



**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIA NAVAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA NAVAL**

LÚCIO CARLOS PINHEIRO CAMPOS FILHO

**MODELO DE PREVISÃO DE CALADOS OPERACIONAIS E
CAPACIDADES DE CARGA DE COMBOIOS FLUVIAIS VIA
MACHINE LEARNING A PARTIR DE TEMPERATURAS E
PRECIPITAÇÕES OBTIDAS POR SENSORIAMENTO REMOTO**

Belém, PA
2023

LÚCIO CARLOS PINHEIRO CAMPOS FILHO

**MODELO DE PREVISÃO DE CALADOS OPERACIONAIS E
CAPACIDADES DE CARGA DE COMBOIOS FLUVIAIS VIA
MACHINE LEARNING A PARTIR DE TEMPERATURAS E
PRECIPITAÇÕES OBTIDAS POR SENSORIAMENTO REMOTO**

Dissertação de Mestrado apresentada à
Universidade Federal do Pará, como requisito
para a obtenção do grau de mestre em
Engenharia Naval pela Universidade Federal do
Pará sob a orientação do Prof. D. Sc. Nelio
Moura de Figueiredo.

Belém, PA
2023

LÚCIO CARLOS PINHEIRO CAMPOS FILHO

**MODELO DE PREVISÃO DE CALADOS OPERACIONAIS E
CAPACIDADES DE CARGA DE COMBOIOS FLUVIAIS VIA
MACHINE LEARNING A PARTIR DE TEMPERATURAS E
PRECIPITAÇÕES OBTIDAS POR SENSORIAMENTO REMOTO**

Dissertação de Mestrado apresentada à
Universidade Federal do Pará, como requisito
para a obtenção do grau de mestre em
Engenharia Naval pela Universidade Federal do
Pará sob a orientação do Prof. D. Sc. Nelio
Moura de Figueiredo.

BANCA EXAMINADORA:

Prof. D. Sc. Nelio Moura de Figueiredo
(Orientador)

Prof. D. Sc. Valcir João da Cunha Farias
(Coorientador)

Prof. Hito Braga de Moraes, Ph.D.
(Membro interno)

Prof. Claudio José Cavalcante Blanco, Ph.D.
(Membro Externo)

Belém - PA
2023

Aos meus pais, Nildete Smith e Lúcio Campos,

À minha namorada, Márcia Alho,

Ao meu orientador, D. Sc. Nelio Figueiredo,

Aos meus amigos,

Dedico este trabalho.

AGRADECIMENTOS

Sempre em primeiro lugar à Deus, pela minha vida e por me conceder saúde e determinação para ir em busca das conquistas e da consecução dos meus objetivos, permitindo-me ultrapassar todos os obstáculos encontrados ao longo da minha trajetória nestes últimos anos. À Nossa Senhora de Nazaré por interceder perante Deus diante das mais variadas situações da minha vida, sempre me abençoando e me concedendo sabedoria e discernimento para enfrentar as dificuldades. À Nossa Senhora Aparecida, por todas as bênçãos e glórias concedidas em minha vida.

Aos meus pais, Lúcio Carlos P. Campos e Nildete Smith Nunes, por lutarem ao meu lado e se manterem firmes em todos os momentos da minha vida. Agradeço a estes por todas as abdições, por todo o esforço e oração dedicados a mim. Em especial, agradeço a minha Mãe por toda dedicação cotidiana para auxílio na minha árdua rotina acadêmica e profissional, haja vista que, certamente, sem ela, as minhas conquistas e oportunidades alcançadas não teriam o mesmo brilho nem o mesmo impacto.

Agradeço ao meu padrinho, Abdias Smith Nunes (*in memoriam*) por ter sempre acreditado em mim e depositado, com plena convicção, esperanças nas minhas conquistas.

À minha namorada e melhor amiga, Márcia L. Batista Alho, por todo o companheirismo, zelo, confiança e cumplicidade, sendo fundamental para esta conquista. Sou totalmente grato por todos os momentos vividos até a presente data, na certeza que muitos outros momentos de vitória como estes virão.

Não mais no âmbito familiar, mas sim na esfera profissional, muitos são os agradecimentos às pessoas que passaram e que ainda se encontram presentes na minha vida e cotidiano, visto que nestes últimos anos de graduação, mestrado e docência, muitas foram as pessoas que me ajudaram e depositaram confiança no meu potencial. Agradeço a todos os professores, chefes, gerentes, orientadores e companheiros de trabalho os quais tive e tenho a oportunidade de conviver e aprender. Agradeço a todos os profissionais do GHPORT, GTNAV, Estaleiro Rio Maguari, Registro Brasileiro de Navios e Aeronaves (RBNA), Norte Marine e demais lugares de aprendizado. Dedico também aos demais que tiveram participação na conquista, como familiares, amigos, colegas de curso, corpo docente e profissionais indiretos. Certamente, os objetivos que estão por vir serão maiores ainda e também dependerão daqueles que estarão ao meu redor.

Dedico esta vitória também ao meu orientador, mentor e amigo, D. Sc. Nelio Moura de Figueiredo, por sempre ter acreditado no meu potencial e por todas as oportunidades que me

proporcionou ao longo dos últimos anos. Certamente, sem seu auxílio e parceria ao longo dos últimos seis anos este triunfo não seria o mesmo. Agradeço também ao meu coorientador, D. Sc. Valcir Farias, por todo suporte e disponibilidade dada para o desenvolvimento desta dissertação.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo fomento à ciência e ao desenvolvimento de pesquisas por intermédio dos Programas de Pós-Graduação vinculados às UF's, em especial, ao PPGENAV, programa o qual sou vinculado.

Agradecimento especial a minha *alma matter*, Universidade Federal do Pará (UFPA), instituição que tanto amo e defendo. Foram seis anos de vivência, experiências e felicidades como discente de graduação, pós-graduação e docente substituto, torcendo para que venham muitos outros anos como doutorando e, futuramente, docente efetivo, de modo a ser possível contribuir significativamente para a devida reconção e medrança desta colenda instituição.

Em complementação, ainda na esfera institucional, agradeço aos meus alunos da graduação em Engenharia Naval, por toda a atenção e valorização conferida a mim dentro de sala, portanto, meu sincero agradecimento. Nestes últimos dez meses de magistério tive o merecimento de aprender muito com cada um, tanto no âmbito técnico-profissional quanto no pessoal.

De modo a finalizar este breve texto de gratulação, destaco esta vitória também aos professores e amigos M.Sc. Yuri Guedes, M. Sc. Emmanuel Loureiro, Dr. Pedro Lameira, Dr. Hito Braga e Vânia Figueredo Coelho, os quais tive e tenho a oportunidade de desenvolver, além de uma relação de sala de aula, uma relação de amizade e profissional, de muito aprendizado e experiências. Agradeço também ao Prof. M. Sc. Paulo Zigmantas (*in memoriam*), por toda a confiança depositada em mim e por todas as palavras e energias positivas direcionadas a mim em vida. Teço agradecimentos também ao Prof. Cláudio Blanco, Ph. D., por, desde os primeiros contatos, depositar confiança em meu desenvolvimento científico.

“Aqueles que se sentem satisfeitos sentam-se e nada fazem. Os insatisfeitos são os únicos benfeitores do mundo.”

(Walter S. Landor)

“O homem não teria alcançado o possível se, repetidas vezes, não tivesse tentado o impossível.”

(Max Weber)

RESUMO

As vias navegáveis interiores são vulneráveis às alterações climáticas, uma vez que a navegação fluvial depende dos níveis das águas. A exemplo disso, tem-se os impactos das mudanças de temperatura e pressão no Oceano Pacífico que acarretam alterações no ciclo hidrológico, em especial na precipitação, ocasionando mudanças na configuração sazonal das lâminas d'água, sofrendo influências do El Niño e La Niña. Esta sazonalidade de cursos d'água fluviais se caracteriza como um fator limitante do transporte nas localidades em que esta limitação é considerável, afetando diretamente as condições de carregamento das embarcações que utilizam as vias navegáveis, fato este que justifica a importância do desenvolvimento de ferramentas capazes de aferir e analisar estas influências negativas, a fim de mitigá-las. Atrelado a isso, destaca-se que nestes cursos fluviais, outro ponto de destaque que influencia diretamente na navegação se caracteriza pela escassez e qualidade de dados de estações pluviométricas e fluviométricas *in situ* para utilização em modelos de previsão, fatos estes que justificam a utilização de dados obtidos via satélite. Dentro deste contexto, portanto, este trabalho objetivou a elaboração de um modelo de previsão de lâminas d'água e calados operacionais via Redes Neurais Artificiais do tipo *Perceptron* Multicamada e Rede Neural Recorrente a partir de temperaturas e precipitações obtidas por satélite com a plataforma *Google Earth Engine*, a fim de possibilitar a obtenção das capacidades de carga de uma embarcação tipo para uma dada hidrovia, avaliando em condições de cheia e estiagem os impactos a este transporte. Como forma de validar os modelos desenvolvidos, aplicou-se um estudo de caso para o Rio Madeira, no trecho de Porto Velho à Cujubim, na Bacia Amazônica, no Brasil, onde a movimentação de cargas, em especial o transporte de grãos, é pujante e dependente do modal hidroviário. As condições planialtimétricas da via navegável foram avaliadas em termos de profundidade e largura com a geração do Modelo Digital de Elevação e aplicação do software “*DimChannel*” (*Dimensioning of Navigation Channel*) no processo de dimensionamento geométrico do canal de navegação. Os resultados obtidos para o estudo de caso mostraram-se satisfatórios e tornaram possível a validação dos módulos desenvolvidos e possibilitaram a aferição das perdas de capacidade nos períodos de estiagem, bem como a verificação de gargalos de navegação.

Palavras-chave: Precipitação via Satélite. Modelagem Hidrológica. Via navegável. Rede Neural Artificial. Ferramenta Computacional.

ABSTRACT

Inland waterways are vulnerable to climate change, as river navigation depends on water levels. As an example, there are the impacts of changes in temperature and pressure in the Pacific Ocean that lead to changes in the hydrological cycle, especially in precipitation, causing changes in the seasonal configuration of water depths, suffering influences from El Niño and La Niña. This seasonality of river watercourses is characterized as a limiting factor for transport in locations where this limitation is considerable, directly affecting the loading conditions of vessels that use waterways, a fact that justifies the importance of developing tools capable of to assess and analyze these negative influences, to mitigate them. Linked to this, it should be noted that in these river courses, another highlight that directly influences navigation is characterized by the scarcity and quality of data from in situ rainfall and fluviometric stations for use in forecast models, facts that justify the use of data obtained via satellite. Within this context, therefore, this work aimed at the elaboration of a forecast model of water depths and operational drafts via Artificial Neural Networks of the Multilayer Perceptron type and Recurrent Neural Network from temperatures and precipitations obtained by satellite with the Google Earth platform Engine, in order to make it possible to obtain the load capacities of a type vessel for a given waterway, evaluating the impacts on this transport in flood and dry conditions. As a way of validating the developed models, a case study was applied to the Madeira River, in the stretch from Porto Velho to Cujubim, in the Amazon Basin, in Brazil, where the movement of cargo, especially the transport of grains, is strong and dependent on the waterway modal. The planialtimetric conditions of the waterway were evaluated in terms of depth and width with the generation of the Digital Elevation Model and application of the software “DimChannel” (Dimensioning of Navigation Channel) in the process of geometric dimensioning of the navigation channel. The results obtained for the case study were satisfactory and made it possible to validate the developed modules and make it possible to measure capacity losses during dry periods, as well as to verify navigation bottlenecks.

Keywords: Precipitation via Satellite. Hydrological Modelling. Waterway. Artificial Neural Network. Computational Tool.

LISTA DE FIGURAS

Figura 1 - Detalhamento Metodológico.....	57
Figura 2 - Fluxograma Metodológico do Módulo 01	60
Figura 3 – <i>Google Developer - GEE</i>	65
Figura 4 – Seleção de Período de Análise	66
Figura 5 – Tipo de Elemento de Captação de Dados	67
Figura 6 – Aquisição de Imagem de Precipitação	68
Figura 7 – Exemplo de Aquisição de Imagem de Precipitação.....	69
Figura 8 - Fluxograma Metodológico do Módulo 02	72
Figura 9 – <i>Google Developer - GEE</i>	74
Figura 10 - Fluxograma Metodológico do Módulo 03	76
Figura 11 – Estruturação do Neurônio Artificial.....	80
Figura 12 – Função de Ativação Linear	81
Figura 13 – Função de Ativação Linear por Partes	82
Figura 14 – Função de Ativação Limiar.....	82
Figura 15 – Função de Ativação Sigmoide Logística.....	83
Figura 16 – Função de Ativação Sigmoide Tangente.....	84
Figura 17 - Estruturação de Modelos de RNA do Tipo <i>Perceptron</i>	85
Figura 18 – Fluxo de Sinal com Neurônio j sendo um nó de saída.....	88
Figura 19 – Fluxo de Sinal com Neurônio j sendo um nó oculto.....	89
Figura 20 – Retropropagação dos sinais de erro.....	90
Figura 21 – RNN x MLP	95
Figura 22 - Fluxograma Metodológico do Módulo 04	99
Figura 23 - Fluxograma Metodológico do Módulo 05	105
Figura 24 - Fluxograma da geração das bases geométricas.....	106
Figura 25 - Parâmetros Geométricos de Vias Navegáveis	108

Figura 26 - Exemplo de seção transversal de canal de via única com talude normal	109
Figura 27 - Exemplo de seção transversal de canal de tráfego nos dois sentidos	110
Figura 28 - Faixa de Trajetória Varrida.....	110
Figura 29 - Gráficos da Largura da Faixa de Trajetória Varrida.....	113
Figura 30 - Raio de Curvatura de Trechos Curvos	117
Figura 31 - Fluxograma simplificado do Software.....	119
Figura 32 - Área de Aplicação do Estudo de Caso.....	120
Figura 33 – Movimentação de Cargas – Rio Madeira (2013 a 2022)	125
Figura 34 – Movimentação por Natureza de Cargas – Rio Madeira (2022)	125
Figura 35 – Movimentação por Porto – Rio Madeira (2022).....	126
Figura 36 - Espacialização de Cartas Náuticas - Rio Madeira	128
Figura 37 – Mapa de Localização – Porto Velho a Cujubim	129
Figura 38 – Espacialização dos Pontos de Temperatura do Pacífico	132
Figura 39 – Estruturação da Rede Neural Desenvolvida.....	134
Figura 40 - Formação do Comboio Fluvial	137
Figura 41 - Formação do Comboio Fluvial	138
Figura 42 – Características Hidrostáticas do Comboio	139
Figura 43 – Curvas de Capacidade de Carga.....	140
Figura 44 – Curvas de Precipitação Aquisitadas para EA.....	143
Figura 45 – Curvas de Precipitação Histórica para PSEA, PRI1 e PR2.....	144
Figura 46 – Curvas de Precipitação Histórica para PSEA, PRI1 e PR2 – 2016 a 2018.....	144
Figura 47 – Série Histórica de Temperatura – TSM1 a TSM6	146
Figura 48 – Série Histórica de Temperatura – TSM1 a TSM6 – 2016 a 2018.....	146
Figura 49 – Níveis d’água previstos – Real x Perceptron x Recorrente.....	148
Figura 50 – Níveis d’água previstos – Real x <i>Perceptron</i> x Recorrente – 2016 a 2018	150
Figura 51 - Tela de Informações da Embarcação	151

Figura 52 - Tela de Informações da Hidrovia.....	151
Figura 53 - Tela de Resultados para o Trecho.....	152
Figura 54 – Modelagem Digital de Elevação – Período de Estiagem.....	153
Figura 55 – Modelagem Digital de Elevação – Período de Cheia.....	154
Figura 56 – MDE Período de Estiagem – Trecho 01	156
Figura 57 – MDE Período de Estiagem – Trecho 02	156
Figura 58 – MDE Período de Estiagem – Trecho 03	157
Figura 59 – MDE Período de Estiagem – Trecho 04	157

LISTA DE TABELAS

Tabela 1 - Fatores de Influência à Segurança da Navegação	24
Tabela 2 – Definição de Principais Satélites pela Literatura.....	61
Tabela 3 – Ordem de Prioridades de Critérios para Alternativas	63
Tabela 4 – Matriz Modelo de Seleção de Satélites.....	63
Tabela 5 – Ordem de Prioridades de Critérios para Alternativas	71
Tabela 6 – Matriz Modelo de Seleção de Satélites.....	74
Tabela 7 – Aquisição de Variáveis	78
Tabela 8 – Definição de Entradas e Saídas.....	79
Tabela 9 – Hiperparâmetros do Melhor Modelo – RNA Perceptron	97
Tabela 10 – Hiperparâmetros do Melhor Modelo – RNA Recorrente LSTM.....	98
Tabela 11 - Equações da Largura da Faixa de Trajetória Varrida.....	114
Tabela 12 - Raio de Curvatura de Giro.....	118
Tabela 13 - Caracterização Geral Rio Madeira	122
Tabela 14 - Informações de Cartas Náuticas - Rio Madeira.....	127
Tabela 15 – Satélites Utilizados – Estudo de Caso	130
Tabela 16 – Satélite Utilizado – Estudo de Caso - TSM.....	131
Tabela 17 – Coordenadas Geográficas – Estações Base de Temperatura	132
Tabela 18 – Estações de Precipitação Avaliadas.....	133
Tabela 19 – Estações de Nível D’água Avaliadas	133
Tabela 20 – Características do Comboio Fluvial.....	136
Tabela 21 – Características do Comboio Fluvial.....	137
Tabela 22 – Satélites Melhores ranqueados definidos.....	142
Tabela 23 – Métricas Satélites CHIRPS e PersiANN	143
Tabela 24 – Métricas Estatísticas - <i>Perceptron</i> Multicamadas	148
Tabela 25 – Métricas Estatísticas – Rede Neural Recorrente.....	149

Tabela 26 – Capacidades de Carga Obtidas	159
--	-----

LISTA DE SIGLAS

AHIMOC	Administração das Hidrovias da Amazônia Ocidental
AHIMOR	Administração das Hidrovias da Amazônia Oriental
AHINOR	Administração das Hidrovias do Nordeste
AHIPAR	Administração da Hidrovia do Paraguai
AHITAR	Administração das Hidrovias do Tocantins e Araguaia
AHRANA	Administração da Hidrovia do Paraná
AHSFRA	Administração da Hidrovia do São Francisco
AHSUL	Administração das Hidrovias do Sul
AIS	Sistema Automático de Identificação
ANA	Agência Nacional de Águas
ANTAQ	Agência Nacional de Transportes Aquaviários
BIAS	Viés Relativo
BP	<i>Backpropagation</i>
CFPV	Capitania Fluvial de Porto Velho
CFSR	<i>Climate Forecast System Reanalysis</i>
CHIRPS	Precipitação Infravermelha do Grupo de Riscos Climáticos com Dados de Estação
CHM	Centro de Hidrografia da Marinha
CMORPH	Produto <i>MORPHing</i> do Centro de Previsão Climática
CNA	Confederação da Agricultura e Pecuária do Brasil
CNRH	Conselho Nacional de Recursos Hídricos
CNT	Confederação Nacional do Transporte
COE	Coefficiente de Eficiência
CONAB	Companhia Nacional de Abastecimento
DHN	Diretoria de Hidrografia e Navegação
DL	<i>Deep Learning</i>

DNIT	Departamento Nacional de Infraestrutura de Transportes
ECMWF	Centro Europeu de Previsões Meteorológicas a Médio Prazo
<i>ENC</i>	<i>Electronic Navigation Chart</i>
ETCs	Estações de Transbordo de Carga
EVTEA	Estudos de Viabilidade Técnica, Econômica e Ambiental
FFNN	Rede neural <i>feed forward</i>
GEE	<i>Google Earth Engine</i>
GPCP	Produto de Climatologia de Precipitação Global
IBGE	Instituto Brasileiro de Geografia e Estatística
IMO	<i>International Maritime Organization</i>
LSTM	<i>Long Short Term Memory</i>
MLP	<i>Multi-Layer Perceptron</i>
MTPA	Ministério dos Transportes, Portos e Aviação Civil
<i>NCEP</i>	<i>National Centers for Environmental Prediction</i>
NPCF	Normas e Procedimentos da Capitania Fluvial
PHE	Plano Hidroviário Estratégico
PIANC	<i>Permanent International Association of Navigation Congresses</i>
PNIH	Plano Nacional de Integração Hidroviária
PNL	Programação não linear
PNLP	Plano Nacional de Logística Portuária
PNRH	Plano Nacional De Recursos Hídricos
R ²	Critério de desempenho de Nash e Sutcliffe
RF	<i>Random Forests</i>
RMSE	Critério de desempenho da raiz do erro quadrático médio
RNA	Rede Neural Artificial
RNN	Redes Neurais Recorrentes

TMPA	<i>Multi Satellite Precipitation Analysis</i>
TRMM	<i>Tropical Rainfall Measuring Mission</i>
TSM	Temperatura Superficial do Mar
UKC	<i>Under keel clearance</i>
USDA	<i>United States Department of Agriculture</i>
WWINN	<i>Worldwide Inland Navigation Network</i>

LISTA DE SÍMBOLOS

\bar{y}	Média dos valores presente na série histórica
y_i	Valor previsto pelo modelo
\hat{y}_i	Valor real
r_j	Junção somatória
w_{ij}	Fator de peso
$\varphi(\cdot)$	Função de ativação
x_i	Sinais de entrada
β_{kj}	Peso da conexão do neurônio escondido j com o neurônio de saída
y_k	k -ésima saída da rede
θ_k	Bias da k -ésima saída
$g(\cdot)$	Função de ativação do neurônio
j	Neurônio é um nó de saída
$e_j(n)$	Sinal do erro na saída do neurônio j para a iteração n
$d_j(n)$	Resposta desejada para o neurônio j
$y_j(n)$	Sinal funcional que aparece na saída do neurônio j na iteração n
h_t	Estado oculto na etapa de tempo t
W_{hx}	Matriz de pesos que transforma a entrada x_t no espaço oculto
W_{hh}	Matriz de pesos transforma o estado oculto anterior h_{t-1} no espaço oculto a
b_h	Viés associado ao estado oculto.
W_{yh}	Matriz de pesos que transforma o estado oculto em uma saída.
b_y	Viés associado à saída.
\bar{X}_n	Valor da variável normalizada
X_n	Valor real da variável
X_{\max}	Maior valor entre o conjunto de dados analisado
h	Espaçamento entre as balizas

An	Área da baliza submersa
xn	Distância da baliza n para um eixo de referência
∇	Volume deslocado
ρ	Densidade da água
g	Gravidade
I_L	Inércia longitudinal
I_T	Inércia transversal
L	Comprimento da embarcação
T	Calado da embarcação
A_{WL}	Área do plano de flutuação
K_b	Fator de correção para a largura do canal W em relação à boca (B)
T	Pontal
H	Profundidade do canal
V_S	Velocidade da embarcação

SUMÁRIO

1. INTRODUÇÃO	23
1.1. OBJETIVOS	26
1.1.1. Objetivo Geral.....	26
1.1.2. Objetivos Específicos	26
1.2. JUSTIFICATIVA	27
1.3. HIPÓTESE.....	29
1.4. ESTRUTURA DO TRABALHO	29
2. REVISÃO DE LITERATURA E REFERENCIAL TEÓRICO.....	31
2.1. IMPORTÂNCIA DO TRANSPORTE AQUAVIÁRIO	31
2.2. TRANSPORTE HIDROVIÁRIO DE CARGAS E PASSAGEIROS.....	32
2.2.1. Transporte Hidroviário no Rio Madeira	33
2.3. EMPECILHOS À NAVEGAÇÃO	35
2.4. FLUTUABILIDADE SAZONAL DE NÍVEIS D'ÁGUA.....	35
2.5. INFLUÊNCIA DOS EVENTOS ENOS NA PRECIPITAÇÃO.....	36
2.6. INFLUÊNCIA DA PRECIPITAÇÃO EM ANÁLISES HIDROLÓGICAS.....	39
2.7. PRECIPITAÇÃO PLUVIOMÉTRICA POR SATÉLITE.....	40
2.7.1. Utilização de Precipitação via Satélite na Amazônia	41
2.7.2. Satélites Globais para Avaliação de Precipitação.....	42
2.8. IMPORTÂNCIA DA ANÁLISE DA TEMPERATURAS SUPERFICIAL DO MAR (TSM).....	44
2.8.1. Aquisição de Dados de Temperatura por Satélite	45
2.9. USO DE REDES NEURAS NA HIDROLOGIA.....	46
2.10. PREVISÃO DE LÂMINAS D'ÁGUA	47
2.11. PREVISÃO DE CALADOS OPERACIONAIS E CAPACIDADES DE CARGA	48

2.12. PROPRIEDADES GEOMÉTRICAS E HIDROSTÁTICAS DE EMBARCAÇÕES.....	49
2.12.1. Cálculo de Curvas Hidrostáticas	49
2.12.2. Curvas Cruzadas	50
2.12.3. Cálculo de Curvas de Bonjean	50
2.13. DIMENSIONAMENTO DE VIAS NAVEGÁVEIS.....	51
3. MATERIAIS E MÉTODOS	53
3.1. MÓDULO 01: MODELO DE AQUISIÇÃO DE PRECIPITAÇÕES.....	59
3.1.1. Seleção de Satélites para Aplicação	60
3.1.2. Rotina Computacional para Leitura de Precipitação.....	63
3.1.3. Calibração de Medições de Precipitação <i>In Situ</i>	69
3.2. MÓDULO 02: MODELO DE AQUISIÇÃO DE TEMPERATURAS.....	72
3.2.1. Seleção de Satélites para Aplicação	73
3.2.2. Rotina Computacional para Leitura de Temperaturas.....	74
3.3. MÓDULO 03: PREVISÃO DE NÍVEIS D'ÁGUA	76
3.3.1. Base de Dados do Modelo.....	77
3.3.2. Modelos e Parâmetros	79
3.3.2.1. Neurônio Artificial	79
3.3.2.2. <i>Perceptron</i> Multicamadas – MLP	84
3.3.2.3. Aprendizado via Algoritmo de <i>Backpropagation</i>	86
3.3.2.4. Rede Neural Recorrente e LSTM.....	92
3.3.3. Treinamento, Calibração e Validação do Modelo	95
3.3.4. Seleção do Melhor Modelo	96
3.4. MÓDULO 04: CÁLCULO DE CALADOS OPERACIONAIS E CAPACIDADES DE CARGA.....	99
3.4.1. Modelagem Hidrostática da Embarcação Tipo.....	99

3.4.2.	Dimensões Verticais - <i>Underkeel clearance</i> e <i>Efeito SQUAT</i>	103
3.5.	MÓDULO 05: MODELO DE DEFINIÇÃO DE CONDIÇÕES PLANIALTIMÉTRICAS	105
3.5.1.	Modelo Digital de Elevação	105
3.5.1.1.	Base Cartográfica, Vazões e Níveis d'água.....	106
3.5.1.2.	Integração dos dados das cartas náuticas com os das imagens SRTM.....	107
3.5.1.3.	Geração do Modelo Digital de Elevação.....	107
3.5.2.	Definição das Condições Planialtimétricas	108
3.5.2.1.	Larguras em Trechos Retos	109
3.5.2.2.	Largura da Faixa de Trajetória Varrida (<i>Ws</i>).....	110
3.5.2.3.	Raio de Curvatura do Trecho Curvo (<i>Rc</i>).....	115
3.5.3.	Aplicação da Ferramenta Computacional: <i>Dimchannel</i>	118
4.	ESTUDO DE CASO: RIO MADEIRA	120
4.1.	CARACTERIZAÇÃO GERAL	121
4.2.	NAVEGABILIDADE	123
4.3.	CARACTERÍSTICAS ECONÔMICAS E DE MOVIMENTAÇÃO	124
4.4.	CARTAS NÁUTICAS	126
4.5.	TRECHO DE ANÁLISE E APLICAÇÃO DOS MODELOS	128
4.6.	PROVEDORES DE DADOS DE PRECIPITAÇÃO UTILIZADOS	130
4.7.	PROVEDOR DE DADOS DE TEMPERATURA UTILIZADOS	131
4.8.	ESTAÇÕES PLUVIOMÉTRICAS E FLUVIOMÉTRICAS UTILIZADAS	132
4.8.1.	Modelo de Previsão de Níveis d'Água	134
4.9.	CENÁRIOS DE ANÁLISE E CONDICIONANTES PARA DIMENSIONAMENTO DO CANAL	134
4.9.1.	<i>Underkeel Clearance</i> – Folga Abaixo da Quilha (FAQ)	135
4.9.2.	Embarcação de Projeto	136

5.	RESULTADOS.....	141
5.1.	RESULTADOS DA AQUISIÇÃO DE DADOS DE PRECIPITAÇÃO VIA SATÉLITE	142
5.2.	RESULTADOS DA AQUISIÇÃO DE DADOS DE TEMPERATURA VIA SATÉLITE	145
5.3.	NÍVEIS D'ÁGUA SIMULADOS	147
5.4.	CARACTERÍSTICAS PLANIALTIMÉTRICAS.....	151
5.5.	CANAL PROJETADO E RESTRIÇÕES DE NAVEGAÇÃO	152
5.6.	CAPACIDADES DE CARGA PREVISTAS	159
6.	CONCLUSÕES.....	161
6.1.	CONCLUSÕES PARA OS MÓDULOS DE AQUISIÇÃO DE DADOS	161
6.2.	CONCLUSÕES PARA MÓDULO DE PREVISÃO DE LÂMINAS D'ÁGUA ...	161
6.3.	CONCLUSÕES PARA CONDIÇÕES PLANIALTIMÉTRICAS	162
7.	REFERÊNCIAS BIBLIOGRÁFICAS	165
	ANEXOS.....	193
	ANEXO 01: SÉRIE TEMPORAL UTILIZADA	193
	ANEXO 02: MDE Completo e Trechos Críticos – Período de Estiagem	200
	ANEXO 03: MDE Completo e Trechos Críticos – Período de Cheia.....	205

1. INTRODUÇÃO

O processo de escolha entre alternativas de transporte considera atributos que são mensuráveis, como custo e tempo, bem como atributos que não são diretamente observáveis, como segurança e conforto (MIHIC; GOLUSIN; MIHAJLOVIC, 2011). O transporte aquaviário possui inquestionável importância, destaque nas relações comerciais mundiais. Pelas suas características, apresenta-se como uma alternativa de baixo custo e grande eficiência, além de ser a modalidade responsável por transportar grande parte das cargas movimentadas em escala global. Nessa perspectiva, a navegação interior é de suma importância no volume de carga transportada pelo transporte aquaviário, principalmente no transporte de cargas e passageiros (AHADI; SULLIVAN; MITCHELL, 2018; HAURELHUK; VALENTE, 2016; SEGOVIA *et al.*, 2019).

Com o crescente volume de cargas transportadas por vias navegáveis, a navegação interior desempenha um papel de destaque na busca por economias de escala no sistema de transporte. Com isso, o porte das embarcações que operam nas hidrovias interiores está aumentando e, conseqüentemente, a eficiência das operações portuárias e os ajustes necessários ao porto devem ser aumentados proporcionalmente. Esse aumento no tamanho das embarcações exige cada vez mais a adoção de tecnologias capazes de otimizar a navegação e a segurança das embarcações que operam em portos interiores que requerem instalações portuárias (RUGGERI *et al.*, 2018; WATAI *et al.*, 2018).

O volume total de cargas transportadas nos portos brasileiros em 2017 foi de aproximadamente 620 milhões de toneladas, apresentando um aumento de 6,31% em relação a 2016 (ANTAQ, 2019). Entre outros fatores, esse aumento mostra um crescimento gradativo do volume de cargas transportadas por hidrovias na matriz de transportes brasileira, com aumento da eficiência energética, redução dos impactos ambientais e da multimodalidade e intermodalidade do sistema de transporte (LALLA-RUIZ; SHI; VOSS, 2018). A navegação interior promove a integração dos modais de transporte, uma vez que uma das questões mais importantes na logística e conectividade portuária é a existência de vias navegáveis interiores que permitem o escoamento de grandes volumes de carga para os portos marítimos (IMO - INTERNATIONAL MARITIME ORGANIZATION, 2009; ROHACS; SIMONGATI, 2007).

A demanda por hidrovias interiores está aumentando, principalmente devido ao maior custo-benefício do transporte hidroviário em comparação com outros modos de transporte (FLODÉN; WOXENIUS, 2017; VIDAN; KASUM; JOLIĆ, 2010). Entretanto, a segurança da

navegação fluvial não se desenvolve na mesma velocidade. Nessa perspectiva, os critérios fundamentais a serem adotados no projeto de canais de navegação devem ser a segurança da navegação, o cumprimento das condições ambientais e a eficiência econômica (MOU *et al.*, 2019). Como o volume de investimentos necessários para implementar a infraestrutura necessária para hidrovias interiores não acompanha o aumento da carga transportada pelos portos, a navegação interior tornou-se um gargalo para o sistema logístico (LIANG *et al.*, 2019; PIANC, 2014; WANG *et al.*, 2015a).

Uma análise dos aspectos de segurança da navegação durante o transporte hidroviário mostra que esse transporte é influenciado por fatores exógenos e endógenos relacionados à hidrovia, conforme discutido na literatura em Zhang *et al.* (2013); Márquez, Cantillo e Arellana (2014), Harlacher (2016); Zijl, Sumihar e Verlaan (2015); Trojanowski e Iwan (2014); Kuwahara, Lago Neto e Abensur (2012). A Tabela 1 resume os principais fatores apontados na literatura como influenciadores da segurança da navegação, que devem ser verificados ao se realizar o dimensionamento ou análise de um canal de navegação.

Tabela 1 - Fatores de Influência à Segurança da Navegação

Fatores de influência	Literatura Analisada
Características Geométricas do Navio	Paulauskas & Paulauskas (2013) PIANC (2014) Trojanowski & Iwan (2014)
Manobrabilidade e Propulsão da Embarcação	Zijl; Sumihar & Verlaan (2015) Abraham & Lepetit (1978)
Características Físicas e Geométricas do Canal	Morris (2013) Kaarsemaker <i>et al.</i> (2010) Kuwahara, Lago Neto & Abensur (2012)
Aumento da Demanda e Tamanho dos Navios	Márquez; Cantillo & Arellana, (2014) Harlacher (2016)
Condições de Manutenção da Hidrovia	Koedijk (2013) Harlacher (2016) Zhang <i>et al.</i> (2013)
Condições naturais (Precipitação, Fluxo, Mudança Climática, Correntes e Ventos)	Zhang <i>et al.</i> (2013) Morris (2013) Adhiperdana <i>et al.</i> (2018)

Fonte: Autor (2023).

A utilização de ferramentas que auxiliam na análise e prevenção de riscos à segurança da navegação apresentam considerável valor agregado em relação aos possíveis impactos socioambientais (TROJANOWSKI; IWAN, 2014). Com foco na segurança da navegação e melhor desempenho hidrodinâmico das hidrovias interiores, inúmeras pesquisas têm sido realizadas para melhorar e garantir a navegação utilizando modelos matemáticos para auxiliar neste propósito (TAYLOR *et al.*, 2005; XU; XIA; WEN, 2020).

Em complementação, a partir do entendimento da importância da segurança da navegação em hidrovias, deve-se destacar a necessidade de implementação de estudos de previsão da capacidade de carga, dado o fato de que a sazonalidade destes cursos d'água impacta significativamente de maneira negativa na navegação, haja vista que baixos fluxos e valores reduzidos de nível d'água dificultam a ocorrência de uma navegação perene (CAO *et al.*, 2020).

Ao analisar a problemática da flutuabilidade sazonal de profundidades como fator limitante, este fenômeno (enchentes e estiagem) é responsável por variações de profundidade, de calado e, conseqüentemente, da capacidade de carga das embarcações que navegam (SCHEEPERS *et al.*, 2018). Em períodos de estiagem, as embarcações reduzem seus volumes de carga, por terem que reduzir os valores de calado, acarretando aumentos de custo/tonelada (ZUO *et al.*, 2020). Assim, a análise da navegação e dos processos hidrológicos dos rios são de fundamental importância para uma gestão eficiente destas vias navegáveis (LUO *et al.*, 2020).

No contexto da variação constante das profundidades dos cursos fluviais, há a necessidade de avaliar, compreender e prever as flutuações do nível da água para o aprimoramento das operações de gerenciamento de recursos hídricos (REN *et al.*, 2020), como avaliação de prejuízos atrelados à redução de calado disponível para navegação (CAMPOS FILHO *et al.*, 2019). Assim, dentro da análise de modelos de previsão de nível d'água, pode-se observar o uso constante de técnicas estatísticas aplicadas a utilização de *machine learning* nas séries temporais com o objetivo de encontrar relações ou obter previsões futuras (GJIKA; FERRJA; KAMBERI, 2019; YASEEN *et al.*, 2019).

Acerca desta variação de lâminas d'água e suas variáveis de influência, destaca-se o impacto significativo dos fenômenos ocorridos no Oceano Pacífico no que concerne às mudanças de temperatura e pressão, que ocasionam os fenômenos de El Niño e La Niña, responsáveis por alterações nos índices pluviométricos e fluviométricos de cursos fluviais em todo o planeta (FOK *et al.*, 2023). Esses fenômenos naturais de larga escala têm sido investigados em escala regional e global, uma vez que as fases extremas dos episódios ENOS

podem causar grandes extremos hidrológicos, por exemplo, inundações e secas, em várias partes do mundo (FENG; HAO, 2021; HONG LEE; JULIEN; LEE, 2023).

Nesse sentido, o estudo em questão encontra-se pautado no objetivo de desenvolvimento de um modelo de previsão de lâminas d'água, calados operacionais e capacidades de carga em hidrovias fazendo uso de técnicas de *Machine Learning*, a fim de ser possível desenvolver a modelagem das condições de navegabilidade, com posterior cálculo dos valores de folga abaixo da quilha (UKC), com a finalidade intrínseca de obtenção das condições de navegabilidade de embarcações tipo analisadas. Para validação da ferramenta desenvolvida, o modelo foi aplicado na Bacia Hidrográfica do Rio Madeira com o dimensionamento, modelagem e análise hidrostática de um comboio de empurra fluvial típico. A previsão de lâminas d'água foi realizada a partir de técnicas de redes neurais artificiais utilizando-se de séries históricas de temperaturas e precipitações obtidas via satélite, consistindo em estimativas corrigidas e reprocessadas, comparadas com valores obtidos *in situ*. As condições geométricas da via navegável foram avaliadas em termos de profundidade e parâmetros geométricos, com a elaboração de modelo digital de elevação, na avaliação dos impactos da flutuabilidade sazonal sobre a capacidade de carga, e na verificação das restrições geradas tanto em profundidade e largura disponíveis, quanto em capacidade de carga total do comboio.

1.1. OBJETIVOS

1.1.1. Objetivo Geral

O objetivo deste trabalho é desenvolver um modelo de previsão de lâminas d'água e capacidades de carga em hidrovias, fazendo-se uso de programação, redes neurais artificiais e sensoriamento remoto, com a validação a partir de um estudo de caso.

1.1.2. Objetivos Específicos

- Criação e tratamento de banco de dados GIS e de variáveis hidrológicas;
- Geração da rotina computacional para leitura de precipitações via satélite;
- Geração da rotina computacional para leitura de temperaturas via satélite;
- Geração da Rede Neural Artificial para previsão de lâminas d'água;
- Aplicação da ferramenta de cálculo de propriedades geométricas do canal;
- Geração do Modelo Digital de Elevação para localização analisada;
- Proposição e modelagem de cenários de análise de condições de carregamento e de navegabilidade em hidrovias.
- Cálculo de calados operacionais e capacidades de carga do comboio tipo.

1.2. JUSTIFICATIVA

Segundo a *Worldwide Inland Navigation Network* - WWINN (2022) e a Agência Nacional de Transportes Aquaviários - ANTAQ (2019), as hidrovias interiores do Brasil têm alto potencial, mas atualmente são subutilizadas, visto que de, aproximadamente, 60.000 km de hidrovias interiores disponíveis, um número próximo de 13.000 km é, de fato, utilizado, transportando 45.000.000 ton/ano, mas com potencial para o sistema chegar a cerca de 180 milhões de toneladas movimentadas. Tal potencial não é explorado de maneira significativa em virtude de questões de priorização histórica de modal e, também, por conta da escassez de estudos realizados nestas hidrovias com a finalidade de evidenciar os gargalos e propor soluções técnicas, como o presente estudo.

Concomitante a isso, ressalta-se que adentrar no conhecimento sobre as hidrovias, seus parâmetros de projeto, suas condições, capacidades de movimentação ao longo do ano e restrições de navegabilidade, características de canais de navegação, particularidades e as embarcações que as utilizam, se faz necessário nesse momento em que o país necessita de competitividade estratégica perante o mercado internacional, por não ter preparado e diversificado sua infraestrutura logística para atender as necessidades dos mercados consumidores internos e externos de mercadorias.

Portanto, no contexto da implantação de estudos acerca destes cursos fluviais, a modelagem hidrológica para verificação dos impactos do ciclo hidrológico na sazonalidade destes cursos configura-se como de fundamental importância para o transporte hidroviário, haja vista que períodos de estiagem impactam no nível d'água permitido e isto, conseqüentemente, reduz a capacidade de carga factível de transporte, fatos estes que fundamentam estudos significativos nas variáveis associadas à hidrologia (endógenas e exógenas à via navegável) que influenciam diretamente na navegação, como os índices de precipitação, níveis d'água e o escoamento superficial.

No cenário de estudo das temperaturas do oceano, tem-se a necessidade de entender o fenômeno da variabilidade dos totais anuais de precipitação e sua associação com a Temperatura Superficial do Mar (TSM) no Oceano Pacífico, visto que estas exercem influências diretas e diferentes na Amazônia Ocidental, de acordo com o fenômeno apresentado, isto é, El Niño e La Niña. Portanto, faz-se necessário entender como tais temperaturas influenciam as precipitações e, conseqüentemente, o volume de escoamento superficial que contribui para a lâmina d'água de um curso fluvial em uma dada bacia de contribuição.

No contexto do estudo dos índices de precipitação, tem-se que este é necessário para monitorar e compreender os balanços hídricos, desempenhando papel fundamental na tomada de decisões no que tange ao planejamento da navegação. Entretanto, apesar da importância da precipitação nos estudos, sabe-se que a aquisição de dados pluviométricos confiáveis, precisos e com uma série histórica significativa configura-se como um processo complicado, visto que, inicialmente, dependia-se único e exclusivamente das estações de medição *in situ*.

Dentro do contexto da importância da precipitação, evidencia-se a necessidade de estudos capazes de adquirir dados de pluviosidade fazendo uso de ferramentas computacionais atreladas ao sensoriamento remoto, com a utilização de aferições realizadas por satélite, sendo este, um dos cerne da pesquisa, com o objetivo de não depender diretamente de dados de estações de superfície, em virtude dos dados obtidos por satélite terem vantagens estratégicas intrínsecas a sua utilização, como: (1) Uniformidade dos dados históricos; (2) Disponibilidade espacial e temporal dos dados; (3) Vanguarda científica.

De posse desses dados, destaca-se que a aferição de níveis d'água fazendo-se uso de redes neurais artificiais para previsão de valores futuros utilizando como o *input* de dados a precipitação adquirida via satélite evidencia-se como um estudo pioneiro no tocante a sua forma de desenvolvimento (isto é, o *modus operandi*) e área de aplicação, fatos estes que corroboram com a importância do estudo.

O uso de redes neurais artificiais no estudo configura-se como de fundamental importância para consecução dos objetivos propostos, visto que estas possibilitam a utilização dos dados de satélite em detrimento dos dados adquiridos *in situ*, uma vez que o modelo de RNA é capaz de captar o comportamento da série histórica.

Tendo em vista o contexto supracitado, tem-se que, em virtude da extensão do estudo em várias frentes de trabalho e módulos metodológicos, a justificativa deste encontra-se pautada em quatro vertentes consolidadas:

- a) A necessidade de estudos capazes de adquirir diferentes dados de precipitação por sensoriamento e calibrá-los com estações pluviométricas de superfície;
- b) A necessidade de implementação de ferramentas computacionais capazes de aferir dados de lâmina d'água de localidades que não dispõem de réguas de medição e de uma série histórica;
- c) A imprescindibilidade de aplicação de estudos relativos ao desenvolvimento de um modelo computacional capaz de avaliar as condições planialtimétricas e de

navegação em cursos fluviais com navegação pujante e necessária para o escoamento da produção do país.

- d) A carência de pesquisas na área voltadas ao setor da navegação para os rios Amazônicos;

1.3. HIPÓTESE

As hipóteses de desenvolvimento desta dissertação se fundamentam nos seguintes questionamentos:

A criação de modelos associados à Redes Neurais Artificiais e ferramentas computacionais pode se configurar como uma solução viável e de grande impacto no processo de aprimoramento do transporte em vias navegáveis interiores, seja no contexto da modelagem geométrica ou na previsão de capacidade de carga destes cursos fluviais?

1.4. ESTRUTURA DO TRABALHO

Esta seção visa apresentar a estrutura deste trabalho de pesquisa, com destaque para a divisão dos capítulos, conforme a disposição abaixo.

No Capítulo 1, já exposto, faz-se a apresentação do trabalho através da introdução, objetivos gerais e específicos, assim como sua estrutura. Retratando ao leitor a importância do estudo a respeito do modal hidroviário e a necessidade de estudos de previsão da capacidade de carga e em projetos aplicados a segurança da navegação voltados ao transporte de cargas na região amazônica.

No Capítulo 2 destaca-se a revisão bibliográfica, buscando contextualizar as temáticas norteadoras do presente trabalho, como o panorama do transporte aquaviário, a relevância do conhecimento hidroviário à logística de transporte nacional e o cenário do transporte de passageiros na Região Amazônica. Concomitante ao referencial atrelado ao transporte fluvial, observa-se também neste capítulo a abordagem referente à utilização da metodologia de análise, com as abordagens matemáticas, vantagens, desvantagens e aplicações da referida metodologia no transporte aquaviário.

O Capítulo 3 apresenta o detalhamento da metodologia utilizada na pesquisa, com a classificação da pesquisa, apresentação das fontes de dados e formalização dos modelos propostos.

O Capítulo 4 destaca-se por ser o estudo de caso. Tendo a apresentação de diversas características e particularidades da região de estudo. Discorrendo sobre a região de estudo e suas características, bem como caracterizando os trechos analisados, descrevendo os cenários de análise e selecionando as variáveis envolvidas e apresentando a embarcação de projeto.

O Capítulo 5 apresenta os resultados obtidos com a aplicação metodológica, discorrendo-se acerca dos cenários obtidos com base nos valores de profundidade previstos. O Capítulo 6 apresenta as considerações finais do trabalho. O Capítulo 7 informa as referências bibliográficas utilizadas na pesquisa.

2. REVISÃO DE LITERATURA E REFERENCIAL TEÓRICO

2.1. IMPORTÂNCIA DO TRANSPORTE AQUAVIÁRIO

Na logística, a escolha criteriosa dos modais de transportes constitui-se como uma etapa de fundamental importância nas relações de mercado do cenário econômico global (SOLOMON *et al.*, 2020; WOJEWÓDZKA-KRÓL; ROLBIECKI, 2018). Esta economia mundial, por sua vez, caracteriza-se como o fator determinante das demandas por transporte e das necessidades de aprimoramento nos modais existentes (MICHAIL, 2020).

A procura constante de aprimoramento da logística dos países em busca de aumento de competitividade acarretam necessidade de estudos capazes de indicar quais os fatores determinantes para as escolhas dos modais de transporte, sendo esta escolha fundamentada, sobretudo, em questões relacionadas à qualidade do serviço (tempo, confiabilidade, frequência), aos custos (FLODÉN; WOXENIUS, 2017; WIEGMANS; KONINGS, 2015), aos aspectos ambientais (BERGANTINO *et al.*, 2013; LAMMGÅRD; ANDERSSON, 2014) e à confiabilidade do modal (ARENCEBIA *et al.*, 2015; BERGANTINO *et al.*, 2013). Portanto, a escolha do tipo de transporte encontra-se diretamente fundamentada a atributos mensuráveis, como custos e tempo de realização, e a variáveis qualitativas, como confiabilidade e segurança (FLODÉN; BÄRTHHEL; SORKINA, 2017; MIHIC; GOLUSIN; MIHAJLOVIC, 2011).

A partir da análise dos critérios centrais de escolha do meio de transporte, o modal aquaviário adquire importância inquestionável e de destaque na economia mundial, em virtude de suas características superiores em relação aos outros modais, sendo este responsável por cerca de 90% da movimentação de carga do mercado internacional (LISTER, 2015; WILLIAMSSON; ROGERSON; SANTÉN, 2020). Dentro desta perspectiva, o modal aquaviário destaca-se como o mais eficaz, menos custoso e com menores índices de poluição ambiental em comparação com os volumes correspondentes de movimentação por estradas, pelas ferrovias ou pelo ar (NOKELAYNEN, 2018; WOJEWÓDZKA-KRÓL; ROLBIECKI, 2018). Com o aumento da participação dos custos de transporte nos custos finais do produto e com o aumento das preocupações com o meio ambiente, observa-se uma tendência de mudança do modal rodoviário para o aquaviário (WILLIAMSSON; ROGERSON; SANTÉN, 2020).

Ao analisar o transporte aquaviário, as vias navegáveis interiores desempenham um papel crucial na cadeia logística (TAYLOR, 2018; WILLIAMSSON; ROGERSON; SANTÉN, 2020), haja vista que permitem um transporte de baixo custo de grandes volumes mercadorias, com reduções significativas nos impactos ambientais e com significantes aumentos de

eficiência logística (MEDDA; TRUJILLO, 2010; SUÁREZ-ALEMÁN; TRUJILLO; MEDDA, 2015; WIEGMANS; KONINGS, 2015). O gerenciamento destes cursos d'água interiores possibilitam a criação de uma infraestrutura de transportes natural capaz de proporcionar um desenvolvimento de áreas litorâneas mais afastadas, com o apoio a extração e ao transporte de recursos e produtos industrializados, fatos estes que justificam sua importância (SOLOMON *et al.*, 2020; TAYLOR, 2018; TVEDT, 2010).

Ao analisar o cenário Amazônico, com o aumento do comércio exterior brasileiro nas últimas décadas, evidencia-se também a crescente utilização do modal hidroviário para o escoamento desta produção, sobretudo de grãos agrícolas, aumentando a importância das estruturas portuárias responsáveis por este escoamento (LALLA-RUIZ; SHI; VOSS, 2018). Quanto ao escoamento desta produção pelo modal aquaviário, com a utilização de estruturas portuárias, tem-se reduções significativas nos custos por tonelada em relação aos demais modais (AHADI; SULLIVAN; MITCHELL, 2018; LINDSTAD; SANDAAS, 2016; LING-CHIN; ROSKILLY, 2016; SEGOVIA *et al.*, 2019). Da mesma forma, observam-se impactos técnico-econômicos decorrentes da capacidade estrutural para grandes quantidades de carga (DEDES; HUDSON; TURNOCK, 2016; SAKALIS; FRANGOPOULOS, 2018; TALLURI *et al.*, 2016; ZHAO *et al.*, 2016). Para Teixeira *et al.* (2018) embora o potencial de exportação por terminais portuários esteja longe de ser totalmente explorado, grande parte do volume de carga está sendo transportada via rota fluvial para portos que redirecionam essas cargas para o mercado externo, a exemplo dos portos que compõem os corredores logísticos do Arco Norte.

Como exemplo da importância da navegação interior para o transporte, Scheepers *et al.* (2018) destacam a importância do rio Mackenzie, no Canadá, para a movimentação de carga a granel para as regiões no entorno. Solomon *et al.* (2020) discutem a respeito da dependência de muitos países em relação às hidrovias para o transporte de carga a granel e geral por longas distâncias para chegar em portos de exportação ou de multimodalidade.

2.2. TRANSPORTE HIDROVIÁRIO DE CARGAS E PASSAGEIROS

A utilização dos rios da bacia amazônica pautou o processo de ocupação da Região Norte do país, inclusive nos seus ciclos econômicos, cumprindo, até os dias atuais, papel de destaque na dinâmica econômica e social da região. Foram determinantes para isso a presença da densa floresta equatorial de difícil penetração humana, as grandes distâncias entre as localidades, a disponibilidade de uma ampla rede hidroviária naturalmente configurada, acompanhados da ausência de recursos financeiros e de capital humano para a abertura de

caminhos terrestres que viabilizassem a plena ocupação territorial da Amazônia (WWINN, 2022).

Destarte, o transporte hidroviário se estabelece, de maneira regular, como meio de conexão das poucas cidades existentes na floresta, a exemplo de Manaus, Belém, Macapá, Cametá, Gurupá (TAVARES, 2011), viabilizando o acesso de suas populações a bens de consumo, de subsistência e a serviços públicos básicos, como educação e saúde. Mesmo com a recente ampliação dos centros urbanos, das fronteiras agrícolas e a implementação de projetos de exploração mineral e industrial relevantes, com conseqüente expansão da rede de transportes terrestre e aéreo, a navegação interior de passageiros e misto permanece como a principal alternativa de transporte para a Região Amazônica (AGÊNCIA NACIONAL DE TRANSPORTE AQUAVIÁRIO, 2018).

Os estudos mais recentes no âmbito do planejamento federal, como o Plano Nacional de Integração Hidroviária (PNIH) e o Plano Hidroviário Estratégico (PHE), enaltecem a importância das hidrovias como parte necessária da solução logística do país. No entanto, não consideram no planejamento do transporte de passageiros e misto a magnitude e as peculiaridades das vias navegáveis da Região Amazônica.

2.2.1. Transporte Hidroviário no Rio Madeira

Tendo como cerne de análise na pesquisa o rio Madeira, necessita-se apresentar o cenário no qual o referido curso fluvial encontra-se inserido, a fim de explicitar a importância de estudos acerca deste. Nesse sentido, destaca-se que o rio Madeira se configura como um dos principais rios do Brasil e o mais longo e importante afluente do rio Amazonas. No mundo, é um dos cinco rios mais caudalosos e o 17º mais extenso, justificando sua importância ambiental (LI *et al.*, 2020; MOLINA CARPIO *et al.*, 2017). Além desta importância, destaca-se a relevância econômica da hidrovia em questão, visto que é essencial para a economia de muitas regiões, pois tradicionalmente proporciona a pesca, o transporte hidroviário e, em suas margens, o plantio de diversos produtos agrícolas (WATLING *et al.*, 2020).

No trecho navegável de mais de 1.000km entre Porto Velho/RO e Itacoatiara/AM, o rio Madeira se configura como um vetor de exportação de cargas agrícolas, recebendo as produções advindas do Centro-Oeste via modal rodoviário, realizando o transbordo da carga na região de Porto Velho e descendo o rio em direção aos portos de exportação, como os terminais em Itacoatiara/AM, o Porto de Manaus/AM e o Porto de Santarém/PA (ANA, 2022; DNIT, 2021).

A referida opção intermodal caracteriza-se como promissora, uma vez que este modal fluvial apresenta crescimento na utilização pela soja mato-grossense, apresentando-se como uma boa alternativa tendo em vista a proximidade aos portos do Norte do país e com menores impactos nos custos logísticos (DNIT, 2021). No entanto, o rio Madeira apresenta gargalos referentes às condições de navegação em períodos de seca, que dificultam o transporte por este modal, bem como em virtude ao deslocamento de bancos de areia associados ao fluxo de sedimentos, o que aumenta as ocorrências de encalhe (CFPV, 2020). Tais características de navegação reforçam a necessidade de implantação de pesquisas capazes de prever as condições de navegabilidade da referida hidrovia.

No tocante aos estudos realizados para o rio Madeira, tem-se a existência de uma vasta quantidade de literaturas que abordam, em especial, o transporte de sedimentos no referido curso fluvial, visto que tal transporte acarreta processos erosivos e movimentações de bancos de areia que prejudicam a navegação. Além disso, verifica-se uma vasta quantidade de projetos implementados e em execução acerca dos barramentos (Santo Antônio e Jirau) hidroenergéticos e seus impactos na região. Entretanto, apesar desta quantidade de estudos, não se evidencia na literatura a aplicação de modelos de previsão de lâmina d'água para a referida região.

Acerca das pesquisas existentes para a região em relação a estudos relativos à precipitação, destaca-se que Gomes *et al.* (2022) realizaram previsões de conjunto de escala intrasazonal de precipitação e evapotranspiração para a bacia do rio Madeira usando diferentes parametrizações físicas. Sikora de Souza *et al.* (2020) apresentaram um estudo acerca dos eventos extremos de chuva (El Niño e La Niña) na bacia do rio Madeira, fazendo uso da aquisição de dados de precipitação via satélite CHIRPS, de modo a efetuar uma avaliação de tendência nas chuvas extremas em regiões com variação na cobertura vegetal.

No que concerne aos estudos relativos ao transporte de sedimentos, exemplifica-se Föeger *et al.* (2022), que realizaram uma modelagem de sedimentos em larga escala, usando duas abordagens diferentes de roteamento de fluxo: um método combinado de *Saint-Venant* e *Muskingum-Cunge* e o roteamento de fluxo inercial. Li *et al.* (2020) avaliaram a reversão do aumento da carga de sedimentos na bacia amazônica influenciada por tendências divergentes de transporte de sedimentos dos rios Solimões e Madeira. Espinoza Villar *et al.* (2013) efetuaram um estudo do transporte de sedimentos no Rio Madeira, Brasil, usando imagens de sensoriamento remoto MODIS. Vauchel *et al.* (2017) apresentaram uma reavaliação da carga de sedimentos suspensos na bacia do rio Madeira desde os Andes do Peru e Bolívia até o rio Amazonas no Brasil, com base em 10 anos de dados do programa de monitoramento HYBAM.

A respeito de estudos acerca dos barramentos existentes, Cochrane *et al.*(2017) efetuaram uma análise baseada em *Landsat* dos impactos de inundações de megabarragens no Alto Rio Madeira durante o período de 2006–2015, comparando os resultados com avaliações de impacto ambiental (EIA) destes empreendimentos. Fearnside (2014) avaliou os impactos das barragens do rio Madeira no Brasil no que tange aos prejuízos aos ecossistemas, às inundações consequentes, ao deslocamento de populações ribeirinhas e às emissões de gases estufas.

Os estudos da literatura exposta tiveram como objetivo a evidenciação da grande importância do curso fluvial em questão sob diversos aspectos, entretanto, também teve como objetivo explicar a escassez de pesquisas que implementem modelos de previsão de lâmina d'água associados à aquisição de dados de precipitação via satélite, de modo a evidenciar a importância do presente estudo.

2.3. EMPECILHOS À NAVEGAÇÃO

Evidenciado nos tópicos supracitados a importância dos cursos fluviais no geral e em especial do rio Madeira, tem-se que apesar do aumento da demanda do transporte por este modal, a segurança da navegação nos rios e lagos não se desenvolve na mesma proporção, o que corrobora com empecilhos que impedem o aumento de sua utilização, em virtude, principalmente, de questões infraestruturais, climáticas e hidrológicas (ALMAZ; ALTIOK, 2012; FATHONI *et al.*, 2017; KAMAL; SADEK, 2018). Em relação aos fatores naturais, destacam-se as questões relacionadas aos fenômenos de maré, às conformações geométricas dos rios, aos problemas de sedimentação e erosão, e aos fenômenos de sazonalidade das lâminas d'água (FATHONI *et al.*, 2017; KUO; GAN; HIGUCHI, 2017; LAI *et al.*, 2016; SCHEEPERS *et al.*, 2018; SUGENG, 2010; XU; XIA; WEN, 2020; ZUO *et al.*, 2020).

2.4. FLUTUABILIDADE SAZONAL DE NÍVEIS D'ÁGUA

Ao analisar a sazonalidade de cursos d'água como fator limitante, os fenômenos de enchentes e vazantes de cursos d'água são responsáveis por aumentos e reduções de profundidade e, conseqüentemente, aumentos e reduções de calado e capacidade de carga das embarcações que navegam (KUO; GAN; HIGUCHI, 2017; SCHEEPERS *et al.*, 2018). Em períodos do ano com baixos níveis d'água, as embarcações reduzem seus volumes de carga para reduzir os valores de calado e este fato acarreta, eventualmente, aumentos dos preços de transporte por tonelada (JONKEREN; JOURQUIN; RIETVELD, 2011). Portanto, a análise da

navegação e dos processos hidrológicos dos rios é de fundamental importância para uma gestão eficiente (LUO *et al.*, 2020; NASIR *et al.*, 2018).

Nesse sentido, torna-se evidente que as vias navegáveis interiores são vulneráveis às alterações climáticas, uma vez que a navegação fluvial depende dos níveis das águas (CHRISTODOULOU; CHRISTIDIS; BISSELINK, 2020). As secas podem prejudicar gravemente os serviços de navegação interior, reduzindo os níveis de água a níveis completamente não navegáveis ou a níveis que obrigam os operadores a reduzir a carga das embarcações (NOUASSE *et al.*, 2016).

2.5. INFLUÊNCIA DOS EVENTOS ENOS NA PRECIPITAÇÃO

O El Niño-Oscilação Sul (ENOS) é um fenômeno climático recorrente que ocorre no Oceano Pacífico tropical e tem impactos significativos no clima global. Ele é caracterizado por mudanças nas temperaturas da superfície do mar (TSM) e nos padrões de vento, afetando o clima, a pesca e a agricultura em várias partes do mundo (LI; ZHAI; CAI, 2011; ZHU; ZHANG, 2023).

Os eventos ENOS são iniciados por alterações nas condições oceânicas e atmosféricas, que interagem de maneira complexa. Existem duas fases principais do ENOS: El Niño e La Niña (CIRINO *et al.*, 2015; SCHOSSLER *et al.*, 2018). No início de um evento ENOS, as condições normais são conhecidas como "Neutras". Nessa fase, as águas superficiais do Oceano Pacífico equatorial estão relativamente frias no leste e mais quentes no oeste, criando um gradiente de temperatura chamado "Gradiente de Temperatura do Pacífico Tropical" (GTP). Os ventos alísios sopram do leste para o oeste, empurrando as águas quentes para o oeste e permitindo a ascensão de águas mais frias no leste, o que é conhecido como "Ressurgência" (AMAROUCHE *et al.*, 2021; BRANDSÆTER; VANEM, 2018).

Durante a transição para um evento El Niño, ocorre uma mudança nas condições atmosféricas. O enfraquecimento dos ventos alísios ou até mesmo a sua inversão permitem que as águas quentes do oeste fluam para o leste, diminuindo o gradiente de temperatura. Isso resulta no aquecimento das águas superficiais no leste do Pacífico, especialmente próximo à costa do Peru e do Equador. À medida que as águas quentes se deslocam para o leste, uma área de convecção atmosférica intensa se desenvolve sobre essa região, liberando calor e umidade para a atmosfera (AMAROUCHE *et al.*, 2021; BRANDSÆTER; VANEM, 2018).

