



MARINHA DO BRASIL
INSTITUTO DE ESTUDOS DO MAR ALMIRANTE PAULO MOREIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM ACÚSTICA SUBMARINA

LOCALIZAÇÃO DE FONTES SUBMARINAS POR PROCESSAMENTO DE
CAMPO CASADO, FOCALIZAÇÃO E APRENDIZAGEM DE MÁQUINA

Pedro Mendes Diniz

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Acústica Submarina, PPGAS, do Instituto de Estudos do Mar Almirante Paulo Moreira, como parte dos requisitos necessários à obtenção do título de Mestre em Acústica Submarina.

Orientador: Rogério de Moraes Calazan

Arraial do Cabo
Março de 2023

LOCALIZAÇÃO DE FONTES SUBMARINAS POR PROCESSAMENTO DE
CAMPO CASADO, FOCALIZAÇÃO E APRENDIZAGEM DE MÁQUINA

Pedro Mendes Diniz

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO PROGRAMA
DE PÓS-GRADUAÇÃO EM ACÚSTICA SUBMARINA DO INSTITUTO DE
ESTUDOS DO MAR ALMIRANTE PAULO MOREIRA COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE
EM CIÊNCIAS EM ACÚSTICA SUBMARINA.

Orientador: Prof. Rogério de Moraes Calazan, Ph.D.

Aprovada por: Prof. Orlando Camargo Rodríguez, Ph.D.

Prof. Natanael Nunes de Moura Junior, D.Sc.

Prof. Renato Peres Vio, Ph.D.

ARRAIAL DO CABO, RJ – BRASIL

MARÇO DE 2023

Diniz, Pedro Mendes

Localização de Fontes Submarinas por Processamento de Campo Casado, Focalização e Aprendizagem de Máquina/Pedro Mendes Diniz. – Arraial do Cabo: IEAPM, 2023.

XXI, 96 p.: il.; 29, 7cm.

Orientador: Rogério de Moraes Calazan

Dissertação (mestrado) – IEAPM/Programa de Pós-Graduação em Acústica Submarina, 2023.

Referências Bibliográficas: p. 70 – 79.

1. problema inverso. 2. localização de fontes. 3. processamento de campo casado. 4. aprendizagem de máquina. I. Calazan, Rogério de Moraes. II. Instituto de Estudos do Mar Almirante Paulo Moreira, Programa de Pós-Graduação em Acústica Submarina. III. Título.

Para Laura.

Agradecimentos

Primeiramente, devo agradecer ao Comandante Moraes por ter ido muito além do chamado do dever em minha orientação. Se este trabalho foi bem sucedido, foi graças à sua incansável atenção, disponibilidade e prestatividade. Obrigado por todo o apoio e pela amizade.

Agradeço a Laura por me ajudar a manter o foco no trabalho - sem perder o foco das outras coisas que importam. A certeza de poder contar com você para o que der e vier me deu a tranquilidade para perseverar. Obrigado pelo carinho e pela compreensão muito além do que eu mereço.

Aos grandes amigos Rodrigo, Lima e Vinícius por toda a companhia nesses dois anos. Tenho certeza que a amizade forjada sob o fogo do trauma mútuo será para sempre. Obrigado, meus amigos, e tenham plena garantia de que ajudaram a tornar essa jornada inteira muito mais aprazível. Essa é a história.

Ao CF Renato Vio, CMG Barroso, CMG Simões e os demais professores do PPGAS e pessoal do departamento de Acústica Submarina do IEAPM que tanto contribuíram, direta ou indiretamente, em sala de aula e fora dela, para a realização deste projeto e pelo incansável esforço em fazer este curso acontecer.

Ao Prof. Sérgio Jesus, do SiPLAB, por ter gentilmente cedido os dados experimentais usados neste trabalho.

Ao grande amigo Costa Medeiros, cujos conselhos acertados mais de uma vez já me colocaram num caminho melhor. Sou muito grato que nossos caminhos se cruzaram na Marinha e espero que um dia tornem a se cruzar.

Ao CMG Dante, pelo apoio e por ter acreditado durante todo o processo seletivo para o mestrado. Foi fundamental para que eu pudesse ter chegado aqui. Estendo os agradecimentos a todos os amigos e companheiros de praça d'armas e dos conveses do Navio Hidrográfico "Sirius", numerosos demais para nomear, mas todos valiosos, cada um, por sua contribuição à minha formação pessoal e profissional ao longo de cinco anos de embarque. Se tive convicção para perseguir este objetivo acadêmico, foi porque julguei a vida operativa bem vivida. Ao Cachorrão, tudão!

Ao grande amigo Marlio, uma das melhores pessoas que conheço, que, embora longe, sempre conseguiu aliviar os momentos de tensão com nossas conversas e prestou grande ajuda com os *insights* de quem já trilhou este caminho antes.

E, por fim, à minha mãe, Andréa, meu irmão, Ugo, e meus tios, Inesita e Eduardo, pelo perene suporte e carinho.

We wish to pursue the truth no matter where it leads. But to find the truth, we need imagination and skepticism both.

Carl Sagan, *Cosmos*

Resumo da Dissertação apresentada ao IEAPM como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

LOCALIZAÇÃO DE FONTES SUBMARINAS POR PROCESSAMENTO DE CAMPO CASADO, FOCALIZAÇÃO E APRENDIZAGEM DE MÁQUINA

Pedro Mendes Diniz

Março/2023

Orientador: Rogério de Moraes Calazan

Programa: Acústica Submarina

A localização de fontes é um clássico problema inverso de grande interesse para a acústica submarina. O processamento de campo casado (MFP) combina o processamento de um sinal recebido com réplicas do campo acústico calculadas por um modelo de propagação para inverter a distância e a profundidade da fonte, explorando a complexidade do campo acústico completo em um guia de ondas. Embora uma técnica versátil com diversas aplicações na inversão acústica, o MFP é limitado pelo modelo ambiental usado para descrever o guia de ondas. Se o modelo não é uma representação precisa, ocorre um problema denominado desajuste de modelo que possui implicações quanto à robustez da técnica. Esta dissertação explora o uso de dois métodos desenvolvidos como alternativas mais robustas ao MFP clássico. O primeiro, focalização, é uma extensão adaptativa do MFP que trata a inversão como um problema de otimização global ao incluir outros parâmetros do modelo no espaço de busca. Uma heurística de busca, neste trabalho baseada em algoritmos genéticos, é usada para encontrar o máximo global de uma função objetivo. A heurística é usada para localizar em profundidade e distância a fonte de um conjunto de dados experimentais em um ambiente incerto com baixo conhecimento *a priori* de seus parâmetros. Os resultados apresentam significativa melhora quando comparados ao MFP clássico, levando a taxa de acerto de 31% a 73%. Outra abordagem é desenvolvida à luz da aprendizagem de máquina, mantendo um enfoque no uso de campos modelados para o treinamento de redes neurais. É demonstrado que uma rede neural é capaz de aproximar o processador usado no MFP e que, quando as incertezas do ambiente são consideradas no treinamento da rede neural, ela se torna mais robusta e produz resultados mais consistentes que o MFP na estimação da distância da fonte, obtendo erro de somente 2,69% para o conjunto de dados usado.

Abstract of Dissertation presented to IEAPM as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

UNDERWATER SOURCE LOCALIZATION BY MATCHED FIELD PROCESSING, FOCALIZATION AND MACHINE LEARNING

Pedro Mendes Diniz

March/2023

Advisor: Rogério de Moraes Calazan

Department: Underwater Acoustics

Source localization is a classic inverse problem of great interest in underwater acoustics. Matched field processing (MFP) combines the processing of a received signal with replicas of the acoustic field calculated by a propagation model to invert for source range and depth, thereby exploiting the complexity of the full acoustic field in a waveguide. Although a versatile technique with multiple applications in acoustic inversion, MFP is limited by the environmental model used to describe the waveguide. If the model is not an accurate depiction of the waveguide, a problem called model mismatch arises, with implications to the technique's robustness. This dissertation explores the use of two methods developed as more robust alternatives to classic MFP. The first one, focalization, is an adaptive extension of MFP that treats inversion as a global optimization problem by including other model parameters in the search space. A search heuristic, in this work based on genetic algorithms, is used to find the global maximum of an objective function. The heuristic is used to locate in depth and range the source of an experimental dataset in an uncertain environment with low *a priori* knowledge of its parameters. Results show significant improvement over classic MFP, taking the accuracy from 31% to 73%. Another approach is developed based on machine learning with a focus on the use of modeled fields for neural network training. It is demonstrated that a neural network is capable of approximating the processor used in MFP and that, when environment uncertainty is considered in the training of the neural network, it becomes more robust and produces more consistent source range estimations than MFP, obtaining only 2.96% error for the dataset used.

Sumário

Lista de Figuras	xii
Lista de Tabelas	xvi
Lista de Símbolos	xvii
Lista de Abreviaturas	xx
1 Introdução	1
1.1 Apresentação do problema	1
1.2 Motivação para o trabalho	5
1.3 Objetivos	6
1.4 Publicações	7
2 Referencial Teórico	8
2.1 O problema inverso	8
2.2 Teoria de raios	10
2.3 Processamento de campo casado	12
2.4 Focalização	16
2.4.1 Algoritmos genéticos	18
2.5 Aprendizagem de máquina	21
2.5.1 Redes neurais de alimentação direta	23
3 Metodologia	27
3.1 O experimento CALCOM'10	27
3.2 Processamento dos dados	29
3.3 Modelagem	30
3.4 Focalização	32
3.4.1 Heurística	32
3.4.2 Métricas	36
3.4.3 Parâmetros	36
3.5 Aprendizagem de máquina	37

3.5.1	Hipótese	37
3.5.2	Arquitetura da rede neural	39
3.5.3	Avaliação dos modelos de aprendizagem de máquina	40
3.5.4	Criação dos conjuntos de dados e réplicas	40
3.5.5	Descrição do método	42
4	Resultados e Discussão	46
4.1	Focalização	46
4.1.1	Busca global	46
4.1.2	Busca local	50
4.1.3	MFP	53
4.2	Aprendizagem de máquina	58
4.2.1	Testes de desajuste	59
4.2.2	Análise da variabilidade	61
4.2.3	Comparação com o MFP	65
5	Conclusões e Sugestões para Trabalhos Futuros	68
	Referências Bibliográficas	70
A	Distribuições de probabilidade <i>a posteriori</i> da busca global	80
B	Superfícies de ambiguidade	89

Lista de Figuras

1.1	Esquema de funcionamento do conformador de feixes para um arranjo linear uniforme.	2
1.2	Traçado de autorraios em um ambiente simulado com uma fonte e três sensores. As setas indicam as três direções proeminentes de chegada das frentes de onda e ilustram a dificuldade de resolução da direção de chegada por um VLA em um ambiente de águas rasas devido à propagação por multicaminhos.	3
2.1	Diagrama ilustrativo de como as abordagens direta e inversa relacionam entrada, saída e modelo de um sistema. O sinal de entrada, ilustrado por um espectrograma, é transformado pela propagação no meio submarino e produz uma saída ao ser adquirido por um sensor. O problema direto tenta prever essa saída a partir de um modelo conhecido do sistema, enquanto que o problema inverso tenta estimar o modelo a partir de uma saída conhecida.	9
2.2	Fluxograma de funcionamento do MFP. Na superfície de ambiguidade, o máximo global, sinalizado por um círculo preto, representa a estimativa da posição da fonte.	14
2.3	Comparação entre superfícies de ambiguidades produzidas pelo processador a) Bartlett e b) MVDR.	15
2.4	Representação binária de um parâmetro θ_i usando uma distribuição uniforme e 3 bits de informação.	19
2.5	Funcionamento dos operadores (a) <i>crossover</i> e (b) <i>mutação</i>	20
2.6	Esquema do algoritmo genético aplicado ao processamento de campo casado.	20
2.7	Representação gráfica do modelo matemático de um neurônio artificial.	24
3.1	Carta batimétrica da região do experimento CALCOM'10 com posições do VLA e fonte, com as transmissões de cada evento numeradas.	28

3.2	Modelo ambiental base com os transectos de batimetria considerando os azimutes médios entre VLA e fonte para os eventos P2 (linha sólida) e P6 (linha pontilhada). Posição da fonte representada na máxima distância de busca.	31
3.3	(a) Traçado de raios e (b) campo de pressões e perda na transmissão para o modelo base usando o azimute médio do evento P2. No traçado de raios, a abertura do feixe foi limitada a 20° e foram traçados somente 11 raios para permitir a visualização.	31
3.4	Fluxograma da heurística de inversão por focalização.	32
3.5	Análise de EOF dos SSP. (a) Medições de temperatura convertidas para velocidade do som. (b) Resíduos das medições. (c) Três primeiras EOF.	35
3.6	Esquema do aumento de variabilidade entre os conjuntos de dados.	42
3.7	Carta batimétrica mostrando as regiões para posicionamento da fonte e VLA nos dados sintéticos.	42
4.1	Matriz de correlação entre os parâmetros da busca global. A cor de cada campo reflete a magnitude do coeficiente de correlação.	49
4.2	(a) SSP invertidos durante a busca local. (b) Resíduos dos SSP.	52
4.3	Resultados do MFP com o modelo base.	54
4.4	Resultados do MFP com o modelo ajustado pela média da PPD da distância.	55
4.5	Resultados do MFP com o modelo ajustado pela mediana da PPD da distância.	56
4.6	Seção das superfícies de ambiguidade das 225 amostras na profundidade correta da fonte. Bartlett de cada amostra normalizado individualmente. Círculos marcam a distância correta da fonte.	57
4.7	Resultados dos testes de desajuste para o ambiente RD.	59
4.8	Resultados dos testes de desajuste para o ambiente RI.	60
4.9	Função de ambiguidade para a amostra do teste RI na distância de 2,8 km. Sem desajuste, há um único pico bem definido (lóbulo principal) e o processador alcança o valor normalizado de 1. Na presença de desajuste suave, como no teste de sedimento, a função ainda apresenta um pico bem definido, embora deslocado da posição verdadeira e com menor energia. No caso do desajuste da inclinação de batimetria, mais influente, a função degradou a tal ponto que a posição correta é perdida em meio aos lóbulos secundários.	61

4.10	Análise de componentes principais dos seis conjuntos de dados sintéticos, com o número de componentes necessários para explicar 90% da variância.	62
4.11	Curvas de aprendizagem das FNN treinadas nos seis conjuntos de dados sintéticos.	62
4.12	Melhores resultados no conjunto de dados do CALCOM para as FNN treinadas em cada um dos seis conjuntos de dados sintéticos.	64
4.13	Resultados da localização do conjunto de dados do CALCOM pelo MFP usando o modelo base, MFP usando o modelo ajustado e pela FNN treinada no conjunto de dados 5.	66
A.1	PPD de posição da fonte para a transmissão P2-1.	80
A.2	PPD de posição da fonte para a transmissão P2-2.	81
A.3	PPD de posição da fonte para a transmissão P2-3.	81
A.4	PPD de posição da fonte para a transmissão P2-4.	82
A.5	PPD de posição da fonte para a transmissão P2-5.	82
A.6	PPD de posição da fonte para a transmissão P2-6.	83
A.7	PPD de posição da fonte para a transmissão P2-7.	83
A.8	PPD de posição da fonte para a transmissão P6-1.	84
A.9	PPD de posição da fonte para a transmissão P6-2.	84
A.10	PPD de posição da fonte para a transmissão P6-3.	85
A.11	PPD de posição da fonte para a transmissão P6-4.	85
A.12	PPD de posição da fonte para a transmissão P6-5.	86
A.13	PPD de posição da fonte para a transmissão P6-6.	86
A.14	PPD de posição da fonte para a transmissão P6-7.	87
A.15	PPD de posição da fonte para a transmissão P6-8.	87
A.16	PPD dos parâmetros do fundo.	88
B.1	Superfícies de ambiguidade para a transmissão P2-1.	89
B.2	Superfícies de ambiguidade para a transmissão P2-2.	90
B.3	Superfícies de ambiguidade para a transmissão P2-3.	90
B.4	Superfícies de ambiguidade para a transmissão P2-4.	91
B.5	Superfícies de ambiguidade para a transmissão P2-5.	91
B.6	Superfícies de ambiguidade para a transmissão P2-6.	92
B.7	Superfícies de ambiguidade para a transmissão P2-7.	92
B.8	Superfícies de ambiguidade para a transmissão P6-1.	93
B.9	Superfícies de ambiguidade para a transmissão P6-2.	93
B.10	Superfícies de ambiguidade para a transmissão P6-3.	94
B.11	Superfícies de ambiguidade para a transmissão P6-4.	94
B.12	Superfícies de ambiguidade para a transmissão P6-5.	95

B.13 Superfícies de ambiguidade para a transmissão P6-6.	95
B.14 Superfícies de ambiguidade para a transmissão P6-7.	96
B.15 Superfícies de ambiguidade para a transmissão P6-8.	96

Lista de Tabelas

3.1	Parâmetros e hiperparâmetros dos algoritmos de otimização.	38
4.1	Estatísticas extraídas das PPD de posição da fonte após a busca global com os erros associados em relação à posição de referência (r' e z').	48
4.2	Resultados da busca local usando a média da PPD de distância. A média do Bartlett considera 0 o valor das transmissões que não obtiveram acerto.	50
4.3	Resultados da busca local usando a mediana da PPD de distância. A média do Bartlett considera 0 o valor das transmissões que não obtiveram acerto.	51
4.4	Resultados do MFP usando o modelo ambiental base. O Bartlett médio (\bar{B}) considera 0 o valor das amostras que não obtiveram acerto. 53	53
4.5	Resultados do MFP usando o modelo ajustado pela média da PPD de distância. O Bartlett médio considera 0 o valor das amostras que não obtiveram acerto.	54
4.6	Resultados do MFP usando o modelo ajustado pela mediana da PPD de distância. O Bartlett médio considera 0 o valor das amostras que não obtiveram acerto.	56
4.7	Resultados do MFP usando cada transmissão como uma única amostra e comparando com os resultados obtidos por Diniz <i>et al.</i>	58
4.8	Resultados (MAPE) da validação cruzada das FNN treinadas nos seis conjuntos de dados sintéticos.	64
4.9	Parâmetros e limites de busca incluídos na focalização para comparação com ML.	66

Lista de Símbolos

A	amplitude, p. 11
B	energia do processador, p. 13
G	função de custo, p. 25
L, l	número de <i>snapshots</i> , <i>snapshot</i> individual, p. 13
M, m	número de sensores, sensor individual, p. 2
N	número de amostras, p. 36
P	pressão acústica, p. 10
T	temperatura (parâmetro da distribuição de Boltzmann), p. 33
Σ	somatório, p. 13
Δ	variação, p. 25
α_p	atenuação da onda compressional no fundo, p. 30
\mathbf{R}	matriz de covariância, p. 13
\mathbf{W}	matriz de pesos da FNN, p. 25
\mathbf{X}	conjunto de dados expresso em forma matricial, p. 44
$\boldsymbol{\theta}$	vetor de parâmetros do modelo, p. 13
\mathbf{v}	EOF, p. 34
\mathbf{d}	vetor de dados, p. 12
\mathbf{e}	vetor réplica, p. 13
\mathbf{r}	vetor posição, p. 11
\mathbf{s}	componente principal do conjunto de dados, p. 44

\mathbf{v}	autovetor, p. 44
\mathbf{x}	vetor de amostra do conjunto de dados, p. 44
δ	delta de Kronecker, p. 33
η	taxa de aprendizagem, p. 25
max	máximo, p. 38
μ	média, p. 37
∇	gradiente, p. 11
∇^2	Laplaciano, p. 10
ν	mediana, p. 37
ω	frequência angular, p. 11
ρ	densidade, p. 30
σ	desvio padrão, p. 37
τ	tempo de percurso, p. 11
θ	direção de chegada, parâmetro do modelo, p. 2
θ'	valor do parâmetro no espaço de busca, p. 33
ε	erro, p. 36
φ	função de ativação, p. 24
a	coeficiente da EOF, p. 34
c_p	velocidade da onda compressional no fundo, p. 30
d	espaçamento entre sensores, p. 2
f	frequência, p. 13
i	índice, p. 33
j	unidade imaginária, p. 11
k	número de partes na validação cruzada, p. 40
n_{bit}	número de bits, p. 18

n_{ger}	número de gerações, p. 19
n_{pop}	número de vetores na população, p. 18
n_{run}	número de execuções independentes do algoritmo genético, p. 20
n_{vec}	número de vetores selecionados na otimização global, p. 33
p	probabilidade, p. 33
q	coeficiente de correlação, p. 43
r	distância, p. 11
r'	distância verdadeira, p. 36
t	tempo, p. 2
v	saída intermediária de um neurônio, p. 25
w	peso (conformador de feixes, rede neural), p. 2
x	entrada, p. 2
y	saída, p. 2
z	profundidade, p. 11
z'	profundidade verdadeira, p. 36
T	transposto, p. 44
H	operador hermitiano, p. 13

Lista de Abreviaturas

AOB	boia acústico-oceanográfica (<i>acoustic oceanographic buoy</i>), p. 28
EOF	função ortogonal empírica (<i>empirical orthogonal function</i>), p. 34
FNN	rede neural de alimentação direta (<i>feedforward neural network</i>), p. 21
GA	algoritmos genéticos (<i>genetic algorithms</i>), p. 5
MAE	erro médio absoluto (<i>mean absolute error</i>), p. 36
MAPE	erro médio absoluto percentual (<i>mean absolute percentage error</i>), p. 36
MFP	processamento de campo casado (<i>matched field processing</i>), p. 4
ML	aprendizagem de máquina (<i>machine learning</i>), p. 6
MVDR	mínima variância com resposta sem distorção (<i>minimum variance distortionless response</i>), p. 14
PCA	análise de componentes principais (<i>principal component analysis</i>), p. 44
PPD	distribuição de probabilidade <i>a posteriori</i> (<i>posterior probability distribution</i>), p. 17
ReLU	unidade linear retificada (<i>rectified linear unit</i>), p. 25
SA	recozimento simulado (<i>simulated annealing</i>), p. 5
SCM	matriz de covariância da amostra (<i>sample covariance matrix</i>), p. 13
SHC	<i>stochastic hill climbing</i> , p. 32

SNR	relação sinal-ruído (<i>signal-to-noise ratio</i>), p. 1
SSP	perfil de velocidade do som (<i>sound speed profile</i>), p. 3
SiPLAB	<i>Signal Processing Laboratory</i> , p. 27
VLA	arranjo linear vertical (<i>vertical line array</i>), p. 3

Capítulo 1

Introdução

A localização de fontes é um problema de grande interesse para a acústica submarina, mas que permanece cercado de dificuldades que derivam da complexidade do meio de propagação: o ambiente marinho. A Seção 1.1 deste capítulo apresenta as principais dificuldades envolvidas na localização de uma fonte por um arranjo vertical de sensores no mar. A Seção 1.2 apresenta algumas alternativas para contornar os problemas associados à localização de fontes, cujo estudo aprofundado motivou este trabalho. A Seção 1.3 cita os objetivos do trabalho e a Seção 1.4 lista as publicações que decorreram desta dissertação.

1.1 Apresentação do problema

O princípio do desenvolvimento da tecnologia de localização de alvos submarinos se deu no contexto da Primeira e Segunda Guerras Mundiais, o que levou ao desenvolvimento de tecnologias como o sonar e intensificação de estudos oceanográficos sobre a propagação do som no meio oceânico e fontes de ruído no ambiente marinho [1]. Na aplicação militar, o sonar passivo, o qual apenas recebe sinais, tem grandes vantagens táticas na guerra anti-submarino por ser silencioso, embora sofra com limitações inerentes ao seu modo de funcionamento, principalmente no que diz respeito à relação sinal-ruído (SNR, *signal-to-noise ratio*). Um sonar passivo pode ser empregado para detecção, classificação e localização de uma fonte acústica submarina. Dessas tarefas, a localização é particularmente dependente da coerência temporal e espacial do campo acústico, a qual está diretamente associada à coerência de um ambiente oceânico dinâmico [2].

O uso de um arranjo de sensores praticamente se faz necessário para, por meio do processamento em conjunto dos sinais recebidos em cada sensor, produzir-se um ganho do sinal de interesse (com melhora do SNR, supondo que o ruído seja decorrelacionado e com média zero) e caracterizar espacialmente o campo acústico [3]. Algoritmos que usam processamento em banda larga para contornar a falta

de diversidade espacial são capazes de alcançar localização de fontes com um único hidrofone [4], mas a maior parte das técnicas de localização empregam uma classe de algoritmos de processamento de sinais em arranjos conhecidos como conformadores de feixes.

A base do funcionamento dos algoritmos de conformação de feixe consiste na multiplicação do sinal em função do tempo recebido em cada sensor $x_m(t)$ por um peso complexo w_m^* e subsequentemente somar todos os sinais para se obter a saída $y(t)$ do conformador. A Figura 1.1 ilustra esse processo para um arranjo linear uniforme com M sensores.

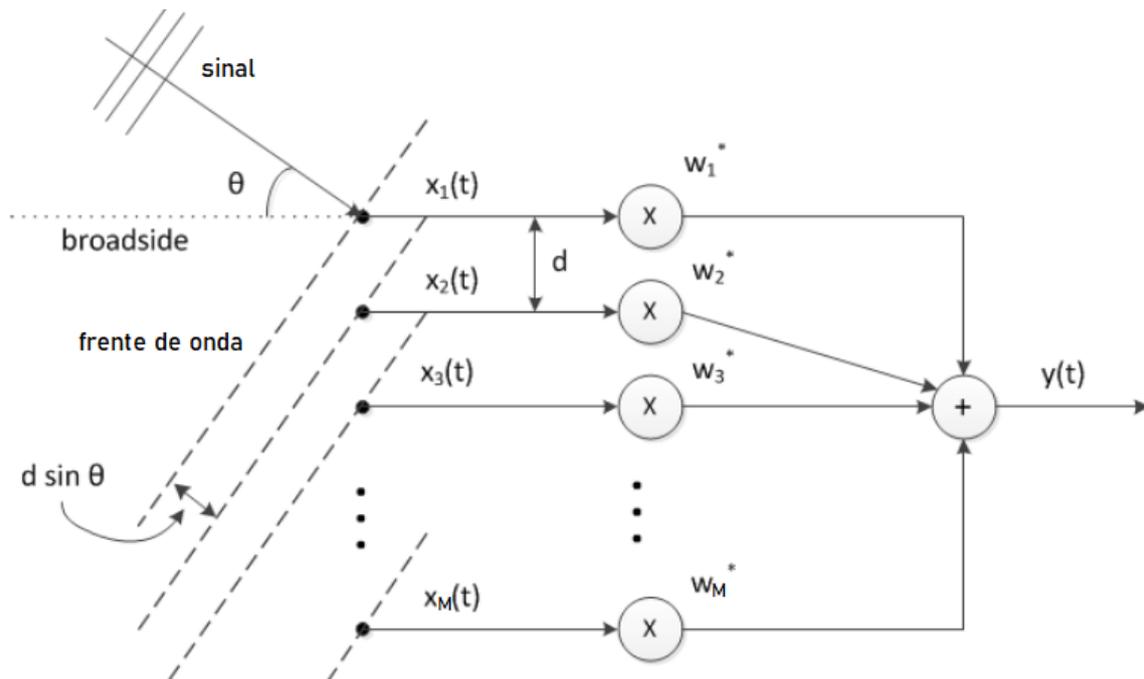


Figura 1.1: Esquema de funcionamento do conformador de feixes para um arranjo linear uniforme. Fonte: adaptado de OKKONEN [5].

O sinal recebido em cada sensor pode ser modelado como uma onda plana monocromática que incide sobre cada um deles com um atraso determinado pela geometria do sensor, pelo meio de propagação e pela direção de chegada da onda. Como o arranjo é linear e uniformemente espaçado de d , e assumindo-se um meio homogêneo e isotrópico com velocidade de propagação constante o atraso se torna dependente somente da direção de incidência θ da onda em relação à direção normal ao arranjo (*broadside*). Uma vez que, para uma onda plana monocromática, um atraso corresponde a uma mudança de fase, pode-se calcular o conjunto de pesos adequados para aplicar a mudança correta no sinal de cada um dos sensores e somá-los todos em uma dada fase. Esse é um processo de filtragem espacial que “aponta” o arranjo para uma dada direção. Um algoritmo que selecione o conjunto de pesos para maximizar a energia da saída do conformador de feixes equivale a um detector de direção de

chegada e é a base da localização de fontes por um sonar passivo.

Foram tacitamente empregados dois tipos de modelos nesse raciocínio: um modelo de propagação (onda plana monocromática com uma única direção de propagação) e um modelo ambiental (meio homogêneo e isotrópico com velocidade do som conhecida e constante). É importante notar esses dois aspectos porque, embora a conformação de feixes seja largamente utilizada no processamento de sinais em antenas para ondas eletromagnéticas no ar e arranjos horizontais ou bidimensionais de hidrofones no mar, ela deixa de ser diretamente aplicável a arranjos verticais, para os quais o efeito de propagação por multicaminhos produz ambiguidades [6]. A propagação por multicaminhos é ocasionada pela estratificação do oceano, que resulta em um perfil de velocidade do som (SSP, *sound speed profile*) que varia com a profundidade e provoca a refração do som, e pela reflexão do som nas fronteiras (superfície e fundo do mar). A Figura 1.2 ilustra a dificuldade de resolução da direção de chegada devido à combinação desses efeitos por meio do traçado de autorraios, *i.e.* raios que ligam uma fonte a um arranjo linear vertical (VLA, *vertical line array*) com três sensores em um ambiente simulado.

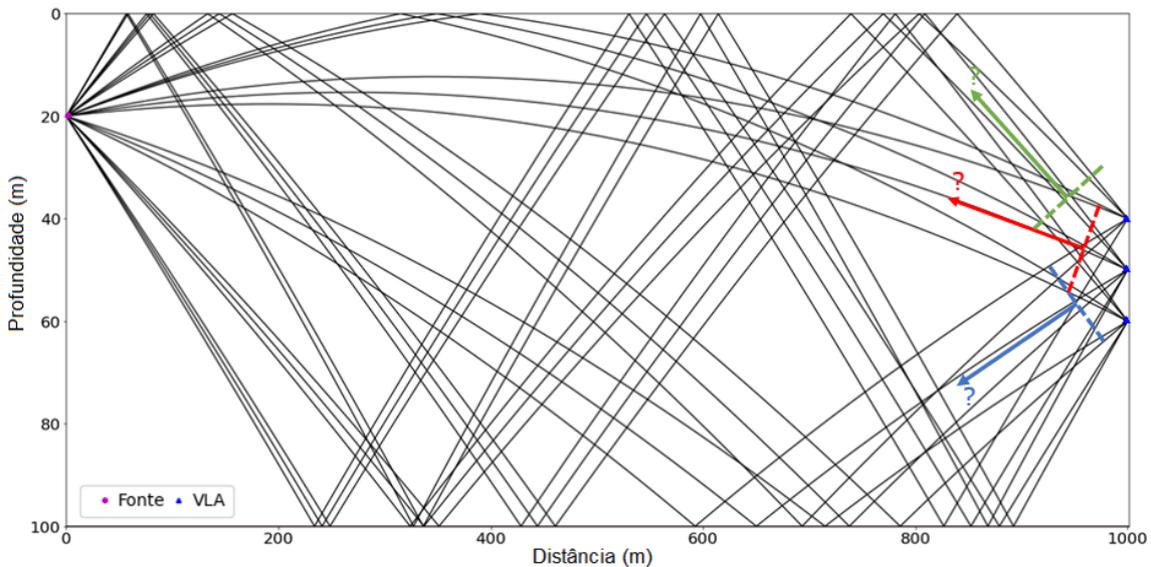


Figura 1.2: Traçado de autorraios em um ambiente simulado com uma fonte e três sensores. As setas indicam as três direções proeminentes de chegada das frentes de onda e ilustram a dificuldade de resolução da direção de chegada por um VLA em um ambiente de águas rasas devido à propagação por multicaminhos.

A mesma estratificação do ambiente oceânico que provoca essa complexidade na propagação do som permite que o plano vertical seja tratado como um guia de ondas (alguns guias são particularmente eficientes, como o canal sonoro profundo, dutos de superfície e propagação em águas rasas abaixo do ângulo crítico com o fundo [7]). Uma multitude de abordagens matemáticas baseadas em soluções para a equação da onda foram desenvolvidas para calcular o campo acústico nesses guias de ondas,

das quais pode-se citar a teoria de raios, teoria de modos normais, integração do número de onda, equações parabólicas e elementos finitos [8].

BUCKINGHAM [9] menciona que o modelo ideal deveria ser matematicamente exato e completamente generalista, capaz de lidar com os detalhes da propagação acústica nos mais complicados ambientes oceânicos. A equação da onda é uma equação diferencial parcial de difícil tratamento matemático em ambientes complexos, de modo que implementações numéricas de sua solução empregam simplificações que permitem uma solução aproximada. Não obstante tais simplificações, que todos os modelos inevitavelmente fazem, quando aplicados adequadamente eles são capazes de fornecer soluções mais acuradas que a aproximação de onda plana usada na conformação de feixes. Aliando tais modelos matemáticos a uma melhor descrição oceanográfica e geoacústica do ambiente e implementações numéricas eficientes, as técnicas de processamento de campo casado ou processamento por ajuste de campo, coletivamente denominadas MFP (*matched field processing*) puderam ser desenvolvidas e aplicadas para diversas modalidades de inversão acústica [10].

O MFP foi introduzido por BUCKER [11] no contexto de localização de fontes como uma alternativa à conformação de feixes. A técnica é uma generalização da conformação de feixes que usa uma solução da equação da onda em um guia de ondas no lugar da aproximação de onda plana, assim explorando a complexidade espacial do campo acústico [12]. Assim como um modelo matemático da propagação, é assumido um modelo ambiental do guia de ondas entre fonte e receptor, o que inclui uma série de parâmetros que descrevem a geometria do guia (posições da fonte e receptor, batimetria), parâmetros oceanográficos (SSP) e geoacústicos (material e propriedades do fundo, número de camadas). Na conformação de feixes, o único parâmetro de interesse é a direção de incidência, com a possível adição da velocidade do som, que em geral é tratada como constante. Ao levar em conta outros parâmetros do sistema no modelo ambiental, o MFP pode ser empregado também para a inversão geoacústica [13] e tomografia oceânica [14], além da localização de fontes.

Apesar de se mostrar uma poderosa ferramenta para inversão acústica, o MFP apresenta uma série de limitações que dificultam sua operacionalização, particularmente na sua concepção inicial de localização de fontes. Dentre elas, destacam-se a questão da robustez contra o chamado desajuste de modelo, que ocorre quando o modelo ambiental não é representativo da realidade, e o custo computacional [10].

