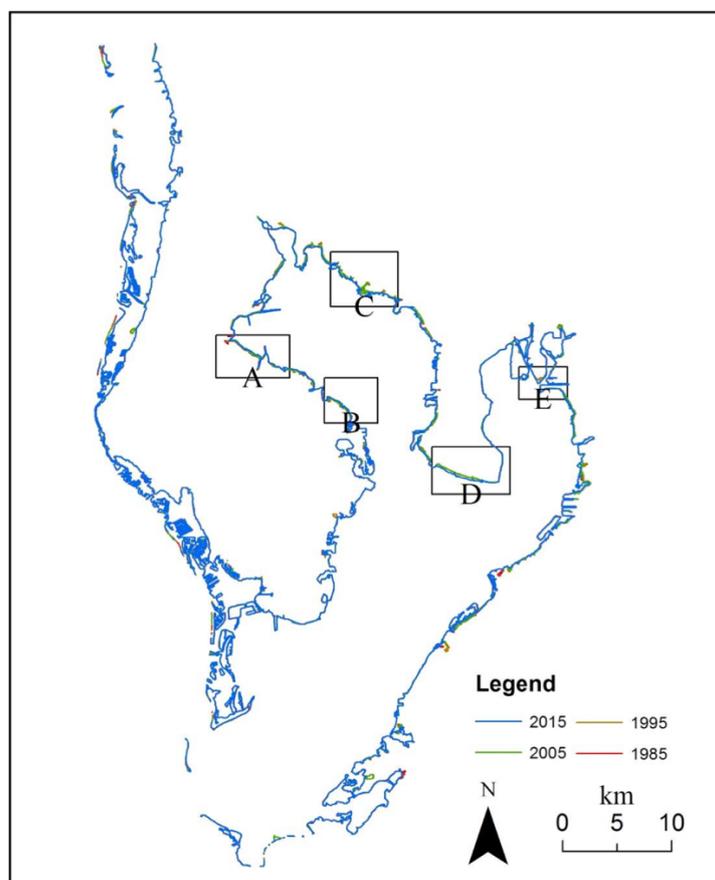
Figura 7 - Imagens NDWI classificadas de: (a) 1985, (b) 1995, (c) 2005 e (d) 2014 no porto de *Xiangshan*



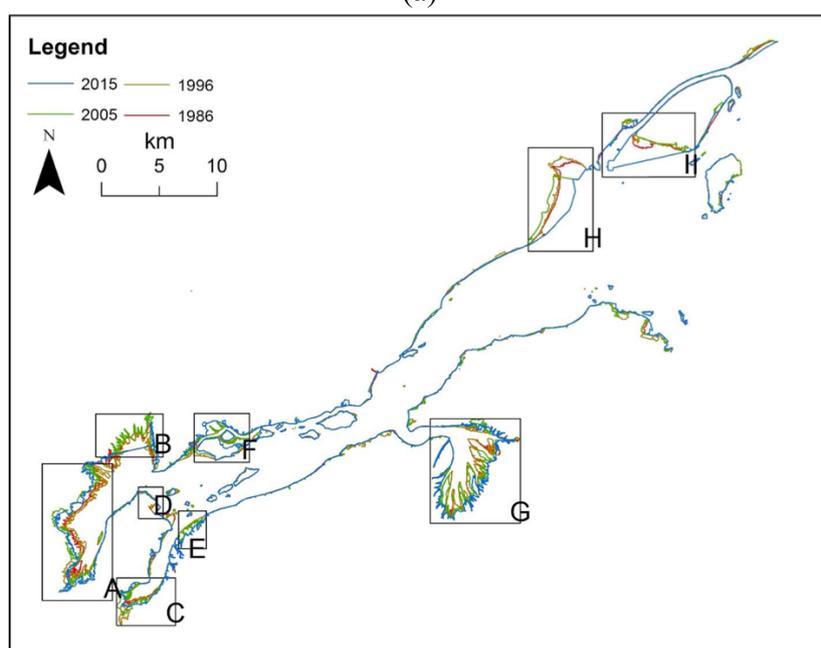
Fonte: Guo *et al.* (2016).

Nestes mapas as principais mudanças são destacadas com retângulos pretos. É notável que as linhas de costa em *Tampa* têm mudanças ligeiras, enquanto *Xiangshan* tem mudanças significativas no mesmo período.

Figura 8 – Mudanças na linha de costa: (a) Baía de Tampa de 1985 a 2015 e (b) porto de *Xiangshan* de 1986 a 2015



(a)



(b)

Fonte: Guo et al. (2016).

Ainda na vertente dos trabalhos que visam monitorar regiões com processos de erosão

costeira, encontra-se o trabalho de Suwanprasit (2015).

A autora procurou investigar o relacionamento entre as mudanças no uso da terra e a erosão costeira na ilha de *Phuket*, na Tailândia, usando imagens de multisensores e resoluções multitemporais, incluindo Landsat 7 ETM+, SPOT, ASTER e THEOS, adquiridas entre 2003 e 2011.

Neste estudo, a partir das imagens dos sensores descritos acima, foram extraídos sete índices de vegetação, incluindo: *Modified Soil Adjusted Vegetation Index* (MSAVI), *Normalized Difference Vegetation Index* (NDVI), *Perpendicular Vegetation Index* (PVI), *Renormalized Difference Vegetation Index* (RDVI), *Ratio Vegetation Index* (RVI), *Soil Adjusted Vegetation Index* (SAVI) e *Transform Normalized Difference Vegetation Index* (TNDVI). Além deles, a técnica de Análise de Principais Componentes foi utilizada para realizar o processo de classificação. Nesta etapa, as imagens foram classificadas utilizando a técnica de *Support Vector Machines* (SVMs) para identificar as seguintes classes: área urbana, agricultura, floresta, mangue, aquicultura, corpos d'água, praia e outros.

Ao todo, foram extraídos 334 (trezentos e trinta e quatro) pontos amostrais, divididos entre pontos de treinamento e de teste. Por fim, a matriz de confusão e o coeficiente Kappa foram utilizados para avaliar a acurácia dos resultados. As linhas de costa foram extraídas dos resultados da classificação e foram comparadas usando o método de diferença de imagens.

A partir dos resultados apresentados na Tabela 2, foi possível perceber que, durante os anos de 2003 a 2011, houve um incremento nas classes de vegetação de mangue, de área construída e áreas agrícolas. Inversamente, houve um decréscimo nas classes de floresta, aquicultura e água. As áreas construídas foram as que apresentaram mudança mais crescente em 2009, tendo um aumento de 109 km² (60,29% da área de 2003).

Tabela 2 – Detecção de mudanças no uso da terra durante o período de 2003 a 2011

Uso da terra	Mudanças no uso da terra (km ²)				
	2003-2005	2005-2007	2007-2009	2009-2011	2003-2011
Floresta	-97	9	9	23	-56
Mangue	-5	4	-2	11	12
Aquicultura	0	-6	-1	0	-7
Água	1	-37	20	11	-5
Praia	0	-0,7	0,7	0	0
Áreas construídas	12	-2	-11	4	10
Agricultura	28	59	13	-72	28
Terra vazia	-6	-8,7	6,7	8	0
Nuvem	67	-69	16	4	18

Fonte: Suwanprasit (2015).

Na vertente de trabalhos que buscam gerar modelos de prognósticos para estimar a evolução dos processos de erosão costeira, existe o trabalho de Wen *et al.* (2016). Neste estudo, os autores implementaram um modelo de previsão das posições da linha costeira usando dados de sensoriamento remoto de alta resolução (0,5 m) em um ambiente de Sistema de Informação Geográfica (SIG), através do uso da extensão *Digital Shoreline Analysis System (DSAS)*, aplicada no estudo da costa arenosa de *Tianlongsi*, na China.

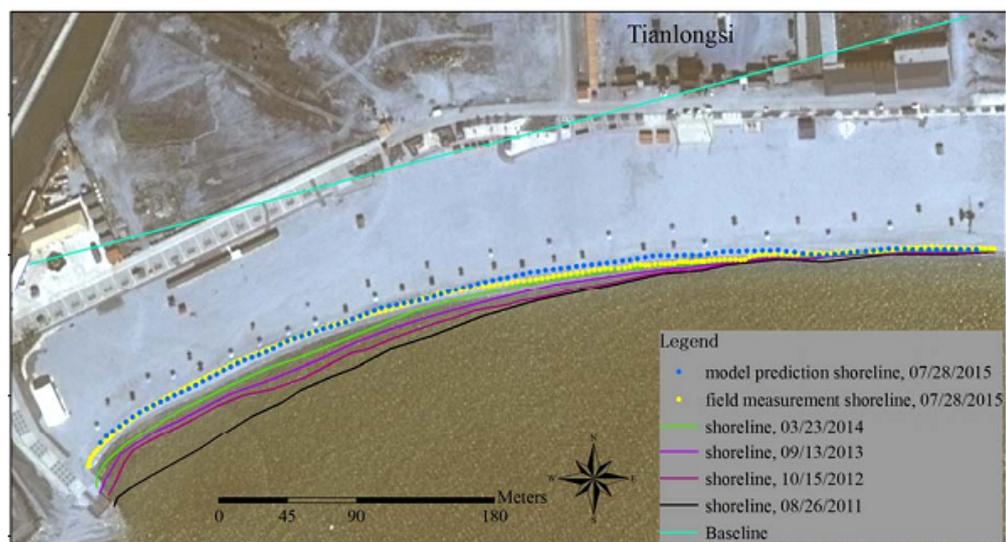
Dados de Sensoriamento Remoto de 2011, 2012, 2013 e 2014 foram usados para analisar a taxa de mudança na linha de costa, no decorrer dos anos. Além disso, dados de campo também foram obtidos em 2015, usando dispositivo GPS com precisão a nível de centímetros.

A informação das linhas de costa foi extraída através de interpretação visual, em ambiente SIG. Em seguida, o DSAS foi utilizado para estabelecer o modelo de prognóstico, de acordo com as posições históricas das linhas de costa de cada ano.

Em seguida, a linha de costa para o ano de 2015 foi gerada e comparada com os dados de campo coletados no mesmo ano. Estes dados foram usados para validar os resultados do modelo.

Como pode ser visto da Figura 9, há uma coincidência entre as linhas que representam o ano de 2015 gerado pelo modelo e a linha gerada com os dados coletados em campo. Este resultado serviu para validar o modelo de prognóstico proposto. A partir daí, foi gerada uma imagem para o ano de 2018.

Figura 9 – Predição e validação do modelo de predição de posições de linha de costa em 28 de julho de 2015



Fonte: Wen *et al.* (2016).

2.6 Geração de Prognósticos de Linhas de Costa Utilizando Regressão Linear

O modelo de regressão linear faz uma predição calculando uma soma ponderada das características de entrada, além de uma constante chamada viés (também chamado de intercepto ou coeficiente linear), conforme mostrado na Equação 1 (GÉRON, 2019).

$$y = a + bx + e \quad (1)$$

Onde: y é a variável dependente; x é a variável independente; a e b são as ordenadas na origem (ou intercepto) e de inclinação, respectivamente e “ e ” é o erro vindo do caráter aleatório de y .

Para a geração de prognósticos futuros, Sousa *et al.* (2018) utilizaram um método de regressão estatística, que definiu a equação do modelo de regressão linear ajustada ao método de extrapolação de séries temporais de imagens dada pela Equação 2.

$$I_1(x, y, t) = a_1(x, y)t + b_1(x, y) \quad (2)$$

Na Equação 2, o par (x, y) corresponde às coordenadas do *pixel* de interesse; $I_1(x, y, t)$ representa o nível de cinza dos *pixels* de cada sequência na t -ésima tentativa, ou observação; $t=1, 2, 3, \dots, n$ é a variável independente de tempo; o subíndice 1 indica que um ajuste linear entre duas sequências sucessivas de imagens foi usado para calcular a extrapolação em um tempo futuro após a segunda sequência; a_1 é o coeficiente de regressão (coeficiente angular); e, finalmente, b_1 representa o coeficiente linear. Assim, a_1 e b_1 representam os parâmetros de ajuste da regressão linear no tempo.

O objetivo do método proposto foi calcular $a_1(x, y)$ e $b_1(x, y)$, através de uma sequência de imagens de anos anteriores. Assim, considerando t_1, t_2, \dots, t_n como uma sequência temporal de imagens para treinamento do modelo, o método foi executado para cada um dos *pixels*, conforma e Equação 3.

Considerando $M = \begin{bmatrix} t_1 & 1 \\ t_2 & 1 \\ \dots & \dots \\ t_n & 1 \end{bmatrix}$, $X = \begin{bmatrix} a \\ b \end{bmatrix}$ e $Y = \begin{bmatrix} I_1 \\ I_2 \\ \dots \\ I_n \end{bmatrix}$, a Equação 3 pode ser reescrita de

acordo com a Equação 4:

$$MX = Y \quad (4)$$

Desta forma, a matriz X pode ser encontrada usando a Equação 5:

$$X = (MTM)^{-1}(MTY) \quad (5)$$

2.7 Redes Neurais Artificiais

Técnicas de Inteligência Artificial (IA), em particular de Aprendizado de Máquina, têm sido utilizadas com sucesso em vários problemas reais. Entretanto, até alguns anos atrás, a IA era vista como uma área teórica, com aplicações apenas em pequenos problemas curiosos, desafiadores, mas de pouco valor prático (FACELI *et al.*, 2019).

Nas últimas décadas, com a crescente complexidade dos problemas a serem tratados computacionalmente e do volume de dados gerados por diferentes setores, tornou-se clara a necessidade de ferramentas computacionais mais sofisticadas, que fossem mais autônomas, reduzindo a necessidade de intervenção humana e dependência de especialistas. Neste cenário, as Redes Neurais Artificiais (RNA) surgiram como excelente alternativa (FACELI *et al.*, 2019).

As RNAs são modelos computacionais inspirados no sistema nervoso de seres vivos. Elas possuem a capacidade de aquisição e manutenção do conhecimento e podem ser definidas como um sistema computacional distribuído, composto por um conjunto de unidades de processamento, caracterizados por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), sendo estas representadas, computacionalmente, por vetores ou matrizes de pesos sinápticos (FACELI *et al.*, 2019; SILVA, 2016).

Elas possuem características relevantes, como: adaptação por experiência, capacidade de aprendizado, habilidade de generalização, tolerância a falhas, armazenamento distribuído e facilidade de prototipagem (SILVA, 2016).

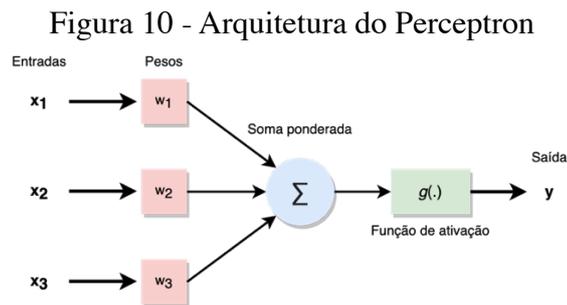
A primeira publicação relacionada à neurocomputação data de 1943, por meio do trabalho publicado por McCulloch e Pitts (1943). Nesta pesquisa, os autores realizaram o primeiro modelamento matemático inspirado no neurônio biológico, resultando-se assim na primeira concepção de neurônio artificial. Esta foi a primeira arquitetura de RNA proposta. Desde então, muitas outras surgiram (GÉRON, 2019; SILVA, 2016).

Basicamente, uma RNA pode ser dividida em três partes ou camadas, são elas: camada de entrada, camadas escondidas (também chamadas de camadas ocultas) e camada de saída. A

camada de entrada é responsável pelo recebimento de informações, sinais, características ou medições advindas do meio externo. Por sua vez, as camadas escondidas são compostas de neurônios que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser inferido. Por último, a camada de saída é responsável pela produção e apresentação dos resultados da rede (SILVA, 2016).

As principais arquiteturas de redes neurais artificiais, de acordo com a disposição de seus neurônios e a forma de interligação entre eles, podem ser divididas em: redes *feedforward* de camada simples, redes *feedforward* de múltiplas camadas, redes recorrentes e redes reticuladas (SILVA, 2016).

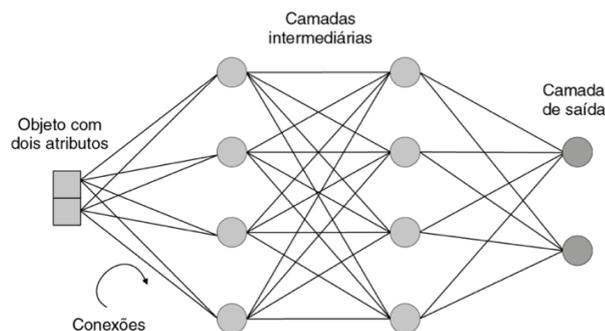
Entre os principais tipos de redes *feedforward* de camada simples estão o *Perceptron* e o *Adaline*. A rede *Perceptron* foi idealizada por Rosenblatt (1958) e é a forma mais simples de configuração de uma RNA. A arquitetura do *Perceptron* está representada na Figura 10.



Fonte: elaborada pelo autor.

A arquitetura do *Perceptron* de uma camada é adequada a problemas que são linearmente separáveis. Entretanto, a maioria das aplicações atuais possuem a característica de serem não linearmente separáveis. Nestas situações, o mais adequado são as redes *feedforward* de múltiplas camadas. Tais redes são constituídas de uma ou mais camadas escondidas de neurônios. A Figura 11 apresenta um exemplo desse tipo de arquitetura.

Figura 11 - Representação de uma Rede Neural feedforward de múltiplas camadas



Fonte: Faceli *et al.* (2019).

Apesar dos primeiros estudos em RNAs começarem em meados de 1940, acreditava-se, até a década de 1960, que com o avanço nos estudos, em pouco tempo, seria possível interagir com máquinas verdadeiramente autônomas e inteligentes. Na época, quando ficou claro que essa promessa não seria cumprida, o financiamento nesta área de pesquisa ficou reduzido e os estudos de RNAs ficaram prejudicados. Posteriormente, no início dos anos 1980, à medida que novas arquiteturas de rede foram inventadas e melhores técnicas de treinamento foram desenvolvidas, houve um ressurgimento do interesse neste tema (GÉRON, 2019).

Atualmente, elas são versáteis, poderosas e escaláveis, tornando-as ideais para lidar com grandes tarefas altamente complexas do aprendizado de máquina, como avaliar e classificar imagens captadas por satélite, classificar padrões de escrita e de fala, reconhecer faces em visão computacional, prever ações no mercado financeiro, dentre tantas outras possibilidades (GÉRON, 2019; SILVA, 2016).

2.7.1 *Redes Neurais Convolucionais*

O ser humano possui um sistema de reconhecimento visual complexo e, devido a esta característica, é capaz de distinguir e classificar um objeto de forma independente de outros (YI, 2018).

Os algoritmos de *Machine Learning* (ML) têm sido utilizados para aprender o relacionamento subjacente em dados e, assim, tomar decisões sem exigir instruções explícitas. Porém, os modelos computacionais de processamento de informações do cérebro que têm dominado a neurociência computacional são arquiteturas em grande parte superficiais, que executam computação simples (KHAN *et al.*, 2020; YI, 2018).

Em seus trabalhos, Hubel (1959) e Hubel e Wiesel (1968) realizaram uma série de experimentos com gatos e macacos, que proporcionaram aprendizados cruciais sobre a estrutura do córtex visual. Em particular, eles mostraram que muitos neurônios presentes no córtex visual tem um pequeno campo receptivo local, o que significa que eles reagem apenas a estímulos visuais localizados em uma região limitada do campo visual. Os campos receptivos de diferentes neurônios podem se sobrepor e, juntos, formarem todo o campo visual (GÉRON, 2019).

Além disso, os estudos do córtex visual inspiraram o projeto *Neocognitron* (FUKUSHIMA, 1980), que posteriormente evoluiu para o que hoje são chamadas as Redes Neurais Convolucionais (do inglês, *Convolutional Neural Network* - CNN) (GÉRON, 2019).

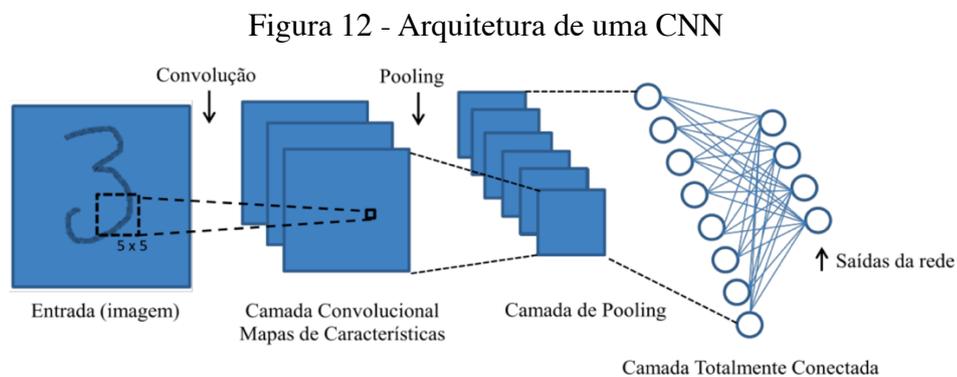
A arquitetura de CNN foi proposta em 1989 e tem apresentado um enorme potencial em

tarefas relacionadas à visão computacional e vem ganhando atenção por sua capacidade de classificação com base em informações contextuais (INDOLIA *et al.*, 2018; KHAN *et al.*, 2020).

As CNNs são utilizadas para explorar propriedades espaciais dos dados. Assim, a visão computacional baseada em redes neurais convolucionais permitiu aos pesquisadores realizarem o que havia sido considerado impossível nos últimos séculos, como: reconhecimento facial, desenvolvimento de veículos autônomos, autoatendimento em supermercados, atendimento médico inteligente e etc. (LI *et al.*, 2021).

Existem algumas razões pelas quais as redes neurais convolucionais estão se tornando tão importantes e melhores do que as redes neurais tradicionais. Em CNNs, os pesos da camada convolucional são usados para extração de características e os pesos das camadas totalmente conectadas são usados para classificação, que são determinados no processo de treinamento. Em comparação com as redes tradicionais, a melhoria das CNNs leva à economia nos requisitos de memória e redução da complexidade computacional (YI, 2018).

A arquitetura típica de uma CNN, geralmente, consiste em quatro componentes: camada de convolução, camada de *pooling*, função de ativação e camada totalmente conectada. A Figura 12 ilustra a arquitetura de uma CNN (INDOLIA *et al.*, 2018). As subseções a seguir apresentam as características e as funções de cada uma das camadas de uma CNN.



Fonte: Faria (2021).

2.7.1.1 Camada Convolucional

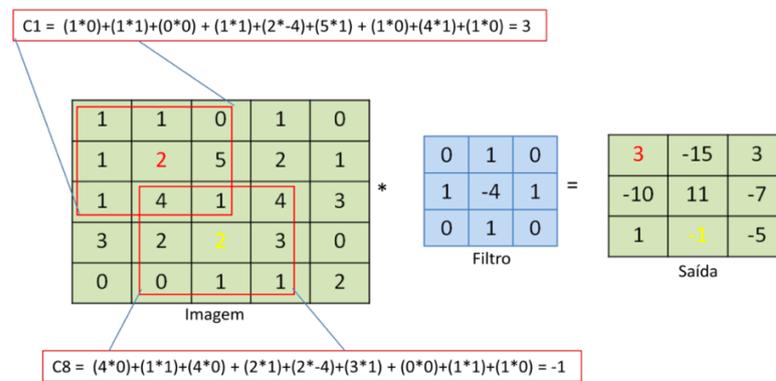
A camada convolucional é a mais importante de uma CNN. Ela utiliza filtros não lineares para percorrer sequencialmente os dados de entrada (ou da camada anterior). Cada um destes filtros responde a um subconjunto ou uma pequena região do conjunto de entrada (COCOLO, 2020; FARIA, 2021; GÉRON, 2019).

Para cada sequência percorrida sobre a entrada, é calculado o produto entre cada

elemento do filtro (chamado *Kernel*) e o elemento de entrada que ele sobrepõe, e os resultados são somados para obter a saída correspondente àquela localização. O resultado deste procedimento é denominado mapa de características. Além disso, durante o processo de treinamento da rede, a camada de convolução acaba encontrando os filtros mais adequados para uma determinada tarefa e aprende a combiná-los em padrões mais complexos (COCOLO, 2020; FARIA, 2021; GÉRON, 2019).

Na Figura 13, é representada a operação de convolução, onde a imagem de entrada é representada por uma matriz de tamanho 5×5 e o filtro é representado por outra matriz de tamanho 3×3 . Este filtro em questão é responsável por detecção de bordas em imagens (FARIA, 2021).

Figura 13 – Exemplo do processo de convolução



Fonte: Faria (2021).

2.7.1.2 Função de Ativação

A saída da camada de convolução é fornecida a outra função matemática chamada função de ativação. Ela desempenha um papel importante, nas redes neurais convolucionais. Ela serve como uma função de decisão que traz a não-linearidade ao sistema e ajuda na aprendizagem de padrões intrínsecos aos dados. Por isso, a seleção de uma função de ativação apropriada pode acelerar o processo de aprendizagem (BHATT *et al.*, 2021; KHAN *et al.*, 2020).

A função de ativação mapeia os valores de saída entre -1 e 1 ou 0 e 1 , por exemplo (o intervalo de valores vai depender da função de ativação utilizada). No contexto das CNNs, a função de ativação *ReLU* é a mais utilizada (BHATT *et al.*, 2021; KHAN *et al.*, 2020).

2.7.1.3 Camada de Pooling

Após obter os mapas de características, é necessário adicionar uma camada de *pooling* à CNN. Esta camada é usualmente utilizada imediatamente depois das camadas convolucionais

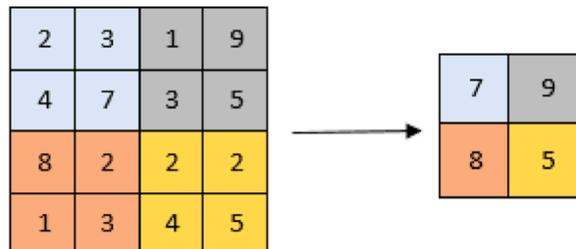
e são responsáveis por tentar encontrar a informação mais importante e significativa obtidas a partir das camadas convolucionais (BHATT *et al.*, 2021; FARIA, 2021).