Os eventos climáticos El Niño e La Niña têm um papel significativo nas variações climáticas globais e podem exercer influência nas precipitações, no escoamento em cursos

fluviais e na navegação nestes (LIU et al., 2023; SIKORA DE SOUZA et al., 2020; WANG et al., 2023). Compreender as características e as consequências desses eventos é fundamental para a gestão de recursos hídricos e para o planejamento de atividades socioeconômicas em regiões afetadas.

Eventos climáticos, como El Niño e La Niña, podem modificar a circulação atmosférica global, resultando em mudanças nas precipitações e no regime de escoamento em cursos fluviais (FOK et al., 2023; HONG LEE; JULIEN; LEE, 2023). Essas alterações podem variar de acordo com a região geográfica e o período do ano.

O El Niño é caracterizado pelo aquecimento anômalo das águas superficiais do Oceano Pacífico Equatorial, enquanto a La Niña é marcada por resfriamento dessas mesmas águas. Ambos os eventos estão associados a perturbações na circulação atmosférica e oceânica, desencadeando consequências significativas em escala global (LI; ZHAI; CAI, 2011; ZHU; ZHANG, 2023).

Durante o El Niño, em algumas regiões tropicais, como a América do Sul, pode ocorrer um aumento nas precipitações. Esse aumento pode ser explicado pela modificação na circulação atmosférica, que favorece o deslocamento de sistemas frontais e a intensificação da convecção, levando a chuvas intensas e prolongadas (CIRINO et al., 2015; SCHOSSLER et al., 2018). Essas chuvas intensas podem aumentar o volume de água nos cursos fluviais e influenciar no regime de escoamento, podendo resultar em enchentes e erosão nas margens dos rios.

Durante a La Niña, algumas regiões tropicais e subtropicais, como partes da Ásia e da América do Sul, podem experimentar uma diminuição nas precipitações. Esse padrão está associado a uma maior estabilidade atmosférica e a um enfraquecimento da convecção. Como resultado, pode ocorrer um escoamento reduzido nos cursos fluviais, o que pode levar a secas e escassez hídrica (AMAROUCHE et al., 2021; BRANDSÆTER; VANEM, 2018).

Durante o El Niño, o aumento das precipitações pode levar a um maior volume de água nos cursos fluviais, resultando em um aumento do escoamento. Isso pode afetar a navegação, tornando os rios mais caudalosos e apresentando desafios adicionais para a navegação fluvial. Por outro lado, durante a La Niña, a redução das precipitações pode levar a um escoamento reduzido nos cursos fluviais, o que pode dificultar a navegação em determinadas áreas devido à diminuição do calado e à exposição de obstáculos naturais (FOK et al., 2023; WANG et al., 2023; ZHU; ZHANG, 2023).

Dessa forma, evidencia-se que os eventos El Niño e La Niña exercem influência nas precipitações e no escoamento em cursos fluviais, resultando em impactos significativos na gestão de recursos hídricos e na navegação. Compreender esses padrões climáticos é essencial para o desenvolvimento de estratégias de adaptação e mitigação, visando a minimização dos riscos e o aproveitamento sustentável dos recursos hídricos em regiões afetadas.

No contexto dos estudos associados à análise destes eventos climáticos, tem-se diversas contribuições da literatura científica (HONG LEE; JULIEN; LEE, 2023; LI; ZHAI; CAI, 2011; LI et al., 2021; MALUF DE LIMA; PIEDADE BACCHI, 2019; WANG et al., 2023; ZHU; ZHANG, 2023). Fok et al. (2023) realizaram uma abordagem geográfica para análise do balanço hídrico para estimativa do escoamento na Bacia de Mekong sob influência dos efeitos dos eventos ENOS, concluindo que as influências destes processos climáticos tem influência substancial nas precipitações e, conseqüentemente, no escoamento na bacia.

Zhang et al. (2022b) investigaram a variação sazonal da precipitação no leste da China associada às respostas ao El Niño-Oscilação Sul (ENSO, destacando um aumento da precipitação sobre o leste da China durante o inverno e a primavera. Ainda na China, Li et al. (2021) estudaram as mudanças nos extremos de precipitação na bacia do rio Yangtze durante 1960-2019 e a associação com os eventos ENOS, realizando correlações capazes de afirmar que tais eventos são fatores determinantes significativos que controlam a variabilidade espaço-temporal da precipitação.

Mohammadi e Goudarzi (2018) avaliaram intercorrelações da radiação solar, velocidade do vento e precipitação sob a influência do El Niño e La Niña na Califórnia, com dados de longo prazo de 50 anos (1961 e 2010), tendo os resultados mostrando impactos distintos dos eventos na magnitude e distribuição das variáveis meteorológicas estudadas. Ainda nos Estados Unidos, Hong Lee, Julien e Lee (2023) avaliaram a variabilidade das precipitações, bem como sua correlação cruzada em relação às fases quentes e frias dos eventos ENOS usando análises empíricas e estatísticas.

No cenário brasileiro, destaca-se que Cirino et al. (2015) avaliaram os impactos dos eventos ENOS na produção agrícola brasileira, focada nas regiões Nordeste e Sul, as mais vulneráveis aos efeitos no Brasil. Schossler et al. (2018) estudaram as anomalias de precipitação na costa sul brasileira associadas aos modos de variabilidade climática ENOS.

Evidencia-se, a partir das pesquisas supracitadas, que as variações de temperatura no Pacífico geram reflexos significativos em todas as partes do mundo, como apresentado para

China, Estados Unidos e Brasil, fatos estes que reforçam a necessidade de avaliação destas influências.

2.6. INFLUÊNCIA DA PRECIPITAÇÃO EM ANÁLISES HIDROLÓGICAS

Sabendo, portanto, que as precipitações sofrem influências diretas das variações dos valores de temperatura e pressão no oceano, deve-se avaliar também os impactos destas variações no ciclo hidrológico (FENG; HAO, 2021). Assim, destaca-se que a flutuabilidade sazonal dos cursos fluviais encontram-se intrinsecamente ligadas ao ciclo hidrológico e aos índices de precipitação pluviométrica da região em análise (JIANG *et al.*, 2021; TALCHABHADEL *et al.*, 2021). Tendo em vista isso, destaca-se a precipitação como um ponto chave do ciclo hidrológico, sendo necessária para monitorar e compreender os balanços hídricos para posteriormente realizar modelagens hidrológicas e prever mudanças climáticas, sendo esta variável (MOGES; KMOCH; UUEMAA, 2022), portanto, de fundamental importância no impacto e avaliação de riscos em bacias hidrográficas (SIKORA DE SOUZA *et al.*, 2020).

Corroborando ao supracitado, reforça-se a partir da literatura em Adnan *et al.* (2017) que a precipitação está entre os componentes vitais do ciclo da água, desempenhando papel fundamental na tomada de decisões acerca do planejamento da navegação, produção agrícola, segurança alimentar, gestão de recursos hídricos e geração de energia hidrelétrica (AHMED *et al.*, 2019a, 2019b; LATIF; SYED; HANNACHI, 2017). A exemplo desta importância, destaca-se que a precipitação está entre uma das principais variáveis para avaliar as variações extremas que ocorrem no clima, como a seca (DINKU *et al.*, 2018; FUNK *et al.*, 2015; ZAMBRANO *et al.*, 2017).

Para tanto, apesar da grande importância desta para estudos hidrológicos, adquirir dados de precipitação de maneira precisa e confiável sobre a variabilidade espacial e temporal configura-se como um processo, por vezes, limitado às observações terrestres escassas e falhas, em algumas situações (LEI *et al.*, 2021; RIVERA; MARIANETTI; HINRICHS, 2018; SATGÉ *et al.*, 2020). Atualmente, a variável pluviométrica em questão configura-se por ser observada fazendo uso de instrumentos/equipamentos científicos confiáveis, como pluviômetros terrestres, radares meteorológicos e satélites (BAI *et al.*, 2018; IQBAL; ATHAR, 2018).

Dentro deste cenário, com a necessidade de alternativas às aferições de dados *in situ*, a obtenção de variáveis de precipitação com alta resolução espaço-temporal configura-se como uma alternativa viável (SHUKLA *et al.*, 2014). Portanto, produtos de precipitação precisos e

confiáveis são necessários para o monitoramento do crescimento agrícola e gestão dos recursos hídricos (LE; PRICOPE, 2017; NAWAZ; IQBAL; MAHMOOD, 2021). Embora essas técnicas de aquisição de precipitação possam fornecer informações de precipitação relativamente precisas e em tempo real (LE *et al.*, 2020), elas são frequentemente propensas a grandes valores ausentes, efeitos do vento e distribuição espacial desigual (MAGGIONI; MEYERS; ROBINSON, 2016).

2.7. PRECIPITAÇÃO PLUVIOMÉTRICA POR SATÉLITE

Dentro do panorama explicitado anteriormente, os dados de precipitação baseados em satélite podem ser uma fonte valiosa para a realização de análises hidroclimatológicas (AKSU; AKGÜL, 2020; TALCHABHADEL *et al.*, 2021), visto que a área de sensoriamento remoto encontra-se em constante avanço (NAWAZ; IQBAL; MAHMOOD, 2021), tornando a estimativa de precipitação por satélite um método alternativo importante para coleta de dados e posterior aplicação em modelos hidrológicos, reduzindo a dependência de dados aferidos a partir de estações pluviométricas superficiais (AYEHU *et al.*, 2018; BAI *et al.*, 2018; DEMBÉLÉ; ZWART, 2016).

Nesse sentido, tem-se que destacar a ampla quantidade de dados de satélite disponíveis relativos à precipitação, como o modelo de Estimativa de precipitação a partir de informações de sensoriamento remoto usando redes neurais artificiais (PERSIANN), o *Tropical Rainfall Measuring Mission* (TRMM), *Multi Satellite Precipitation Analysis* (TMPA), Integração de Dados Observacionais de Alta Resolução para Avaliação de Precipitação Asiática (APHRODITE), Produto de Climatologia de Precipitação Global (GPCP), Produto *MORPHing* do Centro de Previsão Climática (CMORPH) e Precipitação Infravermelha do Grupo de Riscos Climáticos com Dados de Estação (CHIRPS) (DINKU *et al.*, 2018; FUNK *et al.*, 2015).

Em complementação, no contexto de estudos realizados implementando a utilização de dados de precipitação via satélite, destaca-se Hinge *et al.* (2022), que avaliaram a utilidade hidrológica de produtos de precipitação por satélite na previsão de cheias, fazendo uma análise de metadados e avaliando as diferenças de desempenho destes dados em regiões com diferentes climas (temperados e tropicais) e diferentes relevos a fim de avaliar a influência destes fatores na obtenção de resultados. Chen *et al.* (2022) verificaram a confiabilidade dos dados de precipitação derivados de satélite na condução de simulações hidrológicas a partir da aplicação de um estudo de caso da bacia superior do rio Huaihe na China. Moges, Knoch e Uemaa (2022) realizaram a aplicação de produtos de precipitação por satélite, com uma reanálise para

modelagem hidrológica usando CMORPH e SM2RASC na bacia hidrográfica de Porijõgi - Estônia, que sofre com escassez de dados.

2.7.1. Utilização de Precipitação via Satélite na Amazônia

O uso de dados de precipitação pluviométrica obtidos via satélite configura-se como de constante uso por parte da literatura no contexto brasileiro, seja para a verificação da reprodução da variabilidade sazonal em relação aos dados de superfície ou para a utilização destes dados como insumo de espacialização de chuvas.

Nesse contexto, de modo a evidenciar a amplitude de pesquisas e reforçar a viabilidade do uso destes dados, destaca-se a literatura em Biggs e Shen (2021), que realizaram estimativas de precipitação por satélite CHIRPS usando uma densa rede de pluviômetros sobre o sudoeste da Amazônia brasileira, de modo a apresentar a viabilidade de utilização destes dados para avaliação de períodos de estação seca e de chuva extrema (DE OLIVEIRA-JÚNIOR et al., 2018).

De modo a corroborar com a utilização dos dados adquiridos por sensoriamento remoto, destaca-se o estudo de Cordeiro e Blanco (2021), que avaliaram a utilização do satélite CHIRPS para preencher lacunas de dados pluviométricos na região amazônica, reforçando a validade de uso da ferramenta em questão.

Paca et al. (2020) usaram o CHIRPS para documentar tendências na precipitação anual na bacia amazônica e validaram seus resultados com dados de medidores de solo. Eles descobriram que a precipitação média espacial da bacia amazônica aumentou apenas ligeiramente entre 1981 e 2017, mas a tendência teve uma grande variação espacial, com algumas áreas mostrando aumentos e outras diminuindo.

Cavalcante et al. (2020) realizaram uma avaliação de índices de precipitação extrema a partir de estimativas de precipitação do CHIRPS sobre a Amazônia brasileira, comparando a precipitação mensal, os índices anuais de precipitação e suas tendências calculadas usando dados CHIRPS e observações pluviométricas com uma análise ponto a pixel, chegando a resultados conclusivos acerca da boa captação das tendências de precipitação a partir desta metodologia.

Marinho e Rivera (2021) apresentaram uma análise de variabilidade temporal e espacial de dados de chuva para a bacia do Rio Negro, na Região Amazônica fazendo uso do CHIRPS, alcançando resultados de métricas estatísticas com elevados coeficientes de determinação (R^2

> 0,85) e baixo erro médio (RMSE < 1%), reforçando a viabilidade de uso da metodologia em questão.

Rabelo et al. (2022) realizaram uma avaliação comparativa de dados de satélite com dados disponíveis de 28 postos pluviométricos na bacia hidrográfica entre os anos de 1994 e 2014, tendo como conclusões de que os resultados mostraram que o CHIRPS tem boa capacidade de espacialização dos dados quando comparados aos dos postos pluviométricos

2.7.2. Satélites Globais para Avaliação de Precipitação

No que tange aos satélites globais para avaliação de precipitação considerados principais e mais comuns em termos de aplicação na literatura, destaca-se o ERA5, CMORPH, PERSIANN-CDR, CFSR e CHIRPS. Dessa forma, a seguir evidenciam-se aplicações a literatura dos satélites em questão que, na etapa de aplicação metodológica, foram abordados acerca de suas características principais.

i. CHIRPS

De acordo com Funk *et al.*(2015), o *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS) é um conjunto de dados de precipitação quase global de mais de 35 anos, abrangendo dados de 50°S-50°N (e todas as longitudes) e variando de 1981 até quase o presente. O CHIRPS incorpora a climatologia interna com imagens de satélite com resolução de 0,05° para criar séries temporais de chuva em grade para análise de tendências e monitoramento de configurações sazonais.

No contexto de estudos realizados a partir deste satélite, Nawaz, Iqbal e Mahmood (2021) realizaram a validação do conjunto de dados de precipitação baseado em satélite CHIRPS sobre o Paquistão dos últimos 38 anos (1981 a 2018) por meio de métricas estatísticas. Prakash (2019) avaliou o CHIRPS junto com outros produtos na Índia e resultou em uma mistura de superestimação e subestimação em várias regiões. Bai *et al.* (2018) analisaram o CHIRPS sobre a China, que apresentou diferenças incomuns com melhor desempenho no sul e fraco no noroeste e norte da China, avaliando também conjunto de dados de precipitação no Paquistão. Ullah et al (2019) avaliaram o CHIRPS juntamente com *Multi-Source Weighted-Ensemble Precipitation* (MSWEP), *PERSIANN Climate Data Record (CDR)* e produtos TMPA usando observações *in situ* em diversas regiões climáticas do Paquistão durante o período de 18 anos (1998-2016). Aksu e Akgül (2020) concluíram que o CHIRPS exibe alta correlação em escala de tempo mensal ao comparar os dados obtidos por este satélite com os dados de 77

estações meteorológicas terrestres distribuídas por toda a Turquia, com um período de estudo correspondente aos anos de 2008 a 2018.

ii. ERA5

O ERA5 é a reanálise atmosférica proposta pelo ECMWF (Centro Europeu de Previsões Meteorológicas a Médio Prazo) de quinta geração do clima global, que combina dados de modelo com observações de todo o mundo em um conjunto de dados globalmente completo e consistente (GEE, 2022a).

No que tange à aplicação deste, Jiao *et al.* (2021) realizaram uma avaliação do desempenho da variação espaço-temporal dos dados de precipitação ERA5 na China, de modo a verificar os dados de 1979 a 2018 com base em dados observacionais de estações meteorológicas de solo, tendo como resultado que os dados ERA5 podem capturar bem os padrões anuais e sazonais de precipitação observada, com valores de coeficiente de correlação variando de 0,796 a 0,945. Moges, Kmoch e Uemaa (2022) realizaram a aplicação de produtos de precipitação por satélite, avaliando que os resultados do satélite ERA5 mostraram a melhor capacidade de detecção para a precipitação mensal e demonstraram desempenho confiável para simular a vazão mensal.

iii. PERSIANN-CDR

PERSIANN-CDR é um produto diário de precipitação quase global que abrange o período de 1983-01-01 até o presente. Os dados são produzidos trimestralmente, com um atraso típico de três meses. O produto é desenvolvido pelo Centro de Hidrometeorologia e Sensoriamento Remoto da Universidade da Califórnia, Irvine (UC-IRVINE/CHRS) usando dados IR de satélites em grade (GridSat-B1) derivados da fusão de dados ISCCP B1 IR, juntamente com a versão GPCP 2.2 (GEE, 2022b).

No contexto da aplicação deste método de obtenção de precipitações, Talchabhadel *et al.* (2021) realizaram uma avaliação da elasticidade da precipitação usando dados de precipitação de estimativas terrestres e baseadas em satélite e modelagem de bacias hidrográficas no oeste do Nepal com PERSIANN-CDR e CHIRPS. Eini; Rahmati e Piniewski (2022) avaliaram os resultados de precipitação obtidos por meio do PERSIANN-CDR para a parte central da Polônia, na bacia hidrográfica de Wełna, concluindo que produtos PERSIANN não são confiáveis na modelagem diária de precipitação e escoamento.

iv. CFSR

O *National Centers for Environmental Prediction (NCEP) Climate Forecast System Reanalysis (CFSR)* foi projetado e executado como um sistema global de precipitação de alta resolução para fornecer a melhor estimativa durante o período de registro de 32 anos, de janeiro de 1979 a março de 2011. Os dados no *Earth Engine* estão presentes apenas a partir de 13 de dezembro de 2018 (GEE, 2022c).

Yu; Wu; Chen (2019) realizaram uma abordagem para avaliar os dados de chuva CFSR a montante do rio Lancang-Mekong em uma bacia montanhosa, evidenciando que os dados de satélite exibiram super desempenho em comparação com os dados de precipitação não corrigidos.

2.8. IMPORTÂNCIA DA ANÁLISE DA TEMPERATURAS SUPERFICIAL DO MAR (TSM)

O Oceano Pacífico é o maior oceano do mundo e desempenha um papel fundamental no sistema climático global. A interação entre a atmosfera e o oceano nessa região afeta a distribuição de calor, a formação de correntes oceânicas e a circulação atmosférica, influenciando o clima em diferentes partes do planeta (ABHISHEK; VIJITH; ANUP, 2023; AL-SHEHHI, 2022).

Nesse cenário, as variáveis de temperatura superficial do mar no Oceano Pacífico são de extrema importância para entender os processos climáticos globais e as interações oceano-atmosfera (PANDEY; LIOU, 2022; WICK; JACKSON; CASTRO, 2023). Essas variáveis têm influência significativa nas variações hidrológicas, como as correntes oceânicas, a circulação atmosférica e a distribuição de chuvas em diferentes regiões do mundo. (ABHISHEK; VIJITH; ANUP, 2023; WICK; JACKSON; CASTRO, 2023) Estas variáveis são essenciais para monitorar as variações de temperatura na superfície do mar ao longo do tempo. Esses dados são fundamentais para estudos climáticos, previsões de eventos climáticos extremos, como o El Niño e La Niña, além de auxiliar na compreensão das interações oceano-atmosfera (AL-SHEHHI, 2022; JANEKOVIĆ et al., 2022). No contexto das influências desta variável na hidrologia, destaca-se:

- **Correntes oceânicas:** A distribuição da TSM influencia diretamente a formação e intensidade das correntes oceânicas. A diferença de temperatura entre as massas de água provoca movimentos de circulação, como a Corrente Equatorial

do Pacífico e a Corrente de *Humboldt*, que desempenham um papel crucial no transporte de calor e nutrientes, afetando a distribuição da vida marinha.

- **Circulação atmosférica:** As variações da TSM no Oceano Pacífico também influenciam a circulação atmosférica, como a Oscilação Sul (*Southern Oscillation*) e a Oscilação Decadal do Pacífico (*Pacific Decadal Oscillation*). Esses padrões de variabilidade afetam a distribuição de pressão atmosférica, ventos e padrões de chuva em diferentes partes do globo.
- **Distribuição de chuvas:** A TSM influencia a evaporação e a umidade atmosférica, desempenhando um papel fundamental na distribuição de chuvas em diferentes regiões. Por exemplo, durante

2.8.1. Aquisição de Dados de Temperatura por Satélite

A temperatura superficial do mar (TSM) desempenha um papel fundamental nos processos climáticos e oceanográficos (ABHISHEK; VIJITH; ANUP, 2023; DE ALMEIDA FILHO et al., 2018; PANDEY; LIOU, 2022). A sua aquisição por meio de satélites oferece uma abordagem eficaz para monitorar as variações térmicas em escalas globais e regionais. Neste artigo, serão exploradas as bases científicas e as metodologias avançadas utilizadas para a aquisição precisa e confiável dos valores de TSM por satélite.

A aquisição da TSM por satélite se baseia na detecção da radiação eletromagnética emitida pelos oceanos na região do infravermelho termal. A temperatura da superfície do mar afeta a emissão de radiação, que pode ser detectada e convertida em valores de temperatura. (EICHHORN et al., 2020; PAGOTTO et al., 2015) Diferentes tipos de sensores, como radiômetros infravermelhos e micro-ondas, são empregados em satélites para aquisição de dados de TSM. As plataformas orbitais permitem a cobertura global e a obtenção de imagens em alta resolução temporal.

Modelos matemáticos e algoritmos de inversão são utilizados para converter as medidas de radiância obtidas pelos sensores em valores de temperatura. Esses modelos consideram parâmetros atmosféricos, como a concentração de vapor d'água e o perfil vertical de temperatura (SAUX PICART et al., 2020). Diversas validações científicas são realizadas para garantir a confiabilidade dos valores de TSM obtidos por satélite. Comparação com medições in situ, calibração radiométrica e técnicas de correção atmosférica são algumas das abordagens utilizadas para assegurar a precisão dos dados (ABHISHEK; VIJITH; ANUP, 2023).

A aquisição de valores de TSM por satélite tem inúmeras aplicações e benefícios. Ela é fundamental para o monitoramento de eventos climáticos, como El Niño e La Niña, e contribui para a compreensão das interações entre os oceanos e a atmosfera (WICK; JACKSON; CASTRO, 2023; ZHU; ZHANG, 2023). Além disso, os dados de TSM por satélite são essenciais para estudos climáticos, previsão de fenômenos extremos, monitoramento da saúde dos ecossistemas marinhos e suporte à pesca e à navegação, sendo uma ferramenta científica poderosa e amplamente utilizada para o monitoramento global das variações térmicas dos oceanos (ZHU; ZHANG, 2023). Através de fundamentações científicas sólidas e metodologias avançadas, é possível obter dados precisos e confiáveis, contribuindo significativamente para a compreensão dos processos climáticos e oceanográficos. Essa abordagem tem um papel crucial no desenvolvimento de estratégias de adaptação às mudanças climáticas e na gestão sustentável dos recursos marinhos.

2.9. USO DE REDES NEURAIS NA HIDROLOGIA

Garcia *et al.* (2016) aplicaram no rio Cagayan em Filipinas, o algoritmo de Random Forest com o objetivo de realizar previsões de níveis d'água para aprimorar as condições de utilização do curso d'água. Wagena *et al.* (2020) utilizaram a modelagem estocástica com o uso de RNA para realização de comparações de fluxos d'água em uma bacia hidrográfica dos USA. Yang *et al.* (2017) aplicaram um modelo de previsão baseado em séries temporais para obtenção das cotas de nível d'água no reservatório de Taiwan usando metodologias de aprendizado.

Prasad *et al.* (2017) utilizaram um modelo híbrido de RNA para previsões de fluxo na bacia Murray Darling para avaliação das condições de sazonalidade. Zhu *et al.* (2020) aplicaram rede neural *feed forward* (FFNN) e *Deep Learning* (DL) para prever as cotas mensais de altura da coluna d'água para regiões lacustres da Polônia. Li *et al.* (2020) aplicaram uma metodologia híbrida baseada em inteligência artificial para obtenção de valores de níveis d'água de rios da China. Shang *et al.* (2019) aplicaram uma metodologia de previsão para uma hidrelétrica na China com o intuito de aprimorar a gestão de recursos hídricos e controlar os níveis d'água a jusante.

2.10. PREVISÃO DE LÂMINAS D'ÁGUA

Nesse sentido, em virtude da variação constante das profundidades dos cursos fluviais, há a necessidade de avaliar, compreender e prever as flutuações do nível da água para o aprimoramento das operações de gerenciamento de recursos hídricos (ALTUNKAYNAK, 2014; PHAN; NGUYEN, 2020; REN *et al.*, 2020; ZIJL; SUMIHAR; VERLAAN, 2015), como previsão de inundações (CHEN *et al.*, 2013; HASHEMI *et al.*, 2014; SHEN *et al.*, 2015), avaliação de prejuízos atrelados à redução de calado disponível para navegação (CAMPOS FILHO *et al.*, 2019; KAMAL; SADEK, 2018; LIU *et al.*, 2016a) e operação de reservatórios (AGRAWAL; AHIDUZZAMAN; KUMAR, 2018; ARUNKUMAR; JOTHIPRAKASH, 2012; SEO *et al.*, 2015; SORACHAMPA; TIPPAYAWONG; NGAMSANROAJ, 2020), bem como a eventos de inundação relacionados à condições de degelo (LINDENSCHMIDT, 2020; SUN; TREVOR, 2018).

No contexto das pesquisas desenvolvidas pela literatura (DADASHI *et al.*, 2017; DU *et al.*, 2015; LALLA-RUIZ *et al.*, 2016; LE CARRER; FERSON; GREEN, 2020; XU; LI; LEUNG, 2012; ZHEN *et al.*, 2017), Seo *et al.* (2015) realizaram a previsão de níveis d'água a partir da utilização de técnicas de inteligência artificial. Scheepers *et al.* (2018) avaliaram o impacto das variáveis climáticas que influenciam na navegação do rio Mackenzie sob a ótica dos efeitos de redução de lâminas d'água. Le Carrer *et al.* (2020) realizaram a otimização do carregamento de embarcações a partir de técnicas estocásticas para verificação das oscilações de nível d'água. Li *et al.* (2016) elaboraram e validaram um modelo de redes neurais artificiais baseado em *Random Forest* (RF) para verificação das condições hidrológicas de cursos d'água na China. Khan *et al.* (2016) utilizaram modelos RNA (Rede Neural Artificial) para prever vazões e níveis de água do rio Ramganga, Índia. Phan and Nguyen (2020) analisaram o rio Vermelho, na Ásia, sob a ótica da estocástica a partir de modelos estatísticos para previsão do nível da água. Na Bacia Amazônica, Figueiredo and Blanco (2014) fizeram uso de modelos estocásticos ARIMA para previsão de vazões e níveis d'água no rio Tapajós.

Dentro da análise dos modelos de previsão de nível d'água, pode-se observar o uso constante de técnicas estatísticas aplicadas a utilização de *machine learning* nas séries temporais com o objetivo de encontrar relações ou obter previsões futuras (GJIKA; FERRJA; KAMBERI, 2019; PENG *et al.*, 2017; SANIKHANI *et al.*, 2019; YASEEN *et al.*, 2018, 2019), sendo modelagem matemática baseada em inteligência artificial caracterizada como uma ferramenta computacional robusta e valiosa para uso na hidrologia (ZHU *et al.*, 2020). Nesse contexto, destaca-se que nas últimas décadas os estudos hidrológicos tem sido agregados a

crescente utilização de métodos de redes neurais artificiais (PAPACHARALAMPOUS *et al.*, 2019; SULAIMAN *et al.*, 2018), com o uso constante para modelagem de níveis e fluxos d'água, avaliação de condições de inundação e de qualidade da água e dentre outras aplicações (GHORBANI *et al.*, 2018; KASIVISWANATHAN *et al.*, 2016; KIM; SEO, 2015).

2.11. PREVISÃO DE CALADOS OPERACIONAIS E CAPACIDADES DE CARGA

A partir do entendimento da importância da previsão de nível d'água em rios, deve-se destacar o fato de que a sazonalidade destes cursos d'água impactam significativamente de maneira negativa na navegação, haja vista que baixos fluxos e valores reduzidos de nível d'água dificultam a ocorrência de uma navegação perene (CAO *et al.*, 2020).

Dentro desta perspectiva, Li *et al.*(2020) destacam que as variações destas condições hidrológicas e climáticas influenciam na capacidade de carga do transporte via navegação interior, tendo impacto significativo no desenvolvimento econômico e nos preços deste tipo de transporte. Nesse sentido, destaca-se que as reduções de profundidade acarretam em reduções de calado (KIM; YEO, 2020; WETZSTEIN *et al.*, 2020), e estas reduções de calado influenciam no carregamento das embarcações e nas condições de navegação sob a ótica do *under keel clearance* (UKC) e nas influências do efeito *Squat* (LE CARRER; FERSON; GREEN, 2020). O UKC é a distância entre o fundo do rio e fundo da embarcação (LE CARRER; FERSON; GREEN, 2020), sendo uma variável influenciada pela velocidade do navio, coeficiente de bloco, fator de bloqueio, sentido da navegação e características geométricas do canal (BARRASS; DERRETT, 2006; LATAIRE; VANTORRE; DELEFORTRIE, 2012). O UKC é uma folga que, apesar de restringir os aumentos de calado (ELSHERBINY *et al.*, 2019), caracteriza-se como necessária para garantir a segurança da navegação por conta das condições dos leitos do rio, dos movimentos verticais da embarcação e das influências do efeito *squat* (GALOR, 2008; LI; LIU; LIU, 2017; SCHOENEICH, 2011).

Para análise das condições de folga abaixo da quilha das embarcações, faz-se necessária a obtenção das profundidades disponíveis no rio para que assim seja possível a verificação das condições hidrostáticas da embarcação para o calado disponível (BIRAN; LÓPEZ-PULIDO, 2014a, 2014b; KIM; YEO, 2020), isto é, a análise das condições relacionadas ao volume deslocado, deslocamento, porte bruto e outras condições operacionais diretamente dependentes da situação de carregamento e do calado da embarcação (BARRASS; DERRETT, 2012a, 2012b; TUPPER, 2013).

2.12. PROPRIEDADES GEOMÉTRICAS E HIDROSTÁTICAS DE EMBARCAÇÕES

2.12.1. Cálculo de Curvas Hidrostáticas

O estudo da conformação geométrica e das condições de carregamento e previsão de inclinação são de suma importância na etapa de projeto de uma embarcação, pois tais questões, dentre outros fatores, determinam a estabilidade do corpo flutuante.

Também conhecidas como Curvas de Forma, Almeida et. al. (2006) definem as curvas hidrostáticas como representações das características da embarcação na situação de flutuação em repouso e águas tranquilas, dependendo apenas da forma do volume submerso do casco. O plano de linhas é de fundamental importância para esta etapa do projeto da embarcação, visto que apresenta o conjunto dos planos de balizas, flutuação e linhas do alto dos quais são retiradas as principais medidas de referência para a construção das curvas.

Essencialmente, caracterizam-se por serem parâmetros que dependem da forma do volume submerso do casco, ou seja, da carena (PAIK; SEO; KIM, 2008). Como o volume deslocado representa o peso suportado pela embarcação, o conhecimento do volume de carena ajuda a determinar o quanto de carga a estrutura flutuante pode suportar e “fornecem noção do comportamento da embarcação do ponto de vista hidrostático” (RONG; CUI, 2013).

Em geral, sua principal finalidade é apresentar de forma direta as propriedades hidrostáticas do navio em função do seu calado, este, portanto, o dado de entrada (MARTINS, 2010). É através do calado que finalmente serão determinados o plano de flutuação e as áreas das balizas que, através de métodos numéricos e até mesmo computacionais, servirão para projetar as curvas. Os cálculos necessários envolvem, em sua grande maioria, a integração de áreas e volumes. Para Moideen; Somayajula e Falzarano (2014), através das curvas é que se obtêm as propriedades hidrostáticas para as diferentes condições de operação.

As principais variáveis para as análises hidrostáticas são:

- **V**: volume deslocado pelo navio, normalmente em m^3 ;
- **Δ** : deslocamento em peso do navio;
- **AWL**: área do plano de linha d'água em m^2 . Apresenta valores da área interna à curva definida pela interseção de planos horizontais com as formas do casco;
- **LCB**: Posição longitudinal do centro do volume submerso em relação à seção mestra;

- **LCF:** Longitudinal do centro de flutuação, em metros. É o centroide do plano de linhas d'água e interfere diretamente no estudo do compasso (trim) do navio;
- **KB:** Posição vertical do centro de carena, em metros. É a distância vertical do centro de carena à linha de base (quilha);
- **KMT:** Altura Transversal do Metacentro. Distância entre o centro de gravidade da embarcação e o Metacentro Transversal Inicial. É positiva quando o metacentro está acima do centro de gravidade e negativa em caso contrário. É uma medida da estabilidade inerente a um dado navio;
- **TCI:** Toneladas por centímetro de imersão. Indica quantas toneladas de carga devem ser adicionadas ao navio para que o calado aumente em um centímetro;
- **MT_{cm} :** Sendo este o momento necessário para trimar em 1 centímetro.

2.12.2. Curvas Cruzadas

A partir do entendimento dos fundamentos da estabilidade intacta de navios, faz-se necessária a análise desta estabilidade, por intermédio da geração de gráficos ou curvas capazes de representar as características de estabilidade de um navio.

Uma vez que a estabilidade de um navio pode ser comentada diretamente pela natureza e valor de sua altura metacêntrica (GM), um método direto para aferir a estabilidade de um navio para uma gama de ângulos de inclinação seria gerar uma curva que relaciona este parâmetro. Como a altura metacêntrica está diretamente relacionada ao braço de endireitamento (GZ) e ao ângulo de inclinação, a curva de estabilidade estática é um gráfico entre o braço de endireitamento e o ângulo (BIRAN; LÓPEZ-PULIDO, 2014c, 2014d).

Nesse sentido, seja qual for o ângulo de banda, o valor da “habilidade da embarcação” retornar à posição vertical é dada pelo produto do deslocamento do navio Δ e do braço de endireitamento (GZ).

2.12.3. Cálculo de Curvas de Bonjean

As curvas de Bonjean são um conjunto de curvas demonstram a variação da área das balizas com o calado. Assim, cada baliza apresenta uma curva de Bonjean. Em casos de trim excessivos há a necessidade de integrar as balizas utilizando as curvas de Bonjean. Com isso é possível calcular aspectos como o descolamento de massa e o LCB da embarcação. Em outras palavras, é possível calcular o deslocamento da embarcação em caso de condição de trim partindo-se do calado a vante e do calado a ré e realizando uma integração numérica simples por toda a extensão do Navio (MARTINS, 2010).

2.13. DIMENSIONAMENTO DE VIAS NAVEGÁVEIS

Um rio é um sistema complexo e a variedade em suas dimensões é ampla e contínua, devido às mudanças constantes na massa de água que é descarregada. Rios e canais são áreas limitadas de navegação, seja pela profundidade e largura, como também devido às variáveis presentes neste tipo de ambiente, como os efeitos de *squat*, aumento de resistência, perda de eficiência propulsiva e também a manobrabilidade (SCHALCK; BAATRUP, 1990). Parâmetros variáveis como características de vazão, mudança climática, evolução do tráfego, aumento das dimensões da embarcação, etc. devem ser levados em conta e um planejamento adequado de manutenção e extensão deve ser fornecido para garantir ou melhorar o desempenho a longo prazo das hidrovias (HARLACHER, 2016).

Corroborando com esse contexto, Liu *et al.*(2016) fazem uma análise acerca da manobrabilidade de navios em vias interiores, destacando as dificuldades de se operar nesse tipo de configuração, pois a navegação fluvial apresenta um cenário mais complexo do que a operação de navios em mar aberto. Sem falar da necessidade de os navios de navegação interior terem que operar em grande parte do tempo sem auxílio de “assistências” como os rebocadores. Ademais a manobrabilidade do navio nessas condições é de fundamental importância, influenciando diretamente nos critérios que permeiam a segurança da navegação.

A profundidade, largura e alinhamento do canal de navegação são as principais dimensões que devem ser analisadas considerando os vários elementos, incluindo detalhes de navios de projeto, condições de tempo e mar ao redor do canal e o método de manuseio do navio (MORRIS, 2013).

As características físicas do canal de navegação limitam o uso do mesmo por intermédio de parâmetros como os supracitados. Ao trabalhar no projeto de um novo layout portuário ou manutenção e análise de infraestrutura costeira, a publicação da *Permanent International Association of Navigation Congresses* (PIANC, 2014) é uma ferramenta valiosa para dimensionar canal de navegação . A avaliação das características dos fluxos naturais existentes deve ser o primeiro passo para o planejamento hidroviário (KUWAHARA; LAGO NETO; ABENSUR, 2012).

As dimensões de um canal de navegação são questões muito importantes para a segurança da navegação e, portanto, são calculadas com base nos parâmetros endógenos e exógenos da via (PAULAUSKAS; PAULAUSKAS, 2013). No projeto de novas hidrovias, essa questão deve ser resolvida por um esforço conjunto de organizações e indivíduos responsáveis

pelo projeto do canal, e organizações e indivíduos responsáveis pela navegação segura no canal após sua conclusão (ABRAHAM; LEPETIT, 1978).

Ferramentas que auxiliam na manutenção dos riscos à segurança mostram um valor agregado considerável em termos de seus impactos sociais e ambientais (TROJANOWSKI; IWAN, 2014). No que concerne ao desenvolvimento modal aquaviário, inúmeras pesquisas foram realizadas com o objetivo de aprimorar e assegurar a navegação, com a utilização de modelos matemáticos que auxiliem neste fim (TAYLOR *et al.*, 2005; XU; ZHANG; MOOKERJEE, 2013). Chen *et al.*(2013) e Wang *et al.*(2015b) deram a definição de hidrovia através da capacidade e analisaram a influência do nível de segurança na hidrovia através da capacidade de carga; Tang *et al.*(2014) discutiram a problemática das dimensões ótimas do canal. Tang *et al.*(2016) exploraram a relação entre a dimensão do canal e a ocupação do berço dos terminais; Liu *et al.*(2016b) propuseram modelos dinâmicos de dimensões de navios para estimar a capacidade de canais de água restritos.

As literaturas mencionadas acima corroboram e vão de encontro aos vários aspectos da pesquisa sobre formas de dimensionamento e análise das hidrovias, o que consolida uma base sólida para estudos relacionados à pesquisa.

No contexto de ferramentas desenvolvidas para amparar a utilização segura de hidrovias, Sun *et al.*(2012) introduziu uma plataforma de simulação geral, chamada MicroPort, que fornecia um sistema de modelagem para avaliar a capacidade operacional e eficiência de projetos portuários; Longo; Huerta e Nicoletti (2013) criou um modelo de simulação para analisar complexidade de um complexo portuário marítimo e a evolução do desempenho desse sistema; Ruggeri *et al.*(2018) desenvolveu uma ferramenta para análise do calado dinâmico de embarcações em um canal de acesso; Clausen e Kaffka (2016) usaram o método de simulação para otimizar as operações portuárias em um sistema geral com todas as suas influências.

3. MATERIAIS E MÉTODOS

Como forma de compreender e analisar a problemática a fim de promover e procurar soluções para o objeto de estudo, o presente trabalho se caracteriza e se classifica metodologicamente em razão de sua natureza como uma pesquisa aplicada, pois tem como objetivo a geração de conhecimentos para aplicação prática, dirigida à solução de problemas específicos (PERDIGÃO; HERLINGER; WHITE, 2012).

Concernente ao tipo de pesquisa, tem-se que esta se apresenta, como uma pesquisa exploratória, em virtude de buscar estudar determinada problemática levantada e determinar a natureza da mesma a partir do estabelecimento de métodos e técnicas, sendo também caracterizada como uma pesquisa explicativa, tendo em vista que este tipo de pesquisa, segundo Wazlawick (2014), visa o registro de determinado processo de modo a ser possível analisá-lo, interpretá-lo e identificar as problemáticas envolvidas neste processo, bem como suas causas.

Quanto ao tipo de abordagem metodológica e aos objetivos, tem-se que esta pode ser denominada de quantitativa e qualitativa. Na abordagem quantitativa, consideram-se todas as informações quantificáveis, traduzindo opiniões e informações em valores numéricos por intermédio de técnicas matemáticas e recursos estatísticos (percentagem, desvio padrão, média, mediana, análise de regressão, etc.), no intuito de classificá-las e analisá-las (CERVO; BERVIAN; SILVA, 2009). Em contrapartida, na abordagem qualitativa, evidencia-se um vínculo entre o mundo objetivo e a subjetividade, não podendo haver a tradução em números, não requerendo técnicas estatísticas e exigindo a interpretação dos fenômenos, com a atribuição de significados (CERVO; BERVIAN; SILVA, 2009).

No que concerne aos procedimentos do trabalho em questão, este pode ser classificado como um estudo de caso, fazendo-se uso da pesquisa bibliográfica. E esta, por sua vez, foi realizada a partir de levantamentos de fontes bibliográficas constituídas principalmente de, artigos científicos, livros, teses, dissertações e relatórios técnicos utilizados para sustentação desse trabalho (PERDIGÃO; HERLINGER; WHITE, 2012; WAZLAWICK, 2014).

Diante do exposto, destaca-se que, segundo Lakatos e Marconi (2003) para se entender o contexto e significado de uma pesquisa científica, deve-se primeiramente fazer o correto uso do método científico, sendo constituído por etapas, na intenção de resolver determinada problemática.

Assim, conforme mencionado nos tópicos supracitados, a pesquisa em questão trata-se de um estudo com objetivos intrínsecos: Desenvolver um modelo de aquisição de precipitações via satélite para posterior aplicação em modelo de previsão de lâminas d'água e consequente obtenção de calados operacionais e capacidades de carga de embarcações avaliando as condições planialtimétricas de um trecho do Rio Madeira. Nesse sentido, para a consecução dos objetivos em questão, necessita-se a realização de um fluxo retilíneo de etapas correspondente às metodologias aplicadas, visto que elas são extensivas e demandam o atendimento de uma série de sub-etapas. Corroborando com o apresentado, a fim de explicar tais metodologias e apresentar a estruturação metodológica deste trabalho, definiu-se a seguir, de maneira geral, as etapas subdivididas em cinco módulos, conforme segue:

i. MÓDULO 01: Modelo de Aquisição de Precipitação via Satélite

- **Seleção de Satélites para Aplicação da Rotina Computacional:** Avaliação detalhada de um grupo de satélites no que tange as suas características e particularidades de modo a selecionar os satélites mais adequados para a localidade estudada a partir de critérios pré-definidos em consonância com a literatura.
- **Rotina Computacional para Leitura de Precipitação:** Geração do modelo computacional para leitura de dados de precipitação via satélite fazendo-se uso da plataforma *Google Earth Engine*.
- **Calibração com Medições de Precipitação *in situ*:** Utilização de precipitações obtidas a partir de estações pluviométricas da ANA e INMET para calibração a partir de métricas estatísticas com os valores obtidos via satélite para as mesmas localizações.

ii. MÓDULO 02: Modelo de Aquisição de Temperaturas via Satélite

- **Seleção de Satélites para Aplicação da Rotina Computacional:** Avaliação detalhada de um grupo de satélites no que tange as suas características e particularidades de modo a selecionar os satélites mais adequados para a localidade estudada a partir de critérios pré-definidos em consonância com a literatura.
- **Rotina Computacional para Leitura de Temperaturas:** Geração do modelo computacional para leitura de dados de temperatura via satélite fazendo-se uso da plataforma *Google Earth Engine*.

iii. **MÓDULO 03: Modelo de Previsão de Lâmina D'água**

- **Aquisição da Base de Dados do Modelo:** Obtenção das variáveis de entrada e saída para a estação base (conhecida) e para a estação alvo (localidade em que se deseja prever os dados).
- **Aplicação de Modelos e Parâmetros:** A etapa em questão tem como objetivo a apresentação do modelo estatístico-matemático utilizado, bem como o algoritmo das duas redes neurais utilizadas (*perceptron* multicamadas com *backpropagation* e rede neural recorrente) com a evidenciação da estruturação da rede neural e suas etapas relativas ao processo de treinamento e validação, para posterior obtenção dos resultados.
- **Calibração e Validação do Modelo:** Comparação das variáveis observadas e simuladas, com posterior análise de resíduos e avaliação de métricas estatísticas.

iv. **MÓDULO 04: Cálculo de Calados Operacionais e Capacidades de Carga**

- **Modelagem Hidrostática da Embarcação:** A respeito da modelagem da embarcação para aferição das características hidrostáticas, tem-se esta como uma etapa de fundamental importância para a aferição das capacidades máximas de carga da formação de comboios analisada. Dessa forma, fez-se necessária a geração e avaliação destas propriedades, que se caracterizam como variáveis intrínsecas às embarcações adotadas.
- **Cálculo do *Underkeel Clearance*:** Avaliação da folga abaixo da quilha a partir de metodologias analíticas definidas pela literatura.
- **Definição dos Calados Operacionais e Capacidades de Carga:** Posterior a etapa citada, teve-se a quarta etapa, que se resumiu à aplicação das Redes Neurais Artificiais para geração dos valores de lâmina d'água, o que, conseqüentemente, possibilitou o cálculo dos valores de porte bruto do comboio partindo-se de um *underkeel clearance* calculado.

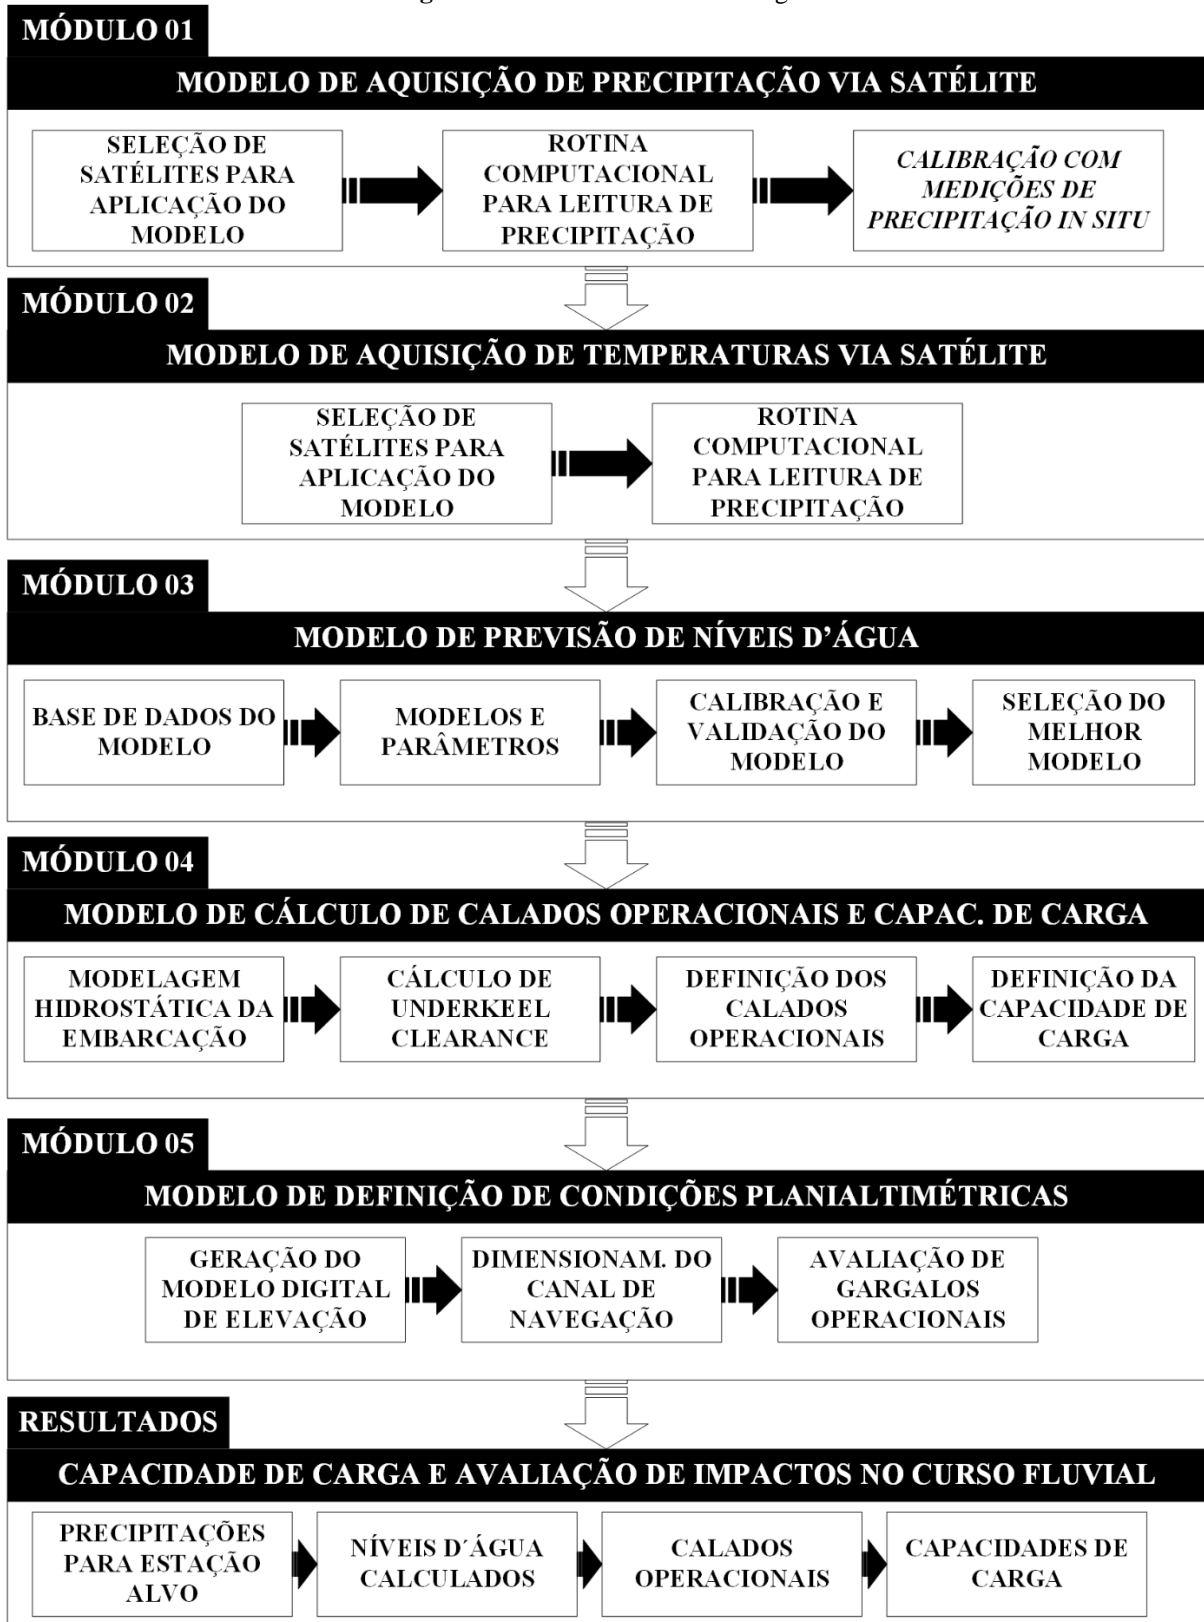
v. **MÓDULO 05: Modelo de Definição de Condições Planialtimétricas**

- **Desenvolvimento do Modelo Digital de Elevação:** Etapa de desenvolvimento do processo de convergência dos dados de relevo de fundo com os dados de lâmina d'água.
- **Definição das Condições Planialtimétricas:** Aplicação do software desenvolvido e patenteado denominado "*DimChannel*", o qual caracteriza-se por ser o responsável pelo cálculo dos valores de largura em trechos retos e curvos para a navegação segura na hidrovia analisada tendo por base a embarcação de projetos adotada.

- **Avaliação do Impacto da Sazonalidade:** Por fim, teve-se, a partir da geração das capacidades de carga e do dimensionamento da via navegável, a geração e avaliação dos impactos da sazonalidade dos cursos d'água na navegação, sendo possível verificar-se os períodos críticos e seus impactos na navegação e na capacidade de carga.

Para o desenvolvimento dos modelos e aplicação do estudo de caso, foram adotadas as etapas metodológicas supracitadas como forma de seguir um fluxo retilíneo e dirigido de processos pré-definidos. Na Figura 1 pode-se observar um fluxograma metodológico com a evidenciação e sintetização das etapas seguidas e implementadas nos modelos.

Figura 1 - Detalhamento Metodológico



Fonte: Autor (2023).

Para tanto, evidencia-se que o estudo em questão se destaca como uma pesquisa de auxílio à tomada de decisões no que tange ao transporte de cargas na Amazônia, por intermédio da previsão das capacidades de carga ao longo do ano e definição do traçado seguro de navegação. Dessa forma, de modo a detalhar as etapas supramencionadas, tem-se os tópicos que seguem apresentando as discussões acerca de cada uma.

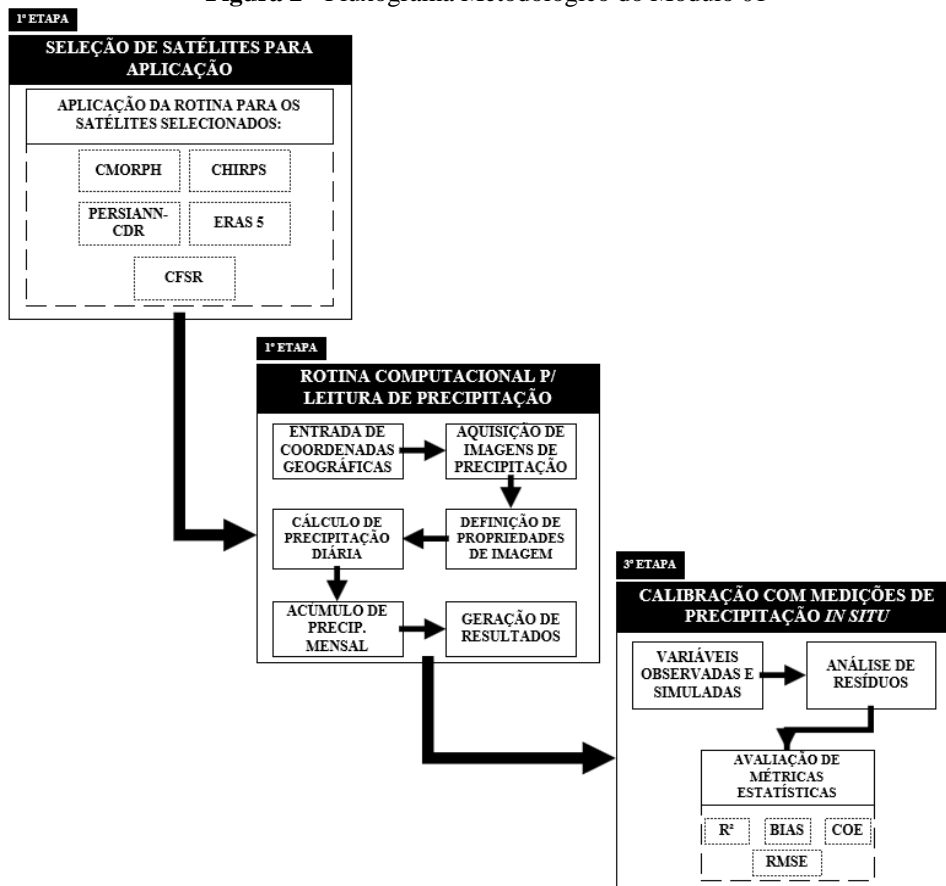
3.1. MÓDULO 01: MODELO DE AQUISIÇÃO DE PRECIPITAÇÕES

A obtenção de dados de precipitação via satélite configura-se como uma metodologia complementar às estações de superfície que dependem, por exemplo, de um pluviômetro. Os dados adquiridos a partir do sensoriamento remoto tem sua importância e necessidade justificadas no fato de proporcionarem a obtenção de valores contínuos de precipitação, isto é, referentes a áreas completas, ao passo que os obtidos com aferição *in situ* configuram-se como pontuais e dependentes da disponibilidade de estações pluviométricas que, por vezes, ficam a muitos quilômetros umas das outras, fato este que dificulta parte das análises. Associado a isso, reitera-se a vantagem dos satélites em relação às estações locais no que diz respeito à disponibilidade de dados, visto que os bancos de imagens se encontram disponíveis e preenchidos para todo o período histórico de referência do satélite, enquanto as aferições *in situ*, em algumas situações, apresentam falhas e escassez de dados de medição.

De modo a sustentar a partir da literatura a utilização de dados de precipitação via satélite no presente estudo, reforça-se a literatura em Biggs e Shen (2021), Rabelo et al. (2022), Marinho e Rivera (2021), Cavalcante et al. (2020) e Paca et al. (2020) que avaliaram para Região Amazônica o uso dos satélites CHIRPS e/ou PERSIANN acerca do comportamento da variabilidade sazonal em relação aos dados de superfície, reforçando a viabilidade de uso dos dados em questão no processo de inserção destes como *inputs* posteriormente na Rede Neural Artificial (RNA) para obtenção de lâminas d'água.

Assim, corroborando com este cenário, apresenta-se a primeira etapa metodológica com o desenvolvimento do modelo de aquisição de precipitações elaborado em sub-etapas, conforme apresentado na Figura 2.

Figura 2 - Fluxograma Metodológico do Módulo 01



Fonte: Autor (2023).

Em consonância com o fluxograma apresentado na Figura 2, nos itens que seguem evidenciam-se os pormenores referentes ao Módulo 01, correspondendo às etapas processuais relativas ao método adotado para a consecução do objetivo proposto, referente à concepção do modelo de aquisição por intermédio de linguagem de programação na plataforma *Google Earth Engine*.

3.1.1. Seleção de Satélites para Aplicação

No que concerne à primeira sub-etapa referente à aquisição dos dados de precipitação, tem-se que, a partir de análise apurada na literatura recente, com uso da vanguarda científica, definiram-se os principais satélites citados e utilizados em estudos hidrológicos relativos à variável precipitação pluviométrica, a fim de que suas características sejam posteriormente avaliadas já partindo de uma pré-seleção filtrada com base em fundamentação bibliográfica, conforme apresentado no item “2.6. PRECIPITAÇÃO PLUVIOMÉTRICA POR SATÉLITE” do presente documento e corroborado com a Tabela 2, sendo os satélites apresentados posteriormente avaliados e detalhados acerca de seus critérios específicos nos itens que seguem, relacionados às características de cada um.

Tabela 2 – Definição de Principais Satélites pela Literatura

Satélite	Provedor de Dados	Literatura Analisada
<i>CHIRPS – Climate Hazards Group InfraRed Precipitation</i>	UCSB	Ghozat; Sharafati e Hosseini (2021) Prakash (2019) Aksu e Akgül (2020) Nawaz; Iqbal e Mahmood (2021) Le e Pricope (2017) Bai <i>et al.</i> (2018) Rivera; Marianetti e Hinrichs (2018) Abdelmoneim; Soliman e Moghazy (2020) Dinku <i>et al.</i> (2018) Paredes-Trejo; Barbosa; Lakshmi e Kumar (2017)
<i>PERSIANN – Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks</i>	NOAA	Eini; Rahmati; Piniewski (2022) GEE (2022b) Yang e Luo (2014) Sadeghi <i>et al.</i> (2021) Nguyen <i>et al.</i> (2018) (Huang; Liu e Hsu (2021) Zhang <i>et al.</i> (2022) Salmani-Dehaghi; Samani (2021) Santos <i>et al.</i> (2021) Sobral <i>et al.</i> (2020) Alijanian <i>et al.</i> (2019)
<i>ERA5 – Latest Climate Reanalysis Produced by ECMWF</i>	ECMWF	Maggioni; Meyers e Robinson (2016) Jiang <i>et al.</i> (2021) Cochrane <i>et al.</i> (2017) Yilmaz (2023) Huang <i>et al.</i> (2022) Noël <i>et al.</i> (2022) Cantoni <i>et al.</i> (2022) Wu <i>et al.</i> (2023) Steinkopf e Engelbrecht (2022) Nikfal (2023) Saidelles <i>et al.</i> (2022)
<i>ERA5 – Latest Climate Reanalysis Produced by ECMWF</i>	ECMWF	
<i>CFSR – Climate Forecast System Reanalysis</i>	NOAA	Amarouche <i>et al.</i> (2021) Gramcianinov <i>et al.</i> (2020) Olaofe (2019) Tomy e Sumam (2016) Cannon <i>et al.</i> (2015) Sharp <i>et al.</i> (2015) Worqlul <i>et al.</i> (2017) Kessete; Moges e Steenhuis (2019) Li <i>et al.</i> (2015b)
<i>CMORPH – Climate Prediction Center (CPC) Morphing Technique</i>	NOAA	Jiang <i>et al.</i> (2016) Trenberth; Zhang; Gehne (2017) Gumindoga <i>et al.</i> (2020) Yang e Luo (2014) Li <i>et al.</i> (2015) Haile; Habib e Rientjes (2013) Bytheway <i>et al.</i> (2020) Chen <i>et al.</i> (2015) Habib <i>et al.</i> (2012) Chen <i>et al.</i> (2020) Haile; Yan e Habib (2015) Prasad <i>et al.</i> (2017)

Fonte: Autor (2023).