O problema do desajuste deriva do fato de que o oceano é um ambiente complexo, dinâmico e variável espacialmente, cujo pleno conhecimento é objeto de grande dificuldade. Se o modelo ambiental empregado no cálculo dos campos acústicos não é uma representação adequada do ambiente real, situação chamada desajuste de modelo, o MFP sofre com erros sistemáticos na inversão dos parâmetros de interesse ou, em caso de grave desajuste, degrada completamente. Formulações adaptativas

da técnica e processadores tolerantes a desajuste têm sido desenvolvidos para tentar contornar esse problema.

Além disso, mesmo com códigos numéricos eficientes e grande evolução nos computadores desde sua origem, o MFP permanece uma técnica intensiva computacionalmente, pois envolve o cálculo de sucessivos campos acústicos para diferentes combinações dos parâmetros de interesse, o que pode facilmente incorrer dezenas ou centenas de milhares de execuções do modelo de propagação a fim de encontrar a combinação de parâmetros que resulte na maior energia [10]. Esse elevado custo computacional dificulta o uso do MFP em aplicações sensíveis ao tempo.

1.2 Motivação para o trabalho

Apesar do MFP ser uma técnica madura e amplamente utilizada no meio científico, suas limitações dificultam a operacionalização em aplicações de recursos limitados e inversão em tempo real [15], das quais se sobressai o emprego tático na localização de fontes. O requisito de fiel conhecimento do ambiente torna favorável o seu emprego em situações como defesa de porto ou monitoramento com uso de arranjos fixos, nas quais o ambiente ao redor pode ser adequadamente caracterizado. Ainda assim, o oceano é um ambiente dinâmico que sofre mudanças em escalas de tempo de minutos (ondas internas), horas (maré) ou mesmo meses (efeito das estações do ano sobre a temperatura da água). Portanto, um certo grau de desajuste é sempre esperado quando se trabalha com técnicas baseadas em modelos, tornando um algoritmo tolerante ou adaptativo uma necessidade.

Uma das abordagens mais perspicazes é a focalização, introduzida por COLLINS e KUPERMAN [16], que consiste basicamente em incluir outros parâmetros do modelo, juntamente com a posição da fonte, no espaço de busca. Como o modelo ambiental é ajustado ao mesmo tempo em que a fonte é localizada, o requisito de estrito conhecimento do ambiente é amenizado. Em contrapartida, a inclusão de outros parâmetros no espaço de busca rapidamente expande a dimensionalidade do problema, tornando computacionalmente inviável a busca em grade dos parâmetros tradicionalmente associada ao MFP (onde os parâmetros são apenas dois, profundidade e distância). Um algoritmo de otimização eficiente se faz necessário para encontrar a combinação de parâmetros que resulte no melhor casamento de campo, tornando o processo um problema de maximização. Desde o princípio, o MFP foi abordado como um problema de maximização, mas a focalização requer técnicas mais sofisticadas, como o recozimento simulado (SA, *simulated annealing*) usado no trabalho original de COLLINS e KUPERMAN [16], ou algoritmos genéticos (GA, *genetic algorithms*), empregados nesse contexto primeiramente por GERSTOFT [17] e amplamente utilizado para inversão de parâmetros em *softwares* como o SAGA

[18].

Um problema de maximização requer o uso de uma função objetivo a ser maximizada. Felizmente, o mesmo processamento de ajuste de campo fornece uma função objetivo, a energia da saída do processador. A combinação da técnica de ajuste de campo com algoritmos de otimização fornece uma interessante abordagem adaptativa e robusta ao problema de desajuste.

Outro método, distinto do MFP, que tem sido bastante estudado graças aos recentes avanços em inteligência computacional, é a aprendizagem de máquina, que já encontra diversos usos na acústica submarina, incluindo a localização de fontes [19]. Aprendizagem de máquina (ML, *machine learning*) é uma designação abrangente para um conjunto de algoritmos de regressão e classificação estatística [20]. Ao empregar algoritmos de regressão com múltiplos parâmetros que são ajustados durante uma fase de treinamento, em que conjuntos de dados são apresentados ao algoritmo repetidamente e uma função de custo quantifica o erro entre a estimativa do algoritmo e um valor verdadeiro de base, os algoritmos de ML são capazes de aproximar funções complexas e não lineares cujo domínio e imagem são desconhecidos. Se os dados acústicos de um VLA forem pré-processados tal qual para o MFP antes de serem alimentados ao algoritmo de ML, o algoritmo irá operar de maneira análoga ao MFP, ajustando a variável de regressão (posição da fonte) para aproximar as características dos campos acústicos usados em seu treinamento, como primeiro notado por OZARD *et al.* [21].

Tradicionalmente baseada em grandes volumes de dados, há vantagens ainda não plenamente estudadas em associar uma abordagem de aprendizagem de máquina ao uso de modelos de propagação para a criação de amplos conjuntos de dados sintéticos. Além dos possíveis benefícios quanto à robustez e redução dos requisitos operacionais ao se usar dados modelados com ambientes diversos, a abordagem por ML traz consigo grande redução no custo computacional da localização que a torna interessante para estudo.

1.3 Objetivos

Os objetivos deste trabalho são:

- Estudar a técnica de MFP para localização de fontes e aplicar o algoritmo a um conjunto de dados experimentais por meio da modelagem de um ambiente com incertezas; e
- A fim de contornar as limitações inerentes ao MFP, particularmente quanto à robustez, estudar e aplicar métodos alternativos para localização da fonte no conjunto de dados, sejam eles:

- Focalização, como uma extensão adaptativa do MFP; e
- Aprendizagem de máquina, uma outra abordagem do problema ainda baseada na modelagem, com o uso de conjuntos de dados sintéticos.

1.4 Publicações

As seguintes publicações foram produzidas no contexto do desenvolvimento desta dissertação:

- *Source localization based on matched field processing focalization using shallow-water experimental data* [22]: publicado nos anais do 12^o Congresso Iberoamericano de Acústica. Consistiu em estudos preliminares da técnica de focalização que embasaram as seções dedicadas a essa técnica nesta dissertação.
- *Integrating modeled environmental variability into neural network training for underwater source localization*: submetido para avaliação ao *Journal of the Acoustical Society of America*. Engloba a metodologia e os resultados apresentados nas seções referentes à aprendizagem de máquina deste trabalho.
- *Aplicação de redes neurais para a classificação automática de embarcações mercantes usando sinais sonar passivos*: aceito para publicação na Revista Pesquisa Naval. Usa um conjunto de dados distinto do analisado nesta dissertação e emprega uma metodologia de aprendizagem de máquina para abordar um problema de classificação.

Capítulo 2

Referencial Teórico

Este capítulo fundamenta a teoria e os algoritmos que são usados neste trabalho, iniciando, na Seção 2.1, por uma discussão sobre o problema inverso e as dificuldades de tal abordagem. A Seção 2.2 traz uma breve introdução à teoria de raios, usada para o cálculo dos campos acústicos modelados. A técnica do MFP é apresentada e discutida na Seção 2.3. A Seção 2.4 apresenta a técnica da focalização, que trata o MFP como um problema de otimização global, e os algoritmos genéticos usados nessa abordagem. Por fim, a Seção 2.5 discute o uso de algoritmos de aprendizagem de máquina, em particular aqueles baseados em redes neurais, para inversão acústica.

2.1 O problema inverso

Um problema inverso consiste no processo de calcular ou estimar os fatos causais que produziram uma determinada observação, baseando-se na premissa de que a observação da variável amostrada contém informação suficiente a respeito do sistema físico que a produziu. Na acústica submarina, uma variável que pode ser amostrada é o campo acústico (magnitude e fase), o qual contém informação sobre a estrutura do meio oceânico no qual o sinal acústico se propaga [10]. O processo de extração dessa informação a partir das observações é chamado inversão.

A solução de problemas inversos, tal qual a de problemas diretos, exige uma teoria física do fenômeno em estudo, *i.e.* um modelo. Dada uma descrição física completa de um sistema, é possível prever a saída do sistema para uma particular entrada. Esse é o chamado problema direto ou problema de simulação ou modelagem [23]. Nesse sentido, a solução do problema direto é única para cada entrada usando um modelo completamente especificado.

O problema inverso, no entanto, é inerentemente não-único. Existe uma infinidade de combinações de entradas e modelos que produzem uma dada saída. A inversão envolve selecionar o modelo capaz de gerar as observações sintéticas (réplicas) mais próximas possíveis da observação amostrada para uma mesma entrada. O

resultado da inversão é, portanto, fundamentalmente limitado pelo modelo usado. Na acústica submarina, mesmo que seja assumido que o modelo matemático da propagação acústica contém uma descrição da física do fenômeno e seja capaz de produzir estimativas precisas o suficiente, os parâmetros ambientais e geométricos usados para descrever o guia de ondas podem fornecer uma representação imprecisa ou incompleta do meio. Ademais, é impossível no problema inverso obter informações sobre grandezas do sistema real. Como todos os cálculos são mediados pelo modelo, o máximo que se pode obter são informações a respeito dos parâmetros do modelo usados para produzir as observações sintéticas. A solução completa do problema inverso envolve não apenas a estimativa dos parâmetros do modelo, mas também uma medida do erro das estimativas.

A Figura 2.1 ilustra como entrada, saída e modelo de um sistema se relacionam nas abordagens direta e inversa.

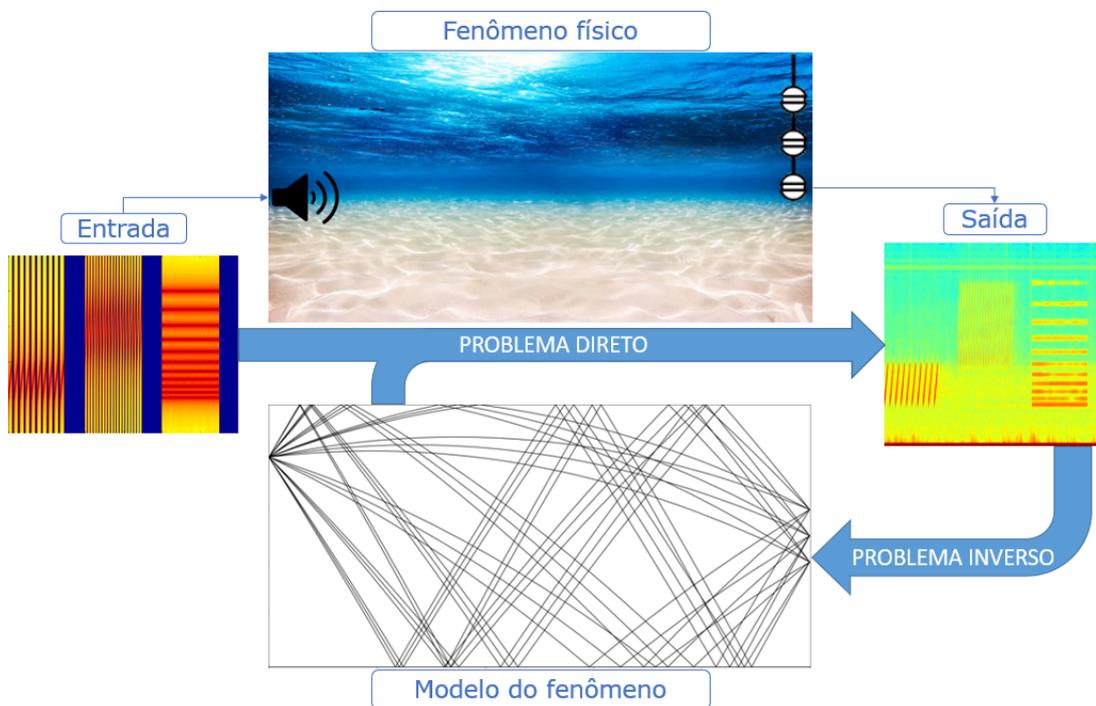


Figura 2.1: Diagrama ilustrativo de como as abordagens direta e inversa relacionam entrada, saída e modelo de um sistema. O sinal de entrada, ilustrado por um espectrograma, é transformado pela propagação no meio submarino e produz uma saída ao ser adquirido por um sensor. O problema direto tenta prever essa saída a partir de um modelo conhecido do sistema, enquanto que o problema inverso tenta estimar o modelo a partir de uma saída conhecida.

Uma vez que as observações são contaminadas por ruídos e a modelagem dominada por incertezas, muitos modelos serão capazes de prover réplicas próximas da observação, mas nem todos eles são representações plausíveis ou realistas do ambiente oceânico. É importante ter certo conhecimento *a priori* das distribuições de probabilidade dos parâmetros. Essa característica de não-unicidade leva também à

ideia do modelo equivalente [24]. É possível empregar um modelo mais simples, com menos parâmetros, que produza a mesma resposta acústica que uma descrição mais completa do ambiente, como, por exemplo, substituir um modelo geoacústico de três camadas por um de uma única camada. Tais modelos podem não ser realistas, mas facilitam o problema se não interferirem com os parâmetros de interesse [10, 16].

Os parâmetros que compõem um modelo de guia de ondas na acústica submarina podem ser separados em três categorias:

- geométricos: incluem a posição da fonte, posição dos receptores (o que deve levar em conta também a inclinação do arranjo) e batimetria.
- oceanográficos: incluem, basicamente, o perfil ou campo de velocidade do som entre fonte e receptor. Por meio de modelos da velocidade do som no mar [25], perfis de temperatura e salinidade também podem ser levados em conta.
- geoacústicos: um modelo geoacústico do fundo considera o número e espessura das camadas, tipos dos sedimentos e rochas e suas propriedades acústicas e elásticas [26].

O campo acústico amostrado tende a ser bastante sensível a mudanças em parâmetros geométricos, moderadamente sensível a mudanças em parâmetros oceanográficos e menos sensível a mudanças nos parâmetros geoacústicos [16, 27], embora essas sejam tendências gerais de comportamento e o efeito de cada parâmetro precise ser estudado caso a caso [28].

A inversão na acústica submarina preocupa-se com a estimativa de algum desses conjuntos de parâmetros: localização de fontes (geométricos), tomografia oceânica (oceanográficos) ou inversão geoacústica. Para que a inversão de qualquer um desses conjuntos de parâmetros seja bem sucedida, é necessário que os demais parâmetros sejam fixados ou conhecidos com razoável grau de certeza. Portanto, para a localização de fontes, é preciso que o modelo ambiental esteja bem calibrado para representar adequadamente o ambiente. Como a obtenção de informações de alta precisão para caracterização do oceano é pouco prática e, além disso, o oceano é um ambiente dinâmico, o problema inverso na acústica submarina permanece de alta complexidade.

2.2 Teoria de raios

Neste trabalho, a modelagem da propagação acústica utilizou um modelo baseado na teoria de raios [8, 29]. A teoria de raios provê uma solução para a equação de Helmholtz, descrita a seguir na forma homogênea para pressão acústica P :

$$\nabla^2 P + \frac{\omega^2}{c^2} P = 0 \quad (2.1)$$

$P = P(\mathbf{r}, \omega)$ é o campo de pressão acústica para uma única frequência ω , dependente da posição \mathbf{r} no sistema de coordenadas cilíndricas considerado somente a propagação no plano $\mathbf{r} = (r, z)$, e ∇^2 é o operador Laplaciano. $c = c(r, z)$ é a velocidade do som no meio, que pode variar espacialmente. O ponto de partida para a solução baseada em raios é assumir que o campo de pressão pode ser descrito da forma:

$$P(\mathbf{r}, \omega) = A e^{-j\omega\tau} \quad (2.2)$$

onde $A = A(\mathbf{r})$ é uma amplitude que varia lentamente em relação à fase $\omega\tau$, sendo $\tau = \tau(\mathbf{r})$. As superfícies de mesma fase, com τ constante, são chamadas frentes de onda. A aplicação do Laplaciano ao campo de pressão resulta na seguinte expressão:

$$\nabla^2 P = e^{-j\omega\tau} [-(\omega^2 |\nabla\tau|^2 + j\omega \nabla^2 \tau) A - 2j\omega \nabla\tau \nabla A + \nabla^2 A] \quad (2.3)$$

Substituir as Equações 2.2 e 2.3 na Equação 2.1 e separar as partes real e imaginária resulta no par de equações:

$$\frac{1}{c^2} A - |\nabla\tau|^2 A + \frac{\nabla^2 A}{\omega^2} = 0 \quad (2.4)$$

$$A \nabla^2 \tau + 2 \nabla\tau \nabla A = 0 \quad (2.5)$$

Faz-se, então, a aproximação para altas frequências, de modo que o termo $\frac{\nabla^2 A}{\omega^2}$ pode ser desprezado. A Equação 2.4 se torna, então:

$$\nabla\tau = \frac{1}{c} \quad (2.6)$$

Esta equação é denominada Eikonal. A integração da Eikonal, com aplicação da reflexão especular quando as coordenadas interceptam uma fronteira, corresponde às trajetórias de propagação das frentes de onda, ou o traçado de raios. A Equação 2.5, denominada equação de transporte, é usada para o cálculo das amplitudes ao longo dessas trajetórias.

Softwares que implementam o modelo de raios, como TRACEO [30] e o BELLHOP [31], fazem primeiro a integração numérica da Eikonal para determinar os tubos de raios, delimitados por dois raios adjacentes, e em seguida calcular, pela equação de transporte, a amplitude ao longo dos tubos, que é inversamente proporcional à área de sua seção transversal. Esse cálculo considera somente a perda na transmissão devido ao espalhamento geométrico, portanto perdas por absorção

e nas reflexões são implementadas separadamente. Como os raios não penetram a fronteira com o fundo, usualmente o fundo é modelado como somente um meio-espaço e as perdas e mudanças de fase na reflexão são tratadas por coeficientes de reflexão de onda plana.

A solução baseada na equação de transporte encontra problemas nas regiões em que a área da seção transversal do tubo aproxima-se de zero. A singularidade no ponto onde a área é precisamente zero se chama cáustica e produz amplitudes anormalmente altas nas proximidades (e infinitamente alta na singularidade), além de introduzir uma mudança de fase de $\pi/2$. Na prática, para contornar esse problema, os modelos implementam uma solução baseada em feixes Gaussianos [32], que introduz um decaimento Gaussiano da amplitude na direção normal ao raio.

O traçado de raios é limitado somente pela aproximação de alta frequência feita para se derivar a Eikonal, uma vez que nenhuma outra aproximação é feita no desenvolvimento. A implicação disso é que as mudanças de amplitude, curvatura do raio e velocidade do som devem ser pequenas ao longo de um comprimento de onda [9]. Grosseiramente, a solução baseada em raios é válida quando o comprimento de onda é muito menor que qualquer outra escala de comprimento do guia de ondas, como profundidade ou variações significativas de velocidade do som.

Apesar da aproximação de alta frequência que leva a resultados menos precisos que outras soluções da equação da onda em algumas situações, modelos de raios permanecem relevantes, particularmente em aplicações onde incertezas ambientais estabelecem restrições muito mais severas à precisão dos resultados, na presença de guia de ondas que apresentem variações relevantes na batimetria e aplicações onde o custo computacional é um fator crítico [8].

2.3 Processamento de campo casado

O processamento de campo casado, ou processamento por ajuste de campo, é uma generalização da conformação de feixes e adquire seu nome devido ao uso de uma solução da equação da onda para o campo acústico completo e técnicas de processamento de sinais que exploram a estrutura desse campo em um guia de ondas [10, 12]. Como uma técnica de inversão acústica, o MFP possui três componentes:

- Uma amostra do sinal recebido no arranjo de sensores, denominado vetor de dados \mathbf{d} . Como o sinal recebido é contaminado por ruído, emprega-se técnicas de processamento para se obter uma estimativa do sinal real.
- Um modelo do sinal recebido, que inclui um modelo matemático da propagação de ondas, um modelo ambiental e, em alguns casos, um modelo de ruído. Esses

elementos são usados para produzir réplicas do sinal amostrado sob diversas combinações de parâmetros. Cada vetor réplica é denominado \mathbf{e} .

- Uma função, ou processador, capaz de correlacionar a estimativa do sinal amostrado com a réplica modelada.

Um processador capaz de fazer essa correlação entre os vetores de dados e réplica é um simples produto interno. O processador linear, também chamado de Bartlett, calcula o quadrado da norma l^2 desse produto:

$$B(\boldsymbol{\theta}, f) = |\mathbf{e}(\boldsymbol{\theta}, f)^H \mathbf{d}(f)|^2 \quad (2.7)$$

onde $\mathbf{d} = [d_1, d_2, \dots, d_M]^T$ é o vetor de dados cujos elementos são a amplitude complexa da transformada de Fourier da pressão acústica do sinal recebido em cada hidrofone, para uma determinada frequência f . O vetor de réplica $\mathbf{e} = [e_1, e_2, \dots, e_M]^T$ contém a pressão calculada pelo modelo na posição de cada hidrofone, enquanto que H denota o operador Hermitiano. $\boldsymbol{\theta}$ representa um vetor de parâmetros do modelo que são variados para gerar diferentes réplicas; no caso da localização de fontes por MFP, os parâmetros de interesse são a distância r e a profundidade z da fonte. É evidente que o processador irá obter o valor máximo quando o vetor de réplica igualar o vetor de dados, o que, na ausência de ruído e supondo o modelo uma perfeita representação do fenômeno, só acontecerá quando os parâmetros $\boldsymbol{\theta}$ usados para gerar a réplica estejam corretos. Se ambos os vetores, de dados e réplica, forem previamente normalizados pelas suas respectivas normas, de modo a se tornarem vetores unitários, o valor máximo que o processador pode atingir é a unidade.

Expandindo o produto na Equação 2.7 e omitindo as dependências das funções para clareza da notação, tem-se:

$$B = \mathbf{e}^H \mathbf{d} \mathbf{d}^H \mathbf{e} \quad (2.8)$$

A grandeza $\mathbf{d} \mathbf{d}^H$ é em geral substituída por uma estimativa da matriz de covariância da amostra (SCM, *sample covariance matrix*) \mathbf{R} , calculada pela média de L *snapshots*, ou instantâneos, do sinal a fim de se obter uma estimativa do sinal com menos influência do ruído:

$$\mathbf{R} = \frac{1}{L} \sum_{l=1}^L \mathbf{d}_l \mathbf{d}_l^H \quad (2.9)$$

Substituindo a SCM na Equação 2.8, obtém-se a forma usual do processador Bartlett:

$$B = \mathbf{e}^H \mathbf{R} \mathbf{e} \quad (2.10)$$

O MFP clássico consiste em calcular a energia do processador para diferentes vetores réplica $e(\theta, f)$ computados pelo modelo com diferentes combinações de parâmetros. Se os parâmetros de interesse forem dois, como distância e profundidade ($\{r, z\} \subset \theta$), a energia do processador pode ser mapeada em uma grade desses parâmetros para produzir uma superfície de ambiguidade, conforme ilustrado na Figura 2.2. O máximo global da superfície de ambiguidade se manifesta na combinação de parâmetros que produz o melhor casamento de campo.

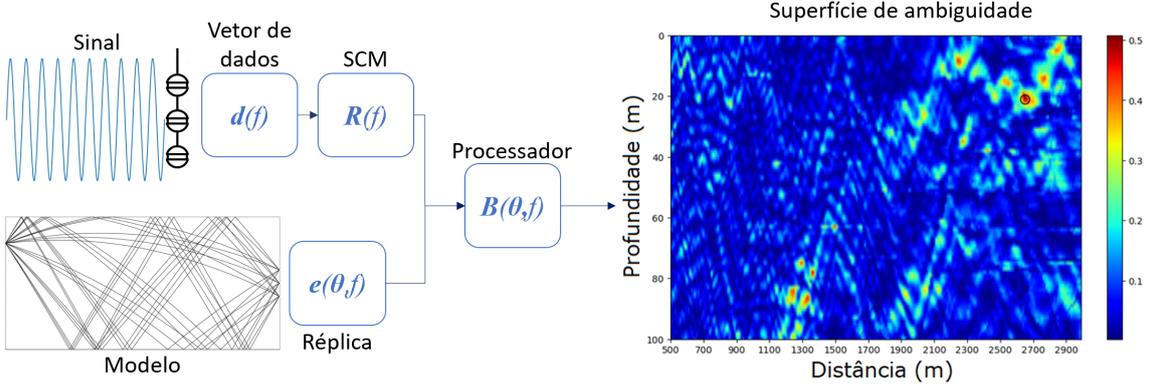


Figura 2.2: Fluxograma de funcionamento do MFP. Na superfície de ambiguidade, o máximo global, sinalizado por um círculo preto, representa a estimativa da posição da fonte.

As demais regiões de alta energia, ou máximos locais da superfície de ambiguidade, são chamadas, por analogia com o conformador de feixes, de lóbulos secundários [6]. Na presença de ruído ou severo desajuste de modelo, o máximo global da superfície de ambiguidade pode se manifestar em um lóbulo secundário, levando a inversão a um resultado incorreto.

Outros processadores foram desenvolvidos com propriedades distintas do Bartlett em questões como resolução e supressão de lóbulos secundários. Um exemplo deles é o processador de variância mínima com resposta sem distorção (MVDR, *minimum variance distortionless response*) [8, 33]:

$$B = [e^H \mathbf{R}^{-1} e]^{-1} \quad (2.11)$$

Ao minimizar a energia do processador exceto no lóbulo principal, o MVDR consegue suprimir lóbulos secundários e obter melhor resolução em profundidade e distância, como ilustrado na Figura 2.3.

Está implícito, no entanto, que a alta resolução se estende aos demais parâmetros do modelo, não somente àqueles de interesse. Essa propriedade torna o MVDR particularmente suscetível ao problema de desajuste de modelo, o que se pode dar inclusive por discretização insuficiente dos parâmetros de interesse, possibilitando que a posição verdadeira não corresponda precisamente a uma das posições da grade

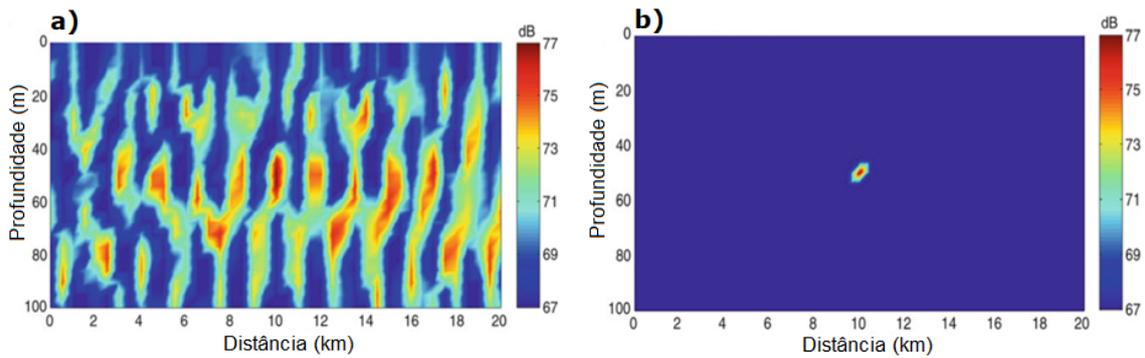


Figura 2.3: Comparação entre superfícies de ambiguidades produzidas pelo processador a) Bartlett e b) MVDR. Fonte: adaptado de JENSEN *et al.* [8].

de busca [28], situação em que sua alta resolução se torna uma desvantagem. Boa parte da literatura de MFP lida com o desenvolvimento de processadores de alta resolução robustos e tolerantes a desajuste [34–36]. O Bartlett é o processador menos sensível a erros de modelagem [37], o que, combinado com sua simplicidade, o torna um dos processadores mais usados ainda hoje e a referência contra qual outras técnicas costumam ser comparadas.

Outra questão a ser levada em conta é a frequência da fonte. O grau de desajuste é dependente da frequência, em particular porque as escalas de tempo e distância necessárias para descrever o ambiente decrescem com o aumento da frequência [38]. A frequências maiores, a rápida mudança de fase e o menor comprimento de onda fazem com que a estrutura do campo acústico varie rapidamente e o processador obtenha uma resolução maior - o que leva mais facilmente a problemas de desajuste [39]. Por essa razão, a maior parte dos estudos sobre MFP são feitos a baixa frequência, abaixo de 500 Hz. Apesar do tratamento até então ter sido para ondas monocromáticas, o MFP pode ser facilmente estendido para processamento em banda larga, a forma mais simples das quais envolve fazer a média incoerente das superfícies de ambiguidade nas várias frequências do sinal. Tal processamento pode trazer melhoras na localização da fonte e do SNR, mas incorre no custo computacional adicional do cálculo das réplicas a múltiplas frequências [6].

Muitos dos estudos sobre MFP lidam com o efeito que variações de parâmetros ambientais e do sistema (quantidade e posicionamento dos sensores, extensão do arranjo) possuem sobre as superfícies de ambiguidade [40–42]. Uma das dificuldades do estudo do MFP é que essas investigações precisam acontecer caso a caso para cada tipo de desajuste e configurações do sistema, pois é difícil prever o impacto que perturbações nesses parâmetros têm sobre o campo acústico e sobre os processadores, particularmente os não-lineares, o que leva a conclusões pouco específicas [28]. Não obstante, o conhecimento desses efeitos pode informar a interpretação dos resultados do MFP e o desenvolvimento de algoritmos adaptativos para contornar o problema

de desajuste.

2.4 Focalização

A principal limitação do MFP quanto à robustez advém do ambiente oceânico que, como mencionado, é complexo, dinâmico e espacialmente variável. A resposta impulsiva de um guia de ondas inevitavelmente dependerá de todos os elementos que o compõem, incluindo aqueles que são difíceis de mensurar com a resolução temporal e espacial necessária para descrevê-los completamente. Mesmo quando a aquisição de dados é possível, há limitações de ordem operacional na quantidade, qualidade e abrangência de dados que podem ser coletados. Ao se trabalhar com modelagem oceânica, é preciso reconhecer que o conhecimento a respeito do ambiente será sempre incompleto; não obstante, é possível muitas vezes construir modelos equivalentes do ambiente, baseados na limitada informação *a priori*, que sejam representativos o suficiente para os fenômenos estudados pela acústica submarina.

A compreensão de que não apenas os parâmetros de interesse (no caso da localização, distância e profundidade da fonte), mas quaisquer parâmetros pertencentes ao vetor θ que compõem o modelo poderiam ser buscados simultaneamente levou ao desenvolvimento da técnica denominada focalização por COLLINS e KUPERMAN [16]. Normalmente chamados parâmetros perturbadores na estatística e em problemas de otimização, a falta de conhecimento sobre os valores desses parâmetros limita a capacidade de inversão dos parâmetros de interesse. Ao incluí-los no espaço de busca, juntamente com os parâmetros de interesse, obtém-se um algoritmo adaptativo a variações desconhecidas nos parâmetros perturbadores.

No trabalho original de COLLINS e KUPERMAN [16], apenas parâmetros referentes à velocidade do som na coluna d'água foram incluídos no espaço de busca, de modo a tratar a coluna d'água como uma lente que pudesse ser ajustada para “focar” o modelo na posição correta da fonte. Trabalhos subsequentes expandiram o método para funcionar de modo mais geral como uma otimização global e incluir também parâmetros geoacústicos e profundidade da coluna d'água [17] além de variações na posição do arranjo de sensores [38]. As técnicas de otimização global desenvolvidas nesse contexto passaram a ser empregadas não somente na localização de fontes, mas também tomografia oceânica [43] e inversão geoacústica [13, 44, 45].

Um processador que incorpora as incertezas do ambiente já havia sido desenvolvido por RICHARDSON e NOITE [34]. Denominado processador de campo incerto, a incorporação dos parâmetros perturbadores é feita por meio de funções densidade de probabilidade *a priori* desses parâmetros. O avanço alcançado pela técnica de focalização foi o tratamento da inversão como um problema de otimização global. O MFP clássico é um problema de otimização que é abordado através do mapeamento

de uma função de ambiguidade (o processador) em duas coordenadas e localizando por inspeção o máximo global da superfície resultante. Com a adição de outros parâmetros no espaço de busca, o número de combinações a serem testadas aumenta exponencialmente, tornando proibitivo computacionalmente testar todas elas. O espaço de busca multidimensional pode ser amostrado por métodos de Monte Carlo, mas um algoritmo de otimização capaz de direcionar a busca baseado na maximização de uma função objetivo se faz necessário para que o processo se torne eficiente. O próprio processador usado no ajuste de campo pode ser usado como função objetivo, pois é sabido que seu valor máximo só é alcançado quando a réplica perfeitamente iguala o campo medido.

Dois dos algoritmos de otimização mais empregados são o recozimento simulado (SA) [46] e os algoritmos genéticos (GA) [47]. O SA aplica perturbações aleatórias sobre um vetor θ e calcula a função objetivo para a réplica produzida usando a nova combinação de parâmetros. Caso o novo vetor produza uma melhora na função objetivo, ele é aceito como solução e a busca prossegue a partir dele. Caso contrário, o novo vetor tem uma probabilidade de ser aceito, mediada por um parâmetro denominado temperatura, cujo valor inicia alto e decresce a cada iteração do algoritmo. No início, com a temperatura alta, o SA tem grandes chances de aceitar soluções piores, o que facilita que o algoritmo escape de máximos locais e explore o espaço de busca mais amplamente. Conforme a temperatura decresce, diminui também a probabilidade de vetores piores serem aceitos, o que afunila a busca em direção ao máximo global. O SA é bastante eficiente em encontrar o máximo global de funções que dependem de muitos parâmetros e foi aplicado com sucesso por COLLINS e KUPERMAN [16].

O GA, que é descrito em detalhe na próxima seção, é também um método de Monte Carlo (ou seja, utiliza aleatoriedade na amostragem do espaço de busca), mas emprega uma coleção de vetores que exploram o espaço de busca simultaneamente. Efeitos estocásticos promovem a troca de informação entre os vetores a fim de melhorar o ajuste (a função objetivo) da população inteira entre iterações para que os vetores convirjam para regiões promissoras do espaço de busca. GA foi primeiro utilizado para inversão acústica por casamento de campo por GERSTOFT [17] e, desde então, tornou-se uma das ferramentas mais populares para esse fim graças ao poder de exploração paralela e à possibilidade de se obter distribuições de probabilidade *a posteriori* (PPD, *posterior probability distribution*) dos parâmetros contidos no vetor. Em uma comparação entre os algoritmos GA e SA [45], concluiu-se que a exploração paralela com troca de informação entre os vetores permite determinar a importância relativa de cada parâmetro para a função objetivo e torna o GA um algoritmo muito mais rápido.