O objetivo da camada de *pooling* é subamostrar (diminuir) o tamanho espacial da imagem de entrada para reduzir a carga computacional, o uso de memória e evitar *overfitting* (COCOLO, 2020; GÉRON, 2019).

O tipo mais comum de *pooling* é o *Max Pooling*. Este tipo de *pooling* delimita regiões e seleciona o maior valor de cada uma delas (COCOLO, 2020; GÉRON, 2019).

Conforme ilustrado na Figura 14, para realizar a operação de *Max Pooling*, um *kernel* de tamanho $n \times n$ é definido e percorre a matriz de entrada, selecionando o maior valor encontrado e o adiciona no local apropriado da matriz de saída (BHATT *et al.*, 2021).

Figura 14 - Representação da camada de *max pooling* com *kernel* 2 x 2



Fonte: Bhatt *et al.* (2021).

2.7.1.4 Dropout

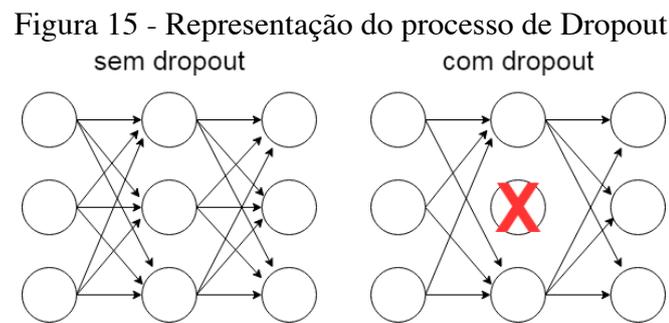
As aplicações que fazem uso das arquiteturas de CNN podem apresentar milhares de camadas de processamento, aumentando assim a quantidade de parâmetros utilizados pela rede. Conseqüentemente, esta maior complexidade da arquitetura pode apresentar um problema conhecido como sobreajuste (*overfitting*), que ocorre quando o modelo implementado ajusta-se muito aos dados, durante o processo de treinamento e, conseqüentemente, não generaliza bem. Por exemplo, às vezes, pode ocorrer que a rede neural aprenda a classificar bem as imagens de seu conjunto de treinamento, porém, em novas imagens, ela apresente um desempenho ruim (EBERMAM; KROHLING, 2018; FARIA, 2021; KHAN *et al.*, 2020).

O *overfitting* pode ser resolvido através de diferentes técnicas de regularização. Tais técnicas são responsáveis em realizar uma modificação no algoritmo de aprendizagem, com o objetivo de reduzir o erro de generalização (FARIA, 2021).

Uma das técnicas de regularização que vem sendo utilizada em redes neurais é a técnica de *Dropout*, proposta por Hinton *et al.* (2012). Esta técnica consiste em remover aleatoriamente,

a cada iteração, uma determinada porcentagem de neurônios, durante o processo de treinamento. Para isto, é definida uma probabilidade p , onde cada unidade tem essa probabilidade de seu sinal ser propagado na rede (COCOLO, 2020; EBERMAM; KROHLING, 2018; FARIA, 2021; LI *et al.*, 2021).

A ideia do *Dropout* é que exista uma arquitetura de rede diferente a cada vez que uma amostra de treinamento é apresentada, mas todas essas redes compartilham os mesmos pesos para as unidades escondidas que estão presentes. A Figura 15 ilustra o processo de *Dropout*. A Figura 15(a) apresenta uma rede neural sem *dropout*, ou seja, com os neurônios ativos. A Figura 15(b), por sua vez, apresenta uma rede neural artificial onde um neurônio da segunda camada é aleatoriamente desligado, através do uso da técnica de *dropout* (COCOLO, 2020; EBERMAM; KROHLING, 2018; FARIA, 2021; LI *et al.*, 2021).



Fonte: Ebermam e Krohling (2018).

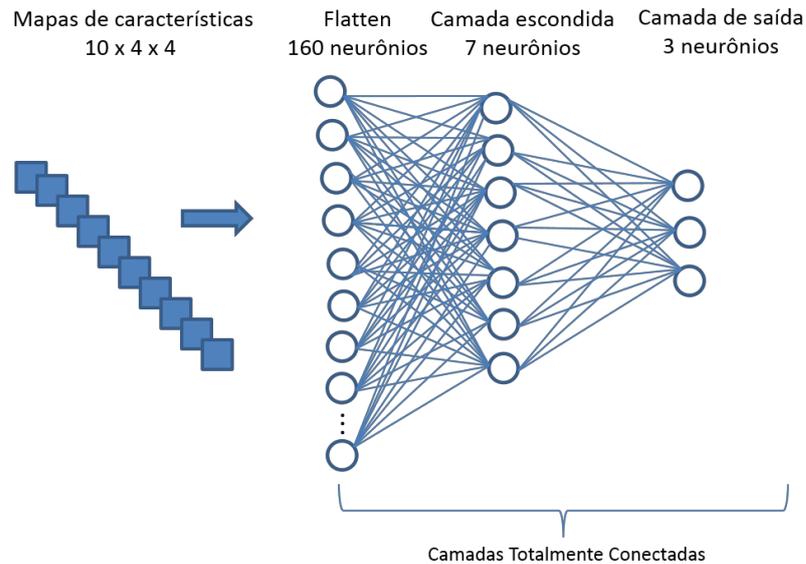
2.7.1.5 Camada Totalmente conectada

As CNNs apresentam uma ou mais camadas totalmente conectadas. Tais camadas funcionam como uma rede neural multicamadas *feedforward* e são responsáveis pela interpretação das características extraídas pelas camadas anteriores da CNN. Com isso, elas são capazes de fazer a classificação ou a previsão de valores, baseada em um conjunto de treinamento (EBERMAM; KROHLING, 2018; FARIA, 2021).

Normalmente, a camada anterior às camadas totalmente conectadas consiste em uma camada de *pooling*, onde seus os mapas de características apresentam mais de uma dimensão e, por isso, são redimensionados para uma única dimensão (técnica conhecida como *flatten*) para poder conectar-se à parte final da rede (EBERMAM; KROHLING, 2018).

A Figura 16 ilustra a estrutura de uma CNN com camadas totalmente conectadas, que recebem como entrada 10 (dez) mapas de características de dimensão 4×4 e que são redimensionados para 160 neurônios, utilizando a técnica *flatten*.

Figura 16 - Arquitetura CNN com camadas totalmente conectadas



Fonte: Faria (2021).

2.7.2 Redes Neurais Recorrentes

Dados de séries temporais estão sendo coletados e incrementados diariamente, para aplicações em áreas como saúde, biologia, geociências etc. No entanto, este grande volume de dados, geralmente, exige especialistas para sua interpretação e rotulagem (ELDELE *et al.*, 2021).

A análise de séries temporais é um processo de identificação das características, padrões e propriedades importantes em uma série de dados, usada para descrever em termos gerais um determinado fenômeno gerador (SANTOS; LUDERMIR; PRUDENCIO, 2004).

A previsão de séries temporais é considerado um dos principais objetivos na análise de séries temporais e é tratado pelas técnicas de aprendizado de máquina como um problema de previsão de sequências (BROWNLEE, 2020; SANTOS; LUDERMIR; PRUDENCIO, 2004).

A previsão de sequência é diferente de outros tipos de problemas de aprendizado de máquina. Uma sequência impõe uma ordem nas observações que deve ser respeitada e preservada ao treinar modelos e fazer previsões (BROWNLEE, 2020).

As redes neurais clássicas podem ser aplicadas a problemas de predição de sequência. Entretanto, elas não conseguem manter os aspectos temporais presentes nestes dados, gerando assim previsões independentes (BROWNLEE, 2020; CHOLLET; ALLAIRE, 2018).

Neste contexto, as Redes Neurais Recorrentes (do inglês, *Recurrent Neural Network* - RNN), são um tipo de arquitetura de rede neural mais avançada e que são principalmente usadas em problemas que envolvem sequências e séries temporais. Elas são as principais ferramentas

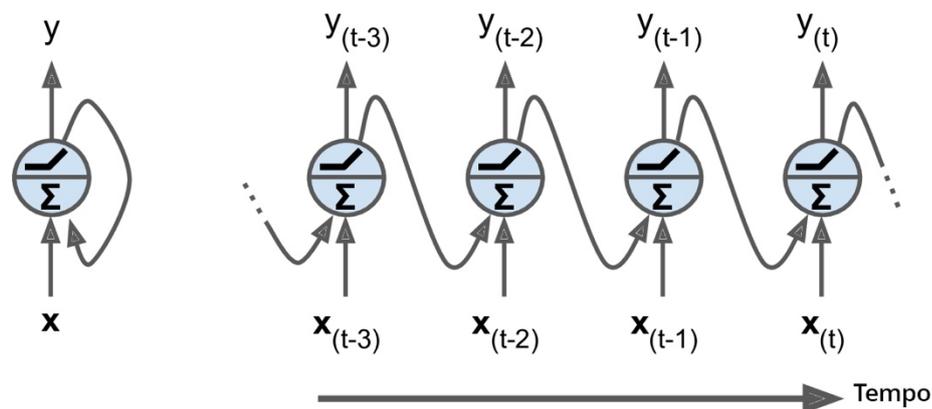
usadas, atualmente, no aprendizado de máquina ao lidar com dados sequenciais e em muitas tarefas que requerem uma memória de eventos passados (HAVIV; RIVKIND; BARAK, 2019; MOSKOLAĪ et al., 2020).

Ao contrário das redes neurais *feedforward*, as RNNs permitem conexões entre unidades ocultas associadas a um atraso de tempo. Quando treinadas, elas tomam como entrada não apenas o dado atual, mas também utilizam informações que foram observadas anteriormente no tempo (ASTOLFI *et al.*, 2019). Por meio de suas conexões, elas podem manter uma memória que sumariza as entradas de sequências passadas, permitindo-lhe capturar correlações entre eventos temporalmente distantes nos dados (TU; HE; TAO, 2020).

Cada ciclo de treinamento, em uma RNN, armazena informações relevantes ao longo do tempo, em estados ocultos mantidos pela rede. Dessa forma, a cada tempo t , a rede armazena, no seu estado oculto, além de informações dos dados observados em t , também informações do estado oculto de $t - 1$, que armazenou toda a informação relevante que aconteceu no passado. Assim, o estado oculto de t contém traços não apenas do estado oculto anterior $t - 1$, mas também de todos aqueles que o precederam. Isso capacita a rede a criar correlações entre dados, criando uma dependência entre eles de longo prazo (ASTOLFI *et al.*, 2019).

A Figura 17 ilustra como o modelo recorrente pode ser desdobrado na dimensão temporal. Dessa forma, pode-se caracterizar a rede recorrente como uma rede neural *feedforward*, porém com pesos iguais entre as camadas temporais (GÉRON, 2019).

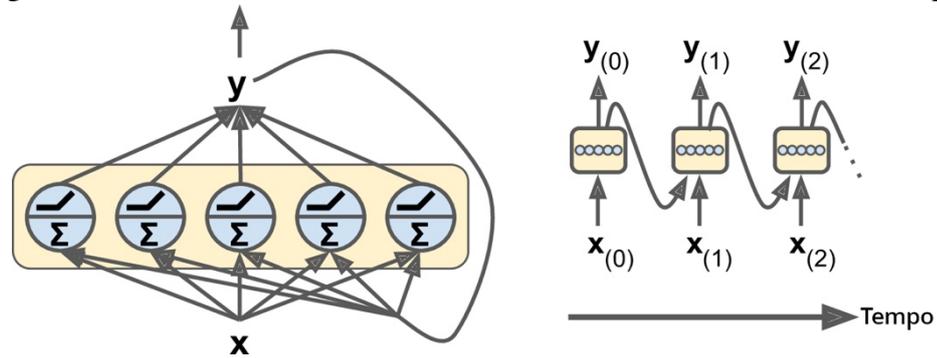
Figura 17 - Neurônio recorrente desenrolado através do tempo



Fonte: Géron (2019).

A cada intervalo de tempo t , o neurônio recorrente recebe as entradas $x(t)$, bem como sua própria saída do intervalo de tempo anterior, $y(t - 1)$. A Figura 18 representa uma camada de neurônios recorrentes desenrolados através do tempo (direita) (GÉRON, 2019).

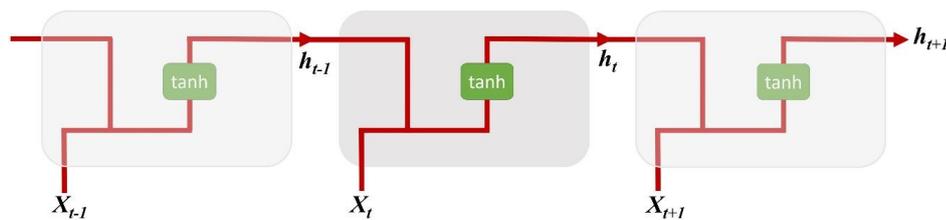
Figura 18 - Camada de neurônios recorrentes desenrolados através do tempo



Fonte: Géron (2019).

A arquitetura padrão de uma RNN é composta por três componentes principais: entrada, neurônio oculto e função de ativação. A Figura 19 apresenta a estrutura dessa RNN.

Figura 19 - Arquitetura de uma RNN



Fonte: Rajagukguk, Ramadhan e Lee (2020).

Atualmente, as RNNs têm sido utilizadas com bastante eficiência em áreas, como: Processamento de Linguagem Natural (PLN), tradução automática e previsão de séries temporais (FAN *et al.*, 2019).

2.7.3 Long Short-Term Memory

Um problema enfrentado pelas RNNs de longa duração é o fato de que as memórias das primeiras entradas desaparecem gradualmente, durante um longo período de treinamento. Para treinar uma RNN com sequências muito longas, será necessário executá-la ao longo de vários intervalos de tempo e, como qualquer rede neural profunda, isso poderá demorar muito e ela acabará sofrendo com o problema dos gradientes *vanishing/exploding* (GÉRON, 2019).

Os gradientes calculados para o ajuste dos pesos podem ficar muito grandes ou tão pequenos, a ponto de desaparecerem, à medida que avança para camadas inferiores. Como resultado, a atualização do gradiente descendente deixa os pesos de conexão da camada inferior praticamente inalterados e o treinamento nunca converge para uma boa solução. Este problema

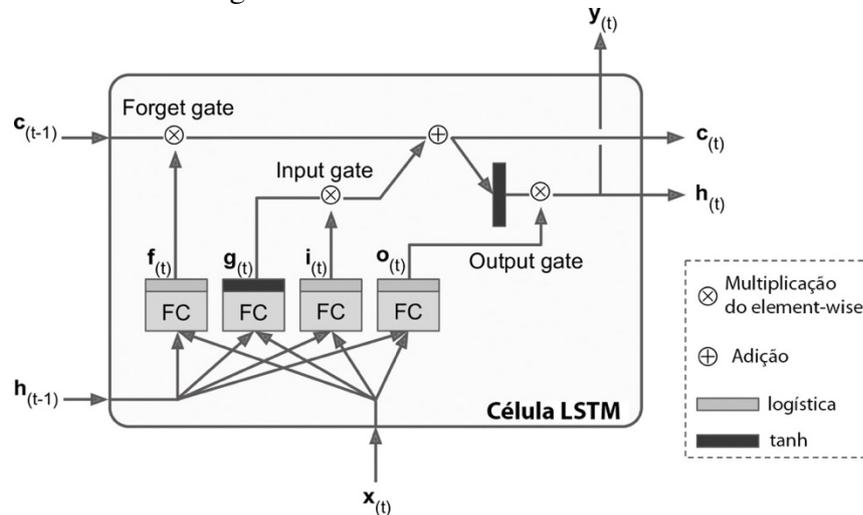
é conhecido como *vanishing gradient*. Em outras situações, os gradientes podem crescer cada vez mais, as camadas recebem atualizações de peso muito grandes e o algoritmo diverge, o que é chamado de *exploding gradient* (GÉRON, 2019).

As *Long Short Term Memory* (LSTM) foram propostas por Hochreiter e Schmidhuber (1997), como uma solução para as dependências de longo prazo que as RNNs sofriam (MELO *et al.*, 2019).

LSTM é uma arquitetura específica de RNN que foi projetada para modelar sequências temporais. Elas têm dependências de longo alcance que a tornam mais precisa do que as RNNs convencionais (SALMAN *et al.*, 2018).

Ao contrário das RNNs, as LSTM contêm unidades especiais chamadas blocos de memória, na camada oculta recorrente. Estes blocos contêm células de memórias com autoconexões, que armazenam o estado temporal da rede, além de unidades multiplicativas especiais chamadas de portas para controlar o fluxo de informações. Cada bloco de memória na arquitetura original contém três tipos de portas: *input gate*, *output gate* e *forget gate* (SALMAN *et al.*, 2018). A Figura 20 ilustra a arquitetura de uma célula de memória LSTM.

Figura 20 - Célula de memória LSTM



Fonte: Géron (2019).

A partir da Figura 20 é possível observar que dado um instante no tempo t , a célula LSTM possui como entradas o instante atual de alimentação de informação da rede, identificado como x_t , o estado oculto (*hidden state*) h_{t-1} e o estado da célula (*cell state*) c_{t-1} , ambos oriundos do instante de tempo anterior ($t - 1$). As saídas da célula são o estado atual da célula (*cell state*) c_t , o estado oculto atual (*hidden state*) h_t e a saída da informação y_t . Se a célula LSTM pertencer a última camada da rede, o h_t será interpretado como a saída final y_t . Por outro lado, se pertencer

a uma camada interna a rede, o h_t servirá como o h_{t-1} para a próxima camada da rede.

Uma vantagem das redes LSTM em relação a redes recorrentes comuns se dá pelo fato de que a primeira utiliza portas que permitem ajustes de peso com a capacidade de modificar (adicionar, descartar ou atualizar) as informações no tempo, de modo a prever melhor os estados futuros. Essa característica as torna ideais para o processamento de dados sequenciais no tempo, uma vez que este tipo de dado caracteriza-se pelo fato de que a previsão de um estado futuro depende do estado atual ou de um estado da rede em um momento anterior. Por isso, é fundamental que o modelo de rede neural seja capaz de associar de forma eficiente dados atuais a dados remotos no tempo, sem os inconvenientes dos problemas de *vanishing ou exploding gradients* (MESQUITA; OLIVEIRA; PEREIRA, 2019).

2.7.4 *ConvLSTM e Redes CNN-LSTM*

A CNNs e as RNNs são duas estruturas de redes neurais amplamente utilizadas. As primeiras são as arquiteturas especialmente adequadas ao processamento de dados bidimensionais (como imagens). Já as últimas foram desenvolvidas especificamente para o processamento de dados sequenciais com correlações entre amostras de dados (ZHANG; DONG; YUAN, 2020).

Entretanto, nos modelos que utilizam somente arquiteturas RNN (ou LSTM) com imagens como dados de entrada, as previsões são feitas *pixel a pixel* e não levam em consideração a distribuição espacial das informações. Por outro lado, quando o aspecto espaço-temporal deve ser modelado, as CNN são frequentemente empregadas (MOSKOLAĪ et al., 2020).

Para conseguir melhores resultados em trabalhos que buscam previsão, usando imagens como entrada, Shi *et al.* (2015) propuseram a fusão das funcionalidades das arquiteturas CNN e LSTM, com o objetivo de criar uma arquitetura híbrida, chamada *ConvLSTM*. Ela foi desenvolvida, inicialmente, para ser utilizada com dados espaço-temporais de duas dimensões (2D), como imagens de satélite (MOSKOLAĪ et al., 2020).

Ao combinar estas duas arquiteturas, é possível utilizar o poder de representação da CNN, além de também empregar a capacidade de modelagem de contexto das RNNs. Com isso, a porção CNN do modelo poderá extrair boas características dos dados de entrada e ajudar a aprender dependências espaciais efetivas entre os recursos presentes na imagem. Enquanto isso, as informações de contexto codificadas pela porção RNN do modelo podem levar a uma melhor representação da imagem e transmitir supervisões mais precisas para as camadas CNN durante

a etapa de treinamento (ZHANG; DONG; YUAN, 2020).

A arquitetura *ConvLSTM* substitui todas as operações lineares por camadas de convolução, para capturar dependências espaciais, além da modelagem de longo prazo, e muitas de suas variantes alcançaram resultados impressionantes na previsão espaço-temporal (LIN *et al.*, 2020).

Outra abordagem para trabalhar com dados espaço-temporais é combinar camadas CNN e LSTM, utilizando um bloco após o outro. Tal arquitetura é chamada de *Convolutional-LSTM* (CNN-LSTM) e foi originalmente chamada de *Long-Term Recurrent Convolutional Network* (LRCN). Na primeira parte deste modelo, camadas convolucionais extraem características importantes dos dados de entrada e os resultados são achatados em tensor de uma dimensão (1D) para serem usados como entrada para a segunda parte do modelo (LSTM). Finalmente, antes de passar os dados para a última camada oculta, as informações são reformuladas na forma original dos dados de entrada (MOSKOLAÏ *et al.*, 2020).

2.8 Métodos de Redes Neurais Artificiais usados em estudos de dinâmica costeira

A quantidade de dados disponíveis a respeito de sistemas costeiros aumentou muito nos últimos anos. Aliado a isso, os dados possuem grandes extensões espaciais e temporais, alta resolução e alta disponibilidade, o que permite a criação de aplicações e modelos voltados à dinâmica costeira (GOLDSTEIN; COCO; PLANT, 2019).

Como os dados observacionais sempre foram a base para desenvolver relações empíricas ou testar modelos quantitativos, o volume de dados disponíveis e a não linearidade dos processos subjacentes, além do aumento do poder computacional levaram a um interesse renovado em pesquisas com a utilização de modelos de aprendizagem de máquina profunda (GOLDSTEIN; COCO; PLANT, 2019).

Kerh, Lu e Saunders (2014) utilizaram imagens dos anos de 1990, 2001 e 2010 de seis praias da ilha de *Taiwan*, para monitorar as mudanças nas linhas de costa destas áreas. As imagens de cada um dos anos foram carregadas no pacote de software *AutoCAD*, onde comparou-se a tendência de variação da linha de costa para esses diferentes anos. Em seguida, eles utilizaram um modelo que implementou redes neurais artificiais, para estimar a variação da linha de costa nos anos de 2015 e 2020. Os resultados apontaram que não houve alteração significativa da área arenosa das praias, nos três diferentes períodos. Entretanto, os resultados da previsão indicaram que duas das seis praias poderiam apresentar um aumento da área total de areia, com um intervalo de confiança de 95%.

Em sua pesquisa, Peponi, Morgado e Trindade (2019) implementaram uma ferramenta robusta, combinando SIG e RNAs, para prever as áreas que são mais propensas à erosão costeira, na costa de Caparica em Portugal. Os autores testaram duas topologias de RNAs: a Rede de funções de base radial (RBF) e o *Perceptron* multicamada (do inglês, *Multilayer Perceptron* - MLP). O modelo proposto combinou o uso dos softwares ArcGIS, STATISTICA e IDRISI, onde o primeiro teve a função de organizar os bancos de dados geográficos e visualizar os resultados. O IDRISI foi utilizado para transferir os dados do banco de dados para o STATISTICA. Este, por sua vez, foi utilizado para executar os modelos de redes neurais. Após a etapa de treinamento, os resultados apontaram que o MLP é mais adequado para o tipo de dado analisado e, por isso, foi utilizado na implementação do método. A saída de rede foi apresentada em forma de mapa temático, com uma classificação da área em diferentes níveis de erosão, variando entre baixa, média, alta e sem alteração.

Em seu trabalho, Yin *et al.* (2021) criaram um modelo de previsão com a implementação do modelo estatístico SARIMA (*Seasonal Auto-regressive Integrated Moving Average*), em conjunto com dois modelos de aprendizado de máquina, utilizando Redes Neurais Auto-regressivas e LSTM, com o objetivo de estimar as variações da linha costeira de *Nha Trang*, no Vietnã, a partir de imagens de câmeras de vigilância. Os resultados apontaram que este modelo é altamente eficiente na detecção de linhas de costa, mesmo em condições climáticas extremas.

Bujak *et al.* (2021) aplicaram uma abordagem com RNA para prever a variabilidade espacial da deposição de cascalho, na costa da Croácia. Para isso, foram utilizados como dados de entrada para o modelo o volume de sedimentos, no período de 2016 a 2020, além de dados sobre ventos, marés e dados pluviométricos para treinar e testar o modelo de rede neural implementado. Para avaliar a performance do modelo, os autores utilizaram o *Mean Square Error* (MSE).

Tiggeloven *et al.* (2021) exploraram a capacidade de quatro abordagens de RNAs, como redes neurais de múltiplas camadas, redes neurais convolucionais, células de memória LSTM e o modelo híbrido *ConvLSTM*, para prever as oscilações da variabilidade do nível do mar, com base nas condições atmosféricas locais. Para a condução dos estudos, foram utilizados dados atmosféricos de 736 estações de maré. Para avaliar o desempenho de cada um dos modelos apresentados, os autores utilizaram o *Continuous Ranked Probability Score* (CRPS). Este índice calcula a média da diferença entre as distribuições cumulativas observadas e as previstas, em todas as etapas de tempo. Os resultados apontaram que os modelos de redes neurais são capazes de capturar a evolução das ondas, através de uma série temporal, obtendo um desempenho médio de CRPS maior que 40%.

Li *et al.* (2020) implementaram uma arquitetura híbrida de RNA, composta por camadas CNN e LSTM. O objetivo do trabalho foi monitorar o Motor de areia, projeto que cobre cerca de 4,7 km da costa holandesa e que foi construído em 2011, para reforçar a linha costeira e proteger contra inundações. A ideia é estimar a sua evolução morfológica. Para isso, eles utilizaram dados da área de estudo, coletados por GPS, no período de agosto de 2011 a setembro de 2015. Os dados de entrada foram convertidos em grades interpoladas de célula 20 x 20 m, para servirem como entrada para a porção CNN do modelo. Para avaliar a eficácia do modelo de provisão proposto, os autores utilizaram os índices MAE, RMSE, Coeficiente de correção Person e o Índice de Concordância. Eles obtiveram como resultado para cada um desses índices os valores 0.4555, 0.7574, 0.9902 e 0.9946, respectivamente.