De início, portanto, tem-se a necessidade de, antes de adentrar no desenvolvimento da rotina computacional e posterior aplicação desta, realizar-se o processo de definição dos critérios iniciais de seleção de satélites para aplicação da rede. No que tange a estes critérios, eles foram necessários de modo a sistematizar o procedimento a fim de tornar célere e bem definida a escolha alternativas existentes. Assim, com base na literatura e nas características dos satélites estudados, definiram-se como critérios de seleção, os que seguem:

- **Espaço Amostral Disponível:** Este parâmetro caracteriza-se como a definição do range de dados disponível em termos de série histórica, isto é, o período inicial da medição ao período final da medição (EINI; RAHMATI; PINIEWSKI, 2022; PRAKASH, 2019).
- **Provedor de Dados:** Configura-se como o responsável pelo fornecimento e tratamento dos dados disponibilizados para aquisição, sendo, em sua maioria, entidades governamentais, instituições privadas e organizações internacionais (FUNK *et al.*, 2015; NAWAZ; IQBAL; MAHMOOD, 2021).
- **Amplitude Geográfica:** Definido como a amplitude dos dados em torno do globo terrestre, isto é, se estão disponíveis em uma dada região em um dado continente (AKSU; AKGÜL, 2020; CHEN *et al.*, 2022; COCHRANE *et al.*, 2017).
- **Resolução:** Configura-se como o valor referente às dimensões dos pixels das imagens de satélite, influenciando diretamente na qualidade dos dados (GEE, 2022c, 2022b).
- **Banda e Unidade:** Caracteriza-se como a unidade de medição referente às variáveis fornecidas pela alternativa analisada (ABDELMONEIM; SOLIMAN; MOGHAZY, 2020; JING *et al.*, 2014).
- **Disponibilidade no GEE:** Dado o fato de que a plataforma de desenvolvimento do *script* de aquisição dos dados utilizada foi a *Google Earth Engine*, tem-se a necessidade de que os dados estejam disponíveis como trecho de “*ee.ImageCollection*” na plataforma em questão: <https://developers.google.com/earth-engine/datasets> (GEE, 2022d).

Dessa forma, a partir dos critérios em questão, definiu-se uma matriz de seleção para ranqueamento das alternativas com base nas respostas de cada parâmetro supracitado, definindo uma ordem de prioridade destes, conforme elencado na Tabela 3 que segue.

Tabela 3 – Ordem de Prioridades de Critérios para Alternativas

Prioridade	Critério	Motivo da Prioridade
1	Disponibilidade no GEE	O script de aquisição de dados foi realizado no <i>Google Earth Engine</i> , portanto, faz-se necessário, como critério inicial, que haja interface com a plataforma.
2	Amplitude Geográfica	A região de análise configura-se como um critério extremamente relevante para escolha ou não do satélite, portanto, se os dados não tiverem disponíveis para a região analisada, o mesmo não pode ser utilizado.
3	Espaço Amostral Disponível	Verifica-se o a série histórica de dados disponíveis, visto que para a realização da aplicação do modelo de previsão e lâminas d'água, faz-se necessária uma série histórica significativa de, no mínimo, 30 anos de dados.
4	Banda e Unidade	Necessita-se de dados de previsão em mm/dia, portanto, satélites que fornecem valores em mm/mês foram descartados.
5	Resolução	Optou-se pela prioridade a satélites com maior definição para que, assim, tenham-se maiores precisões na aquisição dos dados.
6	Provedor de Dados	Optou-se por provedores de dados de Entidades Governamentais e Empresas Privadas com ampla aceitação perante a comunidade científica.

Fonte: Autor (2023).

De posse dos critérios e da ordem de prioridade supracitada, para a consolidação da primeira etapa do Módulo 01 de estudo, apresenta-se na Tabela 4 uma matriz modelo desenvolvida com satélites fictícios apenas para apresentação e posterior preenchimento com valores reais relativos ao ranqueamento dos avaliados no estudo de caso, sendo selecionado, dentre os avaliados, os TRÊS melhores ranqueados para posterior aplicação do método de coleta de dados e calibração.

Tabela 4 – Matriz Modelo de Seleção de Satélites

Item	Satélite	Disponibilidade no GEE	Amplitude Geográfica	Espaço Amostral	Banda e Unidade	Resolução (metros)	Provedor de Dados	Ranking
1	Satélite A	Sim	Global	1981-01-01 2022-01-01	mm/dia	5566	UCSB	1
2	Satélite B	Sim	América Central e Europa	1983-01-01 2022-06-30	mm/dia	27830	NOAA	2

Fonte: Autor (2023).

3.1.2. Rotina Computacional para Leitura de Precipitação

No que tange ao desenvolvimento da rotina computacional para leituras de precipitação, procedeu-se com a elaboração desta a partir da plataforma *Google Earth Engine - GEE*, em virtude das facilidades relativas à associação de dados de satélite com coordenadas geográficas do globo. O GEE (GORELICK et al., 2017) implementa a combinação e disponibilidade de um catálogo de *petabytes* de imagens de satélite e conjuntos de dados geoespaciais com recursos

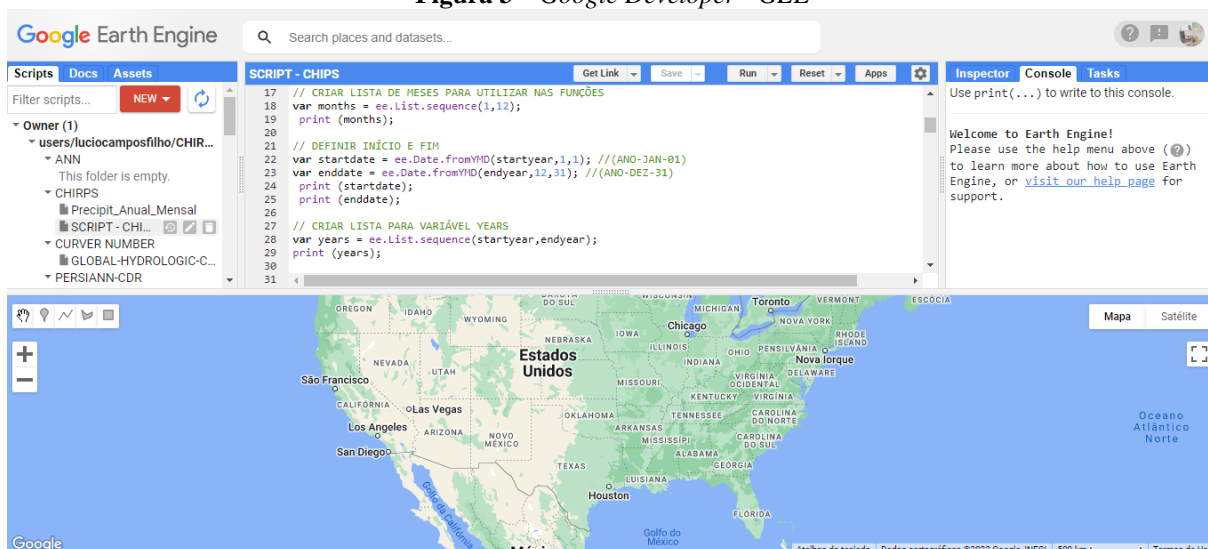
de análise em escala planetária, sendo uma ferramenta voltada para uso acadêmico e científico por parte de pesquisadores e desenvolvedores, que o usam para detectar mudanças climáticas, adquirir dados, mapear tendências e quantificar diferenças na superfície da Terra.

A ferramenta em questão faz uso de dois outros módulos principais: *Earth Engine Data Catalog* e *Google Developer*. O primeiro sendo responsável por reunir a biblioteca de informações relativas às principais áreas de análise dentro da plataforma, sendo elas (GORELICK et al., 2017):

- ***Climate and Weather***: Divido em *Surface Temperature* (Sensores de satélite térmicos que podem fornecer informações de temperatura e emissividade da superfície), *Climate* (modelos climáticos que geram previsões climáticas de longo prazo e interpolações históricas de variáveis de superfície), *Atmospheric* (dados atmosféricos para ajudar a corrigir dados de imagem de outros sensores), *Weather* (conjunto de dados meteorológicos que descrevem condições previstas e medidas em curtos períodos de tempo, incluindo precipitação, temperatura, umidade e vento);
- ***Imagery***: Divido em *Landsat* (imagens de toda a superfície da Terra com uma resolução de 30 metros, incluindo dados multiespectrais e térmicos), *Sentinel* (incluem imagens de radar de alta resolução do Sentinel 2A e 2B, com dados oceânicos e terrestres adequados para monitoramento ambiental e climático), *MODIS* (*Moderate Resolution Imaging Spectroradiometer*) e *High-resolution Imagery* (captura de detalhes mais sutis de paisagens e ambientes urbanos);
- ***Geophysical***: Divido em *Terrain* (com Modelos Digitais de Elevação globais baseados em *Shuttle Radar Topography Mission – SRTM*), *Land Cover* (classes de cobertura da terra, como floresta, pastagem e água) e *Cropland* (dados das terras agrícolas).

O segundo módulo da ferramenta configura-se como o *Google Developer*, sendo este um site da companhia Google para interesse de programadores em desenvolvimento de *softwares*, contendo código-fonte aberto (GORELICK et al., 2017). De modo a ilustrar este, tem-se na Figura 3 a evidência de parte do *script* desenvolvido na plataforma do *GEE* para aquisição dos dados de precipitação.

Figura 3 – Google Developer - GEE



Fonte: Autor (2023).

De posse das informações supramencionadas no que diz respeito à plataforma utilizada, pode-se partir para a apresentação do desenvolvimento do *script* de aquisição de dados, que se deu a partir de etapas, desde a seleção de coordenadas de satélite à geração de resultados e gráficos, conforme detalhado a seguir.

a. Seleção de Período de Análise

A seleção do período analisado consistiu na declaração de variáveis relativas à série histórica a ser adquirida para os satélites selecionados, de modo que este período de análise esteja compreendido por variáveis de dia, mês e ano, definindo-se um *range* de dados comum aos satélites designados da etapa anterior, isto é, se um Satélite A tem dados de 01/01/1981 à 31/12/2021 e um Satélite B tem dados de 01/01/1983 a 01/12/2022, o *range* considerado seria aquele em que ambos os satélites possuem dados comuns: 01/01/1983 a 31/12/2021. Tal fato se deu para que a posterior calibração pudesse ser realizada com parâmetros e espaços amostrais semelhantes.

A fim de facilitar o entendimento, desenvolveu-se a Figura 4 que segue, de modo a evidenciar a forma de seleção do espaço amostral.

Figura 4 – Seleção de Período de Análise

SATÉLITE	SÉRIES HISTÓRICAS DISPONÍVEIS											
	ANO A	ANO B	ANO C	ANO D	ANO E	...	ANO UU	ANO VV	ANO WW	ANO XX	ANO YY	ANO ZZ
Satélite A	●										●	
Satélite B		●										●
Satélite C	●										●	
Período Adotado		●	—	—	—	—	—	—	—	—	●	

Fonte: Autor (2023).

Entretanto, reitera-se que na seleção de satélites, o ranqueamento foi realizado tendo como um dos critérios principais a quantidade de dados disponíveis, fato este que possibilitou uma homogeneidade significativa nas informações utilizadas, visto que grande parte dos satélites possuem séries históricas semelhantes.

De posse dessas informações, no *GEE Developer*, as variáveis de data forma definidas com o método “*ee.Date.fromYMD*”, na forma de data AAAA-MM-DD (hh-mm-ss), podendo-se prosseguir às etapas seguintes.

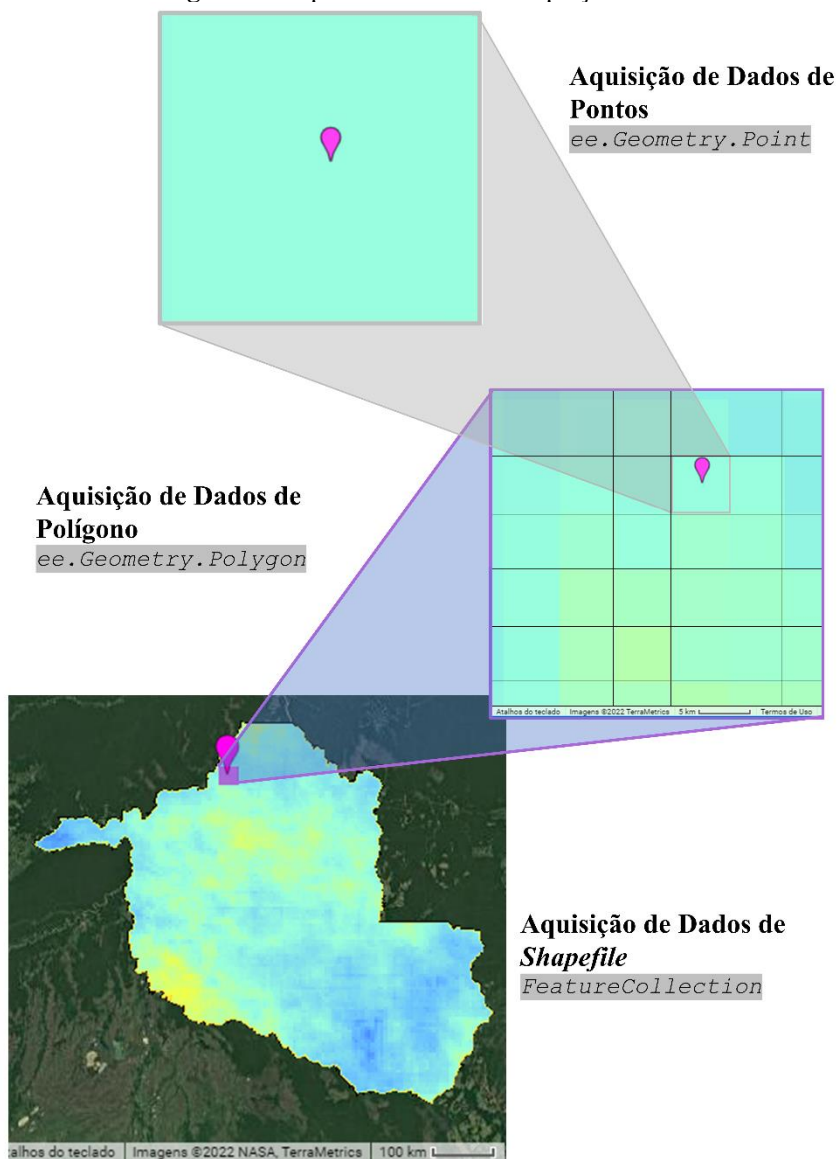
b. Entrada de Coordenadas Geográficas

Para realização do procedimento de cálculo de precipitações, necessita-se definir a região de captação dos dados, inserindo-se a propriedade do elemento a ser utilizado no processo. No modelo em questão, trabalhou-se com três possibilidades de seleção: *Shapefile*, Polígono e Ponto, tendo cada um desses características intrínsecas a serem avaliadas no que tange aos seus dados.

Entretanto, antes de apresentar tais características, deve-se ter o entendimento correto de que as imagens de precipitação disponíveis no GEE se configuram como imagens que associam um valor diferente de uma mesma variável a cada pixel presente na imagem, portanto, *shapefiles* e polígonos possuem um conjunto de pixels associados a um conjunto de valores de mesma variável, ao passo que um ponto específico possui apenas um pixel e, conseqüentemente, apenas um valor para a mesma variável. Tal esclarecimento configura-se como de fundamental importância na seleção do tipo de entrada, visto que isto influencia diretamente na saída de dados.

Para tanto, de modo a ilustrar e facilitar o entendimento da explicação supracitada, foi desenvolvida a Figura 5, que apresenta três imagens: A primeira representando a aquisição de dados a partir de um *shapefile*, a segunda a aquisição de dados de um polígono com dimensões de altura e largura sendo múltiplas da resolução do pixel da imagem e, por fim, na última imagem a aquisição de dados por meio da inserção de um ponto.

Figura 5 – Tipo de Elemento de Captação de Dados



Fonte: Autor (2023).

Nesse sentido, no *GEE*, para o *input* de um *shapefile*, recorreu-se ao método “*FeatureCollection*”, em que se faz a inserção de um arquivo *.shp* oriundo do banco de dados *Assets*. Em complementação, para a inserção de dados de um polígono, utilizou-se o método “`ee.Geometry.Polygon`”, colocando as latitudes e longitudes de cara vértice da forma geométrica adotada. Como terceira alternativa de elemento para aquisição, tem-se o

ponto, com uso do método “*ee.Geometry.Point*”, inserindo unicamente uma coordenada geográfica com latitude e longitude.

c. Aquisição de Imagens de Precipitação

A partir da definição do período de análise e do tipo de elemento adotado com entrada, desenvolveu-se o procedimento de aquisição das imagens de precipitação, com a declaração do satélite desejado que esteja previsto no banco de dados do *GEE* como um “*Earth Engine Snippet*”, sendo declarado como uma variável associada à ferramenta “*ee.ImageCollection*” seguido do caminho da base de informações (ASSET) vinculado ao satélite. Como exemplo, apresenta-se na Figura 6 a definição desenvolvida para chamada do satélite CHIRPS DAILY ((FUNK et al., 2015).

Figura 6 – Aquisição de Imagem de Precipitação

```
var dataset = ee.ImageCollection('UCSB-CHG/CHIRPS/DAILY')
    .filter(ee.Filter.date('2018-05-01', '2018-05-03'));
var precipitation = dataset.select('precipitation');
var precipitationVis = {
  min: 1.0,
  max: 17.0,
  palette: ['001137', '0aab1e', 'e7eb05', 'ff4a2d', 'e90000'],
};
Map.setCenter(17.93, 7.71, 2);
Map.addLayer(precipitation, precipitationVis, 'Precipitation');
```

Fonte: Autor (2023).

Tendo em vista que a plataforma GEE configura-se como de fácil manipulação, a etapa em questão foi realizada em poucas linhas de código e de maneira simplificada, conforme supracitado, podendo-se, então, seguir com o desenvolvimento metodológico.

d. Definição de Propriedades da Imagem

No que tange à etapa de seleção da propriedade do satélite, esta configura-se como de fundamental importância tendo em vista que, dentre os satélites avaliados, alguns deles tratam de mais de um tipo de variável, sendo selecionado, para todos eles, a variável como sendo precipitação diária em milímetros.

Na presente etapa realizou-se, portanto, o procedimento de aquisição dos dados da imagem para a variável definida e declarada, utilizando ferramentas de filtro de contorno (“*ee.ImageCollection.filterBounds*”) a partir do elemento definido (*shapefile*, ponto ou polígono) para efetuar o corte da imagem *raster* em relação aos limites da geometria declarada, bem como de filtro de período (“*ee.ImageCollection.filterDate*”), para posterior extração dos dados por pixel e geração dos procedimentos matemáticos de acúmulo de dados para períodos mensais e anuais de precipitação.

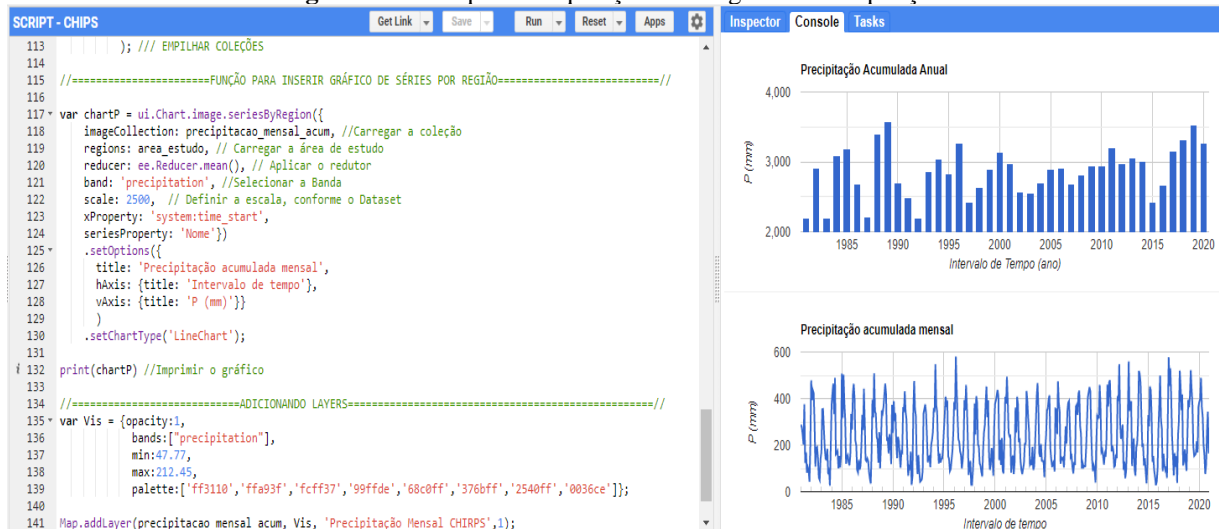
e. Acúmulo de Precipitação Mensal e Anual

A cerca dos procedimentos de acúmulo de precipitação, estes foram realizados de modo a gerar funções loop aninhadas (isto é, laço dentro de laço) associadas à procedimentos matemáticos pré-definidos de filtro, já descritos a partir de funções prontas no GEE, como “`ee.Filter.calendarRange`”, de modo a otimizar o processo de acúmulo nas imagens para posterior associação dos dados gerados a variáveis de saída e à imagem rasterizada com as informações especializadas.

f. Geração de Resultados e Gráficos

Realizados os procedimentos supracitados e com os valores de saída já associados às variáveis, desenvolveu-se o procedimento de plotagem dos resultados em gráficos de barra vertical, com o eixo das abscissas dispostos em relação ao tempo (mês ou ano) e o eixo das ordenadas associado à variável precipitação em milímetros. A partir disso, os gráficos foram plotados com a definição de três tipos de *output*: *.csv* (para visualização dos dados numéricos em tabela), *.png* (para visualização do gráfico) e *.svg* (para visualização das variáveis em formato de gráfico vetorial escalonável). Como exemplo ao procedimento em questão, evidencia-se a Figura 7 com parte do script de plotagem na esquerda e com gráficos na direita.

Figura 7 – Exemplo de Aquisição de Imagem de Precipitação



Fonte: Autor (2023).

3.1.3. Calibração de Medições de Precipitação *In Situ*

a. Comparação de Variáveis Observadas e Aquisitadas

A etapa em questão configurou-se como de fundamental importância para o desenvolvimento metodológico, visto que possibilitou a calibração dos valores captados a partir de sensoriamento remoto com estações conhecidas superficiais por intermédio da comparação da

precipitação acumulada mensal de um pixel em um dado polígono, sendo este pixel coincidente com a latitude e longitude de uma estação *in situ* obtidas a partir da Agência Nacional de Águas, na ferramenta *Hidroweb*.

A comparação dos valores de variáveis observadas (Estações ANA) e aquisitadas (Sensoriamento Remoto) foi realizada a partir da utilização de métricas estatísticas de modo a verificar o satélite com menor BIAS e RMSE e maior R² e COE dentre os três satélites selecionados na etapa do item 3.1.1. *Seleção de Satélites para Aplicação*. A partir desta seleção, foi conduzida, então, a aplicação do modelo de previsão de lâminas d'água.

b. Avaliação de Métricas Estatísticas

Na literatura evidencia-se a existência de uma vasta quantidade de análises estatísticas utilizadas para avaliar dados de precipitação *in situ* e estimativas de satélite, tendo em vista a importância de medir a compatibilidade desses dados. Para o presente estudo, quatro métricas foram avaliadas: Coeficiente de determinação (R²), a Raiz do Erro Quadrado Médio (RMSE), o Viés Relativo (BIAS) e o Coeficiente de Eficiência (COE), conforme detalhados a seguir.

O BIAS, de acordo com Yapó; Gupta; Sorooshian (1996), indica como as estimativas de chuva por satélite (y_i) se relacionam com as medições obtidas pelos pluviômetros (\hat{y}_i). Valores de BIAS negativos indicam que, em média, o satélite superestima a chuva obtida pelos pluviômetros, e para valores positivos, significa que ocorreu uma subestimação (Equação 1).

$$BIAS = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)}{\sum_{i=1}^N \hat{y}_i} \quad (1)$$

Em que y_i representando o valor previsto pelo modelo, e \hat{y}_i representando o valor real.

O COE, coeficiente de eficiência de Nash e Sutcliffe (1970), foi utilizado também como métrica, sendo citado na literatura como um dos mais importantes critérios estatísticos para avaliar o ajuste de modelos hidrológicos. A Equação 2 apresenta a formulação referente a este parâmetro estatístico.

$$COE = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2} \quad (2)$$

Em que \bar{y} é a média dos valores presente na série histórica, y_i representando o valor previsto pelo modelo, e \hat{y}_i representando o valor real.

No que tange ao R², este é uma medida de proporção da variabilidade entre o valor real e o valor previsto pelo modelo. No geral, o valor desta métrica oscila entre 0 e 1, em certos casos específicos, como modelos variantes destes em que o a métrica pode obter o valor menor

que um, indicando uma correlação arbitrária pior. A expressão para o modelo R^2 foi definida na Equação 3.

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Um dos modelos de métricas mais utilizados é o MSE, ou erro quadrático médio, que calcula a média dos erros ao quadrado. Essa métrica apresenta vantagens pois pondera a diferença do erro por grau de importância. O uso da raiz quadrada no MSE permite com que se obtenha um erro de mesma escala da variável de análise, permitindo uma interpretação mais intuitiva quanto a precisão do modelo desenvolvido. A formulação da métrica MSE adaptada, conhecida pela sigla RMSE, foi definida na Equação 4.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Em que \bar{y} é a média dos valores presente na série histórica, y_i representando o valor previsto pelo modelo, e \hat{y}_i representando o valor real.

De posse das formulações de métricas supracitadas, a fim de consolidar os parâmetros utilizados, apresenta-se Tabela 5 os valores ótimos e as faixas de valores relativos à cada métrica.

Tabela 5 – Ordem de Prioridades de Critérios para Alternativas

Métrica Estatística	Faixa de Valor	Valor Ótimo
R^2	0 a 1	1
RMSE	0 a ∞	0
COE	$-\infty$ a 1	1
BIAS	0 a ∞	0

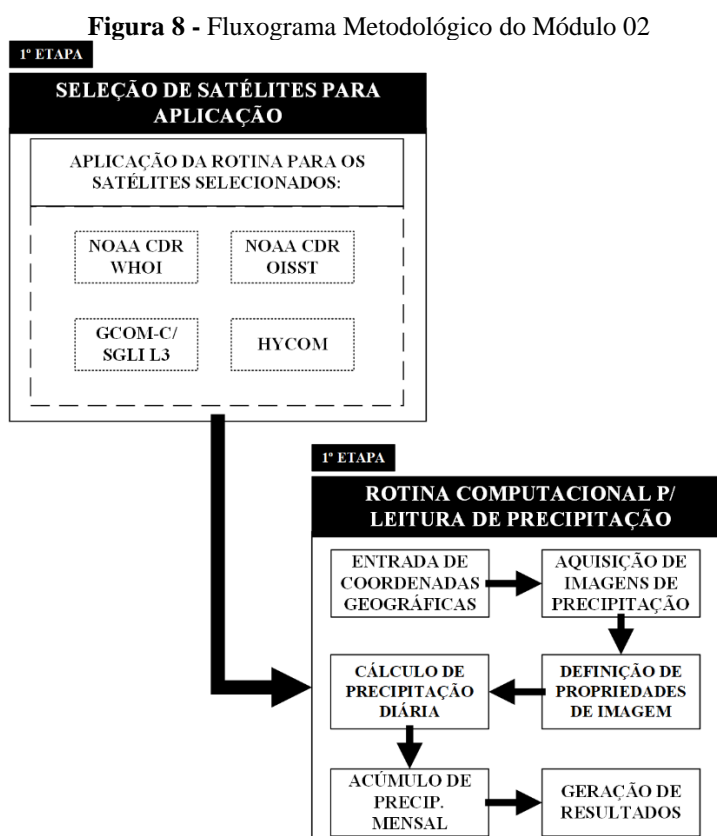
Fonte: Autor (2023)

3.2. MÓDULO 02: MODELO DE AQUISIÇÃO DE TEMPERATURAS

No que tange ao processo de obtenção de dados de temperatura via satélite, este foi realizado adotando-se como premissas e etapas processuais as semelhantes às apresentadas no Módulo 01, aproveitando-se o script de aquisição de precipitações e filtrando-se os dados com base em outro satélite com diferente variável.

Os dados aquisitados a partir do sensoriamento remoto tem sua importância e necessidade justificadas no fato de proporcionarem a obtenção de valores contínuos de temperatura, isto é, referentes a áreas completas, ao passo que os obtidos com aferição *in situ* configuram-se como pontuais e dependentes da disponibilidade de estações que, por vezes, ficam a muitos quilômetros umas das outras, fato este que dificulta parte das análises. Associado a isso, reitera-se a vantagem dos satélites em relação às estações locais no que diz respeito à disponibilidade de dados, visto que os bancos de imagens se encontram disponíveis e preenchidos para todo o período histórico de referência do satélite, enquanto as aferições *in situ*, em algumas situações, apresentam falhas e escassez de dados de medição.

Assim, corroborando com este cenário, apresenta-se a primeira etapa metodológica com o desenvolvimento do modelo de aquisição de precipitações elaborado em sub-etapas, conforme apresentado na Figura 8.



Fonte: Autor (2023).

Em consonância com o fluxograma apresentado na Figura 2, nos itens que seguem evidenciam-se os pormenores referentes ao Módulo 02, correspondendo às etapas processuais relativas ao método adotado para a consecução do objetivo proposto, referente à concepção do modelo de aquisição por intermédio de linguagem de programação na plataforma *Google Earth Engine*.

3.2.1. Seleção de Satélites para Aplicação

Semelhante ao aplicado na primeira sub-etapa do Módulo 01, tem-se que concernente à primeira sub-etapa referente à aquisição dos dados de precipitação, a partir de análise apurada na literatura recente, com uso da vanguarda científica, definiram-se os principais satélites citados e utilizados em estudos hidrológicos relativos à variável precipitação pluviométrica, a fim de que suas características sejam posteriormente avaliadas já partindo de uma pré-seleção filtrada com base em fundamentação bibliográfica, conforme apresentado no item “2.6. PRECIPITAÇÃO PLUVIOMÉTRICA POR SATÉLITE” do presente documento e corroborado com a Tabela 2, sendo os satélites apresentados posteriormente avaliados e detalhados acerca de seus critérios específicos nos itens que seguem, relacionados às características de cada um.

De início, portanto, tem-se a necessidade de, antes de adentrar no desenvolvimento da rotina computacional e posterior aplicação desta, realizar-se o processo de definição dos critérios iniciais de seleção de satélites para aplicação da rede. No que tange a estes critérios, eles foram necessários de modo a sistematizar o procedimento a fim de tornar célere e bem definida a escolha alternativas existentes. Assim, com base na literatura e nas características dos satélites estudados, definiram-se como critérios de seleção, os que seguem:

- Espaço Amostral Disponível;
- Provedor de Dados;
- Amplitude Geográfica;
- Resolução
- Banda e Unidade;
- Disponibilidade no GEE.

Dessa forma, a partir dos critérios em questão, definiu-se uma matriz de seleção para ranqueamento das alternativas com base nas respostas de cada parâmetro supracitado, para a consolidação da primeira etapa do Módulo 01 de estudo, apresenta-se na Tabela 6 a matriz modelo desenvolvida com satélites avaliados para posterior seleção do mais bem avaliado.

Tabela 6 – Matriz Modelo de Seleção de Satélites

Item	Satélite	Dispon. no GEE	Amplitude Geográfica	Espaço Amostral	Banda e Unidade	Resolução (metros)	Provedor de Dados	Ranking
1	NOAA CDR WHOI	Sim	Global	1988-01-01 2021-08-31	°C	27830 metros	NOAA	1
2	NOAA CDR OISST	Sim	Global	1979-01-01 2022-06-01	°C	27830 metros	NOAA	2
3	GCOM-C/SGLI L3	Sim	Global	2018-01-01 2020-06-28	°C	27830	GCOM	3
4	HYCOM	Sim	Global	1992-10-02 2023-05-08	°C	8905.6	NOPP	4

Fonte: Autor (2023).

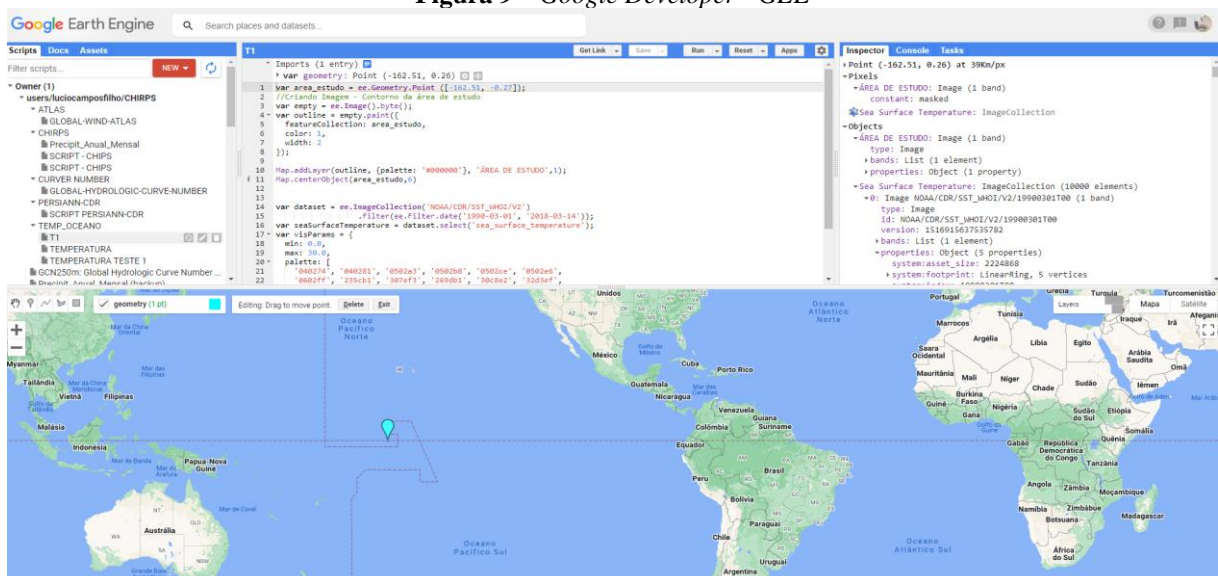
Para seleção da melhor alternativa, avaliaram-se os parâmetros da literatura bem como os critérios pré-definidos a fim de utilizar a mais adequada.

3.2.2. Rotina Computacional para Leitura de Temperaturas

No que tange ao desenvolvimento da rotina computacional para leituras de temperaturas da superfície do oceano, procedeu-se com a elaboração desta a partir da plataforma *Google Earth Engine - GEE*, em virtude das facilidades relativas à associação de dados de satélite com coordenadas geográficas do globo, do mesmo modo realizado com o Módulo 01 de aquisição de variáveis de precipitação.

Dessa forma, tomando-se como base o script desenvolvido para a captação dos vetores de precipitação, procedeu-se com a aquisição dos vetores de TSM. De modo a ilustrar o script gerado, tem-se na Figura 9 a evidênciação de parte deste desenvolvido na plataforma do *GEE* para aquisição dos dados de temperatura.

Figura 9 – Google Developer - GEE



Fonte: Autor (2023).

As etapas da rotina computacional consistiram em:

- Entrada de coordenadas geográficas (latitude e longitude em UTM);
- Aquisição de imagens de temperatura;
- Definição das propriedades da imagem com base na banda definida pelo satélite;
- Cálculo dos vetores de temperatura por hora;
- Cálculo dos vetores de temperatura diários;
- Cálculo dos vetores de temperatura mensais;
- Geração de Resultados.

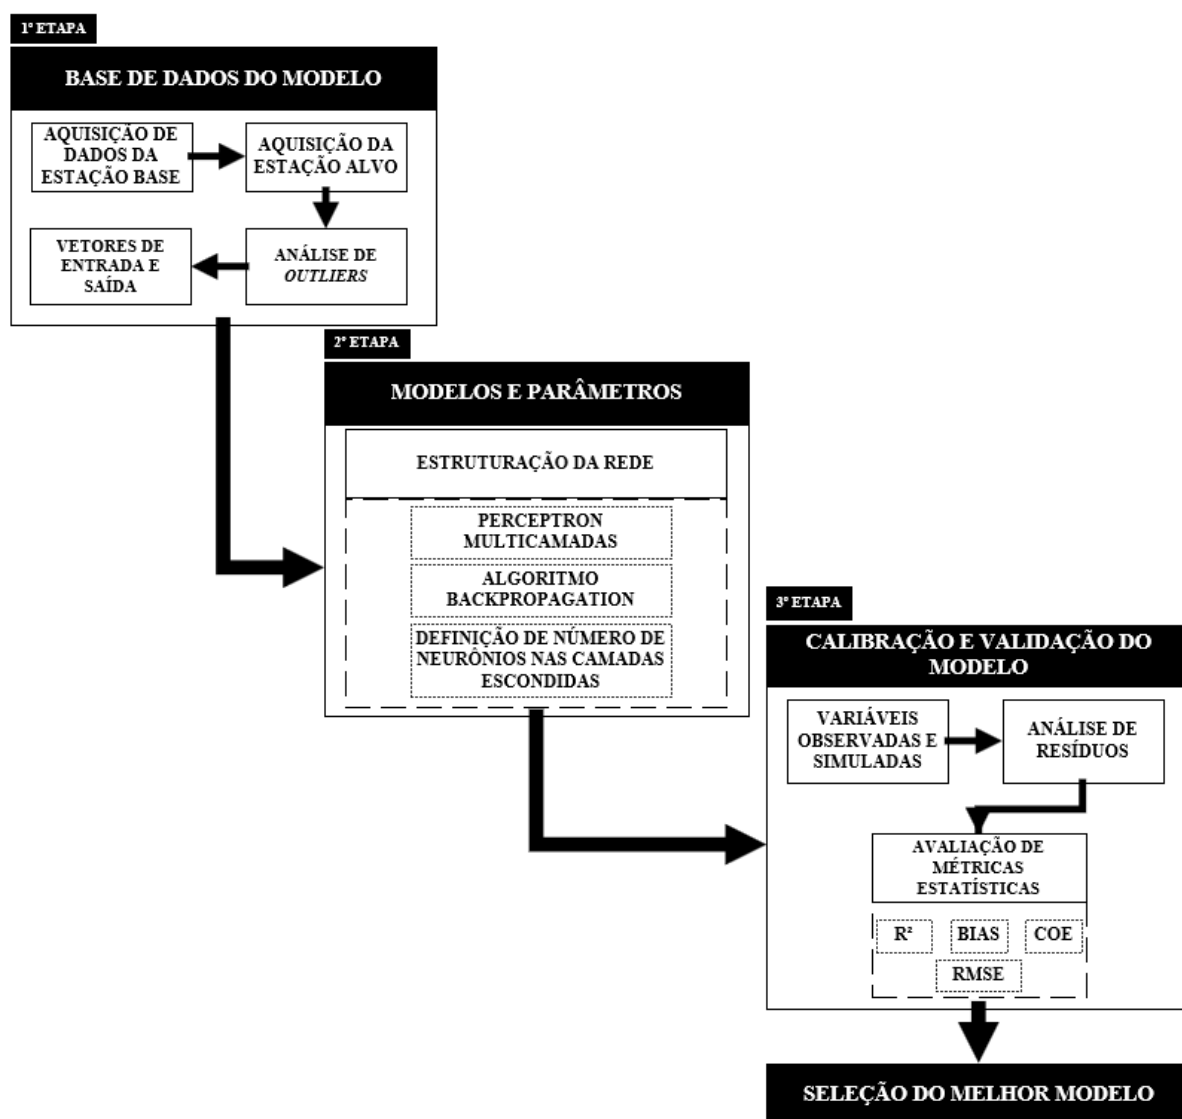
Destaca-se que as etapas em questão não foram detalhadas tendo em vista que se configuram como semelhantes às apresentadas anteriormente para o Módulo 01, sendo, portanto, efetuadas somente alterações no que tange às bandas utilizadas, bem como no cálculo dos vetores de variável em destaque (TSM).

3.3. MÓDULO 03: PREVISÃO DE NÍVEIS D'ÁGUA

O módulo referente ao desenvolvimento do modelo de previsão de níveis d'água consistiu na concepção, estruturação, calibração, validação e treinamento da rede neural artificial (RNA) do tipo *Multi-Layer Perceptron* (MLP), com algoritmos de treinamento do tipo *Backpropagation* (BP), que tem como *inputs* de dados os resultados de aquisição do Modelo 01 apresentado nos tópicos supracitados.

De modo a apresentar de forma detalhada os mecanismos adotados na presente etapa, desenvolveu-se o fluxograma da Figura 10, a fim de detalhar tais mecanismos.

Figura 10 - Fluxograma Metodológico do Módulo 03



Fonte: Autor (2023).

Sob a ótica da modelagem hidrológica e da utilização de modelos de previsão de nível d'água, modelos de Redes Neurais Artificiais – RNA tem sido utilizados com bastante sucesso

neste processo previsão, a partir de dados de precipitação, conjugados ou não com outras variáveis hidrológicas (FENG et al., 2020; REN et al., 2020). Nesse sentido, Modelos RNA tipo *Multi-Layer Perceptron* (MLP), com algoritmo *Backpropagation* (BP), vêm sendo cada vez mais utilizados na previsão de lâminas d'água a partir de dados de variáveis hidrológicas como precipitação, uma vez que esses modelos são adequados a simulações de variáveis com comportamento não lineares (KHAN et al., 2016; SUN; TREVOR, 2018).

Corroborando com o fluxograma apresentado na Figura 10 e com o contexto de importância supracitado, nos itens que seguem evidenciam-se os pormenores referentes às etapas de execução do Módulo 02 na presente pesquisa.

3.3.1. Base de Dados do Modelo

No presente tópico, abordou-se a base de dados do modelo no que tange à estruturação da RNA, de modo a ter-se o entendimento das variáveis de entrada do modelo e das nomenclaturas adotadas aos grupos de variáveis analisado.

Desse modo, antes de adentrar nos processos de aquisição de dados, deve-se conceituar os três grupos de variáveis principais adotados, sendo estes:

- **Estações Bases (EB's):** Tendo-se conhecimento teórico das influências diretas das oscilações de temperatura no Oceano nas variáveis hidrológicas na Amazônia, definiu-se, portanto, como variáveis base, seis vetores de temperatura superficial do mar (TSM) localizados em diferentes zonas de eventos ENOS, a fim de utilizar estas como vetores de entrada para posterior aquisição dos níveis d'água desejados.
- **Estações Intermediárias (EI's):** As Estações Intermediárias consistiram nas localizações utilizadas na superfície a qual dispõe de todos os dados necessários, isto é: Precipitação via Satélite e Precipitação *in situ* (ANA), sendo estas estações localizadas dentro da Bacia Hidrográfica analisada como estação alvo, definindo-se duas EI's: EI1 – Estação Próxima da Estação Alvo; EI2 – Estação Distante da Estação Alvo.
- **Estação Alvo (EA):** A Estação Alvo consistiu na localização em que se deseja prever os dados, tendo-se, portanto, somente dados de precipitação via satélite, visto que se trata de uma localização em que não se dispõe de dados de nível d'água, nem precipitação *in situ*, sendo este o maior diferencial do trabalho.

Conceituados os principais grupos de variáveis utilizados, pode-se apresentar a forma de aquisição de cada variável referente aos grupos em questão, tendo-se, então, estas apresentadas na Tabela 7 que segue.

Tabela 7 – Aquisição de Variáveis

Grupo	Variável	Sigla	Conceito	Aquisição
ESTAÇÕES BASE (EB)	Temperatura Superficial do Oceano no Ponto 01	TSM1	Configura-se como o ponto de TSM localizado na zona El Niño 3, sendo o ponto mais próximo da EA	Módulo 02 – Saída de Dados da segunda aplicação metodológica
	Temperatura Superficial do Oceano no Ponto 02	TSM2	Configura-se como o ponto de TSM localizado na zona El Niño 3.4, sendo um ponto intermediário	Módulo 02 – Saída de Dados da segunda aplicação metodológica
	Temperatura Superficial do Oceano no Ponto 03	TSM3	Configura-se como o ponto de TSM localizado na zona El Niño 3.4, sendo um ponto intermediário	Módulo 02 – Saída de Dados da segunda aplicação metodológica
	Temperatura Superficial do Oceano no Ponto 04	TSM4	Configura-se como o ponto de TSM localizado na zona El Niño 3.4, sendo um ponto intermediário	Módulo 02 – Saída de Dados da segunda aplicação metodológica
	Temperatura Superficial do Oceano no Ponto 05	TSM5	Configura-se como o ponto de TSM localizado na zona El Niño 4, sendo um ponto distante da EA	Módulo 02 – Saída de Dados da segunda aplicação metodológica
	Temperatura Superficial do Oceano no Ponto 06	TSM6	Configura-se como o ponto de TSM localizado na zona El Niño 4, sendo um ponto distante da EA	Módulo 02 – Saída de Dados da segunda aplicação metodológica
ESTAÇÕES INTERMEDIÁRIAS (EI)	Precipitação Satélite Estação Intermediária 01	PRI1	Configura-se como os valores de precipitação mensais obtidos via satélite na EI próxima de EA	Módulo 01 – Saída de Dados da primeira aplicação metodológica
	Precipitação Satélite Estação Intermediária 02	PRI2	Configura-se como os valores de precipitação mensais obtidos via satélite na EI distante de EA	Módulo 01 – Saída de Dados da primeira aplicação metodológica
ESTAÇÃO ALVO (EA)	Precipitação Satélite na EA	PREA	Configura-se como os valores de precipitação mensais obtidos por meio de medições com auxílio de pluviômetros na Estação Alvo	Módulo 01 – Saída de Dados da primeira aplicação metodológica
	Nível D'água Desejado	NACEA	Configuram-se como os valores de nível d'água que se deseja obter de maneira inferencial por intermédio da RNA.	Inicialmente, para treinamento da rede, a variável em questão foi calculada a partir de Ábaco para Correção de Sondagens das Cartas Náuticas, a fim de ter-se a Saída Desejada até a etapa de validação da RNA, sendo, posteriormente, um vetor de saída calculado pela RNA

Fonte: Autor (2023).

A partir das definições em questão, pode-se, então, apresentar de maneira consolidada as variáveis supracitadas como vetores de entrada e saída na Rede Neural Artificial, sendo definido, portanto, na Tabela 8.

Tabela 8 – Definição de Entradas e Saídas

Tipo de Variável	Variável
Variáveis de Entrada	Temperatura Superficial do Oceano no Ponto 01 – TSM1
	Temperatura Superficial do Oceano no Ponto 02 – TSM2
	Temperatura Superficial do Oceano no Ponto 03 – TSM3
	Temperatura Superficial do Oceano no Ponto 04 – TSM4
	Temperatura Superficial do Oceano no Ponto 05 – TSM5
	Temperatura Superficial do Oceano no Ponto 06 – TSM6
	Precipitação Satélite Estação Intermediária 01 – PRI1
	Precipitação Satélite Estação Intermediária 02 – PRI2
	Precipitação Satélite Estação Alvo - PREA
Variável de Saída	Nível D'água Desejado Estação Alvo - NACEA

Fonte: Autor (2023).

Em complementação, destaca-se que a estruturação da rede, no que tange às camadas escondidas e número de neurônios foi apresentada detalhadamente nos tópicos referentes ao estudo de caso, de modo a ser evidenciado posterior ao desenvolvimento metodológico completo, conforme segue.

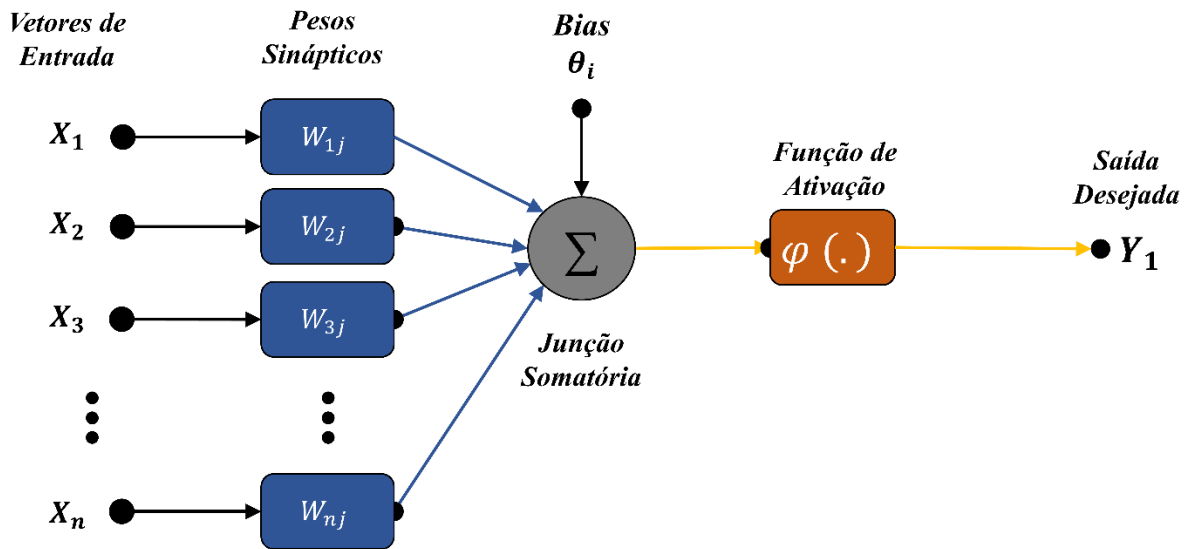
3.3.2. Modelos e Parâmetros

Para o entendimento da estruturação da rede e posterior aplicação desta, faz-se necessário apresentar tópicos-chaves relativos aos conceitos e tipo de RNA utilizada na presente pesquisa. Dessa forma, a seguir apresenta-se todo o procedimento matemático adotado na pesquisa no que tange à definição do modelo e de seus parâmetros.

3.3.2.1. Neurônio Artificial

Antes de adentrar nos modelos matemáticos que compreendem à aplicação da rede neural, faz-se necessária a apresentação da conceituação de neurônio artificial (também chamados de *Perceptrons*, *Units* ou *Nodes*) conforme a literatura como sendo os elementos mais simples ou blocos de construção em uma rede neural, inspirados em neurônios biológicos encontrados no cérebro humano, tendo como características básicas a adaptação e representação de conhecimentos baseados em conexões (BRENES; JOHANNSEN; CHUKHROVA, 2022; DYER; GRIFFIN, 2023; HUNASIGI et al., 2022). Em complementação a tal conceituação, destaca-se que estes neurônios se configuram em três elementos básicos para o processamento da rede neural: Sinapses (pesos sinápticos), Somador (junção somatória) e Função de ativação; sendo estes também explicitados detalhadamente a seguir e apresentados visualmente na Figura 11 baseada em Haykin (1999).

Figura 11 – Estruturação do Neurônio Artificial



Fonte: Adaptado de Haykin (1999).

De posse da estruturação apresentada, pode-se discutir acerca de cada item presente nesta. Acerca da conectividade entre a fonte do sinal e o neurônio, esta é estabelecida por meio de pesos sinápticos que amplificam, com a utilização de um fator de peso (w_{ij}), um sinal de entrada (x_i) vindo de entradas externas ou de outros neurônios, gerando uma conexão sináptica (ou peso sináptico - w_{ij}), sendo positivo se a sinapse pertinente for excitatória e negativo se ela for inibitória.

No que tange à junção somatória (r_j), esta configura-se como responsável pela execução do somatório dos sinais produzidos pelo produto entre os sinais de entrada (x_i) e os pesos de sinápticos (w_{ij}) de conexão de cada neurônio. Tal procedimento matemático encontra-se genericamente estruturado na Equação 5 que segue.

$$r_j = \sum_{i=1}^p w_{ij} \cdot x_i + \theta_j \quad (5)$$

Em que, é um θ_j (*bias*) aplicado externamente que tem o efeito de incrementar ou reduzir o sinal da junção somatória.

Em complementação, deve-se destacar a necessidade de aplicação de uma função de ativação no neurônio artificial, conforme apresentado na estruturação da Figura 11, sendo esta uma função que determina o nível de ativação do neurônio artificial, executando a limitação da amplitude do sinal de saída do neurônio em uma faixa de valores finitos definidos na faixa de [0 1], ou alternadamente [-1 1] e calculando o estímulo interno (ou nível de ativação) do neurônio e produzindo uma saída por intermédio de uma relação linear ou não linear. Dessa

forma, tendo por base uma função de ativação $\varphi()$, a saída do neurônio (y_j) pode ser calculada pela Equação 6.

$$y_j = \varphi \left(\sum_{i=1}^p w_{ij} \cdot x_i + \theta_j \right) \quad (6)$$

Em que:

$\varphi()$ é a função de ativação;

w_{ij} são os pesos de sinápticos;

x_i são os sinais de entrada; e

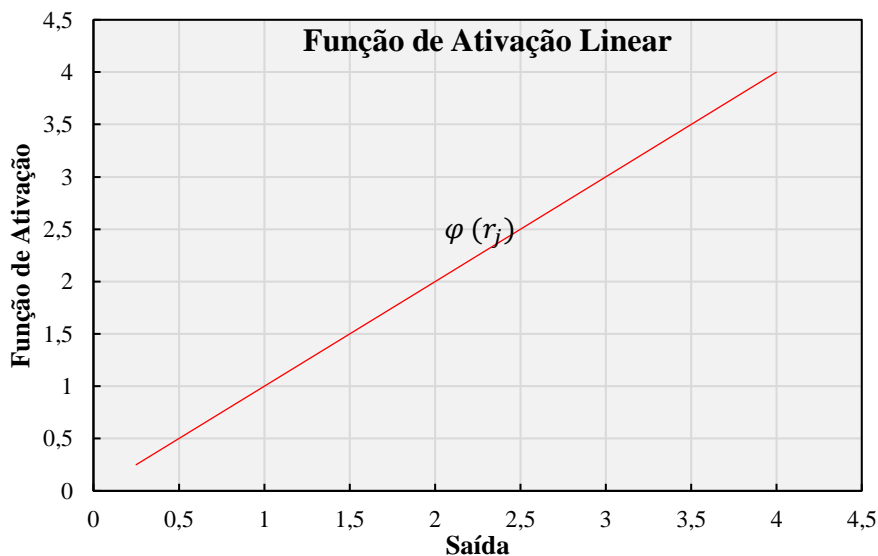
θ_j é um *bias* aplicado externamente.

Nesse sentido, no que diz respeito aos tipos principais de funções de ativação existentes, destaca-se uma abordagem extremamente vasta na literatura, visto que estas funções têm o papel fundamental de limitar a saída do neurônio e introduzir não linearidade no modelo. Corroborando com isto, apresentaram-se a seguir cinco tipos principais, de acordo com Haykin (1999):

i. Linear: Configura-se como a função de ativação mais básica, haja vista que não altera a saída de um neurônio. Geralmente é utilizada nas camadas de saída em redes neurais de regressão e tem sua definição matemática definida na Equação 7 e sua representação gráfica apresentada na Figura 12.

$$\varphi(r_j) = r_j \quad (7)$$

Figura 12 – Função de Ativação Linear

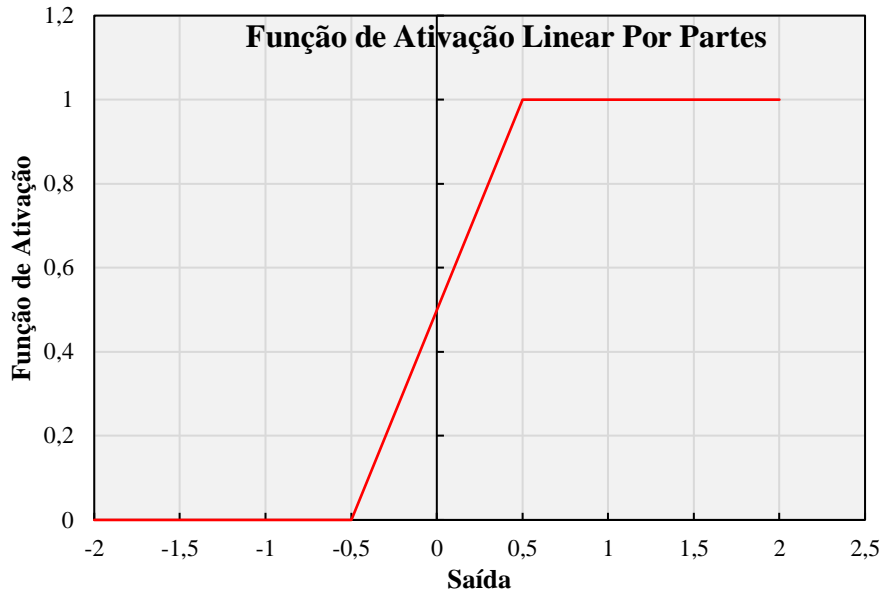


Fonte: Adaptado de Haykin (1999).

ii. **Linear Por Partes:** Tem-se esta como uma vertente da primeira apresentada, sendo definida pela Equação 8 e representada graficamente pela Figura 13.

$$\varphi(r_j) = \begin{cases} 1, & \text{se } r_j \geq 1/2 \\ r_j, & \text{se } 1/2 > r_j > -1/2 \\ 0, & \text{se } r_j \leq -1/2 \end{cases} \quad (8)$$

Figura 13 – Função de Ativação Linear por Partes

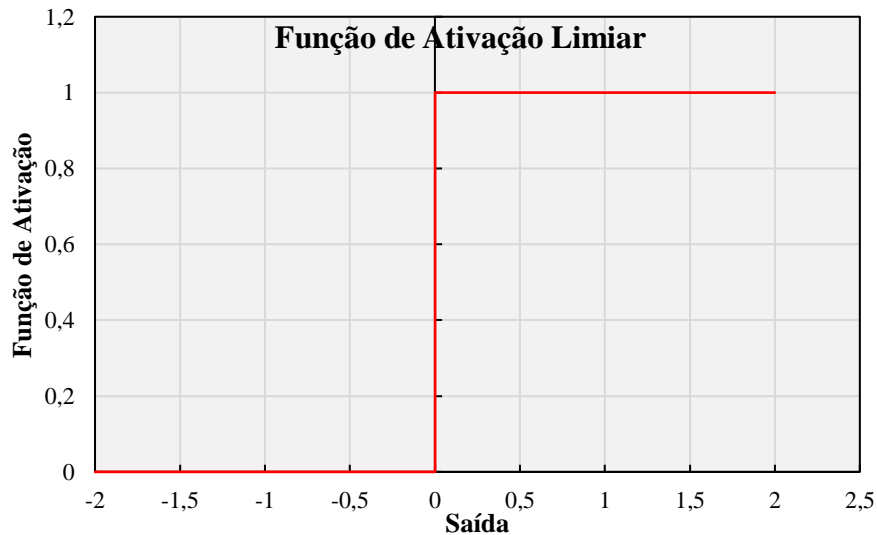


Fonte: Adaptado de Haykin (1999).

iii. **Limiar:** Trata-se da função de ativação com limite (denominada *Threshold*), sendo definida pela Equação 9 e representada graficamente pela Figura 14.

$$\varphi(r_j) = \begin{cases} 1, & \text{se } r_j \geq 0 \\ 0, & \text{se } r_j < 0 \end{cases} \quad (9)$$

Figura 14 – Função de Ativação Limiar



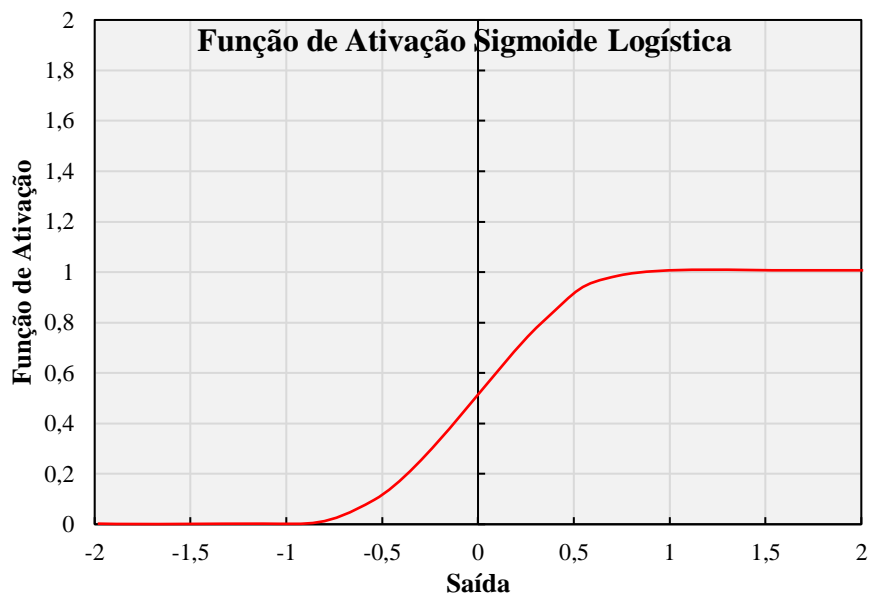
Fonte: Adaptado de Haykin (1999).

iv. Sigmoide Logística: A função de ativação *sigmoid* é comumente utilizada por redes neurais com propagação positiva (*Feedforward*) que precisam ter como saída apenas números positivos, em redes neurais multicamadas e em outras redes com sinais contínuo, sendo definida pela Equação 10 e representada graficamente pela Figura 15.

$$\varphi(r_j) = \frac{1}{1 + e^{-ar_j}} \quad (10)$$

Em que, a é o parâmetro de declive da função e r_j é a junção somatória. A saída está limitada ao intervalo $[-1 \ 1]$.

Figura 15 – Função de Ativação Sigmoide Logística



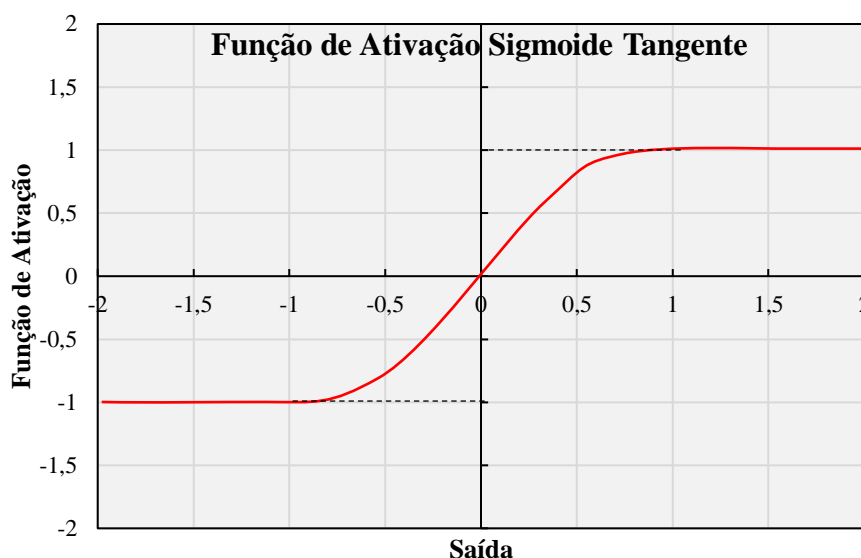
Fonte: Adaptado de Haykin (1999).

i. Sigmoide Tangente Hiperbólica: A função de ativação tangente hiperbólica possui uso muito comum em redes neurais cujas saídas devem ser entre -1 e 1, sendo definida pela Equação 11 e representada graficamente pela Figura 16.

$$\varphi(r_j) = \frac{1 - e^{-ar_j}}{1 + e^{-ar_j}} \quad (11)$$

Em que, a é o parâmetro de declive da função e r_j é a junção somatória. A saída está limitada ao intervalo $[-1 \ 1]$.