O caso bidimensional da otimização global é a superfície de ambiguidade: o resul-

tado da função objetivo (processador) para cada combinação possível de parâmetros. Cada parâmetro adicional incluído na busca aumenta em um o número de dimensões do problema e também a complexidade da imagem da função. Pela superfície de ambiguidade do Bartlett, exemplificada nas Figuras 2.2 e 2.3, percebe-se que a topografia da imagem da função é complexa e não convexa, apresentando múltiplos máximos e mínimos locais. Não é possível encontrar o máximo global dessa função analiticamente, por isso algoritmos de otimização e técnicas de Monte Carlo são necessárias.

Devido à complexidade e à alta dimensionalidade do problema, não há garantia que os algoritmos de otimização encontrem a melhor solução possível. Não obstante, a solução encontrada pode conduzir a um modelo ambiental equivalente que produza um ajuste de campo eficaz e uma localização correta da fonte. Particularmente para a localização de fontes, é importante lembrar que o campo acústico tem maior sensibilidade aos parâmetros geométricos, principalmente a posição da fonte. Não é inesperado que o algoritmo estabilize na posição correta da fonte antes de estabilizar nos demais parâmetros [16] - e que os demais parâmetros estabilizem em valores não realistas ou incorretos. Particularmente, a baixos SNR os parâmetros menos importantes tendem a ficar indeterminados [17].

2.4.1 Algoritmos genéticos

Os GA foram desenvolvidos por analogia com o princípio biológico da evolução. Dada uma função objetivo multiparâmetro, cada combinação de parâmetros (indivíduo), simbolizada pelo vetor θ , produz um valor associado tomado como seu “*fitness*” (adaptação, no sentido evolutivo). No processamento por ajuste de campo, essa adaptação é o valor do processador que correlaciona o campo modelado (réplica) com o campo observado. Considere uma população inicial com n_{pop} vetores amostrados dentre todas as possíveis combinações de parâmetros do espaço de busca. Por meio de uma série de iterações evolutivas, a população inicial é modificada a fim de aumentar sua adaptação.

Para que as operações de cada iteração evolutiva sejam aplicadas, os vetores são convertidos para representação binária. Se n_{bit} bits forem usados na representação de cada parâmetro θ_i , o espaço de busca de cada um deles será discretizado em $2^{n_{bit}}$ valores entre θ_i^{min} e θ_i^{max} . A discretização dos parâmetros pode incorporar uma distribuição uniforme, Gaussiana ou alguma distribuição que reflita um conhecimento *a priori* de cada parâmetro. A Figura 2.4 exemplifica essa representação.

Uma iteração evolutiva consiste das seguintes operações:

- Seleção: Dentre os n_{pop} vetores, os mais adaptados são selecionados como pais da geração seguinte. A seleção pode ser determinística, quando somente os mais

*	*	*	*	*	*	*	*		
0	0	0	0	0	0	0	0	=	θ_i^{\min}
0	0	0	0	0	0	0	1	=	$\theta_i^{\min} + 1 \Delta\theta$
0	0	0	0	0	0	1	0	=	$\theta_i^{\min} + 2 \Delta\theta$
0	0	0	0	0	0	1	1	=	$\theta_i^{\min} + 3 \Delta\theta$
.
1	1	1	1	1	1	1	1	=	θ_i^{\max}

Figura 2.4: Representação binária de um parâmetro θ_i usando uma distribuição uniforme e 3 bits de informação. Fonte: adaptado de GERSTOFT [18].

adaptados são selecionados, ou estocástica, quando há possibilidade de vetores piores serem selecionados como pais, o que pode ajudar a manter o espaço de busca ampliado e a diversidade dentro da população. Um hiperparâmetro como a temperatura do SA pode ser introduzido nessa fase para controlar a probabilidade de seleção de cada vetor [18]. Caso os melhores indivíduos sejam não apenas selecionados como pais mas preservados para compor a geração seguinte, o GA é chamado elitista [48].

- *Crossover*: A operação de *crossover* é aplicada em um par de indivíduos selecionados como pais. Um ponto de corte é selecionado aleatoriamente ao longo da representação binária dos vetores e os bits de cada lado desse ponto de corte são trocados entre os dois vetores, como ilustrado na Figura 2.5. Esse *crossover* pode ocorrer em um único ponto na representação binária do vetor inteiro ou em múltiplos pontos nas seções de n_{bit} bits referentes a cada parâmetro. É essa operação que permite a troca de informações a respeito da topologia do espaço de busca e é recomendado que a taxa de *crossover* seja alta, próxima de 1.

- *Mutação*: Após o *crossover*, cada bit dos filhos resultantes tem uma pequena chance de sofrer uma mutação, que consiste em inverter o valor do bit, como exemplificado na Figura 2.5. A operação de mutação é particularmente importante pois permite que os indivíduos de uma população que tenha se tornado demasiadamente uniforme escapem máximos locais dando “saltos” de grande distância no espaço de busca [49].

As três operações descritas são aplicadas sequencialmente por n_{ger} gerações ou até que um critério de parada seja atingido, como nenhum vetor com melhor grau de adaptação ser encontrado após dado número de iterações evolutivas. A Figura 2.6 delinea como um GA funciona para inversão por MFP usando o Bartlett como função de custo.

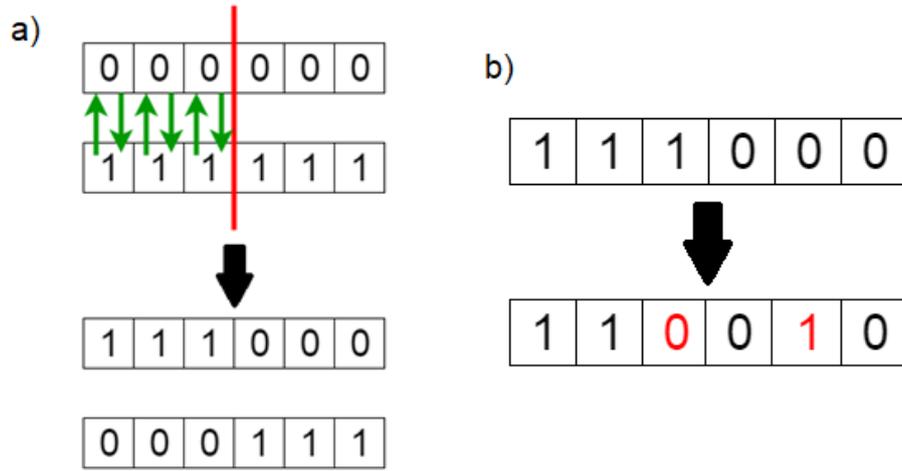


Figura 2.5: Funcionamento dos operadores (a) *crossover* e (b) *mutação*.

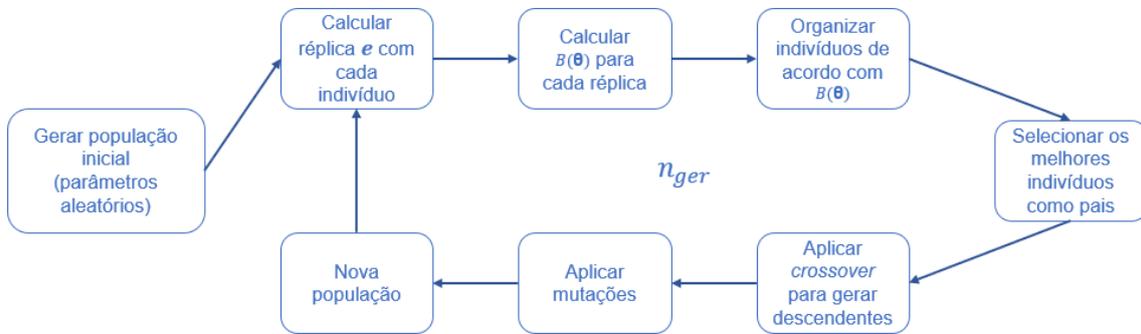


Figura 2.6: Esquema do algoritmo genético aplicado ao processamento de campo casado.

O processo evolutivo pode ser repetido por n_{run} execuções independentes com populações iniciais distintas. Caso se deseje somente uma estimativa dos parâmetros a serem invertidos, $n_{run} = 1$ é suficiente, embora, devido aos efeitos estocásticos e à possibilidade da população ficar presa em um máximo local, é razoável executar o algoritmo mais de uma vez e tomar o vetor de parâmetros que resulta no melhor ajuste dentre as várias execuções como solução. Para que se possa extrair estatísticas *a posteriori* sobre as distribuições dos parâmetros, recomenda-se que n_{run} seja um valor alto o suficiente para que se obtenha uma ampla coleção de vetores bem adaptados [18]. Os resultados das inversões usando otimização global por GA normalmente dispensam a superfície de ambiguidade tradicionalmente associada com o MFP em favor de estatísticas das PPD marginais dos parâmetros. Sendo assim, o GA é capaz tanto de incorporar conhecimento *a priori* a respeito da variabilidade do ambiente quanto fornecer informações *a posteriori* sobre o ambiente em consideração naquele dado instante.

2.5 Aprendizagem de máquina

Aprendizagem de máquina (ML) é um termo abrangente para uma classe de algoritmos estatísticos de regressão e classificação. A aprendizagem chamada supervisionada fundamentalmente baseia-se no uso de exemplos para treinamento de um algoritmo, o que resulta em um modelo estatístico capaz de realizar previsões e estimativas para novas entradas distintas dos exemplos usados no treinamento. DE VITO *et al.* [50] estabeleceram que, embora as teorias de aprendizagem de máquina e problemas inversos sejam distintas, o aprendizado por exemplos equivale a uma solução de um problema inverso. Nesse caso, o modelo usado na inversão é um modelo estatístico construído a partir dos exemplos de entrada, aqui denominado “modelo de ML”, em substituição aos modelos determinísticos baseados na física tradicionalmente usados para inversão.

Com amplos volumes de dados de treinamento, algoritmos de ML são capazes de encontrar padrões complexos nos dados automaticamente [19]. Tal capacidade tem sido bastante explorada na acústica submarina para a solução de problemas como detecção e classificação de mamíferos marinhos [51, 52] e classificação automática de embarcações [53, 54], com o desempenho das abordagens por ML se mostrando mais robustas que as técnicas algorítmicas convencionais [55].

Há grande interesse no uso de ML também para localização de fontes, com estudos considerando o uso de redes neurais¹ de alimentação direta (FNN, *feedforward neural networks*) datando desde o começo da década de 1990 [21, 56]. Tais estudos demonstraram o potencial do método, mas foram severamente limitados na complexidade do modelo devido à pouca capacidade de processamento. Mais recentemente, um estudo detalhado por NIU *et al.* [57] comparou vários algoritmos de ML (FNN, máquinas de vetor suporte e florestas aleatórias) e concluiu que, dentre eles, as FNN são capazes de produzir modelos não-lineares mais robustos, particularmente abordando o problema de localização como um de regressão. A estimação de distância de um navio a partir do seu ruído irradiado alcançou erros de 3%, quando usada uma rede neural para classificação, e 5% usando uma rede neural para regressão.

Outros estudos exploraram estratégias de aprendizado semi-supervisionado [58], que fazem uso de redes neurais especiais para extrair informações de dados não rotulados, diferentes arquiteturas de redes neurais [59, 60], e técnicas de regularização para reduzir a complexidade dos modelos resultantes e melhorar o ajuste aos dados [61, 62]. Os resultados desses trabalhos favorecem a abordagem por ML em detrimento dos métodos clássicos de localização. WANG e PENG [60] alcançaram cerca de 3,5% de erro na estimação de distância de uma fonte rasa emitindo vários tons

¹Embora o termo correto estritamente relacionado a neurônios seja “neuronal”, em razão da difusão da terminologia “rede neural” no campo da aprendizagem de máquina, esta é a nomenclatura usada neste trabalho.

pela abordagem baseada em redes neurais, contra 18%, em média, obtido pelo MFP.

Por sua natureza, a aprendizagem supervisionada depende da existência de grande volume de dados rotulados, isto é, com um valor conhecido do parâmetro de inversão associado, como, por exemplo, a distância verdadeira da fonte em relação ao receptor. Tais dados são difíceis de se obter para o problema de localização, particularmente se a intenção é criar um modelo robusto capaz de generalizar sob diversas condições ambientais. Como o oceano é dinâmico, o conjunto de dados necessário para treinar tal modelo robusto precisa ser abrangente em termos dos ambientes amostrados; caso contrário, os vieses contidos no conjunto de dados (como um perfil de velocidade do som predominante) se propagarão para o modelo em si. Esse é um problema análogo ao desajuste de modelo no MFP. Uma abordagem do MFP baseada em dados coletados *in loco* em vez de campo modelados [63] encontrou o mesmo problema de degradação após o ambiente passar a diferir suficientemente do banco de réplicas.

De uma perspectiva do ML, esse problema pode ser encarado à luz do dilema do viés-variância [64]. Um modelo “simples”, com alto viés, irá falhar em generalizar (problema chamado *underfitting*). Se os dados de treinamento são enviesados, esse viés se manifestará no modelo treinado também [65]. Dessa forma, o modelo de ML não será capaz de fazer previsões corretas para casos distintos das amostras de treinamento.

Um modo de aliviar os efeitos de conjuntos de dados pequenos, subamostrados ou enviesados é o aumento de dados [66–68], dentre os quais um dos mais simples e eficazes é adição de ruído às amostras existentes [69, 70]. Com o desenvolvimento de redes neurais adversariais generativas [71], modelos generativos têm sido cada vez mais usados para aumentar conjuntos de dados por meio da criação de amostras inteiramente novas, ao invés de transformações em amostras existentes. Na acústica submarina, o uso de modelos de propagação tem servido também a esse propósito.

Trabalhos existentes que exploram o treinamento de algoritmos de ML com dados sintéticos notaram que a robustez do modelo contra desajuste de SSP aumenta quando os dados de treinamento são aumentados por campos modelados [61] e que dados simulados gerados com uma diversidade de profundidades batimétricas também ajuda a compensar esse tipo de desajuste [72]. Modelos de aprendizagem profunda, *i.e.* capazes de realizar extração de feições dos dados automaticamente, ambos usando redes neurais convolucionais treinadas exclusivamente em dados simulados [73] ou dados mistos incluindo dados simulados ruidosos [74] obtiveram bom desempenho em testes com dados reais, esta última alcançando 2,10% de erro médio em distância contra 6,41% do MFP. CHEN e SCHMIDT [75] concluíram que redes neurais convolucionais treinadas com dados sintéticos apresentam maior robustez a desajuste de SSP e profundidade batimétrica que o MFP clássico, além de obter re-

sultados melhores quando testados com dados reais de dois experimentos distintos, embora a estrutura de classificação tenha se saído melhor que a de regressão. Em todos esses casos, o ambiente foi modelado invariante com a distância.

O problema de localização pode ser abordado de duas maneiras: por classificação ou por regressão. Quando tratado como um problema de classificação, a distância ao receptor é discretizada em *bins* que funcionam como as distintas classes, enquanto que o problema de regressão possui uma única saída que é uma variável cujo valor varia livremente. A abordagem de classificação é normalmente usada por ser um problema mais simples, resultando em modelos menos complexos, com menos parâmetros [75], apesar da perda de precisão associada à discretização.

A localização de fontes por ML, até então, tem sido explorada quase que inteiramente como estimação de distância somente, ou seja, localização unidimensional. A localização bidimensional em distância e profundidade normalmente associada ao MFP é possível, mas traz complexidade adicional. Em uma estrutura de classificação, cada combinação de profundidade e distância pode ser tratada como uma classe, mas por essa abordagem o número de classes aumenta exponencialmente, o que não só aumenta a complexidade do modelo mas também resulta em requisitos mais difíceis para os dados de treinamento, que devem conter amostras distribuídas de maneira balanceada em todas as classes. Na regressão, essa abordagem equivale a um modelo de regressão de duas variáveis, o que incorre no mesmos problemas (maior complexidade e necessidade de se ter dados uniformemente amostrados no domínio da função) com a complicação adicional de que o modelo precisará compartilhar parâmetros para ajustar as duas variáveis. Alternativamente, em ambos os casos, pode-se usar uma estrutura de modelos em cascata, no qual um primeiro modelo faz a localização em uma coordenada (*e.g.* distância) e então chama um outro modelo treinado para realizar a localização na outra coordenada. A desvantagem desse processo é a necessidade de se treinar uma grande quantidade de modelos. NIU *et al.* [73] contornam, até certo ponto, esse problema ao usar uma primeira discretização grosseira em distância para estimar um dentre quatro *bins* e então chamar outras duas redes neurais treinadas para o respectivo *bin*, uma para fazer a localização em profundidade e a outra para uma localização mais fina em distância. Apesar dos bons resultados encontrados, a localização bidimensional por ML permanece um problema de grande complexidade.

2.5.1 Redes neurais de alimentação direta

As redes neurais de alimentação direta (FNN) englobam três arquiteturas de redes neurais:

- perceptron multicamadas: usadas para processamento de dados tabulares

(consistindo de uma entrada com um respectivo rótulo). São a mais simples arquitetura de redes FNN, mas bastante versáteis e expansíveis em complexidade.

- rede neural convolucional: bastante utilizadas no processamento de imagens, usam filtros convolucionais com pesos ajustáveis para realizar extração de feições dos dados automaticamente, o que as tem tornado um componente importante em metodologias de aprendizagem profunda.
- rede neural recorrente: implementa neurônios recorrentes na sua arquitetura, que podem ser entendidos como neurônios com memória que se retroalimentam a própria saída. Essa adição de memória à rede a torna particularmente apropriada ao processamento de sinais temporais, como áudio, ou dados com relação sequencial, como processamento de texto, além de serem usados em modelos generativos para produção de novas sequências de dados.

O elemento básico de uma rede neural artificial é o neurônio, esquematizado na Figura 2.7.

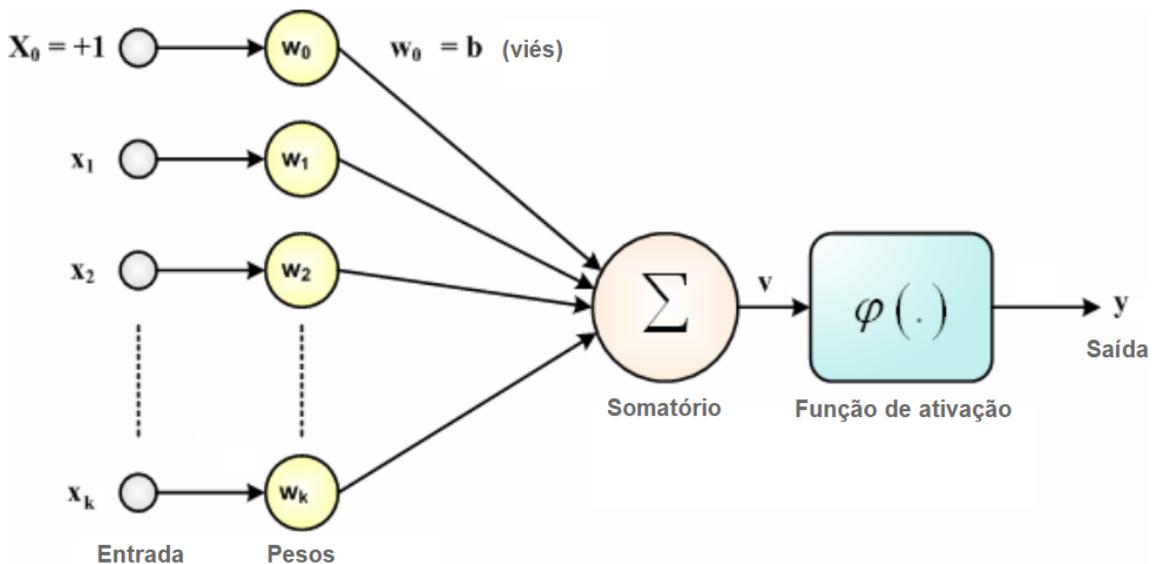


Figura 2.7: Representação gráfica do modelo matemático de um neurônio artificial. Fonte: adaptado de SUMARI *et al.* [76].

Matematicamente, a saída y de um neurônio pode ser sumarizada por:

$$y = \varphi \left(\sum_{i=0}^k x_i w_i \right) \quad (2.12)$$

onde cada peso multiplicativo w é conectado a um outro neurônio da camada anterior, seja a camada de entrada ou uma camada intermediária. O peso w_0 é chamado de viés e permanece conectado a uma entrada unitária, de modo a servir como um

limiar de ativação do neurônio, um valor que o restante do somatório deve exceder a fim de que o sinal se propague adiante. O somatório dos pesos multiplicados pelas entradas, representado pela saída intermediária v , é passado a uma função de ativação φ . Duas funções de ativação comuns são a sigmoide:

$$\varphi(v) = \frac{1}{1 + e^{-v}} \quad (2.13)$$

e a unidade linear retificada (ReLU, *rectified linear unit*):

$$\varphi(v) = \begin{cases} v, & \text{se } v > 0 \\ 0, & \text{se } v \leq 0 \end{cases} \quad (2.14)$$

A função de ativação é usualmente não-linear e é o que permite que a rede neural faça mapeamentos complexos entre entradas e saídas. Com efeito, foi demonstrado que uma rede neural com uma única camada intermediária, desde que possua neurônios suficientes, consegue aproximar qualquer função não-linear arbitrária [77].

A capacidade de aproximar uma dada função surge, além do mapeamento não-linear, da possibilidade de expandir a quantidade de parâmetros ajustáveis (pesos) a partir do modelo matemático simples que define um neurônio. Uma simples rede neural composta por um único neurônio de saída ligado a dez neurônios de entrada possui 11 parâmetros ajustáveis. Caso seja adicionada uma camada intermediária com dez neurônios, o número de pesos se torna 121. O aumento da capacidade da rede pode ser feito pelo aumento do número de neurônios dessa camada intermediária ou pela adição de mais camadas, o que permite, por meio da crescente abstração entre as saídas intermediárias, que o mapeamento não linear entre as camadas funcione como um extrator de feições dos dados [78].

O ajuste dos pesos é o processo de aprendizagem propriamente dito e, na aprendizagem supervisionada, se dá pela repetida apresentação de pares de entradas e saídas ao algoritmo. Esse ajuste acontece pelo algoritmo de retropropagação [79]. O cálculo de uma saída \mathbf{y}_i a partir de uma entrada \mathbf{x}_i é chamado propagação direta. A retropropagação usa uma medida do erro entre a saída \mathbf{y}_i produzida pela FNN e a saída \mathbf{y}'_i correta, dada pelo rótulo da amostra, e ajusta todo o conjunto de pesos \mathbf{W} da FNN a partir da última camada em direção à primeira. Para isso, é primeiro necessário usar uma função de custo $G(\mathbf{W})$, cujo valor depende da saída produzida pela FNN e, por conseguinte, da matriz de pesos. Um exemplo de tal função é o erro médio quadrático:

$$G(\mathbf{W}) = \|\mathbf{y}'_i - \mathbf{y}_i(\mathbf{W})\|^2 \quad (2.15)$$

O ajuste mais eficiente para minimizar a função de custo é na direção do gradiente $\nabla G(\mathbf{W})$:

$$\Delta \mathbf{W} = -\eta \nabla G(\mathbf{W}) \quad (2.16)$$

O hiperparâmetro η é chamado taxa de aprendizagem e controla o tamanho do passo na direção do gradiente. O gradiente em si é encontrado por simples aplicação da regra da cadeia a todos os caminhos possíveis dentro da rede neural ligando neurônios de entrada aos neurônios de saída. Como a maior parte dos caminhos são repetidos, é possível escrever implementações bastante eficientes do algoritmo de retropropagação que reutilizam as derivadas já calculadas. A função de ativação escolhida impacta o processo de aprendizagem da rede neural, no entanto. A sigmoide apresenta gradiente próximo a zero quando o valor da função se aproxima de 0 ou 1, o que, em redes com múltiplas camadas, pode fazer com que o gradiente tenda a zero e impeça o processo de treinamento. A função ReLu, além de não apresentar esse problema, tem um custo computacional muito menor que a sigmoide, o que acelera tanto o cálculo direto quanto a retropropagação. Por essas razões, a função ReLU tem se tornado cada vez mais popular em relação à sigmoide [80].

Após iterações suficientes, esse processo encontra a matriz de parâmetros \mathbf{W} que minimiza a função de custo para todo o conjunto de dados. Além dos parâmetros que são ajustados, todo modelo de ML depende também de uma série de hiperparâmetros que governam seu aprendizado e sua arquitetura, como a já mencionada taxa de aprendizagem, mas também número de camadas e neurônios. Na maioria dos problemas, os hiperparâmetros são fixados previamente à implementação do algoritmo. Embora o desempenho de tais algoritmos seja bastante dependente dos hiperparâmetros selecionados, não existe uma heurística definitiva para estabelecer seus valores. O ajuste dos hiperparâmetros pode ser considerado um processo de meta-aprendizagem [81] e costuma ser conduzido empiricamente ou por alguma heurística de otimização externa à aprendizagem de máquina em si.

Capítulo 3

Metodologia

O estudo apresentado nesta dissertação se baseou na inversão acústica usando dados experimentais coletados pelo *Signal Processing Laboratory* (SiPLAB), da Universidade do Algarve, em um experimento denominado CALCOM'10. Este capítulo apresenta o experimento e as técnicas empregadas para a localização da fonte no conjunto de dados usado.

A Seção 3.1 descreve o experimento, sinais e condições ambientais. A Seção 3.2 descreve o processamento dos sinais coletados para produzir o conjunto de dados usado na inversão acústica. A Seção 3.3 indica como o conhecimento do ambiente nas condições do experimento foi usado para produzir um modelo ambiental base. O algoritmo usado na abordagem baseada em focalização para localização da fonte é apresentado na Seção 3.4, enquanto a abordagem por aprendizagem de máquina é apresentada na Seção 3.5.

3.1 O experimento CALCOM'10

O experimento CALCOM'10, ocorrido nas proximidades do litoral sul de Portugal, foi planejado para testar o conceito de “calibração de campo” como uma ferramenta, baseada em inversão acústica, para ajustar os parâmetros de um modelo ambiental de uma área de interesse [82]. A ideia central deste conceito é a de que resultados de uma inversão acústica podem ser usados como parâmetros para um modelo ambiental mesmo diante de escassez ou ausência de informações batimétricas ou geoacústicas. Comissões para coleta de dados acústicos, apesar das dificuldades operacionais envolvidas, ainda são mais simples e rápidas que campanhas batimétricas ou para coleta de dados geoacústicos. Tais dados acústicos podem ser usados para prever perda na transmissão ou distribuição de ruído, assim aliviando a necessidade de levantamentos hidroceanográficos na área. Como ferramenta, calibração de campo pode ser usada nos estágios iniciais de planejamento para construção de estruturas *offshore* e avaliação do seu impacto. MARTINS *et al.* [27] demonstram

essa aplicação.

O experimento consistiu de duas boias acústico-oceanográficas (AOB, *acoustic oceanographic buoys*) à deriva, cada uma carregando um VLA. Os dados usados neste trabalho foram gravados por um VLA composto por 16 hidrofones espaçados 4 m entre si, de 6,3 a 66,3 m de profundidade. Os sinais foram adquiridos com uma taxa de amostragem de 50 kHz e subsequentemente decimados para 5 kHz. Uma fonte acústica Lubell 1424 foi rebocada a uma velocidade aproximada de 4 nós ao longo de várias trajetórias enquanto emitia uma série de *chirps* e multitons na banda de 500-2000 Hz. As transmissões possuíam duração de um minuto, com 15 segundos reservados aos multitons, e foram repetidas sequencialmente ao longo de cada uma das trajetórias, denominadas de eventos. Cada AOB possuía uma unidade GPS, enquanto que a determinação da posição da fonte foi aproximada pela posição GPS da embarcação de reboque. Na fonte, foi instalado um sensor de pressão para medição da sua profundidade, que foi mantida entre 7 e 9 m durante os eventos de interesse.

Um total de 6 eventos, numerados de P1 a P6, durante os quais a fonte rebocada transmitiu repetidamente os sinais ao longo de sua trajetória, foram produzidos no segundo dia do experimento. Desses, os dados referentes aos eventos nomeados P2 e P6 foram cedidos pelo SiPLAB para uso neste trabalho. A Figura 3.1 traz uma carta batimétrica da região do experimento com as posições do VLA e da fonte em cada transmissão para os eventos P2 e P6.

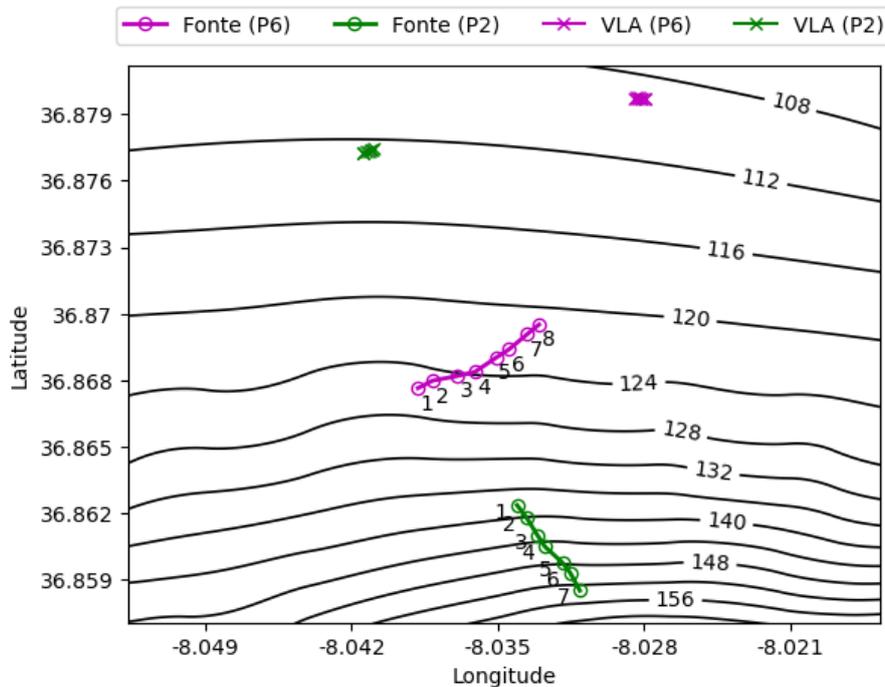


Figura 3.1: Carta batimétrica da região do experimento CALCOM'10 com posições do VLA e fonte, com as transmissões de cada evento numeradas.

Uma das limitações do experimento, e o que o torna um estudo de caso interessante para técnicas de inversão robustas como a focalização, é o reduzido conhecimento acerca dos parâmetros ambientais. Dados geoacústicos precisos do leito marinho são inexistentes, havendo somente uma limitada descrição qualitativa de que a região está localizada na cobertura sedimentar da plataforma continental, descrita como uma estreita (<10 m) camada de sedimento fino sobre uma superfície erosiva mais áspera [83].

Além disso, o SSP é calculado pela equação de Mackenzie [25], considerando salinidade de 36 ppm, a partir de valores de temperatura obtidos por sensores de baixa resolução ($0,5^{\circ}\text{C}$) instalados na posição de cada hidrofone. O que se tem, então, é um SSP incompleto e aproximado, somente na posição do receptor, o que representa uma grande incerteza no conhecimento do ambiente.

3.2 Processamento dos dados

Um total de 8 gravações do VLA, cada uma correspondente a uma transmissão do evento P6 (curta distância, baixa variação batimétrica), e 7 gravações do evento P2 (maior distância, batimetria mais variável) foram processadas neste trabalho. Dentre os sinais presentes nas gravações, foi selecionado o trecho compreendido entre 40 e 55 s, que contem o tom de 500 Hz, utilizado neste trabalho para a inversão da posição da fonte. O tom de 500 Hz é o de mais baixa frequência dentre os tons contidos nesse trecho do sinal. Sabe-se que a resposta impulsiva do guia de ondas é dependente da frequência, com sinais de alta frequência apresentando um tempo de coerência reduzido [84]. Por essa razão, o MFP tende a apresentar resultados melhores e mais estáveis a baixas frequências.

Os respectivos trechos de 15 segundos de todas as gravações foram divididos em segmentos com duração de 1 s, que foram então subdivididos em $L = 10$ *snapshots* de 0,1 s sem *overlap*. Cada *snapshot* passou por uma transformada de Fourier com 500 pontos, e os *bins* de 500 Hz de todos os hidrofones foram extraídos para formar os vetores de dados \mathbf{d}_i , usados para calcular a SCM do segmento de 1 s de acordo com a Equação 2.9. Os vetores foram normalizados para norma unitária previamente ao cálculo. Os conjuntos de 15 amostras processadas provenientes de uma mesma gravação serão referidos simplesmente por transmissões e numeradas sequencialmente referente ao respectivo evento. Por exemplo, a terceira transmissão do evento P2 é denominada P2-3.

Esse processo resultou em um total de 225 SCM, 15 respectivas a cada transmissão, cada uma tomada como uma amostra experimental a ser localizada. A posição verdadeira atribuída a cada amostra foi a posição da fonte no instante 47,5 s da respectiva transmissão, ou seja, o instante central do trecho dos multitons. Como

as posições registradas disponíveis no conjunto de dados foram marcadas no início da transmissão, para a distância foi feita uma regressão linear das posições de cada evento e a profundidade foi interpolada de duas marcações consecutivas. Existem múltiplas fontes de incerteza a respeito da posição da fonte, sendo elas: erro do GPS, erro da interpolação linear entre sucessivas posições e atraso devido à fonte estar sendo rebocada. Sendo assim, e considerando que, apesar da fonte estar se movendo, o está fazendo com baixa velocidade (aproximadamente 2 m/s relativo ao VLA), é uma concessão razoável de precisão atribuir a mesma posição verdadeira a todas as amostras respectivas a uma mesma transmissão.

3.3 Modelagem

O modelo base do ambiente do CALCOM, esquematizado na Figura 3.2, usou o SSP médio das transmissões, extrapolado linearmente abaixo do último ponto medido. As características do fundo foram obtidas em estudos preliminares feitos por DINIZ *et al.* [22], quais sejam, $c_p = 1630,91$ m/s, $\rho = 1.88$ g/cm³ e $\alpha_p = 0.79$ dB/ λ . Devido à ausência de informações detalhadas, o fundo foi modelado como uma única camada, o que, para todos os efeitos, representa um fundo equivalente [24]. Além disso, em um ajuste prévio, o arquivo de batimetria sofreu uma subtração de 10 m de profundidade.

O azimute do receptor à fonte foi tratado como conhecido e calculado a partir das posições GPS no início da transmissão. Como o ambiente é variável com a distância, o azimute impacta o transecto de batimetria usado no modelo. A Figura 3.2 ilustra os transectos médios, obtidos usando as coordenadas médias de fonte e VLA em cada evento.