3 METODOLOGIA

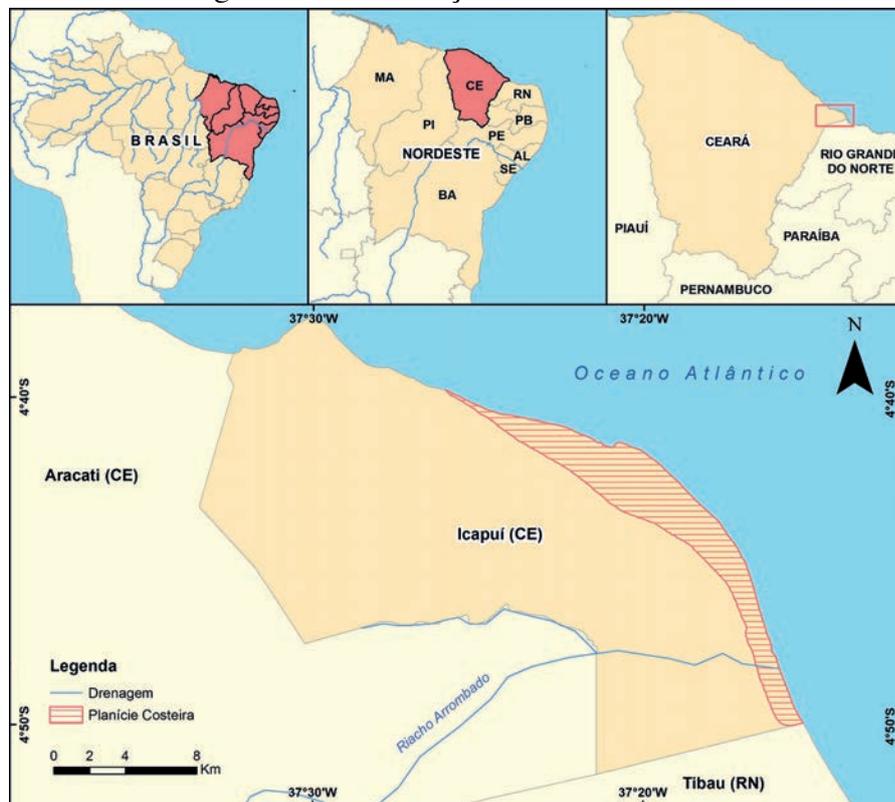
Este capítulo apresenta a área de estudo e os procedimentos metodológicos utilizados para atingir os objetivos da pesquisa. A Seção 3.1 caracteriza a área de estudo, apresentando sua localização, os seus aspectos geológicos e geomorfológicos, além dos aspectos hidrodinâmicos. A Seção 3.2 apresenta as etapas e os procedimentos metodológicos utilizados na pesquisa.

3.1 Caracterização da Área de Estudo

Para a aplicação do modelo de prognóstico de evolução costeira, foi utilizado como estudo de caso o município de Icapuí, no Estado do Ceará.

O município de Icapuí fica a cerca de 190 km da capital, Fortaleza, e está localizada na porção setentrional do Nordeste brasileiro, no Estado do Ceará, já no limite com o Estado do Rio Grande do Norte. A localização de Icapuí pode ser visualizada na Figura 21.

Figura 21 - Localização da área de estudo



Fonte: Silva Neto *et al.* (2019).

A planície costeira de Icapuí é uma área que ainda gera discussões a respeito dos fenômenos geológicos que condicionaram sua formação. Ela possui uma forma convexa, com aproximadamente 30 quilômetros de extensão de litoral, sendo limitada a norte pelo Oceano Atlântico, a sul por rochas sedimentares de falésias inativas e a sudeste pela fronteira com o município de Tibau, localizado no Estado do Rio Grande do Norte (SILVA NETO *et al.*, 2019).

Além disso, a área de estudo tem como característica o clima semiárido, de poucas chuvas (média de 800 mm ao ano), geologicamente composta por sedimentos do Quaternário (depósitos de praia, de dunas e flúvio-marinho) e por rochas sedimentares Tércio-quadernárias (Mioceno) e geomorfologicamente é composta por praias areias, bancos de areias, estuários e falésias com 45 metros de altura (SOUSA *et al.*, 2018).

O litoral do município de Icapuí sofre influência do transporte eólico e da dinâmica costeira, que são responsáveis por variações na taxa de erosão e deposição sedimentar, promovendo mudanças no fluxo de canais de marés e variações de balanço sedimentar da linha de costa pela interação entre aporte sedimentar e espaço de acomodação, dando origem a processos de progradação e retrogradação da linha de costa (MOREIRA; ROMARIZ; SOUTO, 2014; SANTOS; AMARO; SOUTO, 2011).

3.2 Procedimentos Metodológicos

A metodologia proposta neste trabalho teve como objetivo desenvolver um modelo computacional, através da implementação de algoritmo de regressão linear e uma arquitetura híbrida de RNAs, para estimar a tendência de evolução dos processos erosivos presentes em ambientes costeiros.

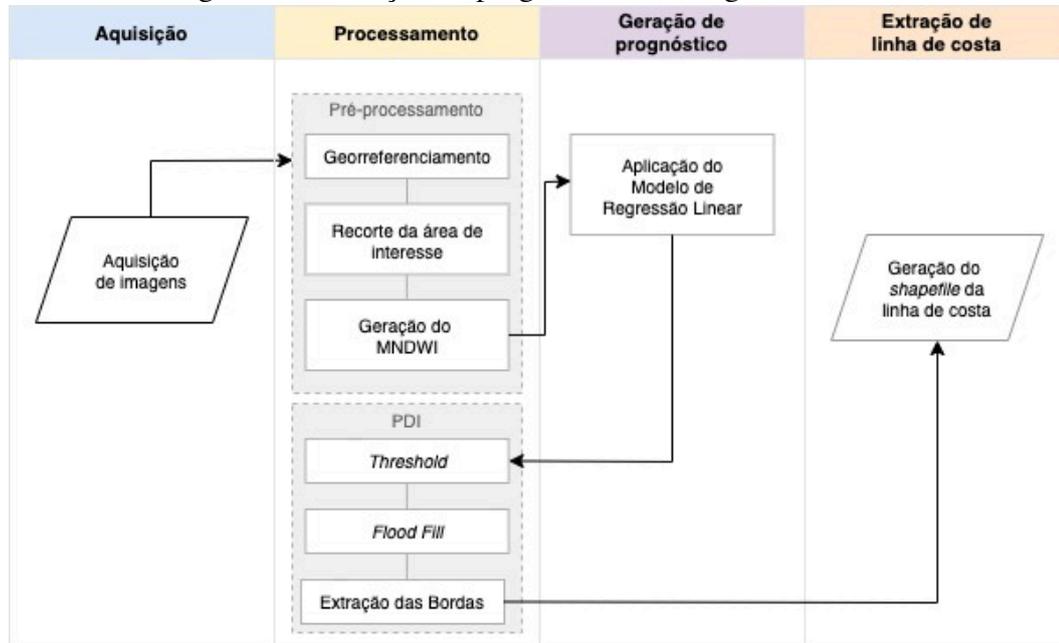
Os procedimentos metodológicos foram criados com base na análise das técnicas utilizadas pelos autores citados no capítulo anterior, visando o aprimoramento de um método capaz de estabelecer um processo automatizado de extração de linhas de costa e geração de cenários futuros, através de séries temporais de imagens de Sensoriamento Remoto.

Para esta finalidade, as etapas da metodologia foram, inicialmente, divididas em duas fases. A primeira fase teve como objetivo a geração de prognóstico e extração automática de linha de costa, utilizando um algoritmo de regressão linear. A segunda fase, por sua vez, utilizou uma arquitetura híbrida de RNAs para a extrapolação de imagens, a partir de setores da linha de costa do município de Icapuí-CE.

As Figuras 22 e 23 apresentam, respectivamente, as duas fases da metodologia, ilustrando cada um dos procedimentos metodológicos presentes em cada uma das fases. Tais

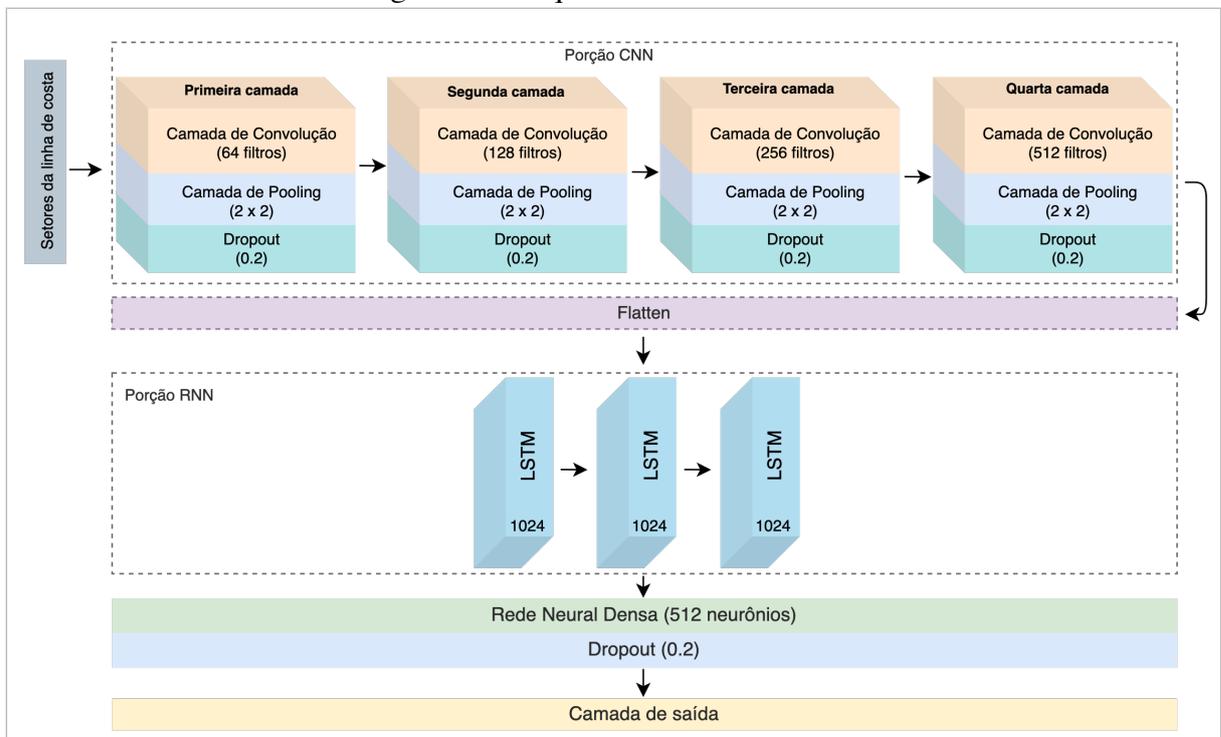
procedimentos são descritos em detalhes nas subsecções a seguir.

Figura 22 - Geração de prognóstico com regressão linear



Fonte: elaborada pelo autor.

Figura 23 - Arquitetura híbrida CRNN



Fonte: elaborada pelo autor.

3.2.1 Geração de prognóstico utilizando Regressão Linear

Como pode ser visualizado na Figura 22, a primeira fase da metodologia foi dividida em cinco etapas: (1) aquisição de imagens; (2) pré-processamento das imagens; (3) geração de prognóstico; (4) Processamento Digital de Imagens e (5) geração de linhas de costa automatizadas em formato vetorial (*shapefile*).

3.2.1.1 Aquisição de imagens

A primeira fase do estudo teve como objetivo a aquisição de uma série temporal de imagens que seriam utilizadas para geração de cenários futuros.

Assim, foram utilizadas as imagens dos satélites Landsat 5-TM e Landsat 8-OLI, para os anos de 1985, 1991, 1997, 2003, 2009 e 2015, como forma de estimar a tendência de evolução costeira dos processos erosivos que ocorrem no município de Icapuí.

As imagens Landsat foram escolhidas por pertencer a um grande acervo, que ajuda na implementação de trabalhos que visam monitorar uma determinada região, por um grande período de tempo. Além disso, a sequência escolhida possui um intervalo de anos fixo, para que o modelo consiga ter mais eficiência na geração do prognóstico futuro. Durante a escolha do intervalo também foi considerado o fato de possuir muita cobertura de nuvens. Além disso, outro aspecto importante para a escolha da sequência de imagens com essa resolução é que as zonas costeiras possuem uma ampla área territorial.

A Tabela 3 disponibiliza as informações sobre as imagens, tais como o ano de referência, a data, as cenas, as bandas e os sensores utilizados.

Tabela 3 - Imagens Landsat 5-TM e Landsat 8-OLI utilizadas no estudo

Ano	Data	Cena	Bandas	Sensor
1985	27/06/1985	216/63	2 e 5	TM
1991	15/08/1991	216/63	2 e 5	TM
1997	02/10/1997	216/63	2 e 5	TM
2003	15/07/2003	216/63	2 e 5	TM
2009	31/07/2009	216/63	2 e 5	TM
2015	01/08/2015	216/63	3 e 6	OLI

Fonte: elaborada pelo autor.

3.2.1.2 Pré-processamento de imagens

Após adquiridas, as imagens foram pré-processadas usando técnicas de correções atmosféricas e radiométricas para que todas apresentassem valores da reflectância similares

entre elas. Além disso, todas as cenas utilizadas foram georreferenciadas a partir de uma imagem base ortorretificada do ano de 2009 pelo Programa *Global Land Surveys* (GLS), obtida no site da *United States Geological Survey* (USGS).

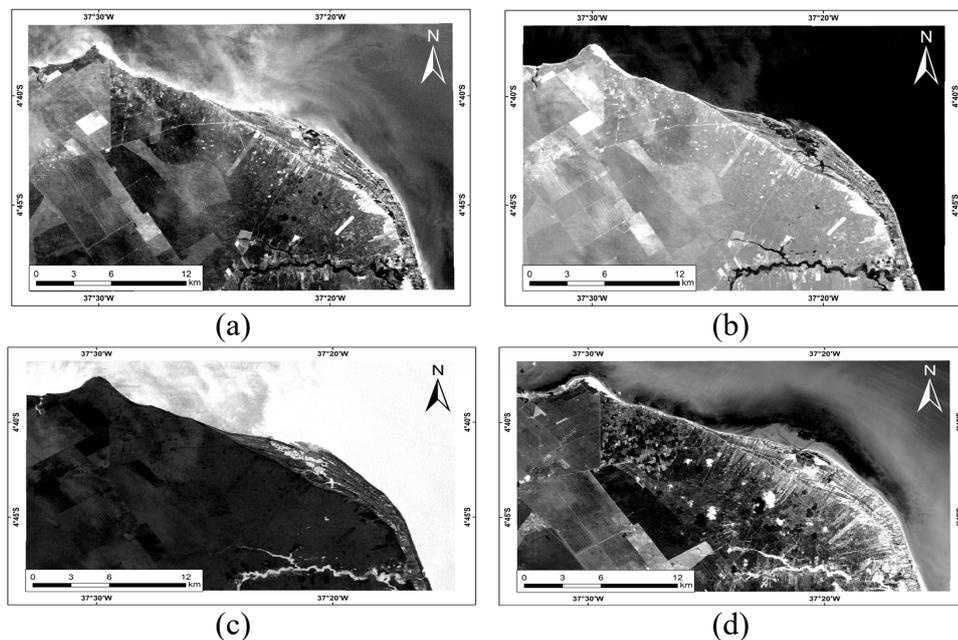
Uma vez georreferenciadas, as imagens foram submetidas a extração do *Modified Normalized Difference Water Index* (MNDWI), que permite distinguir, de maneira eficiente, a informação de corpos d'água das demais, tais como: solo, edificações e vegetação (GONÇALVES et al., 2015). A geração do MNDWI foi realizada através da aplicação da Equação 6 (GAUTAM et al., 2015):

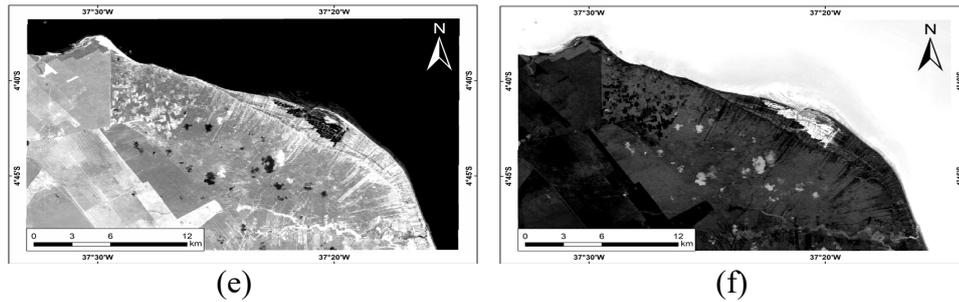
$$\text{MNDWI} = \frac{\text{Green} - \text{SWIR } 1}{\text{Green} + \text{SWIR } 1} \quad (6)$$

A Figura 24 apresenta as bandas do satélite Landsat utilizadas na Equação 6 e as imagens MNDWI geradas para os anos de 1985 e 2015 a partir delas.

As Figuras 24(a) e 24(b) ilustram, respectivamente, as bandas 2 e 5 usadas para gerar o MNDWI de 1985 (Figure 24(c)). Da mesma forma, as Figuras 24(d) e 24(e), apresentam as bandas 3 e 6 usadas para a geração da imagem MNDWI do ano de 2015 (Figura 24(f)).

Figura 24 – Geração das imagens MNDWI para os anos de 1985 e 2015: (a) Banda 2 (*green*) do ano de 1985, (b) Banda 5 (*Swir 1*) do ano de 1985, (c) MNDWI do ano de 1985 gerado a partir da aplicação da Equação 6, (d) Banda 3 (*green*) do ano de 2015, (e) Banda 6 (*Swir 1*) do ano de 2015 e (f) MNDWI do ano de 2015 gerado a partir da Equação 6.





Fonte: elaborada pelo autor.

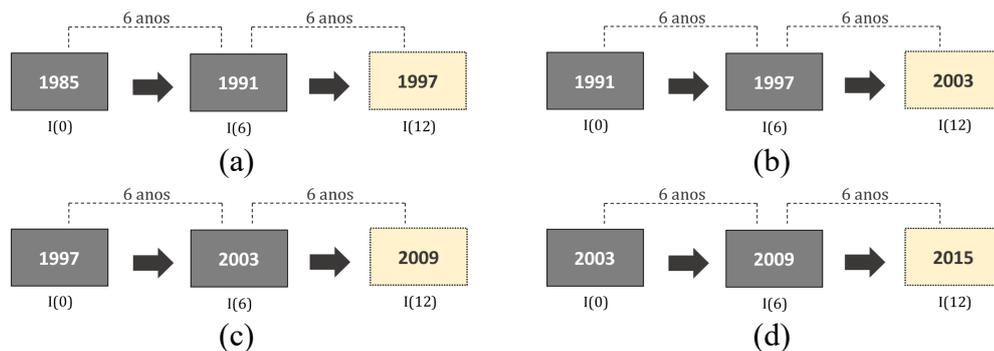
3.2.1.3 Geração de Prognóstico Futuro

Para a geração de prognósticos futuros foi utilizado o método de regressão estatística proposto por Sousa *et al.* (2012).

Assim, de acordo com as Equações 2, 3, 4 e 5, para extrapolar imagens, usando o método de regressão linear é necessário utilizar duas sequências de imagens de anos anteriores.

A Figura 25 ilustra o esquema de extrapolação de imagens, utilizando o método de regressão linear, para os anos de 1997, 2003, 2009 e 2015.

Figura 25 – Geração das imagens MNDWI para os anos de 1997, 2003, 2009 e 2015 pelo método de regressão linear: (a) Extrapolação do MNDWI para o ano 1997, (b) Extrapolação do MNDWI para o ano de 2003, (c) Extrapolação do MNDWI para o ano de 2009 e (d) Extrapolação do MNDWI para o ano de 2015



Fonte: elaborada pelo autor.

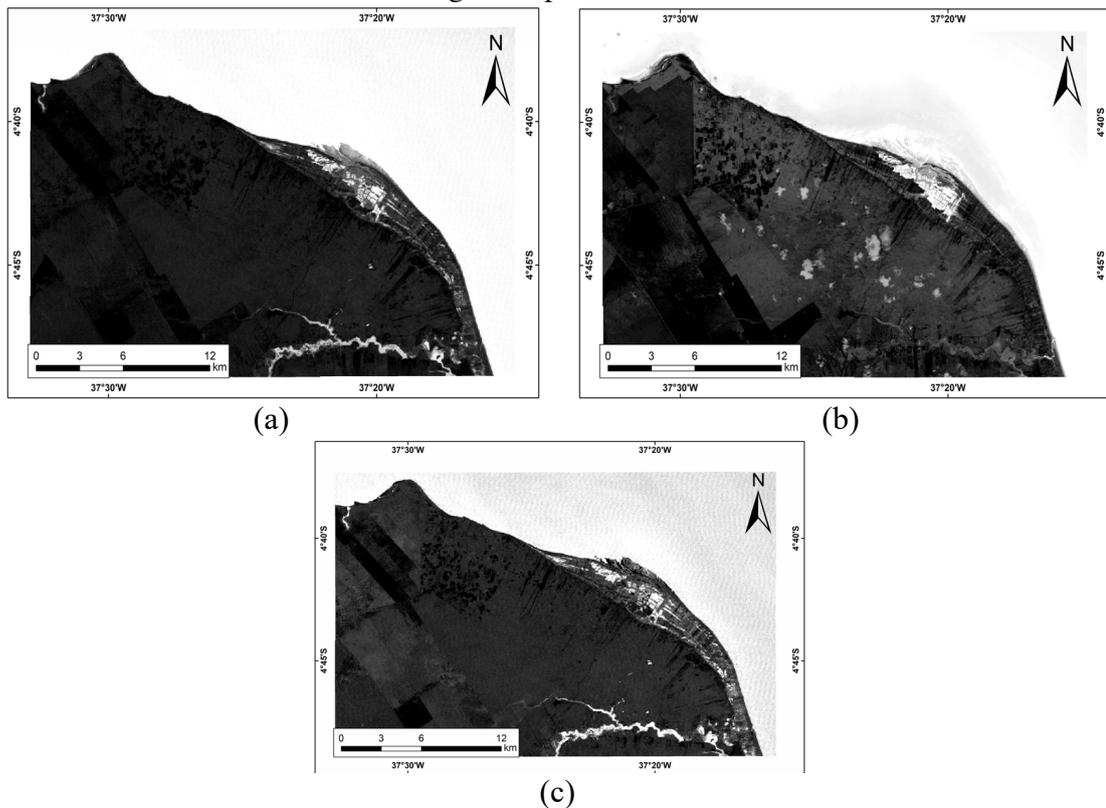
Como pode ser verificado na Figura 25, a primeira imagem da sequência corresponde ao instante inicial de tempo ($t = 0$). Assim, por exemplo, a imagem de 1985 é chamada $I(0)$ (ou seja, a imagem no tempo 0). Como a variação temporal é de 6 (seis) anos entre cada uma das imagens da sequência, a imagem de 1991 é chamada $I(6)$. Por sua vez, a imagem que se pretende extrapolar é chamada $I(12)$.

Assim, para gerar o prognóstico do MNDWI para o ano de 2021, foram utilizadas as

imagens dos anos de 2009 e 2015. A Figura 26 apresenta o MNDWI gerado, utilizando a Equação 2.

As Figuras 26(a) e 26(b) exibem as imagens MNDWI do ano de 2009 e 2015, respectivamente. Por sua vez, a Figura 26(c) apresenta o MNDWI gerado para o ano de 2021, com base nas duas imagens anteriores.

Figura 26 – Geração do MNDWI do ano de 2021 a partir dos anos de 2009 e 2015, através do modelo de Regressão Linear: (a) MNDWI do ano de 2009, (b) MNDWI do ano de 2015 e (c) MNDWI gerado para o ano de 2021



Fonte: elaborada pelo autor.

3.2.1.4 Processamento Digital de Imagens

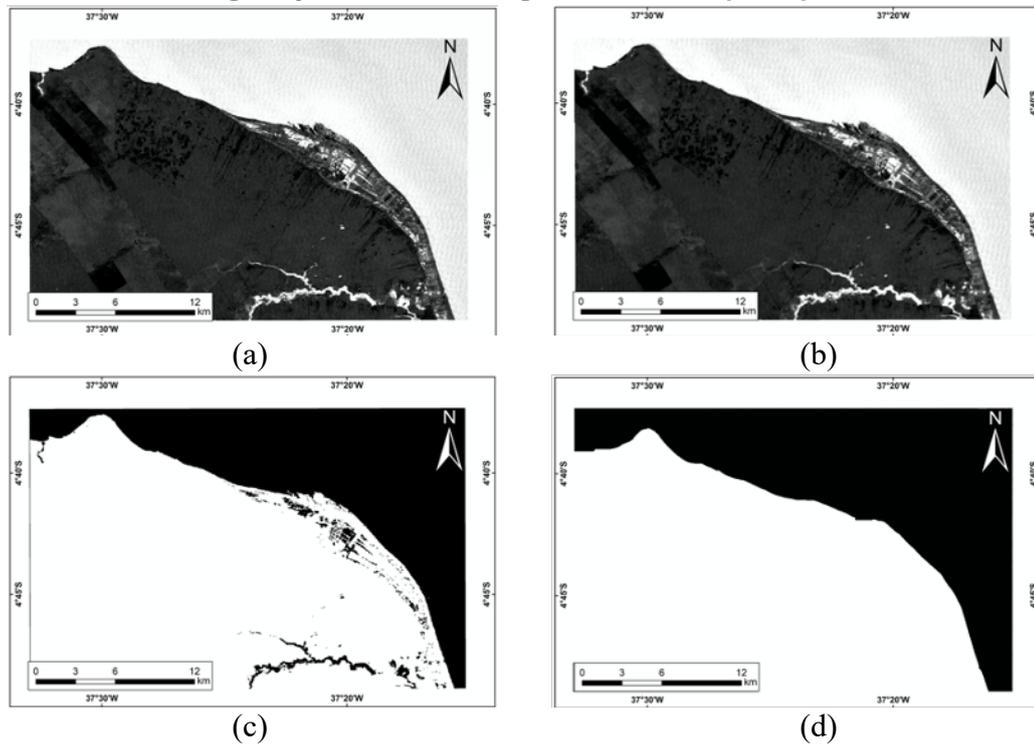
Através do uso da biblioteca OpenCV[®], juntamente com a linguagem Python[™], foram aplicadas as técnicas de filtro Gaussiano e Binarização (*Threshold*).