Figura 16 – Função de Ativação Sigmoide Tangente



Fonte: Adaptado de Haykin (1999).

De posse do entendimento supracitado acerca dos mecanismos e elementos fundamentais de uma Rede Neural Artificial, pode-se adentrar no conhecimento acerca do tipo específico do estudo em questão, configurado como sendo *Perceptron* de múltiplas camadas.

3.3.2.2. *Perceptron* Multicamadas – MLP

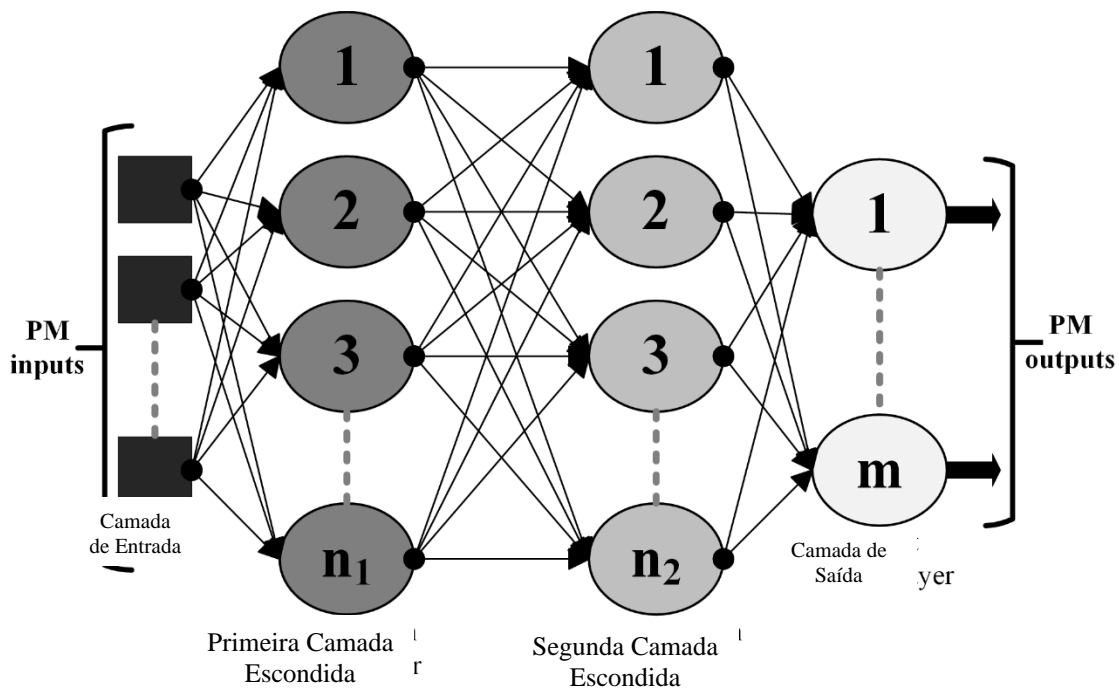
A partir do entendimento do neurônio artificial, pode-se adentrar no conhecimento acerca de *Perceptrons* de múltiplas camadas (MLP), sendo a rede neural mais comumente utilizada na literatura, apresentando como características um algoritmo de aprendizado supervisionado com retropropagação de erro (*backpropagation*), que é considerado um marco no desenvolvimento das redes neurais, sendo este algoritmo baseado na regra de aprendizagem por correção de erro.

A aprendizagem por retropropagação de erro consiste em dois passos por intermédio de diferentes camadas da rede, sendo: a propagação (que é um passo para frente) e a retropropagação (que é e um passo para trás).

As RNA do tipo MLP estão constituídas de três partes: a primeira parte é denominada camada de entrada (*input layer*), a qual é constituída de um conjunto de unidades sensoriais; a segunda parte é constituída de uma ou mais camadas escondidas (*hidden layers*); e a terceira parte é constituída de uma camada denominada camada de saída (*output layer*). Com exceção da camada de entrada, todas as outras camadas estão constituídas por neurônios, que implicam em um esforço computacional. Na Figura 17 observa-se uma ilustração para facilitar o

entendimento da estrutura de modelos de redes neurais artificiais do tipo *Perceptron*, com a evidenciação das entradas e saídas de dados, bem como das camadas da rede.

Figura 17 - Estruturação de Modelos de RNA do Tipo *Perceptron*



Fonte: Autor (2023).

Na Figura 17 evidenciou-se uma generalização da rede *Perceptron*, com a adição de uma ou mais camadas intermediárias, também conhecidas como camadas escondidas. Nesse sentido, de modo a detalhar as camadas apresentadas na imagem, define-se:

a) Camada de Entrada: Responsável pelo recebimento dos dados de entrada, sem a realização de processamentos e realizando apenas a distribuição das variáveis para a camada subsequente.

b) Camada Escondida: Camada em que os neurônios realizam o procedimento de processamento de dados a partir da aplicação de regras de propagação e funções de ativação, suas entradas e saídas permanecem dentro do sistema; e

c) Camada de Saída: Camada em que se recebe a resposta da rede no que tange à variável analisada.

A partir do entendimento metodológico da estruturação de uma Rede *Perceptron* Multicamadas (MLP) na Figura 17, com duas camadas escondidas, cada neurônio na camada escondida pode ser obtido por meio da Equação 12.

$$S_j = f \left(\sum_{i=1}^p w_{ij} \cdot x_i + \theta_j \right) \quad (12)$$

Em que:

x_i é a i-ésima entrada para a rede;

w_{ij} é o peso da conexão do neurônio de entrada para o neurônio escondido j;

θ_j é o bias do j-ésimo neurônio escondido; e

$f(\cdot)$ é a função de ativação do neurônio.

Para a RNA do tipo MLP da Figura 17, considerando a camada de saída, cada neurônio na camada de saída é obtido a partir da Equação 13.

$$y_k = g \left(\sum_{j=1}^m \beta_{kj} \cdot S_j + \theta_k \right) \quad (13)$$

Em que:

β_{kj} é o peso da conexão do neurônio escondido j com o neurônio de saída;

y_k é a k-ésima saída da rede k;

θ_k é o bias da k-ésima saída; e

$g(\cdot)$ é a função de ativação do neurônio.

Definidos os equacionamentos principais de uma rede do tipo MLP, necessita-se da definição do algoritmo de aprendizado utilizado, bem como suas propriedades matemáticas.

3.3.2.3. Aprendizado via Algoritmo de *Backpropagation*

Para implantação de uma RNA, necessita-se a definição de um processo de aprendizagem, sendo este de fundamental importância para aprimorar o desempenho desta, que ocorre a partir de uma medida de aprendizado preestabelecida com um processo iterativo de ajustes aplicados a pesos sinápticos e níveis de bias, sendo então o processo de aprendizagem responsável por uma sequência de eventos: a) A rede neural é estimulada por um ambiente; b) A rede neural sofre modificações nos seus parâmetros livres como resultado desta estimulação; e c) A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

Nesse sentido, dentre os algoritmos usados para executar aprendizado supervisionado, o *Backpropagation* emergiu como um algoritmo para treinamento de redes MLP amplamente utilizado pela literatura e com altas taxas de aceitação (ABRAHART; WHITE, 2001; HAYKIN, 1999; WANG et al., 2020), sendo este desenvolvido em duas fases:

- **Propagação** - Fluxo da informação da entrada para saída da rede: Ativação dos neurônios escondidos propagados para os neurônios de saída
- **Retropropagação** - Fluxo da informação da saída em direção dos neurônios escondidos: Erro propagado para trás e realização da atualização dos pesos.

A partir do entendimento da conceituação e dos princípios do algoritmo de aprendizado *Backpropagation*, pode-se, então, apresentar o desenvolvimento matemático deste.

Considerando a *perceptron* multicamadas da Figura 17, o sinal de erro na saída do neurônio na iteração é definido pela Equação 14.

$$e_j(n) = d_j(n) - y_j(n) \quad (14)$$

Em que:

j é o neurônio é um nó de saída;

$e_j(n)$ é o sinal do erro na saída do neurônio j para a iteração n ;

$d_j(n)$ refere-se a resposta desejada para o neurônio j ; e

$y_j(n)$ refere-se ao sinal funcional que aparece na saída do neurônio j na iteração n .

Com isto, formula-se o sinal funcional $y_j(n)$ que aparece na saída do neurônio j na iteração n , conforme Equação 15.

$$y_j(n) = g_j(v_j(n)) \quad (15)$$

Em que $v_j(n)$ é definido como o campo local induzido produzido na entrada da função de ativação associada ao neurônio, sendo definido pelas Equações 15 e 16.

$$v_j(n) = \sum_{i=1}^m w_{ij}(n) \cdot y_i(n) + \theta_j \quad (16)$$

O algoritmo *back-propagation* aplica, então, uma correção ao peso sináptico, sendo proporcional à derivada parcial dos erros quadráticos (Equação 4, denominado no presente tópico como E_n), conforme evidenciado a seguir dada pela Equação 17.

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (17)$$

Realizando-se os procedimentos matemáticos para solução da Equação 17, obtém-se a Equação 18 que segue.

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) g'_j(v_j(n)) y_j(n) \quad (18)$$

Aplica-se, então, a correção $\Delta w_{ji}(n)$ à $w_{ji}(n)$, conforme definido pela Equação 18 que segue.

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (19)$$

Em que, η é o parâmetro da taxa de aprendizagem do algoritmo de retropropagação, com o uso do sinal negativo indicando a descida do gradiente no espaço de pesos.

Aplica-se, então, o gradiente local do neurônio ($\delta_j(n)$) na iteração n , pela Equação 20.

$$\delta_j(n) = -\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -e_j(n) g'_j(v_j(n)) \quad (20)$$


De acordo com a Equação 20, pode-se definir o gradiente local ($\delta_j(n)$) do neurônio j na iteração n , para o neurônio oculto j por intermédio da Equação 21.

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial y_j(n)} g'_j(v_j(n)) \quad (21)$$

Em função da localização do neurônio na rede neural, ou seja, se esse neurônio é um nó de saída ou um nó oculto, dois distintos casos podem ocorrer:

- **Neurônio j sendo um nó de saída:** Este caso é simples de se tratar, porque cada nó de saída da rede é suprido com uma resposta desejada particular, fazendo com que o cálculo do sinal de erro associado seja direto. Neste caso, conforme evidenciado na Figura 18, o neurônio j é suprimido com uma resposta desejada particular, e, então, utiliza-se a Equação 14 para calcular o $e_j(n)$ associado ao neurônio.

Figura 18 – Fluxo de Sinal com Neurônio j sendo um nó de saída




Fonte: Haykin (1999).

- **Neurônio j sendo um nó oculto:** Apesar dos neurônios ocultos não serem acessíveis diretamente, eles compartilham a responsabilidade por qualquer erro cometido na saída

da rede. Assim quando o neurônio j está em uma camada escondida, conforme Figura 19, não existe uma resposta desejada para aquele neurônio. Então, o sinal do erro deve ser calculado recursivamente em termos dos sinais de erro de todos os demais neurônios.

Figura 19 – Fluxo de Sinal com Neurônio j sendo um nó oculto



Fonte: Haykin (1999).

A partir do entendimento das situações supracitadas, considerando o neurônio j como um nó oculto da rede, conforme Figura 19, e tendo por base a Equação 20, redefine-se o gradiente local para um neurônio oculto j , conforme evidenciado na Equação 21.

Considerando a camada de saída k da Figura 19, a soma dos erros quadráticos na iteração foi dada pela Equação 22.

$$E(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (22)$$

Assim, para o cálculo de $\frac{\partial e_j(n)}{\partial y_j(n)}$ utiliza-se a Equação 22, tendo-se, então, como resultado a Equação 23.

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k \frac{\partial E(n)}{\partial e_k(n)} \frac{\partial e_k(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (23)$$

Considerando o sinal funcional $y_k(n)$ da Equação 15 aplicado ao neurônio de saída na iteração k e tendo-se como referência o caso da Figura 19, observa-se o exposto na Equação 24 e Equação 24.1.

$$e_k(n) = d(n) - y_k(n) = d_k(n) - g_k(v_k(n)) \quad (24)$$

$$\frac{\partial e_k(n)}{\partial v_k(n)} = g'_k(v_k(n)) \quad (24.1)$$

Dessa forma, o campo local induzido $v_k(n)$ aplicado ao neurônio de saída na iteração k pode ser equacionado a partir da Equação 25 e derivado parcialmente conforme Equação 26.

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) \quad (25)$$

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (26)$$

Com a Equação 25 e Equação 26, substituem-se estas na Equação 23, obtendo-se o apresentado na Equação 27.

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) g'_k(v_k(n)) w_{kj}(n) = \sum_k \delta_k(n) w_{kj}(n) \quad (27)$$


Por fim, efetuando-se a substituição da Equação 27 na Equação 21, obtém-se a fórmula de retropropagação para o gradiente local do neurônio oculto na iteração j , por intermédio da Equação 28.

$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} g'_k(v_k(n)) = (v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (28)$$

Dessa forma, corroborando com o obtido na Equação 28, tem-se na

Figura 20 a evidenciação por grafo do fluxo de sinais da Equação 28, considerando que a camada de saída consista em neurônios m_L , sendo este o número de nós da camada l .

Figura 20 – Retropropagação dos sinais de erro



Fonte: Haykin (1999).

Assim, destaca-se que segundo Haykin (1999), o aprendizado da rede resulta de muitas apresentações de um determinado conjunto de exemplos de treinamento para o *perceptron* de

múltiplas camadas. A apresentação completa do conjunto de treinamento inteiro é denominada uma época. O processo de aprendizagem é mantido em uma base de época em época até que os pesos sinápticos e os níveis de bias se estabilizarem e o erro médio quadrado sobre todo o conjunto de treinamento venha a convergir para um valor mínimo. É usual tornar aleatória a ordem de apresentação dos exemplos de treinamento, de uma época para a seguinte.

A aprendizagem por retropropagação, para um mesmo conjunto de treinamento, pode dar-se de dois modos (HAYKIN, 1999):

a) Modo Sequencial: onde a atualização do peso é realizada após a apresentação de cada padrão de treinamento (exemplo), requerendo menos memória;

b) Modo por Lote: onde a atualização do peso é realizada após a apresentação de todos os padrões de treinamento que constituem uma época, requerendo mais memória.

Em complementação, acerca do valor da taxa de aprendizado, destaca-se que quanto menor esta for, menores serão as variações dos pesos sinápticos de uma iteração para outra, tornando mais suave a trajetória no espaço dos pesos. Ao passo que quanto maior esta taxa for, maiores serão as variações dos pesos sinápticos, fato este que torna a rede instável.

E, por fim, sobre o critério de parada, este pode ser definido de três formas principais, sendo estas:

- Número de ciclos de treinamento: onde o treinamento termina após a execução de um dado número de ciclos ou épocas de treinamento;
- Valor do erro: onde o treinamento termina quando valor do erro é menor ou igual a um dado valor previamente definido;
- Critério de validação: onde o treinamento termina quando o erro, no conjunto de validação, para de decrescer.

O processo de obtenção das previsões de lâmina d'água foi feito, portanto, por intermédio de um modelo RNA tipo Multi-Layer Perceptron (MLP) com a utilização do algoritmo Backpropagation (MLP-BP). A operacionalização da metodologia RNA foi feita com a utilização de algoritmos e funções implementados no software MATLAB® - 2014b, que é uma linguagem de alto nível e um ambiente interativo para computação e programação, desenvolvida pela MathWorks.

A discussão acerca das entradas e saídas, bem como número de modelos, camadas escondidas e neurônios utilizada fora apresentada no tópico de Estudo de Caso, na sequência do tópico de Materiais e Métodos.

3.3.2.4. Rede Neural Recorrente e LSTM

Redes Neurais Recorrentes (RNNs) são arquiteturas de aprendizado de máquina que têm a capacidade de lidar com dados sequenciais, como texto, áudio e séries temporais. Diferentemente das redes neurais convencionais, as RNNs possuem conexões recorrentes que permitem a propagação de informações ao longo do tempo, o que as torna adequadas para modelar dependências de longo prazo.

Seja uma sequência de entrada $x = (x_1, x_2, \dots, x_t)$, onde x_t é o vetor de entrada na etapa de tempo t . O objetivo das RNNs é prever uma sequência de saída $y = (y_1, y_2, \dots, y_t)$, em que y_t é o vetor de saída correspondente à etapa de tempo t .

Em uma RNN básica, a saída em cada etapa de tempo é calculada da forma apresentada na Equação 29 e Equação 30 que seguem.

$$h_t = f(W_{hx}x_t + W_{hh}h_{t-1} + b_h) \quad (29)$$

$$y_t = g(W_{yh} h_t + b_y) \quad (30)$$

Em que:

h_t é o estado oculto na etapa de tempo t , que representa a representação intermediária da sequência até aquele ponto.

W_{hx} é a matriz de pesos que transforma a entrada x_t no espaço oculto.

W_{hh} é a matriz de pesos que transforma o estado oculto anterior h_{t-1} no espaço oculto atual.

b_h é o viés associado ao estado oculto.

W_{yh} é a matriz de pesos que transforma o estado oculto em uma saída.

b_y é o viés associado à saída.

f é uma função de ativação aplicada ao estado oculto, como a função tangente hiperbólica (tanh) ou a função sigmoideal.

g é uma função de ativação aplicada à saída, dependendo do problema em questão.

Embora as RNNs tenham a capacidade de modelar dependências de longo prazo, elas sofrem do problema do desaparecimento do gradiente, no qual o gradiente usado para atualizar os pesos diminui exponencialmente à medida que se propaga para trás no tempo durante o treinamento. Isso dificulta a captura de dependências de longo prazo em sequências de dados.

Para contornar esse problema, a arquitetura *Long Short Term Memory* (LSTM) foi proposta. O LSTM introduz uma unidade de memória interna que permite armazenar e recuperar informações relevantes ao longo de várias etapas de tempo. A unidade de memória é atualizada usando portões adaptativos, que controlam o fluxo de informações para dentro e para fora da memória.

A unidade de memória LSTM é composta por três vetores principais: o vetor de entrada (i_t), o vetor de esquecimento (f_t) e o vetor de saída (o_t). Esses vetores são calculados, respectivamente, conforme Equação 31, Equação 32 e Equação 33.

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (31)$$

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (32)$$

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (33)$$

Em que:

σ é a função sigmoideal.

i_t é o vetor de ativação do portão de entrada, que controla quais valores da entrada devem ser atualizados na memória.

f_t é o vetor de ativação do portão de esquecimento, que controla quais valores da memória devem ser mantidos ou esquecidos.

o_t é o vetor de ativação do portão de saída, que controla quais valores da memória serão usados para calcular a saída atual.

A memória interna de uma unidade LSTM é atualizada conforme Equação 34.

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{cx}x_t + W_{ch}h_{t-1} + b_c) \quad (34)$$

Em que:

c_t é o estado da memória atualizado.

\odot denota a multiplicação elemento por elemento.

O estado oculto atualizado de uma unidade LSTM é calculado pela Equação 35.

$$h_t = o_t \odot \tanh(c_t) \quad (35)$$

A saída em cada etapa de tempo é obtida pela transformação do estado oculto atualizado, conforme apresentado na Equação 36.

$$y_t = g(W_{yh}h_t + b_y) \quad (36)$$

Essas equações descrevem o funcionamento básico de uma unidade LSTM em uma RNN. Essa arquitetura especializada permite capturar dependências de longo prazo em sequências de dados, tornando-a extremamente útil em várias aplicações, como processamento de linguagem natural, reconhecimento de fala e previsão de séries temporais

A partir do entendimento matemático de uma RNN com unidade LSTM, faz-se necessária a diferenciação entre uma Rede Neural Recorrente (RNN) e uma Rede Neural Feed-forward (ou MLP - *Multilayer Perceptron*). São dois tipos diferentes de arquiteturas de redes neurais que têm propósitos e características distintas:

i. Estrutura de Conexão:

- RNN: As RNNs possuem conexões recorrentes, ou seja, os neurônios estão interconectados em uma estrutura de ciclo, permitindo que informações fluam ao longo do tempo. Cada neurônio recebe entradas não apenas das camadas anteriores, mas também do próprio neurônio em etapas de tempo anteriores.
- MLP: As MLPs têm conexões diretas, ou seja, as informações fluem apenas em uma direção, da camada de entrada para a camada de saída. Não há ciclos ou conexões retroativas nas camadas ocultas.

ii. Processamento Sequencial:


- RNN: As RNNs são adequadas para processar dados sequenciais, onde a ordem e a dependência temporal das entradas são importantes. Elas mantêm uma memória interna que permite capturar informações contextuais ao longo do tempo.
- MLP: As MLPs não são projetadas para processar dados sequenciais. Elas tratam cada exemplo de entrada de forma independente e não possuem memória interna para lembrar de informações anteriores.

iii. Uso de Contexto:

- RNN: As RNNs são especialmente úteis em tarefas que requerem o uso de contexto, como tradução de idiomas, reconhecimento de fala e previsão de séries temporais. Elas são capazes de modelar dependências de longo prazo em sequências de dados.
- MLP: As MLPs são mais adequadas para problemas em que a ordem das entradas não importa e onde não há dependência temporal. Elas são amplamente utilizadas em tarefas de classificação e regressão, onde cada exemplo de entrada é tratado independentemente.

Em resumo, as RNNs são projetadas para lidar com dados sequenciais e capturar dependências de longo prazo ao longo do tempo, enquanto as MLPs são redes neurais feed-forward que processam exemplos de entrada independentemente e não possuem memória interna para informações contextuais sequenciais. Cada arquitetura é mais adequada para diferentes tipos de problemas e tipos de dados. De modo a consolidar este entendimento, tem-se a estruturação de ambas apresentado na Figura 21.

Figura 21 – RNN x MLP



Fonte: Autor (2023).

3.3.3. Treinamento, Calibração e Validação do Modelo

O processo de treinamento das RNA foi realizado utilizando-se o método da validação cruzada, em consonância com Haykin (1999), fazendo-se uso de um conjunto de dados independente para determinar o ponto de parada ótimo durante o treinamento, de forma a minimizar especialmente os riscos de super ajustamento.

O conjunto de dados foi dividido em três subconjuntos independentes, isto é, um conjunto para ajustar os pesos durante o treinamento, um conjunto para a validação e um conjunto para a verificação ou teste.

Em complementação, destaca-se que a fim de reduzir a redundância e o esforço computacional, e aumentar a integridade de dados e o desempenho, foi realizada a normalização dos dados de entrada, sendo uma prática realizada para evitar que o algoritmo fique enviesado para as variáveis com maior ordem de grandeza. A normalização *MaxScaler* foi aplicada a partir da formulação definida na Equação 37.

$$\overline{X}_n = \frac{X_n}{X_{\max}} \quad (37)$$

Em que:

\overline{X}_n é o valor da variável normalizada;

X_n é o valor real da variável; e

X_{\max} é o maior valor entre o conjunto de dados analisado.

Portanto, no presente trabalho as RNA foram treinadas e validadas com valores normalizados, foi adotado o intervalo como valor mínimo e valor máximo da escala de normalização utilizada.

Acerca da calibração e validação do modelo das RNA desenvolvidas, estas foram realizadas a partir determinação dos valores do Coeficiente de determinação (R^2) e a raiz do erro quadrado médio (RMSE), com estas métricas sendo totalmente definidas no que tange às suas formulações e conceituações no tópico 3.1.3. Calibração de Medições de Precipitação In Situ do presente trabalho.

O coeficiente de determinação R^2 mede a qualidade do modelo de RNA em relação à sua capacidade de estimar corretamente valores da variável resposta de Lâmina D'água (LA), indicando quanto da variância de é explicada pela variância de LA. Quanto mais preciso for o modelo, mais próximo de 1 deverá ser o valor de R^2 .

O RMSE é uma indicação do quanto as lâminas d'água simuladas por cada modelo de RNA variam em relação às lâminas de referência (LA), onde quanto mais próximo de zero, maior é a qualidade das lâminas simuladas pela RNA.

3.3.4. Seleção do Melhor Modelo

Assim, a partir dos procedimentos metodológicos supracitados, selecionou-se o melhor modelo em termos de número de camadas escondidas e neurônios a partir da avaliação da estrutura que teve maiores valores de R^2 e menores valores de RMSE, gravando-se a RNA com os parâmetros da rede e do modelo em termos de pesos sinápticos para posterior geração dos dados de previsão.

Os modelos de redes neurais possuem dois tipos de parâmetros: os parâmetros comuns, que são otimizados automaticamente durante o treinamento do modelo, e os hiperparâmetros, que são ajustados manualmente pelo usuário. Os hiperparâmetros incluem fatores como a quantidade de camadas ocultas, o número de neurônios em cada camada oculta, o número de épocas, o tamanho do lote (*batch size*) e a taxa de aprendizagem, não havendo um padrão de valor específico para todos os problemas envolvendo aprendizagem de máquina (LUO, 2016).

Nesse contexto, foi necessário implementar um mecanismo automatizado para buscar os melhores hiperparâmetros para os modelos de rede neural. Para isso, desenvolveu-se um *loop* no script desenvolvido em *Python*, que treinou as redes em 20 combinações diferentes, variando o número de neurônios, nas camadas existentes, de 1 a 20.

Inicialmente, o objetivo foi identificar a melhor arquitetura de rede neural para obter os melhores resultados. Para isso, realizaram-se testes comparando dois tipos diferentes de arquitetura neural usando o conjunto de dados das variáveis de entrada e saída. Dividiram-se os dados em uma proporção de 90% para treinamento e 10% para testes, seguindo uma prática comum para avaliar o desempenho do modelo em dados não vistos durante o treinamento, permitindo uma avaliação mais realista da capacidade de generalização.

Conforme apresentando no que tange aos seus procedimentos metodológicos, a primeira arquitetura avaliada foi a *Perceptron* multicamadas, que consiste em uma única camada de neurônios artificiais, chamados *perceptrons*, que recebem entradas ponderadas e aplicam uma função de ativação, gerando uma saída. Para investigar o desempenho da *Perceptron*, realizou-se um loop de treinamento com parâmetros fixos, incluindo 1000 épocas de treinamento, uma taxa de aprendizagem de 0.01 e um tamanho do lote de 32.

Durante o *loop* de treinamento, testaram-se três funções de ativação diferentes: *relu*, *sigmoid* e seno, com o objetivo de identificar a melhor função de ativação e a quantidade ideal de neurônios para obter o melhor desempenho do Perceptron. Após realizar uma busca sistemática, encontrou-se o melhor resultado com a função de ativação *sigmoid*, utilizando 18 neurônios, alcançando menores valores de RMSE quando avaliado no conjunto de teste, com características da rede definidas conforme segue exposto na Tabela 9.

Tabela 9 – Hiperparâmetros do Melhor Modelo – RNA Perceptron
Melhor Modelo RNA - Perceptron

Hiperparâmetro	Valor
Função de Ativação	Sigmoid
Nº de neurônios	18
Épocas	1000
Taxa de aprendizagem	0.01
batch size	32

Fonte: Autor (2023).

Em complementação, no que tange à outra arquitetura chamada Recorrente *Long Short Term Memory (LSTM)*, esta é capaz de aprender e lembrar informações de longo prazo, tornando-a eficaz para problemas que envolvem dados sequenciais, como uma série histórica.

Ao contrário da arquitetura *Perceptron*, a rede neural recorrente LSTM possuiu três camadas ocultas e para determinação da melhor quantidade de neurônios para cada uma dessas camadas, utilizou-se de um loop de treinamento e avaliação. Durante o loop, mantiveram-se os valores da taxa de aprendizagem, número de épocas e tamanho do lote (*batch size*) fixos em

0.01, 1000 e 32, respectivamente. Esses valores foram escolhidos com base em experimentações anteriores e conhecimento do problema.

Após treinar a rede LSTM com diferentes quantidades de neurônios nas camadas ocultas, avaliou-se seu desempenho usando os 10% dos dados de teste reservados anteriormente no que tange às métricas estatísticas pré-definidas. A análise sistemática permitiu identificar a quantidade de neurônios que melhor se ajustava ao problema e fornecia resultados mais precisos na previsão dos dados de teste. A otimização dos hiperparâmetros (Tabela 10) tornou possível a obtenção de melhores desempenhos da rede LSTM, maximizando a capacidade de modelagem e entendimento da estrutura temporal dos dados.

Tabela 10 – Hiperparâmetros do Melhor Modelo – RNA Recorrente LSTM
Melhor Modelo RNA - Recorrente LSTM

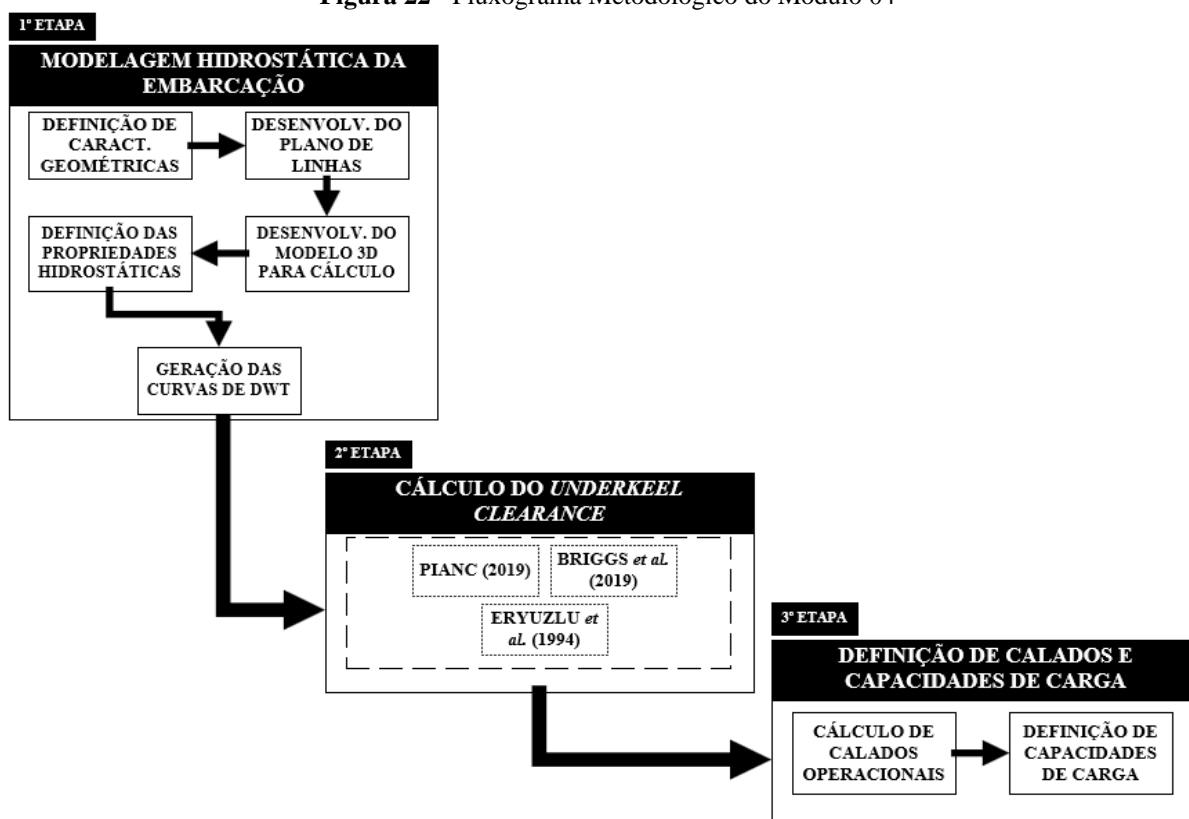
Hiperparâmetro	Valor
Nº de neurônios	200
Épocas	1000
Taxa de aprendizagem	0.01
batch size	32

Fonte: Autor (2023).

3.4. MÓDULO 04: CÁLCULO DE CALADOS OPERACIONAIS E CAPACIDADES DE CARGA

A partir do cálculo de níveis d'água realizado por intermédio da rede neural artificial desenvolvida, procedeu-se à aplicação do Módulo 04 relativo ao cálculo de calados operacionais e capacidades de carga realizados a partir da modelagem hidrostática da embarcação tipo e posterior cálculo do pé de piloto, sendo, então, possível a obtenção das variáveis desejadas. Estas etapas descritas simplificadaamente encontram-se apresentadas no fluxograma detalhado na Figura 22.

Figura 22 - Fluxograma Metodológico do Módulo 04



Fonte: Autor (2023).

De modo a detalhar as etapas supramencionadas, tem-se os tópicos que seguem apresentando as discussões acerca de cada sub-etapa metodológica referente ao Módulo 04.

3.4.1. Modelagem Hidrostática da Embarcação Tipo

A partir da modelagem da embarcação com base no plano de linhas e no arranjo tridimensional, faz-se possível a determinação das propriedades hidrostáticas da embarcação projetada. Estas propriedades, por sua vez, são fundamentais para determinação do comportamento da embarcação do ponto de vista hidrostático em função do calado da embarcação, sendo úteis para determinação de planos de carregamento, movimentação de pesos

a bordo e estudos de estabilidade (BARRASS; DERRETT, 2012a; BIRAN; LÓPEZ-PULIDO, 2014a; TUPPER, 2013).

▪ **Posição longitudinal do centro de carena (LCB)**

Inicialmente, tem-se como primeira propriedade hidrostática calculada a Posição longitudinal do centro de carena (LCB), que se configura como o ponto onde está sendo aplicado a força do empuxo e é igual ao centro geométrico do volume submerso, calculado de acordo com a Equação 38 (BARRASS; DERRETT, 2012a).

$$LCB = \frac{\frac{1}{3} \cdot h (A_1 \cdot x_1 + 4 \cdot A_2 \cdot x_2 + 2 \cdot A_3 \cdot x_3 + 4 \cdot A_4 \cdot x_4 + \dots + 4 \cdot A_{(n-1)} \cdot x_{(n-1)} + A_n \cdot x_n)}{\nabla} \quad (38)$$

Em que:

h representa o espaçamento entre as balizas;

A_n é a área da baliza submersa;

x_n é a distância da baliza n para um eixo de referência; e

∇ representa o volume deslocado.

▪ **Posição longitudinal do centro de flutuação (LCF)**

No que tange ao posição longitudinal do centro de flutuação (LCF), que se refere à posição do centroide da área do plano de flutuação, esta foi calculada pelo momento da área de flutuação em torno do eixo transversal (M_x) dividido pela área de flutuação (A_w), com as equações destas variáveis apresentada nas Equações 39 e 40.

$$M_x = 2 \int_a^b xy \, dx \approx 2 \cdot \left(\sum_{i=n_1}^{n_2} \alpha_i j_i y_i \right) \delta L^2 \quad (39)$$

$$A_w = 2 \int_a^b y \, dx \approx 2 \cdot \left(\sum_{i=n_1}^{n_2} \alpha_i y_i \right) \delta L \quad (40)$$

Portanto, a partir da definição da posição longitudinal do plano de flutuação e combinando as Equações 39 e 40, o LCF é definido pela Equação 41 (BIRAN; LÓPEZ-PULIDO, 2014b).

$$LCF = \frac{M_x}{A_w} = \frac{\left(\sum_{i=n_1}^{n_2} \alpha_i j_i y_i \right)}{\left(\sum_{i=n_1}^{n_2} \alpha_i y_i \right)} \delta L \quad (41)$$

Em que:

S é a área;

ρ é a densidade da água;

g é a gravidade;

∇ é o volume submerso;

I_L é a inércia longitudinal;

I_T é a inércia transversal;

L é o comprimento da embarcação;

T é o calado da embarcação;

A_{WL} é a área do plano de flutuação.

▪ **Momento para trimar um centímetro (MCT)**

No que tange ao cálculo do momento para trimar um centímetro (MCT), que representa o momento necessário para alterar o calado em uma seção do navio (BIRAN; LÓPEZ-PULIDO, 2014a), este encontra-se apresentado na Equação 42.

$$M_{CT} = \frac{\Delta \cdot GM_L}{100 \cdot L_{PP}} \quad (42)$$

Em que:

Δ representa o deslocamento da embarcação;

GM_L refere-se ao raio metacêntrico longitudinal;

L_{pp} é o comprimento entre perpendiculares da embarcação.

Dessa forma, considerando que uma pequena variação no calado gera uma grande variação na quantidade de carga transportada, esse parâmetro hidrostático viabiliza saber quanto de carga aquela embarcação suporta considerando uma variação no calado de um centímetro.

▪ **Demais propriedades hidrostáticas**

A partir das formulações supracitadas, as demais propriedades foram obtidas a partir da utilização das formulações dispostas nas Equações 43, 44 e 45, referentes, respectivamente, ao cálculo do deslocamento, raio metacêntrico transversal e posição vertical do centro de carena.

$$\Delta = \rho g \nabla \quad (43)$$

$$BM_L = \frac{I_L}{\nabla} = \frac{I_T}{3} \quad (44)$$

$$KB = \frac{\int_0^T T \cdot A_{WL} dT}{\int_0^T A_{WL} dT} \quad (45)$$

Em que:

S é a área;

ρ é a densidade da água;

g é a gravidade;

∇ é o volume submerso;

I_L é a inércia longitudinal;

I_T é a inércia transversal;

L é o comprimento da embarcação,

T é o calado da embarcação;

A_{WL} é a área do plano de flutuação.

▪ **Porte Bruto – Capacidade de Carga**

Com base nos cálculos das propriedades hidrostáticas descritas, faz-se possível o cálculo das capacidades de carga para uma dada condição de carregamento. Para o cálculo das capacidades de carga, subtrai-se o valor do deslocamento com o do Peso Leve (LWT). Adland *et al.* (2018) afirma que o *Deadweight* (DWT) de uma embarcação caracteriza-se como a capacidade máxima de carga da embarcação sob Regulamentos internacionais. A Equação 46 evidencia a forma de cálculo da capacidade de carga da embarcação para um determinado calado.

$$DWT = \left[\rho \left(\int_{-L/2}^{L/2} f(x) dx \right) \right] - LWT \quad (46)$$

Em que:

$f(x)$ é a curva de área de cada baliza;

dx é uma distância longitudinal infinitesimal.

3.4.2. Dimensões Verticais - *Underkeel clearance* e *Efeito SQUAT*

No cálculo das dimensões verticais de canais de navegação e hidrovias de navegação interior, a profundidade necessária para navegação segura é dependente de fatores intrínsecos à embarcação e de fatores dependentes do local de navegação. Estes fatores encontram-se relacionados às variáveis de efeito *Squat*, calado dinâmico, efeito de ondas, correntes, ventos, condições de fundo e outros (BRIGGS *et al.*, 2018).

Para o cálculo das profundidades necessárias para a navegação segura do estudo de caso, consideraram-se os valores de calado disponível para cada situação mensal de lâmina d'água prevista, com as considerações de folga (*Under Keel Clearance*) sendo dependentes do efeito *Squat* e dos demais efeitos.

Quando a embarcação encontra-se em águas rasas, o UKC é a permissão líquida mínima (diferença entre a profundidade da água no navio e o calado dinâmico) de profundidade da água capaz de possibilitar uma navegação segura (BARRASS; DERRETT, 2012a; BRIGGS *et al.*, 2013; INLAND NAVIGATION COMMISSION; WORKING GROUP 141; WORLD ASSOCIATION FOR WATERBORNE TRANSPORT INFRASTRUCTURE, 2019; LI; LIU; LIU, 2017).

A *World Association for Waterborne Transport Infrastructure – PIANC*, no InCom WG 141: *Design Guidelines for Waterway Dimensions* (INLAND NAVIGATION COMMISSION; WORKING GROUP 141; WORLD ASSOCIATION FOR WATERBORNE TRANSPORT INFRASTRUCTURE, 2019), apresentam sugestões para considerações das folgas do UKC de acordo com algumas variáveis relacionadas às correntes, ventos, tipo de fundo e tipo de propulsão. (INLAND NAVIGATION COMMISSION; WORKING GROUP 141; WORLD ASSOCIATION FOR WATERBORNE TRANSPORT INFRASTRUCTURE, 2019) afirmam que a diminuição da razão profundidade/draught, a velocidade da embarcação diminui, o que, eventualmente, leva a necessidade de larguras extras maiores, fato este que leva a consideração de um mínimo de 0,2 metros de folga, somados às demais folgas intrínsecas a via analisada. Para garantir que os propulsores de proa ou os lemes duplos sejam totalmente eficazes, (INLAND NAVIGATION COMMISSION; WORKING GROUP 141; WORLD ASSOCIATION FOR WATERBORNE TRANSPORT INFRASTRUCTURE, 2019) sugerem a adição de uma folga de 0,4 m para rochas sólidas no fundo do rio e 0,5 m para fundo de cascalho.

Com relação às folgas de condições de efeito *squat*, a literatura em Briggs *et al.*(2018) indica a existência de formulações baseadas em simulação para a obtenção dos valores deste efeito para determinação do *under keel clearance* (UKC). Briggs *et al.*(2018, 2013) indicam a existência de restrições para as formulações de acordo com a configurações do canal, com base em PIANC (2014).

Com base nas características do estudo de caso, utilizou-se a metodologia de cálculo evidenciada em Eryuzlu *et al.*(1994) para o cálculo das condições de efeito *Squat*. Válida para canais irrestritos e restritos, com CB ≥ 0.8 , B/T de 2.4 até 2.9, e Lpp/B de 6.7 até 6.8. A Equação 47 evidencia a forma de cálculo do efeito *Squat* (S_b) descrita em Eryuzlu *et al.*(1994).

$$S_b = 0.298 K_B \frac{h^2}{T} \left(\frac{V_S}{\sqrt{gT}} \right)^{2.289} \left(\frac{h}{T} \right)^{-2.972} \quad (47)$$

O fator de correção K_B foi calculado com base na Equação 48.

$$K_B = \begin{cases} \frac{3.1}{\sqrt{W/B}} & \text{para } \frac{W}{B} < 9.61 \\ 1 & \text{para } \frac{W}{B} \geq 9.61 \end{cases} \quad (48)$$

Em que:

K_B é um fator de correção para a largura do canal W em relação à boca (B);

T é o pontal;

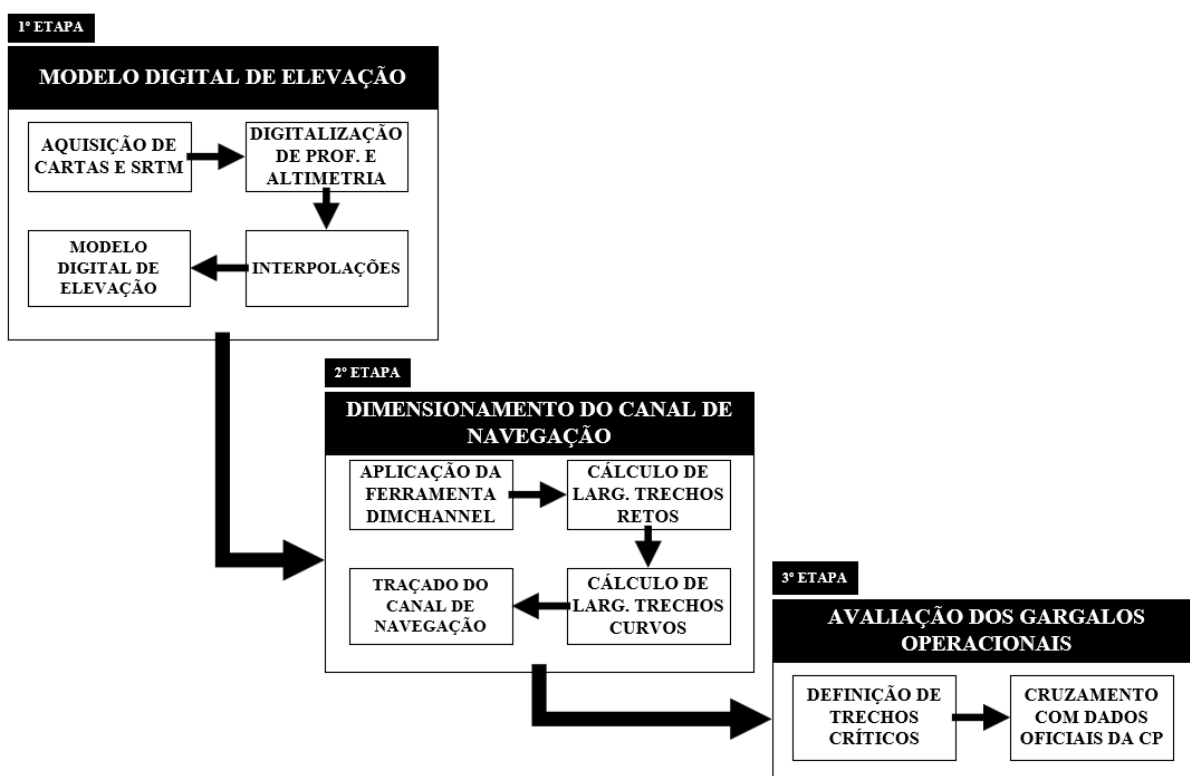
H é a profundidade do canal;

V_S é a velocidade da embarcação; e g é a aceleração da gravidade.

3.5. MÓDULO 05: MODELO DE DEFINIÇÃO DE CONDIÇÕES PLANIALTIMÉTRICAS

A partir do cálculo das propriedades geométricas do canal de navegação para a embarcação de projetos, tem-se a necessidade de definição das condições planialtimétricas da via navegável, configurando este procedimento como o Módulo 05 deste estudo, representando a quarta etapa metodológica realizada. De modo a apresentar uma visão geral referente a este módulo, apresenta-se na Figura 23 o fluxograma das etapas a serem seguidas.

Figura 23 - Fluxograma Metodológico do Módulo 05



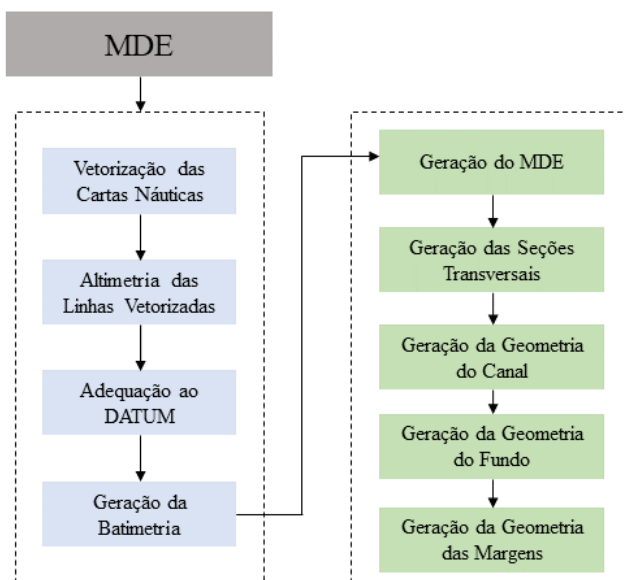
Fonte: Autor (2023).

Dessa forma, apresentada a abordagem adotada para o módulo em questão, detalhou-se nos tópicos que seguem cada uma das sub-etapas realizadas.

3.5.1. Modelo Digital de Elevação

O MDE foi desenvolvido utilizando a interpolação das imagens SRTM e das profundidades das cartas náuticas. Como forma de evidenciar as etapas para geração do Modelo Digital de Elevação, tem-se o fluxograma da Figura 24 ilustrando as etapas principais da geração das bases geométricas.

Figura 24 - Fluxograma da geração das bases geométricas



Fonte: Autor (2023).

3.5.1.1. Base Cartográfica, Vazões e Níveis d'água

O desenvolvimento do MDE foi elaborado a partir da construção da base cartográfica utilizando as imagens *raster* das cartas náuticas e SRTM. Depois desse procedimento é realizado a digitalização dos vetores linhas e vetores pontos das cartas náuticas, obtidas no site do Centro de Hidrografia da Marinha (CHM).

Nas cartas náuticas obtém-se os dados de profundidade e estes foram vetorizadas utilizando o software *ARCGIS*, a partir da ferramenta *ARCSCAN*. As profundidades estão associadas ao nível de redução calculado para as cotas de níveis d'água da estação fluviométrica a qual a carta está referenciada. Como as cartas não são referenciadas a nenhum *datum*, é necessário determinar a altimetria do nível de redução (NR) utilizando a referência de nível (RN) obtida na ficha descritiva F-43.

A altitude ortométrica referenciada ao NR configura-se necessária para os procedimentos subsequentes, portanto, pode-se calcular esta por intermédio da conversão das altitudes elipsoidais, encontrada na ferramenta *MAPGEO*, definida pela Equação 41.

$$H = h - N \quad (41)$$

Em que:

H é a altitude ortométrica;

h é a altitude geométrica ou elipsoidal;

N é a ondulação geoidal.

A atribuição das altitudes ortométricas aos pontos de profundidade das cartas náuticas vetorizadas e disponibilizadas pela Marinha do Brasil devem ser realizadas por meio das relações demonstradas nas Equações 42 e 43.

$$H_{NR} = RN_1 - NR_1 \quad (42)$$

$$H_{CN} = H_{NR} - P_{cn} \quad (43)$$

Em que:

H_{NR} é a elevação ortométrica do nível de redução;

RN_1 é a referência de nível local (associada a ficha descritiva);

NR_1 é a profundidade do nível de redução da carta náutica;

H_{CN} é a elevação ortométrica dos pontos na carta náutica;

P_{cn} é a profundidade na carta náutica.

No cálculo das altitudes ortométricas utilizaram-se as Equações 42 e 43, relacionando cada ponto com sua profundidade da carta náutica respectiva. Após esse cálculo houve a verificação da relação com a referência de nível, e posteriormente a interpolação das elevações utilizando o método IDW para assim terminar o modelo digital de elevação do trecho do rio analisado.

3.5.1.2. Integração dos dados das cartas náuticas com os das imagens SRTM

A integração dos dados configura-se um processo complexo na modelagem hidrológica do rio uma vez que se utilizam duas fontes de dados com características diferentes (carta náutica e imagem SRTM). Assim, há a integração entre a batimetria e a topografia do canal e com a inserção das seções transversais, desenvolve-se o modelo digital de elevação para cada seção, para o talvegue, margens e *flowpaths*.

3.5.1.3. Geração do Modelo Digital de Elevação

Para a geração do modelo digital de elevação foram utilizadas imagens *raster* das cartas náuticas e SRTM. As cartas náuticas do trecho analisado (disponíveis em <https://www.marinha.mil.br/chm/dados-do-segnav/cartas-raster>) primeiramente foram digitalizadas para a extração de suas linhas e pontos, depois foi inserido o valor correspondente a cada profundidade, sendo posteriormente corrigidos com os valores referentes ao nível de


redução obtido das fichas descritivas F-43. Por fim, foi calculada a elevação ortométrica a partir dos valores obtidos para o zero das réguas. As imagens SRTM foram obtidas do site (www.earthexplorer.usgs.gov) com resolução de 30m, estes dados foram interpolados com os provenientes das cartas náuticas gerando o modelo digital de elevação.

3.5.2. Definição das Condições Planialtimétricas

Para realização de uma navegação segura em um dado canal de navegação ou hidrovía, faz-se necessária a definição das características geométricas mínimas do curso d'água, em relação às dimensões horizontais (larguras em trechos retos e curvos) e às dimensões verticais (profundidades mínimas necessárias). Tais variáveis geométricas caracterizam-se por serem dependentes de fatores relacionados, sobretudo, à embarcação de projeto, às condições de relevo, condições climáticas e hidrológicas.

Nesse sentido, em virtude da necessidade de definição das características geométricas da via navegável do estudo de caso, foram definidas as condições horizontais e verticais, com base na Figura 25, sendo calculadas a partir do software *DimChannel- Dimensioning of Navigation Channel*, desenvolvido em pesquisas pretéritas e apresentado em Barbosa *et al.*(2021) e Campos Filho *et al.*(2019).

Figura 25 - Parâmetros Geométricos de Vias Navegáveis



Fonte: Autor (2023).

O *DimChannel* baseou-se em PIANC (2014), e tal escolha se deu em decorrência da maior adequação da *Permanent International Association of Navigation Congresses (PIANC)* em relação às características e realidades da navegação brasileira, bem como em função do

amplo índice de aceitação da referida norma perante as autoridades marítimas, tendo um detalhamento rigoroso a respeito dos fatores que possuem influências consideráveis no dimensionamento de canais e que podem afetar consideravelmente a segurança das embarcações que podem navegar nas vias navegáveis analisadas.

No que tange aos procedimentos de cálculo das características de largura em trechos retos, curvos e raios de curvatura, apresenta-se a seguir o detalhamento metodológico e analítico que deu suporte para a realização deste utilizando o *DimChannel*.

3.5.2.1. Larguras em Trechos Retos

A largura do canal de navegação em trechos retos para trechos sem cruzamento e com cruzamento de embarcações foi obtida através das Equações 44 e 45, respectivamente.


$$W_R = W_{BM} + \sum_{i=1}^n W_i + W_{Br} + W_{Bg} \quad (44)$$

$$W_R = 2 W_{BM} + 2 \sum_{i=1}^n W_i + W_{Br} + W_{Bg} + \sum W_p \quad (45)$$

Em que W_{BM} representa a largura da faixa básica de manobra; W_{Br} e W_{Bg} são larguras adicionais por efeito das distâncias de margens; W_i são larguras adicionais atribuídas aos trechos retos decorrentes de efeitos diversos e $\sum W_p$ é a distância de passagem.

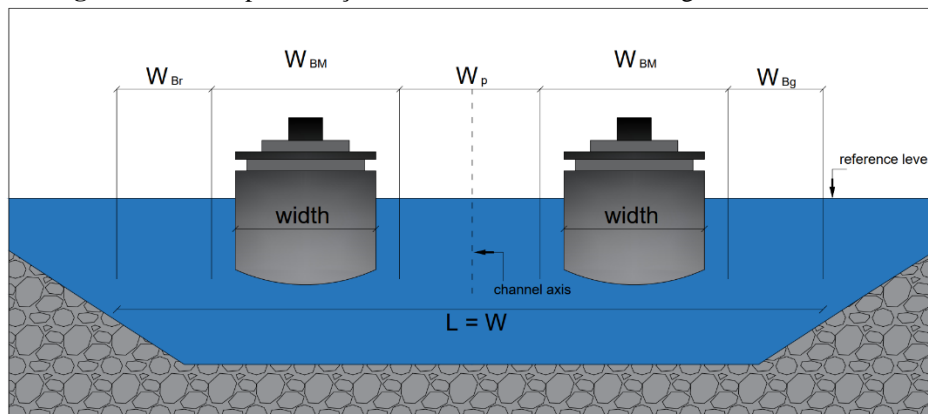
Na Figura 26 e na Figura 27 podem-se observar as representações esquemáticas de seções transversais de canais sem e com cruzamentos, respectivamente, com a indicação das variáveis usadas na obtenção das larguras em trechos retos.

Figura 26 - Exemplo de seção transversal de canal de via única com talude normal



Fonte: Adaptado de PIANC (2014).

Figura 27 - Exemplo de seção transversal de canal de tráfego nos dois sentidos




Fonte: Adaptado de PIANC (2014).

3.5.2.2. Largura da Faixa de Trajetória Varrida (W_s)

Ao passo que uma embarcação guina em uma curva, ela “escorrega lateralmente” e, conseqüentemente, varre uma faixa de trajetória maior que sua boca, denominada faixa de trajetória varrida (Figura 28). Essa faixa é função da boca da embarcação, do ângulo de leme e da razão existente a profundidade da via navegável e o calado da embarcação.

Figura 28 - Faixa de Trajetória Varrida



Fonte: Autor (2023).

Segundo Ligteringen (2009), um dos fatores fundamentais na determinação da faixa de trajetória varrida necessária à embarcação quando encontra-se navegando em trechos curvos é a relação existente entre a profundidade da via navegável e o calado da embarcação. Basicamente, quando a relação profundidade/calado é pequena, a largura da faixa também é pequena (RAYO, 2013). Thorensen (2010) propôs regras práticas relacionadas à largura da faixa de trajetória varrida, estimando condições de influência do ângulo de deflexão da curva em relação a necessidade de aumento das dimensões horizontais em curvas.

A largura da faixa de trajetória varrida foi obtida através de regressões múltiplas não lineares para uma dada razão profundidade/calado, tendo como variável dependente a razão largura da faixa (W_s)/Boca (B) e como variável independente o ângulo de abertura de leme (α) da embarcação quando esta encontra-se descrevendo a curva.

Para estimativa de alinhamento e manobrabilidade em trechos curvos, Viallon (2012) fez uso de processos de regressão polinomial com coeficientes estimados por algoritmos de mínimos quadrados. No presente trabalho, a largura da faixa de trajetória varrida, bem como o raio de curvatura, foi estimada fazendo uso de regressões múltiplas não lineares. Estas regressões, assim como métodos de mínimos quadrados ordinários são constantemente utilizados para análise de dados na engenharia (Forghani e Peralta, 2017; Marčiukaitis *et al.*, 2017; Hose e Hanss, 2018, Wang, 2019).

A análise de regressão pode ser usada para prever valores de uma variável de resposta (dependente), a partir de uma equação que descreve a relação entre os conjuntos de variáveis dependentes e independentes (Alkarkhi, 2019). A regressão múltipla não linear foi usada para prever valores da variável dependente (W_s/B) a partir da variável independente (α), para uma dada razão profundidade/calado. O modelo genérico de regressão não linear que simulou (W_s/B) foi representado pela Equação 46, onde os parâmetros β foram estimados por mínimos quadrados ordinários generalizados.

$$W_s = (f(\alpha, \beta) + u) \cdot B \quad (46)$$

Em que

W_s	Vetor da variável dependente;
α	Matriz de variáveis não dependentes;
β	Vetor de parâmetros desconhecidos;
u	Vetor de erros aleatórias;
$f(\alpha, \beta)$	Função das variáveis não dependentes α e parâmetros β ; e
B	Boca da embarcação.

Segundo Salkind (2010), na aplicação de modelos de regressão, a menos que a relação ou correlação seja perfeita, os valores previstos são diferentes das observações reais. Essas diferenças são erros de previsão ou resíduos, que são medidos pelas distâncias verticais entre os valores reais e a linha de regressão (TOMAZELLA *et al.*, 2019; PESARAN E SMITH, 2018). Para tanto, a calibração do modelo de regressão (Equação 46) foi feita através do Coeficiente de Determinação R^2 (Equação 4) e do RMSE Root Mean Square Error (Equação 5), já apresentados previamente na presente pesquisa para funções do tipo linear, potência e quadrática. Com base na avaliação dos valores aferidos para R^2 e RMSE para cada função utilizada, a equação de regressão obtida com melhores valores para estes parâmetros pode ser descrita pela Equação 47, sendo esta do tipo quadrática.

$$W_s = k.B + a.B.\alpha + b.\alpha^2 \quad (47)$$

Em que

W_s	Valor para Faixa de Trajetória Varrida.
α	Ângulo de Abertura de Leme
B	Boca da Embarcação.
k, a, b	Parâmetros adimensionais do modelo.

A Equação 48 evidencia a equação de regressão obtida tendo por base os valores aferidos de R^2 e RMSE para a equação do tipo linear.

$$W_s = a.B.\alpha + k.B \quad (48)$$

Em que

W_s	Valor para Faixa de Trajetória Varrida.
α	Ângulo de Abertura de Leme
B	Boca da Embarcação.
k, a	Parâmetros adimensionais do modelo.

Sendo a do tipo potencial o terceiro modelo de equação utilizado com base nos valores encontrados para R^2 e RMSE, a Equação 49 evidencia a equação de regressão do tipo potência.

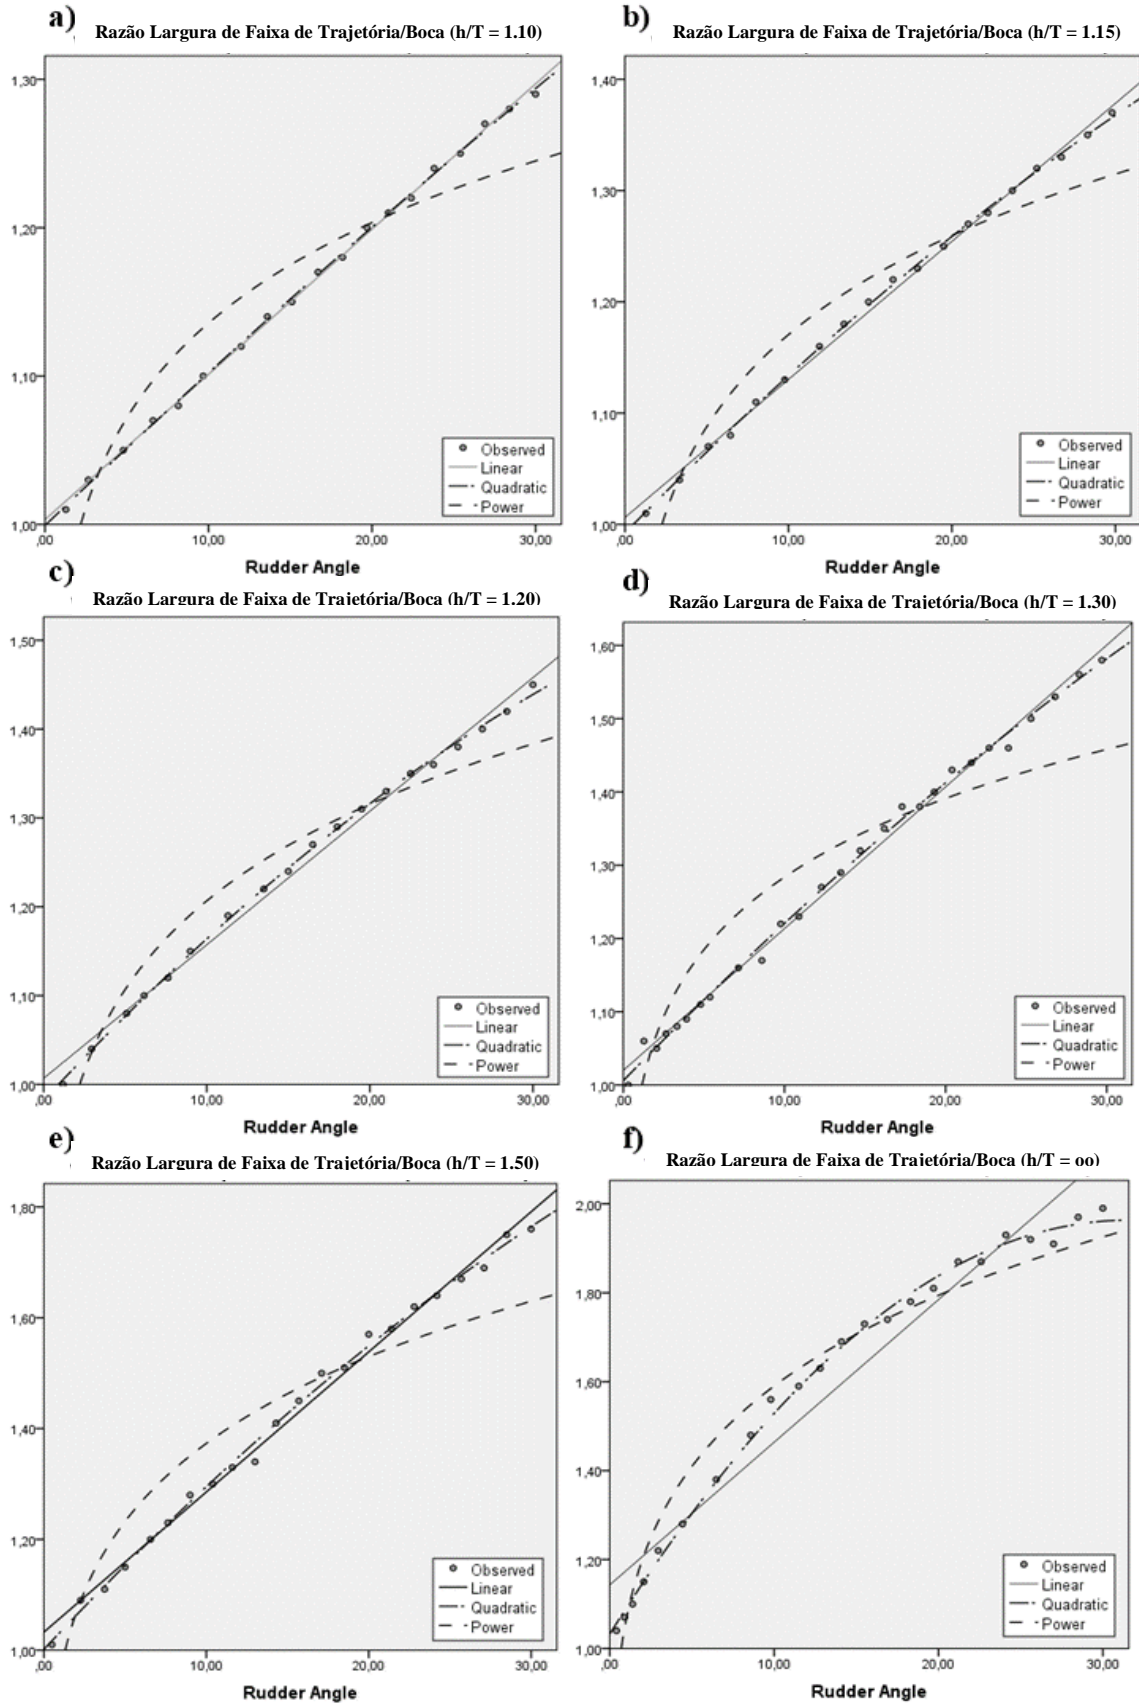
$$W_s = a.B.\alpha^k \quad (49)$$

Em que

W_s	Valor para Faixa de Trajetória Varrida.
α	Ângulo de Abertura de Leme
B	Boca da Embarcação.
k, a	Parâmetros adimensionais do modelo.