Todos os campos acústicos modelados, sejam réplicas para o MFP ou conjunto de dados de treinamento para ML, foram calculados utilizando o modelo de raios TRACEO [30, 32]. Um modelo de raios foi escolhido em razão da frequência relativamente alta sendo processada, ainda que seja a mais baixa contida no sinal, pela ausência de informações suficientes para um modelo geoacústico completo com múltiplas camadas e pela eficiência e rapidez computacional com que modelos de raios são capazes de tratar ambientes variáveis com a distância.

Apesar de saber-se que o campo acústico na teoria de raios é bastante suscetível à geometria do feixe irradiado [85], os parâmetros respectivos à geometria foram mantidos constantes em 90° de abertura de feixe e 91 raios lançados. Espera-se que as formulações adaptativas do algoritmo de localização compensem as influências da geometria do feixe.

A Figura 3.3 traz o traçado de raios e o campo de pressões para o modelo base considerando o azimute do evento P2 com a fonte na posição de 3 km de

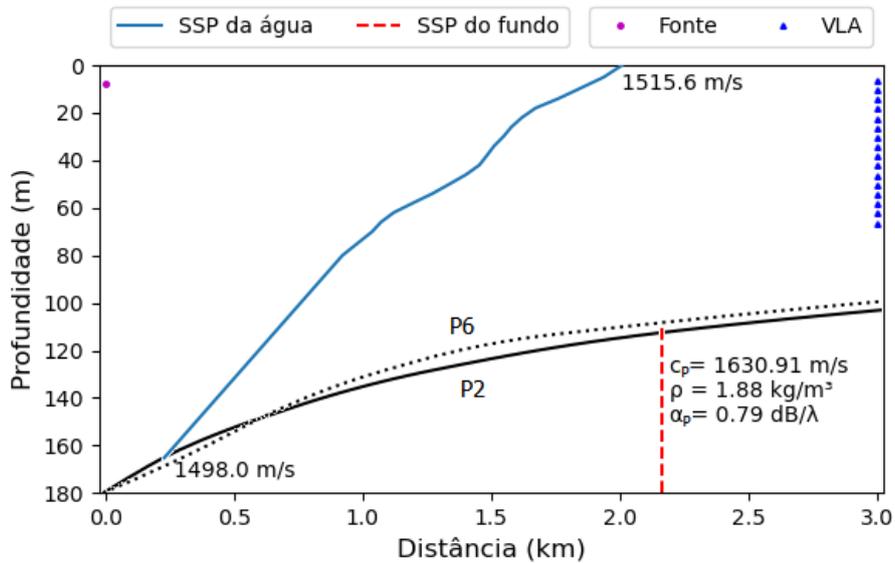


Figura 3.2: Modelo ambiental base com os transectos de batimetria considerando os azimutes médios entre VLA e fonte para os eventos P2 (linha sólida) e P6 (linha pontilhada). Posição da fonte representada na máxima distância de busca.

distância, ambos calculados pelo modelo TRACEO e visualizados com a ferramenta TRACEOTOOLS [86]. Pode-se perceber no traçado de raios a forte influência do SSP, que refrata os raios em direção ao fundo. As interações com o fundo em acríve e com a superfície ocasionam um padrão de interferência dos multicaminhos no campo acústico.

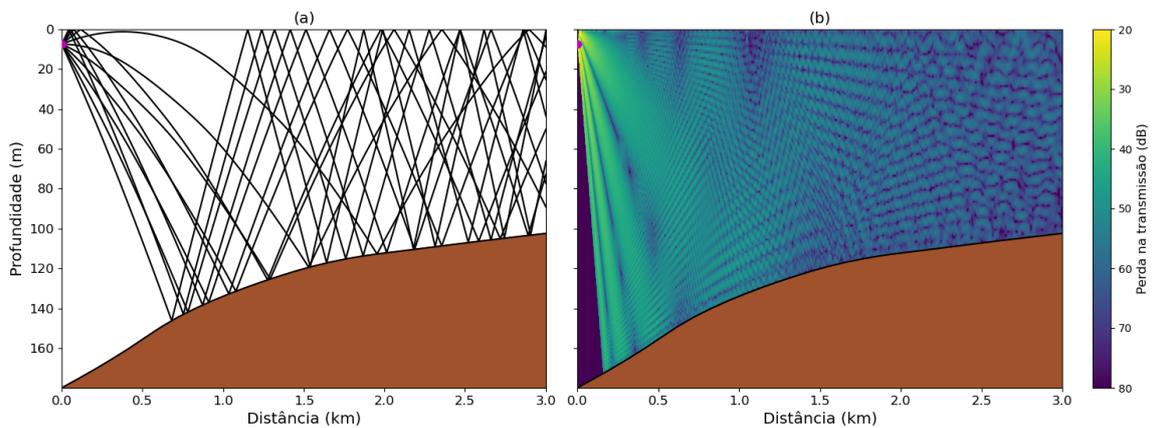


Figura 3.3: (a) Traçado de raios e (b) campo de pressões e perda na transmissão para o modelo base usando o azimute médio do evento P2. No traçado de raios, a abertura do feixe foi limitada a 20° e foram traçados somente 11 raios para permitir a visualização.

3.4 Focalização

3.4.1 Heurística

Em um estudo preliminar usando os dados do evento P6 do CALCOM'10, DINIZ *et al.* [22] aplicaram uma metodologia de focalização usando uma heurística de GA, para busca paralela, seguida por *stochastic hill climbing* (SHC), para busca local, para ajustar o modelo ambiental antes da localização da fonte por uma busca em uma grade regular de réplicas. A etapa de focalização assumiu certo conhecimento *a priori* da posição da fonte para definir os limites de busca e teve o intuito de demonstrar a possibilidade de ajuste do modelo ambiental para uma localização consistente, mesmo com grande deficiência no conhecimento do ambiente, quando incluídos parâmetros geométricos e oceanográficos (SSP) na otimização.

A metodologia neste trabalho expande a de DINIZ *et al.* [22] para dispensar a necessidade de informação *a priori* da fonte, adicionando uma busca global preliminar, baseada em GA, para estabelecer os limites de busca da focalização, que passam a ser estabelecidos a partir das PPD de distância e profundidade. Um fluxograma da metodologia consta na Figura 3.4.

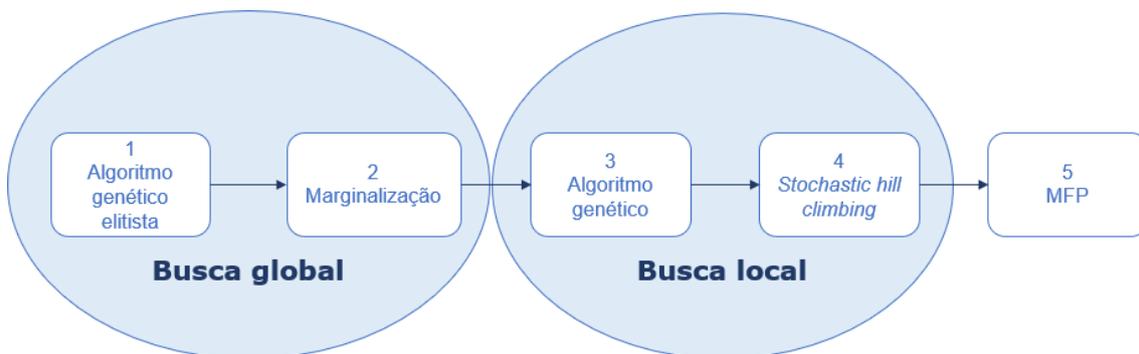


Figura 3.4: Fluxograma da heurística de inversão por focalização.

A heurística é dividida em três fases (busca global, busca local e MFP), com um total de cinco etapas, a saber:

1 - Algoritmo genético elitista

A primeira etapa consiste de uma otimização, conduzida por uma variação do GA chamada de elitista, abrangando todo o domínio de possíveis posições da fonte, aqui considerado como de 0,1 a 3 km de distância e de 0 a 100 m de profundidade. Além da posição da fonte, parâmetros do fundo também foram incluídos na busca, de forma a introduzir variações nas réplicas. Nesta etapa, é considerado o SSP médio dos dois eventos. Cada vetor θ , ou indivíduo, foi constituído por 6 parâmetros:

distância e profundidade da fonte, deslocamento da batimetria, e os três parâmetros geoacústicos (velocidade do som, densidade e atenuação do fundo).

O algoritmo genético elitista consiste em preservar sempre, entre uma geração e outra, alguns dos melhores indivíduos da geração anterior [48], garantindo que a qualidade da solução não decairá devido a efeitos estocásticos. Aqui, foram preservados os $n_{pop}/2$ melhores indivíduos, selecionados pelo processador Bartlett, enquanto que a outra metade da geração seguinte foi produzida por aplicação dos operadores *crossover* e mutação sobre eles. Isso resulta em uma evolução mais lenta, o que dificulta a convergência para um máximo global, mas o intuito dessa etapa ainda não é encontrar o melhor modelo ambiental. Em vez disso, ao fim da evolução os $n_{pop}/2$ melhores vetores foram armazenados e o processo foi repetido n_{run} vezes, produzindo um total de $n_{vec} = 0,5 \times n_{pop} \times n_{run}$ vetores.

A busca global foi repetida para cada uma das transmissões, usando o casamento pelo processador Bartlett com uma das 15 SCM como função objetivo.

2 - Marginalização

Após a otimização por GA ser concluída, um pós-processamento é feito para calcular a distribuição de probabilidade *a posteriori* dos parâmetros associados aos vetores armazenados de cada transmissão. Para isso, foi usada uma distribuição de Boltzmann [17] para calcular a probabilidade p de um vetor θ possuir o parâmetro θ com dado valor θ' no espaço de busca:

$$p(\theta_i = \theta') = \frac{\sum_{j=1}^{n_{vec}} \exp\left[-\frac{1-B(\theta^j)}{T}\right] \delta(\theta_i^j = \theta')}{\sum_{j=1}^{n_{vec}} \exp\left[-\frac{1-B(\theta^j)}{T}\right]} \quad (3.1)$$

onde $1 - B(\theta^j)$ é a energia, dada pelo complemento do Bartlett, do j -ésimo vetor de parâmetros e T é um parâmetro de controle denominado temperatura. A distribuição de Boltzmann favorece os estados de menor energia, atribuindo maior peso a eles na distribuição de probabilidade. O valor usado para a temperatura foi a média da energia dos 50 melhores vetores em cada população, um valor razoável para privilegiar os melhores casamentos de campo [17]. A expressão no somatório do numerador só possuirá valor diferente de zero quando $\theta_i^j = \theta'$, graças ao delta de Kronecker δ .

É possível, após o cálculo das probabilidades, traçar as distribuições de probabilidades marginais dos parâmetros de interesse e usar as estatísticas da distribuição para definir os limites de focalização. A desvantagem, no entanto, de usar as PPD marginais, é que o acoplamento entre os parâmetros não é capturado, o que seria um aspecto negativo caso se estivesse buscando o melhor ajuste do modelo. Nesse caso, o vetor com maior Bartlett seria o melhor candidato, mas neste trabalho a função

desta etapa é somente definir os limites para a etapa seguinte.

Além disso, estatísticas sobre as PPD dos parâmetros do fundo são usadas para estabelecer um fundo invariante nas etapas seguintes.

3 - Algoritmo genético

A busca local tem como função encontrar o melhor modelo ambiental para uma dada transmissão. A primeira etapa da busca local consiste na busca paralela dentro dos limites de focalização usando um GA não elitista. Nessa versão do GA, toda a população é substituída entre gerações. Nesta etapa, as populações do GA são produzidas dentro dos limites de profundidade e distância estabelecidos pelas PPD e o resultado final é um único vetor dos parâmetros que alcançaram o melhor casamento de campo, que é então passado ao SHC.

Além dos limites mais estreitos na posição da fonte e da remoção dos parâmetros do fundo, essa etapa ainda contou com a inclusão de outros parâmetros de geometria e, também, os coeficientes de três funções ortogonais empíricas (EOF, *empirical orthogonal functions*) [87] para construção de um SSP. Análise por EOF é útil quando da existência de dados oceanográficos históricos, levando a uma convergência mais rápida para uma solução [88]. Aqui, é usada para superar a falta de dados históricos e medições *in situ*, sendo utilizada para melhor ajustar o modelo ao campo medido, o que é o conceito fundamental da focalização.

As 15 medições disponíveis do SSP foram usadas na decomposição em EOF e, devido à baixa diversidade dos perfis, somente as três primeiras EOF são capazes de explicar 99% da variância das medições. O SSP usado no modelo é, então, reconstruído por:

$$c(z) = \bar{c}(z) + \sum_{i=1}^3 a_i v_i(z) \quad (3.2)$$

onde \bar{c} é o SSP médio e v_i é cada uma das EOF usadas. Os três coeficientes a_i foram incluídos no espaço de busca do GA. A Figura 3.5 ilustra a decomposição em EOF dos perfis medidos. Os perfis foram extrapolados linearmente abaixo do último ponto.

4 - *Stochastic hill climbing*

O algoritmo SHC de primeira escolha empregado é um algoritmo ganancioso de busca local que gera repetidamente variações do vetor de parâmetros atual e calcula o Bartlett para cada uma delas, aceitando um vetor novo como solução assim que encontrado um com Bartlett maior [89].

Em certo sentido, GA e SCH são complementares em suas funções. Enquanto

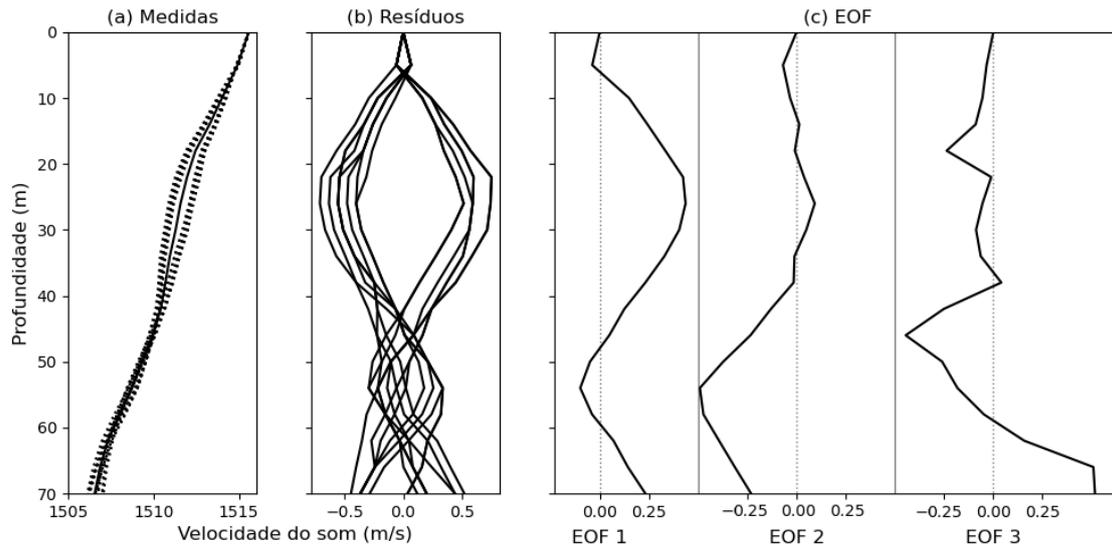


Figura 3.5: Análise de EOF dos SSP. (a) Medições de temperatura convertidas para velocidade do som. (b) Resíduos das medições. (c) Três primeiras EOF.

o primeiro tem o poder de exploração paralela do espaço de busca, com troca de informações entre os vetores, seu progresso tende a desacelerar conforme converge. O SHC, como um algoritmo de busca ganancioso, rapidamente encontra novas soluções, mas tende a ficar preso em máximos locais, particularmente em problemas no qual a topologia do espaço de busca não é convexa ou é complexa demais, como é o caso da inversão acústica. Iniciar o SHC a partir do vetor resultante do GA, já próximo de uma solução, evita esse problema. Dessa forma, o GA foi usado para explorar todo o espaço de busca, encontrando regiões favoráveis para uma solução, e o SHC, com passos pequenos, para rapidamente alcançar o máximo da região para a qual o GA convergiu.

5 - MFP (busca em grade)

Após as quatro primeiras etapas, o que se tem é uma posição candidata para a fonte em dada transmissão e um vetor de parâmetros que ajustam o modelo para dar o melhor casamento de campo. Realizar a busca em grade tradicional do MFP, a essa altura, é supérfluo. Na verdade, espera-se que o resultado do MFP degrade em relação àquele obtido ao fim das quatro etapas anteriores, em razão da perda de precisão devido à discretização da grade e à possibilidade de aparecimento de lóbulos secundários proeminentes fora dos limites da focalização.

Ainda assim, o MFP regular foi conduzido pelas seguintes razões: 1 - testar o modelo ajustado nas demais amostras, pois a focalização usou somente uma das quinze amostras de cada transmissão; 2 - produzir as superfícies de ambiguidade; e 3 - comparar os resultados com o MFP usando o modelo base não ajustado e com

aqueles obtidos nos estudos preliminares feitos por DINIZ *et al.* [22].

3.4.2 Métricas

As métricas usadas para avaliar o sucesso da localização em distância e em profundidade são distintas. Em distância (r), o espaço de busca é teoricamente ilimitado e, em razão da perda de coerência esperada na propagação acústica devido ao espalhamento aleatório causado por faltas de homogeneidade no meio [90], a localização em distância tende a se tornar mais difícil quanto maior a distância da fonte. Por esse motivo, a métrica usada para avaliar o sucesso da localização em distância foi o erro médio absoluto percentual (MAPE, *mean absolute percentage error*), que é uma medida relativa:

$$MAPE = \frac{100\%}{N} \times \sum_{i=1}^N \frac{|r_i - r'_i|}{r'_i} \quad (3.3)$$

Para a localização em profundidade (z), além do espaço de buscar ser limitado pela superfície e pelo fundo, não há relação direta entre o aumento da profundidade da fonte e a dificuldade em localizá-la. Por essa razão, para a profundidade a métrica usada é o erro médio absoluto (MAE, *mean absolute error*):

$$MAE = \frac{1}{N} \times \sum_{i=1}^N |z_i - z'_i| \quad (3.4)$$

Ambos fazem a média das N amostras consideradas e são reportadas a cada fase da heurística: busca global (15 amostras), busca local (15 amostras) e MFP (225 amostras). Quando se tratar de erro simples e não média absoluta, o erro é denotado por ε .

A taxa de acerto também é considerada. Um acerto é definido como a fonte ser encontrada com erro em distância menor que 10% e erro em profundidade menor que 2,5 m.

3.4.3 Parâmetros

Devido à natureza periódica dos lóbulos secundários do processador linear [12], que são todas regiões de alta correlação da posição da fonte, espera-se que as PPD das coordenadas da posição da fonte resultantes da otimização global tendam a ser multimodais, pois as populações irão convergir para essas regiões de alta correlação. A resolução do processador em profundidade é maior que em distância [40, 91], o que produz lóbulos de largura menor e deve levar a modas mais bem definidas, enquanto que a distribuição em distância deve apresentar maior variância. Combinando esse fato com o pequeno intervalo de busca em distância (0,1 a 3 km), espera-se que as

PPD em distância se manifestem como distribuições mais próximas de unimodais, o que foi verificado durante testes preliminares.

Essas características das distribuições informaram os critérios para definição dos limites de focalização a partir das PPD. Para distância, tanto a média (μ) quanto a mediana (ν) da PPD foram exploradas, com os limites de focalização ficando em função do desvio padrão (σ), sendo $\pm 0,5\sigma_{PPD}$. Para profundidade, com a distribuição multimodal com picos estreitos, foi usado o valor máximo da PPD com um intervalo absoluto de $\pm 2,5$ m. Esses intervalos são arbitrários e foram escolhidos após análise preliminar de algumas PPD a fim de limitarem a busca local à região particular de maior probabilidade dos respectivos parâmetros. Sendo assim, o ambiente para cada transmissão é ajustado individualmente baseado na PPD dos parâmetros, sem conhecimento prévio da posição da fonte.

Os parâmetros do fundo tiveram um tratamento diferenciado. Foi calculada a PPD usando os conjuntos de vetores de todas as transmissões e, para as etapas seguintes, os parâmetros foram mantidos constantes com o valor médio das PPD. A média da PPD de deslocamento do fundo foi usada como valor central numa busca mais estreita.

A Tabela 3.1 traz todos os hiperparâmetros que governaram os algoritmos de busca, bem como os parâmetros buscados e seus limites em cada etapa. Os símbolos μ , ν , σ e max referem-se às estatísticas das respectivas PPD. A escolha dos intervalos de busca assumiu baixo conhecimento *a priori* também do ambiente e, portanto, são mais amplos do que seriam caso se tivesse um conhecimento mais detalhado sobre condições ambientais como amplitude de maré e de ondas de superfície ou mais dados espaciais e temporais de SSP.

3.5 Aprendizagem de máquina

3.5.1 Hipótese

Em razão das dificuldades mencionadas na Seção 2.5 no tocante a localização em múltiplas coordenadas usando aprendizagem de máquina, além da limitação da diversidade de profundidades da fonte nos dados do CALCOM que não permitiria uma análise compreensiva da localização em profundidade, a parte deste trabalho dedicada a ML preocupou-se somente com localização em distância.

Além disso, em razão tanto da pouca quantidade de dados experimentais quanto da baixa diversidade entre eles, o que limitaria a capacidade de treinamento de um algoritmo de ML e severamente enviesaria os resultados, foi feita uma abordagem baseada em modelagem como ferramenta de aumento de dados.

Essa abordagem parte da hipótese de que se: 1 - os modelos de propagação acús-

Tabela 3.1: Parâmetros e hiperparâmetros dos algoritmos de otimização.

Hiperparâmetro	Busca global		Busca local	
População	100		150	
Gerações	20		20	
Elitista	Sim		Não	
Número de bits	6		10	
Taxa de crossover	0,9		0,9	
Taxa de mutação	0,09		0,05	
Número de populações	50		1	
Iterações do SHC	0		1000	
Passo máximo do SHC	-		2% do espaço de busca	
Parâmetro	Min	Max	Min	Max
Distância (m)	100	3000	$\mu - 0,5\sigma$ $\nu - 0,5\sigma$	$\mu + 0,5\sigma$ $\nu + 0,5\sigma$
Profundidade (m)	1	101	max -2,5	max +2,5
Azimute	-	-	-1°	+1°
Inclinação do VLA (rad)	-	-	-0,026	0,026
Deslocamento vertical do VLA (m)	-	-	-2	2
Deslocamento na batimetria (m)	-10	10	$\mu - 5$	$\mu + 5$
Velocidade do som no fundo (m/s)	1500	1650	-	-
Densidade do fundo (g/cm ³)	1,2	1,9	-	-
Atenuação no fundo (dB/λ)	0,2	1,0	-	-
Coefficiente EOF 1	-	-	-3	3
Coefficiente EOF 2	-	-	-3	3
Coefficiente EOF 3	-	-	-3	3

tica, como a teoria de raios aqui empregada, são aproximações precisas o suficiente do fenômeno físico de propagação acústica submarina em um guia de ondas; e 2 - um algoritmo de ML é capaz de aprender as características desse fenômeno, então dados artificiais gerados por um modelo de propagação ajustado ao ambiente devem ser suficientes para o treinamento de um algoritmo capaz de fazer inversões precisas de dados reais.

A primeira condicional é corroborada pelo sucesso que os modelos de propagação acústica têm obtido como ferramentas preditivas na acústica submarina e na solução de problemas inversos, suportada pela vasta literatura sobre MFP, e é discutida mais a fundo na Seção 4.1.

O objetivo do componente de ML deste trabalho é verificar a validade da segunda condicional e testar a hipótese no conjunto de dados do CALCOM, comparando os resultados com as técnicas clássicas de inversão baseadas em modelos.

Para verificar se o algoritmo de ML está produzindo resultados análogos ao MFP, o que indicaria que ele está explorando as mesmas características do campo de pressão acústica que o MFP utiliza, foram conduzidos testes de desajuste. A seguir, foi feita uma análise do modo como a construção do conjunto de dados

sintéticos impacta o desempenho do algoritmo no conjunto de dados do CALCOM e, por fim, foi feita a inversão pelo MFP para comparação dos resultados.

3.5.2 Arquitetura da rede neural

Os modelos de ML foram construídos, treinados e avaliados usando a interface de programação Keras da plataforma TensorFlow [92]. Um perceptron multicamadas com camadas completamente conectadas foi usada, mas com alto grau de *dropout* [93] aplicado nas primeiras camadas como forma de regularização.

A entrada da rede neural é a SCM vetorizada. Como os neurônios podem receber somente valores reais, as partes real e imaginária de cada elemento da matriz foram separadas e, uma vez que a SCM é hermitiana, apenas a diagonal principal e matriz triangular superior precisaram ser fornecidas, pois a matriz triangular inferior contém informação redundante. Para uma única frequência e 16 hidrofones, isso corresponde a uma camada de entrada com 272 neurônios. O problema foi abordado por uma metodologia de regressão, o que quer dizer que a camada de saída possui um único neurônio com valor contínuo que fornece a estimativa da rede neural.

Os hiperparâmetros da rede foram previamente selecionados de maneira empírica após teste preliminar usando somente dados sintéticos tanto no treinamento quanto no teste (para evitar transferência de informação dos dados do CALCOM nesse processo de ajuste) por meio de avaliação das curvas de aprendizagem para verificar se não estava ocorrendo *underfitting* ou *overfitting*. A seguinte estrutura para a rede neural foi escolhida por esse processo empírico e mantida constante ao longo de todos os testes neste estudo, de maneira que, com exceção da inicialização aleatória dos pesos da FNN, as únicas variáveis entre os modelos de ML treinados foram os conjuntos de dados de treinamento:

- 6 camadas (entrada, 4 escondidas, saída);
- n° de neurônios: 272 / 256 / 1024 / 512 / 256 / 1;
- *dropout*: 0,2 / 0,4 / 0,4 / 0 / 0;
- função de ativação ReLU (Equação 2.14) em todas as camadas;
- função de custo: erro médio quadrático;
- otimizador Adam [94] com taxa de aprendizagem 0,005; e
- treinamento em *mini-batch* com tamanho de lote de 25 amostras ao longo de 200 épocas (iterações).

3.5.3 Avaliação dos modelos de aprendizagem de máquina

A métrica usada para comparação dos resultados foi o MAPE (Equação 3.3), pelas razões delineadas na Seção 3.4.2.

A avaliação dos modelos foi feita pelo método de reamostragem de validação cruzada *k-fold* [95] com $k = 10$. Devido à natureza estocástica da aprendizagem de máquina, é esperado que uma rede neural treinada múltiplas vezes no mesmo conjunto de dados resulte em modelos distintos que apresentam desempenhos diferentes. A validação cruzada permite a coleta de estatísticas a respeito do desempenho geral dos modelos treinados em pequenas variações do conjunto de treinamento. O método consiste em dividir o conjunto de treinamento em k partes iguais, reservar uma delas para teste e treinar o modelo com as $k - 1$ partes restantes. O modelo treinado é testado, tem seu resultado (MAPE) registrado e então pode ser descartado. O processo é repetido até que todas as k partes tenham sido usadas para teste uma vez, ou seja, são produzidos k modelos nesse processo. A estimativa de desempenho final dos modelos é a média de todos os MAPE. Essa metodologia traz a vantagem de dar uma estimativa mais precisa do desempenho esperado do modelo treinado em um dado conjunto de dados e dispensa a necessidade de um subconjunto de validação.

Além do teste na parte do conjunto designada para tal, o modelo treinado, a cada iteração, foi testado também nas 225 amostras experimentais do CALCOM. O conjunto do CALCOM, portanto, serviu como um conjunto de retenção, que em momento algum teve influência sobre o treinamento da FNN. Ambos os resultados (parte sintética, dados experimentais) estão reportados.

3.5.4 Criação dos conjuntos de dados e réplicas

Um total de 6 conjuntos de dados sintéticos foram gerados, cada um consistindo de 10000 campos acústicos distintos amostrados na posição do VLA. Cada amostra foi gerada usando diferentes parâmetros na configuração do modelo ambiental, empregando um sorteio com distribuição uniforme de probabilidade para os valores dos parâmetros que foram permitidos variar. Os conjuntos de dados, numerados de 1 a 6, tiveram cada vez menos parâmetros fixos em relação ao conjunto anterior, significando um aumento no grau de variabilidade entre conjuntos de dados.

Todos os conjuntos de dados sintéticos, incluindo réplicas para o MFP, foram gerados pelo modelo TRACEO em um ambiente modelado segundo as características conhecidas do ambiente do CALCOM e com os conhecimentos preliminares obtidos em DINIZ *et al.* [22]. As propriedades do fundo são aquelas encontradas nessa referência, mencionadas na Seção 3.4, e todo o arquivo de batimetria teve uma redução de 10 m na profundidade. A não ser quando mencionado, o SSP usado é a média das medições, extrapolado linearmente para as profundidades abaixo do

último sensor.

Em todos os conjuntos de dados, a fonte foi posicionada entre 0,1 e 3 km de distância do VLA, que, por sua vez, teve sua posição fixada na média entre as coordenadas da AOB nos eventos P2 e P6. A profundidade da fonte foi sorteada entre 7 e 9 m para reduzir a chance de amostras idênticas nos conjuntos de dados de menor variabilidade, mas ainda assim permanecer razoavelmente estável, uma vez que somente localização em distância está sendo considerada. Não foi adicionado ruído às amostras sintéticas.

As características dos conjuntos de dados são descritas a seguir e o posicionamento da fonte e VLA podem ser vistos graficamente mais adiante na Figura 3.7. Os azimutes mencionados são medidos no sentido horário a partir do norte.

1: menor variabilidade. Todas as amostras foram geradas ao longo da linha de 180° de azimute em relação ao VLA. A profundidade batimétrica varia com a posição da fonte, uma vez que o ambiente é variável com a distância, mas como somente um transecto de batimetria está sendo considerado esses dois parâmetros são correlatos, de modo que a distância da fonte é o único parâmetro que varia significativamente

2: a região em que a fonte podia ser posicionada foi expandida para um cone contido entre as linhas de 130° e 230° de azimute a partir do VLA. Devido à natureza variável da batimetria da região, amostras próximas das bordas do cone representam uma variação muito mais suave de batimetria que aquelas próximas ao centro.

3: como o conjunto 2, mas no lugar do SSP médio foi usado um SSP reconstruído com 3 EOF, com coeficientes variando entre ± 2 (EOF 1), ± 1 (EOF 2) e ± 0.5 (EOF 3).

4: como o conjunto 2, mas com um deslocamento vertical aplicado à batimetria, na faixa de ± 5 m, alterando a profundidade em todos os pontos do transecto. Este conjunto não segue diretamente do 3, então ainda usa o SSP médio.

5: combina as características do conjunto 3 (SSP reconstruído por EOF) e 4 (deslocamento da batimetria).

6: em adição às características do conjunto 5, inclui inclinação (± 0.026 rad) e deslocamento vertical (± 2 m) do VLA.

A Figura 3.6 mostra um esquema de como esses conjuntos de dados evoluem.

Adicionalmente, dois conjuntos de réplicas para localização por MFP foram criados, um para cada evento do CALCOM. Cada conjunto de réplicas usou as características do modelo base, havendo diferença somente na posição do VLA (respectiva à coordenada do AOB no dado evento) e no transecto de batimetria (que foi baseado no azimute médio da fonte em relação ao VLA no dado evento).

A Figura 3.7 mostra a posição do VLA, trajetórias dos eventos do CALCOM

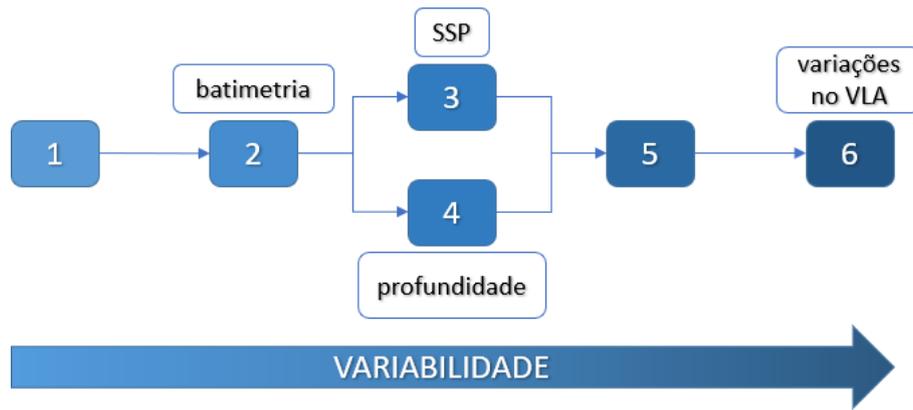


Figura 3.6: Esquema do aumento de variabilidade entre os conjuntos de dados.

e regiões onde a fonte foi posicionada para cada situação, incluindo os testes de desajuste, que são descritos na Seção 3.5.5. O modelo ambiental base usado no MFP é aquele mostrado na Figura 3.2.

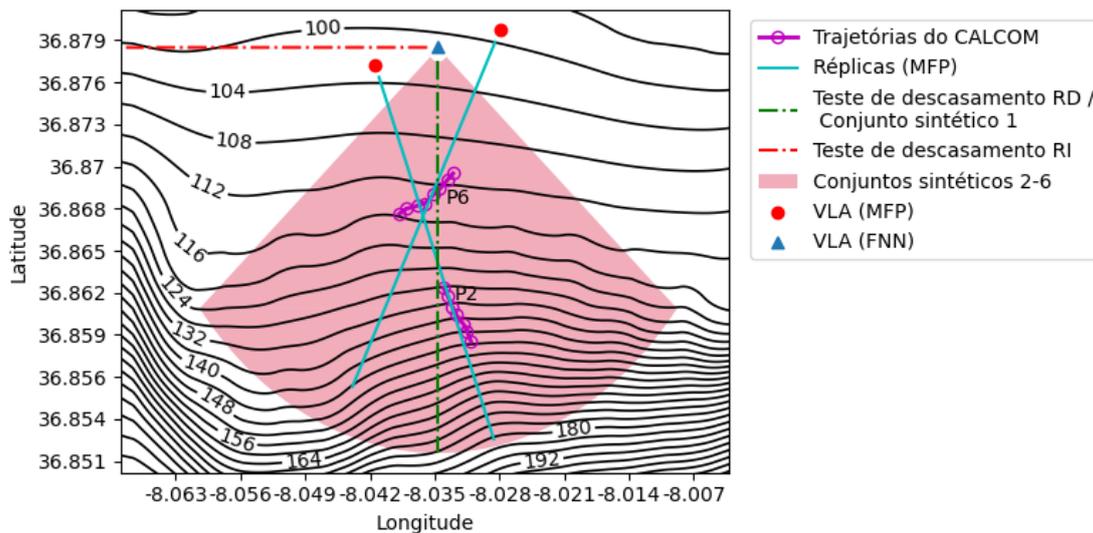


Figura 3.7: Carta batimétrica mostrando as regiões para posicionamento da fonte e VLA nos dados sintéticos.