A primeira técnica teve como objetivo remover o excesso de ruído da imagem. Já a última, foi utilizada para separar as regiões de cada imagem em duas classes, neste caso, o fundo e o objeto de interesse. E por fim, foi aplicada a técnica de preenchimento (*flood fill*) para preencher os espaços vazios de cada imagem.

A Figura 27 apresenta o resultado a aplicação das técnicas de Processamento Digital de Imagens (PDI), proposta na metodologia. A Figura 27(a) exhibe a imagem MNDWI gerada para

o ano de 2021. Por sua vez, a Figura 27(b) apresenta o MNDWI de 2021 após a aplicação do filtro Gaussiano. E, por fim, a Figura 27(c) apresenta o MNDWI de 2021 após a aplicação da técnica *flood fill*.

Figura 27 – Técnicas de Processamento Digital de Imagens aplicadas no MNDWI de 2021: (a) MNDWI gerado para o ano de 2021, (b) MNDWI de 2021 após a aplicação do filtro Gaussiano, (c) MNDWI de 2021 após a etapa de binarização, (d) MNDWI de 2021 depois da aplicação da técnica de preenchimento (*flood fill*)



Fonte: autoria própria.

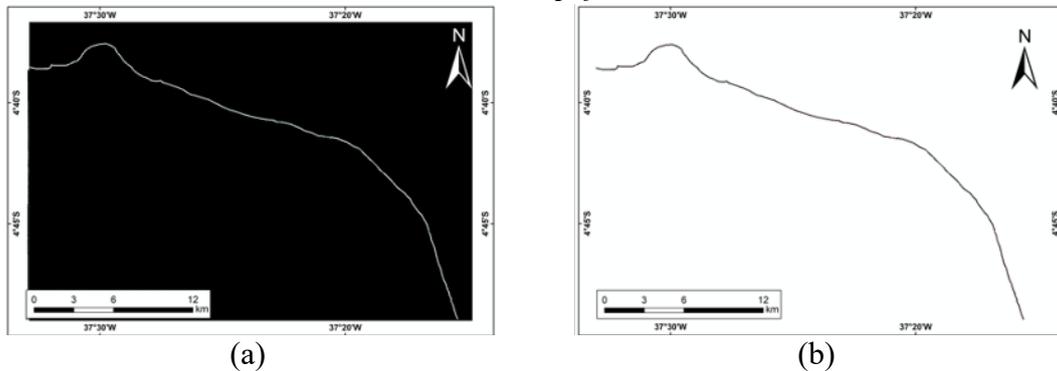
3.2.1.5 Extração de linha de costa

Para a extração da linha de costa, utilizou-se o algoritmo de detecção de bordas proposto por Canny (1986). Através deste algoritmo, implementado em Python em conjunto com a biblioteca OpenCV®, foi possível extrair apenas a linha de costa a partir das imagens binárias processadas anteriormente (SOUSA *et al.*, 2017).

Por fim, foi necessário converter a borda extraída na etapa anterior, em um arquivo vetorial no formato *shapefile*. Para esta finalidade, foi utilizada a biblioteca *Shapely*.

A Figura 28 apresenta a linha de costa extraída a partir da imagem MNDWI do ano de 2021. A Figura 28(a) apresenta a imagem contendo a linha de costa, após a aplicação do algoritmo de detecção de bordas. Já a Figura 28(b) ilustra a linha de costa de 2021, convertida em formato *shapefile*.

Figura 28 – Linha de Costa do ano de 2021: (a) Linha de costa do ano de 2021, após a aplicação do algoritmo de detecção de bordas e (b) Linha de costa do ano 2021 em formato *shapefile*



Fonte: elaborada pelo autor.

3.2.2 Geração de prognóstico utilizando Redes Neurais

Na primeira fase da metodologia, gerou-se um modelo de prognóstico de erosão costeira, baseado na série temporal dos anos de 1985 a 2015, utilizando-se o modelo de Regressão Linear. Com isso, foi possível detectar alguns setores da linha de costa da área de estudo, que tiveram maiores alterações durante os anos.

Posteriormente, a segunda fase da metodologia teve o objetivo de monitorar tais setores, aplicando algoritmos de redes neurais artificiais, mais especificamente o modelo híbrido CNN-LSTM, para extrapolar séries de imagens de toda a linha de costa da área de estudo.

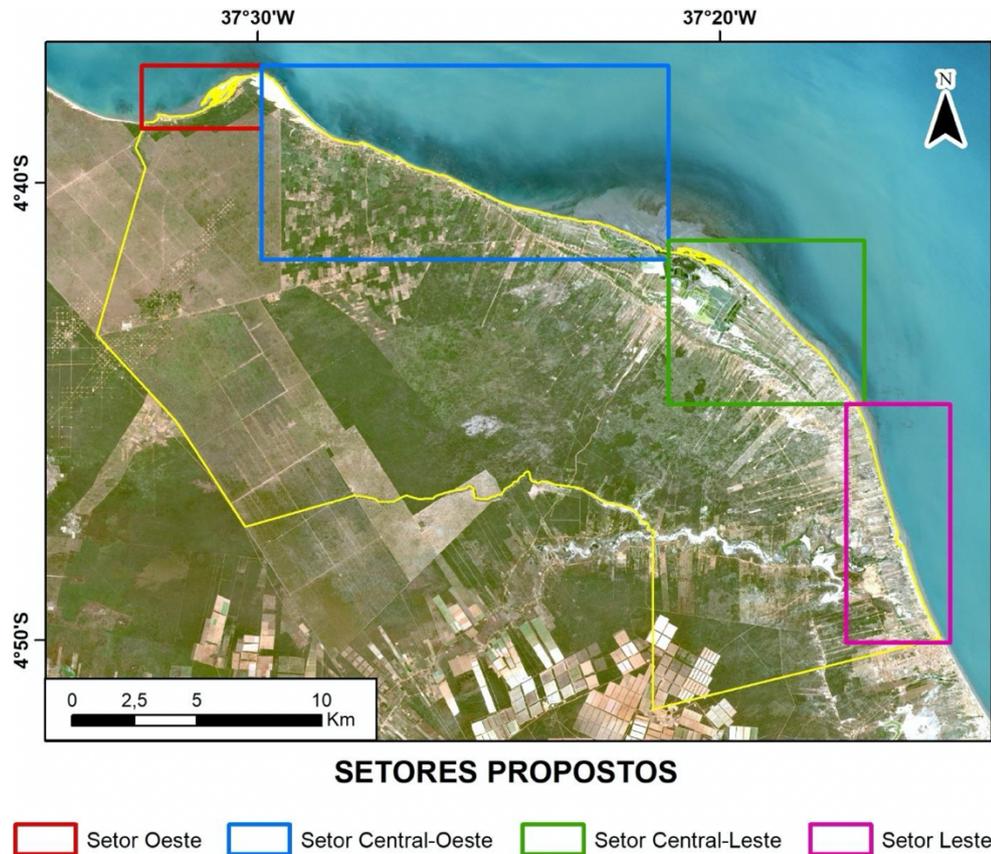
Como apresentado na Figura 23, nesta fase, a metodologia foi dividida em 6 (seis) etapas: (1) divisão dos setores da linha de costa; (2) aquisição e pré-processamento de imagens; (3) divisão da sequência de imagens em entradas e saída; (4) aplicação da camada CNN do modelo; (5) aplicação da camada de RNN do modelo; e (6) aplicação de rede neural densa.

A arquitetura CNN-LSTM proposta neste trabalho foi implementada na linguagem *Python*, utilizando-se as bibliotecas *Sklearn* e *Keras*.

3.2.2.1 Divisão dos setores da linha de costa

Inicialmente, a linha de costa foi dividida nos setores Oeste, Central-Oeste (porção A e B), Central-Leste e Leste, conforme definido por Silva Neto (2019). O setor Central-Oeste foi dividido ao meio, em duas porções, devido a limitações no processamento computacional. A Figura 29 apresenta a disposição espacial dos quatro setores.

Figura 29 - Localização dos quatro setores utilizados no estudo



Fonte: Silva Neto (2019) (com adaptações).

3.2.2.2 Aquisição e pré-processamento de imagens

Em seguida, foram selecionadas imagens Landsat 5-TM e Landsat 8-OLI, dos seguintes anos: 1988, 1993, 1998, 2003, 2008, 2013 e 2018. Elas foram utilizadas como a série temporal para treinamento do modelo de rede neural.

A sequência de imagens foi pré-processada, utilizando-se as mesmas técnicas apresentadas na Seção 3.2.1.2.

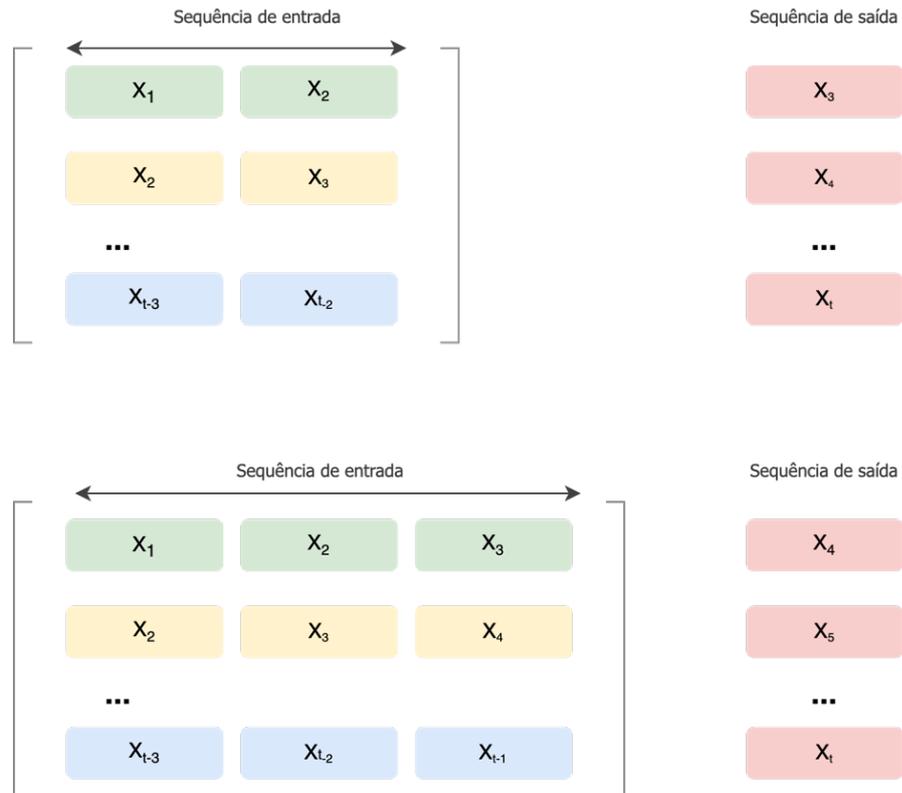
3.2.2.3 Divisão da sequência de imagens em entradas e saída

Após a divisão da linha de costa em setores, a sequência de imagens de cada um deles foi dada como entrada para o algoritmo de redes neurais, utilizando uma sequência de série temporal de imagens.

Por tratar-se de uma série temporal, a sequência foi dividida de duas formas diferentes, para que fosse avaliado qual o melhor formato de entrada para o algoritmo. Desta forma, foram

considerados dois formatos de sequência: (1) duas entradas e uma saída e (2) três entradas e uma saída, conforme a Figura 30.

Figura 30 - Divisão da sequência de imagens em entradas e saída



Fonte: elaborada pelo autor.

3.2.2.4 Aplicação da camada de rede neural convolucional

A arquitetura proposta foi composta por uma porção CNN e outra porção LSTM. A porção CNN incluiu 4 (quatro) camadas, cada uma delas possuindo uma camada de convolução, uma função de ativação, uma camada de *pooling* e uma camada de *Dropout*. Os parâmetros utilizados para a implementação da porção CNN da arquitetura estão apresentados na Tabela 4.

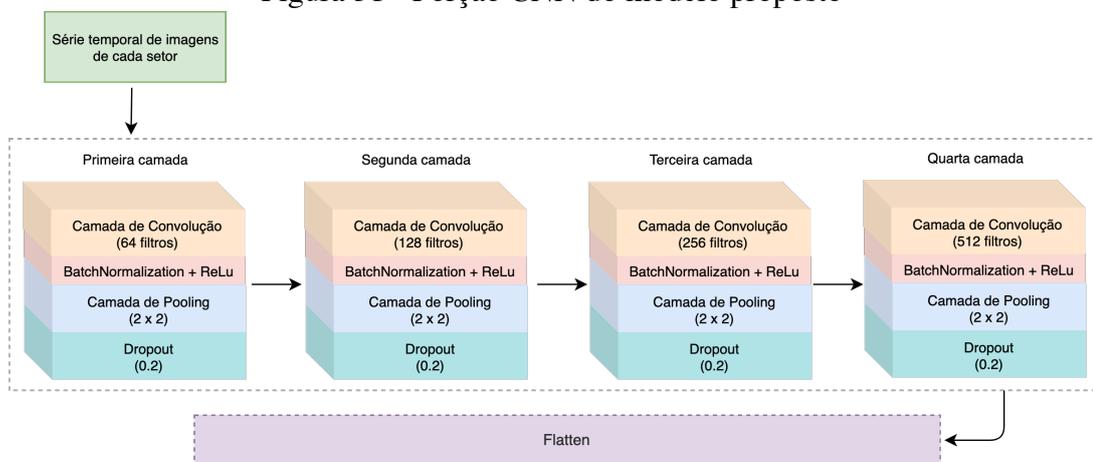
Tabela 4 - Parâmetros utilizados na porção CNN da arquitetura

Parâmetros	Valores
Camadas CNN	4
Filtros de convolução	64, 128, 256 e 512
Tamanho do filtro (<i>kernel</i>)	3 x 3
Função de ativação	<i>ReLU</i>
<i>Kernel</i> do <i>max pooling</i>	2 x 2
<i>Dropout</i>	0.2

Fonte: elaborada pelo autor.

Como pode ser observado na Tabela 4, a porção CNN foi implementada considerando quatro camadas de convolução, com 64, 128, 256 e 512 filtros de convolução, respectivamente. Após cada camada de convolução, foram adicionadas camadas de *pooling*, para reduzir a dimensionalidade de cada imagem, utilizando-se a técnica de *max pooling* e *kernel 2 x 2*. Em seguida, foi aplicada a técnica de *flatten*, para transformar as matrizes em um formato aceito pela próxima camada do modelo. A porção CNN implementada no trabalho é representada na Figura 31 e explicada nos parágrafos a seguir.

Figura 31 - Porção CNN do modelo proposto



Fonte: elaborada pelo autor.

Para executar o modelo CNN-LSTM, as sequências de imagens de entrada foram, inicialmente, convertidas em matrizes contendo os valores dos *pixels*. Assim, cada *pixel* das imagens foi avaliado com valores entre 0 e 255. Além disso, neste estudo, cada setor teve uma dimensão diferente, considerando as características de cada região da linha de costa, conforme a Tabela 5.

Tabela 5 - Dimensões de cada setor em *pixels*.

Setor	Dimensões
Leste	140 x 321 x 1
Central-Leste	262 x 221 x 1
Central-Oeste-porção A	272 x 262 x 1
Central-Oeste-porção B	271 x 262 x 1
Oeste	161 x 86 x 1

Fonte: elaborada pelo autor.

Desta forma, de acordo com a Tabela 5, o modelo recebeu como entrada uma matriz 3D com as dimensões $L \times A \times P$ (onde, L – largura; A – altura; e P – profundidade). A profundidade foi considerada com valor 1, pois as imagens de entrada possuem apenas uma banda.

Após dar entrada no algoritmo, estas matrizes foram manipuladas pela primeira camada de convolução. Tais camadas são compostas por matrizes que aplicam filtros de convolução. A primeira camada utilizou 64 filtros com *kernel* 3×3 , para extrair características de cada imagem da sequência. A segunda, terceira e quarta camada, utilizaram 128, 256 e 512 filtros, respectivamente.

Ao final do processo, cada imagem de entrada foi transformada em uma pilha de mapas de características. Entretanto, este processo acaba aumentando a dimensionalidade dos dados de entrada da rede. Devido a esta característica, após a camada de convolução, cada sequência de imagem passou por uma camada de *pooling*. Nesta nova camada, os mapas de características advindos da camada de convolução tiveram suas dimensões reduzidas. Para isso, utilizou-se a técnica de *Max pooling*, com *kernel* de tamanho 2×2 . Este processo repetiu-se nas camadas dois, três e quatro da arquitetura proposta.

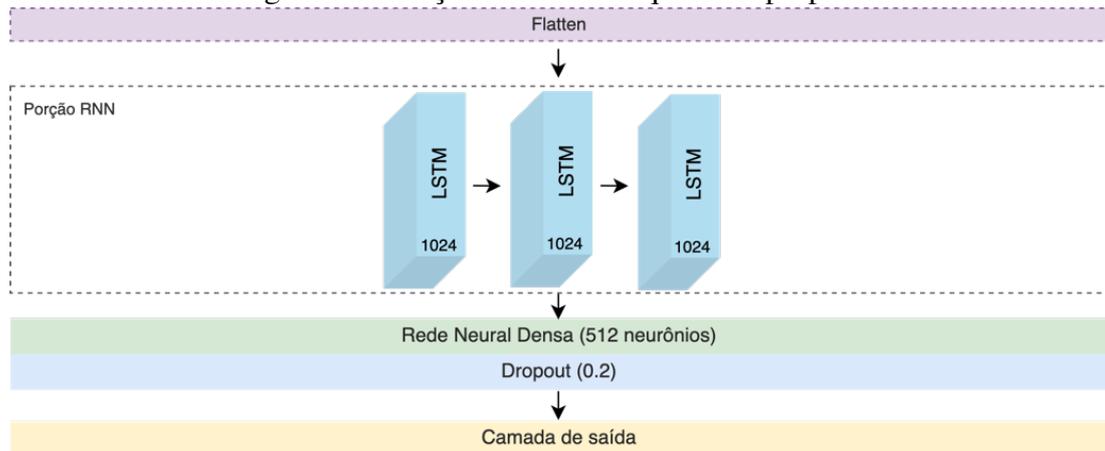
Também foi adicionada uma camada de *Dropout*, para evitar que determinadas partes da rede neural tivessem muita responsabilidade e, conseqüentemente, pudessem ficar muito sensíveis a pequenas alterações entre as imagens da série temporal.

Por fim, as matrizes passaram pela camada de *flatten*, para transformar seu formato em um *array* que serviu como entrada para a porção LSTM do modelo.

3.2.2.5 Aplicação da camada de rede neural recorrente

Após extrair as características espaciais da sequência de imagens, através da porção CNN do modelo, foi necessário a implementação de uma porção LSTM para capturar as relações temporais entre a sequência de dados de entrada. A porção LSTM da arquitetura proposta na metodologia está ilustrada na Figura 32.

Figura 32 - Porção LSTM da arquitetura proposta



Fonte: elaborada pelo autor.

Além disso, a Tabela 6 apresenta os parâmetros utilizados para a implementação da porção LSTM.

Tabela 6 - Parâmetros da porção LSTM

Parâmetros	Valores
Camadas LSTM	3
Células de memória LSTM	1024

Fonte: elaborada pelo autor.

De acordo com a Tabela 6, para extrair o aspecto temporal e poder extrapolar a sequência de imagens, foram implementadas 3 (três) camadas LSTM, cada uma composta por 1024 células de memória.

3.2.2.6 Rede Neural Densa

Por fim, a saída da porção LSTM serviu como entrada para a rede neural densa que finaliza o modelo e fornece os resultados. Esta camada foi implementada com 512 neurônios e foi aplicado *Dropout* em 20% deles.

Ela utilizou para o ajuste dos pesos a função *ReLU* e para a camada de ativação, utilizou a função Linear. Além disso, para executar o treinamento da rede, o modelo foi executado por 150 épocas (número de iterações).

4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados alcançados após a implementação da metodologia proposta. A Seção 4.1 apresenta os estimadores utilizados para avaliar o desempenho e a acurácia dos resultados. A Seção 4.2 discorre sobre os resultados obtidos com a primeira fase da metodologia, onde foi aplicado o método de regressão linear. Finalmente, a Seção 4.3 apresenta os resultados da segunda fase do método proposto, após a aplicação do modelo híbrido CNN-LSTM.

4.1 Avaliação dos Resultados

Após o processo de geração de prognóstico da linha de costa, foi necessário realizar o cálculo do nível de similaridade entre as imagens reais e as imagens extrapoladas.

Existe, entre outros estimadores, o *Mean Absolute Error* (MAE), que em Estatística, é uma métrica usada para medir o quão perto as estimativas estão dos resultados alcançados, além de ser uma medida comum para prever erros em análises de séries temporais.

Assim, o MAE pode ser utilizado para avaliar o erro entre os dados estimados por extrapolação numérica e os dados reais. O MAE é representado pela Equação 7, onde x_i é o valor real e y_i corresponde ao valor estimado e n representa o tamanho da amostra considerada na previsão.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (7)$$

Por tratar-se de um modelo mais complexo, na segunda fase da metodologia, além do MAE, foram utilizadas outras duas métricas para avaliar os resultados.

Um dos métodos aplicados foi o *Root Mean Squared Error* (RMSE). Esse método é uma regra de pontuação quadrática que também mede a magnitude média do erro. Ele é a raiz quadrada da média das diferenças quadradas entre a previsão e a observação real. O RMSE está representado na Equação 8, onde n representa o tamanho da amostra, x_i representa o valor real observado e y_i o valor previsto.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (8)$$

Além do RMSE, para avaliar a arquitetura de rede neural, foi utilizado o *Structural Similarity Index* (SSIM), que é outro método utilizado para medir a similaridade entre duas imagens (WANG *et al.*, 2004). A Equação 9 apresenta o SSIM, onde x e y representam as duas imagens comparadas, μ representa o valor médio, σ representa a variância e c_1 e c_2 são constantes.

$$\text{SSIM}(x, y) = \frac{(2\mu_x \mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (9)$$

Para realizar as comparações entre as linhas de costa reais e extrapoladas e para avaliar o desempenho do modelo CNN-LSTM, o MAE, o RMSE e o SSIM foram implementados através de um componente de software em linguagem *Python*.

4.2 Resultados do método de extrapolação por Regressão Linear

Os resultados apresentados nesta subseção foram retirados do artigo publicado em 2018 no *International Journal of Remote Sensing*, com o título “*Creation of a coastal evolution prognostic model using shoreline historical data and techniques of digital image processing in a GIS environment for generating future scenarios*”, como parte da elaboração desta tese de doutorado (SOUSA *et al.*, 2018).

A Tabela 7 apresenta o percentual de similaridade entre as imagens, após a execução do MAE. As colunas da tabela representam os anos que foram extrapolados pelo método de regressão linear e as linhas representam, respectivamente, o grau de similaridade e diferença, entre a linha de costa original e a linha de costa extrapolada (o valor máximo de similaridade é 100%).

Tabela 7 - Porcentagens de similaridades e diferenças calculadas pelo MAE, para os anos de 1997, 2003, 2009 e 2015

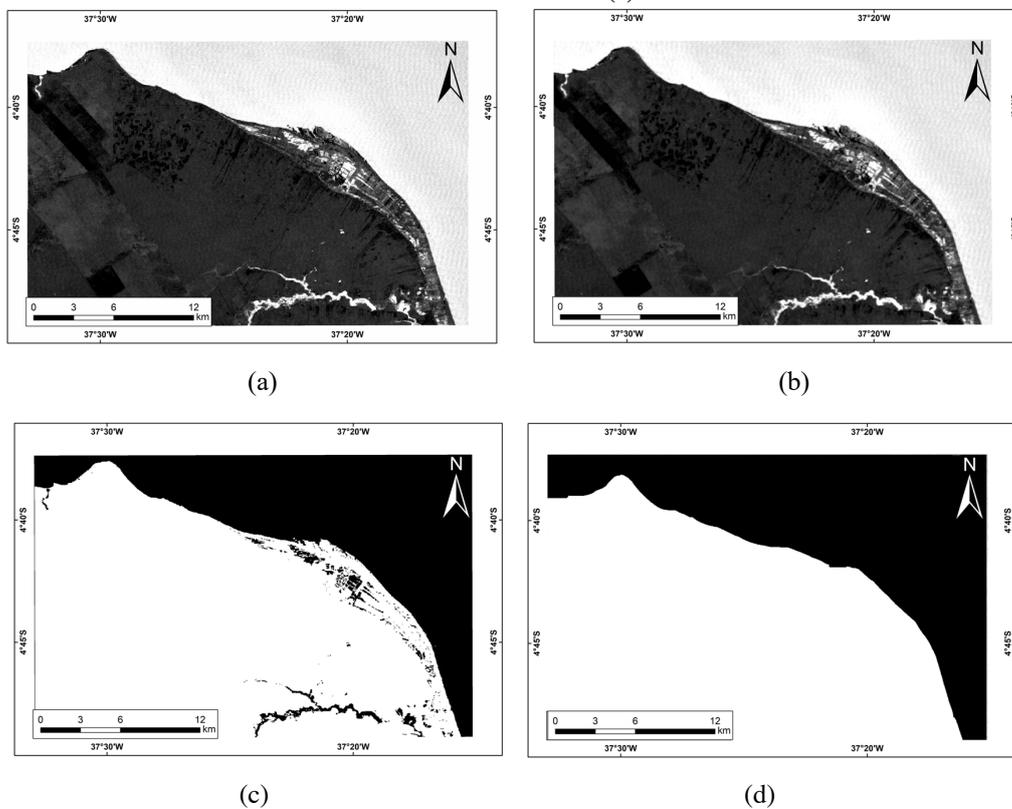
Análises	1997	2003	2009	2015
Similaridade (%)	94,92	96,14	96,40	93,04
Diferença (%)	5,18	3,86	3,60	6,96

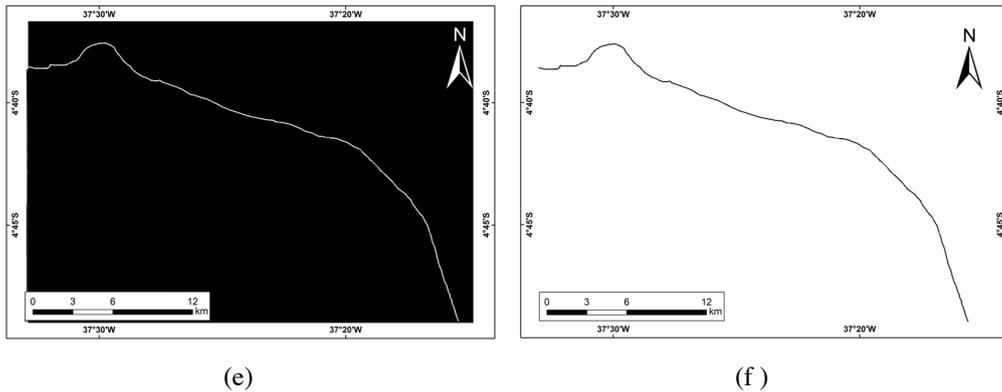
Fonte: elaborada pelo autor.