Pode-se observar na Figura 29 os gráficos referentes a razão largura da faixa de trajetória varrida (W_s)/Boca (B), tendo como variável independente o ângulo de abertura de leme (α), para cada razão profundidade/calado (h/T). Nos gráficos da referida figura, evidenciam-se os pontos obtidos empiricamente para cada razão H/T , bem como a linha de tendência da curva das três funções utilizadas que obtiveram os maiores valores de R^2 e RMSE.

Figura 29 - Gráficos da Largura da Faixa de Trajetória Varrida



Fonte: Autor (2023).

A partir dos gráficos da Figura 29, comprovam-se as relações de proporcionalidade entre os valores de largura da faixa de trajetória varrida (variável dependente), com os valores da razão profundidade/calado e ângulo do leme, conforme afirmam em Thorensen (2010), PIANC (2014), Ligteringen (2009), Mayer et. al (1999) e Rayo (2013).

Com a obtenção dos parâmetros adimensionais de cada curva, obtiveram-se as equações finais para a largura da faixa de trajetória varrida que foi obtida para cada razão profundidade/calado, evidenciadas na Tabela 11.

Tabela 11 - Equações da Largura da Faixa de Trajetória Varrida

Razão h/T	R ²	RMSE	Equação	Tipo
1.10	0,997	0,019	$W_s = -2E-05 \cdot B \cdot \alpha^2 + 0,0105 \cdot B \cdot \alpha + 0,9992 \cdot B$	Quadrática
	0,945	0,076	$W_s = 0,0098 \cdot B \cdot \alpha + 1,0032 \cdot B$	Linear
	0,979	0,045	$W_s = 0,9367 \cdot B \cdot \alpha^{0,0837}$	Potência
1.15	0,997	0,006	$W_s = -8E-05 \cdot B \cdot \alpha^2 + 0,0149 \cdot B \cdot \alpha + 0,9923 \cdot B$	Quadrática
	0,989	0,007	$W_s = 0,0124 \cdot B \cdot \alpha + 1,0063 \cdot B$	Linear
	0,952	0,29	$W_s = 0,9174 \cdot B \cdot \alpha^{0,1058}$	Potência
1.20	0,999	0,005	$W_s = -0,0001 \cdot B \cdot \alpha^2 + 0,0196 \cdot B \cdot \alpha + 0,9823 \cdot B$	Quadrática
	0,993	0,011	$W_s = 0,015 \cdot B \cdot \alpha + 1,0069 \cdot B$	Linear
	0,922	0,032	$W_s = 0,906 \cdot B \cdot \alpha^{0,1244}$	Potência
1.30	0,998	0,01	$W_s = -0,0001 \cdot B \cdot \alpha^2 + 0,0224 \cdot B \cdot \alpha + 1,0068 \cdot B$	Quadrática
	0,997	0,013	$W_s = 0,0192 \cdot B \cdot \alpha + 1,0219 \cdot B$	Linear
	0,919	0,56	$W_s = 0,999 \cdot B \cdot \alpha^{0,1112}$	Potência
1.50	0,998	0,014	$W_s = -0,0002 \cdot B \cdot \alpha^2 + 0,0312 \cdot B \cdot \alpha + 1,0012 \cdot B$	Quadrática
	0,997	0,019	$W_s = 0,0253 \cdot B \cdot \alpha + 1,032 \cdot B$	Linear
	0,928	0,63	$W_s = 0,9579 \cdot B \cdot \alpha^{0,1562}$	Potência
∞	0,997	0,019	$W_s = -0,0009 \cdot B \cdot \alpha^2 + 0,0583 \cdot B \cdot \alpha + 1,0376 \cdot B$	Quadrática
	0,945	0,076	$W_s = 0,0307 \cdot B \cdot \alpha + 1,1713 \cdot B$	Linear
	0,979	0,045	$W_s = 1,0693 \cdot B \cdot \alpha^{0,173}$	Potência

Fonte: Autor (2023).

Sabendo que o R² e RMSE são critérios de mensuração da qualidade do modelo (ALKARKHI, 2019) e com base nas informações mostradas na Tabela 11 e nos gráficos da Figura 29, evidencia-se que a curva correspondente com maior valor R² de RMSE caracteriza-se por ser a do tipo quadrática, sendo, portanto, esta a utilizada no presente trabalho para os fins de cálculo de largura da faixa de trajetória varrida.

3.5.2.3. Raio de Curvatura do Trecho Curvo (R_c)

O raio de curvatura de giro, assim como a largura adicional da trajetória varrida, depende da razão profundidade/calado, do ângulo de leme, e das dimensões da embarcação de projetos. Ligteringen (2009) especifica que o raio das curvas depende da capacidade de manobra da embarcação (comprimento entre perpendiculares, profundidade da água e ângulo do leme). Segundo Eloot (2007), além das dimensões da embarcação e a capacidade de leme disponível necessária para executar uma curva com determinadas características, a velocidade inicial à frente da embarcação também tem influências práticas.

No que concerne à determinação do raio de curvatura, procedeu-se da mesma maneira da adotada no dimensionamento da faixa de trajetória varrida (W_s), evidenciada anteriormente, em que foram obtidas as equações de regressão e seus parâmetros adimensionais e, posteriormente, os gráficos para cada razão profundidade/calado.

Com base na avaliação dos valores encontrados para R^2 e RMSE, a equação de regressão obtida com melhores valores para estes parâmetros pode ser descrita pela Equação 50, caracterizando-se por ser uma quadrática.

$$R = k \cdot Lpp + a \cdot Lpp \cdot \alpha + b \cdot Lpp \cdot \alpha^2 \quad (50)$$

Em que

R	Raio de Curvatura.
α	Ângulo de Abertura de Leme
Lpp	Comprimento entre perpendiculares.
k, a, b	Parâmetros adimensionais do modelo.

A Equação 51 evidencia outro tipo de equação de regressão obtida, tendo por base os valores aferidos de R^2 e RMSE para a equação do tipo logarítmica.

$$R = a \cdot Lpp \cdot \ln(\alpha) + b \cdot Lpp \quad (51)$$

Em que

R	Raio de Curvatura.
α	Ângulo de Abertura de Leme
Lpp	Comprimento entre perpendiculares

k, a Parâmetros adimensionais do modelo.

Sendo do tipo potencial o terceiro modelo de equação utilizado com base nos valores encontrados para R^2 e RMSE, a Equação 52 evidencia a equação de regressão do tipo potência.

$$R = a \cdot L_{pp} \cdot \alpha^k \quad (52)$$

Em que

R Raio de Curvatura

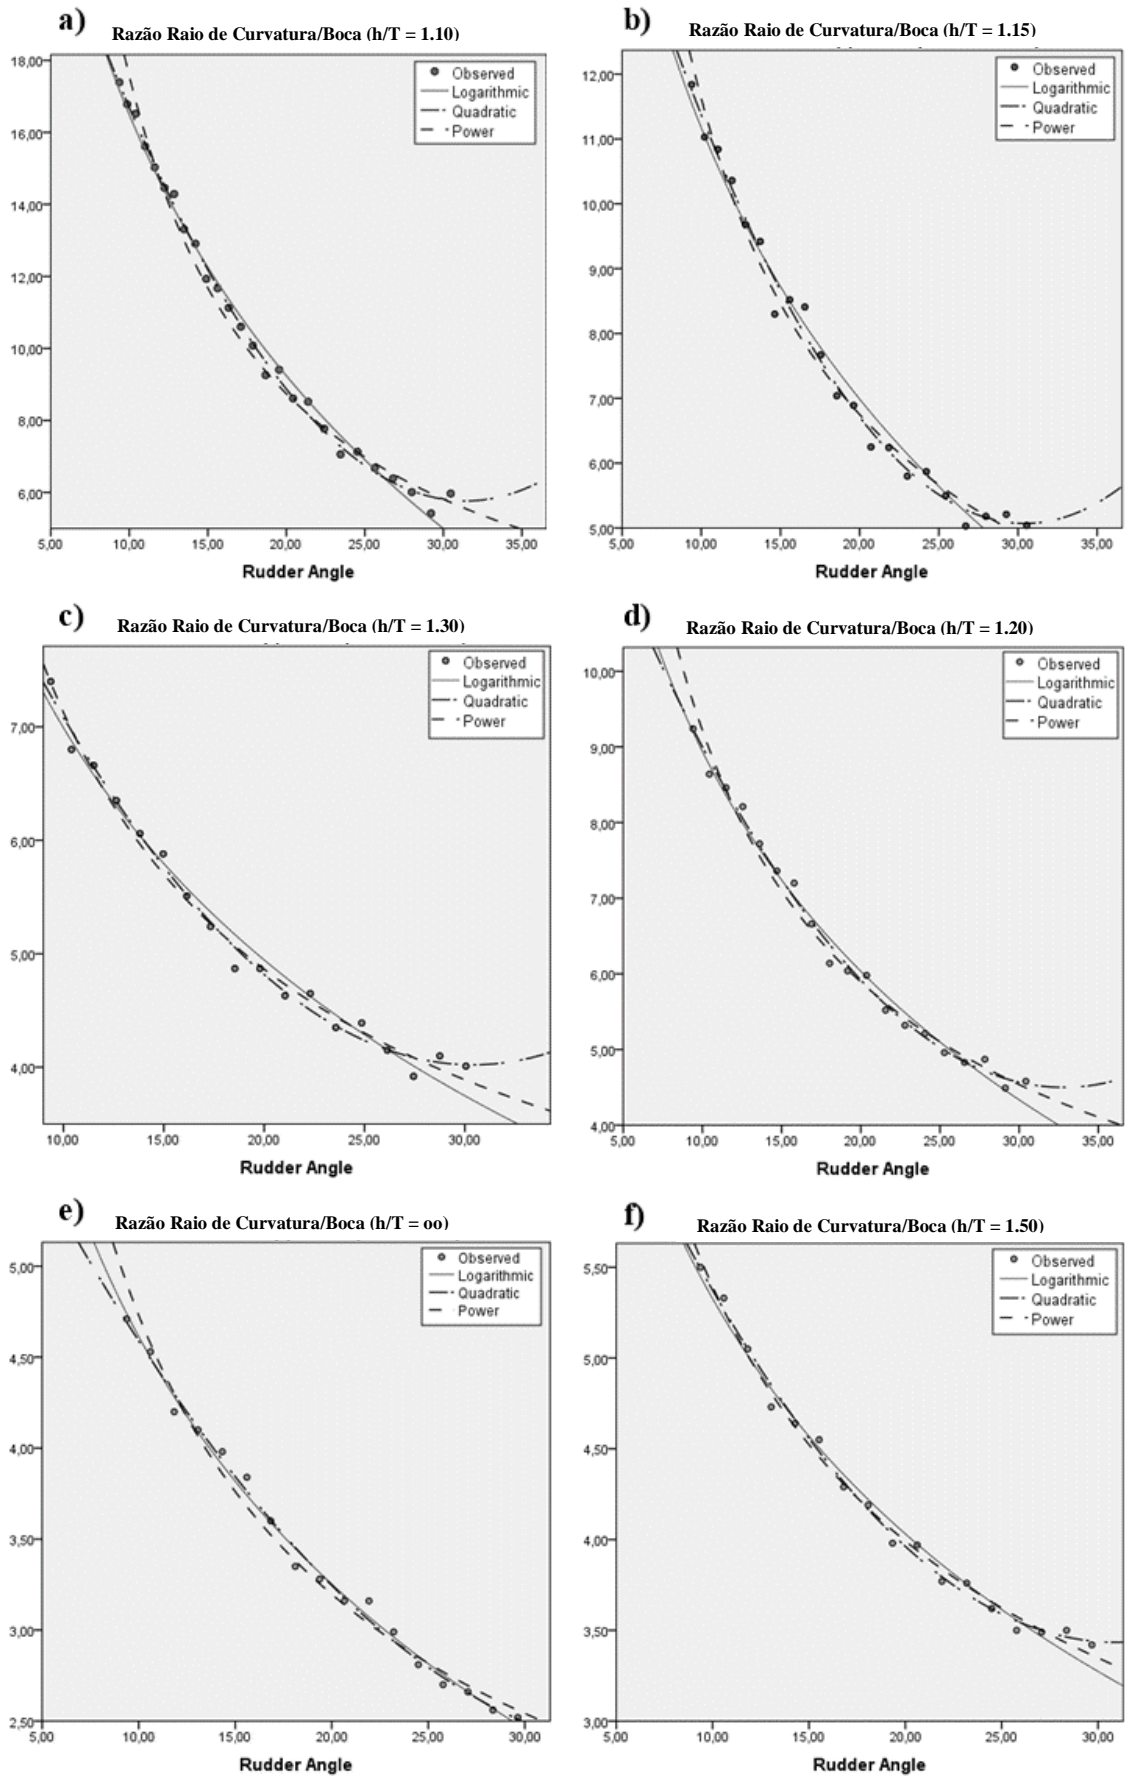
α Ângulo de Abertura de Leme

L_{pp} Comprimento entre perpendiculares

k, a Parâmetros adimensionais do modelo.

A Figura 30 evidencia os gráficos do raio de curvatura de giro para cada razão profundidade/calado, tendo como variável dependente o ângulo de abertura de leme, denotando os pontos obtidos empiricamente e as linhas de tendência das curvas para cada tipo de função utilizada (potência, logarítmica e quadrática), sendo estas as que obtiveram maiores valores de R^2 e RMSE.

Figura 30 - Raio de Curvatura de Trechos Curvos



Fonte: Barbosa et al.(2021) e Campos Filho et al.(2019).

Com a obtenção dos parâmetros adimensionais de cada curva parametrizada, obtiveram-se as equações finais que descrevem o raio de curvatura para cada razão profundidade/calado, evidenciadas na Tabela 12.

Tabela 12 - Raio de Curvatura de Giro

Razão h/T	R ²	RMSE	Equação	Tipo
1.10	0,999	0,214	$R = 0,0238 \cdot Lpp \cdot \alpha^2 - 1,4972 \cdot Lpp \cdot \alpha + 29,28 \cdot Lpp$	Quadrática
	0,9905	0,373	$R = -10,46 \cdot Lpp \cdot \ln(\alpha) + 40,587 \cdot Lpp$	Logarítmica
	0,97	0,41	$R = 178,02 \cdot Lpp \cdot \alpha^{-1,006}$	Potência
1.15	0,996	0,214	$R = 0,0151 \cdot Lpp \cdot \alpha^2 - 0,9196 \cdot Lpp \cdot \alpha + 19,059 \cdot Lpp$	Quadrática
	0,989	0,328	$R = -6,041 \cdot Lpp \cdot \ln(\alpha) + 25,084 \cdot Lpp$	Logarítmica
	0,9844	0,37	$R = 70,748 \cdot Lpp \cdot \alpha^{-0,784}$	Potência
1.20	0,9942	0,123	$R = 0,0087 \cdot Lpp \cdot \alpha^2 - 0,5676 \cdot Lpp \cdot \alpha + 13,808 \cdot Lpp$	Quadrática
	0,9884	0,168	$R = -4,191 \cdot Lpp \cdot \ln(\alpha) + 18,588 \cdot Lpp$	Logarítmica
	0,9882	0,26	$R = 40,723 \cdot Lpp \cdot \alpha^{-0,645}$	Potência
1.30	0,9917	0,105	$R = 0,0074 \cdot Lpp \cdot \alpha^2 - 0,4476 \cdot Lpp \cdot \alpha + 10,822 \cdot Lpp$	Quadrática
	0,9814	0,152	$R = -2,95 \cdot Lpp \cdot \ln(\alpha) + 13,781 \cdot \alpha$	Logarítmica
	0,9871	0,24	$R = 25,327 \cdot Lpp \cdot \alpha^{-0,551}$	Potência
1.50	0,9945	0,054	$R = 0,0044 \cdot Lpp \cdot \alpha^2 - 0,2742 \cdot Lpp \cdot \alpha + 7,6699 \cdot Lpp$	Quadrática
	0,9873	0,178	$R = -1,867 \cdot Lpp \cdot \ln(\alpha) + 9,6233 \cdot Lpp \cdot \alpha$	Logarítmica
	0,9922	0,14	$R = 14,635 \cdot Lpp \cdot \alpha^{-0,434}$	Potência
∞	0,9937	0,058	$R = 0,003 \cdot Lpp \cdot \alpha^2 - 0,2238 \cdot Lpp \cdot \alpha + 6,5301 \cdot Lpp$	Quadrática
	0,9933	0,098	$R = -1,961 \cdot Lpp \cdot \ln(\alpha) + 9,1292 \cdot Lpp$	Logarítmica
	0,9853	0,125	$R = 17,357 \cdot Lpp \cdot \alpha^{-0,565}$	Potência

Fonte: Autor (2023).

Com base nas informações mostradas na Tabela 12 e nos gráficos da Figura 30, evidencia-se que a linha de tendência com maior valor de R² e RMSE caracteriza-se por ser do tipo quadrática, sendo esta a utilizada para os fins de cálculo do raio de curvatura.

Por intermédio das Equações da Tabela 12 e a partir da Figura 30, evidencia-se que o raio de curvatura (variável dependente) é proporcional ao comprimento da embarcação e ao ângulo de leme, conforme afirmam Ligteringen (2009) e Eloot (2007).

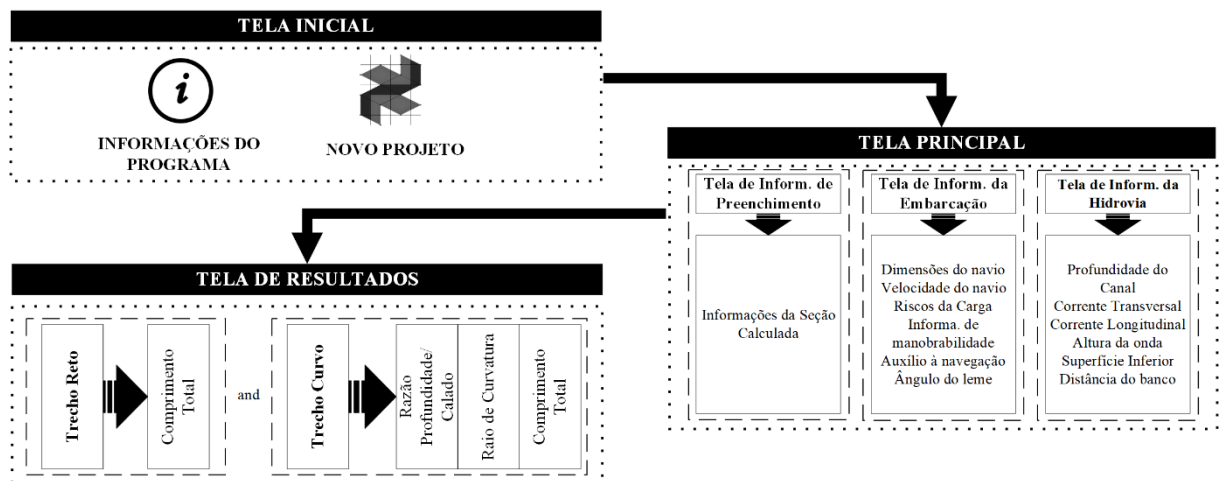
3.5.3. Aplicação da Ferramenta Computacional: *Dimchannel*

Com base na necessidade constante de utilização de ferramentas computacionais que promovam a elaboração e a implementação de modelos computacionais de otimização de dados e projetos na engenharia com o objetivo de aumentar a segurança e a eficiência nas operações, fez-se uso do software denominado *DimChannel- Dimensioning of Navigation Channel*,

desenvolvido em pesquisas pretéritas e apresentado em Barbosa *et al.*(2021) e Campos Filho *et al.*(2019), sendo registrado no INPI (Instituto Nacional da Propriedade Industrial) sob o número BR512019000334-9. O software permite o dimensionamento, análise e simulação de projetos geométricos de vias navegáveis, buscando a segurança e a eficiência operacional na definição das dimensões horizontais dessas vias de modo célere e sem a necessidade de realização de cálculos manuais demasiados, possibilitadas pela verificação automática dos critérios e regulamentações internacionais evidenciadas na PIANC Report nº 121 - 2014 para definição de dimensões de canais de navegação.

O software *DimChannel* proporciona uma redução nos custos de manutenção do canal por intermédio de uma análise mais refinada das condições atuais e futuras da hidrovia em questão e contribui para a elaboração de projetos básicos de canais, com indicações preliminares capazes de auxiliar no estudo de viabilidade e para tomada de decisões operacionais referentes ao controle do tráfego na via navegável estudada. No fluxograma simplificado da Figura 31 encontram-se detalhadas as etapas implementadas pelo software *DimChannel*, relativas ao processo de dimensionamento e de otimização de canais e de vias navegáveis interiores.

Figura 31 - Fluxograma simplificado do Software

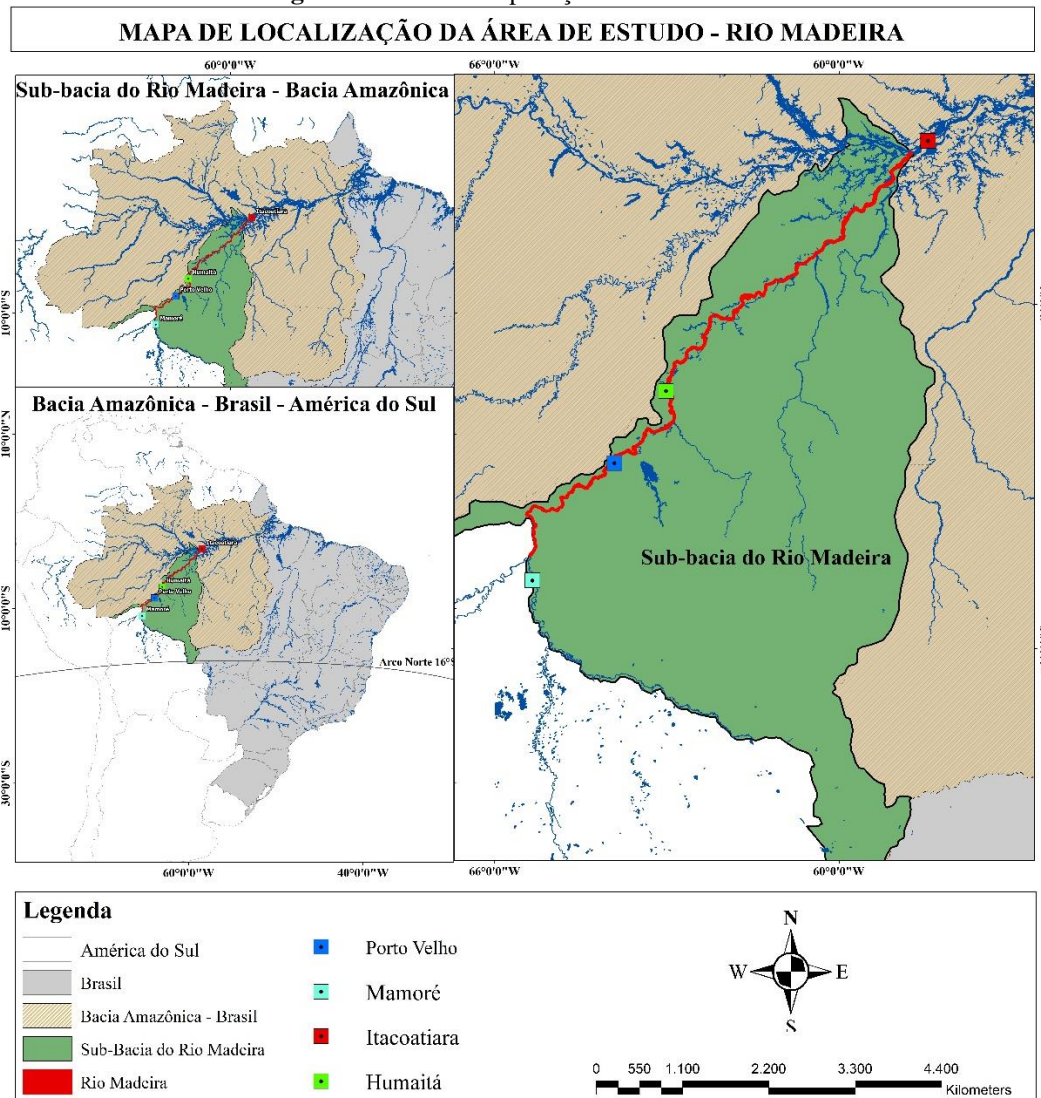


Fonte: Autor (2023).

4. ESTUDO DE CASO: RIO MADEIRA

De posse dos modelos computacionais desenvolvidos e apresentados no tópico supracitado de previsão de lâminas d'água e calados operacionais para posterior determinação da capacidade de carga máxima, estes foram validados e aplicados a um curso fluvial de grande importância no Brasil, localizado na Região Hidrográfica Amazônica e denominado de Rio Madeira (conforme evidenciado na Figura 32) sendo o rio com maior a sub-bacia amazônica (23%), de acordo com Sikora de Souza *et al.*(2020). Situado na porção sudoeste da Bacia Amazônica e nascendo na Cordilheira dos Andes, fluindo para nordeste para se juntar ao rio Amazonas (GOMES *et al.*, 2022), o rio Madeira caracteriza-se por ser um rio transfronteiriço, com sua bacia correspondente se estendendo pela Bolívia (51%), Brasil (42%) e Peru (7%), totalizando uma área de drenagem total de 1.324.727 km² (MOLINA CARPIO *et al.*, 2017; SIKORA DE SOUZA *et al.*, 2020).

Figura 32 - Área de Aplicação do Estudo de Caso



Fonte: Autor (2023).

No que tange ao referido curso fluvial, tem-se que este fundamenta-se como de grande importância para o transporte de cargas e escoamento destas pela região amazônica, seja para o abastecimento interno, como também para o escoamento da produção destinada à exportação, sendo estas características apresentadas detalhadamente nos tópicos que seguem.

Dessa forma, de modo a apresentar as principais características referentes ao rio em questão, nos itens que seguem foram descritas detalhadamente informações relevantes acerca deste, no que tange à caracterização geral em termos de: Navegabilidade; Características Econômicas e de Movimentação de Carga; e Cartas Náuticas. De posse destas informações, apresentou-se o trecho específico de análise, bem como suas características no que concerne à aplicação dos modelos desenvolvidos para posterior obtenção dos resultados.

4.1. CARACTERIZAÇÃO GERAL

Em complementação, no que tange às condições climáticas da Bacia Hidrográfica do rio Madeira, esta tem características de AF (tropical úmido a super úmido), AM (tropical chuvoso, com chuvas de monção, com estação seca de pequena duração) e AW (tropical quente, com clima seco temporada no inverno), de acordo com Sikora de Souza *et al.*(2020), Peel; Finlayson; McMahon (2007).

Para definição detalhada da hidrovia em questão, necessita-se apresentá-la desde sua nascente, formada no rio Mamoré que nasce na serra de Cochabamba na Bolívia e pelo Rio Guaporé. Com a confluência destes dois rios, segue-se até o encontro com rio Abunã, quando o rio Madeira segue em direção ao nordeste atravessando dezenas de corredeiras até chegar a Porto Velho (RO), onde se inicia a hidrovia.

O ciclo das águas da hidrovia do Madeira é bem definido, com enchentes entre fevereiro e maio, e vazante, entre julho e novembro, escoando uma vazão média de aproximadamente 22.000 m³/s. Durante o período de cheias, o rio Madeira sofre influência do rio Amazonas, ocasionando em grandes áreas de inundação e elevadas profundidades, alagando os pedrais e praias que afloram nas vazantes nos trechos mais a jusante do rio. No período seco afloram obstáculos, tais como bancos de areia e pedrais em muitos trechos da extensão do rio, que apesar de não interromperem a navegação, aumentam o tempo de viagem e os riscos para a navegação.

De acordo com a Capitania Fluvial de Porto Velho - CFPV (2020), nas Normas e Procedimentos da Capitania Fluvial, o rio é dividido em dois trechos, definidos como Alto Madeira e Baixo Madeira, sendo o primeiro compreendendo ao trecho desde confluência dos rios Beni e Mamoré até a usina hidrelétrica de Santo Antônio, próxima a Porto Velho-RO, sendo

este um trecho repleto de cachoeiras e corredeiras, não permitindo a navegação. No que tange ao segundo trecho, denominado Baixo Madeira, inicia-se na hidrelétrica de Santo Antônio e vai até a sua foz, no rio Amazonas. Possui forte correnteza em qualquer época do ano, pedras que afloram na seca e outras não determinadas com precisão, e muitos troncos e lixo nos períodos de cheia. Tudo isto o torna um rio peculiar da região (CFPV, 2020).

De posse das informações supracitadas e a fim de complementá-las, na Tabela 13 apresentam-se características gerais da hidrovia no que tange às suas características gerais.

Tabela 13 - Caracterização Geral Rio Madeira

Caracterização Geral – Curso Fluvial Estudado		
Geral	Trecho Navegável	Toda a extensão, com restrições na vazante
	Principais cargas	Soja; milho; combustíveis, óleos minerais e produtos derivados; outras mercadorias
Dimensional	Extensão navegável	1.060 km (Porto Velho à Itacoatiara)
	Largura média	1.000 metros
Navegabilidade	Período de águas baixas	Abril a novembro
	Período de águas altas	Dezembro a março
	Prof. Máx. (90% tempo)	6,8 metros
	Prof. Mín. (90% tempo)	1,7 metros

Fonte: Adaptado de DNIT (2018) e CFPV (2020).

A hidrovia permite a navegação de grandes comboios, com até 18 mil toneladas, mesmo durante a estiagem. A largura varia entre 440 metros e 9.900 metros, e a profundidade oscila de acordo com as estações seca e chuvosa. Com uma declividade de apenas 1,7 cm e um percurso de águas totalmente livres, sem barragens ou qualquer outro obstáculo para a navegação.

A rota fluvial seguida pelo eixo inicia-se no encontro das águas dos rios Amazonas e Madeira, direcionando-se rumo ao rio Madeira, sendo ele uma das vias fundamentais de transporte do Corredor Logístico Norte. É também depois do rio Amazonas a hidrovia mais importante da região, onde o rio Madeira constitui-se como um dos principais afluentes da margem direita do rio Amazonas.

Além disso, a coincidência de ocorrência de maior demanda de movimentação da soja com o período de cheia do rio torna o uso mais intensivo da hidrovia do rio Madeira rumo a Santarém ou Itacoatiara uma opção extremamente interessante aos produtores que visam a exportação ao mercado europeu. Logo, entende-se que a hidrovia do rio Madeira ainda tem um grande potencial a ser explorado, haja vista sua localização estratégica, principalmente para o caso da soja.

4.2. NAVEGABILIDADE

O trecho do rio Madeira amplamente navegável compreende à extensão entre os municípios de Itacoatiara/AM e Porto Velho/RO. Segundo o Departamento Nacional de Infraestrutura de Transportes (DNIT, 2021), a hidrovia do Madeira apresenta nesse trecho uma extensão navegável de 1.060 km, entre porto velho e a foz em Itacoatiara (AM). Destes, aproximadamente 180 km estão dentro dos limites de Rondônia e 876 km no estado do Amazonas, abrangendo cerca de 11 municípios, sendo 8 no Amazonas e 3 em Rondônia com uma população total de 780.916 habitantes.

Entretanto, de acordo com CFPV (2020), apesar de ser navegável até Porto Velho, em qualquer época do ano, deve-se evitar a navegação durante os meses de setembro e outubro, período de seca extrema. Além disso, alguns pontos dificultam a navegação, conforme elencado nos itens que seguem:

- i. Afloramento de Bancos de Areia:** Nas estiagens aparecem bancos de areia que mudam de posição por ocasião das enchentes. A lâmina d'água esperada nos meses de águas baixas e de 1,7 metros. O regime das águas do rio é composto de 3 períodos distintos e existe o fenômeno do “repiquete”, geralmente nos meses de outubro e novembro, quando ocorre uma variação de nível de aproximadamente 3 metros. A amplitude de variação de nível entre a estação das cheias e das águas rasas e de 15 metros.
- ii. Pedrais e Paliteiros:** O rio Madeira é de leito permanente (não muda com a estação das cheias), o canal, porém, sofre modificações. Em decorrência do perigo que representa a existência de pedrais e paliteiros em determinados trechos da hidrovia, mais o fato das modificações que ocorrem no canal, é necessário que as embarcações, ao trafegarem pelo rio Madeira, possuam a bordo pessoal com bastante experiência e conhecimento prático quanto a essas peculiaridades.
- iii. Tráfego de Comboios:** Outros complicadores para a navegação são o crescente tráfego de comboios da região, associado à crescente navegação de embarcações de carga geral e passageiros sem o devido controle de tráfego, aumentando os riscos de abalroamentos e encalhes;

No que tange às passagens de navegação principais elencadas pela Capitania Fluvial de Porto Velho - CFPV (2020) e que requerem maior atenção, tem-se 32 pontos elencados pela referida Capitania, sendo os seguintes: Capitarí, Borba, Ilha Guajará, Passagem Ganchos,

Pedral da Nova Estrela, Passagem Uruá, Passagem Uruazinho, Ilha do Jenipapo, Manicoré, Passagem Jatuarana, Entre a Ilha da Onça Grande e a Ilha da Onça Pequena, Enseada do Curuca, Passagem Marmelos, Passagem Baianos, Ilha da Conceição, Ilha das Três Casas, Paraná do Cintra, Paraná das Pupunhas, Paraíso, Salomão e Goiabol, Pedral de Mirari e Ponta da Gaivota, Passagem do Tambaqui, Papagaios, Pedral do Pombal, Cunia, Curicacas, São Carlos e Jamari, Capitari, Entre a Ilha de Mutum e VEADO, Ilha do Tamanduá, Ponte da Br-319 em Porto Velho e Praia de São Sebastiao.

4.3. CARACTERÍSTICAS ECONÔMICAS E DE MOVIMENTAÇÃO

O Rio Madeira é um dos principais eixos logísticos do norte do país e integra o Arco Norte. A região compreende os estados do Acre, Rondônia, Amazonas, Pará, Mato Grosso e Tocantins, e permite o escoamento de safras pelo rio Amazonas e seus afluentes da margem direita – que correm na direção sul-norte, dos cerrados do centro do país para a floresta Amazônica. Pelo Rio Madeira é feito o escoamento de produção agrícola, principalmente soja e milho, de Mato Grosso e Rondônia, e de insumos como combustíveis e fertilizantes, bem como alimentos e produtos produzidos na Zona Franca que partem de Manaus com destino a Porto Velho (RO) e Rio Branco (AC).

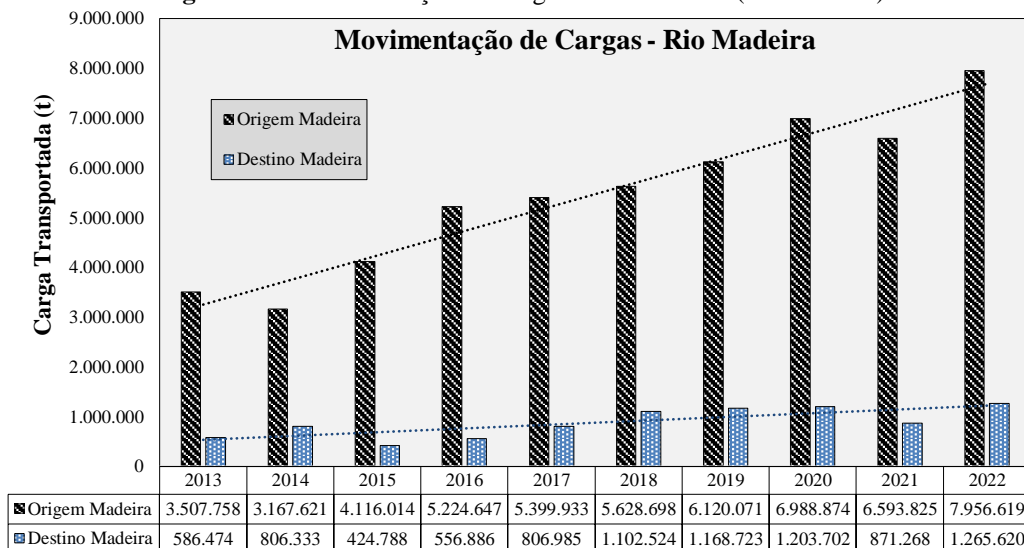
O tráfego de embarcações no Rio Madeira vem ganhando importância desde a década de 1990. Em função da implantação da nova fronteira agrícola de soja e milho na região Centro-Oeste do Brasil, a produção dessas matérias-primas passou de praticamente zero para um volume que exige para seu transporte, atualmente, um fluxo de comboios de balsas e empurradores de grande porte, além dos barcos mistos de passageiros e pequenas cargas, tendo como destinos principais: Itacoatiara, Manaus, Santarém, Porto Velho, Humaitá e Cujubinzinho.

A soja representou, portanto, 70,9% do total das cargas que seguiram no sentido jusante, transportada por caminhão até as instalações portuárias da cidade de Porto Velho, oriundas principalmente da região norte do Mato Grosso. De Porto Velho, esta carga pode ser escoada por Itacoatiara (AM) e Santarém (PA), principalmente.

De modo a evidenciar a relevância econômica do Rio Madeira no que concerne à expedição e recepção de cargas, recorreu-se ao Anuário Estatístico Aquaviário da Agência Nacional de Transportes Aquaviários, com a apresentação dos valores de movimentação de cargas, que em 2022 acumulam 7.956.619 toneladas movimentadas, representando um aumento

de 20,67% em relação ao ano anterior (ANTAQ, 2022). De modo a detalhar os valores em questão, evidencia-se na Figura 33 o gráfico com a evolução da movimentação de cargas no rio Madeira de 2013 a 2022, apresentando-se os valores de carga tendo como origem os portos do rio Madeira (evidenciados como Origem Madeira) e também com destino aos portos do rio Madeira (evidenciados como Destino Madeira), de modo a ilustrar o aumento expressivo nos valores anuais.


Figura 33 – Movimentação de Cargas – Rio Madeira (2013 a 2022)



Fonte: Autor (2023), adaptado de ANTAQ (2022).


Em complementação à abordagem supracitada, tem-se na Figura 34 a apresentação dos valores de movimentação por natureza da carga somente no ano de 2022 (consolidados pelo somatório de origem e destino), evidenciando os números expressivos referentes, sobretudo, ao transporte de granel sólido, com destaque aos granéis de origem vegetal.

Figura 34 – Movimentação por Natureza de Cargas – Rio Madeira (2022)



Fonte: Autor (2023), adaptado de ANTAQ (2022).

De modo a evidenciar a movimentação por estrutura portuária dentre as existentes ao longo das margens do rio Madeira, destaca-se na Figura 35 os valores de movimentação em toneladas no ano de 2022.



Fonte: Autor (2023), adaptado de ANTAQ (2022).

4.4. CARTAS NÁUTICAS

Sabe-se que as cartas náuticas se destacam por serem documentos cartográficos que descrevem levantamentos de massas d'águas navegáveis, como de áreas oceânicas, fluviais e lacustres. Estes documentos destacam-se como auxiliares da navegação, fornecendo informações de profundidades, sinalizações, perigos à navegação (bancos de areia, pedras submersas ou qualquer outro obstáculo), elementos de marés, natureza do fundo, fundeadouros e áreas de fundeio e qualquer outro elemento que influencia na segurança da navegação. Tendo em vista a importância desses documentos à navegação, destaca-se a necessidade de evidenciar as informações referentes a estas cartas náuticas para a hidrovia estudada. Nesse sentido, na

Tabela 14 destacam-se as informações referentes às cartas náuticas que descrevem a região do Rio Madeira.


Tabela 14 - Informações de Cartas Náuticas - Rio Madeira**CARTAS NÁUTICAS RIO MADEIRA**

Carta Nº	Título	Escala	1ª Edição
4500	SÉRIE A – TRECHO ITACOATIARA – BORBA	1:40 000	1999
4500	SÉRIE B – TRECHO BORBA – MANICORÉ	1:40 000	1999
4727	DA VILA BELMONTE À ILHA DO JENIPAPO	1:40 000	2019
4728	DE CURRALINHO AO FURO MATUPIRI	1:40 000	2019
4729	DO IGARAPÉ JATURANA À ENSEADA DO MANIVÃO	1:40 000	2018
4730	DE IGARAPÉ-AÇÚ A MANICORÉ	1:40 000	2018
4731	DE DEMOCRACIA À ILHA DA ONÇA GRANDE	1:40 000	2018
4732	DA ILHA DA ONÇA GRANDE AO PORTO	1:40 000	2018
4733	DO PORTO CURUÇÁ À ILHA DOS MARMELOS	1:40 000	2018
4734	DO PORTO GONDOMAR À ILHA DE SANTA CRUZ	1:40 000	2018
4735	DA COSTA DE SANTA CRUZ À COSTA SANTA ROSA	1:40 000	2018
4736	DA COSTA VALPARAÍSO À ILHA DA MEDITAÇÃO	1:40 000	2018
4737	DA ILHA DA MEDITAÇÃO À ILHA ITAPURU	1:40 000	2018
4738	DA BOCA DO JURARÁ À ENSEADA DO LAGO DO ANTÔNIO	1:40 000	2018
4739	DA ILHA DA CONCEIÇÃO À ILHA DO CARARÁ	1:40 000	2018
4740	DA ILHA CARAPANATUBA À COSTA CAMUJA	1:40 000	2018
4741	DA ILHA DAS TRÊS CASAS AO PORTO SÃO BENEDITO	1:40 000	2018
4742	DA COSTA SANTA JÚLIA À COSTA SÃO PEDRO	1:40 000	2018
4743	DA COSTA SÃO PEDRO À ILHA DAS PUPUNHAS	1:40 000	2018
4744	DO FURO DO PURUZINHO A HUMAITÁ	1:40 000	2018
4745	DA ILHA DO SALOMÃO A MIRARI	1:40 000	2018
4746	DA ILHA TAMBAQUÍ AO PORTO BANDEIRA BRANCA	1:40 000	2018
4747	DE CALAMA À ILHA ASSUNÇÃO	1:40 000	2018
4748	DA ILHA ASSUNÇÃO AO ESTIRÃO DOS PAPAGAIOS	1:40 000	2018
4749	DA ILHA TIRA- FOGO À ILHA DOS PERIQUITOS	1:40 000	2018
4750	DA ILHA DOS PERIQUITOS À BOCA DO MURIQUI	1:40 000	2018
4751	DA ILHA SOBRAL À COSTA VACURANGA	1:40 000	2018
4752	DA ILHA DOS VEADOS À COSTA DA SILVEIRA	1:40 000	2018
4753	DO PORTO DE AMPARO A PORTO VELHO	1:40 000	2018

Fonte: NPCF (2015).

Evidencia-se na Figura 36 a seguir a espacialização das cartas náuticas descritas na Tabela supracitada, destacando em vermelho a distribuição delas para a hidrovía em questão.

Figura 36 - Espacialização de Cartas Náuticas - Rio Madeira



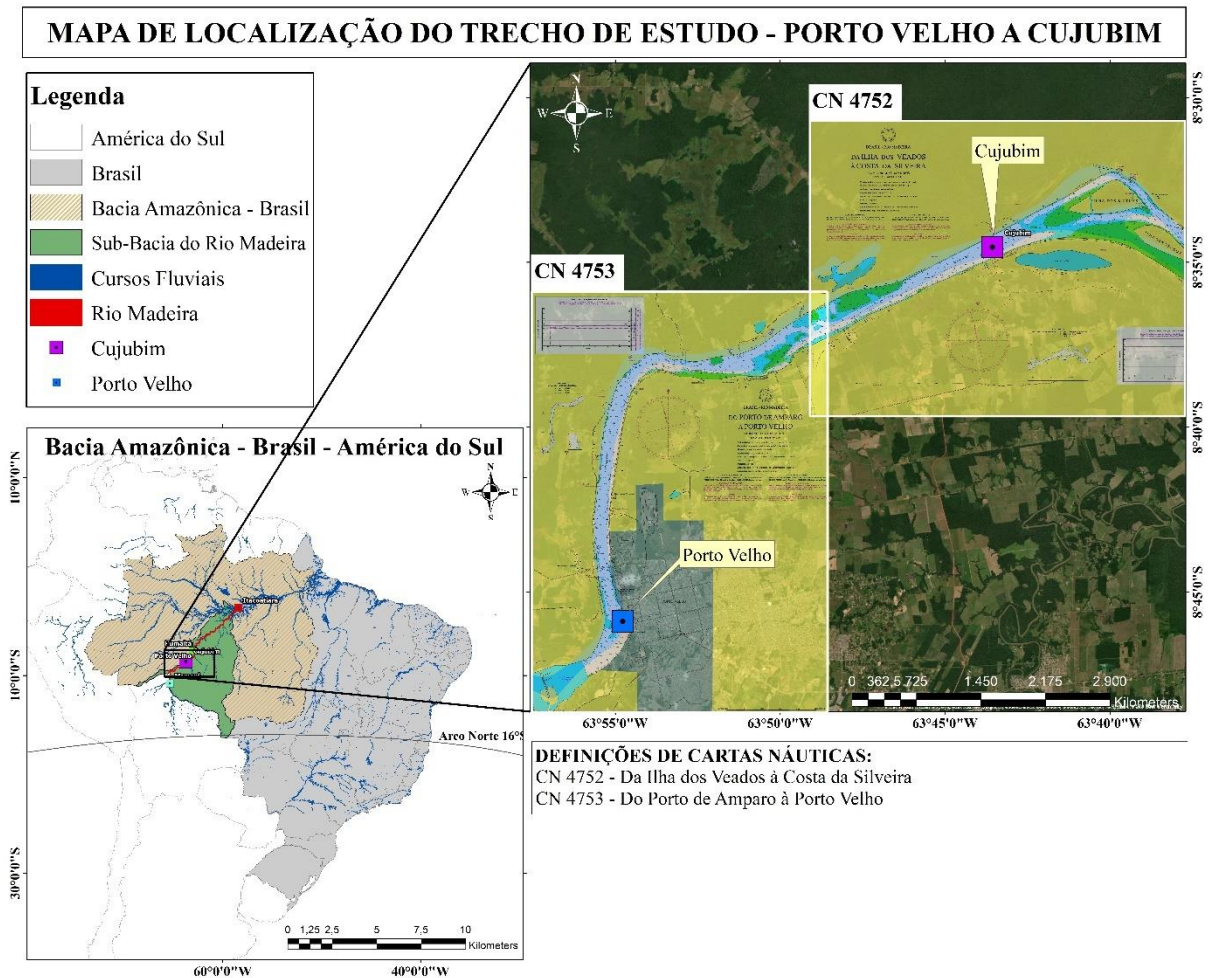
Fonte: (NPCF, 2015).

4.5. TRECHO DE ANÁLISE E APLICAÇÃO DOS MODELOS

Tendo em vista que a extensão navegável do rio madeira compreende a algo em torno de 1.000 quilômetros e que esta extensão se encontra representada em mais de vinte cartas náuticas, definiu-se a utilização de um trecho de análise correspondente a uma região menor, com o objetivo de simplificar a análise. Dessa forma, avaliou-se uma região iniciando no município de Porto Velho e finalizando na região de Cujubim, compreendendo a um trecho de, aproximadamente 40 quilômetros, configurando-se como um trecho importante de navegação

por ser a região em que as Estações de Transbordo de Carga encontram-se estruturadas. Nesse sentido, o trecho de análise em questão foi evidenciado na Figura 37.

Figura 37 – Mapa de Localização – Porto Velho a Cujubim



Fonte: Autor (2023).

Destaca-se que, apesar do trecho de análise corresponder uma pequena parcela do curso fluvial, esta é suficiente para a validação dos modelos propostos no presente estudo, haja vista que a região compreendida entre Porto Velho e Cujubim possui dados suficientes para a utilização em cada um dos módulos metodológicos apresentados nos tópicos supramencionados. Nesse sentido, esclarece-se e valida-se para cada módulo metodológico o uso deste trecho:

- **Módulo 01** – Modelo de Aquisição de Dados de Satélite: Os pixels referentes às bandas de satélite são de, aproximadamente, 5km. Portanto, os dados do trecho seriam suficientes para avaliação de precipitação, tendo em vista que engloba uma região maior que cinco vezes o tamanho do pixel;

- **Módulo 03** – Modelo de Previsão de Nível D’água: A região em questão possui dados pluviométricos e fluviométricos com estações suficientes para avaliação de dados significativa.
- **Módulo 04** – Modelo de Cálculo de Calados e Capac. de Carga: O referido módulo independe do trecho analisado.
- **Módulo 05** – Modelo de Definição de Condições Planialtimétricas: No trecho em questão tem-se duas cartas náuticas (nº 4752 e 4753), bem como dados de relevo de fundo e de trechos críticos definidos pela CFPV (Capitania Fluvial de Porto Velho), portanto, foram suficientes para aplicação.

4.6. PROVEDORES DE DADOS DE PRECIPITAÇÃO UTILIZADOS

Para o estudo em questão, realizou-se o processo de ranqueamento dos provedores de dados de precipitação via satélite para cinco satélites amplamente avaliados pela literatura, sendo estes: *CHIRPS – Climate Hazards Group InfraRed Precipitation*; *PERSIANN – Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks*; *ERA5 – Latest Climate Reanalysis Produced by ECMWF*; *CFSR – Climate Forecast System Reanalysis*; e *CMORPH – Climate Prediction Center (CPC) Morphing Technique*. O ranqueamento dos satélites em questão com base nos critérios metodológicos definidos encontra-se definido na Tabela 15.

Tabela 15 – Satélites Utilizados para Precipitações

Item	Satélite	Disponibilidade no GEE	Amplitude Geográfica	Espaço Amostral	Banda e Unidade	Resolução (metros)	Provedor de Dados	Ranking
1	CHIRPS	Sim	Global	1981-01-01 2022-01-01	mm/dia	5566	UCSB	1
2	PERSIANN	Sim	Global	1983-01-01 2022-06-30	mm/dia	27830	NOAA	2
3	ERA5	Sim	Global	1979-01-01 2022-06-01	m/dia	27830	ECMWF	3
4	CFSR	Sim	Global	1979-01-01 2011-03-01		55660	NOAA	4
5	CMORPH	Não	Global	2000-01-01 2015-01-01	mm/dia	NI	NOAA	5

Fonte: Autor (2023).

A partir do ranqueamento em questão, os dois primeiros satélites foram adotados para obtenção dos valores de precipitação via satélite a partir da ferramenta metodológica desenvolvida, com os resultados apresentados no tópico referente aos resultados esperados.

4.7. PROVEDOR DE DADOS DE TEMPERATURA UTILIZADOS

No que tange aos dados de temperatura superficial do mar (TSM) adotados no presente trabalho, fez-se uso do provedor de dados da *National Oceanic and Atmospheric Administration* (NOAA), faz parte do NOAA *Ocean Surface Bundle* (OSB) e fornece um registro de dados climáticos (CDR) de alta qualidade da temperatura da superfície do mar em oceanos sem gelo. Os valores de TSM são encontrados por meio da modelagem da variabilidade diurna em combinação com observações da temperatura da superfície do mar. Na Tabela 16 evidenciam-se as características do provedor de dados utilizado.

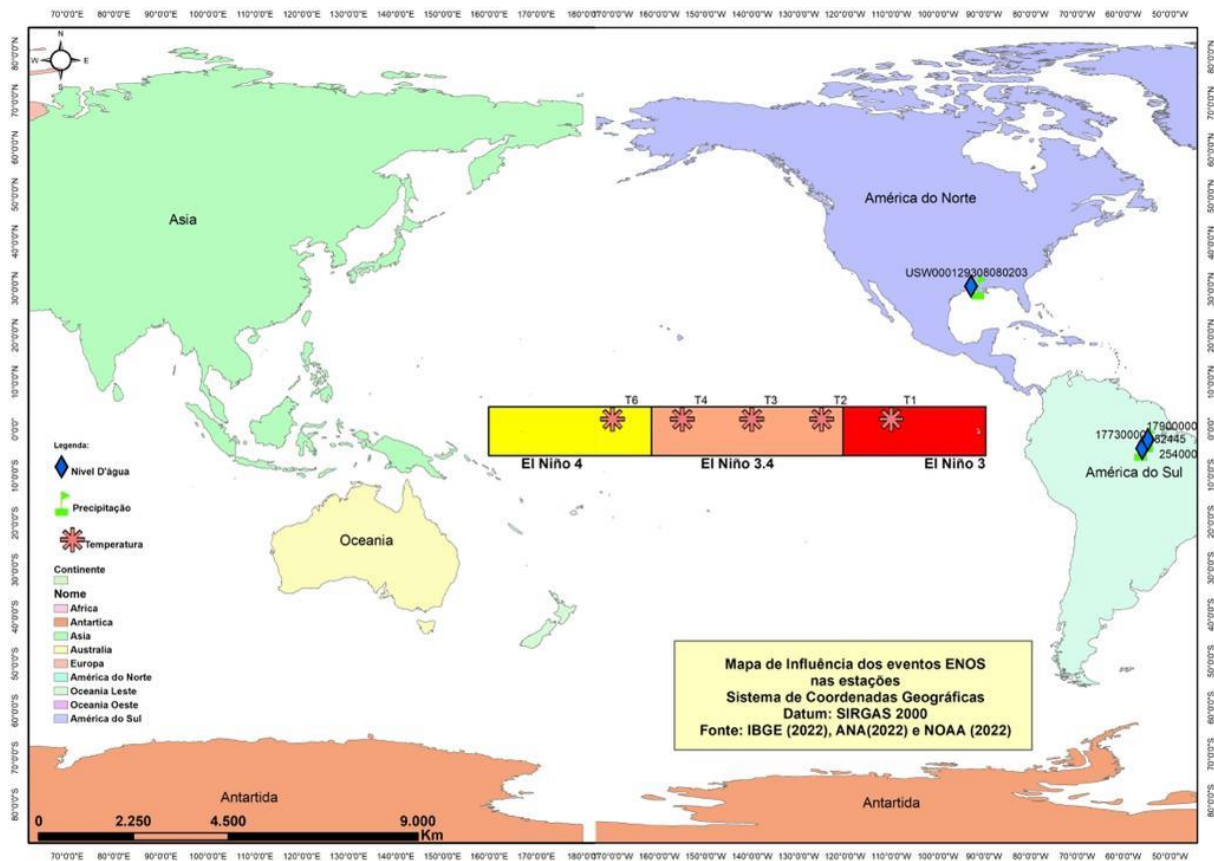
Tabela 16 – Satélite Utilizado para TSM

Item	Satélite	Dispon. no GEE	Amplitude Geográfica	Espaço Amostral	Banda e Unidade	Resolução (metros)	Provedor de Dados	Ranking
1	NOAA CDR WHOI	Sim	Global	1988-01-01 2021-08-31	°C	27830 metros	NOAA	1

Fonte: Autor (2023).

Os dados de temperatura foram aqisitados para seis localidades diferentes do pacífico com o objetivo intrínseco de captar as influências destas variáveis de temperatura a medida que se distanciam da Estação Alvo. Dessa forma, definiram-se seis pontos de temperatura conforme apresentados no mapa da Figura 38.

Figura 38 – Espacialização dos Pontos de Temperatura do Pacífico



Fonte: Autor (2023).

No que tange às coordenadas geográficas das estações de temperatura supracitadas, estas foram evidenciadas na Tabela 17.

Tabela 17 – Coordenadas Geográficas – Estações Base de Temperatura

Item	Estação	Latitude	Longitude
1	TSM1	-162,51	0,27
2	TSM 2	-177,98	0,08
3	TSM 3	-169,02	-0,62
4	TSM 4	-125,07	-0,62
5	TSM 5	-94,84	-1,32
6	TSM 6	-82,88	-1,67

Fonte: Autor (2023).

4.8. ESTAÇÕES PLUVIOMÉTRICAS E FLUVIOMÉTRICAS UTILIZADAS

Conforme apresentado nos tópicos metodológicos referentes à aquisição de dados de precipitação e posterior previsão de lâminas d'água, necessitou-se da definição de Estações Base e Estações Alvo.

Assim, definiu-se como Estação Alvo a região de Porto Velho, tendo-se na região cinco estações superficiais para obtenção de dados de precipitação, conforme apresentado na Tabela 18.

Tabela 18 – Estações de Precipitação Avaliadas

Estações de Precipitação Avaliadas – Porto Velho				
Código	Nome	Responsável	Latitude	Longitude
863007	PORTO VELHO - EMBRAPA / CPAF	SEDAM-RO	-8.795	-63.8458
863008	PORTO VELHO	ANA/CPRM	-8.7419	-63.9025
863000	PORTO VELHO	INMET	-8.7667	-63.9167
863012	UHE SANTO ANTÔNIO	SANTO ANTÔNIO	-8.75	-63.9169
863002	PORTO VELHO	DEPV	-8.7	-63.9167

Fonte: Autor (2023).

Em termos de nível d'água para a Estação Alvo, tem-se três estações com régua de medição, conforme evidenciado na Tabela 19.

Tabela 19 – Estações de Nível D'água Avaliadas

Estações Fluviométricas Avaliadas – Porto Velho				
Código	Nome	Responsável	Latitude	Longitude
15380000	UHE SANTO ANTÔNIO JUSANTE R-7	SANTO ANTÔNIO	-8.7822	-63.9303
15400000	PORTO VELHO	ANA/CPRM	-8.7483	-63.9169
15390000	UHE SANTO ANTÔNIO PORTO VELHO	SANTO ANTÔNIO	-8.7481	-63.9158

Fonte: Autor (2023).

Entretanto, a partir da avaliação detalhada das fontes de dados em questão, para a Estação Alvo, verificou-se que tanto para dados de precipitação, quanto para dados de lâmina d'água, as estações da Agência Nacional de Águas apresentaram melhores dados em termos de consistência e quantidade de dados, procedendo-se de modo a utilizar as estações 863008 e 15400000, para avaliação pluviométrica e fluviométrica, respectivamente.

No que tange às Estações Base, estas foram definidas como sendo uma região nas proximidades de Porto Velho, sendo esta em Cujubim, e uma segunda região distante de Porto Velho, na região de Itacoatiara, na foz do rio Madeira, de modo a ser possível avaliar a correlação destas variáveis com a Estação Alvo, sabendo que a primeira se encontra na mesma sub-bacia da EA e a segunda encontra-se distante desta sub-bacia.

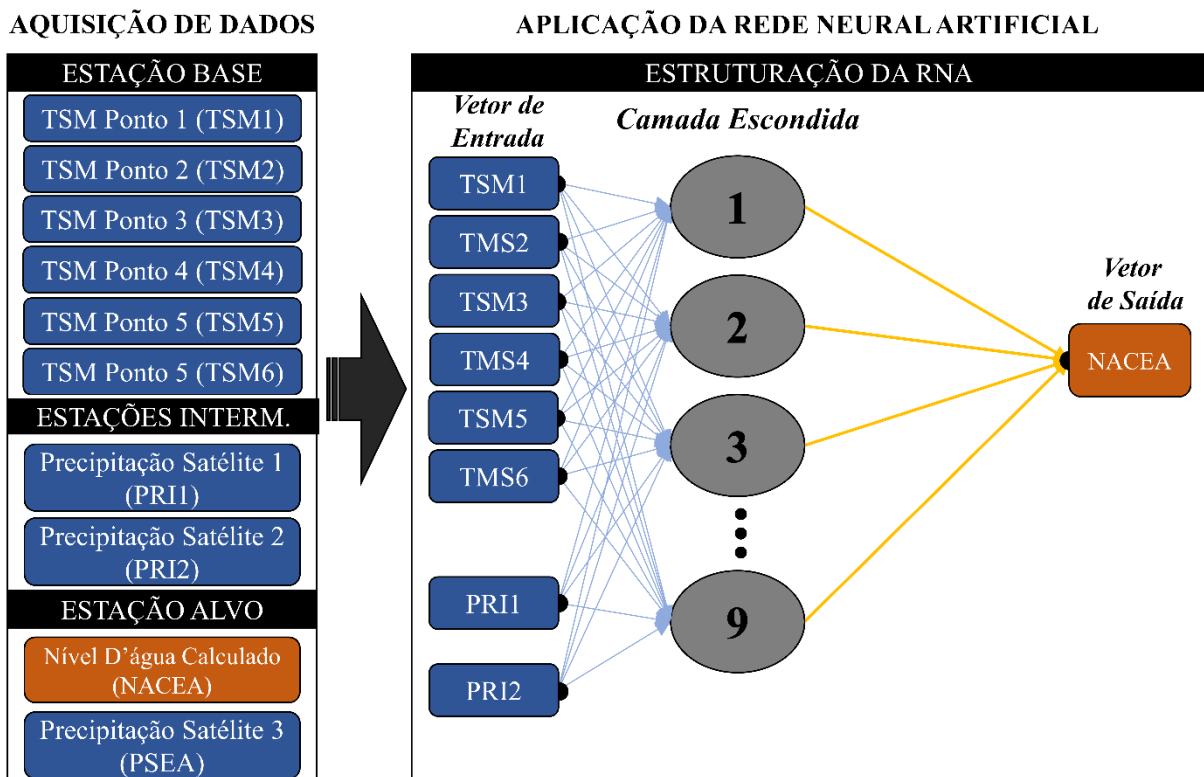
Os dados de precipitação para as Estações em questão foram apresentados nos resultados.