3.5.5 Descrição do método

Testes de desajuste

A principal premissa do uso de ML para inversão é que o algoritmo é capaz de extrair informação sobre a física de um dado fenômeno diretamente a partir de um sinal medido, que necessariamente contém informação a respeito da função de transferência do fenômeno - a propagação em um guia de ondas, no presente caso. A SCM de um campo acústico bem amostrado contém informação espacial suficiente para descrevê-lo. Com efeito, o MFP explora essa informação para localização de

fontes. Portanto, um algoritmo de ML que receba SCM como entrada deveria ser capaz de aprender as características da propagação acústica submarina que o MFP utiliza.

Os testes de desajuste foram designados para testar essa hipótese ao comparar os resultados do MFP e da FNN quando ambos os métodos são expostos ao mesmo tipo de desajuste do modelo.

Para isso, duas situações foram consideradas, baseadas no modelo ambiental base: uma situação onde a batimetria varia com a distância (RD) e uma onde não varia (RI). Para os testes RD, um conjunto sintético com 10000 foi gerado no mesmo molde do conjunto de dados 1, ao longo do azimute 180° , e a FNN foi treinada com ele. Um conjunto de réplicas com espaçamento de 1 m em distância e profundidade fixa de 7,5 m também foi gerado entre as distâncias de 0,1 e 3 km. Para os testes RI, o mesmo procedimento foi seguido, mas com o transecto do azimute 270° , que possui batimetria aproximadamente plana ao longo de uma isóbata, como se pode ver na Figura 3.7.

De posse dos dois conjuntos de réplicas para o MFP e as duas FNN treinadas, um para cada ambiente, um grupo de conjuntos de teste foi produzido. Cada um desses conjuntos teve um único aspecto do modelo ambiental modificado, de maneira a introduzir um desajuste intencional, e contou com 1000 amostras geradas com distância da fonte aleatoriamente selecionadas. Os desajustes testados consistiram de:

- inclinação: os transectos de batimetria dos dois ambientes (RD e RI) foram trocados;
- profundidade: adição de 10 m à batimetria;
- SSP: no lugar do SSP médio, usou um perfil isovelocidade que eliminou a refração em direção ao fundo; e
- sedimento: propriedades do fundo foram substituídas pelas de argila ($c_p = 1500$ m/s, $\rho = 1.5$ g/cm³ e $\alpha_p = 0.2$ dB/ λ) [8], mais absorvente que o fundo do modelo base.

Adicionalmente a esses, um conjunto neutro, isto é, sem desajuste, com amostras novas foi também criado. Esses conjuntos foram passados às FNN treinadas e comparados aos conjuntos de réplicas e os resultados comparados.

Para cada teste, além do MAPE para a FNN e o MFP, o coeficiente de correlação de Pearson [96], aqui denotado por q , foi usado para avaliar a correlação entre as estimativas dos dois métodos.

$$q = \frac{\sum_{i=1}^N (r_{i_{FNN}} - \bar{r}_{FNN})(r_{i_{MFP}} - \bar{r}_{MFP})}{\sqrt{\sum_{i=1}^N (r_{i_{FNN}} - \bar{r}_{FNN})^2 \sum (r_{i_{MFP}} - \bar{r}_{MFP})^2}} \quad (3.5)$$

Cada estimativa de distância para uma amostra i para dado método é representado por r_i , enquanto que \bar{r} representa a média de todas as estimativas. O coeficiente é normalizado entre -1 e 1 e mede a correlação linear entre dois conjuntos de dados, com valores próximos de 1 indicando forte correlação, valores próximos de -1 indicando forte correlação inversa e nenhuma correlação para $q = 0$.

Análise da variabilidade

Variância, como uma medida da variabilidade contida em um conjunto de dados, é difícil de ser medida diretamente nesse contexto, mas pode ser inferida por meio da análise de componentes principais (PCA, *principal component analysis*), a qual consiste em aplicar uma transformação linear no conjunto de dados para um novo conjunto de coordenadas (os componentes principais) de forma que elas sejam descorrelacionadas e apenas uma pequena quantidade delas seja capaz de reter a maior parte da variância do conjunto de dados original [97]. Nesse sentido, os componentes principais funcionam de maneira semelhante às EOF. Se o conjunto de dados \mathbf{X} , expresso em forma matricial, é composto de N vetores coluna com 272 pontos, será transformado em uma matriz também $272 \times N$, mas com as linhas organizadas em ordem decrescente de variância. A j -ésima linha dessa matriz, ou seja, o j -ésimo componente principal, pode ser computada por

$$\mathbf{s}_j = \mathbf{v}_j^T \mathbf{X} \quad (3.6)$$

onde \mathbf{v}_j é o autovetor normalizado, com o j -ésimo maior autovalor associado, da matriz de covariância do conjunto de dados \mathbf{X} . Essa matriz de covariância é calculada da mesma maneira que na Equação 2.9, onde cada vetor \mathbf{x} é uma das amostras do conjunto de dados:

$$\mathbf{C} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^T \quad (3.7)$$

A variância contida no conjunto de dados que é explicada por um componente principal é dada pelo seu autovalor associado.

A PCA por si própria é útil na aprendizagem de máquina para reduzir a dimensionalidade de conjuntos de dados, usando somente aqueles componentes que contêm a maior parte da variância e descartando informação desnecessária, reduzir a complexidade dos modelos e melhorar a acurácia dos algoritmos [98], mas, neste trabalho, de maneira a manter a entrada da FNN comparável à do MFP (isto é, a

SCM para ambos), ela é usada somente para visualizar a variabilidade dos conjuntos de dados.

Os seis conjuntos descritos na Seção 3.5.4 foram usados, individualmente, para treinar múltiplas FNN. Duas análises foram conduzidas. A primeira compara as curvas de aprendizagem de uma única FNN treinada em cada conjunto de dados, usando o paradigma tradicional de divisão do conjunto de dados em treinamento e validação, com um subconjunto de 1000 amostras separadas para validação.

Após isso, todos os conjuntos de dados passaram por um processo de validação cruzada em 10 partes. A cada iteração, o modelo treinado foi testado na parte sintética da divisão do conjunto de dados e também no conjunto do CALCOM. Métricas estão reportadas para cada caso e também para os modelos que obtiveram melhor desempenho nos dados do CALCOM.

Comparação com o MFP

Por fim, a localização da fonte também foi realizada por MFP, com uma metodologia simplificada (unidimensional) em relação à da Seção 3.4, para ser comparável à localização por redes neurais. Para tanto, foram usados os conjuntos de réplicas descritos na Seção 3.5.4.

Capítulo 4

Resultados e Discussão

Foram usadas duas abordagens distintas na localização da fonte no conjunto de dados experimentais e, portanto, seus resultados estão reportados separadamente. A Seção 4.1 lida com os resultados obtidos pela focalização, discriminados pelas diferentes fases da heurística empregada. A Seção 4.2 traz os resultados dos testes de desajuste e da localização da fonte nos dados experimentais pela rede neural.

4.1 Focalização

Os resultados da focalização são apresentados e discutidos a seguir para cada fase da heurística estabelecidas na Seção 3.4.1.

4.1.1 Busca global

Conforme mencionado anteriormente, o estabelecimento dos limites de busca da focalização de cada transmissão foram definidos a partir das respectivas PPD de distância e profundidade, as quais são exibidas graficamente no Apêndice A. As estatísticas extraídas de cada uma delas estão compiladas na Tabela 4.1 juntamente com os erros de estimação associados.

Em se tratando das PPD de profundidade, o comportamento multimodal se manteve para todas as transmissões. Em quase todas, exceto a P2-5 e a P6-4 (Figuras A.5 e A.11), o máximo da PPD se manifestou na moda mais próxima da posição de referência. Para a transmissão P6-5 (Figura A.12), o pico mais próximo se apresentou deslocado em relação à posição de referência. Nas demais, o máximo da PPD foi representativo da profundidade correta.

As PPD de distância apresentaram comportamento muito menos decisivo, em parte porque 5 das 15 transmissões não resultaram em uma PPD perfeitamente unimodal (Figuras A.7, A.12-A.15), mas apresentaram regiões estreitas de alta probabilidade, em alguns casos com valor de pico superando aquele da região correta.

O comportamento multimodal dessas PPD causa um aumento do desvio padrão, o que afeta a busca local subsequente, e faz com que média e mediana deixem de ser bons descritivos da distribuição.

Apesar disso, percebe-se que a mediana se manteve mais estável e, exceto por uma única transmissão, dentro da margem de erro definida na Seção 3.4.2, ao contrário da média, que foi mais suscetível às variações da distribuição.

Tabela 4.1: Estatísticas extraídas das PPD de posição da fonte após a busca global com os erros associados em relação à posição de referência (r' e z').

Transmissão	Distância						Profundidade		
	r' (m)	μ_{PPD} (m)	$\varepsilon_{r,\mu_{PPD}}$ (%)	ν_{PPD} (m)	$\varepsilon_{r,\nu_{PPD}}$ (%)	σ_{PPD} (m)	z'	\max_{PPD} (m)	$\varepsilon_{z,\max_{PPD}}$ (m)
P2-1	1845,87	1917,02	3,85	1957,81	6,06	341,89	8,19	10,38	2,19
P2-2	1924,41	2114,04	9,85	2139,06	11,15	159,54	8,38	10,38	1,99
P2-3	2002,94	2104,13	5,05	2184,38	9,06	294,6	7,93	8,81	0,88
P2-4	2081,48	2098,56	0,82	2184,38	4,94	352,32	8,25	8,81	0,56
P2-5	2160,01	2162,45	0,11	2184,38	1,13	294,1	8,9	29,12	20,23
P2-6	2238,54	2092,73	-6,51	2320,31	3,65	690,79	8,1	8,81	0,71
P2-7	2317,08	2393,05	3,28	2546,88	9,92	644,17	7,94	5,69	-2,25
P6-1	1582,65	1542,74	-2,52	1640,62	3,66	331,4	7,18	7,25	0,07
P6-2	1536,48	1600,74	4,18	1640,62	6,78	212,03	6,97	8,81	1,84
P6-3	1464,51	1499,5	2,39	1550,0	5,84	193,13	7,1	7,25	0,15
P6-4	1399,35	1353,36	-3,29	1368,75	-2,19	443,43	7,06	11,94	4,88
P6-5	1305,64	1105,74	-15,31	1323,44	1,36	658,45	6,98	11,94	4,96
P6-6	1244,31	1128,3	-9,32	1323,44	6,36	559,53	6,94	8,81	1,87
P6-7	1154,61	779,47	-32,49	1142,19	-1,08	516,59	7,07	8,81	1,75
P6-8	1095,61	886,48	-19,09	1142,19	4,25	465,99	7,07	7,25	0,18
Média absoluta	-	-	7,87	-	4,18	-	-	-	2,97

Em geral, além de servir para delimitar a busca local, a busca global por si própria já forneceu uma boa estimativa de localização. Esse resultado, ou possivelmente um ainda melhor, pode ser alcançado com muito menos esforço computacional do que foi aplicado, pois uma análise da convergência das estatísticas das PPD ao longo das gerações do GA indica que, em média, a média das PPD de distância convergiu para o erro mínimo em 18 gerações, a mediana em 8 e o máximo das PPD de profundidade em 9 gerações. Note que o erro mínimo em questão não é necessariamente igual ao erro reportado na Tabela 4.1, pois o erro pode ter aumentado após mais gerações serem contabilizadas. Sem assumir informação *a priori*, é impossível saber quando o erro mínimo foi alcançado, no entanto.

Espera-se que, com o aumento do espaço de busca em distância, a localização usando esse método se torne mais difícil e média, mediana e desvio padrão se tornem métricas cada vez menos confiáveis, com o aparecimento de outras regiões de alta probabilidade. Isso já foi percebido nas PPD que apresentaram comportamento multimodal. Um processamento mais robusto, que leve em conta não a distribuição como um todo, mas a área sob a curva das regiões de alta probabilidade deve ser desenvolvido para lidar com esses casos.

A Figura A.16 traz as PPD para os parâmetros do fundo. Ao contrário da posição da fonte, nenhum deles apresentou um pico claramente discernível, resultando em distribuições praticamente uniformes. Da Figura 4.1, percebe-se que os únicos parâmetros com alto grau de correlação são profundidade e distância, em razão da profundidade média da fonte ser ligeiramente maior durante o evento P2.

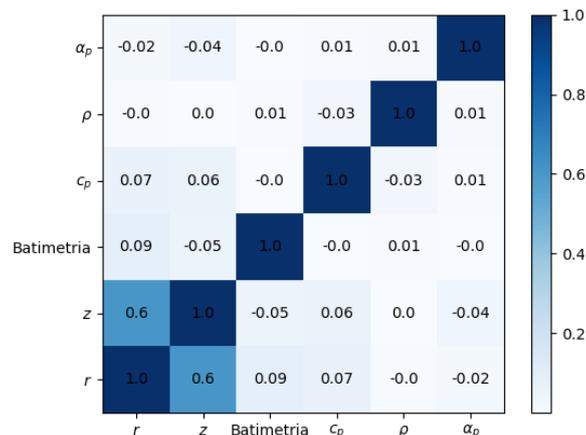


Figura 4.1: Matriz de correlação entre os parâmetros da busca global. A cor de cada campo reflete a magnitude do coeficiente de correlação.

Há duas possíveis razões para isso. GERSTOFT [45] reporta que, quando as incertezas em profundidade e distância são muito grandes, estes se tornam os parâmetros mais importantes, tornando mais difícil estimar corretamente os demais parâmetros por essa metodologia. Por outro lado, MARTINS *et al.* [27], que fizeram inversão dos parâmetros ambientais usando dados do evento P6 assumindo a

posição da fonte como conhecida, sugerem que, além dos parâmetros geoacústicos terem influência de moderada a baixa no campo acústico, eles são espacialmente variantes na região, e obtiveram valores em toda a faixa do espaço de busca. Uma combinação desses dois fatores deve ter levado às PPD encontradas. Mesmo que as propriedades geoacústicas sejam variantes no presente caso, para reduzir a complexidade do espaço da busca local e em virtude da sua baixa influência no campo acústico, elas foram doravante consideradas constantes com o valor médio das PPD: $c_p = 1577,35$ m/s, $\rho = 1,55$ g/cm³, $\alpha_p = 0,59$ dB/ λ . O desvio de batimetria foi mantido na busca local, mas com intervalo de busca reduzido e centrado na média de $-0,78$ m.

4.1.2 Busca local

A busca local foi conduzida separadamente usando intervalos de busca definidos pela média e pela mediana das PPD de distância, além dos demais parâmetros especificados na Tabela 3.1. As Tabelas 4.2 e 4.3 trazem os resultados para a busca local pela média e pela mediana, respectivamente, bem como o erro incorrido e o valor do processador para o modelo mais ajustado.

Tabela 4.2: Resultados da busca local usando a média da PPD de distância. A média do Bartlett considera 0 o valor das transmissões que não obtiveram acerto.

Transmissão	Distância		Profundidade		B	Acerto
	r (m)	ε_r (%)	z (m)	ε_z (m)		
P2-1	1921,80	4,11	8,81	0,62	0,55	Sim
P2-2	2087,20	8,46	9,48	1,10	0,65	Sim
P2-3	2195,07	9,59	8,89	0,96	0,66	Sim
P2-4	2202,40	5,81	9,17	0,92	0,65	Sim
P2-5	2218,41	2,70	31,16	22,26	0,52	Não
P2-6	2314,67	3,40	9,02	0,91	0,61	Sim
P2-7	2411,49	4,07	6,58	-1,36	0,53	Sim
P6-1	1541,94	-2,57	7,96	0,77	0,63	Sim
P6-2	1568,25	2,07	8,92	1,94	0,65	Sim
P6-3	1503,80	2,68	8,86	1,77	0,65	Sim
P6-4	1543,58	10,31	11,55	4,48	0,55	Não
P6-5	1282,86	-1,74	12,48	5,50	0,42	Não
P6-6	1314,51	5,64	9,00	2,06	0,45	Sim
P6-7	1054,95	-8,63	8,02	0,95	0,35	Sim
P6-8	1112,39	1,53	7,95	0,88	0,59	Sim
Média absoluta	-	4,89	-	3,10	0,4634	80%

Os resultados das duas focalizações foram bastante próximos, embora o ajuste pela mediana tenha convergido para regiões com um erro um pouco maior em distância. O ajuste pela média acabou por acertar a localização de 12 das 15 transmissões, errando somente aquelas 3 para as quais o máximo da PPD de profundidade

Tabela 4.3: Resultados da busca local usando a mediana da PPD de distância. A média do Bartlett considera 0 o valor das transmissões que não obtiveram acerto.

Transmissão	Distância		Profundidade		B	Acerto
	r (m)	ε_r (%)	z (m)	ε_z (m)		
P2-1	1935,27	4,84	9,62	1,43	0,57	Sim
P2-2	2086,30	8,41	9,76	1,38	0,67	Sim
P2-3	2148,89	7,29	8,77	0,84	0,66	Sim
P2-4	2196,64	5,53	9,32	1,07	0,65	Sim
P2-5	2096,62	-2,93	28,36	19,47	0,52	Não
P2-6	2413,07	7,80	10,42	2,31	0,62	Sim
P2-7	2541,16	9,67	6,35	-1,59	0,55	Sim
P6-1	1515,12	-4,27	7,38	0,20	0,61	Sim
P6-2	1561,77	1,65	8,15	1,18	0,66	Sim
P6-3	1521,90	3,92	8,05	0,96	0,65	Sim
P6-4	1567,29	12,00	12,83	5,77	0,53	Não
P6-5	1471,31	12,69	11,75	4,77	0,50	Não
P6-6	1357,89	9,13	9,59	2,65	0,51	Não
P6-7	1253,51	8,57	8,77	1,70	0,62	Sim
P6-8	1082,30	-1,21	8,09	1,03	0,59	Sim
Média absoluta	-	6,66	-	3,09	0,4567	73%

se manifestou na posição errada. Isso quer dizer que a profundidade da fonte teve efeito preponderante sobre a distância. Ao se restringir a busca às proximidades da profundidade correta, o modelo pôde ser ajustado o suficiente para eliminar ou suprimir o suficiente as ambiguidades de forma a convergir também para uma distância próxima da correta, mesmo nos casos em que a média da PPD havia sido uma estimativa ruim e produzido um erro inicial grande (P6-7 e P6-8). Como a largura do lóbulo do processador em profundidade é menor, delimitar com precisão o intervalo de busca da profundidade da fonte reduz as chances do algoritmo de busca convergir para alguma região diferente do espaço de busca. O único caso em que isso não se concretizou foi a focalização da transmissão P6-6 pela mediana da PPD de distância, mas o erro nessa transmissão foi menor que os outros casos que foram ajustados em torno de profundidades erradas.

O MAPE com ajuste pela média obteve uma grande melhora em relação à busca global em virtude da correção de distância em transmissões que antes haviam apresentado erro excessivo que enviesava a média. Já o MAPE pela mediana degradou um pouco, no entanto, principalmente em razão das localizações erradas terem resultado em um erro em distância mais elevado que a estimativa original.

Usando os parâmetros invertidos para todas as transmissões e pelas duas estatísticas para calcular o coeficiente de correlação entre eles, foi detectada correlação moderada a forte entre o desvio de batimetria e a profundidade estimada da fonte ($q = -0,54$) e o erro em profundidade ($q = -0,53$), o que sugere um acoplamento

forte desses dois parâmetros agora que o intervalo de busca em profundidade está limitado. O modelo compensou uma estimativa excessiva da profundidade da fonte aumentando a profundidade da coluna d'água. Esse é um efeito já reportado por D'SPAIN *et al.* [42], no qual, se o modelo superestima a profundidade da coluna d'água, ele tende a superestimar a profundidade da fonte também, e o mesmo reciprocamente. O valor médio do desvio de batimetria das localizações bem sucedidas sugere a necessidade de se subtrair cerca de 1,82 m adicionais além da média da PPD. De acordo com GERSTOFT [18], os resultados da inversão poderiam se beneficiar de uma parametrização dos parâmetros acoplados ou da remoção de um deles, nesse caso o desvio da batimetria, do espaço de busca.

Os SSP invertidos não desviaram muito do SSP médio, em razão da baixa variabilidade dos perfis usados na decomposição em EOF, e os coeficientes das três EOF não apresentaram correlação particularmente notável nem entre si e nem com os demais parâmetros. Ainda assim, na Figura 4.2 percebe-se uma tendência, ainda que fraca, dos SSP invertidos se agruparem pelo evento a que pertencem.

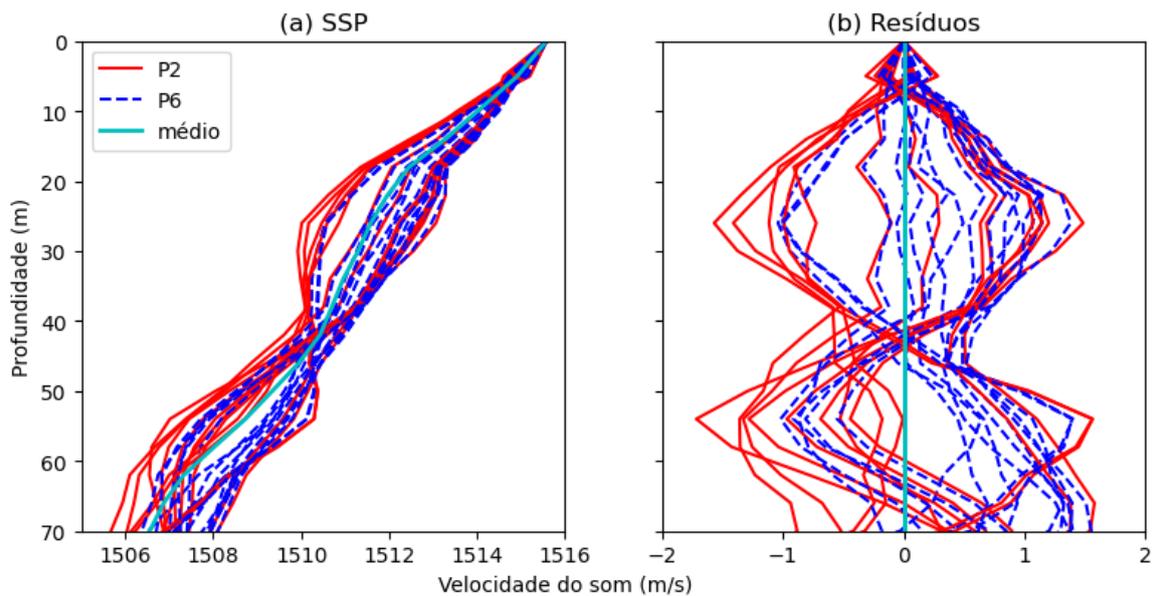


Figura 4.2: (a) SSP invertidos durante a busca local. (b) Resíduos dos SSP.

Como todos os SSP possíveis de serem gerados pela reconstrução por EOF nesse caso possuem a característica de forte refração em direção ao fundo, a inclusão do SSP na inversão teve a função de ajuste fino do campo acústico. Como notado por COLLINS e KUPERMAN [16] e CHAPMAN [10], devido a hierarquia dos parâmetros geométricos sobre os oceanográficos, em relação a seu impacto sobre o campo acústico, e pela natureza não-única da solução do problema inverso, a focalização pode permitir a localização com modelos ambientais não realistas, o que não é um problema se o único interesse for a localização da fonte. Isso significa que, em um contexto de inversão geoacústica ou tomografia por campo casado, os parâmetros

geométricos do guia de ondas devem ser estabelecidos com alto grau de exatidão a fim de que a inversão produza resultados com significado.

4.1.3 MFP

Modelos ambientais configurados com os vetores de parâmetros resultantes da busca local foram usados para gerar conjuntos de réplicas variando somente profundidade e distância da fonte, os quais, juntamente com réplicas geradas pelo modelo base, foram usadas na busca em grade do MFP. Os resultados para o MFP aplicado a todas as 225 amostras experimentais encontram-se enunciados nas Tabelas 4.4 a 4.6 e apresentados de forma gráfica nas Figuras 4.3 a 4.5. Os resultados são apresentados, em ordem, para o modelo base, o modelo ajustado pela média e o modelo ajustado pela mediana das PPD.

Tabela 4.4: Resultados do MFP usando o modelo ambiental base. O Bartlett médio (\bar{B}) considera 0 o valor das amostras que não obtiveram acerto.

Transmissão	$MAPE_r$ (%)	MAE_z (m)	\bar{B}	Acerto (%)
P2-1	20,87	27,81	0,24	40,00
P2-2	9,51	2,15	0,34	53,33
P2-3	8,14	8,80	0,00	0,00
P2-4	20,32	34,68	0,00	0,00
P2-5	17,93	27,04	0,00	0,00
P2-6	3,99	16,23	0,00	0,00
P2-7	23,28	20,00	0,00	0,00
P6-1	28,4	17,04	0,11	20,00
P6-2	2,94	5,56	0,55	93,33
P6-3	6,86	7,84	0,42	73,33
P6-4	34,60	45,77	0,17	33,33
P6-5	31,06	16,02	0,03	6,67
P6-6	67,21	63,26	0,00	0,00
P6-7	39,35	38,07	0,28	53,33
P6-8	2,04	1,61	0,54	93,33
Média	21,10	22,12	0,1785	31,11%

O que se percebe, dos resultados com o modelo base, é uma grande dispersão das localizações, particularmente em profundidade. Apesar de o modelo prover um bom casamento para algumas transmissões, particularmente a P6-2 e a P6-8, o mesmo não ocorreu para a maioria delas e nenhuma alcançou 100% de acerto. Seja porque outras características do ambiente além da batimetria também são espacialmente variantes, seja porque o ambiente é dinâmico e evoluiu o suficiente para que o modelo não fosse mais uma representação adequada dele, o uso de um modelo estático não foi capaz de conseguir uma localização estável da fonte.

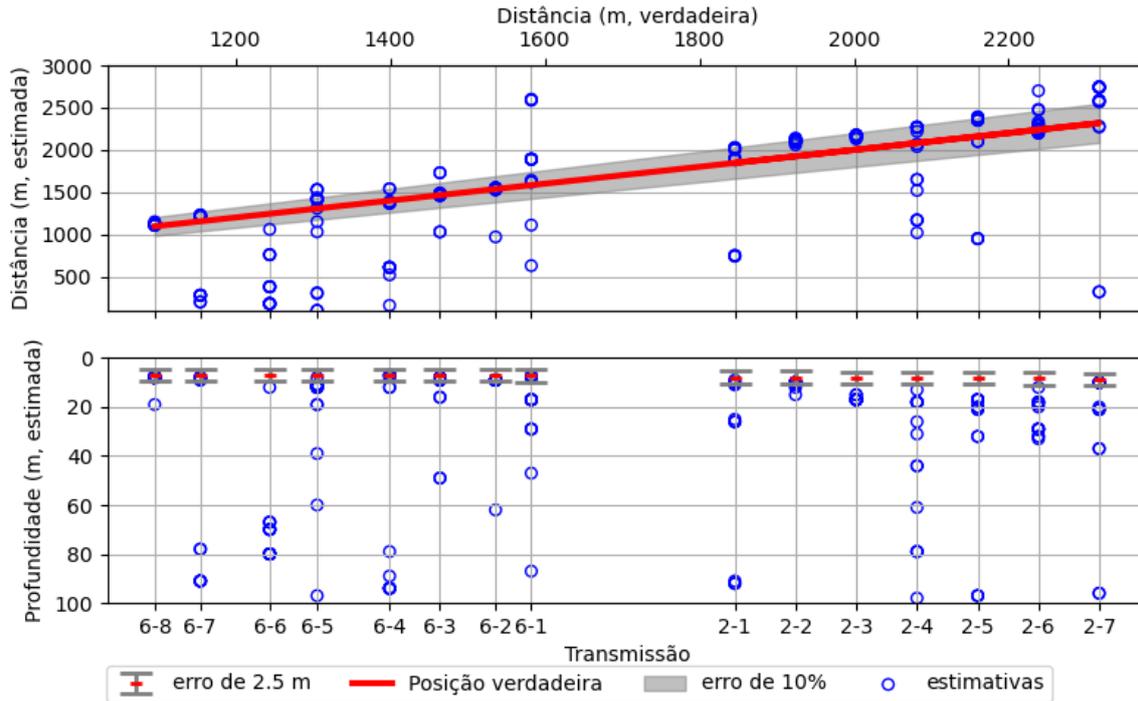


Figura 4.3: Resultados do MFP com o modelo base.

Tabela 4.5: Resultados do MFP usando o modelo ajustado pela média da PPD de distância. O Bartlett médio considera 0 o valor das amostras que não obtiveram acerto.

Transmissão	$MAPE_r$ (%)	MAE_z (m)	\bar{B}	Acerto (%)
P2-1	4,09	1,28	0,57	100,00
P2-2	8,71	2,22	0,56	93,33
P2-3	9,47	1,00	0,57	100,00
P2-4	6,14	1,08	0,57	100,00
P2-5	3,18	21,44	0,00	0,00
P2-6	3,58	0,90	0,52	100,00
P2-7	8,60	1,89	0,49	93,33
P6-1	4,17	3,48	0,52	93,33
P6-2	1,83	2,03	0,63	100,00
P6-3	2,65	1,90	0,64	100,00
P6-4	9,60	5,01	0,00	0,00
P6-5	3,86	10,15	0,00	0,00
P6-6	9,61	7,92	0,46	93,33
P6-7	60,68	57,00	0,13	26,67
P6-8	0,75	0,76	0,58	100,00
Média	9,13	7,87	0,4168	73,33%

Usando os modelos ajustados pela média da PPD de distância, a melhora nos resultados é imediatamente visível. As únicas transmissões para as quais a localização falhou completamente foram as três cuja busca local focalizou o modelo para a região errada, devido ao erro propagado pelas PPD de profundidade com má-

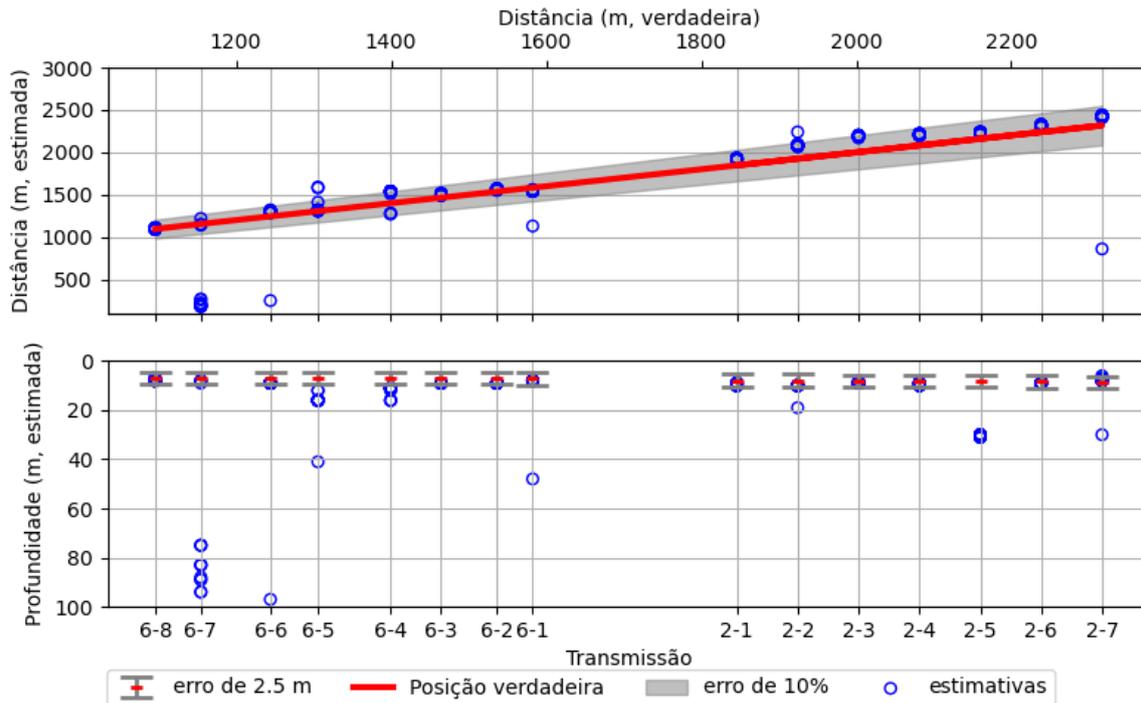


Figura 4.4: Resultados do MFP com o modelo ajustado pela média da PPD da distância.

ximo distante da posição correta. As demais transmissões que não obtiveram 100% de acerto apresentaram erro em uma única amostra, provavelmente em razão de flutuações aleatórias do sinal.

A única exceção é a transmissão P6-7, que degradou severamente em razão do aparecimento de lóbulos secundários proeminentes fora da região de focalização. Como a otimização local busca somente maximizar a função objetivo na região de busca, sem dizer respeito ao restante do domínio, esse é um problema passível de ocorrer ao se realizar uma busca em grade numa região expandida. Para os demais casos, o processo de focalização forneceu não apenas uma boa estimativa da localização da fonte como também um modelo ajustado para garantir uma localização estável durante toda a transmissão.

Os resultados obtidos com os modelos ajustados pela mediana apresentam as mesmas características daqueles obtidos com os modelos ajustados pela média, com as mesmas transmissões apresentando deficiências pelas mesmas razões. Adicionalmente, o MFP para a transmissão P6-6 errou quatro amostras a mais que usando a média das PPD graças à propagação do erro da busca local, que, para o caso da mediana, havia convergido para uma profundidade 0,15 m abaixo do limite aceitável nessa transmissão.

Percebe-se a necessidade de se definir corretamente os intervalos de busca para a focalização, particularmente no tocante à profundidade da fonte. Com exceção da transmissão P6-7, os maiores erros de localização estão associados, primariamente,

Tabela 4.6: Resultados do MFP usando o modelo ajustado pela mediana da PPD de distância. O Bartlett médio considera 0 o valor das amostras que não obtiveram acerto.