Como os resultados de MAE foram considerados relevantes, foram extraídos o MNDWI e as linhas de costa dos anos de 1985, 1991, 1997, 2003, 2009 e 2015 e foi gerado o prognóstico para o ano de 2021, além de extrair a linha de costa em formato vetorial (*shapefile*) deste ano.

A Figura 33 ilustra os resultados de cada uma das etapas apresentadas no capítulo anterior, para extrapolação e extração da linha de costa e apresenta a estimativa de linha de costa gerada para o ano de 2021.

Figura 33 - Resultado da geração e extração de linha de costa para o ano de 2021: (a) MNDWI gerado para 2021, (b) MNDWI de 2021 após a aplicação do filtro Gaussiano, (c) MNDWI de 2021 após a binarização, (d) MNDWI de 2021 após a técnica de *Flood Fill*, (e) Linha de costa de 2021 em formato TIFF e (f) Linha de costa em formato vetorial



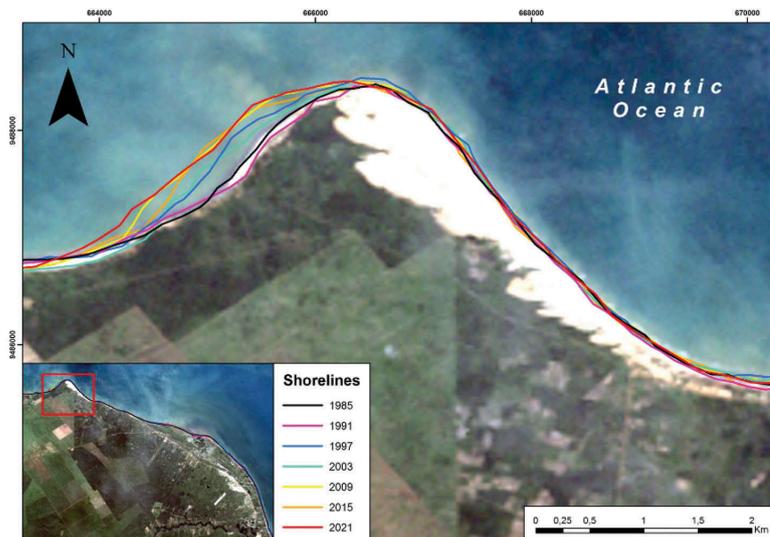


Fonte: elaborada pelo autor.

A Figura 33(a) representa a imagem MNDWI do ano de 2021 que foi gerada pelo método de Regressão Linear proposto. Da mesma forma, a Figura 33(b) mostra o resultado da aplicação do filtro Gaussiano na imagem gerada. Por sua vez, a Figura 33(c) representa a imagem resultante do processo de binarização (*threshold*). Já a Figura 33(d) é o resultado do uso da técnica de *flood fill*. A Figura 33(e) representa a extração da linha de costa do ano de 2021, em formato *TIFF*. E, finalmente, a Figura 33(f) é o resultado da conversão da linha de costa para o formato vetorial (*shapefile*).

A Figura 34 mostra a praia de Ponta Grossa, localizada na porção Oeste do município de Icapuí. Esta região evidenciou a maior variação de linha de costa, depois da aplicação do método extrapolação, principalmente devido à adição lateral de esporões arenosos que ocorre na direção Leste-Oeste.

Figura 34 - Linhas de costa dos anos de 1991, 1997, 2003, 2009, 2015 e 2021, sobrepondo a cena do ano de 1985, com ênfase nas regiões com maiores mudanças



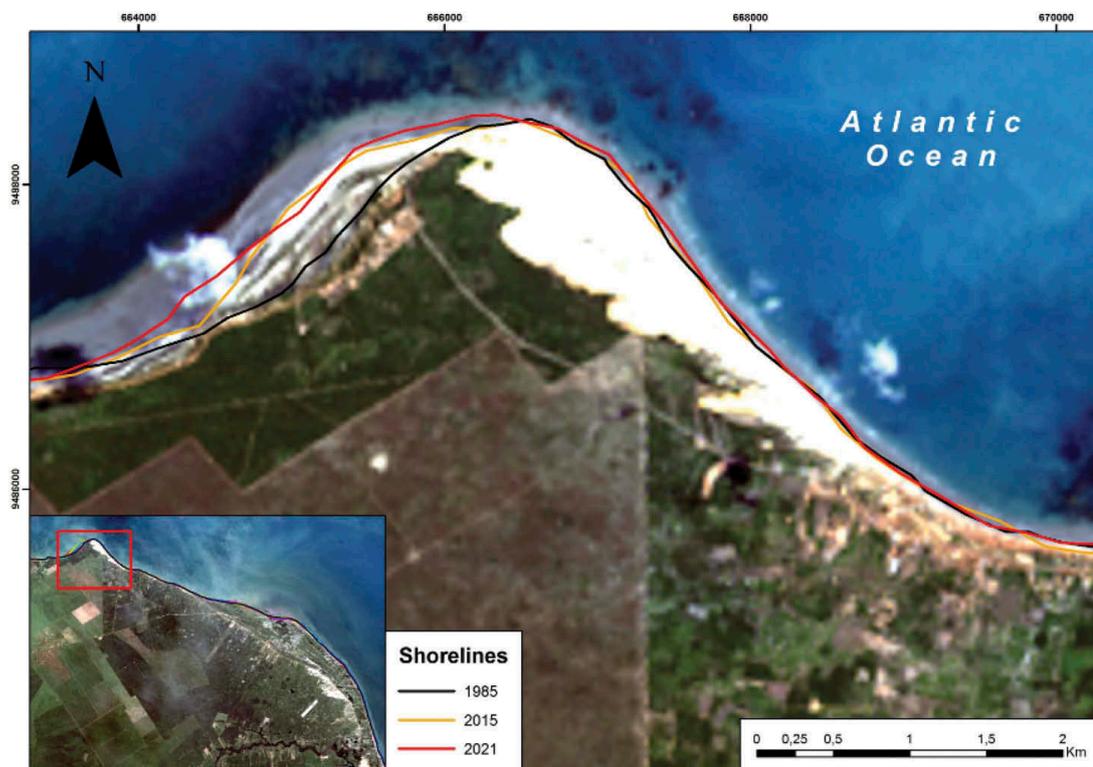
Fonte: elaborada pelo autor.

Observando a Figura 34, torna-se perceptível a variação da linha de costa desde 1985, com variação contínua da linha, perpendicularmente em direção ao mar e lateralmente a oeste. Além disso, é possível visualizar uma composição de cores R3-G2-B1 (*Red-Green-Blue*) do sensor TM do satélite Landsat 5 de 1985, que mostra a posição da linha de costa e sua variação nos últimos 30 anos.

De um modo geral, ainda é notável que, a leste das dunas mostradas na Figura 34, a linha de costa permaneceu levemente alterada, apresentando flutuações positivas e negativas modestas. Assim, percebe-se que o método pode ser aplicado tanto para linhas de costa retilíneas quanto para situações mais complexas, como acresções frontais e laterais que ocorrem na praia de Ponta Grossa.

Ademais, a Figura 35 ilustra a posição do prognóstico da linha de costa para o ano de 2021, apresentando um saldo positivo na área quando comparado aos anos de 1985 e 2015.

Figura 35 - Linhas de costa dos anos de 1985, 2015 e 2021, com ênfase nas regiões com maiores mudanças



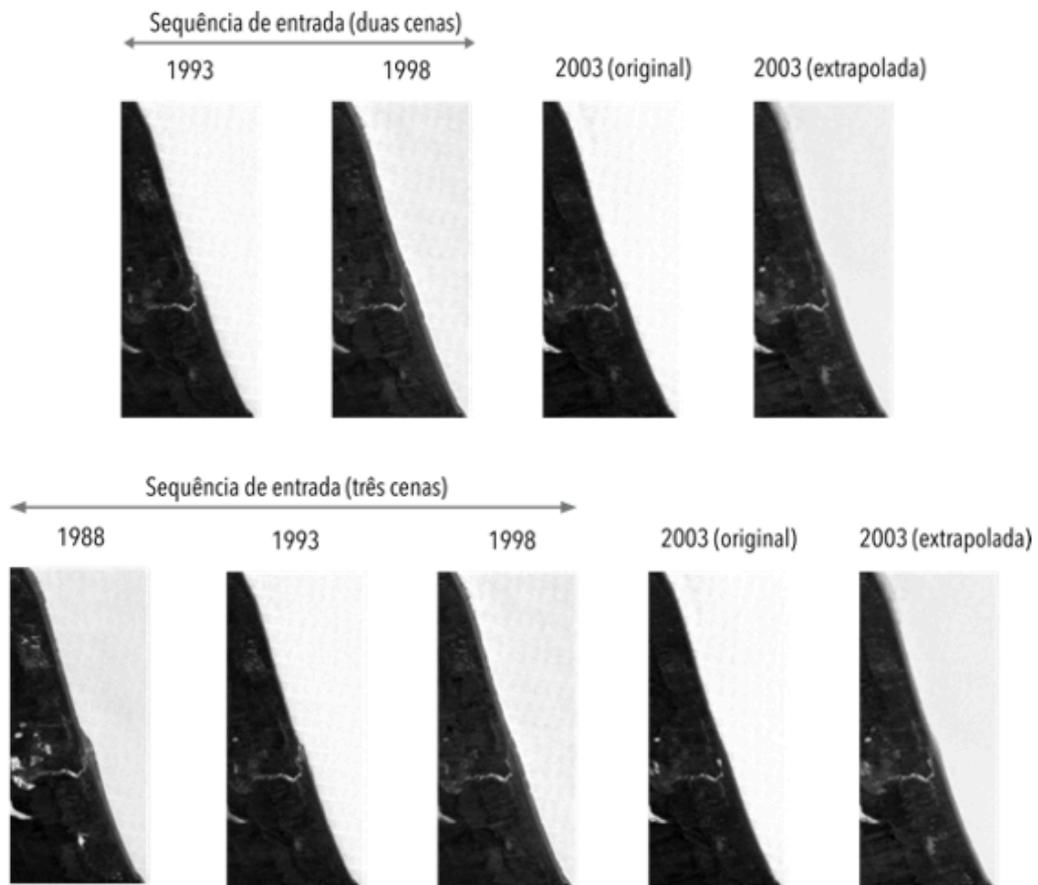
Fonte: elaborada pelo autor.

4.3 Resultados do método de extrapolação através de Redes Neurais

Como foi exposto no Capítulo 3 (metodologia da pesquisa), para avaliar o modelo CNN-LSTM realizou-se teste com sequências de entrada de duas e três imagens, respectivamente. Tal estratégia foi utilizada para identificar se o uso de mais imagens de entrada para o modelo geraria melhores resultados, uma vez que pretendia-se extrair os aspectos espaciais e temporal de cada uma das imagens.

A Figura 36 ilustra o processo de extrapolação de imagens futuras, para o setor Leste da linha de costa de Icapuí, utilizando o modelo de rede neural CNN-LSTM. No exemplo, o ano de 2003 é extrapolado, utilizando duas entradas ($timestep = 2$) e três entradas ($timestep = 3$), utilizando as sequências de imagens dos anos de 1988, 1993 e 1998.

Figura 36 - Extrapolação da cena de 2003 utilizando a arquitetura CNN-LSTM, com duas e três sequências de imagens

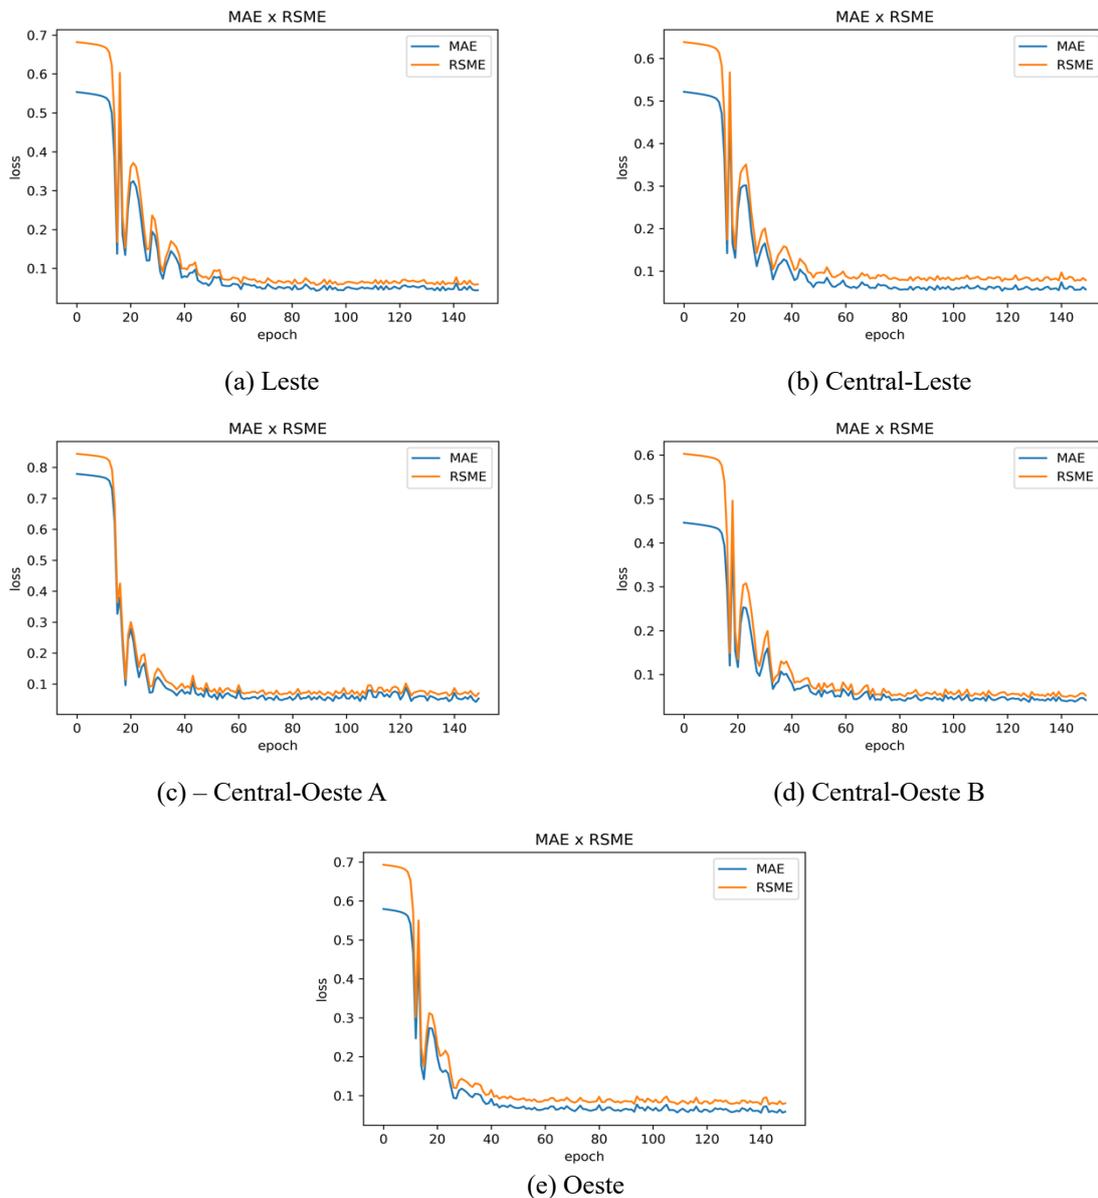


Fonte: elaborada pelo autor.

A Figura 37 mostra duas curvas que representam o comportamento do processo de treinamento do modelo, para cada um dos setores da linha de costa. A Figura 37(a) representa

o comportamento do MAE e do RMSE, calculado para o setor Leste da linha de costa. Já a Figura 37(b) exibe o comportamento do MAE e RMSE para o setor Central-Leste. A Figura 37(c) ilustra o comportamento do MAE e do RMSE para o setor Central-Oeste porção A. Por sua vez, a Figura 37(d) apresenta o comportamento do MAE e do RMSE para o setor Central-Oeste porção B. E, por fim, a Figura 37(e) apresenta o comportamento do MAE e do RMSE para o setor Oeste.

Figura 37 - Avaliação dos erros de treinamento, com o setor da linha de costa: (a) MAE e RMSE para o setor Leste; (b) MAE e RMSE para o setor Central-Leste; (c) MAE e RMSE para o setor Central-Oeste-A; (d) MAE e RMSE para o setor Central-Oeste-B; (e) MAE e RMSE para o setor Oeste



Fonte: elaborada pelo autor.

Como pode ser observado através da Figura 37, o processo de treinamento possui altos valores de MAE e RMSE, no início do treinamento da rede, mas tende a convergir para pequenos valores, ao final do processo.

Após 150 (cento e cinquenta) épocas de treinamento, foi possível calcular os valores médios para o MAE, o RMSE e o SSIM, para todos os setores da linha de costa, considerando os dois cenários de sequência de entrada (duas e três imagens anteriores). Os resultados podem ser visualizados na Tabela 8.

Tabela 8 - Performance do modelo CNN-LSTM

Setor	Timesteps	MAE	RMSE	SSIM	Tempo de treinamento (s)
Leste	2	0,056	0,070	0,89	950
	3	0,042	0,055	0,89	2516
Central-leste	2	0,066	0,088	0,86	1441
	3	0,065	0,086	0,87	3275
Central-oeste-porção A	2	0,044	0,054	0,86	1851
	3	0,039	0,051	0,86	2568
Central-oeste-porção B	2	0,054	0,074	0,85	1845
	3	0,050	0,073	0,84	2733
Oeste	2	0,062	0,081	0,86	311
	3	0,048	0,070	0,87	808

Fonte: elaborada pelo autor.

Os resultados da Tabela 8 demonstram que, geralmente, os valores de MAE e RMSE são menores (menor erro médio), quando a sequência de entrada do modelo é composta por 3 (três) imagens. Tal comportamento pode indicar que um número maior de imagens de entrada contribui para que a porção CNN do modelo consiga extrair um maior número de características que melhor representem a série temporal.

Além disso, os valores do SSIM para o modelo com duas e três imagens de entrada é bem similar. Porém, em quatro dos cinco setores analisados, o percentual de similaridade do modelo que teve 3 (três) imagens como entrada foi maior ou igual ao modelo com apenas duas imagens. Em apenas um dos setores (Central-oeste-porção B) o resultado foi inferior.

A partir destes resultados, apesar dos métodos propostos (regressão linear e CNN-LSTM) serem aplicados na mesma região, mas com abordagens diferentes, foi possível comparar o desempenho de ambos, levando em consideração o valor do MAE.

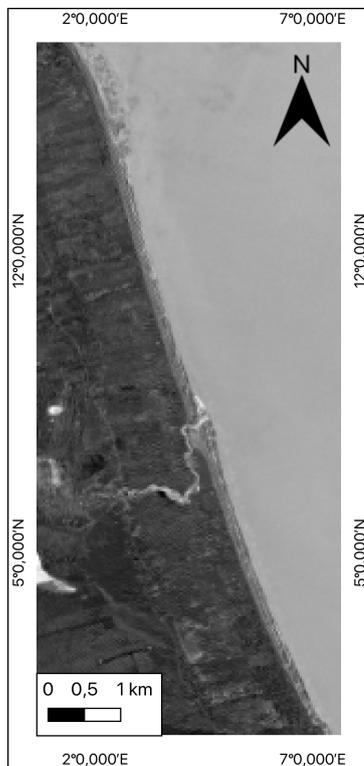
Observando-se a Tabela 7, verifica-se que o valor médio de MAE para o método de regressão linear, considerando todos os anos, foi de 0,049.

De forma similar, analisando a Tabela 8, mesmo considerando a linha de costa dividida em setores, os valores de MAE para o modelo CNN-LSTM são bem próximos aos do modelo

de regressão linear. Entretanto, em alguns setores, obteve um valor menor (como o valor de 0,039 para o setor Central-Oeste porção A) e em outros um valor maior (como o valor de 0,065 para o setor Central-Leste).

Considerando os resultados alcançados, o modelo CNN-LSTM foi utilizado para gerar o MNDWI dos anos 2003, 2008, 2013, 2018 e gerar o prognóstico para o ano de 2023. A Figura 38 apresenta os MNDWI para os setores Leste (Figura 38(a)), Central-Leste (Figura 38(b)), Central-Oeste-A (Figura 38(c)), Central-Oeste-B (Figura 38(d)) e Oeste (Figura 38(e)).

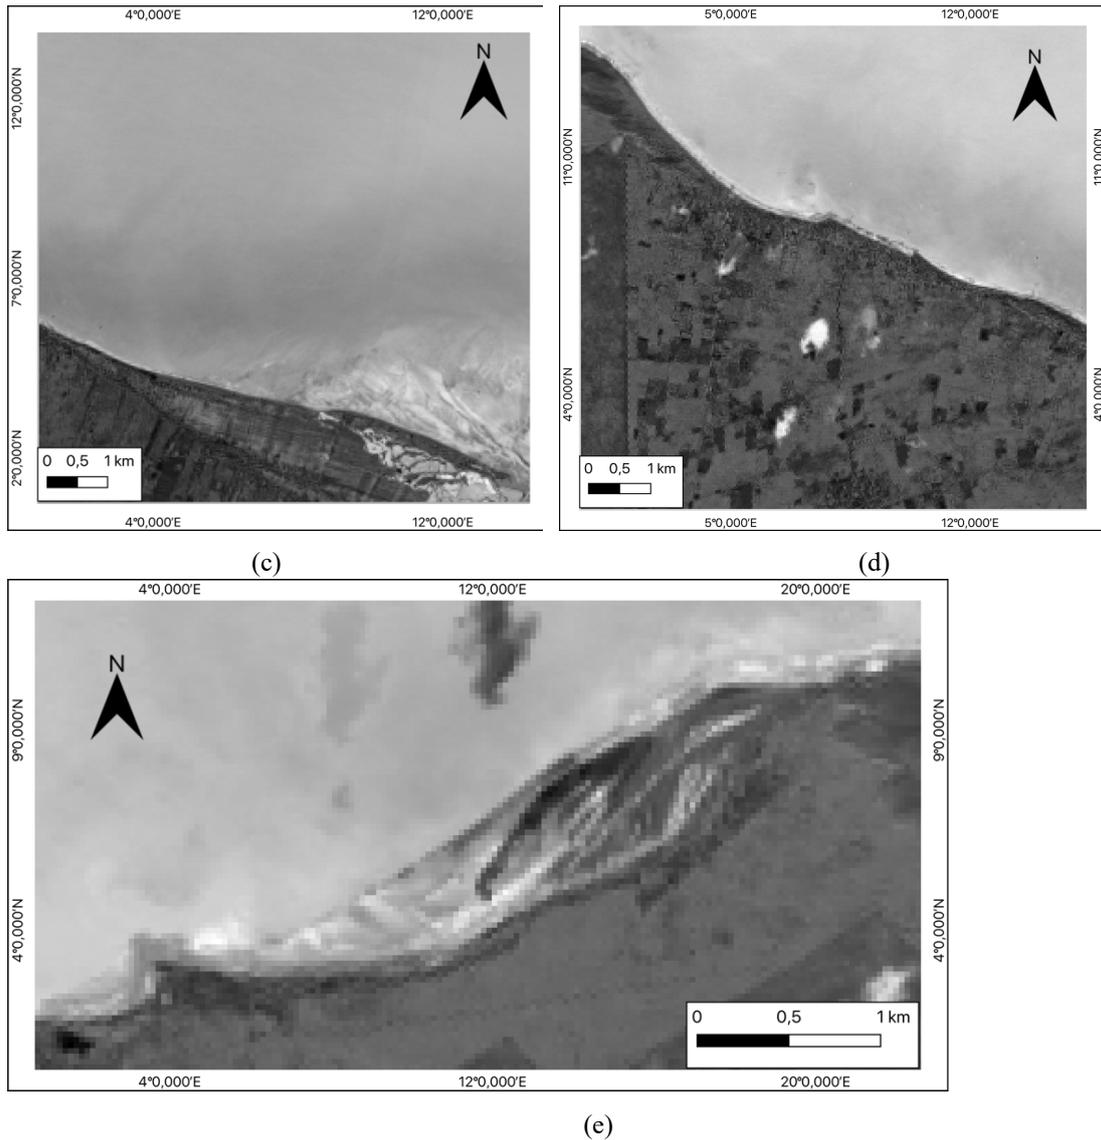
Figura 38 – MNDWIs gerados para todos os setores da costa de Icapuí: (a) MNDWI de 2023 do setor Leste; (b) MNDWI de 2023 do setor Central-Leste; (c) MNDWI de 2023 do setor Central-Oeste-A; (d) MNDWI de 2023 do setor Central-Oeste-B; e (e) MNDWI de 2023 do setor Oeste