4.8.1. Modelo de Previsão de Níveis d'Água

No que tange ao modelo de previsão de níveis d'água utilizado, o processo de obtenção das previsões de lâmina d'água foi feito, portanto, por intermédio de um modelo RNA tipo Multi-Layer Perceptron (MLP) com a utilização do algoritmo Backpropagation (MLP-BP) e um modelo de Rede Neural Recorrente (RNR) do tipo *Long Short Term Memory (LSTM)*, com a utilização de algoritmos e funções implementados no software MATLAB® - 2014b e Python 3.8, com uso do *TensorFlow*, biblioteca de código aberto para *Machine Learning*.

A estruturação da Rede Neural Artificial encontra-se apresentada na Figura 39, com desenvolvimento de modelos com uma camada escondida e os números de neurônios sendo avaliados de 1 a 9 neurônios no primeiro momento, a partir de avaliações semelhantes apresentadas na literatura em Ren et al. (2020), Sun e Trevor (2018), Phan e Nguyen (2020) e Shang et al. (2019).

Figura 39 – Estruturação da Rede Neural Desenvolvida



Fonte: Autor (2023).

4.9. CENÁRIOS DE ANÁLISE E CONDICIONANTES PARA DIMENSIONAMENTO DO CANAL

No que concerne às entradas de dados das condições de contorno parametrizadas e os valores adotados para cada um, com base em análises empíricas e sabendo que o presente estudo de caso busca validar a metodologia adotada no *software DimChannel* propondo uma conformação para o trecho navegável do rio Madeira. Tendo por base os parâmetros que influenciam no dimensionamento dos canais de navegação conforme discrimina PIANC (2014), as condições de contorno de cada parâmetro adotadas pelo *software DimChannel* no dimensionamento e otimização do canal de navegação foram:

- I. Manobrabilidade da Embarcação: Tendo como base a navegação de comboios em vias interiores, estimou-se que a manobrabilidade destes é “moderada”
- II. Velocidade da Embarcação: Tendo como base a navegação de comboios em vias interiores, estimou-se que uma velocidade média “moderada”, entre 8-12 nós para este parâmetro.
- III. Vento pelo Través: Tendo como base as condições ambientais da referida via, estimou-se que os ventos naquela região são “brandos” em relação a sua influência nas embarcações.
- IV. Corrente Pelo Través: Tendo em vista que se trata de uma via interior, considerou-se correntes “moderadas”, estando entre 0,5 e 1,5 nós.
- V. Corrente Longitudinal: Tendo em vista que se trata de uma via interior, considerou-se correntes “moderadas”, estando entre 1,5 e 3 nós.
- VI. Altura Significativa de Onda: Tendo em vista que se trata de uma via interior, considerou-se “baixa” a influência de ondas na embarcação.
- VII. Auxílios à Navegação: Considerou-se que a via navegável em questão possui auxílio “moderado, com baixa visibilidade ocasional”.
- VIII. Tipo de Fundo: Com base em estudos geomorfológicos do Madeira, infere-se que o tipo de fundo em questão é “liso e mole”.
- IX. Profundidade da Hidrovia: Conforme informado anteriormente, a profundidade utilizada foi de “4,6 metros”.
- X. Nível de Periculosidade da Carga: Com base nas cargas transportadas com frequência na referida via, considerou-se o nível de periculosidade como “baixo”.
- XI. Densidade de Cruzamentos: Com base no conhecimento da região em questão, considerou-se uma densidade de cruzamentos “moderada”.
- XII. Largura para Distância de Margens: Considerou-se uma “margem de canal inclinada e com baixios”.

4.9.1. Underkeel Clearance – Folga Abaixo da Quilha (FAQ)

Considerando que, as características das vias navegáveis dos portos e terminais amazônicos e de seus acessos variam muito, o mesmo ocorrendo com as reações das embarcações em função de suas formas, carga, calado e propulsão, a segurança da navegação, com relação à profundidade, pode ser assegurada pela fixação de uma Folga Abaixo da Quilha (FAQ), que garanta, a qualquer tempo, uma margem de segurança adequada para a passagem do navio por uma área considerada crítica.

Acerca do FAQ considerado na análise, este foi calculado com base no equacionamento de Eryuzlu *et al.*(1994), obtendo-se um valor de 0,4 metros. Entretanto, tal valor não utilizado visto que a NPCF (2015) da CFPV, no Capítulo 05 referente aos parâmetros operacionais e calados máximos recomendados nos trechos de jurisdição, a referida Capitania estabelece o valor de 0,5m como Folga Abaixo da Quilha Mínima (FAQM) a ser observada.

4.9.2. Embarcação de Projeto

Para este estudo, especificamente para o caso de aplicabilidade ao Alto Madeira, de Porto Velho à Cujubim, foram adotadas as dimensões maiores e oficiais dos comboios fluviais de acordo com as diretrizes da Marinha do Brasil através do Comando do 9º Distrito Naval. No relatório sobre Regras e Procedimentos de Capitania de Rio - NPCF (2015) da Capitania Fluvial de Porto Velho (CFPV) nos itens 0603 e 0604 da referida norma, as dimensões máximas da embarcação (empurrador e barcaças) são definidas de modo obter-se o cenário mais desfavorável para a navegação no rio Madeira, com comprimento de 210 metros, largura de 37 metros e calados variando de acordo com o nível da régua do rio Madeira em Porto Velho, sendo o calado máximo recomentado de 2,30 metros, quando a régua estiver abaixo dos 4 metros. O transporte é realizado em comboio de 12 ou 16 chatas, a capacidade por comboio é de 18.000 a 23.000 toneladas, a velocidade de transporte varia entre 10 e 12 km/h, e a distância entre Porto Velho e o terminal em Itacoatiara é de 1.056 quilômetros (NPCF, 2015).

De posse das informações supracitadas, para condição de 12 chatas, dimensionou-se o comboio considerando-se as máximas dimensões permitidas, conforme evidencia a Tabela 20.

Tabela 20 – Características do Comboio Fluvial – 9 barcaças


Características	Empurrador	Box	Raked
Comp. Total	-	60.96 m	60.96 m
Boca	12.00 m	10.67 m	10.67 m
Pontal	3.50 m	4.27 m	4.27 m
Calado	2.20 m	3.50 m	3.50 m
Peso Leve	164.2 t	283 t	275 t

Cap. de Carga	81.42 t	2221.35 t	2100.91 t
Qtde.	1	3	6

Fonte: Autor (2023).

De modo a visualizar a configuração supracitada, na Figura 40 mostra-se a conformação do comboio em questão, com a evidência da formação de 3x3.

Figura 40 - Formação do Comboio Fluvial – 9 barcaças
210,23 m



Fonte: Autor (2023).

Em complementação à condição exposta, considerou-se também o comboio tipo considerando-se uma configuração típica de comboio de 3x4, totalizando 12 barcaças com máximas dimensões permitidas, conforme evidencia a Tabela 20.


Tabela 21 – Características do Comboio Fluvial – 12 barcaças

Características	Empurrador	Box	Raked
Comp. Total	-	60.96 m	60.96 m
Boca	12.00 m	10.67 m	10.67 m
Pontal	3.50 m	4.27 m	4.27 m
Calado	2.20 m	3.50 m	3.50 m
Peso Leve	164.2 t	283 t	275 t
Cap. de Carga	81.42 t	2221.35 t	2100.91 t
Qtde.	1	4	8

Fonte: Autor (2023).

Na Figura 40 evidencia-se a conformação do comboio crítico utilizado para o estudo, com a evidência da formação de 3x4.

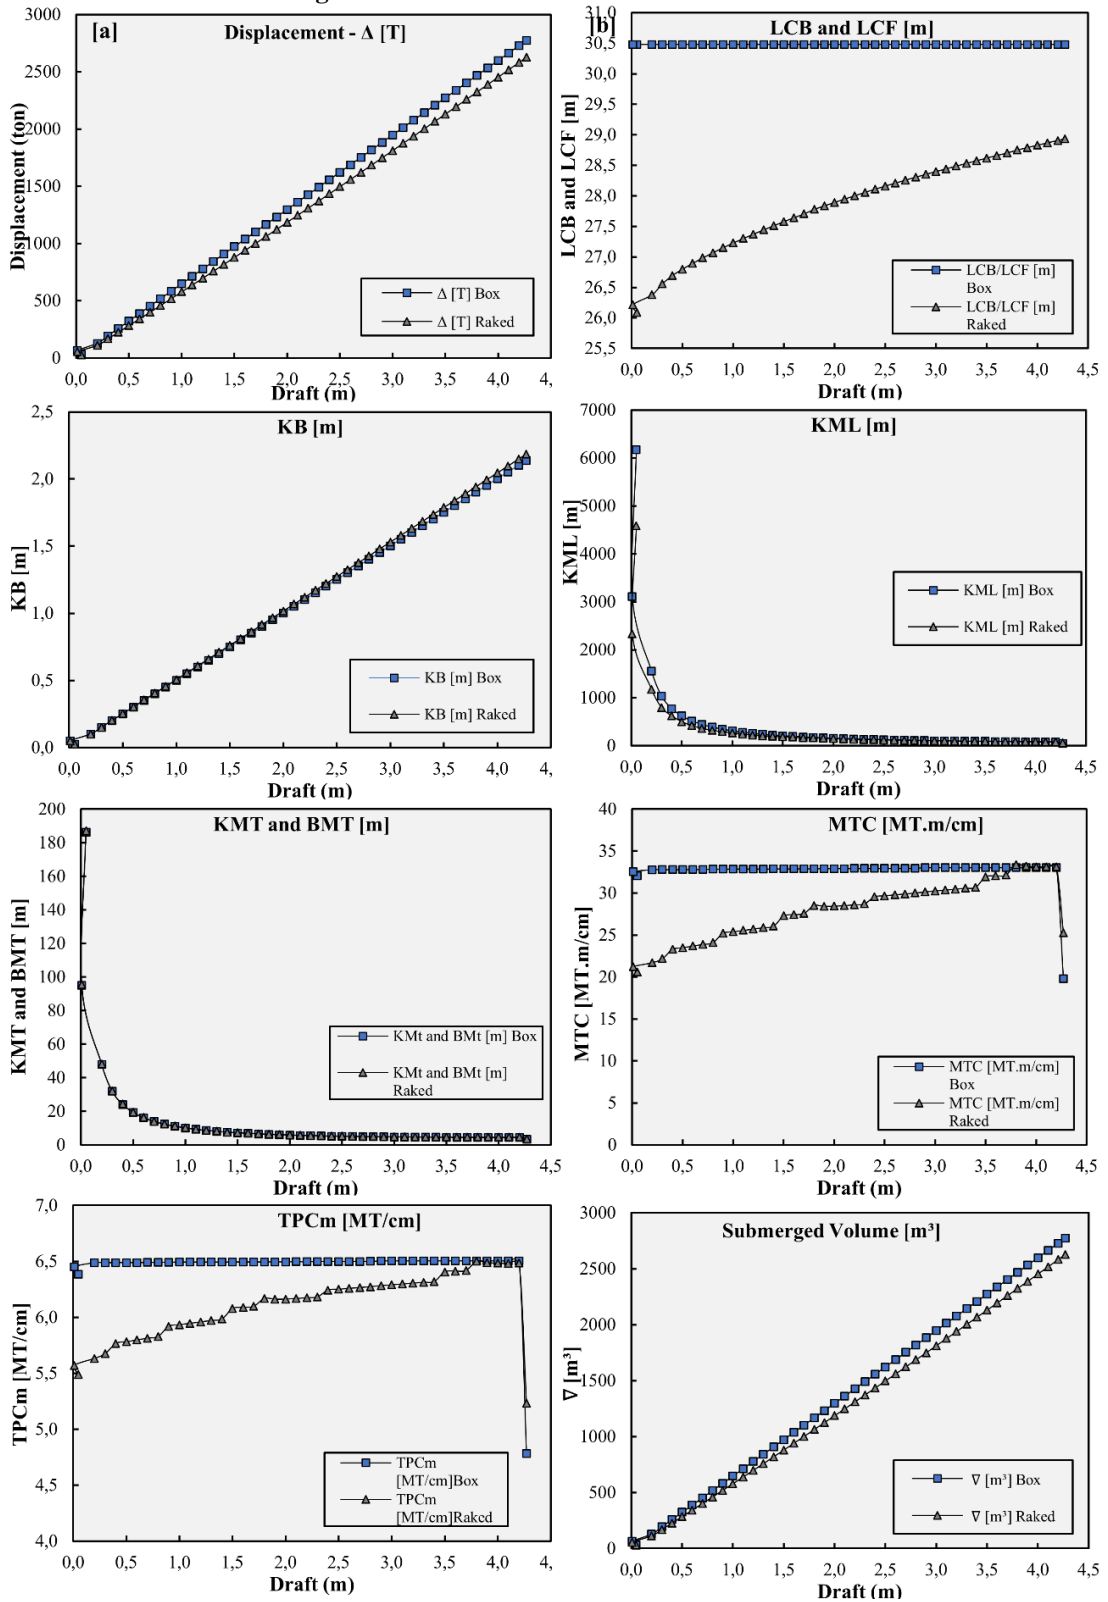
Figura 41 - Formação do Comboio Fluvial – 12 barcaças
210,19 m



Fonte: Autor (2023).

Com relação às características e propriedades hidrostáticas das barcaças que formam o comboio analisado, tem-se que elas foram determinadas para as barcaças do tipo *box* e para as do tipo *raked*, de acordo com as metodologias apresentadas anteriormente. A partir da referida aplicação metodológica, foi-se possível a obtenção dos dados relacionados ao deslocamento, LCB e LCF, KB, KML, KMT, BMT, MTC, TPC apresentados na Figura 42.

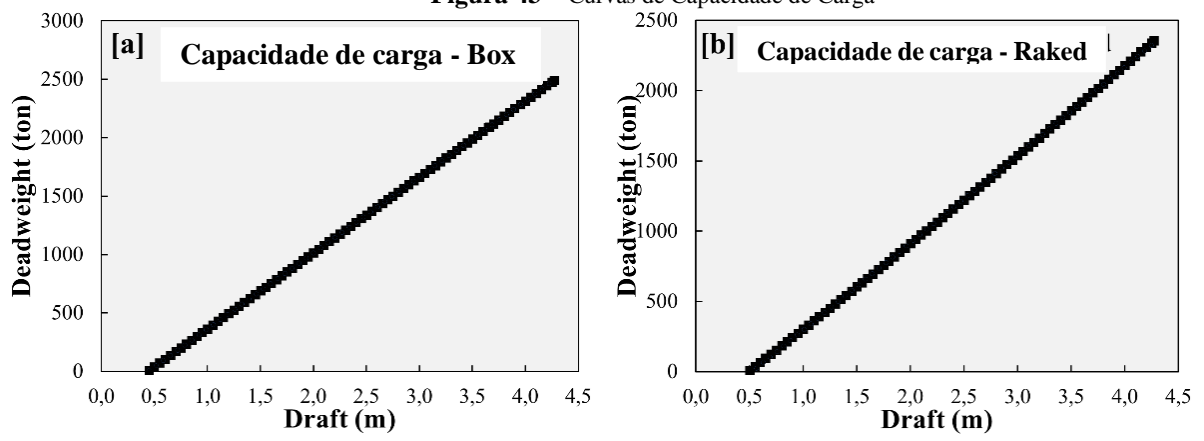
Figura 42 – Características Hidrostáticas do Comboio



Fonte: Autor (2023).

A partir dos deslocamentos calculados nas curvas hidrostáticas (Figura 42), e tendo os valores de peso leve, foi-se possível a determinação das curvas de capacidade de carga das barcaças, conforme evidenciado na Figura 43.

Figura 43 – Curvas de Capacidade de Carga



Fonte: Autor (2023).

5. RESULTADOS

Por intermédio da aplicação metodológica e avaliação das variáveis para o Estudo de Caso proposto para um trecho do Rio Madeira, em especial entre Porto Velho e Cujubim, foi possível obter resultados no que tange à cinco grupos de variáveis, conforme definido a seguir:

- **Precipitações via Satélite para Estação Alvo e Intermediárias:** A partir da aplicação metodológica do Módulo 01 apresentado anteriormente, fez-se possível a obtenção com uso do *script* no *Google Earth Engine* dos vetores históricos de precipitação para as localidades definidas como “Estação Alvo” e Estações Intermediárias”, sendo a Estação Alvo em Porto Velho e as Estações Intermediárias em Cujubim e Itacoatiara, na foz do rio Madeira.
- **Temperaturas via Satélite para Estações Base:** A partir da aplicação metodológica do Módulo 02 supracitado, adquiriram-se as séries históricas de dados de temperatura superficial do mar do Pacífico a fim de ter estas como entradas principais de aplicação da rede neural artificial utilizada.
- **Níveis d’água Calculados para a Estação Alvo:** Com os insumos de dados adquiridos nas duas etapas anteriores, fez-se possível a aplicação das redes neurais artificiais do tipo *Perceptron Multicamadas* e Recorrente, para obtenção dos valores de nível d’água previstos para estação alvo de Porto Velho, a fim de que este seja insumo para posterior modelagem planialtimétrica do trecho em estudo.
- **Avaliação de Condições Planialtimétricas:** Fazendo uso do software *DimChannel*, foi-se possível aferir as características geométricas mínimas necessárias para navegação segura em consonância com o preconizado nas recomendações internacionais de PIANC (2014).
- **Canal Projetado e Restrições de Navegação:** A partir de todos os resultados dos tópicos anteriores, fez-se possível a modelagem tridimensional do trecho da hidrovia em estudo a fim de verificar as zonas críticas de navegação e, assim, identificar quais são as restrições e gargalos operacionais que impedem a navegação plena em cenários críticos de navegação.
- **Calados Operacionais e Capacidades de Carga:** Com a definição das zonas críticas de navegação, definiram-se estes pontos como os de maior restrição de profundidade e, conseqüentemente, de maiores restrições de calado, ocasionando em capacidades de carga menores previstas para a hidrovia. Portanto, definiram-se tais valores.

5.1. RESULTADOS DA AQUISIÇÃO DE DADOS DE PRECIPITAÇÃO VIA SATÉLITE

Por intermédio da aplicação meticulosa do Módulo 01, cuja metodologia foi previamente apresentada, alcançou-se como primeiro resultado a obtenção dos vetores históricos de precipitação para as localidades designadas como "Estação Alvo" e "Estações Intermediárias". Utilizando-se do *script* desenvolvido no *Google Earth Engine*, coletaram-se esses dados valiosos e abrangentes para as áreas definidas como "Estação Alvo", situada em Porto Velho, juntamente com as "Estações Intermediárias" localizadas em Cujubim e Itacoatiara, ambas no rio Madeira, porém separadas por, aproximadamente, 800 km em linha reta.

Com a aplicação do referido *script*, aquisitaram-se informações valiosas no que tange às precipitação ao longo do tempo, permitindo uma compreensão mais profunda dos padrões climáticos nessas localidades específicas, visto que as estações *in situ* de temperaturas encontravam-se restritas a determinadas localidades e com significativa escassez de dados. Dados esses que são de importância crucial para inúmeras aplicações, como estudos hidrológicos, previsões meteorológicas e modelagem climática. Com eles disponíveis, pesquisadores e cientistas têm uma base sólida para investigar os impactos das mudanças climáticas e desenvolver estratégias de adaptação adequadas para essas áreas sensíveis.

Nesse cenário, destaca-se que os vetores de precipitação aquisitados foram captados tendo como satélites de referência os mais bem ranqueados na Tabela 15 e rerepresentados na Tabela 22, sendo *CHIRPS* e *PERSIANN*.


Tabela 22 – Satélites Melhores ranqueados definidos

Item	Satélite	Disponibilidade no GEE	Amplitude Geográfica	Espaço Amostral	Banda e Unidade	Resolução (metros)	Provedor de Dados	Ranking
1	CHIRPS	Sim	Global	1981-01-01 2022-01-01	mm/dia	5566	UCSB	1
2	PERSIANN	Sim	Global	1983-01-01 2022-06-30	mm/dia	27830	NOAA	2

Fonte: Autor (2023).

Nesse sentido, como forma de apresentar os primeiros resultados para avaliação do método, evidencia-se na Figura 44 os valores de precipitação *in situ*, comparado com precipitações aquisitadas pelos satélites *CHIRPS* e *PERSIANN* para a Estação de Porto Velho, sendo possível visualizar de maneira simplificada a convergência dos valores aquisitados em relação aos valores reais.

Figura 44 – Curvas de Precipitação Aquisitadas para EA



Fonte: Autor (2023).

Entretanto, de modo a fazer uso para *input* na RNA com apenas um vetor de precipitação disposto por apenas um satélite, definiu-se como provedor de dados principal o *CHIRPS*, com base no ranqueamento obtido e, sobretudo, tendo como respaldo a literatura em Cordeiro e Blanco (2021), Paca et al. (2020), Cavalcante et al. (2020) e Marinho e Rivera (2021), que utilizaram o satélite em questão para rios Amazônicos. Além do respaldo literário, avaliaram-se as métricas matemáticas a fim de consubstanciar a análise em questão em termos de RMSE e R², obtendo-se os valores dispostos na Tabela 23, reforçando a melhor aderência do CHIRPS para a localidade analisada.


Tabela 23 – Métricas Satélites CHIRPS e PersiANN
Avaliação de Métricas – Variáveis de Temperatura por Satélite

Métrica	CHIRPS	PersiANN
RMSE	0,14532021	0,19217783
R2	0,87807579	0,831148861

Fonte: Autor (2023).


Em complementação ao supracitado, a seguir apresentam-se os dados de saída específicos diretamente retirados a partir do *Google Earth Engine* para o satélite CHIRPS no período de 1981 a 2022 para a região de Porto Velho (PSEA), Cujubim (PRI1) e Itacoatiara (PRI2).

Figura 45 – Curvas de Precipitação Histórica para PSEA, PRI1 e PR2



De modo a avaliar um espaço da série histórica restrito aos últimos dois anos referentes ao treinamento da rede neural aplicada nos módulos metodológicos posteriores, tem-se na Figura 46 os valores de precipitação histórica de 2016 a 2018, sendo possível avaliar a característica sazonal do curso fluvial em questão, bem como a aderência da Estação PSEA com a Estação PRI1, devido a sua proximidade locacional, diferentemente da PRI2, localizada a mais de 800km de distância, sendo esta estação adotada nesta distância propositalmente com a finalidade intrínseca de avaliação de impactos posteriores da temperatura em regiões localizadas em diferentes sub-bacias.

Figura 46 – Curvas de Precipitação Histórica para PSEA, PRI1 e PR2 – 2016 a 2018



5.2. RESULTADOS DA AQUISIÇÃO DE DADOS DE TEMPERATURA VIA SATÉLITE

Por meio da aplicação minuciosa da metodologia apresentada no Módulo 02, obtiveram-se as séries históricas de dados de temperatura superficial do mar do Pacífico. Essas séries históricas foram adquiridas com o intuito de utilizá-las como principais entradas para a aplicação da rede neural artificial.


A coleta desses dados de temperatura superficial do mar é de extrema importância, uma vez que o Pacífico desempenha um papel fundamental na dinâmica climática global. As variações na temperatura do oceano Pacífico têm influência direta em fenômenos como o El Niño e a Oscilação Decadal do Pacífico, que podem ter impactos significativos no clima regional e global.

Ao adquirir essas séries históricas de temperatura superficial do mar do Pacífico, estamos obtendo uma visão abrangente e detalhada das flutuações térmicas ao longo do tempo nessa vasta região. Esses dados servirão como base essencial para alimentar a rede neural artificial, um poderoso modelo de aprendizado de máquina capaz de identificar padrões complexos e fazer previsões com base nas informações fornecidas.

A aplicação da rede neural artificial utilizando os dados de temperatura do mar do Pacífico como entrada permitiu uma análise mais aprofundada dos padrões climáticos e uma melhor compreensão dos fenômenos oceânicos e como estes afetam os padrões de temperatura e nível d'água em cursos fluviais amazônicos.

Nesse sentido, como forma de apresentar os dados em questão, apresenta-se na Figura 47 com a série histórica de temperaturas aquisitadas por intermédio da implantação da ferramenta computacional desenvolvida e utilizada, sendo obtidos os valores para as seis estações de temperatura: TSM1, TSM2, TSM3, TSM4, TSM5 e TSM6.


Figura 47 – Série Histórica de Temperatura – TSM1 a TSM6



Fonte: Autor (2023).

De modo a avaliar um espaço da série histórica restrito aos últimos dois anos referentes ao treinamento da rede neural aplicada nos módulos metodológicos posteriores, tem-se na Figura 48 os valores de temperatura histórica de 2016 a 2018.

Figura 48 – Série Histórica de Temperatura – TSM1 a TSM6 – 2016 a 2018



Fonte: Autor (2023).

5.3. NÍVEIS D'ÁGUA SIMULADOS

Com base nos dados coletados nas etapas anteriores, foi possível realizar a aplicação de redes neurais artificiais do tipo *Perceptron* Multicamadas e Recorrente. Essas redes foram utilizadas para obter previsões dos níveis de água na estação alvo de Porto Velho, visando utilizá-los como insumo para uma posterior modelagem planialtimétrica do trecho em estudo.

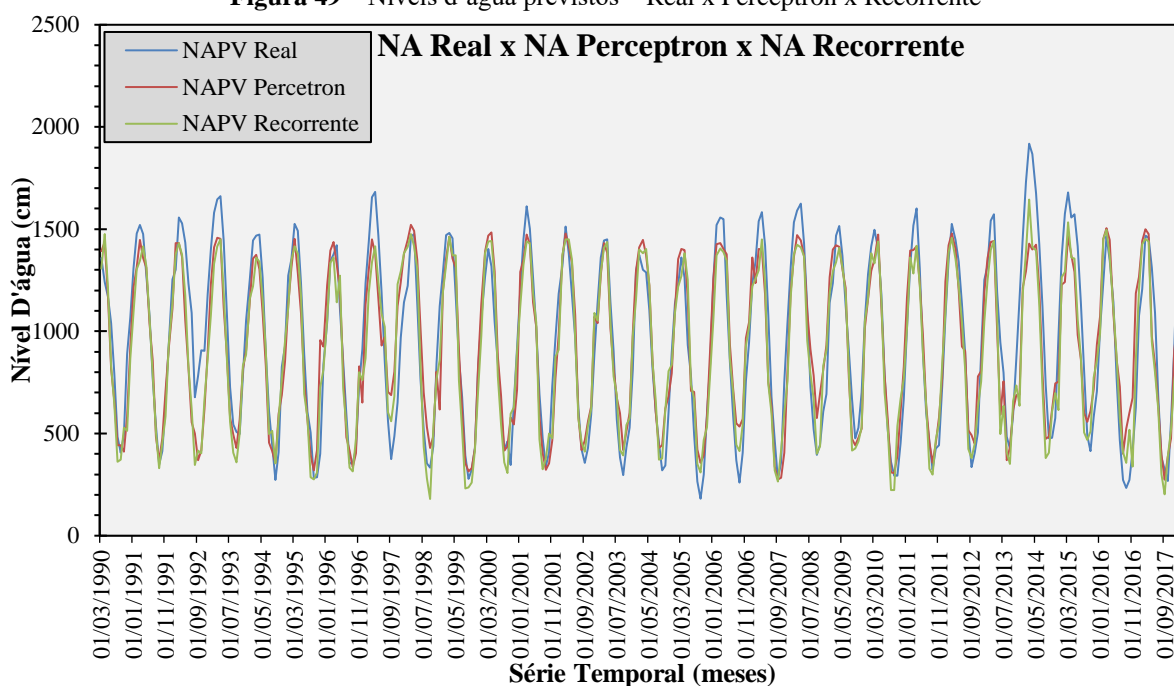
O uso das redes neurais artificiais representa uma abordagem sofisticada e avançada na análise e previsão de dados complexos, como os de níveis de água. Através do treinamento dessas redes com os insumos de dados adquiridos anteriormente, as RNA's foram capazes de aprender padrões e relações, permitindo a geração de previsões confiáveis e precisas.

A aplicação do *Perceptron* Multicamadas e do modelo Recorrente tornou possível extrair informações valiosas sobre os níveis de água esperados na estação alvo de Porto Velho. Essas previsões são cruciais para o desenvolvimento de uma modelagem planialtimétrica detalhada do trecho em análise, pois fornecem dados fundamentais sobre a variação do nível da água ao longo do tempo, tendo como objetivo principal mapear e compreender as características topográficas e altimétricas da área.

Essa abordagem combinada, utilizando as redes neurais artificiais e a modelagem planialtimétrica, oferece uma base sólida para análises mais aprofundadas e tomadas de decisão relacionadas ao gerenciamento de recursos hídricos, previsões de enchentes, planejamento de infraestrutura em áreas suscetíveis a variações no nível da água e, principalmente, a definição precisa das capacidades de carga para a hidrovia levando em consideração cenários específicos de navegação em períodos de cheia e períodos de estiagem.

Dessa forma, na Figura 49 evidenciam-se os valores de nível d'água previstos e obtidos para ambas as redes neurais artificiais, que possuem características específicas, mas que utilizaram os mesmos dados de entrada e a mesma saída esperada. A Figura 49 em questão apresenta a série histórica completa para o período analisado, de março de 1990 a março de 2018.

Figura 49 – Níveis d’água previstos – Real x Perceptron x Recorrente



Fonte: Autor (2023).

Em complementação ao supracitado, a fim de avaliar a convergência dos dados, avaliaram-se os resultados em termos de métricas estatística, tendo como resultado que ambas as redes neurais apresentaram valores de RMSE, MSE e MAE relativamente baixos, indicando que as previsões dos níveis d’água estão próximas dos valores reais. Isso sugere que as redes neurais são eficazes na captura de padrões e relações nos dados para fazer previsões razoavelmente precisas. No entanto, é importante ressaltar que, mesmo com métricas de erro baixas, sempre há uma margem de erro nas previsões. Portanto, é necessário considerar essa margem de incerteza ao utilizar as previsões em tomadas de decisão ou análises críticas.

De modo a evidenciar tais métricas, apresenta-se na Tabela 24 e Tabela 25 os valores de RMSE, MSE, R² e MAE para ambas as previsões obtidas, levando em consideração 10% dos dados e também 100% dos dados, isto é, prevendo apenas uma parte deles ou prevendo a série histórica completa.

Tabela 24 – Métricas Estatísticas - *Perceptron* Multicamadas
Avaliação de Métricas – *Perceptron* Multicamadas

Métrica	10% dos Dados	100% dos Dados
RMSE	0,11532021	0,09217783
MSE	0,013298751	0,008496752
R2	0,74807579	0,831148861
MAE	0,09380883	0,0725808

Fonte: Autor (2023).

Tabela 25 – Métricas Estatísticas – Rede Neural Recorrente
Avaliação de Métricas – Rede Neural Recorrente

Métrica	10% dos Dados	100% dos Dados
RMSE	0,10331342	0,08905495
MSE	0,010673664	0,007930784
R2	0,797804015	0,842396042
MAE	0,082979284	0,07011797

Fonte: Autor (2023).

Com base nos resultados apresentados nas Tabela 24 e Tabela 25, torna-se evidente que a Rede Neural Recorrente teve um desempenho superior em comparação a *Perceptron*, uma vez que apresentou valores menores de RMSE, MSE e MAE, em consonância com a literatura apresentada por De Mendonça; Blanco & de Oliveira Carvalho (2023), para variáveis de precipitação.

Essas métricas indicam que a Rede Neural Recorrente conseguiu fazer previsões mais precisas e com menor erro em relação aos valores reais de nível d'água. Os resultados obtidos para a Rede Neural Recorrente mostraram que, tanto para 10% dos dados previstos quanto para 100% dos dados previstos, os valores de RMSE, MSE e MAE foram menores em comparação com os resultados da *Perceptron*. Isso sugere que a Rede Neural Recorrente foi capaz de capturar melhor os padrões e relacionamentos nos dados, resultando em previsões mais acuradas.


Além disso, a Rede Neural Recorrente apresentou valores mais altos de R^2 em comparação com a *Perceptron*. O R^2 é uma métrica que indica a proporção da variabilidade dos dados que é explicada pelo modelo. Portanto, quanto maior o valor de R^2 , melhor o modelo se ajusta aos dados. Nesse sentido, os resultados indicam que a Rede Neural Recorrente teve um melhor ajuste aos dados em relação a *Perceptron*.

Em resumo, os resultados das métricas estatísticas, como RMSE, MSE, MAE e R^2 , indicam que a Rede Neural Recorrente obteve um desempenho superior a *Perceptron* na previsão dos níveis d'água. Esses resultados demonstram a eficácia da Rede Neural Recorrente em capturar os padrões dos dados e fornecer previsões mais precisas, sendo os dados deste modelo utilizado para a posterior definição dos valores de previsão de capacidade de carga.

Em complementação a análise supracitada, a fim de avaliar a aderência dos dados para um período específico, tem-se na Figura 50 a apresentação dos vetores de nível d'água para os anos de 2016 a 2018, sendo possível avaliar características específicas acerca da flutuabilidade destes valores. Isto é, torna-se possível a avaliação da característica sazonal das lâminas, em consonância com a configuração sazonal de precipitações na região, visto que parte desta

precipitação escoada para os cursos fluviais, contribuindo para a variabilidade da profundidade, conforme pode ser visto na **Figura 50**, havendo períodos de estiagem (iniciados em julho e seguindo até meados de novembro) e períodos de cheia (iniciados em meados de dezembro e seguindo até os meses de maio e junho).

Figura 50 – Níveis d’água previstos – Real x *Perceptron* x Recorrente – 2016 a 2018



Fonte: Autor (2023).

Com base nos dados supracitados, faz-se possível a avaliação das características planialtimétricas do curso fluvial em questão, avaliando-se posteriormente os vetores de capacidade de carga obtidos.

5.4. CARACTERÍSTICAS PLANIALTIMÉTRICAS

Para obtenção dos resultados referentes ao estudo de caso do trecho inicial do Rio Madeira, fez-se uso das funcionalidades do software *DimChannel* desenvolvido, com a inserção das entradas de dados e a, conseqüente, obtenção dos valores de largura em trechos retos e curvos para o cenário e condições de contorno de análise. No que concerne às informações da embarcação, destacam-se na Figura 51 os *inputs* de dados preenchidos dispostos na primeira interface de preenchimento de dados do programa.

Figura 51 - Tela de Informações da Embarcação

The image shows two sections of a software interface for vessel information. The first section, 'Dimensões da Embarcação', contains the following fields: 'Tipo de Embarcação' (Comboio), 'Classificação da Embarcação' (dropdown), 'Comprimento Total (Loa):' (210.19), 'Calado de Projetos (T):' (3.5), 'Boca (B):' (42.68), 'TPB:' (2569.68), 'Comprimento entre Perpendiculares (Lpp):' (205), 'Deslocament:' (3496.2), 'Trim a vante:' (0), 'Trim a ré:' (0), and 'Formação do Comboio' (3x4). The second section, 'Dados da Embarcação', contains: 'Velocidade do Navio:' (Moderada), 'Nível de Periculosidade da carga:' (Baixo), 'Auxílios à Navegação:' (Moderado), 'Manobrabilidade da Embarcação:' (Moderada), 'Angulo do leme' (30), and 'Coeficiente de bloco' (0.8). An 'Adicional:' column shows '0' for the first four items.

Dimensões da Embarcação	
Tipo de Embarcação	Comboio
Classificação da Embarcação	
Comprimento Total (Loa):	210.19
Calado de Projetos (T):	3.5
Boca (B):	42.68
TPB:	2569.68
Comprimento entre Perpendiculares (Lpp):	205
Deslocament:	3496.2
Trim a vante:	0
Trim a ré:	0
Formação do Comboio	3x4

Dados da Embarcação			
Velocidade do Navio:	Moderada	Adicional:	0
Nível de Periculosidade da carga:	Baixo	Adicional:	0
Auxílios à Navegação:	Moderado	Adicional:	0
Manobrabilidade da Embarcação:	Moderada	Adicional:	0
Angulo do leme	30		
Coeficiente de bloco	0.8		

Fonte: Autor (2023).

Na segunda etapa de preenchimento no software, com base na tela da Figura 52, inseriram-se as informações referentes à hidrovia e seus parâmetros influenciadores, bem como informações de correntes e ventos, conforme evidenciado na Figura 52.

Figura 52 - Tela de Informações da Hidrovia

The image shows a software window titled 'DimChannel - Informações da Hidrovia'. It contains two main sections: 'Dados sobre a Hidrovia' and 'Dados sobre Correntes e Ventos'. The first section includes: 'Profundidade:' (4), 'Tipo de Fundo:' (Liso e Mole), 'Tipo de Margem:' (Inclinadas e l), 'Densidade de Cruzamentos:' (Moderada), and 'Navegação:' (radio buttons for 1 Sentido and 2 Sentidos). The second section includes: 'Vento pelo Través:' (Baixo), 'Corrente pelo través:' (Moderada), and 'Corrente Longitudinal:' (Moderada). An 'Adicional:' column shows '0' for the first four items in each section. At the bottom, there are buttons for 'Informações de Preenchimento' and 'Gerar Resultados'.

Dados sobre a Hidrovia:			
Profundidade:	4	Adicional:	0
Tipo de Fundo:	Liso e Mole	Adicional:	0
Tipo de Margem:	Inclinadas e l	Adicional:	0
Densidade de Cruzamentos:	Moderada	Adicional:	0
Navegação:	<input type="radio"/> 1 Sentido <input checked="" type="radio"/> 2 Sentidos	Adicional:	0

Dados sobre Correntes e Ventos:			
Vento pelo Través:	Baixo	Adicional:	0
Corrente pelo través:	Moderada	Adicional:	0
Corrente Longitudinal:	Moderada	Adicional:	0

Fonte: Autor (2023).

Após a inserção completa dos dados de entrada necessários para o dimensionamento do trecho analisado, obtiveram-se os dados de saída na interface de resultados, como mostrado na Figura 53. Os valores encontrados foram obtidos com base na aplicação otimizada das formulações dispostas em PIANC (2014), bem como a partir das formulações para raio de curvatura e largura da faixa de trajetória varrida, obtidas por intermédio de regressões múltiplas não lineares com estimativa de parâmetros dada por mínimos quadrados ordinários generalizados, conforme evidenciado na metodologia.

Figura 53 - Tela de Resultados para o Trecho



Fonte: Autor (2023).

Os valores supracitados configuram-se como de fundamental importância para a desenvolvimento do canal de navegação, referente aos últimos resultados obtidos para a presente pesquisa.

5.5. CANAL PROJETADO E RESTRIÇÕES DE NAVEGAÇÃO

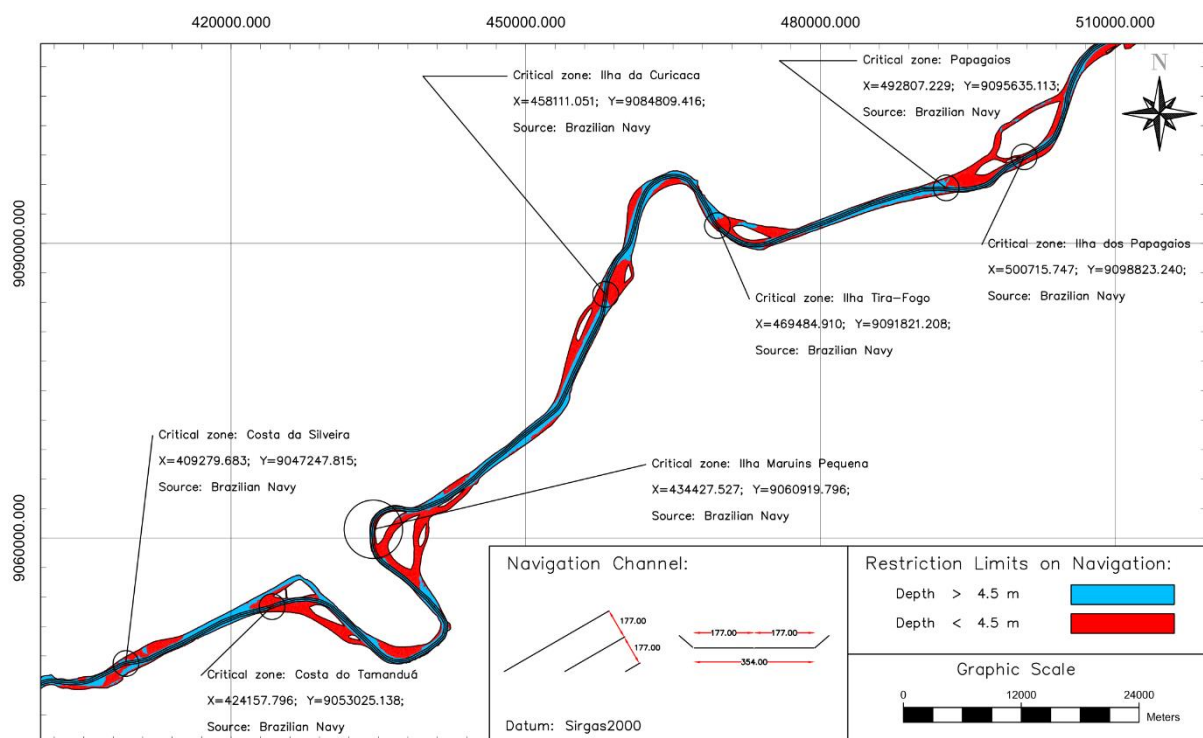
Os resultados evidenciados na Figura 53, obtidos a partir da utilização do *DimChannel*, proporcionaram a concepção do traçado do canal de navegação do trecho, com base na definição de faixas de navegação, fazendo uso de levantamentos hidrográficos indicados nas cartas náuticas do trecho em análise, sendo convertidos em coordenadas de pontos batimétricos por meio do Software Civil 3D.

Para a modelagem do canal de navegação, após as análises normativas e de seus principais parâmetros balizadores, foram utilizadas as informações em sua construção descritas na Figura 51, estando em conformidade com a normativa PIANC Report n° 121-2014.


Outro ponto de extrema relevância possibilitado a partir da determinação dos níveis d'água do rio e, por conseguinte, de suas capacidades de movimentação de carga, trata-se da aferição dos trechos críticos de navegação observados nos cenários de menores profundidades. Estes trechos críticos ocorrem não somente por limitações de profundidade, mas também de limitações de largura oriundas da redução dos níveis d'água. Dessa forma, a fim de espacializar tais trechos críticos, foi-se possível a determinação de dois cenários de análise.

O primeiro cenário, denominado “favorável”, consistiu nos meses de março a julho, o e o segundo, denominado de “crítico”, consistiu nos meses de agosto a novembro. A modelagem dos rios se deu a partir da elaboração do modelo digital de elevação, que possibilitou a evidenciação dos gargalos de navegação, bem como o canal navegável, conforme apresentado na Figura 54 para o cenário “crítico” e na Figura 55 para o cenário “favorável”, com as regiões em vermelho representando locais em que existem impeditivos a navegação naquele cenário e as regiões em azul, por sua vez, representando os locais com possibilidade de navegação.

Figura 54 – Modelagem Digital de Elevação – Período de Estiagem



Fonte: Autor (2023).



Em relação aos cenários analisados, pode-se perceber que nos meses de agosto e novembro, em virtude de terem menores valores de lâminas d'água, as regiões em vermelho são mais afloradas, representando maiores restrições de navegação. Enquanto nos meses de março a julho, as regiões em vermelho são reduzidas, sem restrições de navegação.

A partir da evidenciação dos trechos observada na Figura 54 e Figura 55, pode-se perceber a existência de 7 trechos críticos principais obtidos pela modelagem:

- **Costa da Silveira:** Apresentando restrições de largura em trecho reto, bem como restrições de profundidade no cenário de estiagem.
- **Costa do Tamanduá:** Apresentando restrições significativas de profundidade e, conseqüentemente, de largura em trecho reto, com obstrução significativa no canal de navegação no período de estiagem, atingindo profundidades próximas de 2,8 metros, implicando em condições extremamente desfavoráveis de navegação.
- **Ilha Maruins Pequena:** Restrições de raios de curvatura e larguras em trechos curvos, bem como restrições pontuais nas extremidades das margens do canal de navegação.
- **Ilha de Curicaca:** Restrições pontuais de profundidade no canal de navegação, bem como pontos de restrições de largura em trechos retos.

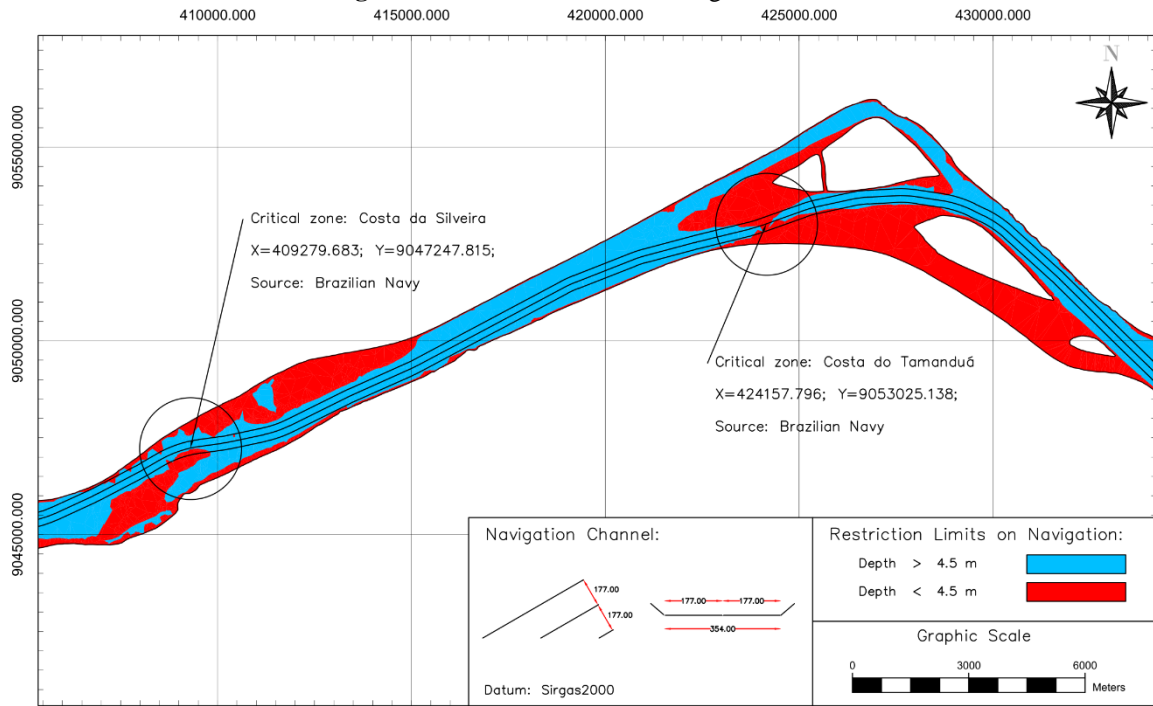
- **Ilha Tira-Fogo:** Restrições pontuais de profundidade no canal de navegação, bem como pontos de restrições de largura em trechos retos.
- **Papagaios e Ilha dos Papagaios:** Restrições de raios de curvatura e larguras em trechos curvos, bem como restrições pontuais nas extremidades das margens do canal de navegação.

As regiões com restrição destacadas na espacialização do layout do canal de navegação caracterizam-se como zonas críticas com restrições de profundidade já apontadas pela Marinha do Brasil, fato este que corrobora com os resultados obtidos. Ao avaliar as publicações da NPCF (2015) e CFPV (2020) nas Normas e Procedimentos, bem como nos Avisos aos Navegantes, tem-se destaque para quatro trechos críticos principais entre os municípios de Porto Velho e Calama (RO); Travessia do Tamanduá, Travessia dos Papagaios, e Travessia de Curicacas, entre Porto Velho e Humaitá, sendo evidenciados no cenário de estiagem como regiões com restrições de largura e profundidade, sendo os mesmos previamente apontados pela modelagem desenvolvida.

É evidente que essas zonas apresentaram restrições de calado para a referência de nível adotada nessa ambientação de análise, e para o tráfego de barcas em mão dupla essas restrições ainda seriam mais acentuadas, conforme se observa a faixa vermelha contida dentro da projeção do canal de navegação. Percebe-se, portanto, que para os valores obtidos a partir do dimensionamento da largura em trechos retos e curvos no software *DimChannel*, o traçado do canal de navegação evidencia e reafirma as zonas críticas já informadas pela Marinha do Brasil, com restrições de profundidade e largura nos trechos em que a faixa vermelha adentra nos limites do canal de navegação traçado.

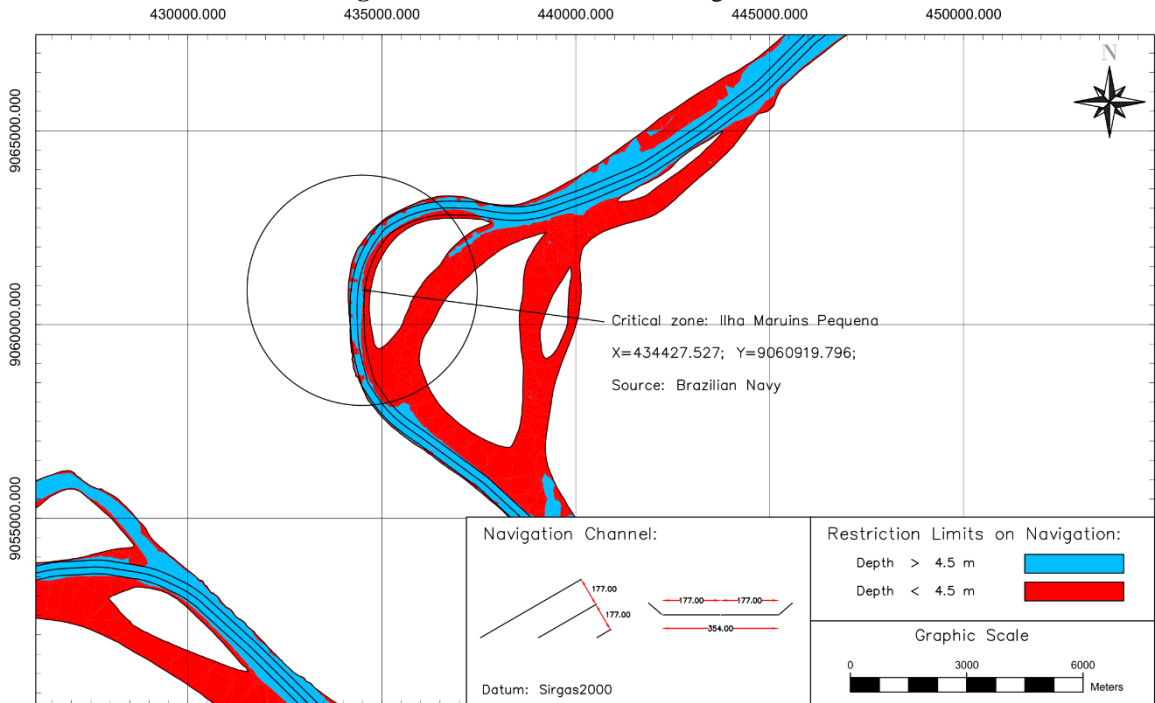
Como forma de apresentar o detalhamento das regiões críticas de navegação previamente discutidas, tem-se as imagens que seguem apresentando o detalhamento destas. Na Figura 56 evidenciam-se os dois trechos críticos mais próximos de Porto Velho, sendo estes Costa da Silveira e Costa do Tamanduá. Na Figura 57 mostra-se o trecho crítico de Ilha Maruins Pequena. Em complementação, na Figura 58 apresentam-se os trechos críticos da Ilha de Curicaca e Ilha Tira-Fogo. Por fim, na Figura 59 denotam-se as regiões com navegação insegura intituladas Papagaios e Ilha dos Papagaios.

Figura 56 – MDE Período de Estiagem – Trecho 01



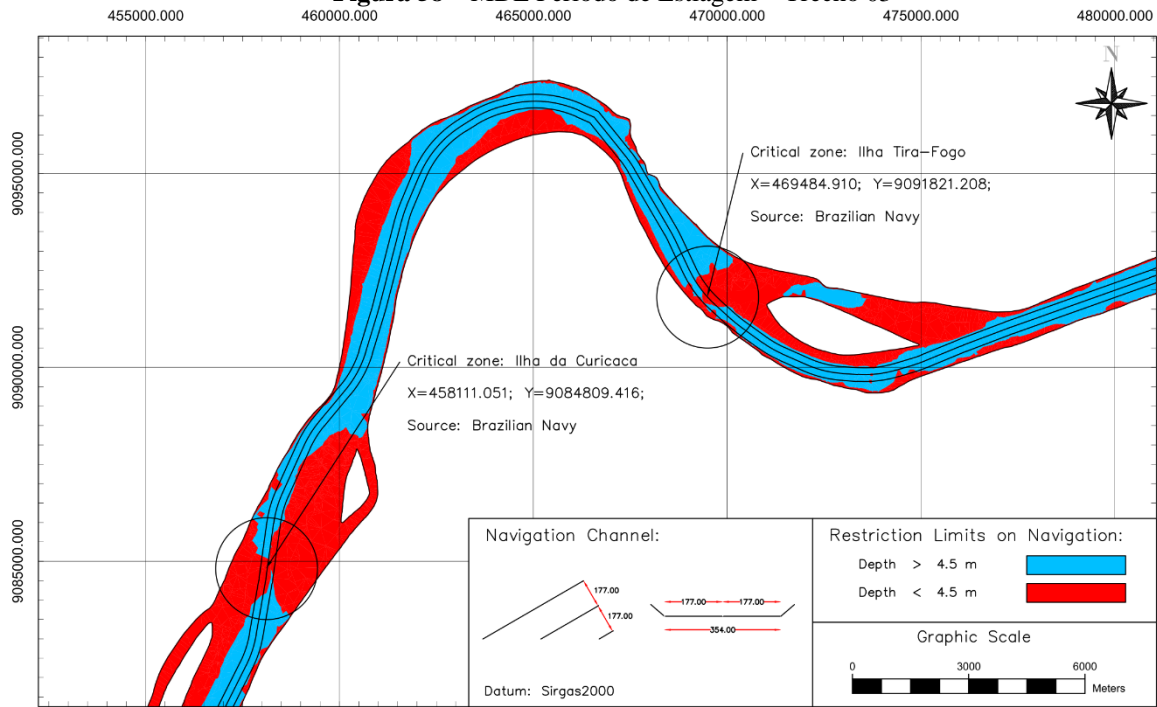
Fonte: Autor (2023).

Figura 57 – MDE Período de Estiagem – Trecho 02



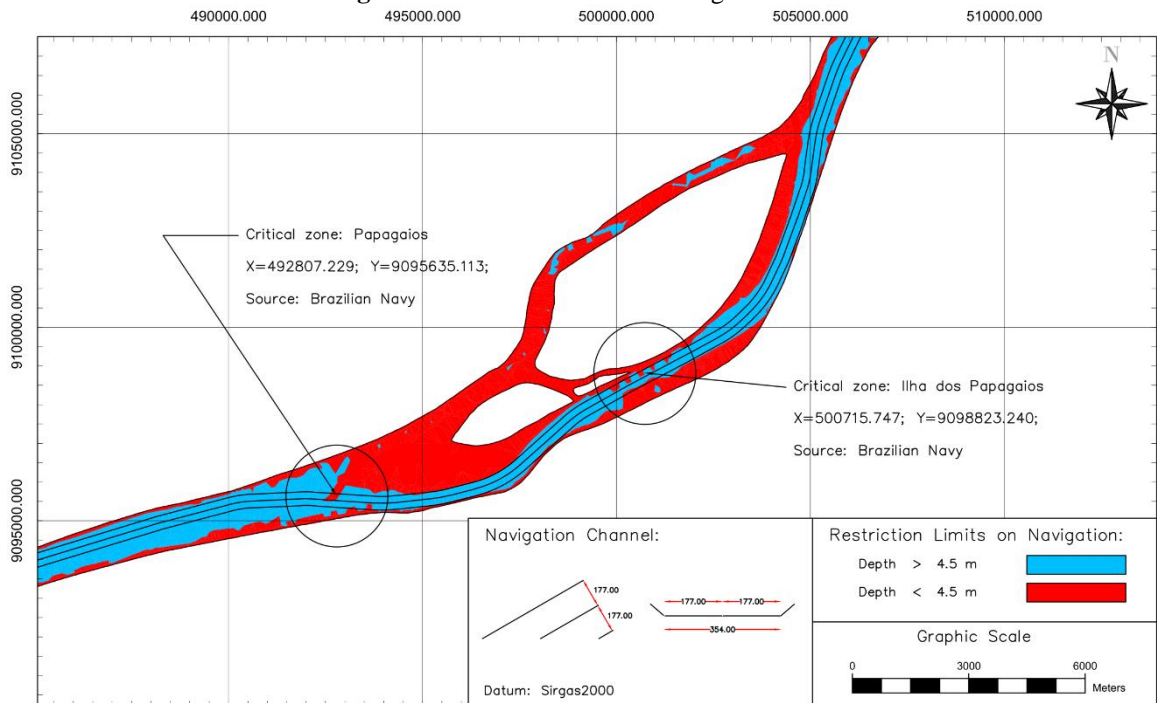
Fonte: Autor (2023).

Figura 58 – MDE Período de Estiagem – Trecho 03



Fonte: Autor (2023).

Figura 59 – MDE Período de Estiagem – Trecho 04



Fonte: Autor (2023).

Com análise dos cenários de navegação, verificou-se que a região com maiores restrições e gargalos operacionais configura-se como a região da Costa do Tamanduá, da ordem de 2,5 metros, impossibilitando a navegação plena de comboios na região.

Dessa forma, de modo a avaliar as profundidades ao longo do ano, bem como as capacidades de carga previstas para a navegação, adotaram-se as profundidades para este trecho e calcularam-se os valores de capacidade de carga com base nos trechos limitadores da navegação, conforme tópico que segue.

5.6. CAPACIDADES DE CARGA PREVISTAS

A partir dos valores de nível d'água obtidos, foi possível a obtenção das capacidades de carga previstas para o período analisado. Para obtenção destas capacidades, foram consideradas as influências do efeito *squat* para cada situação de profundidade mensal, com a consideração de um *underkeel clearance* constante de 0,5 metros, conforme indicado na NPCF.

Com o abatimento dos valores de UKC nos valores de profundidade, foi possível a obtenção do calado navegável disponível para cada mês para um período de 03/2016 a 03/2018, proporcionando, a partir da busca nas curvas hidrostáticas, a obtenção das capacidades de carga para o conjunto de barcaças *box*, para as *raked* e para o comboio, sendo possível o cálculo do percentual de carregamento para cada situação, conforme evidenciado na Tabela 26.

Tabela 26 – Capacidades de Carga Obtidas

Mês	Prof. (m)	<i>Squat</i> (m)	UKC (m)	Calado Disp. (m)	Calado (m)	Box Cap. (t)	Raked Cap.(t)	Comboio Cap. (ton)	Carga %
mar/16	12,52	0,15	0,50	12,02	3,86	2221,16	2077,52	25504,84	99,3%
apr/16	11,95	0,16	0,50	11,45	3,86	2221,16	2077,52	25504,84	99,3%
mai/16	8,32	0,23	0,50	7,82	3,86	2221,16	2077,52	25504,84	99,3%
jun/16	6,09	0,31	0,50	5,59	3,86	2221,16	2077,52	25504,84	99,3%
jul/16	4,75	0,39	0,50	4,25	3,86	2221,16	2077,52	25504,84	99,3%
ago/16	2,48	0,42	0,50	1,98	1,98	1003,32	909,89	11292,41	44,0%
set/16	2,59	0,42	0,50	2,09	2,09	1073,19	976,88	12107,83	47,1%
out/16	1,91	0,41	0,50	1,41	1,41	631,17	553,08	6949,29	27,0%
nov/16	4,21	0,42	0,50	3,71	3,71	2124,41	1984,76	24375,74	94,9%
dez/16	6,07	0,31	0,50	5,57	3,86	2221,16	2077,52	25504,84	99,3%
jan/17	10,13	0,19	0,50	9,63	3,86	2221,16	2077,52	25504,84	99,3%
feb/17	11,89	0,16	0,50	11,39	3,86	2221,16	2077,52	25504,84	99,3%
mar/17	12,47	0,15	0,50	11,97	3,86	2221,16	2077,52	25504,84	99,3%
apr/17	12,23	0,16	0,50	11,73	3,86	2221,16	2077,52	25504,84	99,3%
mai/17	7,82	0,24	0,50	7,32	3,86	2221,16	2077,52	25504,84	99,3%
jun/17	5,84	0,32	0,50	5,34	3,86	2221,16	2077,52	25504,84	99,3%
jul/17	3,83	0,43	0,50	3,33	3,33	1876,72	1747,28	21485,11	83,6%
ago/17	2,78	0,42	0,50	2,28	2,28	1196,70	1095,30	13549,18	52,7%
set/17	2,14	0,42	0,50	1,64	1,64	780,68	696,42	8694,09	33,8%
out/17	2,06	0,42	0,50	1,56	1,56	728,67	646,56	8087,20	31,5%
nov/17	2,24	0,42	0,50	1,74	1,74	845,20	758,29	9447,12	36,8%
dez/17	6,55	0,29	0,50	6,05	3,86	2221,16	2077,52	25504,84	99,3%
jan/18	7,84	0,24	0,50	7,34	3,86	2221,16	2077,52	25504,84	99,3%
fev/18	11,03	0,17	0,50	10,53	3,86	2221,16	2077,52	25504,84	99,3%
mar/18	11,12	0,17	0,50	10,62	3,86	2221,16	2077,52	25504,84	99,3%

Fonte: Autor (2023).