Transmissão	$MAPE_r$ (%)	MAE_z (m)	\bar{B}	Acerto (%)
P2-1	5,14	1,14	0,58	100,00
P2-2	9,19	1,75	0,54	86,67
P2-3	7,18	1,07	0,62	100,00
P2-4	5,18	1,22	0,56	100,00
P2-5	13,39	18,57	0,00	0,00
P2-6	6,77	2,03	0,49	86,67
P2-7	9,51	1,94	0,50	93,33
P6-1	4,13	0,61	0,55	100,00
P6-2	1,49	1,03	0,60	100,00
P6-3	3,79	0,90	0,64	100,00
P6-4	14,42	10,81	0,00	0,00
P6-5	15,63	13,82	0,00	0,00
P6-6	8,12	2,39	0,31	66,67
P6-7	57,06	49,93	0,17	33,33
P6-8	0,78	0,76	0,56	100,00
Média	10,78	7,20	0,4072	71,11%

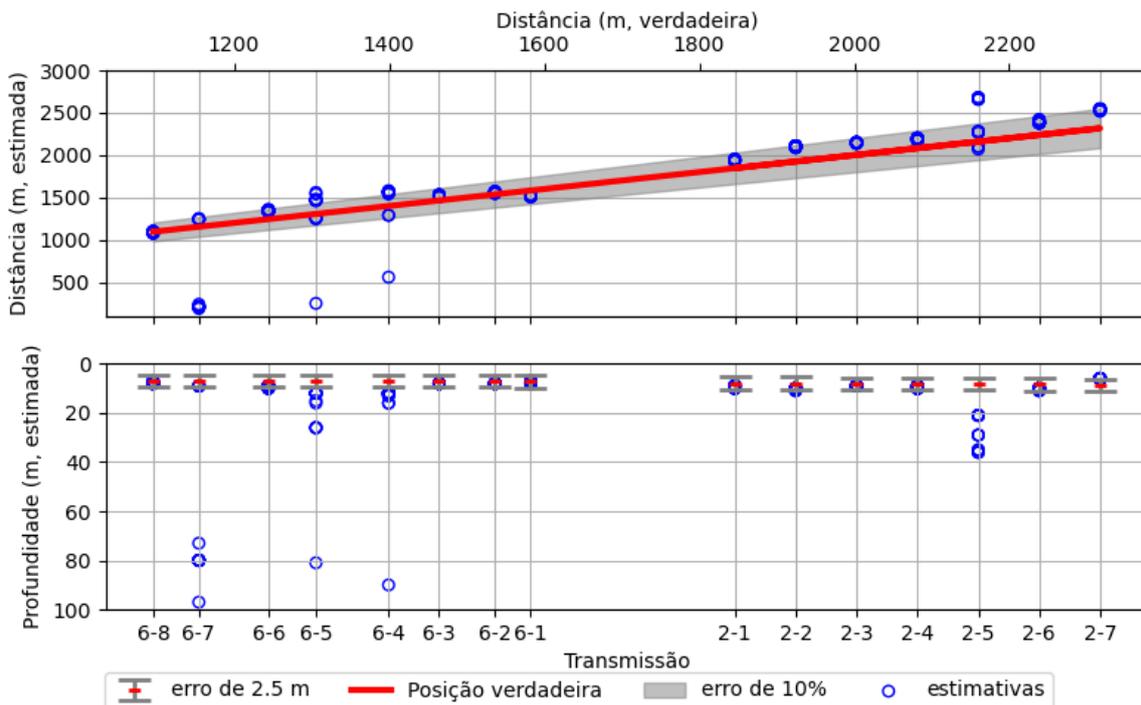


Figura 4.5: Resultados do MFP com o modelo ajustado pela mediana da PPD da distância.

a uma estimativa incorreta da profundidade, devido a propagação de erro em etapas anteriores da heurística.

A preponderância da estimativa correta da profundidade e um ajuste do modelo em torno dela pode ser demonstrado ao se analisar somente a seção da superfície

de ambiguidade de cada amostra na profundidade correta da fonte. Ao se eliminar as ambiguidades em profundidade, o próprio MFP com o modelo base alcança um MAPE de 9,85% com uma taxa de acerto de 80%, enquanto o MFP com os modelos ajustados pela média e mediana alcançam MAPE de 5,84% e 6,77%, com taxas de acerto 86% e 91%, respectivamente. Essa seção das superfícies de ambiguidade de todas as amostras está ilustrada na Figura 4.6.

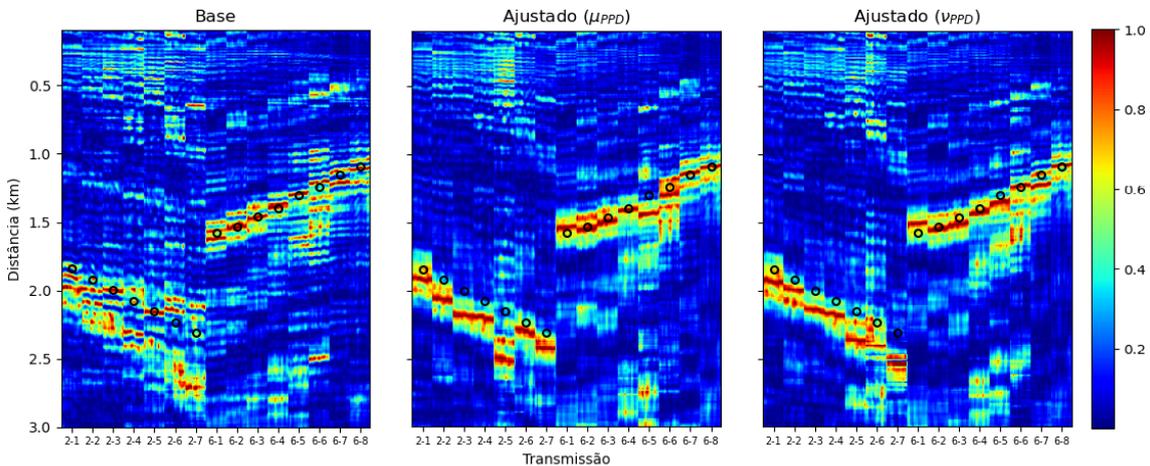


Figura 4.6: Seção das superfícies de ambiguidade das 225 amostras na profundidade correta da fonte. Bartlett de cada amostra normalizado individualmente. Círculos marcam a distância correta da fonte.

O grande ganho do MFP base ao se restringir a profundidade da fonte demonstra que a maior causa de erro de localização são lóbulos secundários em profundidades diversas da correta. Os resultados dos modelos ajustados não obtiveram melhora tão expressiva assim porque a focalização já foi bem sucedida, em grande parte, em suprimir esses lóbulos secundários. Isso se aplica não só aos lóbulos secundários fora da profundidade correta, mas também aqueles fora da distância correta, como se percebe na Figura 4.6. As superfícies de ambiguidade dos modelos ajustados apresentam estruturas muito mais coerentes durante toda a duração de cada transmissão, além de menor quantidade e magnitude de lóbulos secundários em relação ao MFP base, à exceção daquelas transmissões que foram ajustadas na profundidade errada.

Por fim, foi feito um processamento igual ao realizado por DINIZ *et al.* [22], que tratou cada transmissão como uma única amostra dividida em 75 *snapshots* a fim de se gerar as superfícies de ambiguidade constantes no Apêndice B. No trabalho de Diniz *et al.*, não foi usada uma métrica de erro ou uma posição de referência, mas usou-se informação *a priori* da posição da fonte (a profundidade e distância no início de cada transmissão, 40 s antes do início do tom de 500 Hz) e velocidade de deslocamento para definir um intervalo de busca de 300 m de distância e 4 m de profundidade em torno dessa posição, a fim de demonstrar a capacidade da focalização

de suprimir as ambiguidades. Os resultados usando essa forma de processamento encontram-se na Tabela 4.7. Os resultados para o evento P2 não estão reportados no trabalho de Diniz *et al.*, mas foram obtidos usando a mesma metodologia.

Tabela 4.7: Resultados do MFP usando cada transmissão como uma única amostra e comparando com os resultados obtidos por Diniz *et al.*

Transmissão	Base		Diniz <i>et al.</i>		μ_{PPD}		ν_{PPD}	
	ε_r (%)	ε_z (m)						
P2-1	2,93	17,81	4,02	0,81	4,02	0,81	5,10	1,81
P2-2	9,12	1,62	3,41	0,62	8,09	1,62	9,12	1,62
P2-3	8,34	9,07	3,35	0,07	9,34	1,07	7,34	1,07
P2-4	8,58	9,75	2,81	-1,25	5,69	0,75	4,73	0,75
P2-5	9,26	8,10	22,68	12,10	2,78	21,10	5,56	27,10
P2-6	0,07	20,90	2,75	-0,10	3,64	0,90	6,32	1,90
P2-7	18,25	2,06	19,98	12,06	4,87	0,06	9,62	-1,94
P6-1	18,79	9,82	7,41	-0,18	-2,69	0,82	-3,96	0,82
P6-2	0,23	2,03	4,78	1,03	1,53	2,03	1,53	1,03
P6-3	0,37	1,90	11,98	1,90	2,42	1,90	3,79	0,90
P6-4	-56,41	86,94	7,19	-0,06	10,05	3,94	11,48	4,94
P6-5	8,76	4,02	20,25	4,02	0,33	9,02	12,59	5,02
P6-6	-85,53	73,06	15,73	2,06	4,48	2,06	8,49	2,06
P6-7	-75,75	83,93	16,92	1,93	-83,54	67,93	-81,81	72,93
P6-8	2,23	0,93	8,62	0,93	0,40	0,93	-0,51	0,93
Acerto	26,67%		60,0%		73,33%		73,33%	

O que se percebe é que nem a focalização em um espaço de busca bastante estreito foi suficiente para evitar a degradação da localização devido a lóbulos secundários, como na transmissão P2-5. Os autores reportaram que as transmissões P6-4, P6-5 e P6-6 foram particularmente resistentes à focalização, permanecendo com lóbulos secundários em torno da posição correta, o que pode ser verificado nas Figuras B.11 a B.13, com a causa provável sendo ruído na frequência de 500 Hz. A metodologia de delimitar a focalização a partir das estatísticas das PPD, além de dispensar o conhecimento *a priori*, mostrou-se robusta, com maior taxa de acerto.

4.2 Aprendizagem de máquina

São descritos a seguir os resultados para os testes de desajuste, a análise de variabilidade dos conjuntos de dados, juntamente com os resultados da localização pelas FNN e, por fim, uma comparação com a localização feita sob as mesmas condições pelo MFP.

4.2.1 Testes de desajuste

Usando a metodologia descrita na Seção 3.5.5 para comparação entre o MFP e uma FNN, foram obtidos os seguintes resultados, demonstrados graficamente nas Figuras 4.7 (ambiente RD) e 4.8 (ambiente RI), com somente 500 das 1000 amostras plotadas por razões de visibilidade. Além do coeficiente de correlação entre os resultados, cada gráfico traz no topo o MAPE de cada uma das abordagens.

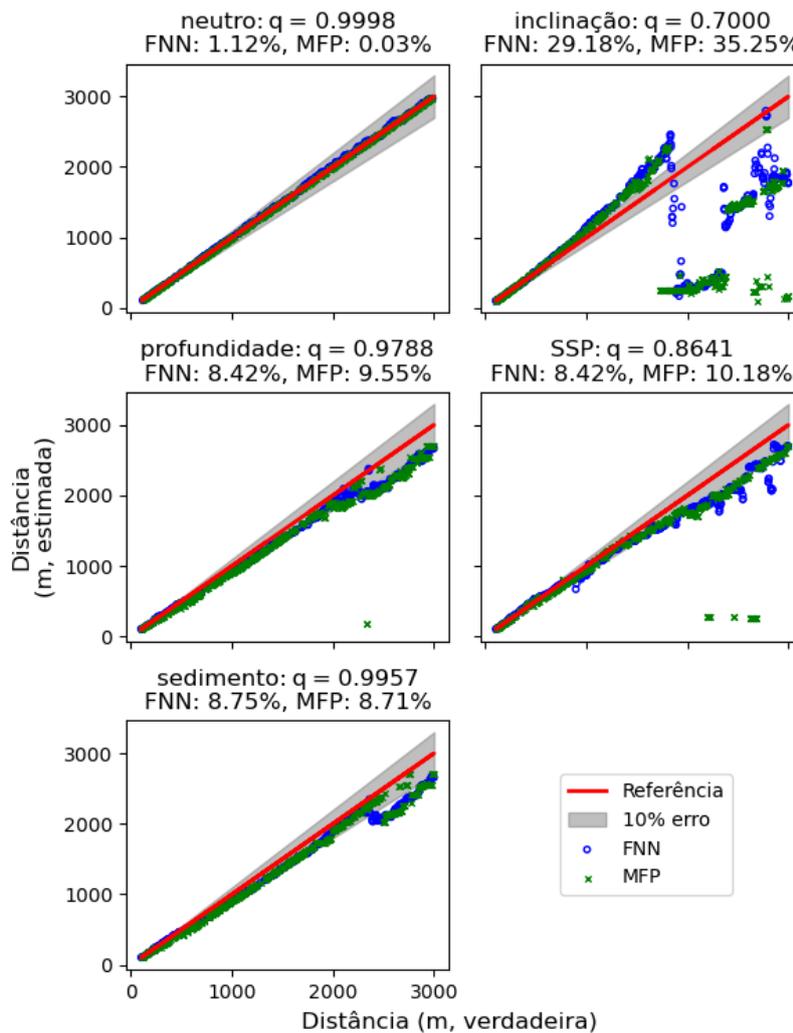


Figura 4.7: Resultados dos testes de desajuste para o ambiente RD.

Algumas das principais características do MFP podem ser enxergadas. Por exemplo, quando o modelo subestima a profundidade, a fonte é localizada sistematicamente mais próxima do que de fato está [41]. No teste de inclinação para o ambiente RD, o efeito de miragem [42], que faz a fonte parecer se afastar conforme adentra águas mais rasas do que o modelo espera, até que o processador degrade completamente (porque só as réplicas a 7,5 m estão sendo consideradas), pode ser visto na tendência das estimativas conforme a distância aumenta. De maneira contrária, no ambiente RI o efeito oposto é enxergado, com a fonte parecendo estar mais próxima

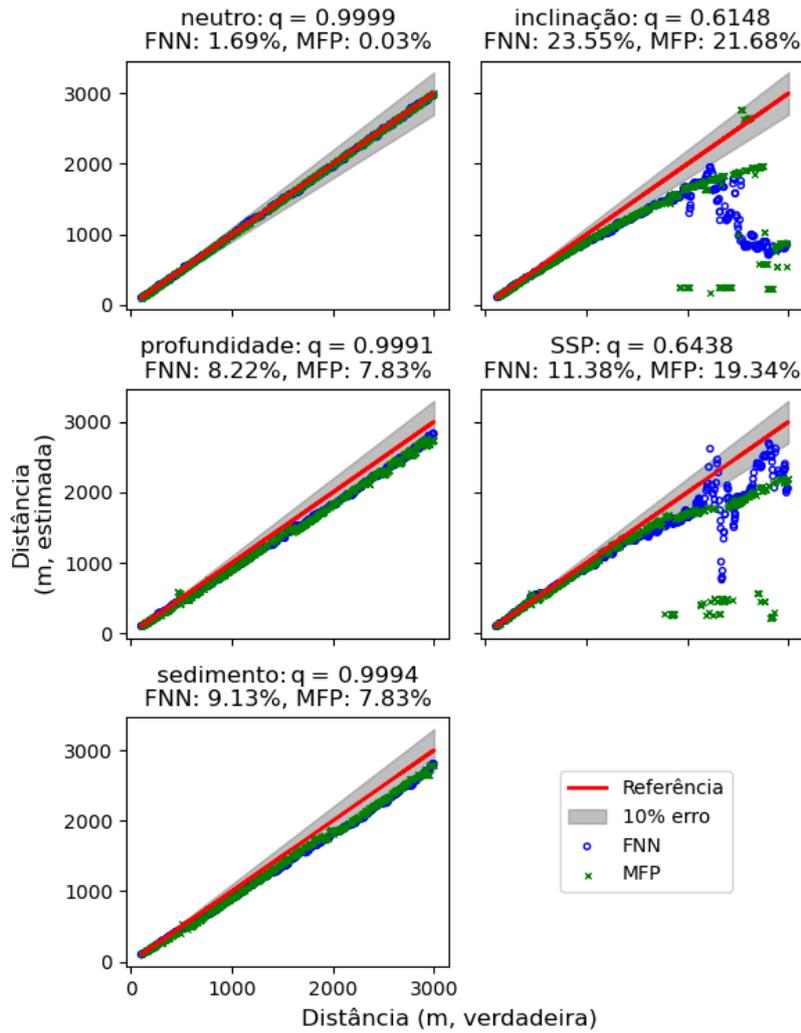


Figura 4.8: Resultados dos testes de desajuste para o ambiente RI.

do que está conforme se move em direção a águas mais profundas do que o modelado. Os efeitos de SSP e batimetria, particularmente no ambiente RI, podem ser vistos como mais importantes que as propriedades do sedimento, produzindo erros grandes que se agravam com o aumento da distância, conforme o desajuste se acumula na propagação do som, como esperado.

É notável que os resultados da FNN seguem de perto os do MFP, exibindo as mesmas respostas aos desajustes aplicados. Essa tendência se reflete no alto valor do coeficiente de correlação dos resultados em todos os testes. Mesmo na presença de fortes fontes de desajuste, como os testes de inclinação, onde os resultados do MFP perdem a tendência inicial em razão da função de ambiguidade (a saída do processador Bartlett para um conjunto de réplicas) ter degradado ao ponto de que o pico verdadeiro dela não é mais identificável, como mostrado na Figura 4.9, a FNN apresenta agrupamentos de pontos nas mesmas regiões que o MFP (Figura 4.7, inclinação) ou perde a tendência da curva nas mesmas regiões em que o MFP apresenta resultados espúrios (Figura 4.8, SSP).

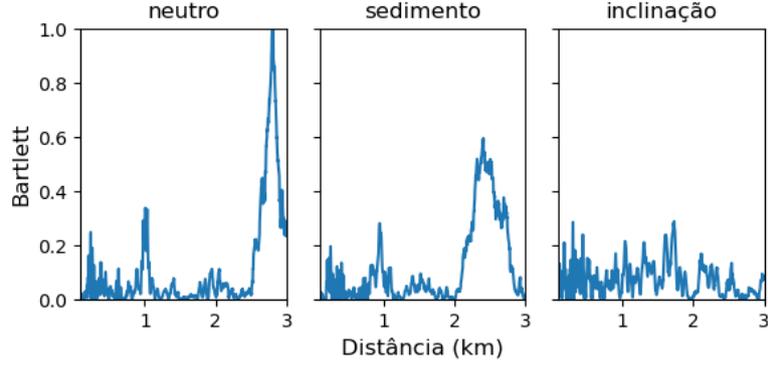


Figura 4.9: Função de ambiguidade para a amostra do teste RI na distância de 2,8 km. Sem desajuste, há um único pico bem definido (lóbulo principal) e o processador alcança o valor normalizado de 1. Na presença de desajuste suave, como no teste de sedimento, a função ainda apresenta um pico bem definido, embora deslocado da posição verdadeira e com menor energia. No caso do desajuste da inclinação de batimetria, mais influente, a função degradou a tal ponto que a posição correta é perdida em meio aos lóbulos secundários.

Mesmo nesses casos, a correlação permanece alta, acima de 0,6, embora seja esperado que, com o aumento da distância, uma vez que o desajuste tenha degradado a função de ambiguidade a tal ponto, ambos MFP e FNN produzirão resultados sem significado e cada vez mais descorrelacionados.

Dadas essas considerações, é, razoável afirmar que a FNN está aprendendo da SCM as mesmas características que o MFP explora para estimação da distância de fontes, uma vez que produz resultados altamente correlacionados ($q \approx 1$) e espera-se que esses resultados se mantenham coerentes enquanto o MFP permanecer estável.

A literatura sobre MFP detalha de maneira aprofundada as características exatas do campo acústico que o MFP utiliza para localização [42] e as maneiras como o desajuste afeta seu comportamento [28, 40].

4.2.2 Análise da variabilidade

A Figura 4.10 traz os resultados da PCA e, na legenda, o número de componentes necessários para explicar 90% da variância em cada conjunto de dados. Esse número aumenta monotonicamente entre os conjuntos de dados e mostra que incluir a variação vertical na batimetria (conjunto 4) adiciona mais variância que os SSP reconstruídos por EOF (conjunto 3) devido à pequena quantidade de medições usadas na decomposição em EOF. 90% da variância é uma medida arbitrária, uma vez que a relação de crescente variabilidade entre conjuntos de dados permanece para qualquer número de componentes ou qualquer fração da variância explicada.

Esse aumento da variabilidade se reflete também nas curvas de aprendizagem, que detalham a evolução da função de custo ao longo das épocas de treinamento

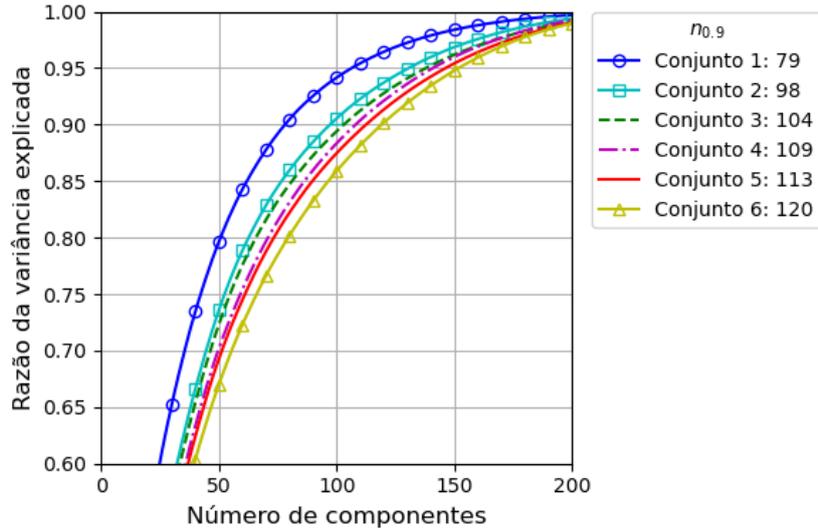


Figura 4.10: Análise de componentes principais dos seis conjuntos de dados sintéticos, com o número de componentes necessários para explicar 90% da variância.

para os conjuntos de treinamento e validação, mostradas na Figura 4.11. Ambas as curvas de treinamento e validação se aproximam de valores ligeiramente mais altos conforme a variabilidade do conjunto de dados aumenta. A principal interpretação desses resultados, juntamente com a PCA, é que o aumento na variabilidade está tornando mais difícil para a FNN tanto se ajustar os dados de treinamento (linhas sólidas) quanto generalizar para novos dados (linhas tracejadas).

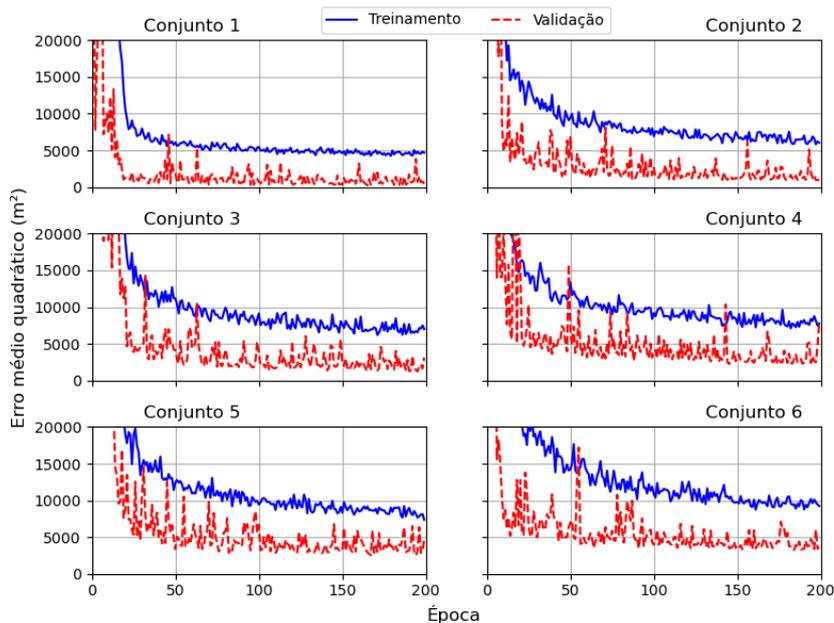


Figura 4.11: Curvas de aprendizagem das FNN treinadas nos seis conjuntos de dados sintéticos.

Esse impacto na aprendizagem da rede é esperado, pois nesse caso o número de

amostras de treinamento permanece constante entre conjuntos de dados. Com um aumento da variabilidade, o domínio da função está sendo expandido (ou, à luz da PCA, os dados com maior variabilidade precisariam de espaços com mais dimensões e, portanto, maior volume, para serem representados em um sistema de coordenadas transformado) e a FNN está sendo incumbida de fazer a regressão de uma função cada vez mais esparsamente amostrada. Esse efeito se traduz no custo de validação, que apresenta a mesma tendência de se aproximar de valores mais altos com o aumento da variabilidade dos dados. Isto acontece pela mesma razão, uma vez que as amostras de validação são extraídas da mesma distribuição que as de treinamento e a rede neural está alcançando um ajuste pior com o aumento da variabilidade. O deslocamento para baixo que as curvas de validação exibem em relação às curvas de treinamento se deve ao alto grau de *dropout* usado, que penaliza a FNN durante o treinamento, mas não é aplicado durante a validação.

Olhando somente para as curvas de aprendizagem com um conjunto de validação sintético, parece que o aumento na variabilidade tem um impacto negativo no desempenho da FNN, mas esses resultados atestam apenas sobre a capacidade de aprendizagem da rede em relação ao domínio da função. Esse método de validação não é representativo do desempenho esperado porque os conjuntos de validação também estão evoluindo em variabilidade, sendo subconjuntos de seus respectivos conjuntos de dados. No entanto, essa abordagem é útil - e, com efeito, necessária, para evitar transferência de informação dos dados de teste durante treinamento - para ajustar hiperparâmetros, o que foi feito para se alcançar a arquitetura final da FNN.

Uma vez que o que está sendo avaliado é o efeito dos próprios conjuntos de dados no desempenho da FNN, é importante que haja um conjunto de retenção invariante, composto por dados reais, para dar uma estimativa não enviesada do desempenho entre conjuntos de dados. Neste caso, os dados do CALCOM serviram a esse propósito. A Tabela 4.8 traz o MAPE médio e desvio padrão da validação cruzada tanto para a parte do conjunto de dados sintéticos separada para teste quanto para os dados do CALCOM. A Figura 4.12 mostra graficamente os melhores resultados nos dados do CALCOM para cada caso.

O MAPE para a parte sintética de teste segue a mesma relação de correlação negativa entre variabilidade e desempenho na validação, exibindo valores progressivamente maiores. Por outro lado, os resultados experimentais melhoram conforme a FNN é treinada com conjuntos de dados mais diversos, mas só até certo ponto.

Em uma analogia com aumento de dados por injeção de ruído, adicionar ruído Gaussiano às amostras de treinamento é um modo de melhorar o aprendizado da rede, mas adição de ruído com variância alta demais pode, em vez disso, ser prejudicial ao desempenho da rede [99]. Aqui, a variância física na diversidade de condições

Tabela 4.8: Resultados (MAPE) da validação cruzada das FNN treinadas nos seis conjuntos de dados sintéticos.

Conjunto	Parte sintética de teste		Dados do CALCOM		
	μ	σ	μ	σ	min
1	1.77	0.28	12.16	2.63	9.55
2	2.48	0.58	6.61	2.04	4.23
3	2.74	0.44	5.99	1.28	3.24
4	3.08	0.33	5.68	1.34	3.11
5	3.27	0.34	4.31	0.87	2.67
6	3.57	0.24	6.88	1.78	4.95

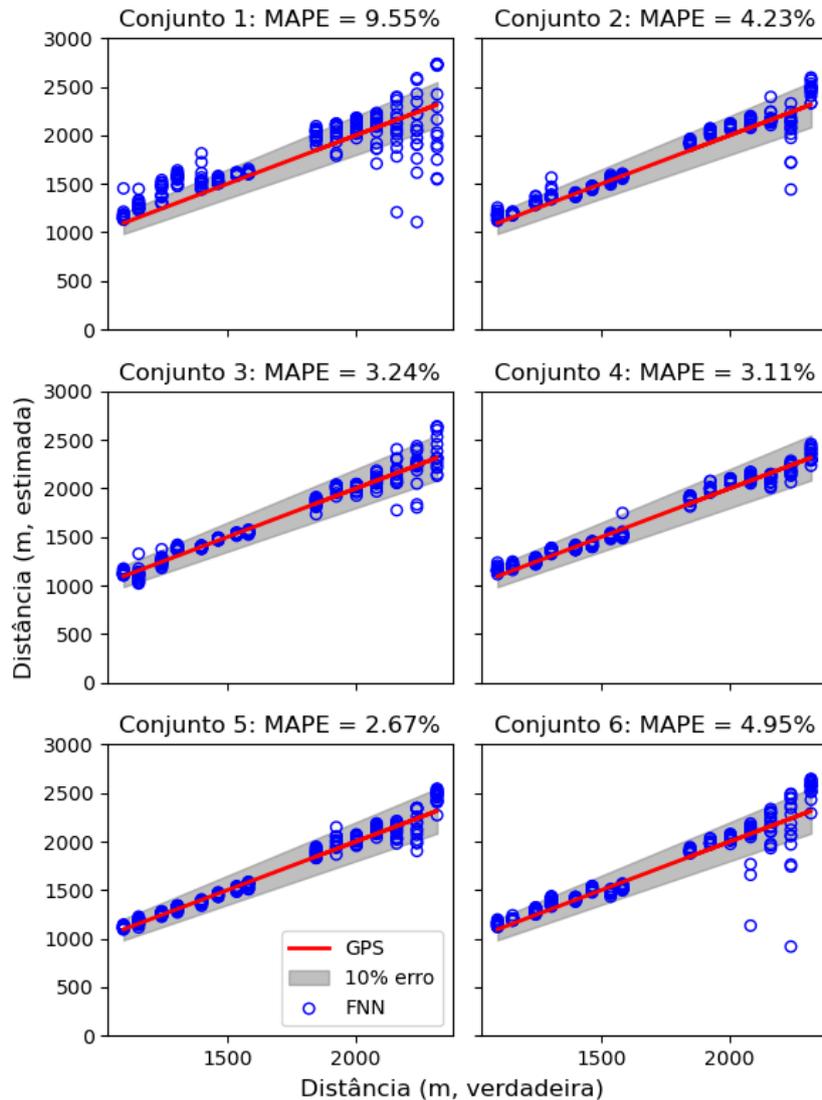


Figura 4.12: Melhores resultados no conjunto de dados do CALCOM para as FNN treinadas em cada um dos seis conjuntos de dados sintéticos.

que produziram os campos acústicos sintéticos tiveram o mesmo efeito.

Esses resultados estão de acordo com o fato que maior diversidade no processo de treinamento leva a modelos mais generalistas. O ponto central, nesse caso, é que

essa diversidade pode ser modelada em consonância com o ambiente e as condições nas quais se deseja que a FNN opere.

O desvio padrão da validação cruzada dos dados do CALCOM servem como uma medida *proxy* da variância do modelo, que não deve ser confundida com a variância do conjunto de dados. A variância de um modelo é resultado de sua complexidade (número de parâmetros) e processo de treinamento. Ela impacta o quanto suas estimativas mudam quando o modelo é treinado em conjuntos de dados diferentes. Se o modelo possui alta variância, pequenas mudanças no conjunto de treinamento resultam em grandes variações no seu desempenho [100], pois um modelo complexo e flexível demais tenderá a se ajustar até mesmo ao ruído presente em um conjunto de dados (*overfitting*). A variância tende a seguir uma curva em forma de “U”, primeiro decrescendo e depois aumentando com o aumento da flexibilidade do modelo. Conjuntamente com o viés, a variância contribui para o erro total do modelo. Essa relação pode ser vista nos resultados da validação cruzada nos dados do CALCOM. O fato que o menor desvio padrão coincidiu com a menor estimativa do MAPE sugere que um modelo com baixo viés e baixa variância foi produzido, o que é considerado um bom ajuste aos dados. Nesse sentido, a variância do conjunto de dados de treinamento está funcionando como um outro hiperparâmetro que pode ser ajustado para afetar o desempenho do modelo.

Embora os resultados apontem que o treinamento de algoritmos de ML somente com dados sintéticos seja eficaz, estes resultados não dispensam completamente a necessidade de aquisição de dados acústicos experimentais. O desempenho das FNN nos dados sintéticos semelhantes ao conjunto de treinamento não foi preditivo de seu desempenho em dados reais. Portanto, um conjunto experimental deve existir e ser usado como conjunto de retenção para validação e seleção dos modelos. Havendo dados suficientes, espera-se resultados melhores com o treinamento usando uma composição de dados sintéticos e experimentais.

4.2.3 Comparação com o MFP

Para comparação com os resultados obtidos pelas FNN, a localização foi feita também por MFP numa versão simplificada do que foi descrito na Seção 3.4, uma vez que aqui só está sendo feita localização em distância, o que reduz significativamente a dificuldade do problema.

Os dados do CALCOM foram comparados aos dois conjuntos de réplicas descritos ao fim da Seção 3.5.4 usando o processador Bartlett (Equação 2.10).

Adicionalmente ao MFP usando o modelo base, a distância também foi invertida usando um modelo ajustado por focalização com GA com parâmetros listados na Tabela 4.9, os quais diferem levemente dos usados na construção do conjunto de

dados 5 e também incluem parâmetros do fundo.

Tabela 4.9: Parâmetros e limites de busca incluídos na focalização para comparação com ML.

Parâmetro	Limite inferior	Limite superior
Distância da fonte (km)	0.1	3
Profundidade da fonte (m)	7	9
Azimute da fonte	-1°	+1°
Deslocamento na batimetria (m)	-5	+5
Velocidade do som no fundo (m/s)	1500	1650
Densidade do fundo (g/cm ³)	1,2	1,9
Atenuação no fundo (dB/λ)	0,2	1,0
Coefficiente da EOF 1	-2	2
Coefficiente da EOF 2	-1	1
Coefficiente da EOF 3	-0,5	0,5

A função objetivo usada na otimização do modelo ambiental foi, mais uma vez, o processador Bartlett, usando a amostra central, temporalmente, de cada um dos eventos. Diferente do que foi feito na seção anterior, foi realizada uma focalização para cada evento, não uma focalização para cada transmissão. Dois conjuntos de réplicas foram, então, gerados usando os novos modelos ambientais ajustados e comparados com o conjunto de dados do CALCOM.