(a)



(b)

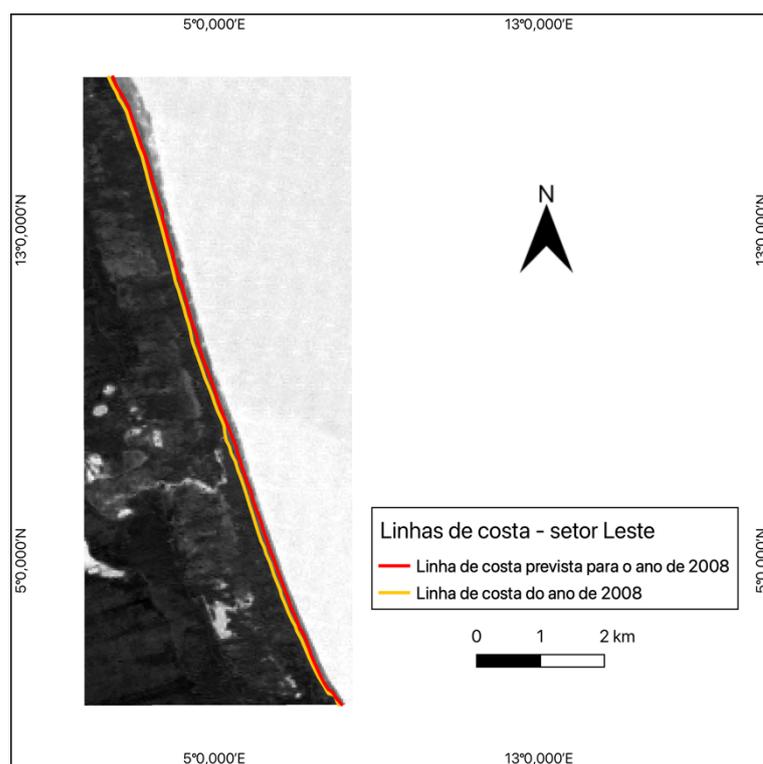
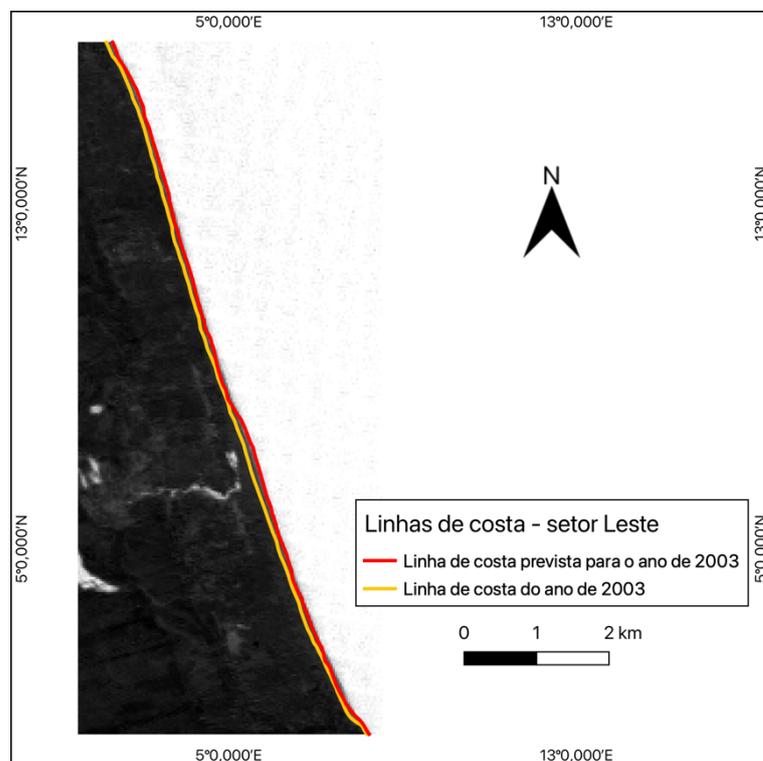


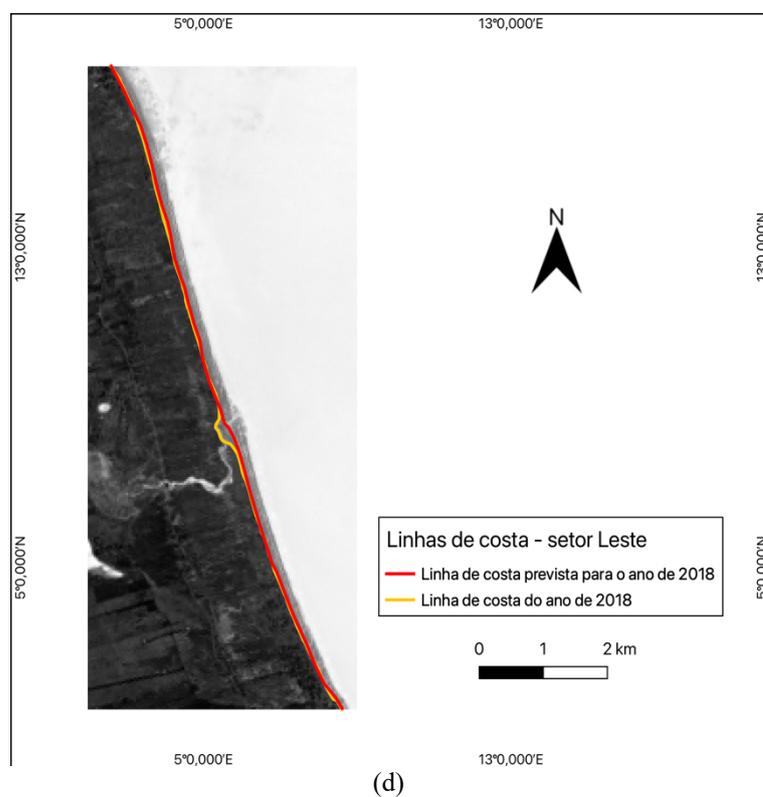
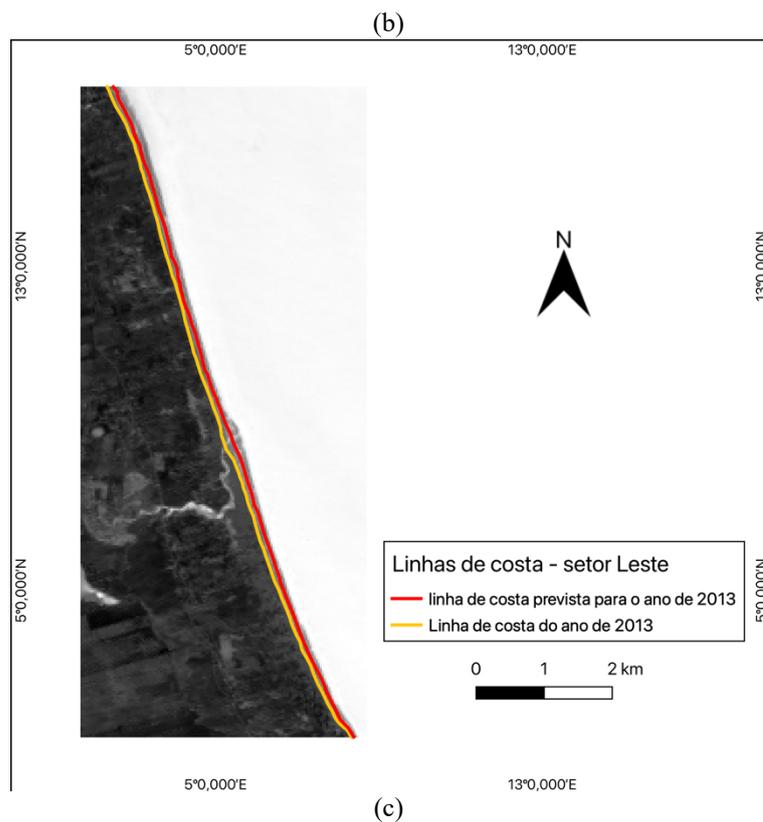
Fonte: elaborada pelo autor.

Após a extrapolação das imagens MNDWI, foram extraídas as linhas de costas de todos os anos da sequência temporal, com a finalidade de realizar uma comparação entre aquelas geradas a partir do modelo CNN-LSTM e as extraídas manualmente por um fotointérprete, através da utilização de um SIG.

A Figura 39 ilustra as linhas de costa para o setor Leste de Icapuí, para os anos de 2003, 2008, 2013 e 2018. A Figura 39(a) representa as linhas de costa extraídas manualmente por um fotointérprete e gerada pelo modelo híbrido CNN-LSTM, para o ano de 2003. Já a Figura 39(b) apresenta as linhas para o ano de 2008, utilizando os dois métodos. A Figura 39(c) ilustra as linhas de costa extraídas manualmente e gerada automaticamente pelo modelo, para o ano de 2013. E, finalmente, a Figura 39(d) apresenta as linhas de costa extraídas para o ano de 2018.

Figura 39 - Linhas de costa do setor Leste: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018





Fonte: elaborada pelo autor.

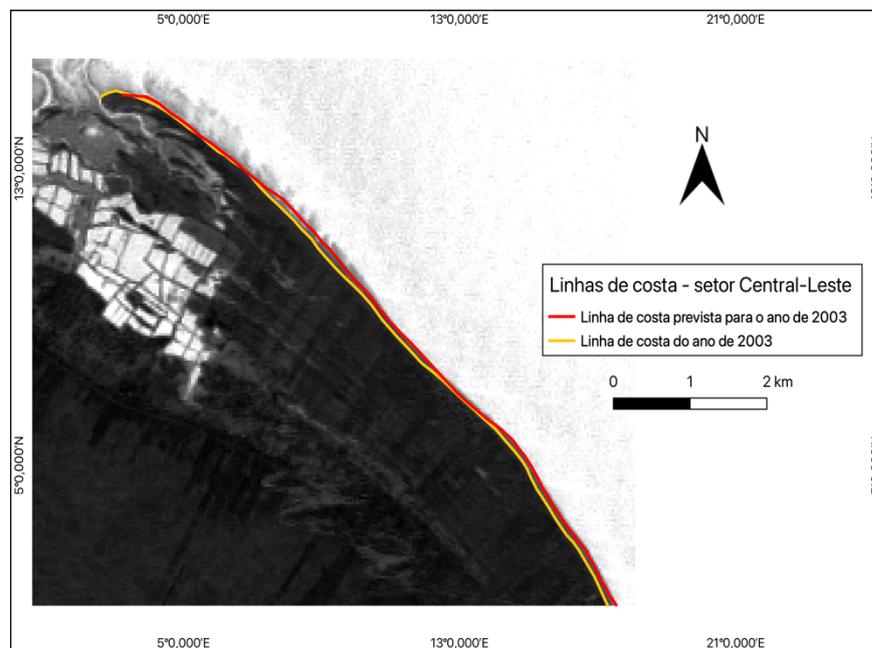
Como pode ser observado através da Figura 39, o setor Leste de Icapuí é caracterizado por uma porção mais retilínea. Este tipo de região sobre menos influência das variações da maré,

mas, mesmo assim, o fenômeno de intermaré (quando a maré está baixa e é possível visualizar toda a região que representa a diferença entre a maré cheia e a maré baixa) influencia na interpretação da linha de costa gerada pelo modelo proposto.

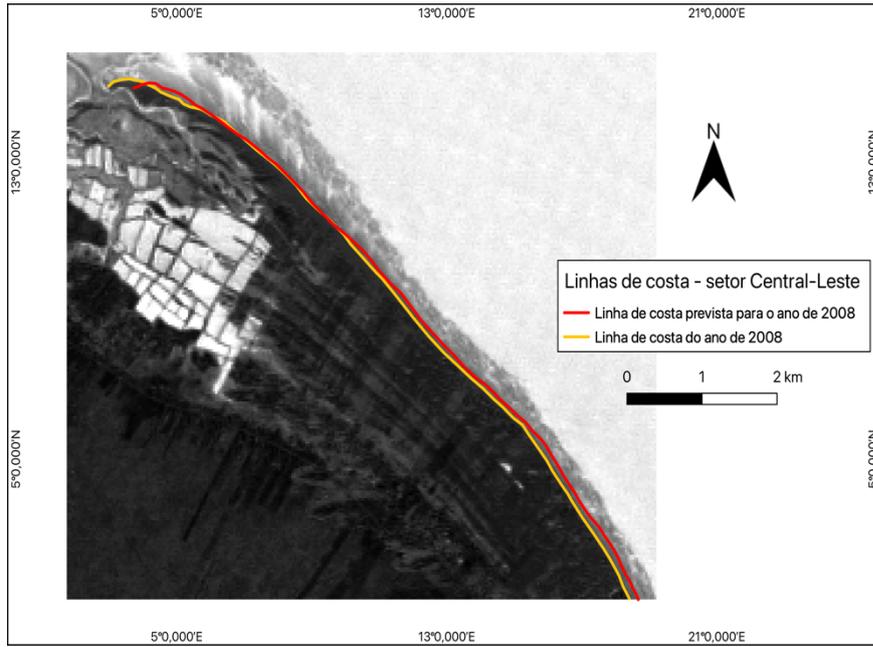
Ainda considerando a Figura 39, é possível perceber que a linha de costa gerada pelo modelo CNN-LSTM, geralmente, é traçada mais para dentro do oceano, muito provavelmente devido a influência do fenômeno de intermaré.

A Figura 40, por sua vez, apresenta as linhas de costa do setor Central-Leste, para os anos de 2003, 2008, 2013 e 2018. A Figura 40(a) representa a linha de costa extraída manualmente por um fotointérprete e a linha de costa gerada pelo modelo híbrido CNN-LSTM para o ano de 2003. Já a Figura 40(b) apresenta as linhas para o ano de 2008. A Figura 40(c) ilustra as linhas de costa extraídas manualmente e geradas automaticamente pelo modelo, para o ano de 2013. Por conseguinte, a Figura 40(d) apresenta as linhas de costa para o ano de 2018.

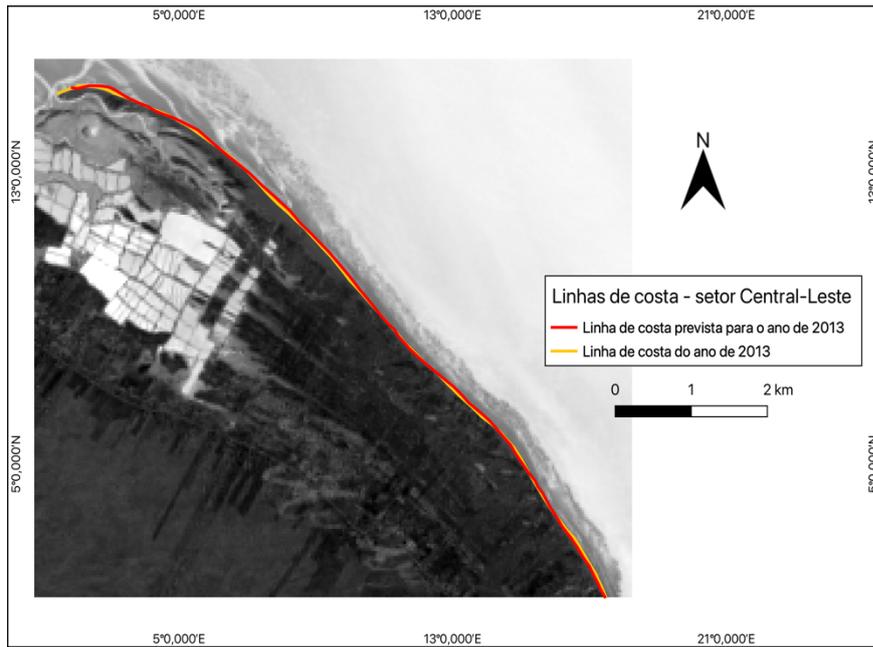
Figura 40 - Linhas de costa do setor Central-Leste: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018



(a)



(b)



(c)



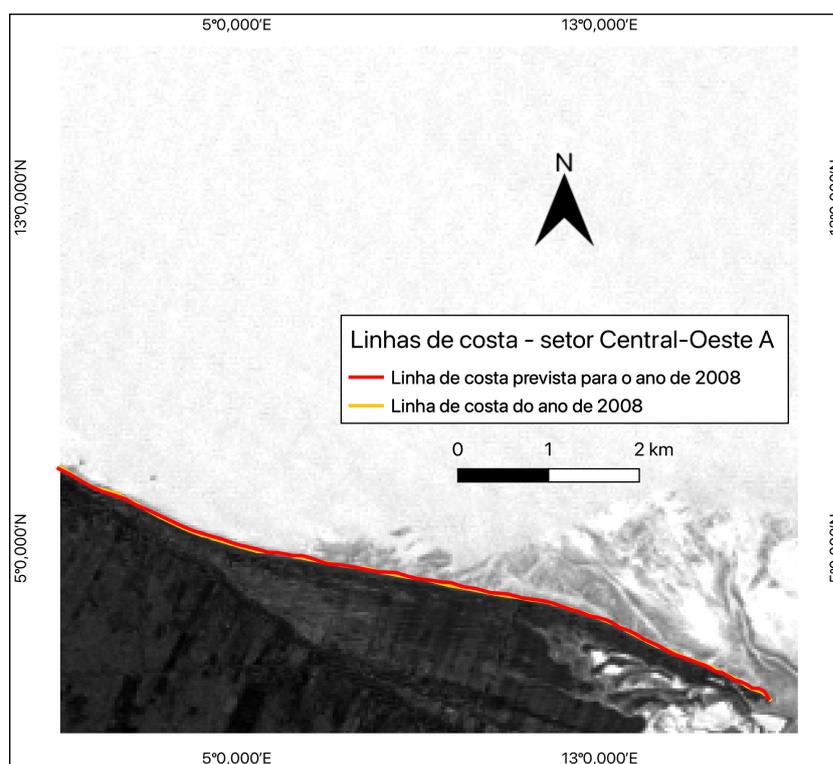
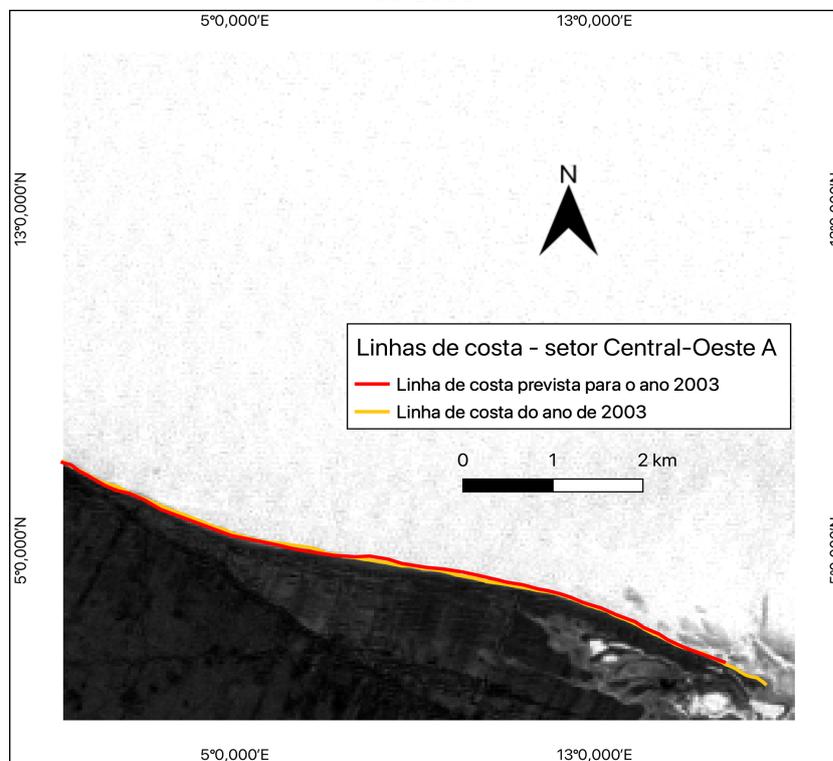
(d)

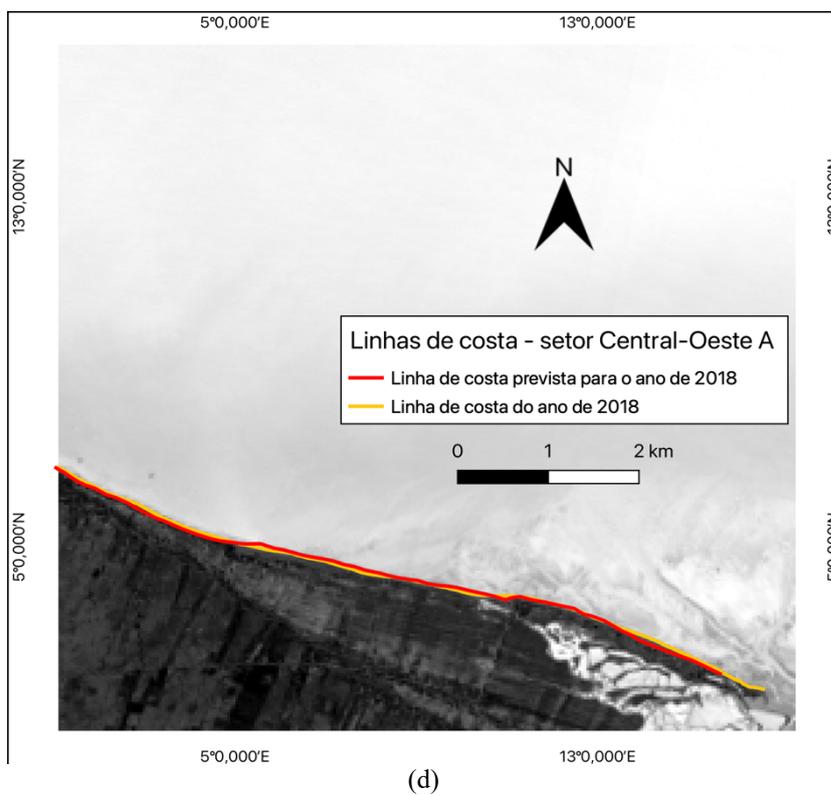
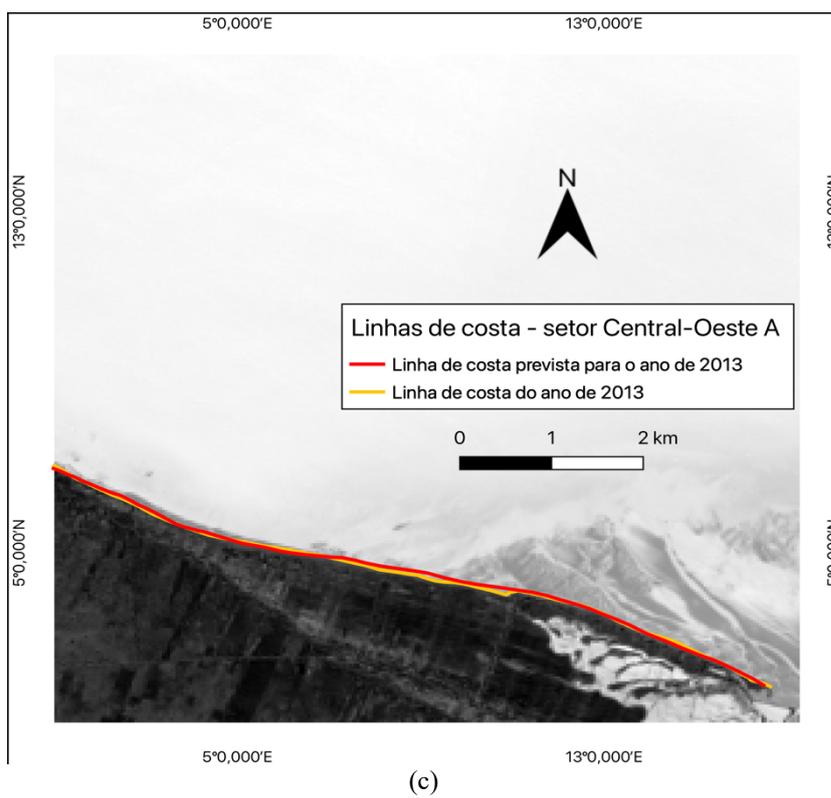
Fonte: elaborada pelo autor.

Como pode ser observado, através da Figura 40, o setor Central-Leste tem características similares, em relação a sua forma retilínea, com o setor Leste. Pode-se observar que as linhas de costa previstas pelo modelo também acabam sofrendo a influência do fenômeno de intermaré, mesmo que em alguns anos (2013 e 2018) algumas porções da linha gerada automaticamente coincidam com a linha de costa gerada pelo fotointérprete.

Já a Figura 41 exibe as linhas de costa do setor Central-Oeste na porção A, também para os anos de 2003, 2008, 2013 e 2018. A Figura 41(a) apresenta as linhas de costa geradas pelo fotointérprete e gerada pelo modelo proposto para o ano de 2003. A Figura 41(b) apresenta as linhas de costa extraídas para o ano de 2008. Por sua vez, a Figura 41(c) exibe as linhas de costa extraídas para o ano de 2013. Ademais, a Figura 41(d) ilustra as linhas de costa geradas para o ano de 2018.