Com a obtenção dos dados apresentados na Tabela 26, foi possível a verificação dos meses com navegação crítica, isto é, aqueles com menores profundidades, correspondentes aos meses de estiagem, sendo o rio influenciado pela sazonalidade dos cursos d'água amazônicos. Em agosto as águas começam a recuar, dando início a estação da seca, que fica mais acentuada.

A partir da modelagem destas capacidades de carga, foi possível a verificação dos períodos em que a navegação com suas capacidades máximas fica restringida, fato este que se mostra como extremamente relevante para a navegação nesta região, haja vista que ela possui uma navegação perene, com as safras do agronegócio (soja e milho) oriundas da região Centro-Oeste do Brasil.

Tais avaliações configuram-se como de fundamental importância, visto que possibilitam otimizar a formação de comboios de acordo com a capacidade máxima da via para o período de navegação. A exemplo disso, pode-se destacar os períodos de setembro a novembro de 2017, em que a capacidade máxima do comboio fica restrita a valores próximos de 35%, sendo um valor consideravelmente baixo para a necessidade de escoamento da produção.

6. CONCLUSÕES

Como forma de organizar as ideias no que tange às conclusões obtidas a partir das aplicações metodológicas definidas, esta foram divididas por módulos, conforme segue: Conclusões acerca o Módulo de Aquisição de Dados; Conclusões para Previsão de Lâmina D'água e Conclusões para Previsão de Condições Planialtimétricas.

6.1. CONCLUSÕES PARA OS MÓDULOS DE AQUISIÇÃO DE DADOS

Os módulos de aquisição de dados consistiram no Módulo 01 e Módulo 02, para aquisição de vetores de precipitação e temperatura, respectivamente. No que tange aos referidos módulos, o processo metodológico desenvolvido configurou-se como satisfatório, tendo em vista que atingiu aos objetivos propostos de utilização da ferramenta *Google Earth Engine* para desenvolvimento de uma ferramenta computacional capaz de associar diferentes provedores de dados com a finalidade intrínseca de avaliar os que mais se adequavam para a problemática proposta na pesquisa.

Em complementação ao exposto, destaca-se que a avaliação a partir de métricas estatísticas para comparação dos valores *in situ* com os valores de satélite configurou-se como de extrema valia, visto que possibilitou a avaliação dos resultados com a finalidade intrínseca de confirmação de que estes poderiam ser utilizados como vetores de entrada nas redes neurais artificiais desenvolvidas.

Destaca-se, que no contexto de obtenção das variáveis de precipitação, avaliaram-se cinco satélites globais de ampla significância em consonância com a literatura: ERA5, CMORPH, PERSIANN-CDR, CFSR e CHIRPS, sendo avaliados em Disponibilidade no GEE, Amplitude Geográfica, Espaço Amostral Disponível, Banda e Unidade, Resolução e Provedor de Dados. O Satélite CHIRPs foi adotado na seleção final com base no ranqueamento obtido e em consonância com a literatura em Cordeiro e Blanco (2021), Paca et al. (2020), Cavalcante et al. (2020) e Marinho e Rivera (2021), bem como com as métricas matemáticas a fim de consubstanciar a análise em questão em termos de RMSE e R^2 .

6.2. CONCLUSÕES PARA MÓDULO DE PREVISÃO DE LÂMINAS D'ÁGUA

A pesquisa em questão apresenta dois modelos computacionais baseados em ANN, sendo o primeiro do tipo *Perceptron* Multicamada e o segundo do tipo Recorrente, sendo ambos com o objetivo principal de obter as capacidades de carga de um comboio fluvial para uma dada

hidrovia a partir da previsão de níveis d'água a fim de verificar a sazonalidade do curso fluvial que, atrelado à modelagem das características hidrostáticas da embarcação projeto e à modelagem das características planialtimétricas do rio, possibilita a verificação de gargalos de navegação, além de promover o conhecimento dos períodos em que o curso fluvial apresentará restrições de navegação, o que representa perdas de capacidade de carga e, eventualmente, aumentos nos preços do transporte e do produto transportado.

A partir do desenvolvimento metodológico, foi possível finalizar ambos os modelos computacionais com o objetivo de aplicar e validar o mesmo a um estudo de caso.

Os valores obtidos possibilitaram a realização da outra etapa metodológica, que consistiu na obtenção dos valores de calado disponíveis para cada mês da análise, com a diferença entre a profundidade aferida e os valores de UKC, obtendo-se os valores de calado disponível, a fim de que estes sejam interpolados nas curvas hidrostáticas para obtenção das capacidades de carga do comboio em cada situação.

No que tange à avaliação das duas redes desenvolvidas, conforme apresentado nos resultados obtidos para o Módulo 02, os valores de métricas estatísticas apresentaram maiores aderências da rede neural recorrente em relação à *perceptron*, sendo mais adequada para a tarefa de previsão dos níveis d'água em Porto Velho, fornecendo previsões mais precisas e um melhor ajuste aos dados em comparação com o Perceptron. Essas conclusões destacam a importância de escolher a arquitetura adequada da rede neural de acordo com as características dos dados e os objetivos da modelagem, corroborando com a literatura em Ren et al. (2020) e Sahoo et al. (2019).

Ressalta-se, também, que o modelo em questão foi capaz de aferir as condições de lâmina d'água mesmo sabendo que na hidrovia utilizada como estudo de caso, faz-se o controle de vazões defluentes nas Usinas Hidrelétricas de Santo Antônio e Jirau, a montante de Porto Velho.

6.3. CONCLUSÕES PARA CONDIÇÕES PLANIALTIMÉTRICAS

De posse das recomendações dispostas em PIANC (2014) e sabendo que o presente trabalho está em conformidade com estas, pode-se constatar, por intermédio das informações supracitadas, que o software adotado (*DimChannel*) apresenta-se como uma alternativa viável para o dimensionamento e análise de canais de acesso, haja vista que o mesmo torna possível aumentar a facilidade do tratamento de dados na etapa do projeto conceito, onde faz-se

necessário o input em demasia de informações, o que, eventualmente, possibilita falhas humanas. Posto isso, o programa torna-se um facilitador desta etapa.

O estudo das normas em PIANC (2014) para o dimensionamento dos canais de acesso necessita de uma análise apurada para que os cálculos possam ser feitos de forma correta. O uso de ferramenta computacionais permite com que o trabalho do engenheiro possa ser facilitado e ser feito de forma mais precisa. Por isso, o uso de ferramentas auxiliares para o projeto como o Excel se torna, muitas vezes vitais para o desenvolvimento de projetos mais externos. E além disso, o desenvolvimento de um software próprio para o dimensionamento dos canais permite uma aplicação mais rápida, simples, direta, e com possibilidades para implementações mais específicas; algo que nenhuma ferramenta pronta pode fornecer.

No que tange aos resultados obtidos a partir da modelagem do trecho da hidrovia, bem como em relação aos valores de capacidade de carga obtidos, destaca-se:

- O uso do software DimChannel permitiu a concepção do traçado do canal de navegação com base em levantamentos hidrográficos e cartas náuticas, convertendo essas informações em coordenadas de pontos batimétricos por meio do Software Civil 3D. Isso possibilitou a modelagem do canal de navegação e a definição de faixas de navegação de acordo com as normas estabelecidas.
- A análise dos cenários de navegação, divididos em "favorável" (março a julho) e "crítico" (agosto a novembro), revelou a existência de trechos críticos com restrições de largura e profundidade ao longo do canal de navegação. A modelagem digital de elevação mostrou que nos meses de menor lâmina d'água, esses trechos críticos são mais aflorados, indicando maiores restrições de navegação.
- Foram identificados 4 trechos críticos principais entre os municípios de Porto Velho e Calama, e Porto Velho e Humaitá, conhecidos como Travessia do Tamanduá, Travessia dos Papagaios e Travessia de Curicacas. Esses trechos apresentaram restrições de largura e profundidade nos dois cenários analisados, corroborando com as informações da Marinha do Brasil.
- As regiões com restrição identificadas na modelagem do canal de navegação correspondem às zonas críticas com restrições de profundidade já apontadas pela Marinha do Brasil. Essas restrições podem afetar o calado e o tráfego de barcas em mão dupla.

- A região da Costa do Tamanduá foi identificada como a mais restritiva e com maiores gargalos operacionais, apresentando uma profundidade de cerca de 2,5 metros, o que impossibilita a navegação plena de comboios nessa região.
- Com base nas profundidades avaliadas ao longo do ano e nas restrições de navegação nos trechos limitadores, será possível calcular os valores de capacidade de carga para a navegação nessa região.
- Em resumo, os resultados obtidos através da modelagem e análise dos cenários de navegação forneceram informações importantes sobre as restrições de largura e profundidade ao longo do canal de navegação, corroborando com as observações da Marinha do Brasil. Essas informações são essenciais para avaliar as capacidades de carga e planejar a navegação nessa região.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABDELMONEIM, H.; SOLIMAN, M. R.; MOGHAZY, H. M. Evaluation of TRMM 3B42V7 and CHIRPS Satellite Precipitation Products as an Input for Hydrological Model over Eastern Nile Basin. **Earth Systems and Environment**, v. 4, n. 4, p. 685–698, dez. 2020.

ABHISHEK, V. A.; VIJITH, V.; ANUP, N. Trend of annual and semiannual harmonics of sea surface temperature in the tropical Indian Ocean, 1979–2018. **Deep Sea Research Part II: Topical Studies in Oceanography**, v. 209, p. 105292, 1 jun. 2023.

ABRAHAM, G.; LEPETIT, J. P. METHODS TO PREDICT PATH OF SHIP; OUTLINE OF STATE OF THE ART: (report on symposium “Aspects of navigability of constraint waterways, including harbour entrances”. Delft, the Netherlands, April 24-27, 1978). **Journal of Hydraulic Research**, v. 16, n. 4, p. 279–295, out. 1978.

ABRAHART, R. J.; WHITE, S. M. Modelling sediment transfer in Malawi: comparing backpropagation neural network solutions against a multiple linear regression benchmark using small data sets. **Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere**, v. 26, n. 1, p. 19–24, 1 jan. 2001.

ADHIPERDANA, B. G. et al. Relationships between discharge parameters and cross-sectional channel dimensions of rivers in an active margin influenced by tropical climate: The case of modern fluvial systems in the Indonesian islands. **CATENA**, v. 171, p. 645–680, dez. 2018.

ADLAND, R.; JIA, H.; STRANDENES, S. P. The determinants of vessel capacity utilization: The case of Brazilian iron ore exports. **Transportation Research Part A: Policy and Practice**, v. 110, p. 191–201, abr. 2018.

ADNAN, M. et al. Snowmelt Runoff Modelling under Projected Climate Change Patterns in the Gilgit River Basin of Northern Pakistan. **Polish Journal of Environmental Studies**, v. 26, n. 2, p. 525–542, 22 mar. 2017.

AGÊNCIA NACIONAL DE TRANSPORTE AQUAVIÁRIO. **Caracterização da oferta e da demanda do transporte fluvial de passageiros e cargas na região amazônica**. Belém: [s.n.].

AGRAWAL, N.; AHIDUZZAMAN, M.; KUMAR, A. The development of an integrated model for the assessment of water and GHG footprints for the power generation sector. **Applied Energy**, v. 216, p. 558–575, abr. 2018.

AHADI, K.; SULLIVAN, K. M.; MITCHELL, K. N. Budgeting maintenance dredging projects under uncertainty to improve the inland waterway network performance. **Transportation Research Part E: Logistics and Transportation Review**, v. 119, p. 63–87, nov. 2018.

AHMED, K. et al. Modeling climate change impacts on precipitation in arid regions of Pakistan: a non-local model output statistics downscaling approach. **Theoretical and applied climatology**, v. 137, n. 1–2, p. 1347–1364, 2019a.

AHMED, K. et al. Evaluation of Gridded Precipitation Datasets over Arid Regions of Pakistan. **Water**, v. 11, n. 2, p. 210, fev. 2019b.

AKSU, H.; AKGÜL, M. A. Performance evaluation of CHIRPS satellite precipitation estimates over Turkey. **Theoretical and Applied Climatology**, v. 142, n. 1–2, p. 71–84, out. 2020.

ALIJANIAN, M. et al. Evaluation of remotely sensed precipitation estimates using PERSIANN-CDR and MSWEP for spatio-temporal drought assessment over Iran. **Journal of Hydrology**, v. 579, p. 124189, 1 dez. 2019.

ALMAZ, O. A.; ALTIOK, T. Simulation modeling of the vessel traffic in Delaware River: Impact of deepening on port performance. **Simulation Modelling Practice and Theory**, v. 22, p. 146–165, mar. 2012.

AL-SHEHHI, M. R. Uncertainty in satellite sea surface temperature with respect to air temperature, dust level, wind speed and solar position. **Regional Studies in Marine Science**, v. 53, p. 102385, 1 jun. 2022.

ALTUNKAYNAK, A. Predicting Water Level Fluctuations in Lake Michigan-Huron Using Wavelet-Expert System Methods. **Water Resources Management**, v. 28, n. 8, p. 2293–2314, jun. 2014.

AMAROUCHE, K. et al. Spatial calibration of an unstructured SWAN model forced with CFSR and ERA5 winds for the Black and Azov Seas. **Applied Ocean Research**, v. 117, p. 102962, 1 dez. 2021.

ANA. **Caracterização do Rio Madeira.** Governo. Disponível em: <<https://www.gov.br/ana/pt-br/sala-de-situacao/rio-madeira/saiba-mais>>. Acesso em: 4 dez. 2022.

ANTAQ. **Anuário Estatístico Aquaviário - 2019.** Disponível em: <<http://web.antaq.gov.br/Anuario2019/>>. Acesso em: 10 dez. 2018.

ANTAQ. **Anuário Estatístico Aquaviário 2022.** Governo. Disponível em: <<http://ea.antaq.gov.br/QvAJAXZfc/opendoc.htm?document=painel%5Cantaq%20-%20anu%C3%A1rio%202014%20-%20v0.9.3.qvw&lang=pt-BR&host=QVS%40graneleiro&anonymous=true>>. Acesso em: 4 dez. 2022.

ARENCIBIA, A. I. et al. Modelling mode choice for freight transport using advanced choice experiments. **Transportation Research Part A: Policy and Practice**, v. 75, p. 252–267, maio 2015.

ARUNKUMAR, R.; JOTHIPRAKASH, V. Optimal Reservoir Operation for Hydropower Generation using Non-linear Programming Model. **Journal of The Institution of Engineers (India): Series A**, v. 93, n. 2, p. 111–120, maio 2012.

AYEHU, G. T. et al. Validation of new satellite rainfall products over the Upper Blue Nile Basin, Ethiopia. **Atmospheric Measurement Techniques**, v. 11, n. 4, p. 1921–1936, 6 abr. 2018.

BAI, L. et al. Accuracy of CHIRPS Satellite-Rainfall Products over Mainland China. **Remote Sensing**, v. 10, n. 3, p. 362, mar. 2018.

BARBOSA, F. G. P. et al. Computational Tool for Sizing and Optimization of Planimetric Geometric Parameters of Inland Navigation Channels and of Port Access in Brazil. **Journal of Waterway, Port, Coastal, and Ocean Engineering**, v. 147, n. 1, p. 04020044, 1 jan. 2021.

BARRASS, C. B.; DERRETT, C. D. R. Ship squat in open water and in confined channels. Em: **Ship Stability for Masters and Mates**. [s.l.] Elsevier, 2006. p. 324–336.

BARRASS, C. B.; DERRETT, D. R. Hydrostatic Curves and Values for Vessels Initially Having Trim by the Bow or by the Stern. Em: **Ship Stability for Masters and Mates**. [s.l.] Elsevier, 2012a. p. 235–240.

BARRASS, C. B.; DERRETT, D. R. Draft Surveys. Em: **Ship Stability for Masters and Mates**. [s.l.] Elsevier, 2012b. p. 467–472.

BERGANTINO, A. S. et al. Taste heterogeneity and latent preferences in the choice behaviour of freight transport operators. **Transport Policy**, v. 30, p. 77–91, nov. 2013.

BIRAN, A.; LÓPEZ-PULIDO, R. Hydrostatic Curves. Em: **Ship Hydrostatics and Stability**. [s.l.] Elsevier, 2014a. p. 97–116.

BIRAN, A.; LÓPEZ-PULIDO, R. Definitions, Principal Dimensions. Em: **Ship Hydrostatics and Stability**. [s.l.] Elsevier, 2014b. p. 1–21.

BIRAN, A.; LÓPEZ-PULIDO, R. Statical Stability at Large Angles of Heel. Em: **Ship Hydrostatics and Stability**. [s.l.] Elsevier, 2014c. p. 117–125.

BIRAN, A.; LÓPEZ-PULIDO, R. Intact Stability Regulations II. Em: **Ship Hydrostatics and Stability**. [s.l.] Elsevier, 2014d. p. 243–258.

BRANDSÆTER, A.; VANEM, E. Ship speed prediction based on full scale sensor measurements of shaft thrust and environmental conditions. **Ocean Engineering**, v. 162, p. 316–330, 15 ago. 2018.

BRENES, R. F.; JOHANNSEN, A.; CHUKHROVA, N. An intelligent bankruptcy prediction model using a multilayer perceptron. **Intelligent Systems with Applications**, v. 16, p. 200136, 1 nov. 2022.

BRIGGS, M. J. et al. Validation of a Risk-Based Numerical Model for Predicting Deep-Draft Underkeel Clearance. **Journal of Waterway, Port, Coastal, and Ocean Engineering**, v. 139, n. 4, p. 267–276, jul. 2013.

BRIGGS, M. J. et al. Prediction of Squat for Underkeel Clearance. Em: KIM, Y. C. (Ed.). **Handbook of Coastal and Ocean Engineering**. Expanded ed. [s.l.] WORLD SCIENTIFIC, 2018. p. 1029–1080.

BYTHEWAY, J. L. et al. On the Uncertainty of High-Resolution Hourly Quantitative Precipitation Estimates in California. **Journal of Hydrometeorology**, v. 21, n. 5, p. 865–879, maio 2020.

CAMPOS FILHO, L. C. P. et al. **Analysis of geometric conformation of the Lower Tapajós stretch using navigation channel sizing software**. Brasília: Galoa, 2019. Disponível em: <https://proceedings.science/proceedings/100110/_papers/110826>. Acesso em: 14 abr. 2020

CANNON, D. J. et al. Using reanalysis data to quantify extreme wind power generation statistics: A 33 year case study in Great Britain. **Renewable Energy**, v. 75, p. 767–778, 1 mar. 2015.

CANTONI, E. et al. Hydrological performance of the ERA5 reanalysis for flood modeling in Tunisia with the LISFLOOD and GR4J models. **Journal of Hydrology: Regional Studies**, v. 42, p. 101169, 1 ago. 2022.

CAO, Y. et al. Impact of trends in river discharge and ocean tides on water level dynamics in the Pearl River Delta. **Coastal Engineering**, v. 157, p. 103634, abr. 2020.

CAVALCANTE, R. B. L. et al. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. **Atmospheric Research**, v. 238, p. 104879, 1 jul. 2020.

CERVO, A. L.; BERVIAN, P. A.; SILVA, R. DA. **Metodologia científica**. São Paulo: Pearson Prentice Hall, 2009.

CFPV. **NORMAS E PROCEDIMENTOS DA CAPITANIA FLUVIAL DE PORTO VELHO**. MARINHA DO BRASIL - COMANDO DO 9º DISTRITO NAVAL, , 2020. Disponível em: <<https://www.marinha.mil.br/cfpv/?q=conteudo/normas-e-procedimentos-especificos-para-jurisdicao-da-capitania-fluvial-de-porto-velho>>. Acesso em: 3 dez. 2022

CHEN, F. et al. Reliability of satellite-derived precipitation data in driving hydrological simulations: A case study of the upper Huaihe River basin, China. **Journal of Hydrology**, v. 612, p. 128076, 1 set. 2022.

CHEN, H. et al. A Machine Learning System for Precipitation Estimation Using Satellite and Ground Radar Network Observations. **IEEE Transactions on Geoscience and Remote Sensing**, v. 58, n. 2, p. 982–994, fev. 2020.

CHEN, L. et al. A new method for identification of flood seasons using directional statistics. **Hydrological Sciences Journal**, v. 58, n. 1, p. 28–40, jan. 2013.

CHEN, S. et al. Urbanization effect on precipitation over the Pearl River Delta based on CMORPH data. **Advances in Climate Change Research**, v. 6, n. 1, p. 16–22, mar. 2015.

CHRISTODOULOU, A.; CHRISTIDIS, P.; BISSELINK, B. Forecasting the impacts of climate change on inland waterways. **Transportation Research Part D: Transport and Environment**, v. 82, p. 102159, 1 maio 2020.

CIRINO, P. H. et al. Assessing the Impacts of ENSO-related Weather Effects on the Brazilian Agriculture. **Procedia Economics and Finance**, International Conference on Applied Economics (ICOAE) 2015, 2-4 July 2015, Kazan, Russia. v. 24, p. 146–155, 1 jan. 2015.

CLAUSEN, U.; KAFFKA, J. Development of priority rules for handlings in inland port container terminals with simulation. **Journal of Simulation**, v. 10, n. 2, p. 95–102, maio 2016.

COCHRANE, S. M. V. et al. Landsat-based analysis of mega dam flooding impacts in the Amazon compared to associated environmental impact assessments: Upper Madeira River example 2006–2015. **Remote Sensing Applications: Society and Environment**, v. 7, p. 1–8, 1 ago. 2017.

DADASHI, A. et al. A novel continuous berth scheduling model at multiple marine container terminals with tidal considerations. **Maritime Business Review**, v. 2, n. 2, p. 142–157, 15 jun. 2017.

DE ALMEIDA FILHO, A. T. et al. Preference modeling experiments with surrogate weighting procedures for the PROMETHEE method. **European Journal of Operational Research**, v. 264, n. 2, p. 453–461, jan. 2018.

DE MENDONÇA, L. M.; BLANCO, C. J. C.; DE OLIVEIRA CARVALHO, F. Recurrent neural networks for rainfall-runoff modeling of small Amazon catchments. **Modeling Earth Systems and Environment**, v. 9, n. 2, p. 2517–2531, jun. 2023.

DE MORAES CORDEIRO, A. L.; BLANCO, C. J. C. Assessment of satellite products for filling rainfall data gaps in the Amazon region. **Natural Resource Modeling**, v. 34, n. 2, p. e12298, 2021.

DE OLIVEIRA-JÚNIOR, J. F. et al. Drought severity based on the SPI index and its relation to the ENSO and PDO climatic variability modes in the regions North and Northwest of the State of Rio de Janeiro - Brazil. **Atmospheric Research**, v. 212, p. 91–105, 1 nov. 2018.

DEDES, E. K.; HUDSON, D. A.; TURNOCK, S. R. Investigation of Diesel Hybrid systems for fuel oil reduction in slow speed ocean going ships. **Energy**, v. 114, p. 444–456, nov. 2016.

DEMBÉLÉ, M.; ZWART, S. J. Evaluation and comparison of satellite-based rainfall products in Burkina Faso, West Africa. **International Journal of Remote Sensing**, v. 37, n. 17, p. 3995–4014, 1 set. 2016.

DINKU, T. et al. Validation of the CHIRPS satellite rainfall estimates over eastern Africa. **Quarterly Journal of the Royal Meteorological Society**, v. 144, n. S1, p. 292–312, nov. 2018.

DNIT. **Hidrovia do Tapajós -Teles Pires**. Departamento Nacional de Infraestrutura de Transportes, , 2018. Disponível em: <<https://www.gov.br/dnit/pt-br/assuntos/aquaviario/hidrovia-do-tapajos-teles-pires>>. Acesso em: 1 nov. 2020

DNIT. **Hidrovia do Madeira**. Disponível em: <<https://www.gov.br/dnit/pt-br/assuntos/aquaviario/old/hidrovia-do-madeira>>. Acesso em: 3 dez. 2022.

DU, Y. et al. Modeling the Impacts of Tides and the Virtual Arrival Policy in Berth Allocation. **Transportation Science**, v. 49, n. 4, p. 939–956, nov. 2015.

DYER, A. J.; GRIFFIN, L. D. Inferring the location of neurons within an artificial network from their activity. **Neural Networks**, v. 157, p. 160–175, 1 jan. 2023.

EICHHORN, M. et al. Sensitivity Analysis of Bias in Satellite Sea Surface Temperature Measurements. **IFAC-PapersOnLine**, 21st IFAC World Congress. v. 53, n. 2, p. 764–771, 1 jan. 2020.

EINI, M. R.; RAHMATI, A.; PINIEWSKI, M. Hydrological application and accuracy evaluation of PERSIANN satellite-based precipitation estimates over a humid continental climate catchment. **Journal of Hydrology: Regional Studies**, v. 41, p. 101109, 1 jun. 2022.

ELSHARBINY, K. et al. Experimental analysis of the squat of ships advancing through the New Suez Canal. **Ocean Engineering**, v. 178, p. 331–344, abr. 2019.

ERYUZLU, N. E.; CAO, Y. L.; D'AGNOLO, F. **Underkeel Requirements for large vessels in shallow waterways**. Proc. 28th Int. Navi. Cong. **Anais...**Spain: PIANC, 1994.

ESPINOZA VILLAR, R. et al. A study of sediment transport in the Madeira River, Brazil, using MODIS remote-sensing images. **Journal of South American Earth Sciences**, Hydrology, Geochemistry and Dynamic of South American Great River Systems. v. 44, p. 45–54, 1 jul. 2013.

FATHONI, M. et al. Analysis to assess potential rivers for cargo transport in Indonesia. **Transportation Research Procedia**, v. 25, p. 4544–4559, 2017.

FEARNSIDE, P. M. Impacts of Brazil's Madeira River Dams: Unlearned lessons for hydroelectric development in Amazonia. **Environmental Science & Policy**, v. 38, p. 164–172, 1 abr. 2014.

FENG, S.; HAO, Z. Quantitative contribution of ENSO to precipitation-temperature dependence and associated compound dry and hot events. **Atmospheric Research**, v. 260, p. 105695, 1 out. 2021.

FENG, X. et al. A multi-layer perceptron approach for accelerated wave forecasting in Lake Michigan. **Ocean Engineering**, v. 211, p. 107526, 1 set. 2020.

FIGUEIREDO, N.; BLANCO, C. Simulação de Vazões e Níveis de Água Médios Mensais para o Rio Tapajós Usando Modelos ARIMA. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 3, p. 111–126, 2014.

FLODÉN, J.; BÄRTHHEL, F.; SORKINA, E. Transport buyers choice of transport service – A literature review of empirical results. **Research in Transportation Business & Management**, v. 23, p. 35–45, jun. 2017.

FLODÉN, J.; WOXENIUS, J. Agility in the Swedish intermodal freight market – The effects of the withdrawal of the main provider. **Research in Transportation Business & Management**, v. 23, p. 21–34, jun. 2017.

FÖEGER, L. B. et al. Large-scale sediment modeling with inertial flow routing: Assessment of Madeira river basin. **Environmental Modelling & Software**, v. 149, p. 105332, 1 mar. 2022.

FOK, H. S. et al. Geographically-weighted water balance approach for satellite-hydrologic runoff estimation in Mekong Basin under ENSO. **International Journal of Applied Earth Observation and Geoinformation**, v. 118, p. 103234, 1 abr. 2023.

FUNK, C. et al. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific Data**, v. 2, n. 1, p. 150066, 8 dez. 2015.

GALOR, W. Determination of Dynamic Under Keel Clearance of Maneuvering Ship. **Journal of Konbin**, v. 8, n. 1, p. 53–60, 1 jan. 2008.

GARCIA, F. C. C.; RETAMAR, A. E.; JAVIER, J. C. **Development of a predictive model for on-demand remote river level nowcasting: Case study in Cagayan River Basin, Philippines**. 2016 IEEE Region 10 Conference (TENCON). **Anais...**Singapore: IEEE, nov. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7848657/>>. Acesso em: 15 jul. 2020

GEE. **ERA5 Daily Aggregates - Latest Climate Reanalysis Produced by ECMWF / Copernicus Climate Change Service | Earth Engine Data Catalog**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/ECMWF_ERA5_DAILY>. Acesso em: 4 dez. 2022a.

GEE. **PERSIANN-CDR: Precipitation Estimation From Remotely Sensed Information Using Artificial Neural Networks-Climate Data Record | Earth Engine Data Catalog**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/NOAA_PERSIANN-CDR>. Acesso em: 4 dez. 2022b.

GEE. **CFSR: Climate Forecast System Reanalysis | Earth Engine Data Catalog**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/NOAA_CFSR>. Acesso em: 4 dez. 2022c.

GEE. **Earth Engine Data Catalog | Google Developers**. Disponível em: <<https://developers.google.com/earth-engine/datasets>>. Acesso em: 8 dez. 2022d.

GHORBANI, M. A. et al. Learning from Multiple Models Using Artificial Intelligence to Improve Model Prediction Accuracies: Application to River Flows. **Water Resources Management**, v. 32, n. 13, p. 4201–4215, out. 2018.

- GHOZAT, A.; SHARAFATI, A.; HOSSEINI, S. A. Long-term spatiotemporal evaluation of CHIRPS satellite precipitation product over different climatic regions of Iran. **Theoretical and Applied Climatology**, v. 143, n. 1–2, p. 211–225, jan. 2021.
- GJIKA, E.; FERRJA, A.; KAMBERI, A. A Study on the Efficiency of Hybrid Models in Forecasting Precipitations and Water Inflow Albania Case Study. **Advances in Science, Technology and Engineering Systems Journal**, v. 4, n. 1, p. 302–310, 2019.
- GOMES, W. DE B. et al. Intraseasonal scale ensemble forecasts of precipitation and evapotranspiration for the Madeira River basin using different physical parameterizations. **Atmospheric Research**, v. 270, p. 106086, 1 jun. 2022.
- GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, dez. 2017.
- GRAMCIANINOV, C. B. et al. Analysis of Atlantic extratropical storm tracks characteristics in 41 years of ERA5 and CFSR/CFSv2 databases. **Ocean Engineering**, v. 216, p. 108111, 15 nov. 2020.
- GUMINDOGA, W. et al. Hydrologic evaluation of bias corrected CMORPH rainfall estimates at the headwater catchment of the Zambezi River. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 115, p. 102809, fev. 2020.
- HABIB, E. et al. Evaluation of the High-Resolution CMORPH Satellite Rainfall Product Using Dense Rain Gauge Observations and Radar-Based Estimates. **Journal of Hydrometeorology**, v. 13, n. 6, p. 1784–1798, 1 dez. 2012.
- HAILE, A. T.; HABIB, E.; RIENTJES, T. Evaluation of the climate prediction center (CPC) morphing technique (CMORPH) rainfall product on hourly time scales over the source of the Blue Nile River: EVALUATION OF THE CMORPH RAINFALL PRODUCT. **Hydrological Processes**, v. 27, n. 12, p. 1829–1839, 15 jun. 2013.
- HAILE, A. T.; YAN, F.; HABIB, E. Accuracy of the CMORPH satellite-rainfall product over Lake Tana Basin in Eastern Africa. **Atmospheric Research**, v. 163, p. 177–187, set. 2015.
- HARLACHER, D. Assessment Procedure of the Trafficability of Inland Waterways. **Procedia Engineering**, v. 154, p. 146–153, 2016.

HASHEMI, H. et al. An extended compromise ratio model with an application to reservoir flood control operation under an interval-valued intuitionistic fuzzy environment. **Applied Mathematical Modelling**, v. 38, n. 14, p. 3495–3511, jul. 2014.

HAURELHUK, S. S.; VALENTE, A. M. **ESTUDO DE CAPACIDADE DO CANAL DA GALHETA (PORTO DE PARANAGUÁ)**. Anais do XVIII Simpósio de Pesquisa Operacional & Logística da Marinha. **Anais...** Em: XVIII SIMPÓSIO DE PESQUISA OPERACIONAL & LOGÍSTICA DA MARINHA. Rio de Janeiro, Brasil: Editora Edgard Blücher, ago. 2016. Disponível em: <<http://www.proceedings.blucher.com.br/article-details/22713>>. Acesso em: 16 set. 2021

HAYKIN, S. S. **Neural networks: a comprehensive foundation**. 2nd ed ed. Upper Saddle River, N.J: Prentice Hall, 1999.

HINGE, G. et al. Hydrologic utility of satellite precipitation products in flood prediction: A meta-data analysis and lessons learnt. **Journal of Hydrology**, v. 612, p. 128103, 1 set. 2022.

HONG LEE, J.; JULIEN, P. Y.; LEE, S. Teleconnection of ENSO extreme events and precipitation variability over the United States. **Journal of Hydrology**, v. 619, p. 129206, 1 abr. 2023.

HUANG, L. et al. Evaluation of surface temperature and pressure derived from MERRA-2 and ERA5 reanalysis datasets and their applications in hourly GNSS precipitable water vapor retrieval over China. **Geodesy and Geodynamics**, 13 out. 2022.

HUANG, W.-R.; LIU, P.-Y.; HSU, J. Multiple timescale assessment of wet season precipitation estimation over Taiwan using the PERSIANN family products. **International Journal of Applied Earth Observation and Geoinformation**, v. 103, p. 102521, 1 dez. 2021.

HUNASIGI, P. et al. Multilayer perceptron neural network based models for prediction of the rainfall and reference crop evapotranspiration for sub-humid climate of Dapoli, Ratnagiri District, India. **Acta Ecologica Sinica**, 4 out. 2022.

IMO - INTERNATIONAL MARITIME ORGANIZATION. **Guidelines for voluntary use of the ship energy efficiency operational indicator (EEOI)**. , 17 jul. 2009.

INLAND NAVIGATION COMMISSION; WORKING GROUP 141; WORLD ASSOCIATION FOR WATERBORNE TRANSPORT INFRASTRUCTURE. **Design guidelines for inland waterway dimensions**. [s.l.: s.n.].

IQBAL, M. F.; ATHAR, H. Validation of satellite based precipitation over diverse topography of Pakistan. **Atmospheric Research**, v. 201, p. 247–260, mar. 2018.

JANEKOVIĆ, I. et al. 4D-Var data assimilation using satellite sea surface temperature to improve the tidally-driven interior ocean dynamics estimates in the Indo-Australian Basin. **Ocean Modelling**, v. 171, p. 101969, 1 mar. 2022.

JIANG, Q. et al. Evaluation of the ERA5 reanalysis precipitation dataset over Chinese Mainland. **Journal of Hydrology**, v. 595, p. 125660, abr. 2021.

JIANG, S. et al. Evaluation of latest TMPA and CMORPH satellite precipitation products over Yellow River Basin. **Water Science and Engineering**, v. 9, n. 2, p. 87–96, abr. 2016.

JIAO, D. et al. Evaluation of spatial-temporal variation performance of ERA5 precipitation data in China. **Scientific Reports**, v. 11, n. 1, p. 17956, 9 set. 2021.

JING, C. et al. Comparison and validation of SRTM and ASTER GDEM for a subtropical landscape in Southeastern China. **International Journal of Digital Earth**, v. 7, n. 12, p. 969–992, 26 nov. 2014.

JONKEREN, O.; JOURQUIN, B.; RIETVELD, P. Modal-split effects of climate change: The effect of low water levels on the competitive position of inland waterway transport in the river Rhine area. **Transportation Research Part A: Policy and Practice**, v. 45, n. 10, p. 1007–1019, dez. 2011.

KAMAL, N.; SADEK, N. Evaluating and analyzing navigation efficiency for the River Nile (Case study: Ensa-Naga Hamady reach). **Ain Shams Engineering Journal**, v. 9, n. 4, p. 2649–2669, dez. 2018.

KASIVISWANATHAN, K. S. et al. Potential application of wavelet neural network ensemble to forecast streamflow for flood management. **Journal of Hydrology**, v. 536, p. 161–173, maio 2016.

KESSETE, N.; MOGES, M. A.; STEENHUIS, T. S. Chapter 2 - Evaluating the applicability and scalability of bias corrected CFSR climate data for hydrological modeling in upper Blue Nile basin, Ethiopia. Em: MELESSE, A. M.; ABTEW, W.; SENAY, G. (Eds.). **Extreme Hydrology and Climate Variability**. [s.l.] Elsevier, 2019. p. 11–22.

KHAN, M. Y. A. et al. Neural network model for discharge and water-level prediction for Ramganga River catchment of Ganga Basin, India. **Hydrological Sciences Journal**, v. 61, n. 11, p. 2084–2095, 17 ago. 2016.

KIM, D. J.; YEO, D. J. Estimation of drafts and metacentric heights of small fishing vessels according to loading conditions. **International Journal of Naval Architecture and Ocean Engineering**, v. 12, p. 199–212, 2020.

KIM, S. E.; SEO, I. W. Artificial Neural Network ensemble modeling with conjunctive data clustering for water quality prediction in rivers. **Journal of Hydro-environment Research**, v. 9, n. 3, p. 325–339, set. 2015.

KUO, C. C.; GAN, T. Y.; HIGUCHI, K. Evaluation of Future Streamflow Patterns in Lake Simcoe Subbasins Based on Ensembles of Statistical Downscaling. **Journal of Hydrologic Engineering**, v. 22, n. 9, p. 04017028, set. 2017.

KUWAHARA, N.; LAGO NETO, J. C. DO; ABENSUR, T. DA C. Modelagem de previsão de navegabilidade em rios da Amazônia: ferramenta web de suporte aos usuários do transporte aquaviário. **Journal of Transport Literature**, v. 6, n. 3, p. 61–89, set. 2012.

LAI, X. et al. Numerical evaluation of flow regime changes induced by the Three Gorges Dam in the Middle Yangtze. **Hydrology Research**, v. 47, n. S1, p. 149–160, 1 dez. 2016.

LAKATOS, E. M.; MARCONI, M. DE A. **Fundamentos de metodologia científica**. São Paulo: Atlas, 2003.

LALLA-RUIZ, E. et al. A Set-Partitioning-based model for the Berth Allocation Problem under Time-Dependent Limitations. **European Journal of Operational Research**, v. 250, n. 3, p. 1001–1012, maio 2016.

LALLA-RUIZ, E.; SHI, X.; VOSS, S. The waterway ship scheduling problem. **Transportation Research Part D: Transport and Environment**, v. 60, p. 191–209, maio 2018.

LAMMGÅRD, C.; ANDERSSON, D. Environmental considerations and trade-offs in purchasing of transportation services. **Research in Transportation Business & Management**, v. 10, p. 45–52, abr. 2014.

LATAIRE, E.; VANTORRE, M.; DELEFORTRIE, G. A prediction method for squat in restricted and unrestricted rectangular fairways. **Ocean Engineering**, v. 55, p. 71–80, dez. 2012.

LATIF, M.; SYED, F.; HANNACHI, A. Rainfall trends in the South Asian summer monsoon and its related large-scale dynamics with focus over Pakistan. **Climate Dynamics**, v. 48, 1 jun. 2017.

LE, A. M.; PRICOPE, N. G. Increasing the Accuracy of Runoff and Streamflow Simulation in the Nzoia Basin, Western Kenya, through the Incorporation of Satellite-Derived CHIRPS Data. **Water**, v. 9, n. 2, p. 114, fev. 2017.

LE CARRER, N.; FERSON, S.; GREEN, P. L. Optimising cargo loading and ship scheduling in tidal areas. **European Journal of Operational Research**, v. 280, n. 3, p. 1082–1094, fev. 2020.

LE, M.-H. et al. Adequacy of Satellite-derived Precipitation Estimate for Hydrological Modeling in Vietnam Basins. **Journal of Hydrology**, v. 586, p. 124820, 1 jul. 2020.

LEI, H. et al. Comprehensive evaluation of satellite and reanalysis precipitation products over the eastern Tibetan plateau characterized by a high diversity of topographies. **Atmospheric Research**, v. 259, p. 105661, 1 set. 2021.

LI, B. et al. Comparison of random forests and other statistical methods for the prediction of lake water level: a case study of the Poyang Lake in China. **Hydrology Research**, v. 47, n. S1, p. 69–83, 1 dez. 2016.

LI, H. et al. Variational merged of hourly gauge-satellite precipitation in China: Preliminary results. **Journal of Geophysical Research: Atmospheres**, v. 120, n. 19, p. 9897–9915, 16 out. 2015a.

LI, H.; LIU, J.; LIU, R. W. **Dynamic Speed Control Model for Very Large Ship in Restricted Waters**. ISOPE-I-17-261 ed. Place of publication not identified: ISOPE, 2017.

- LI, T. et al. Reversal of the sediment load increase in the Amazon basin influenced by divergent trends of sediment transport from the Solimões and Madeira Rivers. **CATENA**, v. 195, p. 104804, 1 dez. 2020.
- LI, W.; ZHAI, P.; CAI, J. Research on the Relationship of ENSO and the Frequency of Extreme Precipitation Events in China. **Advances in Climate Change Research**, v. 2, n. 2, p. 101–107, 25 jun. 2011.
- LI, X. et al. Yearly variations of the stratospheric tides seen in the CFSR reanalysis data. **Advances in Space Research**, Advances in Equatorial, Low- and Mid-Latitude Mesosphere, Thermosphere and Ionosphere Studies. v. 56, n. 9, p. 1822–1832, 1 nov. 2015b.
- LI, X. et al. Changes in precipitation extremes in the Yangtze River Basin during 1960–2019 and the association with global warming, ENSO, and local effects. **Science of The Total Environment**, v. 760, p. 144244, 15 mar. 2021.
- LI, Y.; SHI, H.; LIU, H. A hybrid model for river water level forecasting: Cases of Xiangjiang River and Yuanjiang River, China. **Journal of Hydrology**, v. 587, p. 124934, ago. 2020.
- LIANG, S. et al. Vessel traffic scheduling method for the controlled waterways in the upper Yangtze River. **Ocean Engineering**, v. 172, p. 96–104, jan. 2019.
- LINDENSCHMIDT, K.-E. **River ice processes and ice flood forecasting: a guide for practitioners and students**. [s.l: s.n.].
- LINDSTAD, H. E.; SANDAAS, I. Emission and Fuel Reduction for Offshore Support Vessels through Hybrid Technology. **Journal of Ship Production and Design**, v. 32, n. 4, p. 195–205, 1 nov. 2016.
- LING-CHIN, J.; ROSKILLY, A. P. Investigating the implications of a new-build hybrid power system for Roll-on/Roll-off cargo ships from a sustainability perspective – A life cycle assessment case study. **Applied Energy**, v. 181, p. 416–434, nov. 2016.
- LISTER, J. Green Shipping: Governing Sustainable Maritime Transport. **Global Policy**, v. 6, n. 2, p. 118–129, maio 2015.
- LIU, J. et al. Dynamic Ship Domain Models for Capacity Analysis of Restricted Water Channels. **Journal of Navigation**, v. 69, n. 3, p. 481–503, maio 2016a.

LIU, J. et al. Dynamic Ship Domain Models for Capacity Analysis of Restricted Water Channels. **Journal of Navigation**, v. 69, p. 481–503, 1 maio 2016b.

LIU, Y. et al. Explainable deep learning for insights in El Niño and river flows. **Nature Communications**, v. 14, n. 1, p. 339, 20 jan. 2023.

LONGO, F.; HUERTA, A.; NICOLETTI, L. Performance Analysis of a Southern Mediterranean Seaport via Discrete-Event Simulation. **Strojniški vestnik – Journal of Mechanical Engineering**, v. 9, n. 59, p. 517–525, 15 set. 2013.

LUO, X. et al. Evolution of reversal of the lowest low waters in a tidal river network. **Journal of Hydrology**, v. 585, p. 124701, jun. 2020.

MAGGIONI, V.; MEYERS, P. C.; ROBINSON, M. D. A Review of Merged High-Resolution Satellite Precipitation Product Accuracy during the Tropical Rainfall Measuring Mission (TRMM) Era. **Journal of Hydrometeorology**, v. 17, n. 4, p. 1101–1117, 1 abr. 2016.

MALUF DE LIMA, L.; PIEDADE BACCHI, M. R. Assessing the impact of Brazilian economic growth on demand for electricity. **Energy**, v. 172, p. 861–873, abr. 2019.

MARINHO, R. R.; RIVERA, I. A. A PRECIPITAÇÃO ESTIMADA POR SATÉLITE NA BACIA DO RIO NEGRO, NOROESTE AMAZÔNICO (1981-2017). **Raega - O Espaço Geográfico em Análise**, v. 50, p. 44, 12 abr. 2021.

MÁRQUEZ, L.; CANTILLO, V.; ARELLANA, J. How are comfort and safety perceived by inland waterway transport passengers? **Transport Policy**, v. 36, p. 46–52, nov. 2014.

MARTINS, M. R. **Hidrostática e Estabilidade**. Escola Politécnica da Universidade de São Paulo, , 2010. . Acesso em: 18 set. 2021

MEDDA, F.; TRUJILLO, L. Short-sea shipping: an analysis of its determinants. **Maritime Policy & Management**, v. 37, n. 3, p. 285–303, maio 2010.

MICHAIL, N. A. World economic growth and seaborne trade volume: Quantifying the relationship. **Transportation Research Interdisciplinary Perspectives**, v. 4, p. 100108, mar. 2020.

MIHIC, S.; GOLUSIN, M.; MIHAJLOVIC, M. Policy and promotion of sustainable inland waterway transport in Europe – Danube River. **Renewable and Sustainable Energy Reviews**, v. 15, n. 4, p. 1801–1809, maio 2011.

MOGES, D. M.; KMOCH, A.; UUEMAA, E. Application of satellite and reanalysis precipitation products for hydrological modeling in the data-scarce Porijõgi catchment, Estonia. **Journal of Hydrology: Regional Studies**, v. 41, p. 101070, 1 jun. 2022.

MOHAMMADI, K.; GOUDARZI, N. Study of inter-correlations of solar radiation, wind speed and precipitation under the influence of El Niño Southern Oscillation (ENSO) in California. **Renewable Energy**, v. 120, p. 190–200, 1 maio 2018.

MOIDEEN, H.; SOMAYAJULA, A.; FALZARANO, J. M. Application of Volterra Series Analysis for Parametric Rolling in Irregular Seas. **Journal of Ship Research**, v. 58, n. 02, p. 97–105, 1 jun. 2014.

MOLINA CARPIO, J. et al. Hydroclimatology of the Upper Madeira River basin: spatio-temporal variability and trends. **Hydrological Sciences Journal**, v. 62, p. 911–927, 13 abr. 2017.

MORRIS, R. K. A. Geomorphological analogues for large estuarine engineering projects: A case study of barrages, causeways and tidal energy projects. **Ocean & Coastal Management**, v. 79, p. 52–61, jul. 2013.

MOU, J. M. et al. Vessel traffic safety in busy waterways: A case study of accidents in western shenzhen port. **Accident Analysis & Prevention**, v. 123, p. 461–468, fev. 2019.

MU, Y.; BIGGS, T.; SHEN, S. S. P. Satellite-based precipitation estimates using a dense rain gauge network over the Southwestern Brazilian Amazon: Implication for identifying trends in dry season rainfall. **Atmospheric Research**, v. 261, p. 105741, 15 out. 2021.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I — A discussion of principles. **Journal of Hydrology**, v. 10, n. 3, p. 282–290, abr. 1970.

NASIR, H. A. et al. Efficient River Management using Stochastic MPC and Ensemble Forecast of Uncertain In-flows * *The first and the third authors acknowledge the financial support from

the Australian Research Council Linkage Project (LP130100605) and the Brescia Smart Living Project (MIURSCN00416) respectively. **IFAC-PapersOnLine**, v. 51, n. 5, p. 37–42, 2018.

NAWAZ, M.; IQBAL, M. F.; MAHMOOD, I. Validation of CHIRPS satellite-based precipitation dataset over Pakistan. **Atmospheric Research**, v. 248, p. 105289, jan. 2021.

NGUYEN, P. et al. The PERSIANN family of global satellite precipitation data: a review and evaluation of products. **Hydrology and Earth System Sciences**, v. 22, n. 11, p. 5801–5816, 13 nov. 2018.

NIKFAL, A. PostWRF: Interactive tools for the visualization of the WRF and ERA5 model outputs. **Environmental Modelling & Software**, v. 160, p. 105591, 1 fev. 2023.

NOËL, T. et al. Extending the global high-resolution downscaled projections dataset to include CMIP6 projections at increased resolution coherent with the ERA5-Land reanalysis. **Data in Brief**, v. 45, p. 108669, 1 dez. 2022.

NOKELAYNEN, T. MAPPING OF THE ENVIRONMENTAL IMPACTS OF INLAND WATERWAY TRANSPORT IN RUSSIA. **Proceedings of the International conference “InterCarto/InterGIS”**, v. 24, n. 1, p. 131–137, 14 jun. 2018.

NOUASSE, H. et al. Constraint satisfaction problem based on flow graph to study the resilience of inland navigation networks in a climate change context**This work is a contribution to GEPET-Eau project which is granted by the French ministry MEDDE-GICC, ORNERC and the DGTIM. <http://gepeteau.wordpress.com/enversion/>. **IFAC-PapersOnLine**, 8th IFAC Conference on Manufacturing Modelling, Management and Control MIM 2016. v. 49, n. 12, p. 331–336, 1 jan. 2016.

NPCF. **Normas e Procedimentos da Capitania Fluvial**. Marinha do Brasil, , 2015. Disponível em: <<https://www.marinha.mil.br/cfs/sites/www.marinha.mil.br.cfs/files/npcf.pdf>>

OLAOFÉ, Z. O. Quantification of the near-surface wind conditions of the African coast: A comparative approach (satellite, NCEP CFSR and WRF-based). **Energy**, v. 189, p. 116232, 15 dez. 2019.

PACA, V. H. DA M. et al. Variability of Trends in Precipitation across the Amazon River Basin Determined from the CHIRPS Precipitation Product and from Station Records. **Water**, v. 12, n. 5, p. 1244, 27 abr. 2020.

PAGOTTO, M. A. et al. Influence of regional rainfall and Atlantic sea surface temperature on tree-ring growth of *Poincianella pyramidalis*, semiarid forest from Brazil. **Dendrochronologia**, v. 35, p. 14–23, 1 out. 2015.

PAIK, J. K.; SEO, J. K.; KIM, B. J. Ultimate Limit State Assessment of the M.V. Derbyshire Hull Structure. **Journal of Offshore Mechanics and Arctic Engineering**, v. 130, n. 2, 28 fev. 2008.

PANDEY, R. S.; LIOU, Y.-A. Sea surface temperature (SST) and SST anomaly (SSTA) datasets over the last four decades (1977–2016) during typhoon season (May to November) in the entire Global Ocean, North Pacific Ocean, Philippine Sea, South China sea, and Eastern China Sea. **Data in Brief**, v. 45, p. 108646, 1 dez. 2022.

PAPACHARALAMPOUS, G. et al. Probabilistic Hydrological Post-Processing at Scale: Why and How to Apply Machine-Learning Quantile Regression Algorithms. **Water**, v. 11, n. 10, p. 2126, 14 out. 2019.

PAREDES-TREJO, F. J.; BARBOSA, H. A.; LAKSHMI KUMAR, T. V. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. **Journal of Arid Environments**, v. 139, p. 26–40, abr. 2017.

PAULAUSKAS, V.; PAULAUSKAS, D. Evaluating the width of navigational channels. **Transport**, v. 28, n. 2, p. 166–174, jun. 2013.

PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Updated world map of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, v. 11, n. 5, p. 1633–1644, 11 out. 2007.

PENG, T. et al. Streamflow Forecasting Using Empirical Wavelet Transform and Artificial Neural Networks. **Water**, v. 9, n. 6, p. 406, 7 jun. 2017.

PERDIGÃO, D. M.; HERLINGER, M.; WHITE, O. M. **Teoria e prática da pesquisa aplicada**. [s.l: s.n.].

PHAN, T.-T.-H.; NGUYEN, X. H. Combining statistical machine learning models with ARIMA for water level forecasting: The case of the Red river. **Advances in Water Resources**, v. 142, p. 103656, ago. 2020.

PIANC. **Harbour Approach Channels Design Guidelines, PIANC Report No. 121**. Place of publication not identified: PIANC, 2014.

PRAKASH, S. Performance assessment of CHIRPS, MSWEP, SM2RAIN-CCI, and TMPA precipitation products across India. **Journal of Hydrology**, v. 571, p. 50–59, 1 abr. 2019.

PRASAD, R. et al. Input selection and performance optimization of ANN-based streamflow forecasts in the drought-prone Murray Darling Basin region using IIS and MODWT algorithm. **Atmospheric Research**, v. 197, p. 42–63, nov. 2017.

RABELO, D. R.; SANTOS, M. R. DA S.; FILHO, M. R. P. D. S. Análise comparativa dos dados pluviométricos de satélite e de superfície em bacia hidrográfica semiárida. **Revista Brasileira de Sensoriamento Remoto**, v. 3, n. 1, 1 abr. 2022.

REN, T. et al. Real-time water level prediction of cascaded channels based on multilayer perception and recurrent neural network. **Journal of Hydrology**, v. 585, p. 124783, jun. 2020.

RIVERA, J. A.; MARIANETTI, G.; HINRICHS, S. Validation of CHIRPS precipitation dataset along the Central Andes of Argentina. **Atmospheric Research**, v. 213, p. 437–449, nov. 2018.

ROHACS, J.; SIMONGATI, G. The role of inland waterway navigation in a sustainable transport system. **Transport**, v. 22, 1 out. 2007.

RONG, L.; CUI, J. H. Comparison between Vessel's Displacements Calculated by Bonjean Curves and Hydrostatic Curves. **Applied Mechanics and Materials**, v. 278–280, p. 35–39, 2013.

RUGGERI, F. et al. **THE DEVELOPMENT OF REDRAFT® SYSTEM IN BRAZILIAN PORTS FOR SAFE UNDERKEEL CLEARANCE COMPUTATION**. 1 jan. 2018.

SADEGHI, M. et al. PERSIANN-CCS-CDR, a 3-hourly 0.04° global precipitation climate data record for heavy precipitation studies. **Scientific Data**, v. 8, n. 1, p. 157, 23 jun. 2021.

SAHOO, B. B. et al. Long short-term memory (LSTM) recurrent neural network for low-flow hydrological time series forecasting. **Acta Geophysica**, v. 67, n. 5, p. 1471–1481, 1 out. 2019.

SAIDELLES, C. W. et al. Directional correction of ERA5 and CAWCR wave spectrum partitions in the Southeast Brazil. **Ocean Engineering**, v. 265, p. 112475, 1 dez. 2022.

SAKALIS, G. N.; FRANGOPOULOS, C. A. Intertemporal optimization of synthesis, design and operation of integrated energy systems of ships: General method and application on a system with Diesel main engines. **Applied Energy**, v. 226, p. 991–1008, set. 2018.

SALMANI-DEHAGHI, N.; SAMANI, N. Development of bias-correction PERSIANN-CDR models for the simulation and completion of precipitation time series. **Atmospheric Environment**, v. 246, p. 117981, 1 fev. 2021.

SANIKHANI, H. et al. Temperature-based modeling of reference evapotranspiration using several artificial intelligence models: application of different modeling scenarios. **Theoretical and Applied Climatology**, v. 135, n. 1–2, p. 449–462, jan. 2019.

SANTOS, C. A. G. et al. Geospatial drought severity analysis based on PERSIANN-CDR-estimated rainfall data for Odisha state in India (1983–2018). **Science of The Total Environment**, v. 750, p. 141258, 1 jan. 2021.

SATGÉ, F. et al. Evaluation of 23 gridded precipitation datasets across West Africa. **Journal of Hydrology**, v. 581, p. 124412, 1 fev. 2020.

SAUX PICART, S. et al. A Sea Surface Temperature data record (2004–2012) from Meteosat Second Generation satellites. **Remote Sensing of Environment**, v. 240, p. 111687, 1 abr. 2020.

SCHALCK, S.; BAATRUP, J. Hydrostatic stability calculations by pressure integration. **Ocean Engineering**, v. 17, n. 1, p. 155–169, 1 jan. 1990.

SCHEEPERS, H. et al. The impact of climate change on inland waterway transport: Effects of low water levels on the Mackenzie River. **Journal of Hydrology**, v. 566, p. 285–298, nov. 2018.

SCHOENEICH, M. **Probabilistic Model of Under-Keel Clearance Assessment As a Practical Tool for Ships' Safety Determination in Existing and Designed Ports**. ICTIS

2011. **Anais...** Wuhan, China: American Society of Civil Engineers, 16 jun. 2011. Disponível em: <<http://ascelibrary.org/doi/10.1061/41177%28415%29339>>. Acesso em: 11 jul. 2020

SCHOSSLER, V. et al. Precipitation anomalies in the Brazilian southern coast related to the SAM and ENSO climate variability modes. **RBRH**, v. 23, p. e14, 16 abr. 2018.

SEGOVIA, P. et al. Model predictive control and moving horizon estimation for water level regulation in inland waterways. **Journal of Process Control**, v. 76, p. 1–14, abr. 2019.

SEO, Y. et al. Daily water level forecasting using wavelet decomposition and artificial intelligence techniques. **Journal of Hydrology**, v. 520, p. 224–243, jan. 2015.

SHANG, Y. et al. A method of direct, real-time forecasting of downstream water levels via hydropower station reregulation: A case study from Gezhouba Hydropower Plant, China. **Journal of Hydrology**, v. 573, p. 895–907, jun. 2019.

SHARP, E. et al. Evaluating the accuracy of CFSR reanalysis hourly wind speed forecasts for the UK, using in situ measurements and geographical information. **Renewable Energy**, v. 77, p. 527–538, 1 maio 2015.

SHEN, J.-C. et al. Real-time correction of water stage forecast using combination of forecasted errors by time series models and Kalman filter method. **Stochastic Environmental Research and Risk Assessment**, v. 29, n. 7, p. 1903–1920, out. 2015.

SHUKLA, S. et al. A seasonal agricultural drought forecast system for food-insecure regions of East Africa. **Hydrology and Earth System Sciences**, v. 18, n. 10, p. 3907–3921, 2 out. 2014.

SIKORA DE SOUZA, V. A. et al. Extreme rainfall events in Amazonia: The Madeira river basin. **Remote Sensing Applications: Society and Environment**, v. 18, p. 100316, 1 abr. 2020.

SOBRAL, B. S. et al. PERSIANN-CDR based characterization and trend analysis of annual rainfall in Rio De Janeiro State, Brazil. **Atmospheric Research**, v. 238, p. 104873, 1 jul. 2020.

SOLOMON, B. et al. Inland Waterway Transportation (IWT) in Ghana: A case study of Volta Lake Transport. **International Journal of Transportation Science and Technology**, p. S2046043020300332, maio 2020.

SORACHAMPA, P.; TIPPAYAWONG, N.; NGAMSANROAJ, K. Optimizing multiple reservoir system operation for maximum hydroelectric power generation. **Energy Reports**, v. 6, p. 67–75, fev. 2020.

STEINKOPF, J.; ENGELBRECHT, F. Verification of ERA5 and ERA-Interim precipitation over Africa at intra-annual and interannual timescales. **Atmospheric Research**, v. 280, p. 106427, dez. 2022.

SUÁREZ-ALEMÁN, A.; TRUJILLO, L.; MEDDA, F. Short sea shipping as intermodal competitor: a theoretical analysis of European transport policies. **Maritime Policy & Management**, v. 42, n. 4, p. 317–334, 19 maio 2015.

SUGENG, S. DAMPAK PELAYARAN KAPAL LAUT DI ALUR SUNGAI MUSI. **Gema Teknologi**, v. 16, n. 1, p. 49, 24 out. 2010.

SULAIMAN, S. O. et al. Precipitation pattern modeling using cross-station perception: regional investigation. **Environmental Earth Sciences**, v. 77, n. 19, p. 709, out. 2018.

SUN, W.; TREVOR, B. Multiple model combination methods for annual maximum water level prediction during river ice breakup. **Hydrological Processes**, v. 32, n. 3, p. 421–435, 30 jan. 2018.

SUN, Z. et al. MicroPort: A general simulation platform for seaport container terminals. **Advanced Engineering Informatics**, v. 26, n. 1, p. 80–89, jan. 2012.

TALCHABHADEL, R. et al. Evaluation of precipitation elasticity using precipitation data from ground and satellite-based estimates and watershed modeling in Western Nepal. **Journal of Hydrology: Regional Studies**, v. 33, p. 100768, fev. 2021.

TALLURI, L. et al. Techno economic and environmental assessment of wind assisted marine propulsion systems. **Ocean Engineering**, v. 121, p. 301–311, jul. 2016.

TANG, G. et al. Simulation-based optimization for generating the dimensions of a dredged coastal entrance channel. **SIMULATION**, v. 90, n. 9, p. 1059–1070, set. 2014.

TANG, G. et al. Effect of entrance channel dimensions on berth occupancy of container terminals. **Ocean Engineering**, v. 117, p. 174–187, maio 2016.

- TAYLOR, G. D. et al. A simulation-based software system for barge dispatching and boat assignment in inland waterways. **Simulation Modelling Practice and Theory**, v. 13, n. 7, p. 550–565, out. 2005.
- TAYLOR, N. B. Book review. **Journal of Transport Geography**, v. 69, p. 307, maio 2018.
- TEIXEIRA, C. A. N. et al. **Brazilian Inland Navigation**. BNDES Setorial 47 ed. Rio de Janeiro: National Bank for Economic and Social Development (BNDES), 2018.
- TOMY, T.; SUMAM, K. S. Determining the Adequacy of CFSR Data for Rainfall-Runoff Modeling Using SWAT. **Procedia Technology**, International Conference on Emerging Trends in Engineering, Science and Technology (ICETEST - 2015). v. 24, p. 309–316, 1 jan. 2016.
- TRENBERTH, K. E.; ZHANG, Y.; GEHNE, M. Intermittency in Precipitation: Duration, Frequency, Intensity, and Amounts Using Hourly Data. **Journal of Hydrometeorology**, v. 18, n. 5, p. 1393–1412, 1 maio 2017.
- TROJANOWSKI, J.; IWAN, S. Analysis of Szczecin Waterways in Terms of their Use to Handle Freight Transport in Urban Areas. **Procedia - Social and Behavioral Sciences**, v. 151, p. 333–341, out. 2014.
- TUPPER, E. C. Structures. Em: **Introduction to Naval Architecture**. [s.l.] Elsevier, 2013. p. 299–341.
- TVEDT, T. Why England and not China and India? Water systems and the history of the Industrial Revolution. **Journal of Global History**, v. 5, n. 1, p. 29–50, mar. 2010.
- ULLAH, W. et al. Comparing Multiple Precipitation Products against In-Situ Observations over Different Climate Regions of Pakistan. **Remote Sensing**, v. 11, n. 6, p. 628, jan. 2019.
- VAUCHEL, P. et al. A reassessment of the suspended sediment load in the Madeira River basin from the Andes of Peru and Bolivia to the Amazon River in Brazil, based on 10years of data from the HYBAM monitoring programme. **Journal of Hydrology**, v. 553, p. 35–48, 1 out. 2017.
- VIDAN, P.; KASUM, J.; JOLIĆ, N. A PROPOSAL FOR THE MODELS AND MEASURES OF SEARCH AND RESCUE ON INLAND WATERWAYS. **TRANSPORT**, v. 25, n. 2, p. 178–185, 30 jun. 2010.