A Figura 4.13 traz os resultados para o MFP, além de reproduzir o resultado obtido pela FNN treinada no conjunto 5, para comparação. Enquanto o modelo base proveu um ajuste quase perfeito para o evento P6 (curta distância), certo grau de desajuste degradou a localização para o evento P2. Focalização foi capaz de compensar esse desajuste e alcançou um MAPE de 2,32%, um pouco melhor que a FNN mais bem sucedida.

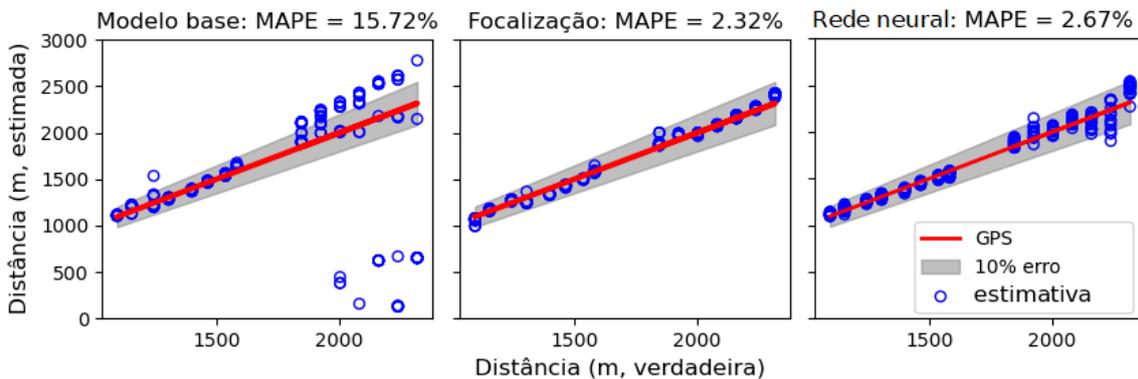


Figura 4.13: Resultados da localização do conjunto de dados do CALCOM pelo MFP usando o modelo base, MFP usando o modelo ajustado e pela FNN treinada no conjunto de dados 5.

As melhoras que a focalização traz, conforme discutido na Seção 4.1, vêm com um custo computacional adicional a um processo que já bastante intensivo como o MFP.

Em adição aos 2×2900 réplicas necessárias para o MFP, a otimização por GA, que usou uma população de 100 indivíduos evoluindo ao longo de 30 gerações, precisou de mais 2×3000 execuções do modelo de propagação, para um total de 11800 execuções, que é mais que o necessário para a produção de um único conjunto sintético usado no treinamento das FNN. Além disso, como o oceano é um ambiente dinâmico e variante espacialmente, para novos dados esse processo teria de ser repetido, uma vez que há a chance de que o modelo ambiental focado não seja mais adequado. MFP com o modelo base ilustra bem esse problema: enquanto que o modelo base estava bem ajustado para o evento P6, obteve resultados ruins para o evento P2, que ocorreu duas horas e meia antes.

Mesmo que não tão bom quanto o resultado obtido por focalização, o modelo de ML com melhor desempenho alcançou MAPE comparativamente próximo (2,67%, contra 2,32% da focalização) contornando dois dos maiores obstáculos do MFP: robustez e custo computacional.

É importante notar que o sucesso tanto das FNN quanto da focalização aqui realizada se deu com muito mais facilidade e eficácia que o método apresentado na seção dedicada a focalização deste trabalho, pois o intervalo de profundidades da fonte para produção das réplicas foi restringido em torno da profundidade correta, reforçando o ponto discutido na Seção 4.1.2 sobre a precisão na determinação da profundidade da fonte ser um fator preponderante para a inversão do campo acústico. A estimação com precisão da profundidade da fonte resolve as ambiguidades em distância e pode reduzir drasticamente o custo computacional do MFP.

Capítulo 5

Conclusões e Sugestões para Trabalhos Futuros

Este trabalho desenvolveu duas abordagens de inversão acústica baseadas em modelos de propagação e ambas foram aplicadas com sucesso para localização da fonte em um conjunto de dados experimental. Por serem abordagens adaptativas, que levam em conta variações dos parâmetros ambientais, ambas sucederam em apresentar resultados melhores que a abordagem clássica com um modelo estático, que requer alto grau de conhecimento do ambiente oceânico.

Na abordagem da focalização, que deriva do método clássico de ajuste de campo, a localização realizada foi bidimensional, em profundidade e distância, o que dificultou o processo. Ainda assim, a heurística de delimitar os limites da focalização (busca local) a partir das estatísticas de uma distribuição de probabilidades resultante de uma busca global se mostrou eficaz e robusta. Resultados melhores podem ser alcançados com um melhor tratamento da PPD de distância. Neste trabalho, foi assumido que ela apresentaria um comportamento unimodal, o que não se mostrou verdadeiro para uma minoria dos casos. Quando o comportamento não é unimodal, as estatísticas extraídas (média, mediana e desvio padrão) deixam de ser representativas da distribuição e podem levar à busca local em região incorreta ou abrangente demais. Já as PPD de profundidade se apresentaram todas multimodais e o máximo da PPD foi uma medida consistente da posição aproximada da fonte. Entretanto, em três das PPD esse máximo se manifestou afastado da posição correta e a propagação desse erro para as outras etapas levou a falha nas localizações. Nas outras transmissões, mesmo as que apresentaram PPD de distância multimodais, a restrição da busca em torno da profundidade correta levou a localizações corretas, colocando a determinação da profundidade como fator preponderante para o sucesso da localização.

Trabalhos futuros usando essa abordagem podem evoluir a metodologia da marginalização, uma vez que foi percebido que é principalmente erro dessa etapa que

se propaga às demais. Estudos com esse enfoque podem dar melhor tratamento às PPD, usando informações de área sob a curva ou largura a meia altura, para estabelecer os limites de focalização de maneira mais consistente, e testar outras combinações de parâmetros a serem incluídos na busca global e local, a fim de encontrar acoplamentos e trabalhar com parametrizações. Na aplicação desta metodologia de focalização, cabe um estudo do tempo de coerência [84] do sinal de interesse a fim de se determinar por quanto tempo o ambiente ajustado pode ser usado na inversão acústica antes de se fazer necessário repetir a focalização. Esse aspecto é importante em uma aplicação como acompanhamento de alvos.

Na abordagem por aprendizagem de máquina, foi demonstrado que o MFP e uma FNN produzem resultados altamente correlacionados quando sujeitos aos mesmos parâmetros de modelo e a entrada é a SCM. Esse resultado valida o uso de conjuntos de dados sintéticos, produzidos com base em modelos de propagação acústica, no treinamento de redes neurais, o que foi subsequentemente verificado nos resultados experimentais com os dados do CALCOM, comparáveis com outros resultados obtidos na literatura e com a técnica de focalização.

O uso de campos acústicos modelados em conjunto com algoritmos de aprendizagem de máquina se mostra uma abordagem promissora para localização em distância ao reduzir a necessidade de aquisição de dados acústicos e preciso conhecimento do ambiente oceânico. Além desses fatores e da robustez que se ganha ao incluir variabilidade ambiental no treinamento do algoritmo, essa técnica se presta a aplicações próximas a tempo real, uma vez que a maior parte da carga computacional é adiantada para a fase de treinamento e seleção do modelo.

Nenhum ruído foi adicionado às amostras sintéticas neste trabalho. Como é sabido que redes neurais são otimizadas para aplicações em que o SNR é o mesmo dos dados de treinamento [101], trabalhos futuros podem estudar se a adição de ruído traz algum benefício a esta metodologia ou apenas degrada o desempenho das FNN ao adicionar variância demais sobre a variância dos parâmetros físicos do modelo de propagação. Localização bidimensional (distância e profundidade ou distância e azimute) usando regressão multivariável (com compartilhamento de pesos) ou modelos em cascata (sem compartilhamento de pesos) pode ser estudada com aplicação desta metodologia. Modelagem em banda larga e o uso de diferentes arquiteturas de redes neurais, bem como diferentes características do campo acústico como entrada dos algoritmos, são outras possibilidades a serem exploradas.

Na modelagem do ambiente em si, como a batimetria variava em forma de cunha e a propagação ocorreu em aclave, é possível que efeitos fora do plano que liga diretamente fonte e receptor sejam relevantes para o cálculo do campo acústico, o que merece investigação por meio de modelagem tridimensional.

Referências Bibliográficas

- [1] HOWETH, L. S. *History of communications-electronics in the United States Navy*. Washington, U.S. Government Printing Office, 1963.
- [2] KUPERMAN, W. A., LYNCH, J. F. “Shallow-water acoustics”, *Physics Today*, v. 57, n. 10, pp. 55–61, 2004.
- [3] JOHNSON, D. H., DUDGEON, D. E. *Array Signal Processing: Concepts and Techniques*. Englewood Cliffs, Prentice Hall, 1993.
- [4] JESUS, S. M., PORTER, M. B., STÉPHAN, Y., et al. “Single hydrophone source localization”, *IEEE Journal of Oceanic Engineering*, v. 25, n. 3, pp. 337–346, 2000.
- [5] OKKONEN, J. *Uniform Linear Adaptive Antenna Array Beamforming Implementation With a Wireless Open-Access Research Platform*. Master’s thesis, University of Oulu, 2013.
- [6] BAGGEROER, A. B., KUPERMAN, W. A., SCHMIDT, H. “Matched field processing: Source localization in correlated noise as an optimum parameter estimation problem”, *The Journal of the Acoustical Society of America*, v. 83, n. 2, pp. 571–587, 1988.
- [7] URICK, R. J. *Principles of Underwater Sound*. 2nd ed. New York, McGraw-Hill, 1975.
- [8] JENSEN, F. B., KUPERMAN, W. A., PORTER, M. B., et al. *Computational Ocean Acoustics*. 2nd ed. New York, Springer, 2011.
- [9] BUCKINGHAM, M. J. “Ocean-acoustic propagation models”, *Journal of Acoustique*, pp. 223–287, 1992.
- [10] CHAPMAN, N. R. “Inverse Methods in Underwater Acoustics”. In: *Applied Underwater Acoustics*, Elsevier, cap. 9, pp. 553–585, 2017.

- [11] BUCKER, H. P. “Use of calculated sound fields and matched-field detection to locate sound sources in shallow water”, *The Journal of the Acoustical Society of America*, v. 59, pp. 368–373, 1976.
- [12] BAGGEROER, A. B., KUPERMAN, W. A., MIKHALEVSKY, P. N. “An overview of matched field methods in ocean acoustics”, *IEEE Journal of Oceanic Engineering*, v. 18, n. 4, pp. 401–424, 1993.
- [13] COLLINS, M. D., KUPERMAN, W. A., SCHMIDT, H. “Nonlinear inversion for ocean-bottom properties”, *The Journal of the Acoustical Society of America*, v. 92, n. 5, pp. 2770–2783, 1992.
- [14] TOLSTOY, A., DIACHOK, O., FRAZER, L. N. “Acoustic tomography via matched field processing”, *Journal of the Acoustical Society of America*, v. 89, n. 3, pp. 1119–1127, 1991.
- [15] SOARES, C., JESUS, S. M. “Processamento por ajuste de campo em acústica submarina e aplicações”. In: *Jornadas do Mar: um Oceano de Oportunidades*, Lisboa, Portugal, 2004.
- [16] COLLINS, M. D., KUPERMAN, W. A. “Focalization: Environmental focusing and source localization”, *The Journal of the Acoustical Society of America*, v. 90, n. 3, pp. 1410–1422, 1991.
- [17] GERSTOFT, P. “Global inversion by genetic algorithms for both source position and environmental parameters”, *Journal of Computational Acoustics*, v. 2, n. 3, pp. 251–266, 1994.
- [18] GERSTOFT, P. “SAGA User Manual 5.4: An inversion software package”. 2007. Disponível em: <<http://noiselab.ucsd.edu/saga/saga.html>>. Acessado em 19/01/2023.
- [19] BIANCO, M. J., GERSTOFT, P., TRAER, J., et al. “Machine learning in acoustics: Theory and applications”, *The Journal of the Acoustical Society of America*, v. 146, n. 5, pp. 3590–3628, 2019.
- [20] MATLOFF, N. *Statistical regression and classification: From linear models to machine learning*. Boca Raton, CRC Press, 2017.
- [21] OZARD, J. M., ZAKARAUSKAS, P., KO, P. “An artificial neural network for range and depth discrimination in matched field processing”, *The Journal of the Acoustical Society of America*, v. 90, n. 5, pp. 2658–2663, 1991.

- [22] DINIZ, P. M., VIO, R. P., XAVIER, F. C., et al. “Source localization based on matched field processing focalization using shallow-water experimental data”. In: *Anais do 12^o Congresso Iberoamericano de Acústica*, Florianópolis, Brasil, 2022.
- [23] TARANTOLA, A. *Inverse Problem Theory and Methods for Model Parameter Estimation*. Philadelphia, USA, Society for Industrial and Applied Mathematics, 2004.
- [24] BARROSO, V. J., RODRÍGUEZ, O. C., RIBEIRO, C. E. P., et al. “Use of ray tracing modeling in shallow water acoustic source localization combined with matched-field processing techniques”, *Revista Brasileira de Geofísica*, v. 34, n. 3, pp. 327–340, 2016.
- [25] MACKENZIE, K. V. “Nine-term equation for sound speed in the oceans”, *The Journal of the Acoustical Society of America*, v. 70, n. 3, pp. 807–812, 1981.
- [26] HAMILTON, E. L. “Geoacoustic modeling of the sea floor”, *Journal of the Acoustical Society of America*, v. 68, n. 5, pp. 1313–1340, 1980.
- [27] MARTINS, N., FELISBERTO, P., JESUS, S. M. “Acoustic field calibration for noise prediction: The CALCOM’ 10 data set”. In: *OCEANS 2011 IEEE - Spain*. IEEE, 2011.
- [28] TOLSTOY, A. *Matched field processing for underwater acoustics*. Singapore, World Scientific, 1993.
- [29] RODRÍGUEZ, O. C. *Fundamentos de Acústica Submarina*. Faro, Portugal, Universidade do Algarve Editora, 2021.
- [30] RODRÍGUEZ, O. C. *The TRACEO ray tracing program*. Faro, Portugal, SiPLAB, University of Algarve, 2011. Disponível em: <<http://www.siplab.fct.ualg.pt/models/traceo/manual.pdf>>. Acessado em 20/11/2022.
- [31] PORTER, M. B. “The BELLHOP Manual and User’s Guide: Preliminary Draft”. 2011.
- [32] RODRÍGUEZ, O. C., COLLIS, J. M., SIMPSON, H. J., et al. “Seismo-acoustic ray model benchmarking against experimental tank data”, *The Journal of the Acoustical Society of America*, v. 132, n. 2, pp. 709–717, 2012.

- [33] FROST, O. L. “An algorithm for linearly constrained adaptive array processing”, *Adaptive Antennas for Wireless Communications*, v. 60, n. 8, pp. 157–166, 2009.
- [34] RICHARDSON, A. M., NOITE, L. W. “A posteriori probability source localization in an uncertain sound speed, deep ocean environment”, *Journal of the Acoustical Society of America*, v. 89, pp. 2280–2284, 1991.
- [35] SCHEER, E. K., BAGGEROER, A. B. “Environmentally tolerant beamforming for high-resolution matched field processing: Deterministic mismatch”, *The Journal of the Acoustical Society of America*, v. 88, n. 4, pp. 1851–1862, 1990.
- [36] HARRISON, B. F., VACCARO, R. J., TUFTS, D. W. “Robust matched-field localization in uncertain ocean environments”, *The Journal of the Acoustical Society of America*, v. 103, n. 6, pp. 3721–3724, 1998.
- [37] MCDONOUGH, R. N. “Degraded Performance of Nonlinear Array Processors in the Presence of Data Modeling Errors”, *Journal of the Acoustical Society of America*, v. 51, n. 4A, pp. 1186–1193, 1972.
- [38] SOARES, C., SIDERIUS, M., JESUS, S. M. “Source localization in a time-varying ocean waveguide”, *The Journal of the Acoustical Society of America*, v. 112, n. 5, pp. 1879–1889, 2002.
- [39] WORTHMANN, B. M., SONG, H. C., DOWLING, D. R. “High frequency source localization in a shallow ocean sound channel using frequency difference matched field processing”, *The Journal of the Acoustical Society of America*, v. 138, n. 6, pp. 3549–3562, 2015.
- [40] HAMSON, R. M., HEITMEYER, M. “Environmental and system effects on source localization in shallow water by the matched-field processing of a vertical array”, *The Journal of the Acoustical Society of America*, v. 86, n. 5, pp. 1950–1959, 1989.
- [41] DEL BALZO, D. R., FEUILLADE, C., ROWE, M. M. “Effects of water-depth mismatch on matched-field localization in shallow water”, *The Journal of the Acoustical Society of America*, v. 83, n. 6, pp. 2180–2185, 1988.
- [42] D’SPAIN, G. L., MURRAY, J. J., HODGKISS, W. S., et al. “Mirages in shallow water matched field processing”, *The Journal of the Acoustical Society of America*, v. 105, n. 6, pp. 3245–3265, 1999.

- [43] TAROUDAKIS, M. I., MARKAKI, M. G. “Matched Field Ocean Acoustic Tomography Using Genetic Algorithms”, *Acoustical Imaging*, v. 22, pp. 601–606, 1996.
- [44] LINDSAY, C. E., ROSS CHAPMAN, N. “Matched Field inversion for Geoaoustic Model Parameters Using Adaptive Simulated Annealing”, *IEEE Journal of Oceanic Engineering*, v. 18, n. 3, pp. 224–231, 1993.
- [45] GERSTOFT, P. “Inversion of seismoacoustic data using genetic algorithms and *a posteriori* probability distributions”, *The Journal of the Acoustical Society of America*, v. 95, pp. 770–782, 1994.
- [46] KIRKPATRICK, S., GELATT, C. D., VECCHI, M. P. “Optimization by simulated annealing”, *Science*, v. 220, n. 4598, pp. 671–680, 1983.
- [47] GOLDBERG, D. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Reading, USA, Addison-Wesley, 1989.
- [48] BALUJA, S., CARUANA, R. “Removing the Genetics from the Standard Genetic Algorithm”. In: *Proceedings of the Twelfth International Conference on Machine Learning*, pp. 38–46, Tahoe City, USA, 1995.
- [49] WINSTON, P. H. “MIT 6.034 Artificial Intelligence, Lecture 13: Learning: Genetic Algorithms”. 2010. Disponível em: <<https://ocw.mit.edu/courses/6-034-artificial-intelligence-fall-2010/resources/lecture-13-learning-genetic-algorithms/>>. Acessado em 15/02/2022.
- [50] DE VITO, E., ROSASCO, L., CAPONNETTO, A., et al. “Learning from examples as an inverse problem”, *Journal of Machine Learning Research*, v. 6, pp. 883–904, 2005.
- [51] SHIU, Y., PALMER, K. J., ROCH, M. A., et al. “Deep neural networks for automated detection of marine mammal species”, *Scientific Reports*, v. 10, n. 1, pp. 1–12, 2020.
- [52] WANG, D., ZHANG, L., LU, Z., et al. “Large-Scale Whale Call Classification Using Deep Convolutional Neural Network Architectures”, *2018 IEEE International Conference on Signal Processing, Communications and Computing, ICSPCC 2018*, 2018.
- [53] CHOI, J., CHOO, Y., LEE, K. “Acoustic classification of surface and underwater vessels in the ocean using supervised machine learning”, *Sensors*, v. 19, n. 16, 2019.

- [54] SOUZA, M., JÚNIOR, N., SEIXAS., J. “Classificação de sinais temporais de sonar passivo utilizando redes neurais convolucionais”. In: *Anais do 15° Congresso Brasileiro de Inteligência Computacional*, Joinville, SC, 2021. SBIC.
- [55] DOMINGOS, L. C., SANTOS, P. E., SKELTON, P. S., et al. “A survey of underwater acoustic data classification methods using deep learning for shoreline surveillance”, *Sensors*, v. 22, n. 6, pp. 1–30, 2022.
- [56] STEINBERG, B. Z., BERAN, M. J., CHIN, S. H., et al. “A neural network approach to source localization”, *Journal of the Acoustical Society of America*, v. 90, n. 4, pp. 2081–2090, 1991.
- [57] NIU, H., REEVES, E., GERSTOFT, P. “Source localization in an ocean waveguide using supervised machine learning”, *The Journal of the Acoustical Society of America*, v. 142, n. 3, pp. 1176–1188, 2017.
- [58] ZHU, X., DONG, H., SALVO ROSSI, P., et al. “Feature selection based on principal component regression for underwater source localization by deep learning”, *Remote Sensing*, v. 13, n. 8, 2021.
- [59] FERGUSON, E. L., WILLIAMS, S. B., JIN, C. T. “Sound source localization in a multipath environment using convolutional neural networks”. In: *IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, v. 2018-April, pp. 2386–2390, 2018.
- [60] WANG, Y., PENG, H. “Underwater acoustic source localization using generalized regression neural network”, *The Journal of the Acoustical Society of America*, v. 143, n. 4, pp. 2321–2331, 2018.
- [61] CAI, S., XU, W. “Matched-field source localization using sparsely-coded neural network and data-model mixed training”. In: *Proceedings of the International Conference on Underwater Networks and Systems (WUWNet)*, pp. 1–5, 2017.
- [62] CHI, J., LI, X., WANG, H., et al. “Sound source ranging using a feed-forward neural network trained with fitting-based early stopping”, *The Journal of the Acoustical Society of America*, v. 146, n. 3, pp. EL258–EL264, 2019.
- [63] FIALKOWSKI, L. T., COLLINS, M. D., KUPERMAN, W. A., et al. “Matched-field processing using measured replica fields”, *The Journal of the Acoustical Society of America*, v. 107, n. 2, pp. 739–746, 2000.

- [64] BRISCOE, E., FELDMAN, J. “Conceptual complexity and the bias/variance tradeoff”, *Cognition*, v. 118, n. 1, pp. 2–16, 2011.
- [65] MAC NAMEE, B., CUNNINGHAM, P., BYRNE, S., et al. “The problem of bias in training data in regression problems in medical decision support”, *Artificial Intelligence in Medicine*, v. 24, n. 1, pp. 51–70, 2002.
- [66] CONLIN, A. K., MARTIN, E. B., MORRIS, A. J. “Data augmentation: An alternative approach to the analysis of spectroscopic data”, *Chemometrics and Intelligent Laboratory Systems*, v. 44, n. 1-2, pp. 161–173, 1998.
- [67] HARTMANN, W., NG, T., HSIAO, R., et al. “Two-stage data augmentation for low-resourced speech recognition”. In: *Proceedings of the Annual Conference of the International Speech Communication Association (INTERSPEECH)*, v. 08-12-September-2016, pp. 2378–2382, 2016.
- [68] SHORTEN, C., KHOSHGOFTAAR, T. M. “A survey on Image Data Augmentation for Deep Learning”, *Journal of Big Data*, v. 6, n. 1, 2019.
- [69] MATSUOKA, K. “Noise injection into inputs in back propagation learning”, *IEEE Transactions on Systems, Man, and Cybernetics*, v. 22, n. 3, pp. 436–440, 1992.
- [70] BISHOP, C. M. “Training with Noise is Equivalent to Tikhonov Regularization”, *Neural Computation*, v. 7, n. 1, pp. 108–116, 1995.
- [71] GOODFELLOW, I., POUGET-ABADIE, J., MIRZA, M., et al. “Generative Adversarial Nets”. In: Ghahramani, Z., Welling, M., Cortes, C., et al. (Eds.), *Advances in Neural Information Processing Systems*, v. 27. Curran Associates, Inc., 2014.
- [72] HUANG, Z., XU, J., GONG, Z., et al. “Source localization using deep neural networks in a shallow water environment”, *The Journal of the Acoustical Society of America*, v. 143, n. 5, pp. 2922–2932, 2018.
- [73] NIU, H., GONG, Z., OZANICH, E., et al. “Deep-learning source localization using multi-frequency magnitude-only data”, *The Journal of the Acoustical Society of America*, v. 146, n. 1, pp. 211–222, 2019.
- [74] LIU, W., YANG, Y., XU, M., et al. “Source localization in the deep ocean using a convolutional neural network”, *The Journal of the Acoustical Society of America*, v. 147, n. 4, pp. EL314–EL319, 2020.

- [75] CHEN, R., SCHMIDT, H. “Model-based convolutional neural network approach to underwater source-range estimation”, *The Journal of the Acoustical Society of America*, v. 149, n. 1, pp. 405–420, 2021.
- [76] SUMARI, A. D. W., WURYANDARI, A., DARUSMAN, M., et al. “The Performance of Supervised and Unsupervised Neural Networks in Performing Aircraft Identification Tasks”, *Seminar Radar Nasional III*, pp. 16 – 22, 2009.
- [77] HORNIK, K. “Approximation capabilities of multilayer feedforward networks”, *Neural Networks*, v. 4, n. 2, pp. 251–257, 1991.
- [78] LERNER, B., GUTERMAN, H., ALADJEM, M., et al. “Feature extraction by neural network nonlinear mapping for pattern classification”, *Proceedings - International Conference on Pattern Recognition*, v. 4, pp. 320–324, 1996.
- [79] RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J. “Learning Representations by Back-Propagating Errors”, *Nature*, v. 323, pp. 533–536, 1986.
- [80] LI, F.-F. “CS231n: Convolutional Neural Networks for Visual Recognition”. 2015. Disponível em: <<https://cs231n.github.io/neural-networks-1/#actfun>>. Acessado em 03/04/2023.
- [81] RASCHKA, S. “Model evaluation, model selection, and algorithm selection in machine learning”, *arXiv:1811.12808*, 2018.
- [82] FELISBERTO, P., JESUS, S., ZABEL, F. *CALCOM’10 Sea Trial: Field calibration data report*. Relatório Técnico 04/10, SiPLAB, University of Algarve, Faro, Portugal, 2010.
- [83] ROQUE, C., HERNÁNDEZ-MOLINA, F. J., LOBO, F., et al. “Geomorphology of the Eastern Algarve proximal continental margin (South Portugal, SW Iberia Peninsula): sedimentary dynamics and its relationship with the last asymmetrical eustatic cycle”, *Ciencias da Terra* 17, v. 17, pp. 28, 2010.
- [84] YANG, T. C. “Measurements of temporal coherence of sound transmissions through shallow water”, *The Journal of the Acoustical Society of America*, v. 120, n. 5, pp. 2595–2614, 2006.
- [85] BARROSO, V. J. *Localização de fontes sonoras em águas rasas com uso de um único arranjo de hidrofones em linha por meio de modelagem acústica tridimensional*. Tese de Doutorado, COPPE/UFRJ, 2018. Dis-

ponível em: <<https://pantheon.ufrj.br/bitstream/11422/12784/1/VicenteBarrosoJunior-min.pdf>>. Acessado em 20/11/2022.

- [86] DINIZ, P. M. “TRACEOTOOLS: Python plotting package and auxiliary functions for TRACEO ray tracing model.” <https://github.com/PedroMDiniz/traceotools>, 2022.
- [87] DAVIS, R. E. “Predictability of Sea Level Pressure Anomalies Over the North Pacific Ocean”, *Journal of Physical Oceanography*, v. 8, n. 2, pp. 233–246, 1978.
- [88] SOARES, C., SIDERIUS, M., JESUS, S. M. “High-frequency source localization in the Strait of Sicily”. In: *Proceedings of the MTS/IEEE Oceans 2001*, v. 4, pp. 2530–2535, Honolulu, USA, 2001.
- [89] RUSSEL, S., NORVIG, P. *Artificial Intelligence: A Modern Approach*. 3rd ed. Upper Saddle River, Prentice Hall, 2010.
- [90] GORODETSKAYA, E. Y., MALEKHANOV, A. I., SAZONTOV, A. G., et al. “Deep-water acoustic coherence at long ranges: theoretical prediction and effects on large-array signal processing”, *IEEE Journal of Oceanic Engineering*, v. 24, n. 2, pp. 156–171, 1999.
- [91] HODGKISS, W. S., BRIENZO, R. K. “Broadband source detection and range/depth localization via full-wavefield (matched field) processing”, *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, v. 5, pp. 2743–2746, 1990.
- [92] ABADI, M., AGARWAL, A., BARHAM, P., et al. “TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems”. 2015. Disponível em: <<https://www.tensorflow.org/>>. Acessado em 07/11/2022.
- [93] BALDI, P., SADOWSKI, P. “The dropout learning algorithm”, *Artificial Intelligence*, v. 210, n. 1, pp. 78–122, 2014.
- [94] KINGMA, D. P., BA, J. “Adam: A Method for Stochastic Optimization”. 2014. Disponível em: <<https://arxiv.org/abs/1412.6980>>. Acessado em 08/11/2022.
- [95] KOHAVI, R. “A study of cross-validation and bootstrap for accuracy estimation and model selection”. In: *IJCAI’95: Proceedings of the 14th International Joint Conference on Artificial Intelligence*, v. 2, pp. 1137–1143, 1995.

- [96] LEE RODGERS, J., ALAN NICE WANDER, W. “Thirteen ways to look at the correlation coefficient”, *American Statistician*, v. 42, n. 1, pp. 59–66, 1988.
- [97] JOLLIFFE, I. T. *Principal Component Analysis*. 2nd ed. New York, Springer-Verlag, 2002.
- [98] HOWLEY, T., MADDEN, M. G., O’CONNELL, M. L., et al. “The effect of principal component analysis on machine learning accuracy with high-dimensional spectral data”, *Knowledge-Based Systems*, v. 19, n. 5, pp. 363–370, 2006.
- [99] HOLMSTROM, L., KOISTINEN, P. “Using Additive Noise in Back Propagation Training”, *IEEE Transactions on Neural Networks*, v. 3, n. 1, pp. 24–38, 1992.
- [100] JAMES, G., WITTEN, D., HASTIE, T., et al. *An Introduction to Statistical Learning*. New York, Springer, 2013.
- [101] YIN, S., LIU, C., ZHANG, Z., et al. “Noisy training for deep neural networks in speech recognition”, *Eurasip Journal on Audio, Speech, and Music Processing*, v. 2015, n. 1, pp. 1–14, 2015.

Apêndice A

Distribuições de probabilidade a *posteriori* da busca global

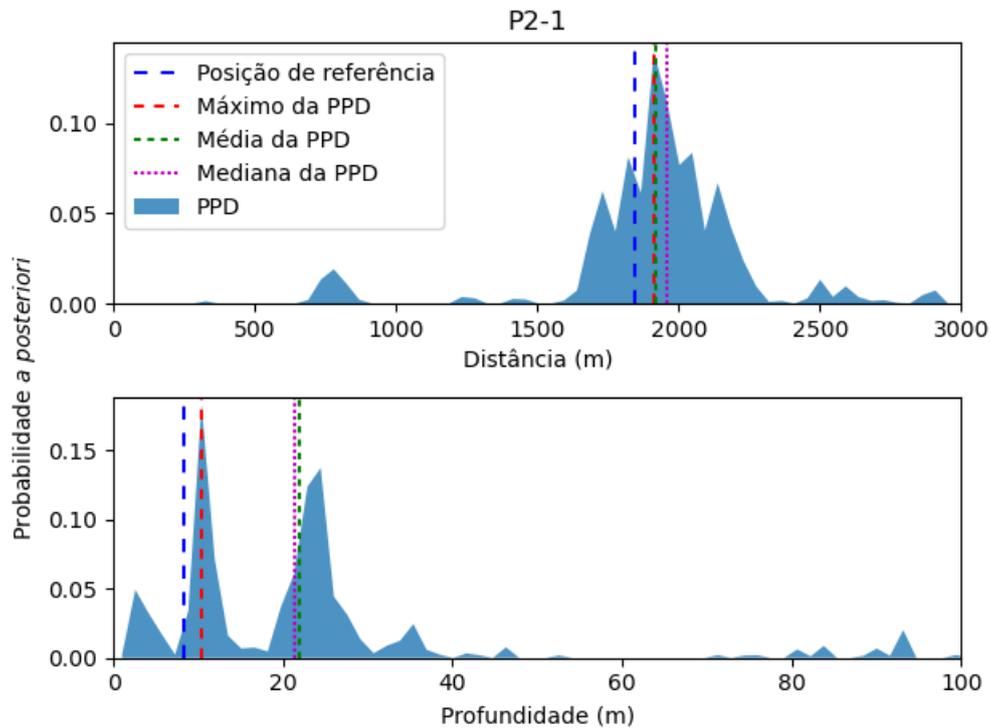


Figura A.1: PPD de posição da fonte para a transmissão P2-1.

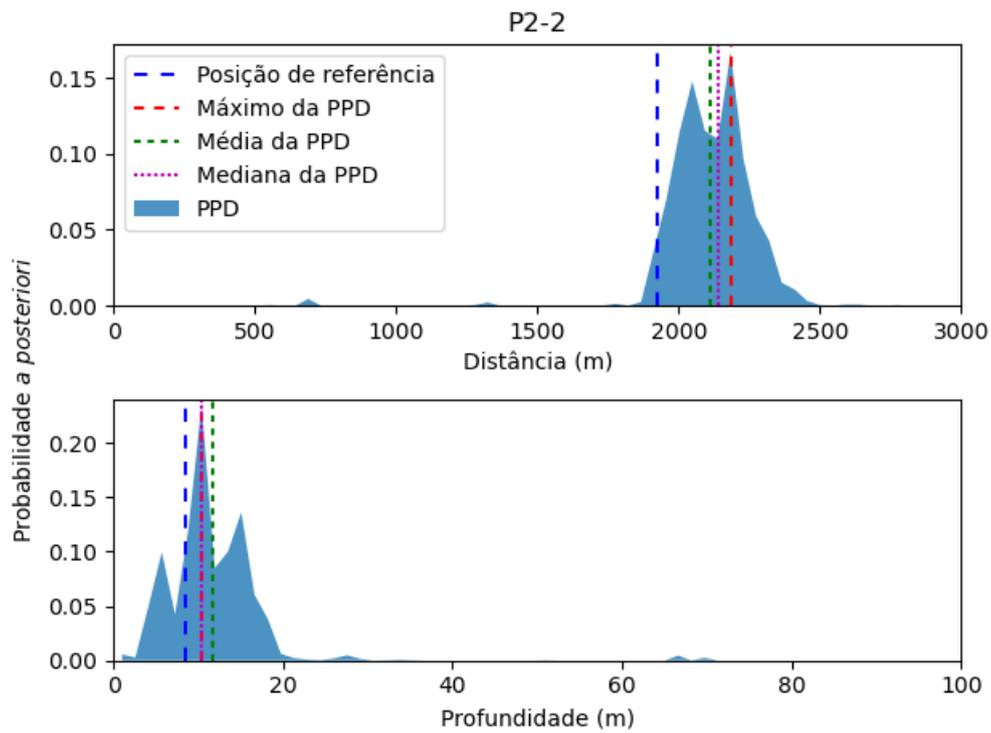


Figura A.2: PPD de posição da fonte para a transmissão P2-2.