Figura 41 - Linhas de costa do setor Central-Oeste porção A: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018





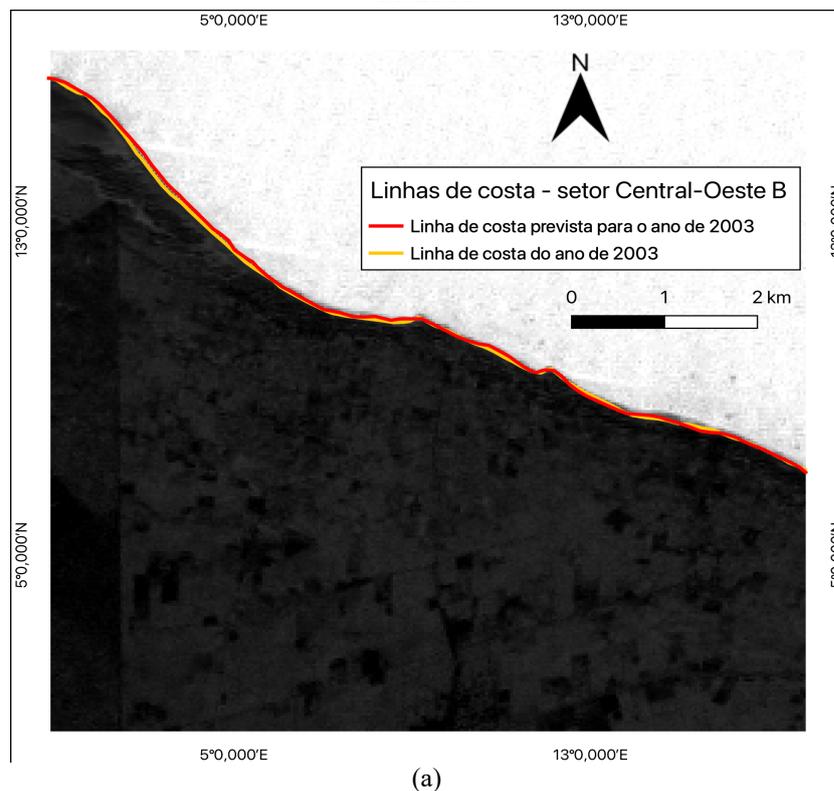
Fonte: elaborada pelo autor.

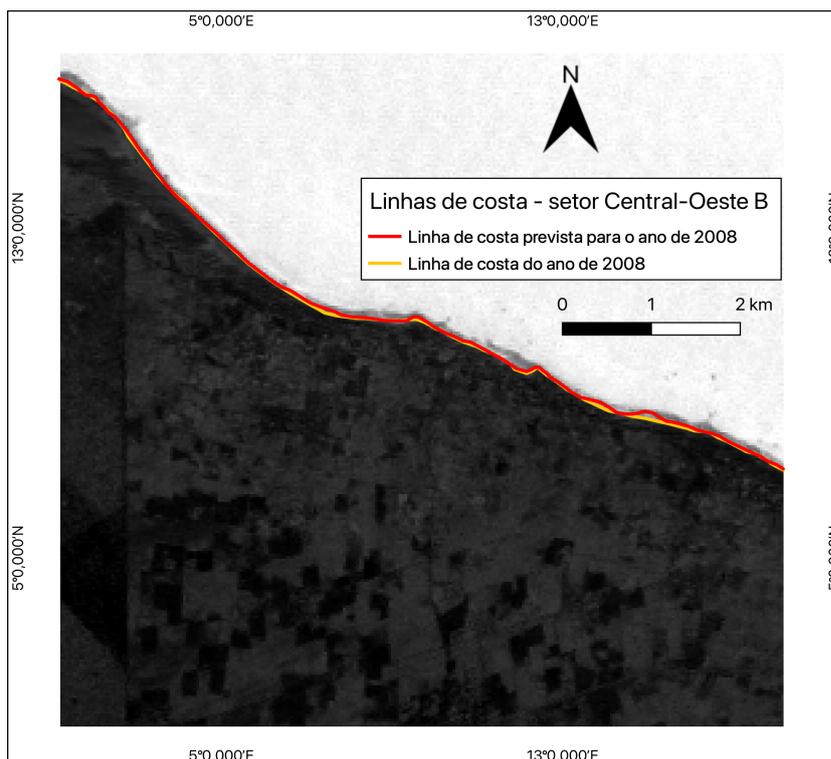
Analisando a Figura 41, observa-se que as linhas de costa, extraídas através dos dois métodos, possuem comportamento similar aos setores Leste e Central-Leste. Da mesma forma

que acontece com o setor Central-Leste, algumas áreas das linhas praticamente coincidem em todos os anos da sequência considerada.

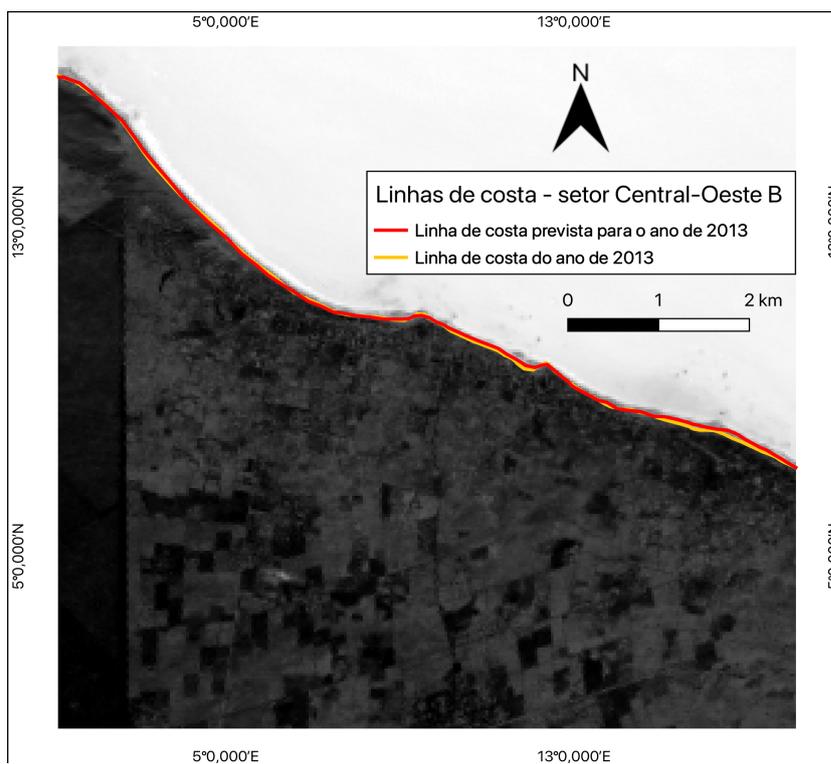
A Figura 42 apresenta as linhas de costa do setor Central-Oeste porção B, extraídas pelos dois métodos, para os anos de 2003, 2008, 2013 e 2018. A Figura 42(a) exhibe as linhas de costa do ano de 2003. A Figura 42(b) apresenta as linhas de costa para o ano de 2008. A Figura 42(c), por sua vez, apresenta as linhas de costa para o ano de 2013. E, por fim, a Figura 42(d) exhibe as linhas de costa para o ano de 2018.

Figura 42 - Linhas de costa do setor Central-Oeste porção B: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2018

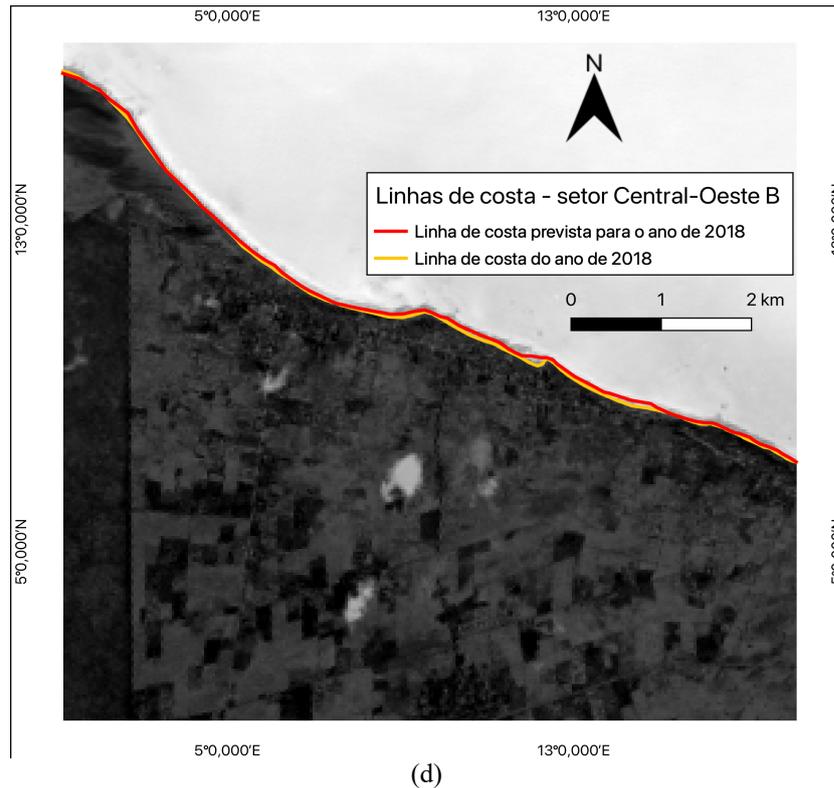




(b)



(c)

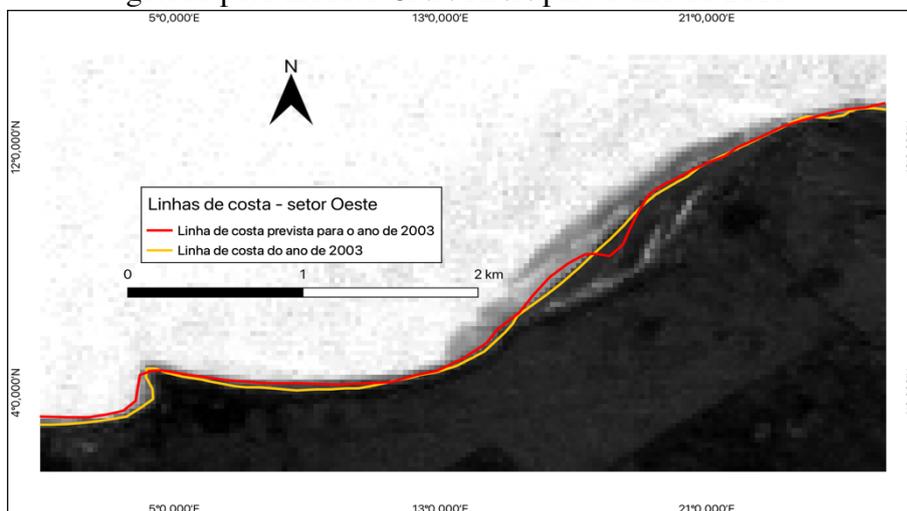


Fonte: elaborada pelo autor.

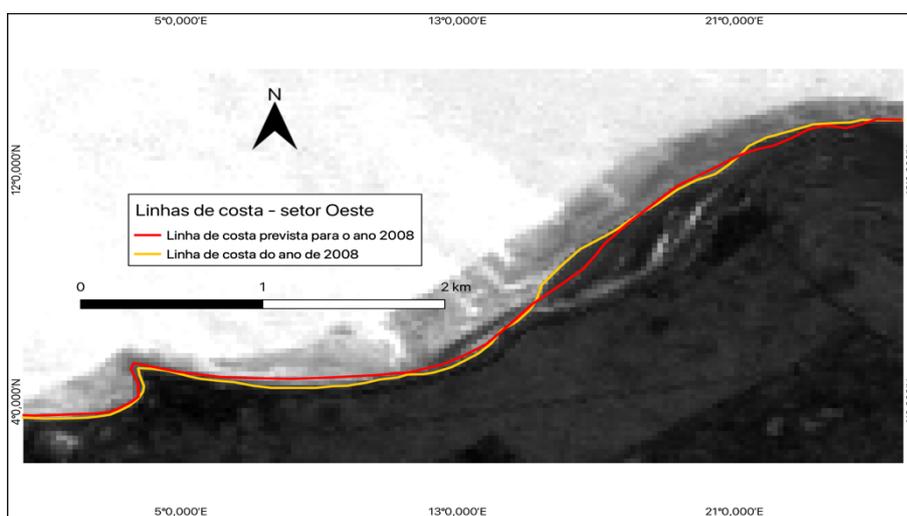
A partir da Figura 42, nota-se um comportamento do setor Central-Oeste porção B similar aos setores analisados anteriormente (Leste, Central-Leste e Central-Oeste-A), com os mesmos tipos de influência no algoritmo implementado para a geração automática.

A Figura 43 apresenta as linhas de costa geradas para o setor Oeste, para os anos de 2003, 2008, 2013 e 2018. A Figura 43(a) exibe as linhas de costa geradas para o ano de 2003. Por sua vez, a Figura 43(b) apresenta as linhas de costa extraídas para o ano de 2008. A Figura 43(c) exibe as linhas de costa para o ano de 2013. E, a Figura 43(d) exibe as linhas de costa geradas para o ano de 2018.

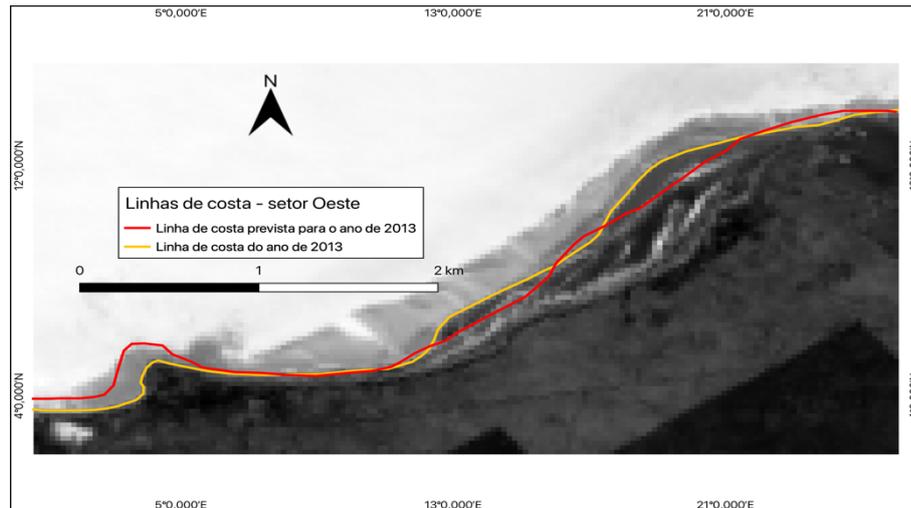
Figura 43 - Linhas de costa do setor Oeste sobrepondo a imagem MNDWI do ano em questão: (a) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2003; (b) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2008; (c) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-LSTM para o ano de 2013 e (d) Linhas de costa extraída pelo fotointérprete e gerada pelo modelo CNN-RNN para o ano de 2018.



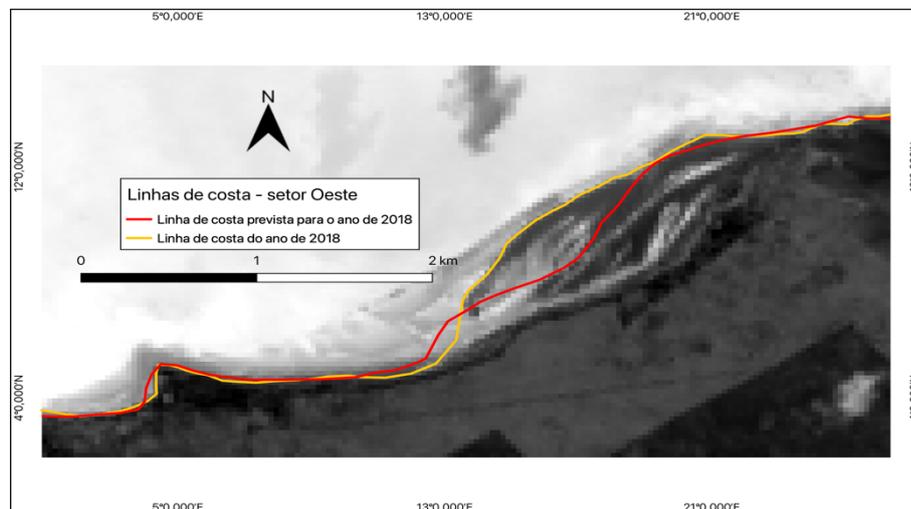
(a)



(b)



(c)



(d)

Fonte: elaborada pelo autor.

Analisando a Figura 43, é possível perceber que o setor Oeste possui uma complexidade maior que os demais setores. Esta é uma região que sofre maior influência do fenômeno de intermarés. Além disso, possui uma progradação lateral da praia, fazendo com que a mesma vá aumentando, de leste para oeste.

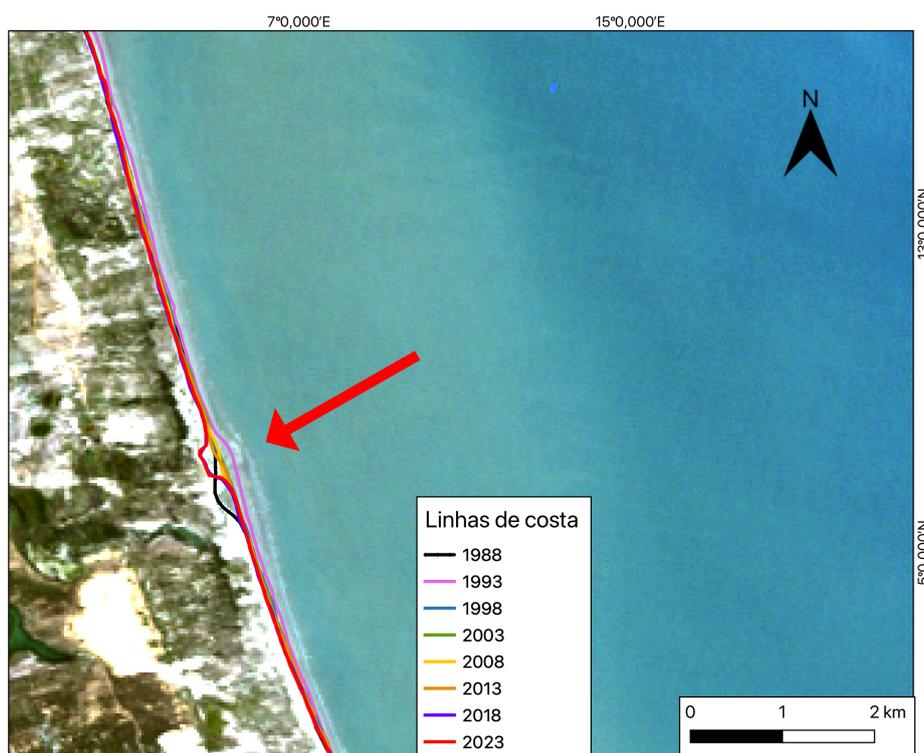
Devido a tais fatores, neste setor, é possível notar diferenças mais relevantes entre as linhas de costa extraídas por um fotointérprete e as linhas de costa geradas pelo modelo CNN-LSTM, o que indica uma sensibilidade do algoritmo relacionadas com tais fatores.

Ao final do processo, para analisar a variação das linhas de costa de todos os setores, desde o ano de 1988, foi gerada uma composição colorida R3-G2-B1 do ano de 1988 que mostra o comportamento das linhas de costa e sua variação nos últimos 30 anos. Além disso, foi plotada

a linha de costa projetada para o ano de 2023, para analisar o comportamento futuro de cada um dos setores.

A Figura 44 apresenta o comportamento das linhas de costa do setor Leste, desde 1988 até 2018 e apresenta a previsão para o ano de 2023.

Figura 44 – Linhas de costa do setor Leste dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.

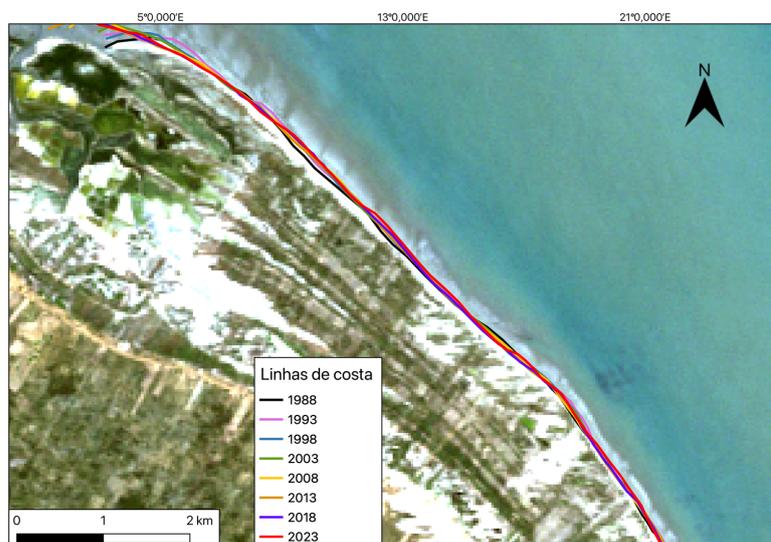


Fonte: elaborada pelo autor.

A partir da Figura 44, verifica-se que a linha de costa estimada para o ano de 2023 (linha vermelha) apresenta um comportamento divergente das linhas de costa dos últimos anos da sequência, principalmente na região indicada (seta vermelha).

Da mesma forma, a Figura 45 exhibe as linhas de costa do setor Central-Leste, de 1988, 1993, 1998, 2003, 2008, 2013 e 2018, além da linha de costa estimada para o ano de 2023.

Figura 45 - Linhas de costa do setor Central-Leste dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.

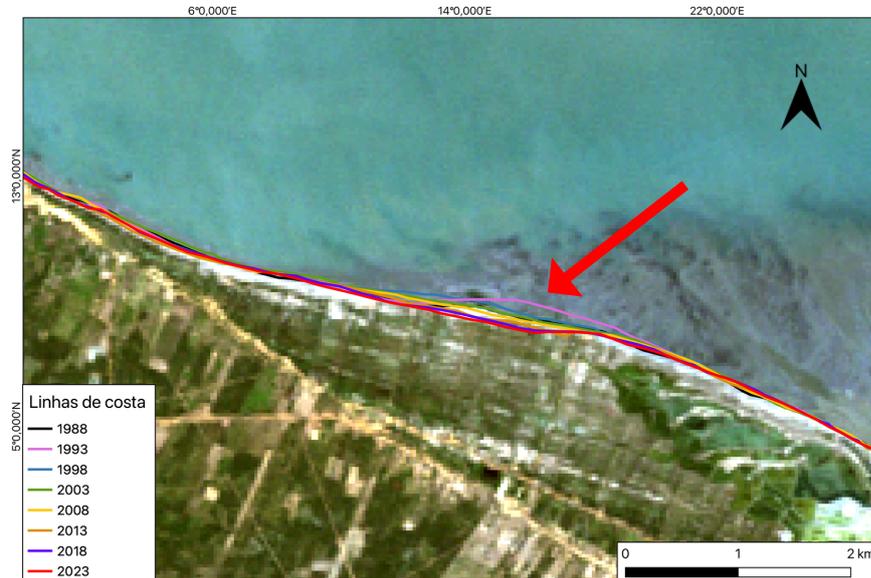


Fonte: elaborada pelo autor.

Considerando a Figura 45, percebe-se que, durante todo o período, as linhas de costa tendem a ter um comportamento homogêneo e a linha prevista para o ano de 2023 segue esta tendência.

A Figura 46 apresenta as linhas do setor Central-Oeste porção A para os anos de 1998, 1993, 1998, 2003, 2008, 2013 e 2018, além da previsão para 2023.

Figura 46 - Linhas de costa do setor Central-Oeste porção A dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.



Fonte: elaborada pelo autor.

Analisando a Figura 46, nota-se que, durante todo o período considerado, as linhas de costa apresentam um comportamento similar, com exceção do ano de 1993 onde houve uma maior alteração, na área apontada (seta vermelha).

A Figura 47 exhibe as linhas de costa do setor Central-Oeste porção B, para os anos de 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo a cena de 1988.

Figura 47 - Linhas de costa do setor Central-Oeste porção B dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.

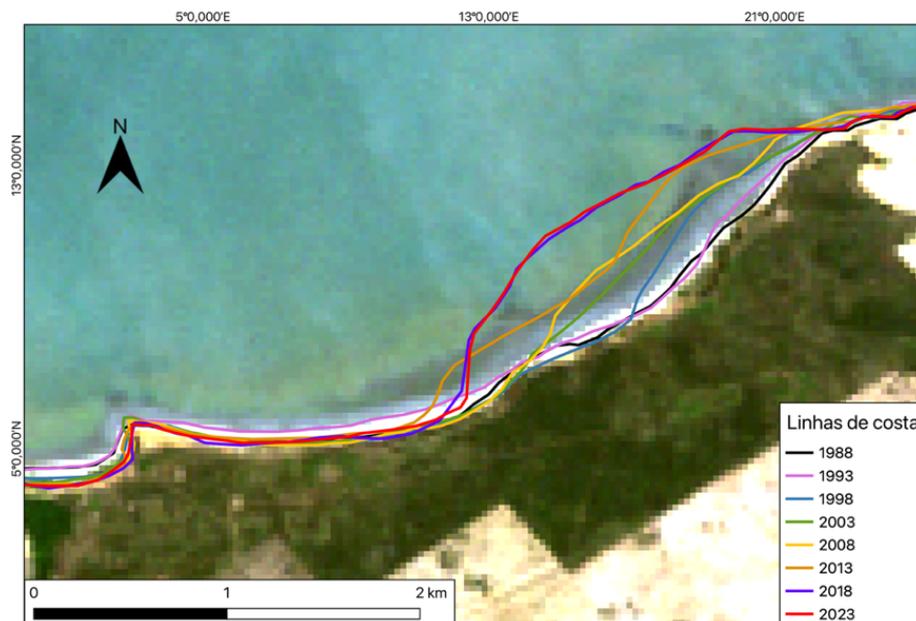


Fonte: elaborada pelo autor.

A Figura 47 demonstra que as linhas de costa do setor Central-Oeste porção B possuem o comportamento quase inalterado, durante todos os anos.

Por último, a Figura 48 apresenta as linhas de costa do setor Oeste para os anos de 1988, 1993, 1998, 2003, 2008, 2013, 2018 e a previsão para 2023.

Figura 48 - Linhas de costa do setor Oeste dos anos 1988, 1993, 1998, 2003, 2008, 2013, 2018 e 2023, sobrepondo o ano de 1988.



Fonte: elaborada pelo autor.

A Figura 48 ilustra mais ainda a complexidade do setor Oeste de Icapuí e apresenta as maiores alterações de linhas de costa, durante todos os anos, quando comparado com os demais setores. Além disso, é possível observar que a linha de costa prevista para o ano de 2023 segue a tendência da linha de costa do ano de 2018.