- WAGENA, M. B. et al. Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. **Environmental Modelling & Software**, v. 126, p. 104669, abr. 2020.
- WANG, G.-G. et al. ENSO analysis and prediction using deep learning: A review. **Neurocomputing**, v. 520, p. 216–229, 1 fev. 2023.
- WANG, L. et al. Forecasting Monthly Tourism Demand Using Enhanced Backpropagation Neural Network. **Neural Processing Letters**, v. 52, n. 3, p. 2607–2636, dez. 2020.
- WANG, W. et al. Impact of Navigational Safety Level on Seaport Fairway Capacity. **Journal of Navigation**, v. 68, n. 6, p. 1120–1132, nov. 2015a.
- WANG, W. et al. Impact of Navigational Safety Level on Seaport Fairway Capacity. **Journal of Navigation**, v. 68, n. 6, p. 1120–1132, nov. 2015b.
- WATAI, R. et al. **AN INTEGRATED ANALYSIS FOR THE PASSING SHIP PROBLEM ON SANTOS PORT CONSIDERING REAL-TIME SIMULATIONS AND MOORED SHIP DYNAMICS**. 1 jan. 2018.
- WATLING, J. et al. Phytoliths from native plants and surface soils from the Upper Madeira river, SW Amazonia, and their potential for paleoecological reconstruction. **Quaternary International**, v. 550, p. 85–110, 10 jun. 2020.
- WAZLAWICK, R. S. **Metodologia de pesquisa para ciência da computação**. [s.l.: s.n.].
- WETZSTEIN, B. et al. Transportation costs: Mississippi River barge rates. **Journal of Commodity Markets**, p. 100123, jan. 2020.
- WICK, G. A.; JACKSON, D. L.; CASTRO, S. L. Assessing the ability of satellite sea surface temperature analyses to resolve spatial variability – The northwest tropical Atlantic ATOMIC region. **Remote Sensing of Environment**, v. 284, p. 113377, 1 jan. 2023.
- WIEGMANS, B.; KONINGS, R. Intermodal Inland Waterway Transport: Modelling Conditions Influencing Its Cost Competitiveness. **The Asian Journal of Shipping and Logistics**, v. 31, n. 2, p. 273–294, jun. 2015.

WILLIAMSSON, J.; ROGERSON, S.; SANTÉN, V. Business models for dedicated container freight on Swedish inland waterways. **Research in Transportation Business & Management**, p. 100466, mar. 2020.

WOJEWÓDZKA-KRÓL, K.; ROLBIECKI, R. Innovative solutions for inland waterway transport. **Transport Economics and Logistics**, v. 80, p. 245–255, 31 dez. 2018.

WORQLUL, A. W. et al. Evaluation of CFSR, TMPA 3B42 and ground-based rainfall data as input for hydrological models, in data-scarce regions: The upper Blue Nile Basin, Ethiopia. **CATENA**, v. 152, p. 242–251, 1 maio 2017.

WU, H. et al. Variation and comparison of cloud cover in MODIS and four reanalysis datasets of ERA-interim, ERA5, MERRA-2 and NCEP. **Atmospheric Research**, v. 281, p. 106477, 1 jan. 2023.

WWINN. **SOUTH AMERICA - Brazil Inland Waterways**. Organização. Disponível em: <<https://www.wwinn.org/brazil-inland-waterways>>. Acesso em: 6 dez. 2022.

XU, D.; LI, C.-L.; LEUNG, J. Y.-T. Berth allocation with time-dependent physical limitations on vessels. **European Journal of Operational Research**, v. 216, n. 1, p. 47–56, jan. 2012.

XU, H.; XIA, Y. F.; WEN, Y. C. Study on Characteristics of River Evolution of Chengtong Reach in the Lower Reach of the Yangtze River Before and After Operation of the Three Gorges Project. Em: TRUNG VIET, N.; XIPING, D.; THANH TUNG, T. (Eds.). **APAC 2019**. Singapore: Springer Singapore, 2020. p. 745–749.

XU, J.; ZHANG, Z.; MOOKERJEE, V. S. Applying bi-random MODM model to navigation coordinated scheduling: a case study of Three Gorges Project. **Transport**, v. 28, n. 2, p. 140–157, jun. 2013.

YANG, J.-H.; CHENG, C.-H.; CHAN, C.-P. A Time-Series Water Level Forecasting Model Based on Imputation and Variable Selection Method. **Computational Intelligence and Neuroscience**, v. 2017, p. 1–11, 2017.

YANG, Y.; LUO, Y. Evaluating the performance of remote sensing precipitation products CMORPH, PERSIANN, and TMPA, in the arid region of northwest China. **Theoretical and Applied Climatology**, v. 118, n. 3, p. 429–445, nov. 2014.

- YAPO, P. O.; GUPTA, H. V.; SOROOSHIAN, S. Automatic calibration of conceptual rainfall-runoff models: sensitivity to calibration data. **Journal of Hydrology**, v. 181, n. 1, p. 23–48, 1 jun. 1996.
- YASEEN, Z. M. et al. Application of the Hybrid Artificial Neural Network Coupled with Rolling Mechanism and Grey Model Algorithms for Streamflow Forecasting Over Multiple Time Horizons. **Water Resources Management**, v. 32, n. 5, p. 1883–1899, mar. 2018.
- YASEEN, Z. M. et al. An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. **Journal of Hydrology**, v. 569, p. 387–408, fev. 2019.
- YILMAZ, M. Accuracy assessment of temperature trends from ERA5 and ERA5-Land. **Science of The Total Environment**, v. 856, p. 159182, 15 jan. 2023.
- YU, Z.; WU, J.; CHEN, X. An approach to revising the climate forecast system reanalysis rainfall data in a sparsely-gauged mountain basin. **Atmospheric Research**, v. 220, p. 194–205, 15 maio 2019.
- ZAMBRANO, F. et al. Evaluating satellite-derived long-term historical precipitation datasets for drought monitoring in Chile. **Atmospheric Research**, v. 186, p. 26–42, 1 abr. 2017.
- ZHANG, D. et al. Incorporation of formal safety assessment and Bayesian network in navigational risk estimation of the Yangtze River. **Reliability Engineering & System Safety**, v. 118, p. 93–105, out. 2013.
- ZHANG, Y. et al. Evaluation and comparison of precipitation estimates and hydrologic utility of CHIRPS, TRMM 3B42 V7 and PERSIANN-CDR products in various climate regimes. **Atmospheric Research**, v. 265, p. 105881, 1 jan. 2022a.
- ZHANG, Y. et al. IOD, ENSO, and seasonal precipitation variation over Eastern China. **Atmospheric Research**, v. 270, p. 106042, jun. 2022b.
- ZHAO, F. et al. Power management of vessel propulsion system for thrust efficiency and emissions mitigation. **Applied Energy**, v. 161, p. 124–132, jan. 2016.
- ZHEN, L. et al. Daily berth planning in a tidal port with channel flow control. **Transportation Research Part B: Methodological**, v. 106, p. 193–217, dez. 2017.

ZHU, S. et al. Forecasting of water level in multiple temperate lakes using machine learning models. **Journal of Hydrology**, v. 585, p. 124819, jun. 2020.

ZHU, Y.; ZHANG, R.-H. A deep learning-based U-Net model for ENSO-related precipitation responses to sea surface temperature anomalies over the tropical Pacific. **Atmospheric and Oceanic Science Letters**, p. 100351, 28 fev. 2023.

ZIJL, F.; SUMIHAR, J.; VERLAAN, M. Application of data assimilation for improved operational water level forecasting on the northwest European shelf and North Sea. **Ocean Dynamics**, v. 65, n. 12, p. 1699–1716, dez. 2015.

ZUO, L. et al. Responses of river bed evolution to flow-sediment process changes after Three Gorges Project in middle Yangtze River: A case study of Yaojian reach. **Water Science and Engineering**, p. S1674237020300168, mar. 2020.

ANEXOS

ANEXO 01: SÉRIE TEMPORAL UTILIZADA

Data	T1	T2	T3	T4	T5	T6	PRPV	PRCJ	PRFZ	NAPV
01/03/1990	27,53	28,75	28,00	25,76	26,56	24,69	296,46	340,96	265,12	1358
01/04/1990	28,09	28,72	28,29	26,84	26,47	22,71	179,89	212,53	350,22	1241
01/05/1990	28,04	28,61	28,30	26,87	25,10	22,92	91,37	140,80	204,80	1171
01/06/1990	27,49	28,65	28,05	25,85	23,44	23,07	49,56	35,63	113,19	1041
01/07/1990	27,92	29,23	28,15	24,95	21,36	21,12	33,82	31,99	171,86	791
01/08/1990	28,10	29,46	28,49	24,73	21,34	21,49	87,68	75,61	56,30	485
01/09/1990	27,64	29,39	28,07	24,86	20,93	20,65	95,55	85,02	67,23	406
01/10/1990	28,35	28,96	28,48	24,51	20,86	21,19	223,28	223,63	58,08	494
01/11/1990	27,68	29,00	28,38	24,41	21,20	21,36	179,86	165,47	136,34	888
01/12/1990	28,13	29,82	28,77	24,86	22,32	22,09	270,65	268,73	218,13	1070
01/01/1991	27,22	29,80	28,20	25,69	23,83	22,76	433,58	409,64	378,45	1308
01/02/1991	27,24	28,46	27,62	25,74	25,50	25,40	281,97	276,22	243,70	1479
01/03/1991	27,31	28,28	27,82	26,16	26,79	24,86	326,16	374,87	352,92	1520
01/04/1991	27,75	28,33	27,86	27,35	25,49	22,46	226,61	197,91	279,14	1477
01/05/1991	28,59	29,17	28,80	27,19	26,04	23,40	148,66	139,77	247,43	1276
01/06/1991	28,40	28,90	28,62	27,24	24,88	22,81	33,24	30,51	144,08	1080,5
01/07/1991	28,69	29,34	28,77	25,94	23,18	22,62	8,80	11,40	170,24	769,5
01/08/1991	28,40	29,45	28,84	25,00	21,38	22,58	21,51	17,84	49,53	539
01/09/1991	28,41	29,46	28,73	24,14	20,98	21,98	54,66	77,48	45,98	348
01/10/1991	28,72	30,19	29,01	24,51	21,46	22,53	154,16	146,66	92,28	413
01/11/1991	22,73	29,27	29,74	25,64	23,17	22,73	173,31	155,71	52,11	646
01/12/1991	29,82	29,12	29,56	26,45	23,56	23,33	247,48	254,63	176,06	933
01/01/1992	29,56	28,55	29,13	27,23	24,76	24,25	305,51	315,14	184,62	1254
01/02/1992	29,00	28,86	29,03	27,36	26,20	26,06	338,80	381,43	375,07	1300
01/03/1992	29,08	28,91	28,93	27,75	27,74	27,58	301,92	321,38	267,75	1558
01/04/1992	29,35	29,15	29,17	28,59	27,76	27,31	189,83	241,92	212,15	1528
01/05/1992	29,51	29,55	29,47	27,79	27,18	26,12	97,48	104,16	107,26	1435
01/06/1992	28,14	29,55	28,88	26,17	24,16	23,87	41,28	20,66	68,57	1233
01/07/1992	28,54	29,82	28,75	24,91	21,69	21,76	14,68	11,33	101,26	1089
01/08/1992	27,61	28,74	27,99	24,13	20,96	21,02	62,39	81,16	123,69	678
01/09/1992	27,06	28,94	28,19	24,32	20,37	20,67	97,97	118,60	48,20	783
01/10/1992	26,45	28,71	27,41	23,86	20,76	21,60	130,09	129,26	54,69	908
01/11/1992	27,16	27,97	27,13	24,24	21,36	21,98	212,44	222,91	118,82	905
01/12/1992	27,21	28,85	28,00	24,74	22,08	21,94	325,69	315,09	196,92	1180
01/01/1993	27,17	28,91	27,69	25,06	23,92	24,14	423,95	413,68	297,95	1400
01/02/1993	27,16	28,94	27,53	26,33	26,09	26,30	333,67	359,82	295,29	1581
01/03/1993	27,26	28,04	27,79	26,78	27,90	26,46	373,28	322,16	309,63	1646
01/04/1993	27,64	28,50	28,25	28,03	27,54	25,15	238,67	269,83	279,40	1660,5
01/05/1993	28,29	29,40	28,88	27,97	26,03	24,37	90,17	68,73	129,64	1445
01/06/1993	28,24	29,48	28,81	25,83	24,41	23,24	37,70	23,48	111,90	1086
01/07/1993	28,33	29,49	28,78	24,99	22,49	22,33	43,06	36,56	81,44	726
01/08/1993	27,34	29,99	28,57	24,60	21,30	21,01	163,99	105,23	80,55	543
01/09/1993	27,72	29,52	28,66	24,58	20,87	21,03	75,49	72,81	76,16	507
01/10/1993	27,64	29,16	27,84	24,60	22,04	21,48	163,46	165,40	86,80	498
01/11/1993	27,22	29,01	28,06	24,59	22,11	23,01	274,43	265,77	167,04	778
01/12/1993	27,00	28,89	27,67	24,47	22,78	22,27	360,66	337,21	166,55	1054
01/01/1994	26,29	28,20	26,91	24,80	24,47	24,78	386,77	348,61	498,68	1253
01/02/1994	26,47	27,35	26,75	25,11	25,52	25,06	402,94	433,67	385,48	1444
01/03/1994	27,32	27,84	27,65	26,22	25,13	22,94	240,20	252,35	326,15	1469
01/04/1994	27,66	27,97	27,73	26,11	24,39	22,16	184,13	214,14	293,25	1474
01/05/1994	28,07	28,81	28,60	26,36	24,21	22,11	81,66	101,77	211,82	1264
01/06/1994	28,21	29,06	28,77	26,25	23,75	23,21	33,61	39,07	131,23	895

01/07/1994	28,73	30,00	29,28	23,94	21,66	21,29	23,07	29,86	87,07	610
01/08/1994	28,81	30,37	29,61	24,53	20,00	20,20	44,72	31,69	129,17	442
01/09/1994	28,52	30,13	29,19	24,30	20,45	20,14	62,49	71,85	58,41	274
01/10/1994	28,68	30,43	29,67	24,98	22,55	22,96	191,01	212,78	101,44	409
01/11/1994	28,80	29,88	29,91	25,90	23,25	23,08	286,70	301,10	96,60	827
01/12/1994	29,20	29,58	29,68	26,06	23,65	23,59	354,22	346,37	140,36	927
01/01/1995	28,45	28,89	29,36	25,16	24,96	24,45	287,23	295,39	200,13	1272
01/02/1995	27,91	29,35	28,40	26,19	26,23	25,53	235,53	267,45	224,84	1354
01/03/1995	27,73	28,90	28,37	25,72	27,01	24,62	257,34	308,14	380,78	1526
01/04/1995	28,24	28,95	28,62	26,32	24,97	23,34	216,98	193,36	272,80	1492
01/05/1995	28,03	29,01	28,74	25,45	23,50	22,68	139,82	134,76	242,04	1232
01/06/1995	27,68	28,89	28,27	25,44	23,06	22,05	63,39	27,90	95,42	886
01/07/1995	27,55	28,80	28,30	24,84	22,00	21,32	20,54	15,51	74,97	608
01/08/1995	26,82	28,40	27,68	23,20	20,45	21,30	44,62	22,73	42,16	505
01/09/1995	27,05	27,95	27,46	22,65	20,27	21,36	104,02	98,84	45,46	282
01/10/1995	26,40	27,82	27,14	22,66	20,85	21,47	107,81	106,48	81,28	285
01/11/1995	26,57	27,89	26,82	23,15	21,57	22,04	257,49	247,54	267,49	402
01/12/1995	26,14	27,76	27,00	23,45	21,50	22,28	320,49	297,52	251,62	837
01/01/1996	25,54	27,54	26,78	24,58	23,39	23,49	363,27	355,64	296,40	1042
01/02/1996	25,65	26,53	26,08	24,57	25,64	25,32	253,14	267,83	332,52	1344
01/03/1996	26,06	26,93	26,50	25,43	26,66	26,13	303,14	351,35	302,81	1378
01/04/1996	27,15	27,40	27,21	25,92	24,30	21,58	288,76	313,32	335,15	1421
01/05/1996	27,80	27,85	27,88	25,82	24,00	23,53	86,26	85,15	272,05	1107
01/06/1996	27,67	28,44	28,26	25,34	22,33	21,93	17,77	9,35	177,25	855
01/07/1996	27,96	28,38	27,85	24,85	20,95	20,23	6,03	5,33	74,63	593
01/08/1996	27,73	28,29	28,33	23,92	20,61	20,17	109,29	85,68	90,64	353
01/09/1996	27,31	28,54	27,50	24,26	19,71	20,30	90,54	78,48	45,88	355
01/10/1996	26,81	28,38	27,82	23,51	20,11	21,15	179,94	182,71	86,54	429
01/11/1996	26,90	28,65	27,50	24,23	20,50	20,98	323,38	309,27	280,12	742
01/12/1996	27,08	28,42	27,36	23,67	21,12	21,60	258,63	293,68	142,41	913
01/01/1997	26,68	28,14	27,42	23,81	22,80	22,58	307,50	314,22	287,40	1236
01/02/1997	26,83	28,09	27,47	24,76	25,49	25,37	372,65	369,29	235,76	1438
01/03/1997	26,91	28,28	28,01	26,25	27,24	26,67	418,72	470,62	314,30	1656
01/04/1997	28,16	29,72	29,43	26,71	27,07	25,49	229,19	267,11	252,21	1681
01/05/1997	29,24	29,52	29,50	27,17	26,70	25,78	109,63	116,60	168,43	1468
01/06/1997	29,38	29,37	29,48	27,76	26,40	25,72	49,97	44,99	49,59	1192
01/07/1997	29,51	29,39	29,33	27,74	26,43	25,74	17,02	16,44	13,75	851
01/08/1997	29,58	29,15	29,77	27,48	25,39	24,74	171,24	154,36	41,91	563
01/09/1997	29,95	30,23	29,76	27,24	25,16	24,28	42,96	44,28	9,38	375
01/10/1997	29,33	29,01	28,91	27,94	25,89	25,92	178,09	206,01	47,36	487
01/11/1997	29,49	29,60	29,50	28,19	26,72	26,75	136,89	147,12	145,79	651
01/12/1997	28,65	29,03	28,84	28,82	27,33	27,36	329,26	301,47	134,31	969
01/01/1998	29,00	29,00	28,70	28,48	28,57	27,92	247,90	259,33	187,47	1142
01/02/1998	28,81	28,79	29,11	28,79	29,00	28,04	242,68	224,07	235,95	1223
01/03/1998	28,30	28,74	28,76	29,37	30,10	28,66	315,84	342,40	323,92	1462
01/04/1998	27,80	28,53	28,43	28,95	29,00	28,77	176,13	179,95	297,32	1477
01/05/1998	28,21	28,67	28,65	27,59	27,84	28,13	109,76	129,85	205,45	1132
01/06/1998	27,14	27,96	28,00	24,06	25,22	25,26	17,69	16,96	159,37	766
01/07/1998	26,07	27,40	27,00	23,16	23,07	23,64	6,94	5,78	118,41	517
01/08/1998	25,36	27,69	26,74	23,17	21,87	21,53	81,72	60,93	63,27	355
01/09/1998	25,87	27,39	26,87	22,80	21,09	21,30	44,52	44,74	79,79	332
01/10/1998	24,95	26,27	25,70	22,60	21,21	22,06	127,22	136,89	67,75	437
01/11/1998	24,62	26,25	25,53	22,79	21,70	20,75	233,33	220,13	153,19	842
01/12/1998	24,77	26,57	25,29	21,87	21,91	22,21	276,80	253,89	78,22	1123
01/01/1999	24,46	25,65	24,90	22,70	24,09	23,94	381,67	358,76	356,78	1288
01/02/1999	24,90	25,80	25,27	24,85	25,03	25,29	304,38	312,56	403,64	1472
01/03/1999	25,58	26,17	26,13	26,04	28,12	26,29	136,32	154,08	364,70	1482
01/04/1999	25,95	26,37	26,57	26,55	25,75	22,64	151,79	162,60	248,47	1454

01/05/1999	26,81	27,52	27,12	25,37	25,48	22,73	135,31	113,35	261,59	1172
01/06/1999	26,56	27,96	27,47	25,03	23,99	20,57	72,52	91,35	139,15	866
01/07/1999	26,43	27,35	26,97	24,44	21,80	20,46	8,35	7,37	108,38	679
01/08/1999	26,09	27,67	26,96	23,11	20,41	19,84	38,49	34,59	40,62	394
01/09/1999	26,46	27,61	26,96	22,80	19,39	20,86	83,22	85,40	95,25	278
01/10/1999	26,53	27,71	26,93	22,68	19,33	21,13	79,83	109,46	111,66	322
01/11/1999	25,72	27,47	26,48	22,35	20,00	20,97	131,26	143,03	113,54	429
01/12/1999	25,10	26,92	26,16	22,40	21,40	23,10	179,28	219,28	195,37	822
01/01/2000	24,93	26,82	25,57	22,33	23,17	23,21	348,95	355,43	367,49	1060
01/02/2000	24,79	26,26	25,74	24,36	25,96	25,63	246,89	259,23	276,27	1267
01/03/2000	25,09	26,48	25,69	25,93	27,67	24,79	259,89	271,30	406,45	1403
01/04/2000	26,13	27,00	26,25	26,98	28,45	25,02	157,91	158,30	333,93	1317
01/05/2000	26,52	27,49	27,18	25,93	25,80	22,64	70,32	88,83	238,59	1045
01/06/2000	27,60	28,48	28,12	25,21	23,67	21,85	27,07	17,66	141,66	842
01/07/2000	27,10	28,35	27,62	24,69	21,81	20,95	58,22	52,77	149,72	604
01/08/2000	27,05	28,26	27,36	24,27	20,44	19,88	138,25	95,50	64,97	418
01/09/2000	27,01	28,39	27,47	23,78	20,45	19,71	78,82	84,46	103,62	461
01/10/2000	26,63	27,58	27,03	24,00	21,27	21,15	199,93	197,28	104,96	345
01/11/2000	26,54	27,39	26,95	23,29	20,71	20,54	218,94	216,87	122,37	649
01/12/2000	25,35	27,00	25,92	23,80	21,82	22,66	347,83	336,51	98,30	919
01/01/2001	25,41	26,93	26,20	24,83	23,77	23,28	318,35	345,74	373,32	1202
01/02/2001	25,88	26,63	26,20	25,61	26,40	24,48	313,77	313,24	198,92	1449
01/03/2001	26,23	27,12	26,54	26,96	27,77	26,60	291,57	284,46	306,14	1613
01/04/2001	27,11	27,64	27,61	26,60	27,00	24,54	201,28	224,43	284,44	1502
01/05/2001	27,50	28,56	28,14	26,55	25,66	22,49	110,65	119,81	165,29	1262
01/06/2001	27,78	28,62	28,27	26,43	23,56	21,51	55,71	63,51	201,73	1011
01/07/2001	28,28	29,10	28,67	24,82	22,30	20,88	63,26	58,86	104,28	693
01/08/2001	27,76	29,01	28,30	24,47	20,35	20,81	54,95	32,87	18,95	477
01/09/2001	28,05	29,61	28,88	23,57	19,99	19,82	135,01	111,75	55,77	338
01/10/2001	27,59	28,87	28,33	24,31	19,74	20,78	187,94	209,75	60,95	409
01/11/2001	27,58	29,17	28,00	23,67	20,72	21,50	171,20	180,26	102,60	731
01/12/2001	26,81	28,94	28,00	24,02	21,98	22,99	374,10	349,91	156,30	966
01/01/2002	27,75	29,75	28,41	24,56	23,35	23,87	279,63	253,71	196,63	1185
01/02/2002	27,62	28,25	28,26	25,54	25,52	26,45	263,90	250,84	316,50	1320
01/03/2002	27,27	28,29	27,63	26,80	28,29	27,13	247,00	240,96	316,17	1512
01/04/2002	28,27	29,21	28,39	27,05	26,51	24,68	185,04	201,40	311,98	1379
01/05/2002	28,74	29,77	28,94	27,12	25,72	24,40	136,15	138,18	282,54	1177
01/06/2002	28,94	29,58	29,31	27,15	24,60	22,55	17,24	7,14	174,08	968
01/07/2002	28,83	30,00	29,44	25,76	22,89	22,16	25,06	27,24	57,72	623
01/08/2002	29,00	29,83	30,15	25,19	21,34	21,08	129,28	122,86	67,11	422
01/09/2002	29,53	29,77	29,83	25,15	22,69	22,21	75,56	83,44	48,43	356
01/10/2002	30,19	29,67	30,37	25,26	22,83	24,11	186,13	159,18	103,91	430
01/11/2002	29,68	30,05	30,11	25,90	23,65	24,01	218,01	216,34	86,34	593
01/12/2002	29,32	29,85	29,96	26,23	24,25	24,47	455,09	439,06	201,32	890
01/01/2003	28,54	29,45	29,55	26,18	24,95	24,00	391,09	400,04	146,19	1140
01/02/2003	27,84	29,64	28,52	26,36	25,91	25,02	302,44	277,24	213,59	1362
01/03/2003	28,14	29,10	28,74	26,74	27,21	26,07	314,99	323,31	295,86	1445
01/04/2003	27,33	28,56	28,04	26,61	25,59	23,78	186,32	196,07	307,67	1451
01/05/2003	27,43	28,37	28,08	25,42	23,50	23,27	169,86	168,34	194,53	1145
01/06/2003	27,96	28,81	28,47	25,37	22,55	21,06	53,72	46,48	177,76	903
01/07/2003	28,05	28,74	28,33	25,53	22,56	20,97	9,65	7,24	98,21	568
01/08/2003	27,44	28,84	28,25	24,66	22,17	21,76	115,11	86,84	100,18	383
01/09/2003	27,80	28,96	28,25	25,00	20,48	21,79	119,91	105,58	72,64	297
01/10/2003	27,89	29,19	28,83	25,24	21,75	23,42	188,74	186,91	71,42	431
01/11/2003	27,73	29,00	28,49	25,18	22,17	24,04	164,82	173,80	96,93	529
01/12/2003	27,14	29,03	27,99	25,93	23,84	23,57	282,45	295,22	147,37	813
01/01/2004	26,91	29,33	27,89	25,50	24,81	23,79	354,39	319,85	272,21	1295
01/02/2004	27,02	28,31	27,59	26,30	26,34	25,31	279,08	275,43	293,65	1374

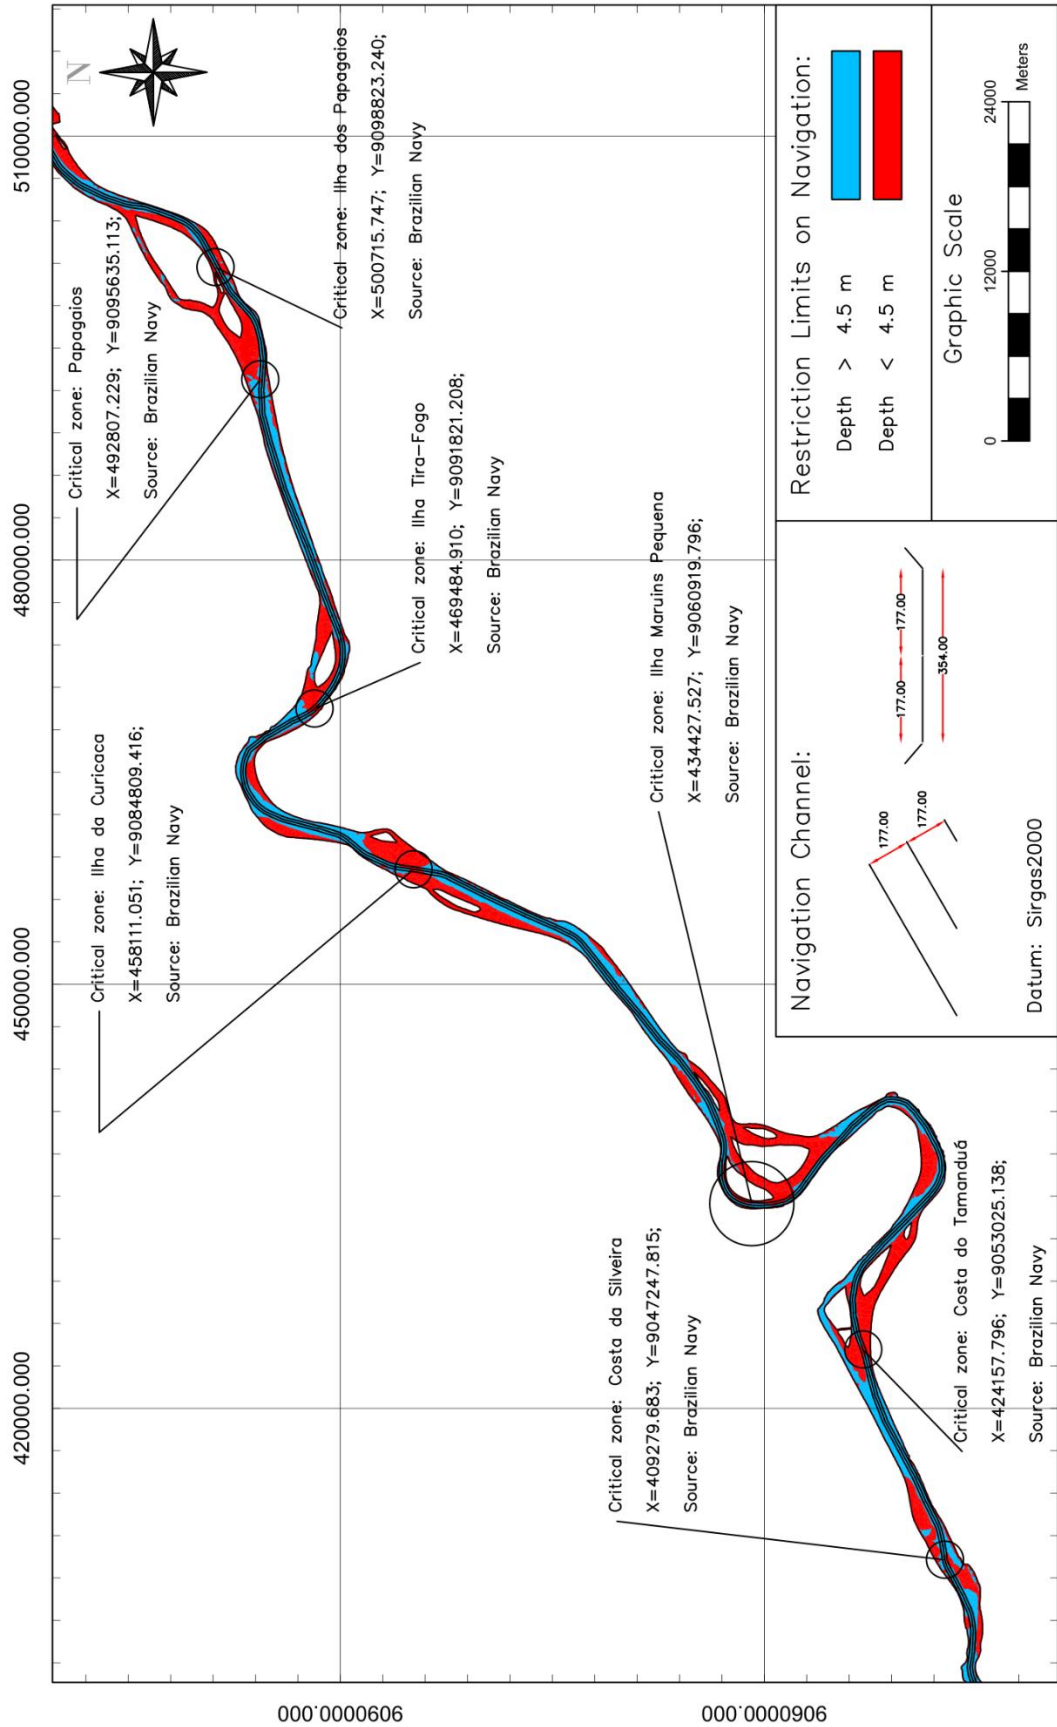
01/03/2004	27,14	28,10	27,71	26,62	27,16	23,00	331,67	335,39	389,98	1300
01/04/2004	27,82	28,72	28,36	26,79	26,30	23,25	186,58	184,74	270,85	1288
01/05/2004	28,50	29,27	28,89	26,82	24,29	23,01	90,71	92,42	273,24	1104
01/06/2004	28,21	28,90	28,48	25,91	23,87	21,54	33,43	27,48	127,78	815
01/07/2004	28,53	29,78	28,96	25,07	21,81	21,12	21,58	17,40	130,59	606
01/08/2004	28,56	29,71	28,72	25,45	20,67	20,85	88,56	70,23	69,33	456
01/09/2004	28,67	29,74	29,12	24,68	21,05	20,51	74,20	68,79	90,97	320
01/10/2004	28,53	29,65	28,98	25,00	22,10	22,55	209,43	219,87	118,16	344
01/11/2004	28,42	29,63	29,13	25,32	22,92	23,74	287,26	281,81	103,01	604
01/12/2004	28,24	29,31	28,94	25,22	23,08	22,42	292,80	268,66	138,26	897
01/01/2005	27,85	29,58	28,65	25,64	24,72	24,23	264,74	264,15	182,19	1137
01/02/2005	27,23	29,40	27,82	25,68	25,07	24,24	344,44	327,50	331,45	1228
01/03/2005	27,85	28,83	28,09	26,47	25,91	23,33	359,44	401,58	398,19	1361
01/04/2005	28,02	28,88	28,44	27,26	26,56	25,71	129,48	157,42	289,51	1262
01/05/2005	28,28	28,78	28,69	26,78	25,18	24,27	113,19	118,35	204,84	932
01/06/2005	28,38	29,27	28,52	26,14	22,86	21,60	12,99	14,83	102,22	785
01/07/2005	27,94	29,13	28,16	25,20	22,93	20,94	6,56	0,00	80,55	493
01/08/2005	27,10	28,65	28,09	24,70	21,24	21,35	60,28	62,98	31,33	264
01/09/2005	27,33	28,94	27,82	24,41	20,17	21,22	43,76	53,26	41,28	181
01/10/2005	27,38	28,41	27,76	24,24	20,20	21,18	196,57	172,00	69,91	298
01/11/2005	26,71	28,43	27,31	23,33	19,90	21,74	172,33	170,86	193,81	597
01/12/2005	26,45	28,12	27,18	22,74	21,29	23,28	291,20	304,40	264,49	842,5
01/01/2006	25,56	27,47	26,55	23,73	23,97	24,16	306,95	301,65	287,04	1249
01/02/2006	25,71	26,97	26,47	24,83	26,95	26,68	317,10	327,56	432,66	1521
01/03/2006	26,39	27,43	27,16	25,06	26,64	25,83	255,02	251,99	378,60	1556
01/04/2006	27,31	27,71	27,76	26,66	26,12	22,55	261,15	276,83	293,35	1548
01/05/2006	27,65	28,28	27,97	26,87	25,65	23,51	89,14	91,12	322,15	1177
01/06/2006	28,31	28,94	28,44	26,28	24,28	22,20	15,44	12,65	132,13	850
01/07/2006	28,03	29,38	28,68	25,02	23,11	22,00	20,43	9,63	104,20	591
01/08/2006	28,07	30,06	28,70	25,18	22,28	22,13	56,06	40,63	53,88	370
01/09/2006	28,42	30,43	28,93	25,31	22,66	22,22	65,70	66,22	59,57	261
01/10/2006	28,81	30,28	29,27	25,35	23,34	24,39	185,93	167,71	61,78	407
01/11/2006	29,04	30,47	29,39	26,04	23,49	23,51	181,38	187,53	200,66	756
01/12/2006	28,64	30,32	29,39	26,53	24,16	23,07	360,17	334,87	181,96	948,5
01/01/2007	27,61	28,68	28,62	26,13	25,75	24,43	365,78	424,48	266,62	1232
01/02/2007	26,96	28,88	27,96	24,71	26,31	25,17	251,65	243,14	182,77	1341
01/03/2007	27,50	28,46	28,17	25,35	26,06	24,14	307,29	321,51	355,60	1539
01/04/2007	27,69	28,42	28,23	26,79	25,48	23,08	203,78	232,71	336,02	1583
01/05/2007	27,77	28,64	28,15	25,21	24,08	22,91	98,00	117,02	262,88	1419
01/06/2007	28,09	28,64	28,47	25,63	22,82	23,42	6,08	11,17	136,86	1080
01/07/2007	27,56	28,45	27,98	24,44	21,68	21,10	24,81	24,12	149,67	681
01/08/2007	27,52	28,13	27,88	23,03	19,86	19,95	45,09	25,85	85,31	468
01/09/2007	26,63	28,04	27,31	23,02	19,23	18,17	57,17	52,28	69,31	276
01/10/2007	26,41	27,94	27,10	22,57	19,17	21,22	169,75	159,85	61,03	359
01/11/2007	25,86	27,17	26,32	23,00	19,41	20,35	212,24	214,01	110,93	754
01/12/2007	25,66	27,37	26,82	22,78	20,66	21,83	281,55	260,33	259,25	1043
01/01/2008	24,89	26,11	25,47	23,13	23,57	24,54	434,27	463,37	271,98	1313
01/02/2008	25,35	25,89	25,33	23,61	26,19	26,86	291,06	283,79	243,28	1533
01/03/2008	25,54	26,27	26,33	25,55	27,75	26,78	298,03	325,22	386,09	1590
01/04/2008	26,33	26,79	26,96	26,38	27,72	25,63	176,70	180,51	280,71	1624
01/05/2008	26,74	27,24	26,91	26,30	26,24	23,41	128,79	165,81	258,76	1431
01/06/2008	27,04	27,70	27,42	25,80	24,48	22,89	17,36	11,35	176,70	1112
01/07/2008	27,02	28,06	27,35	25,52	23,96	22,65	12,83	8,51	115,96	727
01/08/2008	26,70	27,52	27,10	25,05	23,11	22,65	51,61	34,85	106,52	522
01/09/2008	26,76	27,67	27,43	24,38	21,93	22,04	97,56	95,20	92,91	395
01/10/2008	27,18	28,07	27,56	24,49	22,04	22,08	86,82	90,36	145,68	446
01/11/2008	26,83	28,00	27,54	24,94	21,86	22,15	283,08	275,23	159,41	607
01/12/2008	25,82	27,56	26,66	23,65	22,24	22,50	389,87	341,23	201,46	693


01/01/2009	25,21	26,90	26,16	24,20	24,71	23,88	443,74	407,94	326,52	1139
01/02/2009	25,81	26,75	26,19	24,76	26,57	24,37	370,20	355,39	369,18	1237
01/03/2009	26,36	27,39	26,67	25,07	26,87	24,70	321,08	309,35	406,16	1467
01/04/2009	27,58	27,94	27,52	26,59	27,49	23,67	255,53	241,79	248,17	1514
01/05/2009	28,13	28,64	28,36	27,38	26,53	23,65	225,62	245,62	200,56	1369
01/06/2009	28,43	28,92	28,57	26,93	25,41	23,41	95,67	66,02	206,69	1127
01/07/2009	28,28	29,43	28,79	26,30	23,71	22,46	13,52	15,19	89,52	908
01/08/2009	28,13	29,59	28,68	25,22	22,37	22,63	99,40	87,40	26,02	668
01/09/2009	28,12	28,92	28,51	25,55	21,97	21,52	92,77	87,14	14,52	476
01/10/2009	29,10	30,41	29,69	24,67	22,48	21,15	124,46	127,34	63,69	529
01/11/2009	29,30	30,68	29,81	25,83	23,13	22,34	182,53	187,74	50,59	701
01/12/2009	29,67	30,28	30,06	26,36	24,57	23,87	438,31	407,82	172,14	1056
01/01/2010	29,36	29,75	30,09	26,32	25,15	23,82	299,23	292,49	213,14	1279
01/02/2010	28,78	29,51	29,44	26,53	26,11	24,97	212,03	226,75	241,16	1417
01/03/2010	28,80	29,45	29,35	27,59	26,97	25,30	350,18	341,29	223,53	1498
01/04/2010	28,76	29,45	29,28	27,39	27,59	25,93	92,59	72,03	390,86	1404
01/05/2010	27,96	28,91	28,27	25,81	25,05	24,48	68,48	69,92	197,36	1181
01/06/2010	27,13	28,09	27,67	24,87	23,16	22,61	24,09	22,23	129,61	788,5
01/07/2010	26,26	27,69	27,42	24,03	21,19	20,21	6,98	5,76	132,92	516
01/08/2010	25,20	27,13	26,61	23,05	19,60	19,90	63,25	47,54	34,48	361
01/09/2010	25,07	26,68	26,01	23,23	19,63	18,79	52,48	49,62	38,67	294
01/10/2010	26,00	27,02	26,32	22,44	20,09	19,53	206,14	184,74	82,77	293
01/11/2010	25,55	26,53	26,46	23,12	20,34	20,81	211,18	218,32	153,51	453
01/12/2010	26,05	27,02	26,47	22,91	21,19	22,08	270,48	265,11	214,47	670
01/01/2011	25,40	26,92	26,05	23,11	23,25	24,16	350,56	352,95	378,87	1013
01/02/2011	25,50	26,68	26,14	24,02	26,58	25,48	297,45	252,94	284,72	1319
01/03/2011	26,70	27,30	27,34	25,37	26,61	24,30	349,84	360,93	266,07	1519
01/04/2011	26,88	27,26	27,15	26,70	26,78	24,51	199,70	191,76	276,52	1600
01/05/2011	27,62	28,21	28,05	26,29	25,28	23,43	87,10	79,22	224,85	1306
01/06/2011	27,60	28,02	27,81	25,91	24,79	22,93	11,23	8,13	106,65	892
01/07/2011	27,69	28,02	28,09	25,07	22,58	22,82	12,96	10,31	77,33	599
01/08/2011	27,55	28,30	28,20	23,76	21,20	20,88	89,90	82,99	91,63	459
01/09/2011	26,83	28,07	27,50	23,39	20,22	20,97	100,92	93,08	59,92	322
01/10/2011	26,65	27,94	27,03	23,39	20,03	20,68	163,30	171,68	115,18	428
01/11/2011	26,36	27,42	27,05	23,34	20,74	20,90	182,18	170,95	141,29	443
01/12/2011	26,02	27,10	26,40	23,41	21,49	21,51	338,53	340,82	158,13	729
01/01/2012	25,79	26,68	26,31	24,12	24,03	23,73	335,61	299,36	279,67	1068
01/02/2012	26,15	27,51	26,64	25,81	26,47	26,11	315,50	284,21	302,53	1347
01/03/2012	26,41	27,33	26,81	26,48	27,85	26,39	219,98	226,95	356,52	1526
01/04/2012	27,03	27,90	27,46	26,46	27,70	25,73	141,19	153,28	239,84	1447
01/05/2012	27,30	28,43	27,95	26,94	25,95	23,71	90,47	90,25	171,78	1341
01/06/2012	28,05	28,33	28,24	26,79	25,28	23,86	39,47	36,11	75,51	1134
01/07/2012	27,72	28,73	28,35	26,07	23,25	20,90	6,42	5,21	162,24	895
01/08/2012	28,28	28,89	28,50	25,64	21,89	20,01	40,79	37,65	52,85	521
01/09/2012	27,75	28,50	28,12	25,07	21,66	21,41	58,18	58,80	64,81	335,5
01/10/2012	27,98	28,85	28,55	23,78	20,96	20,65	161,99	158,79	96,12	405
01/11/2012	28,12	28,67	28,25	25,12	21,64	21,32	162,30	171,83	188,66	506
01/12/2012	27,09	28,42	27,74	23,64	22,02	22,34	248,39	239,98	179,54	893
01/01/2013	26,29	27,89	27,34	23,52	23,44	25,26	387,36	410,09	369,85	1251
01/02/2013	26,09	28,23	27,16	24,40	25,12	25,56	281,78	282,14	324,58	1323
01/03/2013	26,48	27,61	26,91	26,75	27,22	25,19	294,70	322,13	253,38	1540
01/04/2013	27,71	27,74	27,73	27,65	26,58	23,75	107,20	123,89	363,51	1573


01/05/2013	27,71	28,42	28,35	26,04	24,26	21,91	80,52	93,44	172,50	1191,5
01/06/2013	27,43	28,63	27,99	25,40	22,27	21,64	46,20	46,65	79,04	946
01/07/2013	27,50	28,52	28,08	24,56	21,43	20,01	52,92	47,58	209,44	797
01/08/2013	27,20	28,35	27,99	24,15	20,19	19,31	203,78	124,16	57,27	485
01/09/2013	27,52	28,74	27,87	24,95	20,27	20,13	85,40	72,90	89,26	428
01/10/2013	26,92	28,85	27,83	24,27	21,22	20,34	287,96	203,43	141,70	594
01/11/2013	27,56	28,70	27,87	24,50	20,79	23,03	240,62	229,38	183,17	867,5
01/12/2013	26,46	27,42	27,07	24,89	22,74	22,47	171,28	176,39	84,20	1160
01/01/2014	25,79	27,66	26,50	24,49	24,41	25,02	268,45	236,97	217,13	1459
01/02/2014	25,98	27,79	26,49	24,19	25,08	23,81	115,97	128,89	277,67	1730
01/03/2014	26,92	28,76	27,22	26,00	27,03	23,71	174,14	178,47	520,31	1918
01/04/2014	28,05	29,40	28,40	27,38	27,17	24,53	210,20	204,51	255,08	1868
01/05/2014	28,69	29,82	29,21	27,31	26,57	24,92	114,75	117,51	343,24	1675
01/06/2014	28,23	28,97	28,35	27,08	25,55	24,57	20,29	24,40	196,87	1427,5
01/07/2014	27,23	28,72	27,96	24,83	23,72	23,36	12,32	9,93	101,72	1121
01/08/2014	27,55	29,21	28,22	24,09	22,12	22,02	100,87	92,90	49,86	739
01/09/2014	28,00	29,16	28,45	24,90	21,91	22,16	33,28	34,18	34,69	476
01/10/2014	27,89	29,13	28,31	25,59	22,36	23,44	196,08	198,24	88,68	478,5
01/11/2014	28,46	29,34	28,67	25,49	22,72	22,61	216,39	216,36	133,95	576
01/12/2014	27,93	29,42	28,52	25,63	23,55	22,20	184,90	196,46	102,94	977
01/01/2015	27,95	29,42	28,57	25,43	24,52	24,15	248,91	198,14	265,49	1365
01/02/2015	27,67	29,18	28,54	26,30	25,16	24,42	120,19	118,08	239,61	1575
01/03/2015	28,32	29,84	29,05	26,67	27,16	24,99	213,01	233,11	429,06	1679
01/04/2015	29,23	30,23	29,87	28,11	27,74	26,53	162,63	180,35	239,24	1557
01/05/2015	29,35	30,33	30,06	27,64	26,92	25,63	202,12	199,64	216,57	1572
01/06/2015	29,89	30,29	30,30	27,61	26,10	24,34	12,65	18,82	99,24	1417
01/07/2015	29,79	30,41	30,15	27,20	25,40	24,00	9,20	7,55	41,51	1139
01/08/2015	29,77	30,04	30,22	27,22	23,37	22,81	48,55	38,72	30,04	809
01/09/2015	29,49	30,11	30,04	27,05	24,10	22,95	77,92	75,35	9,47	490
01/10/2015	30,10	29,98	30,13	27,61	24,22	24,21	64,30	60,56	21,49	413
01/11/2015	30,80	30,86	31,09	28,33	24,85	25,42	93,16	88,42	83,11	580
01/12/2015	30,31	30,55	30,34	27,99	25,92	25,43	252,61	273,96	108,60	706
01/01/2016	29,71	29,52	29,68	27,81	26,88	25,08	230,78	228,83	119,26	1012
01/02/2016	29,60	29,44	30,20	28,13	27,51	26,57	163,60	156,24	344,07	1239
01/03/2016	29,35	29,89	29,79	28,73	29,16	26,48	320,46	305,29	384,75	1465
01/04/2016	28,46	29,36	29,04	27,81	27,21	23,58	116,77	114,64	334,71	1349
01/05/2016	28,10	29,59	28,93	25,66	25,41	22,49	69,43	71,71	179,79	1143
01/06/2016	27,49	29,05	28,68	25,81	24,03	22,12	34,19	26,00	114,99	769
01/07/2016	26,50	28,78	27,47	23,88	22,23	21,84	9,02	5,95	158,98	465
01/08/2016	26,19	28,47	27,50	23,58	20,67	20,80	139,82	131,54	50,31	273
01/09/2016	26,09	28,13	26,97	24,19	21,49	21,06	79,29	86,47	78,52	235
01/10/2016	25,95	27,99	26,49	23,36	21,73	20,98	165,17	170,72	95,86	272
01/11/2016	25,98	27,57	26,78	23,26	21,71	21,34	98,98	104,48	146,28	416
01/12/2016	26,44	28,32	27,41	23,84	22,87	23,27	178,64	171,15	327,36	629
01/01/2017	26,26	27,55	27,00	24,66	24,58	25,57	344,66	308,77	441,34	1078

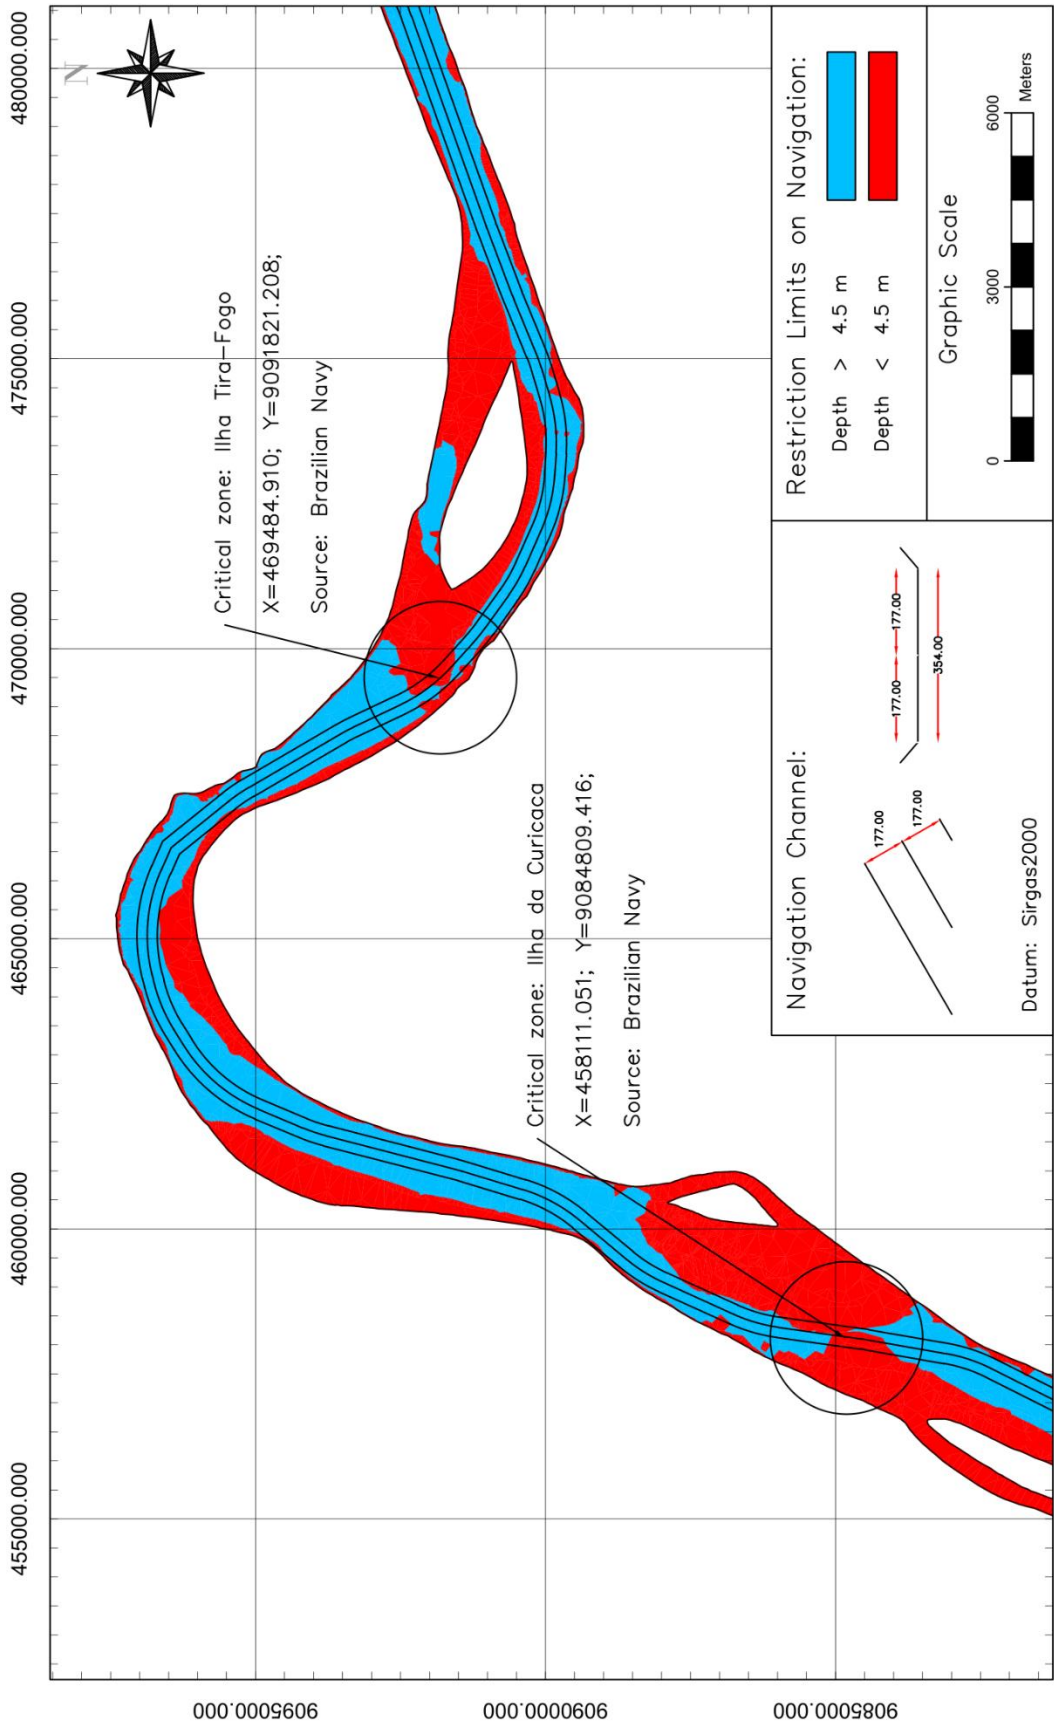
01/02/2017	26,22	27,07	26,78	26,00	27,28	26,71	217,14	235,38	285,26	1208
01/03/2017	26,62	27,16	27,04	26,91	28,91	29,05	332,65	353,96	418,95	1467
01/04/2017	27,59	28,12	28,02	28,74	27,55	24,75	162,06	183,72	329,07	1457
01/05/2017	28,09	28,70	28,63	27,24	25,29	24,03	122,05	144,60	118,88	1311
01/06/2017	28,19	28,93	28,62	25,84	23,67	24,13	10,73	10,24	125,49	1089
01/07/2017	27,30	27,98	27,73	25,13	22,16	20,61	5,46	0,00	75,64	686
01/08/2017	26,38	27,73	27,09	23,59	20,71	20,19	100,30	68,95	34,64	382
01/09/2017	26,60	27,86	27,31	22,49	19,26	21,56	68,45	73,43	88,56	325
01/10/2017	27,19	28,18	27,41	23,22	19,97	21,05	149,63	142,50	98,52	267
01/11/2017	25,57	27,64	26,40	22,40	19,96	20,61	178,15	162,03	137,41	563
01/12/2017	25,99	27,48	26,75	23,30	20,88	21,45	288,72	269,41	323,50	917
01/01/2018	25,43	26,69	26,31	23,44	22,09	22,98	302,03	271,34	259,18	1383
01/02/2018	25,90	26,86	26,36	24,89	25,15	26,18	381,63	385,15	314,70	1541
01/03/2018	26,13	27,26	27,01	24,63	26,30	25,02	266,47	243,49	256,18	1617

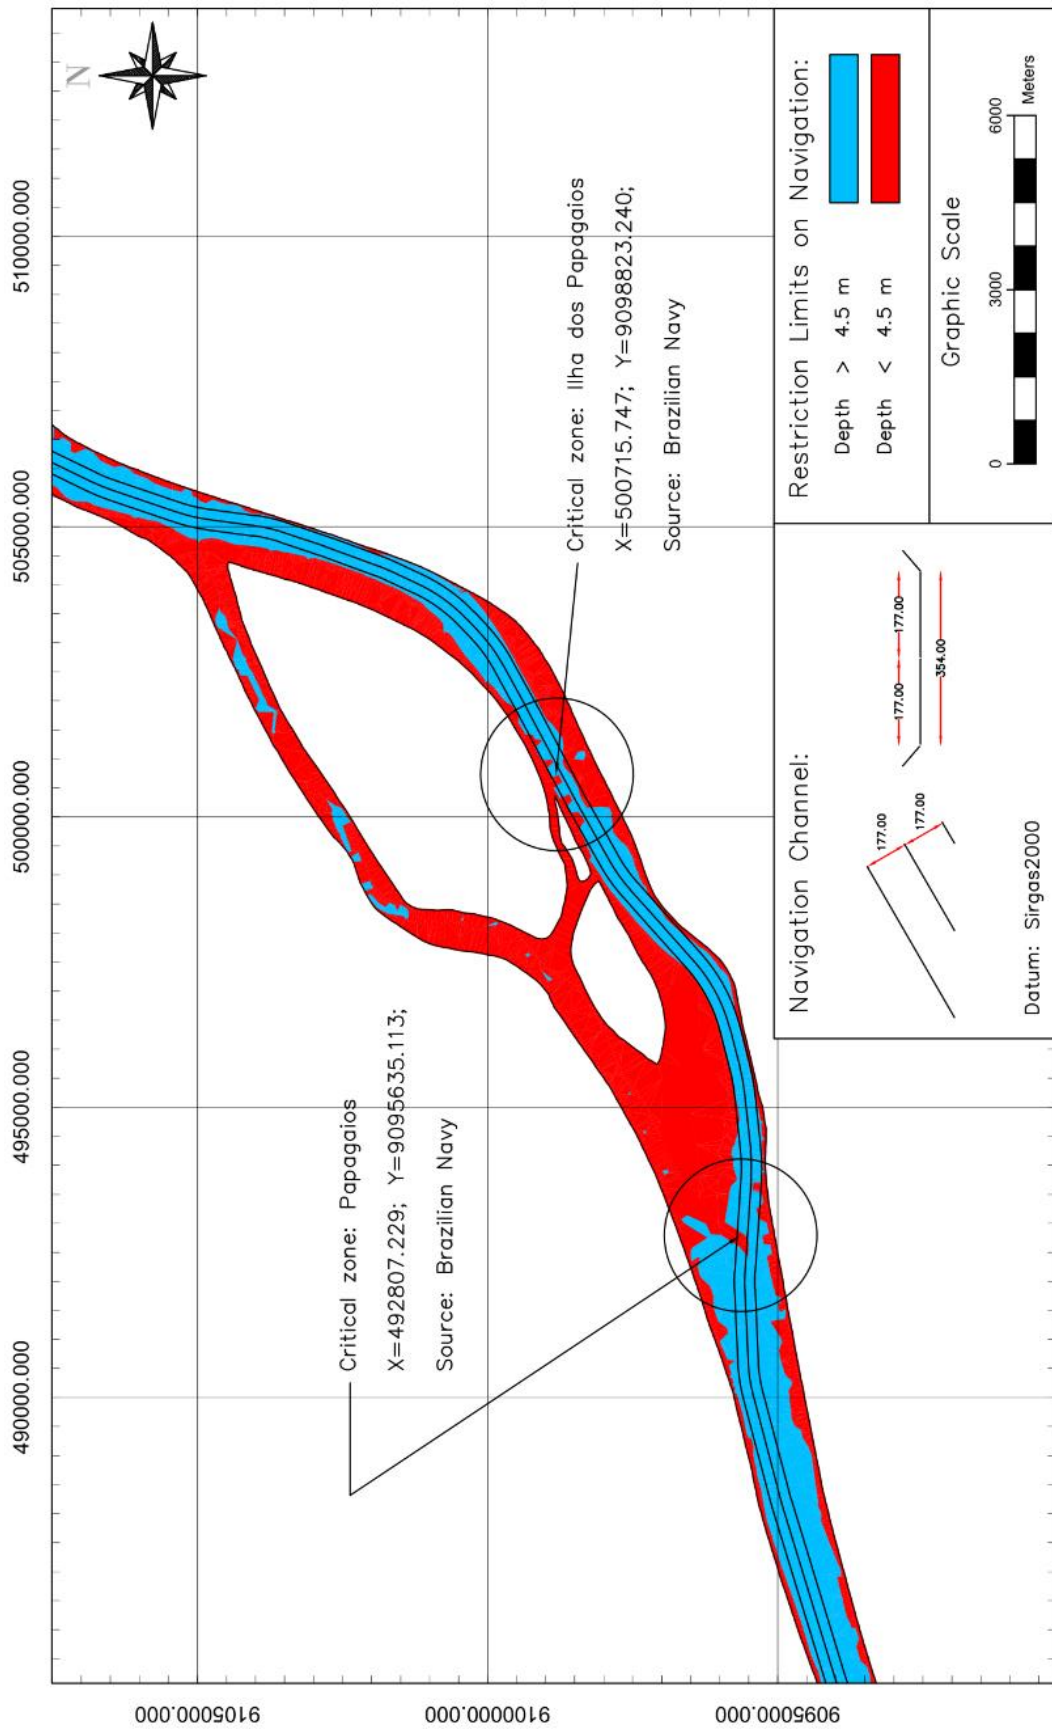
ANEXO 02: MDE Completo e Trechos Críticos – Período de Estiagem











ANEXO 03: MDE Completo e Trechos Críticos – Período de Cheia