5 CONCLUSÕES E RECOMENDAÇÕES

Estimar o comportamento futuro dos processos de erosão costeira é uma questão de extrema importância, pois pode auxiliar na implementação de políticas públicas que visam controlar ou mitigar os efeitos que esse processo pode causar aos moradores, indústrias e/ou empreendimentos turísticos instalados nas zonas costeiras.

Nesse sentido, foi proposta a utilização de técnicas de estimativa de séries temporais, utilizando métodos de regressão linear e técnicas de Processamento Digital de Imagens, aplicadas a séries temporais de imagens de satélite, como ferramentas para a criação de um modelo de prognóstico da evolução costeira, de forma mais automatizada nos procedimentos de estimativa de cenários futuros da linha de costa.

Ademais, foi desenvolvida uma solução computacional para ser executada em plataforma SIG que automatiza o processo de geração de prognóstico e extração da linha de costa em formato *shapefile*.

Os resultados mostraram que as técnicas utilizadas no processamento de imagens orbitais podem ser importantes aliadas em pesquisas que buscam monitorar mudanças em regiões costeiras.

Este estudo de caso, no município de Icapuí, indicou áreas com fortes modificações. A região da praia de Ponta Grossa apresentou tendência deposicional (ou adicional) de sedimentos para o ano de 2021.

Esses resultados já foram confirmados por outros estudos realizados na região por autores como Mororó *et al.* (2015), Fernandes *et al.* (2015) e Ximenes, Souto e Duarte (2013). Neste último estudo, por exemplo, foi analisado o contexto evolutivo da região, no período de 1984 a 2011, concluindo que o balanço sedimentar foi muito positivo para a região litorânea de Icapuí/CE, onde o valor do aumento foi quase o dobro do valor da erosão. Entretanto, em algumas áreas o efeito erosivo predominou, como na porção oeste da região de Ponta Grossa.

Analisando-se os resultados dos dois modelos, com base nos valores das Tabelas 7 e 8 e considerando a abordagem de aplicação diferente de cada um deles, o erro médio do modelo de regressão linear foi de 4,9%. Por sua vez, o erro médio do modelo de RNA foi de 4,88%. Assim, ficou claro que mesmo um modelo sendo mais complexo que o outro (RNAs são mais complexas que regressão linear), isto não contribuiu para uma diferença significativa nos resultados gerados por eles.

Uma hipótese para tal fato pode estar relacionada com a complexidade da morfologia

da costa analisada, onde identifica-se a presença de canais de maré, barras arenosas, ilhas-barreiras e manguezais. Tais características podem comprometer a identificação das linhas de costa e, conseqüentemente, afetar na eficiência dos algoritmos.

Assim, de acordo com os resultados dos dois modelos, conclui-se que o emprego de um modelo mais simples já seria suficiente para a obtenção de um prognóstico futuro, para costas mais retilíneas e com morfologia menos complexa. Por outro lado, quando são aplicados em costa mais complexas, os modelos tendem a reduzir a confiabilidade dos seus resultados.

Como trabalho futuro, sugere-se a implementação de alterações nos modelos, para tentar reduzir a influência da morfologia e da complexidade da costa e, além disso, verificar a eficiência dos modelos em áreas com outras características.

Outra proposta seria utilizar seqüências de imagens de satélites de alta resolução espacial, para avaliar se os modelos são capazes de melhorar os seus resultados.

REFERÊNCIAS

ABRAHAM, E. M.; TORRES, L. M. Estado del arte en el uso de indicadores y puntos de referencia en la lucha contra la desertificación y la sequía en América Latina y el Caribe. **Interciencia**, Caracas, v. 32, p. 827–833, 2007.

AMARO, V. E. **Análise conjunta de dados geológicos, geofísicos e de sensoriamento remoto do setor extremo Nordeste da Província Borborema, Nordeste do Brasil, com ênfase nas zonas de cisalhamento dúcteis Neoproterozóicas**. Tese (Doutorado em Geologia)—São Paulo: USP, 29 out. 1998.

AMARO, V. E.; ARAÚJO, A. B. DE. Análise Multitemporal da Morfodinâmica da Região Costeira Setentrional do Nordeste do Brasil Entre os Municípios de Grossos e Tibau, Estado do Rio Grande do Norte. **Revista de Gestão Costeira Integrada**, Lisboa, v. 8, n. 2, p. 77–100, dez. 2008.

AMARO, V. E.; SANTOS, M. S. T.; SOUTO, M. V. S. **Geotecnologias aplicadas ao monitoramento costeiro: Sensoriamento Remoto e Geodésia de Precisão**. Natal, RN: Do Autor, 2012.

ASTOLFI, G.; WEBER, V. A. DE M.; JUNIOR, A. DA S. O.; MENEZES, G. V. **Using syntactic methods and LSTM to the recognition of objects visual patterns**. Anais do XV Workshop de Visão Computacional (WVC 2019). **Anais...**São Bernardo do Campo: Sociedade Brasileira de Computação - SBC, 9 set. 2019. Disponível em: <<https://sol.sbc.org.br/index.php/wvc/article/view/7632>>

BHATT, D.; PATEL, C.; TALSANIA, H.; PATEL, J.; VAGHELA, R.; PANDYA, S.; MODI, K.; GHAYVAT, H. CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope. **Electronics**, Basel, v. 10, n. 20, p. 2470, 11 out. 2021.

BIJLSMA, L.; EHLER, C.; KLEIN, R. Coastal zones and small islands. Impacts, Adaptations and Mitigation of Climate Change: Scientific-Technical Analyses. p. 289–324, 1996.

BOORI, M. S.; AMARO, V. E. Detecting and understanding drivers of natural and eco-environmental vulnerability due to hydro geophysical parameters, ecosystem and land use change through multispectral satellite data sets in Apodi estuarine, Northeast Brazil. **International Journal of Environmental Sciences**, Londres, v. 1, n. 4, p. 543–557, 1 jan. 2010.

BOORI, M. S.; AMARO, V. E. Natural and eco-environmental vulnerability assessment through multi-temporal satellite data sets in Apodi valley region, Northeast Brazil. **Journal of Geography and Regional Planning**, Lagos, v. 4, n. 4, p. 216–230, 2011.

BRASIL. **Decreto nº 5.300, de 07 de dezembro de 2004**. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/decreto/d5300.htm>.

BROWNLEE, J. **Long Short-Term Memory Networks With Python Develop Sequence Prediction Models With Deep Learning**. 1. ed. [s. l.]: Machine Learning Mastery, 2020.

- BUJAK, D.; BOGOVAC, T.; CAREVIĆ, D.; ILIC, S.; LONČAR, G. Application of artificial neural networks to predict beach nourishment volume requirements. **Journal of Marine Science and Engineering**, Basel, v. 9, n. 8, 2021.
- CANNY, J. A Computational Approach to Edge Detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Seoul, v. PAMI-8, n. 6, p. 679–698, 1986.
- CELLONE, F.; CAROL, E.; TOSI, L. Coastal erosion and loss of wetlands in the middle Río de la Plata estuary (Argentina). **Applied Geography**, Amsterdam, v. 76, p. 37–48, nov. 2016.
- CHOLLET, F.; ALLAIRE, J. J. **Deep learning with R**. 1. ed. Shelter Island, NY, USA: Manning Publications, 2018.
- COCOLO, C. **Reconhecimento de movimentos de cães utilizando um acelerômetro e redes neurais artificiais**. Dissertação de mestrado—São Carlos: USP, 17 dez. 2020.
- COHEN, J. E.; SMALL, C.; MELLINGER, A.; GALLUP, J.; SACHS, J. Estimates of Coastal Populations. **Science**, Washington, v. 278, n. 5341, p. 1209–1213, 14 nov. 1997.
- COOPER, J. A. G.; MCKENNA, J. Social justice in coastal erosion management: The temporal and spatial dimensions. **Geoforum**, Amsterdam, v. 39, n. 1, p. 294–306, 2008.
- CUI, B.; LI, X.; CHANG, X.; YI, W.; WANG, L. **Remote sensing monitoring of coastline change in the Yellow River estuary (1976–2005)**. 3rd International Congress on Image and Signal Processing. **Anais...Yantai**: 2010.
- EBERMAM, E.; KROHLING, R. Uma Introdução Compreensiva às Redes Neurais Convolucionais: Um Estudo de Caso para Reconhecimento de Caracteres Alfabéticos. **Revista de Sistemas de Informação da FSMA**, Visconde de Araújo, v. 22, p. 49–59, 2018.
- ELDELE, E.; RAGAB, M.; CHEN, Z.; WU, M.; KWOH, C. K.; LI, X.; GUAN, C. **Time-Series Representation Learning via Temporal and Contextual Contrasting**. Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence. **Anais...California: International Joint Conferences on Artificial Intelligence Organization**, ago. 2021. Disponível em: <<https://www.ijcai.org/proceedings/2021/324>>
- FACELI, K.; LORENA, A. C.; GAMA, J.; DE CARVALHO, A. **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2019.
- FAN, C.; WANG, J.; GANG, W.; LI, S. Assessment of deep recurrent neural network-based strategies for short-term building energy predictions. **Applied Energy**, Amsterdam, v. 236, p. 700–710, 2019.
- FARIA, E. L. **Redes neurais convolucionais aplicas à negociação de ativos no mercado financeiro**. Dissertação de mestrado—São Bernardo do Campo: FEI, 2021.
- FERNANDES, L. DOS R.; DUARTE, C. R.; SOUTO, M. V. S.; AMARO, V. E. **Análise temporal em curto tempo das barras arenosas na praia de Ponta Grossa, região costeira de Icapuí/CE**. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR. **Anais...João Pessoa-PB: INPE**, 2015.
- FITTON, J. M.; HANSOM, J. D.; RENNIE, A. F. A national coastal erosion susceptibility

model for Scotland. **Ocean & Coastal Management**, Amsterdam, v. 132, p. 80–89, 2016.

FOLEY, J. A.; DEFRIES, R.; ASNER, G. P.; BARFORD, C.; BONAN, G.; CARPENTER, S. R.; CHAPIN, F. S.; COE, M. T.; DAILY, G. C.; GIBBS, H. K.; HELKOWSKI, J. H.; HOLLOWAY, T.; HOWARD, E. A.; KUCHARIK, C. J.; MONFREDA, C.; PATZ, J. A.; PRENTICE, I. C.; RAMANKUTTY, N.; SNYDER, P. K. Global Consequences of Land Use. **Science**, Washington, v. 309, n. 5734, p. 570–574, 2005.

FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics**, Berlin, v. 36, n. 4, p. 193–202, 1980.

GAUTAM, V. K.; GAURAV, P. K.; MURUGAN, P.; ANNADURAI, M. Assessment of Surface Water Dynamics in Bangalore Using WRI, NDWI, MNDWI, Supervised Classification and K-T Transformation. **Aquatic Procedia**, Amsterdam, v. 4, n. January 2016, p. 739–746, 2015.

GE, L.; LI, X.; WU, F.; TURNER, I. L. **Coastal erosion mapping through intergration of SAR and Landsat TM imagery**. IEEE International Geoscience and Remote Sensing Symposium - IGARSS. **Anais...**Melbourne: 2013.

GÉRON, A. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn e TensorFlow**. Rio de Janeiro: Altsa Books, 2019.

GOLDSTEIN, E. B.; COCO, G.; PLANT, N. G. A review of machine learning applications to coastal sediment transport and morphodynamics. **Earth-Science Reviews**, Amsterdam, v. 194, p. 97–108, jul. 2019.

GONÇALVES, G.; DURO, N.; SOUSA, E.; FIGUEIREDO, I. AUTOMATIC EXTRACTION OF TIDE-COORDINATED SHORELINE USING OPEN SOURCE SOFTWARE AND LANDSAT IMAGERY. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Hannover, v. XL-7/W3, p. 953–957, 2015.

GONÇALVES, R. M.; SALEEM, A.; QUEIROZ, H. A. A.; AWANGE, J. L. A fuzzy model integrating shoreline changes, NDVI and settlement influences for coastal zone human impact classification. **Applied Geography**, Amsterdam, v. 113, p. 102093, 2019.

GUIMARÃES, U. S.; RODRIGUES, T. W. P.; DE LOURDES BUENO TRINDADE GALO, M.; PAMPLONA, V. M. S. **Change detection applied on shorelines in the mouth of Amazon River**. IEEE International Symposium on Geoscience and Remote Sensing (IGARSS). **Anais...**Quebec: 2014.

GUO, Q.; PU, R.; ZHANG, B.; GAO, L. **A comparative study of coastline changes at Tampa Bay and Xiangshan Harbor during the last 30 years**. IEEE International Geoscience and Remote Sensing Symposium (IGARSS). **Anais...**Beijing: 2016.

HAVIV, D.; RIVKIND, A.; BARAK, O. Understanding and controlling memory in recurrent neural networks. **36th International Conference on Machine Learning, ICML 2019**, Long Beach, v. 2019- June, p. 4733–4741, 2019.

HINTON, G. E.; SRIVASTAVA, N.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. R. Improving neural networks by preventing co-adaptation of feature

detectors. **arXiv**, Ithaca, p. 1–18, 3 jul. 2012.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Computation**, San Diego, v. 9, n. 8, p. 1735–1780, 1997.

HUBEL, D. H. Single unit activity in striate cortex of unrestrained cats. **The Journal of physiology**, Malden, v. 147, n. 2, p. 226–238, 2 set. 1959.

HUBEL, D. H.; WIESEL, T. N. Receptive fields and functional architecture of monkey striate cortex. **The Journal of physiology**, Malden, v. 195, n. 1, p. 215–243, mar. 1968.

INDOLIA, S.; GOSWAMI, A. K.; MISHRA, S. P.; ASOPA, P. Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. **Procedia Computer Science**, Amsterdam, v. 132, p. 679–688, 2018.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2011.

KERH, T.; LU, H.; SAUNDERS, R. Shoreline Change Estimation from Survey Image Coordinates and Neural Network Approximation. **International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering**, Coimbatore, v. 8, n. 4, p. 381–386, 2014.

KHAN, A.; SOHAIL, A.; ZAHOORA, U.; QURESHI, A. S. A survey of the recent architectures of deep convolutional neural networks. **Artificial Intelligence Review**, [s. l.], v. 53, n. 8, p. 5455–5516, 2020.

LEATHERMAN, S. P. Coastal Erosion and the United States National Flood Insurance Program. **Ocean & Coastal Management**, Amsterdam, v. 156, p. 35–42, 2018.

LI, Y.; VAN OOSTEROM, P.; GE, Y.; ZHANG, X.; BAART, F. A CNN LSTM method for the morphology evolution prediction of beach mega-nourishment. **IEEE Access**, Nova York, v. 8, p. 184512–184523, 2020.

LI, Z.; LIU, F.; YANG, W.; PENG, S.; ZHOU, J. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. **IEEE Transactions on Neural Networks and Learning Systems**, Nova York, p. 1–21, 2021.

LIN, Z.; LI, M.; ZHENG, Z.; CHENG, Y.; YUAN, C. Self-attention ConvLSTM for spatiotemporal prediction. **AAAI 2020 - 34th AAAI Conference on Artificial Intelligence**, Nova York, p. 11531–11538, 2020.

LIU, X. **The coastal erosion of the abandoned Yellow River Delta in northern Jiangsu province, China: Based on analysis of remote sensing images**. 19th International Conference on Geoinformatics. **Anais...Shanghai**: 2011.

MARTINS, K. A.; PEREIRA, P. S. Coastal Erosion at Pau Amarelo Beach, Northeast of Brazil. **Journal of Coastal Research**, Carolina do Norte, v. 71, n. sp1, p. 17–23, 1 out. 2014.

MATHER, P. M.; KOCH, M. Computer Processing of Remotely-Sensed Images: An Introduction, Fourth Edition. **Computer Processing of Remotely-Sensed Images: An Introduction**, 2010.

- MAULUD, K. N. A.; RAFAR, R. M. **Determination the impact of sea level rise to shoreline changes using GIS**. International Conference on Space Science and Communication (IconSpace). **Anais...Langkawi**: 2015.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, [s. l.], v. 5, n. 4, p. 115–133, 1943.
- MELO, D. H. C. T. B. **Uso de dados IKONOS II na análise urbana: testes operacionais na zona Leste de São Paulo**. Tese de doutorado—São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 2015.
- MELO, G. DE; SUGIMOTO, D.; TASINAFFO, P.; MOREIRA, A.; CUNHA, A.; DIAS, L. A new approach to river flow forecasting: LSTM and GRU multivariate models. **IEEE Latin America Transactions**, Nova York, v. 17, n. 12, p. 1978–1986, 2019.
- MESQUITA, C. M.; OLIVEIRA, R.; PEREIRA, A. C. M. **Utilização de uma rede neural LSTM e testes da razão da variância para previsões em séries de ativos da Bovespa**. Belo Horizonte: Universidade Federal de Minas Gerais (UFMG), 2019.
- MOREIRA, A. D.; ROMARIZ, C. D.; SOUTO, M. V. S. Aplicação de Técnicas de Sensoriamento Remoto na Análise Multitemporal da Linha de Costa Região de Icapuí/Ce, entre 1984 e 2013. **Revista Geonorte**, Manaus, v. 16, n. 4, p. 52–58, 2014.
- MORORÓ, E. A. A.; SILVA, R. M. N. DA; SOUSA, M. V. S.; DUARTE, C. R. **Análise de 22 anos (1991 - 2013) da evolução costeira para a porção do litoral cearense, a oeste da cidade de Fortaleza, por meio de imagens históricas da série Landsat**. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR. **Anais...João Pessoa-PB: INPE**, 2015.
- MOSKOLAÏ, W. R.; ABDU, W.; DIPANDA, A.; KOLYANG, D. T. Application of LSTM architectures for next frame forecasting in Sentinel-1 images time series. **arXiv**, Ithaca, p. 13, 2020.
- NGUYEN, Q. H.; TAKEWAKA, S. Land subsidence and its effects on coastal erosion in the Nam Dinh Coast (Vietnam). **Continental Shelf Research**, Amsterdam, v. 207, p. 104227, 2020.
- NICHOLLS, R. J.; HOOZEMANS, F. M. J.; MARCHAND, M. Increasing flood risk and wetland losses due to global sea-level rise: regional and global analyses. **Global Environmental Change**, Amsterdam, v. 9, n. SUPPL., p. S69–S87, 1999.
- PEPONI, A.; MORGADO, P.; TRINDADE, J. Combining Artificial Neural Networks and GIS Fundamentals for Coastal Erosion Prediction Modeling. **Sustainability**, Berna, v. 11, n. 4, 2019.
- RAJAGUKGUK, R. A.; RAMADHAN, R. A. A.; LEE, H. J. A review on deep learning models for forecasting time series data of solar irradiance and photovoltaic power. **Energies**, Basel, v. 13, n. 24, 2020.
- ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. **Psychological Review**, Washington, v. 65, n. 6, p. 19–27, 1958.
- ROWLEY, R.; KOSTELNICK, J.; BRAATEN, D.; LI, X.; MEISEL, J. Risk of Rising Sea

Level to Population and Land Area. **Eos, Transactions American Geophysical Union**, Washington, v. 88, 2007.

SALMAN, A. G.; HERYADI, Y.; ABDURAHMAN, E.; SUPARTA, W. Single Layer & Multi-layer Long Short-Term Memory (LSTM) Model with Intermediate Variables for Weather Forecasting. **Procedia Computer Science**, Amsterdam, v. 135, p. 89–98, 2018.

SANTOS, P. M. DOS; LUDERMIR, T. B.; PRUDENCIO, R. B. C. **Selection of Time Series Forecasting Models based on Performance Information**. Fourth International Conference on Hybrid Intelligent Systems (HIS'04). **Anais...Kitakyushu: IEEE**, 2004. Disponível em: <<http://ieeexplore.ieee.org/document/1410031/>>

SANTOS, M. S. T.; AMARO, V. E.; SOUTO, M. V. S. Metodologia geodésica para levantamento de linha de costa e modelagem digital de elevação de praias arenosas em estudos de precisão de geomorfologia e dinâmica costeira. **Revista Brasileira de Cartografia**, Monte Carmelo, v. 63, n. 5, p. 663–681, 2011.

SHI, X.; CHEN, Z.; WANG, H.; YEUNG, D. Y.; WONG, W. K.; WOO, W. C. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. **Advances in Neural Information Processing Systems**, Cambridge, v. 2015- Janua, p. 802–810, 2015.

SILVA, I. N. DA. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. 2ª ed. São Paulo: Artliber, 2016.

SILVA, M. P. DOS S.; CÂMARA, G.; ESCADA, M. I. S. Image Mining: Detecting Deforestation Patterns Through Satellites. In: **Data Mining Applications for Empowering Knowledge Societies**. Hershey: IGI Global, 2009. p. 55–75.

SILVA, M. P. S.; CAMARA, G.; SOUZA, R. C. M.; VALERIANO, D. M.; ESCADA, M. I. S. **Mining patterns of change in remote sensing image databases**. Fifth IEEE International Conference on Data Mining (ICDM'05). **Anais...Houston: 2005**.

SILVA NETO, C. Â. **Avaliação das Influências de Canais de Maré na Dinâmica Costeira em Icapuí (CE) através de sensores remotos óticos**. Trabalho de Conclusão de Curso (Graduação em Geologia)—Fortaleza: Universidade Federal do Ceará, 2019.

SILVA NETO, C. Â. DA; MAIA, A. D. O.; DUARTE, C. R.; SOUTO, M. V. S. **Caracterização de feições da Planície Costeira de Icapuí (CE) utilizando imagens Sentinel-2**. XIX Simpósio Brasileiro de Sensoriamento Remoto. **Anais...Santos: INPE**, 2019.

SOUSA, W. R. N.; BANDEIRA, C. L. L.; RIBEIRO, E. C.; CASTRO, A. F.; BUSTOS, H. I. A.; SILVA, M. P. S. Monitoring of Desertification Processes Through Trend Estimates of Time Series. **Proceedings of the 4th GEOBIA**, Rio de Janeiro, p. 561–565, 2012.

SOUSA, W. R. N.; SOUTO, M. V. S.; MATOS, S. S.; DUARTE, C. R.; SALGUEIRO, A. R. G. N. L.; NETO, C. A. D. S. Creation of a coastal evolution prognostic model using shoreline historical data and techniques of digital image processing in a GIS environment for generating future scenarios. **International Journal of Remote Sensing**, Londres, v. 39, n. 13, p. 4416–4430, 2018.

SOUSA, W. R. N.; SOUTO, M. V. S.; MATOS, S. S.; SILVA NETO, C. Â. DA; DUARTE, C. R. Extração automática de linhas de costa aplicada ao monitoramento de processos de erosão

costeira. **Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto -SBSR**, Santos, p. 6423–6429, 2017.

SOUTO, M. V. S. **Análise da evolução costeira do litoral setentrional do estado do Rio Grande do Norte, região sob influência da indústria petrolífera**. Tese (Doutorado em Geodinâmica)—Natal: UFRN, 2009.

SUWANPRASIT, C. **Effects of near shore land-use dynamic on coastal erosion in Phuket, Thailand**. 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). **Anais...**Milão: IEEE, jul. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7326912/>>.

TIGGELOVEN, T.; COUASNON, A.; VAN STRAATEN, C.; MUIS, S.; WARD, P. J. Exploring deep learning capabilities for surge predictions in coastal areas. **Scientific Reports**, Londres, v. 11, n. 1, p. 1–15, 2021.

TU, Z.; HE, F.; TAO, D. **Understanding Generalization in Recurrent Neural Networks**. International Conference on Learning Representations. **Anais...**[s. l.]: 2020. Disponível em: <<https://openreview.net/forum?id=rkkg6xBYDH>>.

VENANCIO, K. K.; GARCIA, P. D.; GIRELI, T. Z.; CORRÊA, T. B. Hydrodynamic modeling with scenario approach in the evaluation of dredging impacts on coastal erosion in Santos (Brazil). **Ocean & Coastal Management**, Amsterdam, v. 195, p. 105227, 2020.

WANG, Z.; BOVIK, A. C.; SHEIKH, H. R.; SIMONCELLI, E. P. Image quality assessment: From error visibility to structural similarity. **IEEE Transactions on Image Processing**, Tampere, v. 13, n. 4, p. 600–612, 2004.

WANG, Z.; ZHANG, B.; ZHANG, S.; LI, X.; LIU, D.; SONG, K.; LI, J.; LI, F.; DUAN, H. Changes of Land Use and of Ecosystem Service Values in Sanjiang Plain, Northeast China. **Environmental monitoring and assessment**, Upsália, v. 112, p. 69–91, 2006.

WEN, S.; ZHANG, F.; WANG, X.; WANG, Z.; LI, F.; WANG, F.; WANG, X.; XU, X. **Hazard degree assessment of coastal erosion at Tianlongsi adjacent sandy coast**. 4th International Workshop on Earth Observation and Remote Sensing Applications (EORSA). **Anais...**Guangzhou: IEEE, jul. 2016. Disponível em: <<https://ieeexplore.ieee.org/document/7552843/>>.

XIMENES, D. R. B.; SOUTO, M. V. S.; DUARTE, C. R. Análise multitemporal da linha de costa para avaliação da evolução costeira na região de Icapuí/CE, Nordeste brasileiro, no período de 1984 a 2011. **XVI Simpósio Brasileiro de Sensoriamento Remoto**, Foz do Iguaçu, p. 1618–1625, 2013.

YI, Z. Evaluation and Implementation of Convolutional Neural Networks in Image Recognition. **Journal of Physics: Conference Series**, Bristol, v. 1087, n. 6, 2018.

YIN, C.; BINH, L. T.; ANH, D. T.; MAI, S. T.; LE, A.; NGUYEN, V. H.; NGUYEN, V. C.; TINH, N. X.; TANAKA, H.; VIET, N. T.; NGUYEN, L. D.; DUONG, T. Q. Advanced Machine Learning Techniques for Predicting Nha Trang Shorelines. **IEEE Access**, Nova York, v. 9, p. 98132–98149, 2021.

ZHANG, Z.; DONG, Y.; YUAN, Y. Temperature Forecasting via Convolutional Recurrent

Neural Networks Based on Time-Series Data. **Complexity**, Londres, v. 2020, 2020.