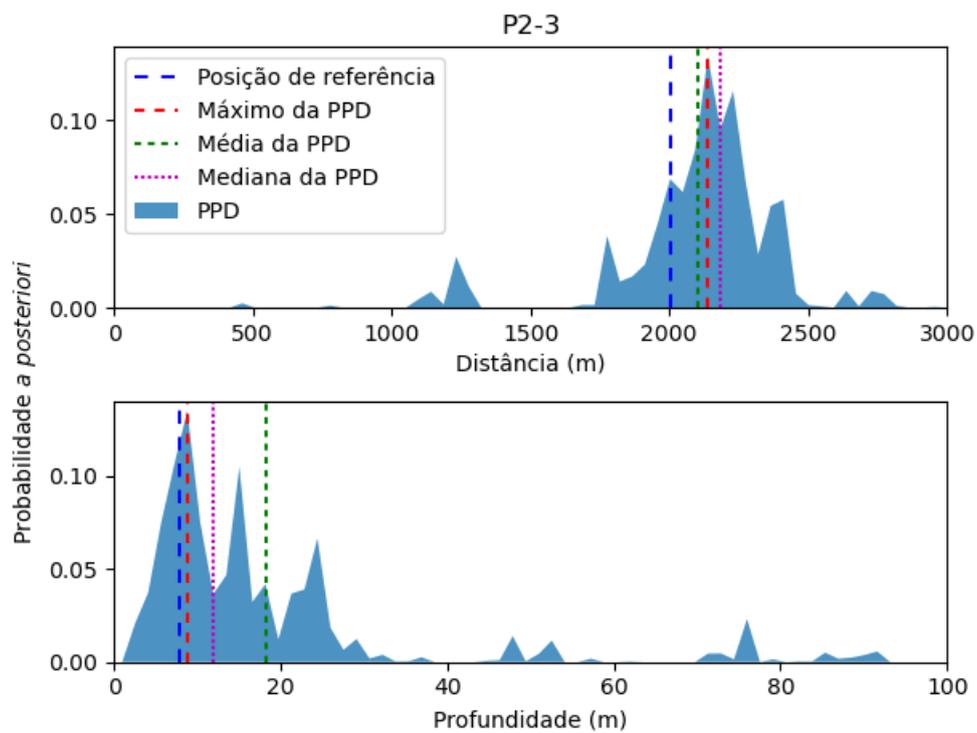


Figura A.3: PPD de posição da fonte para a transmissão P2-3.

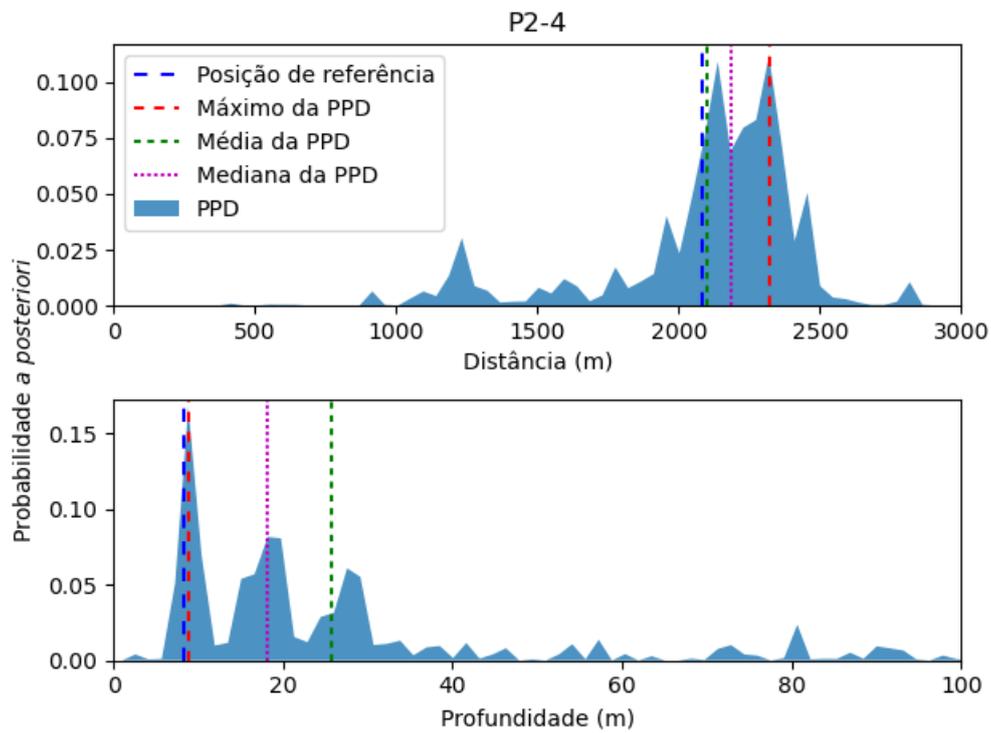


Figura A.4: PPD de posição da fonte para a transmissão P2-4.

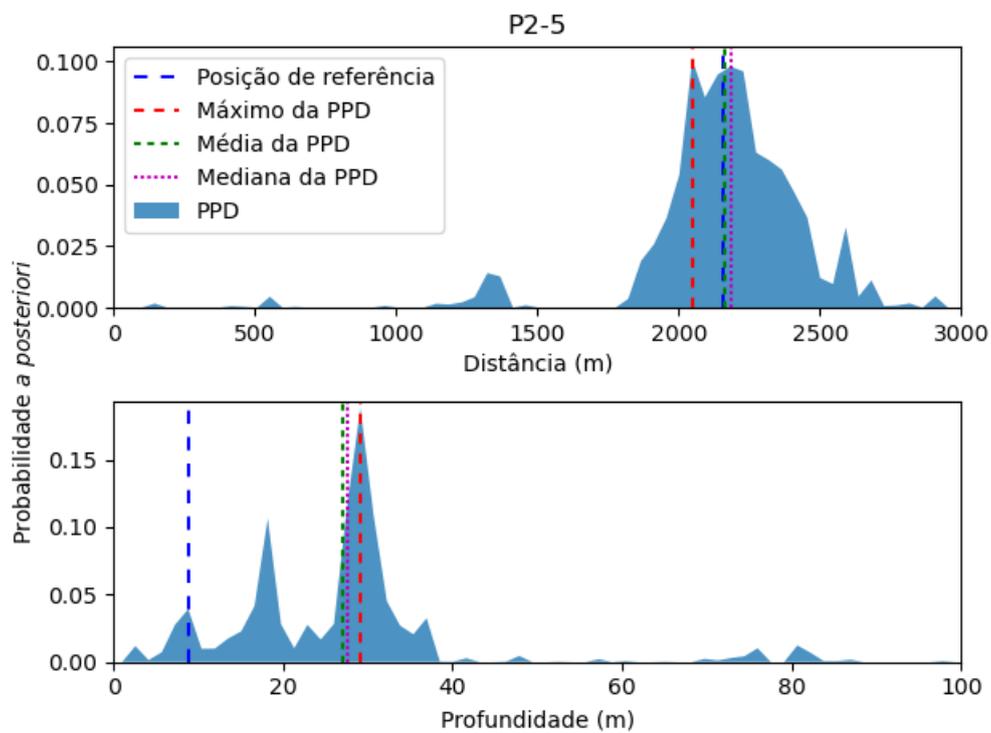


Figura A.5: PPD de posição da fonte para a transmissão P2-5.

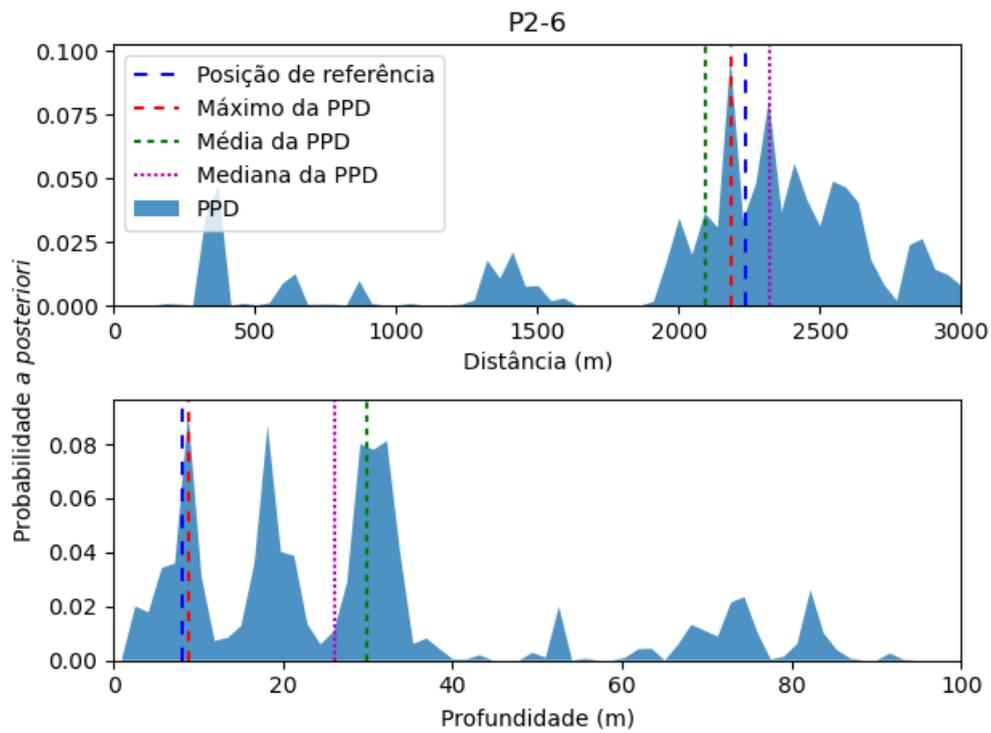


Figura A.6: PPD de posição da fonte para a transmissão P2-6.

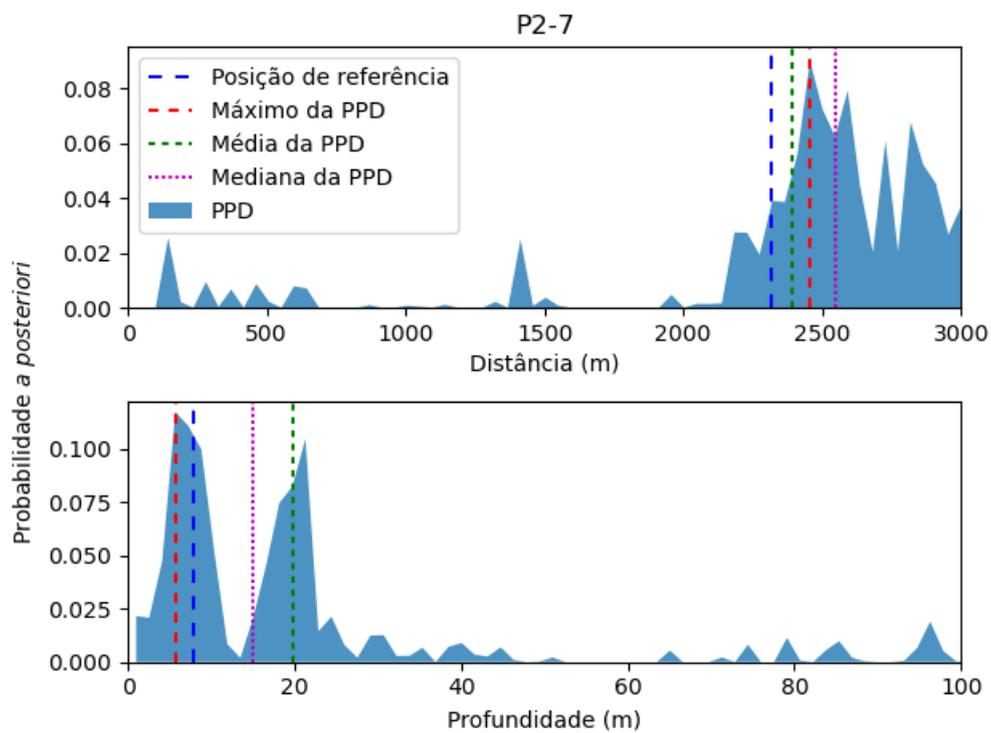


Figura A.7: PPD de posição da fonte para a transmissão P2-7.

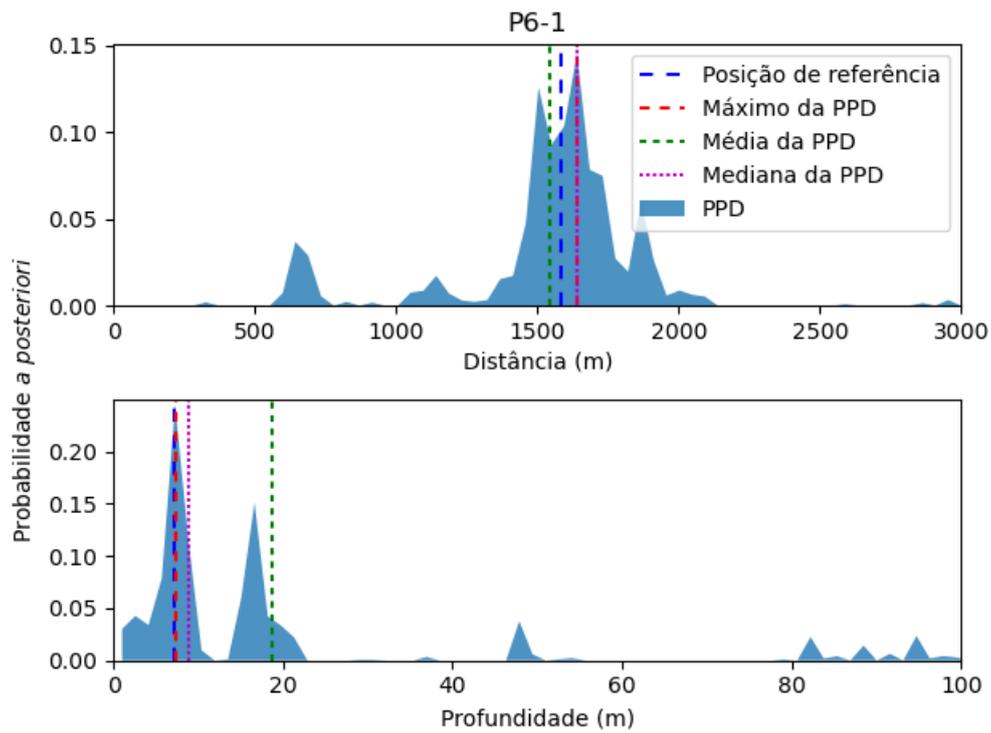


Figura A.8: PPD de posição da fonte para a transmissão P6-1.

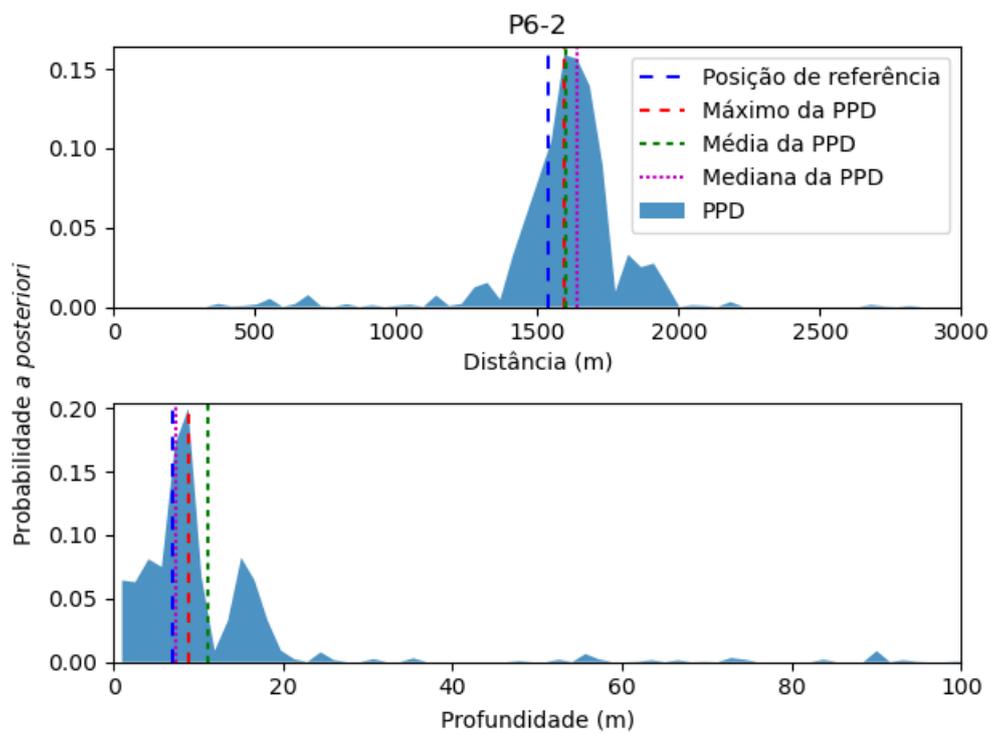


Figura A.9: PPD de posição da fonte para a transmissão P6-2.

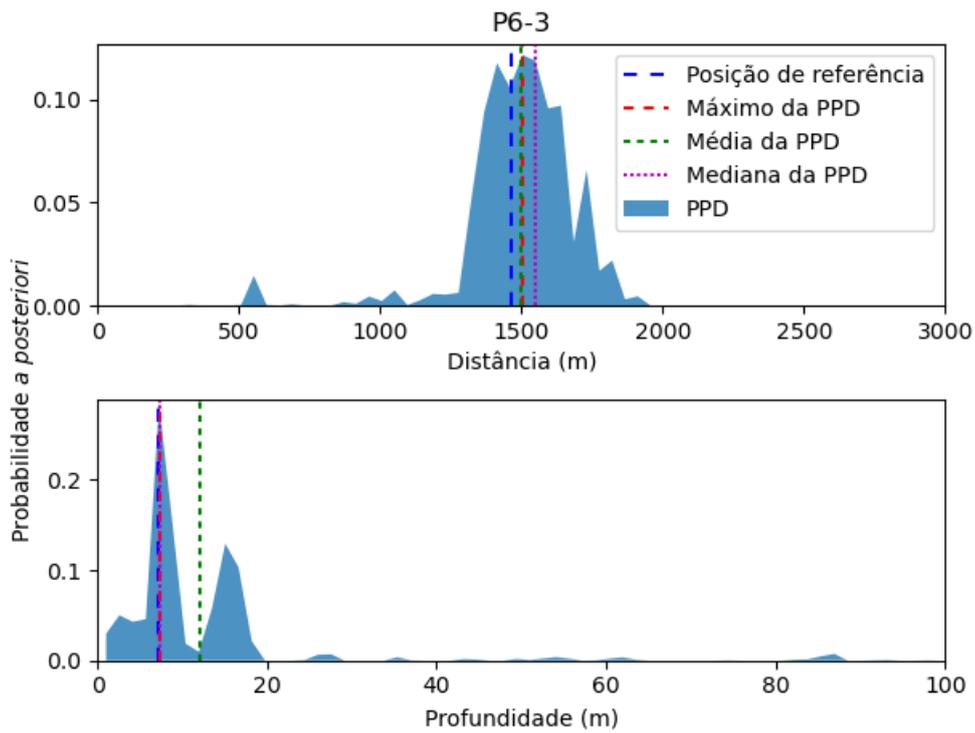


Figura A.10: PPD de posição da fonte para a transmissão P6-3.

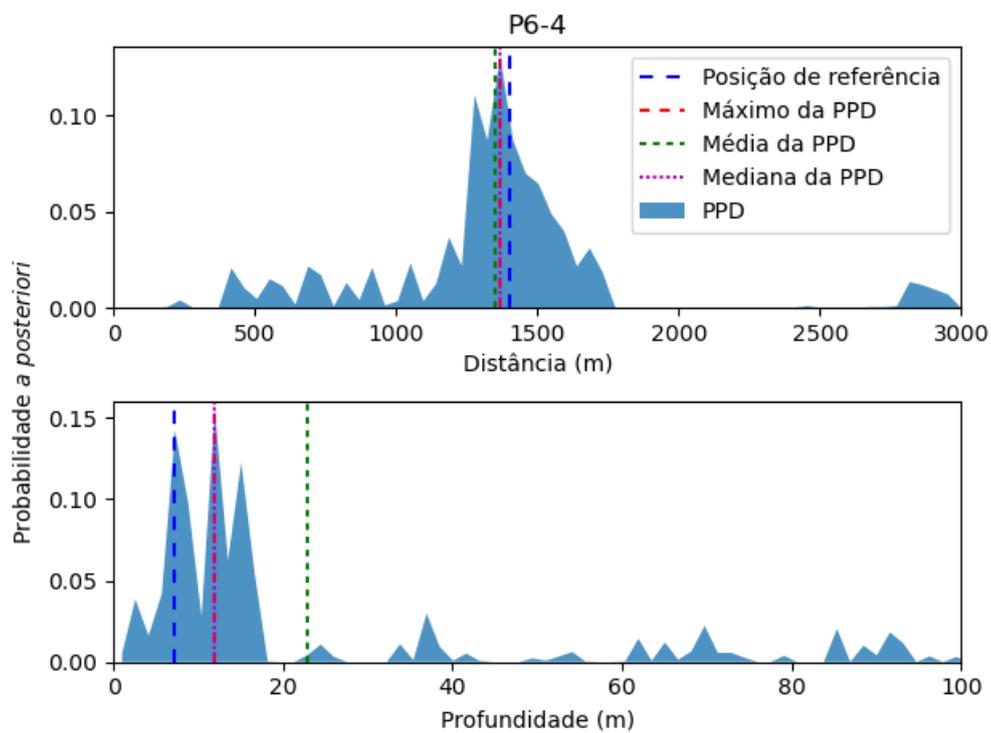


Figura A.11: PPD de posição da fonte para a transmissão P6-4.

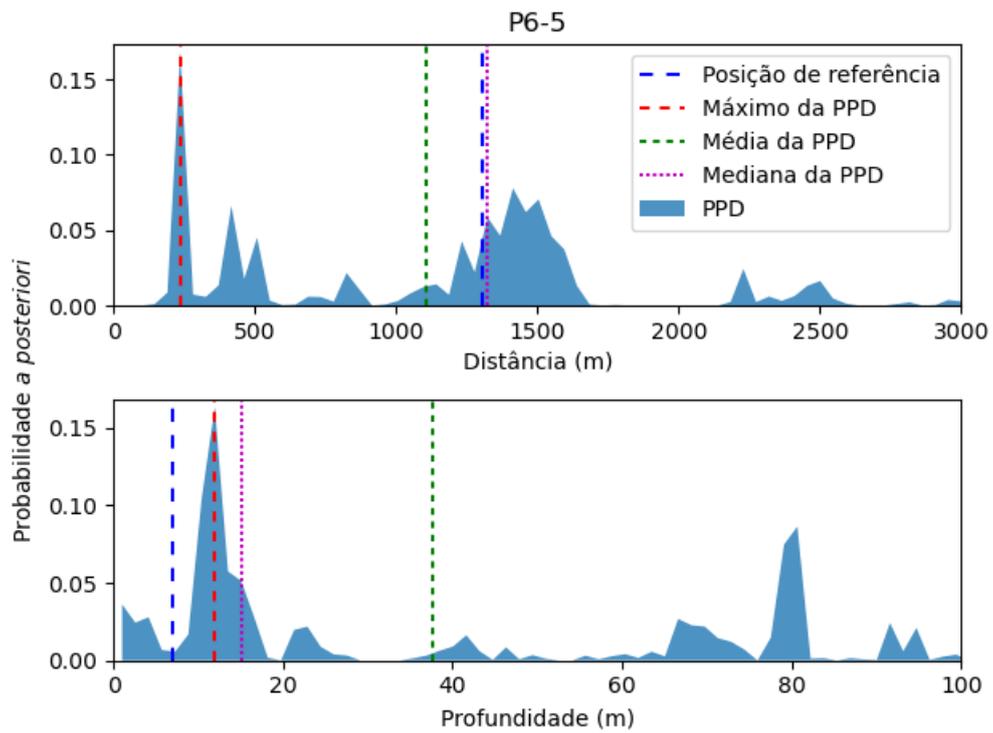


Figura A.12: PPD de posição da fonte para a transmissão P6-5.

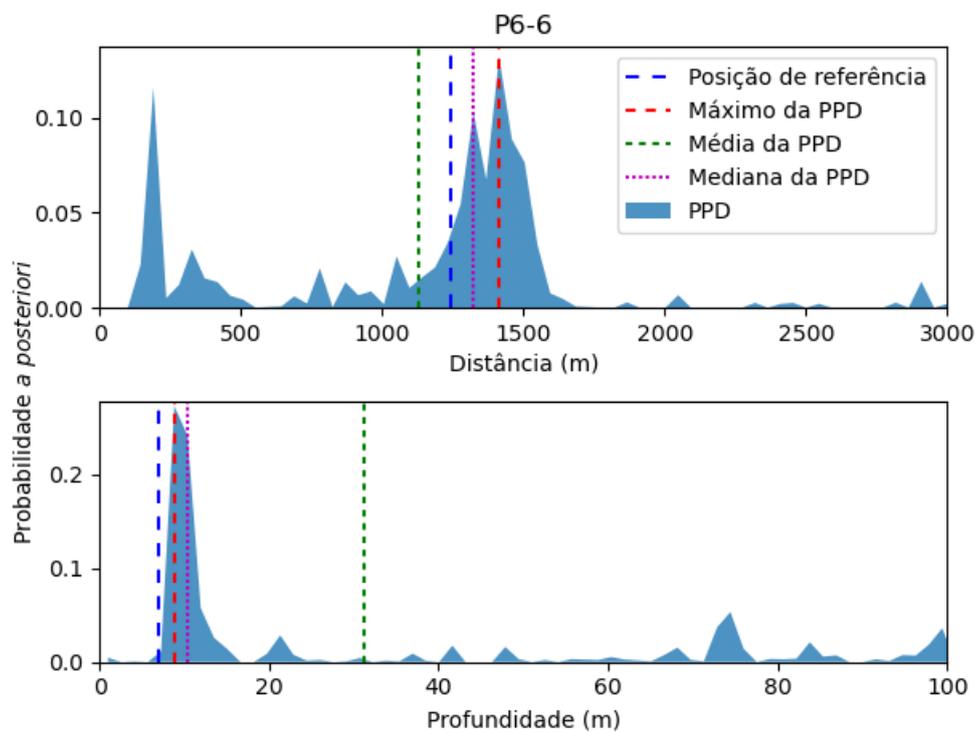


Figura A.13: PPD de posição da fonte para a transmissão P6-6.

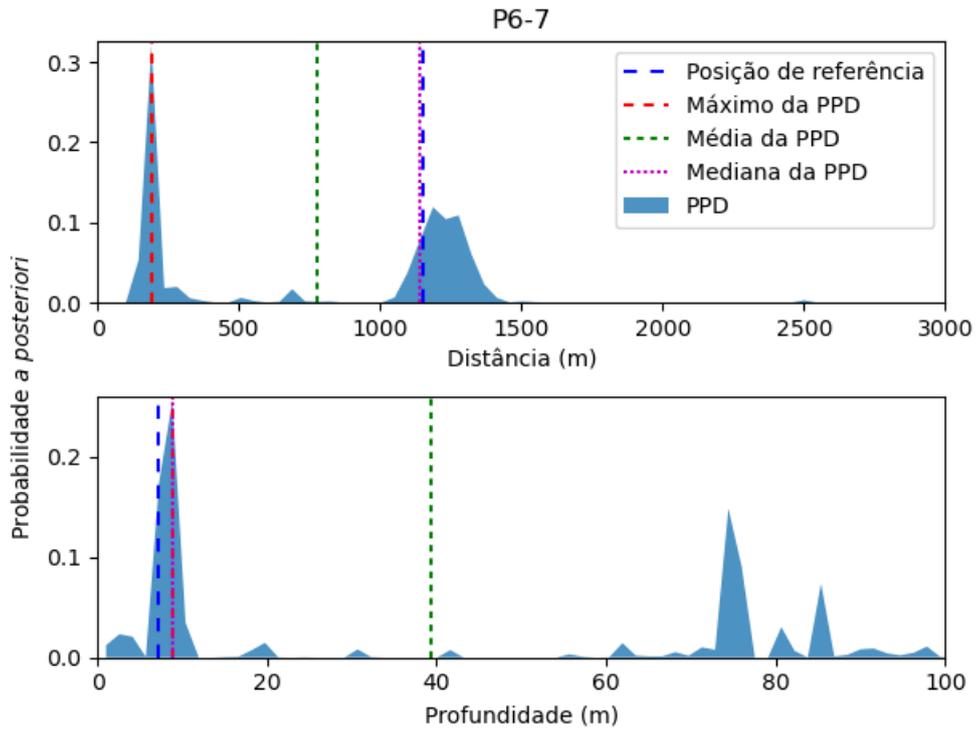


Figura A.14: PPD de posição da fonte para a transmissão P6-7.

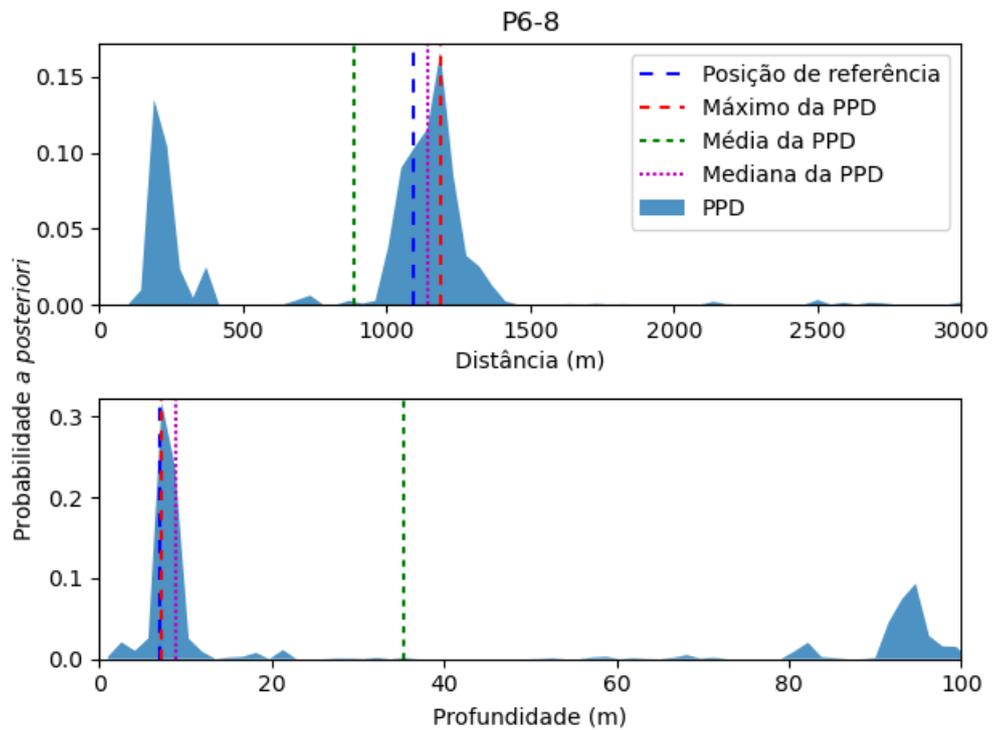


Figura A.15: PPD de posição da fonte para a transmissão P6-8.

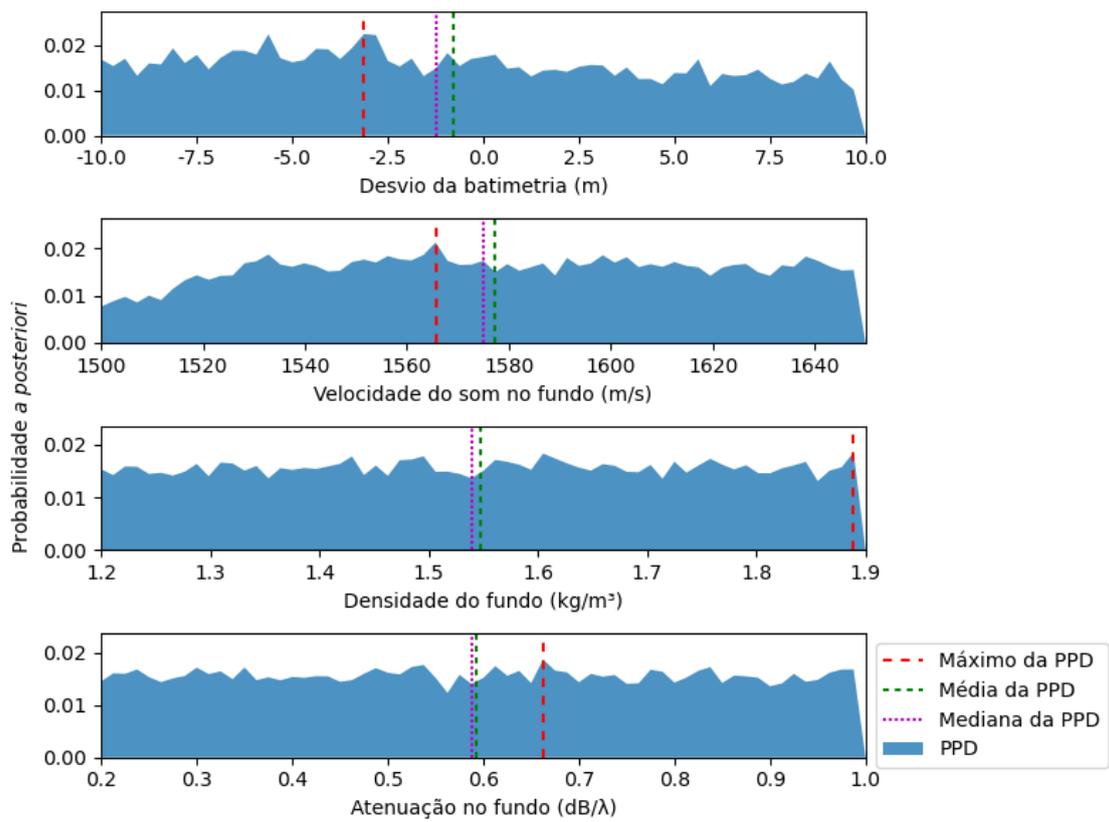


Figura A.16: PPD dos parâmetros do fundo.

Apêndice B

Superfícies de ambiguidade

Superfícies de ambiguidade produzidas pelo MFP usando os três modelos e processando cada transmissão como uma única amostra. Em todas as figuras, o \times indica a posição verdadeira e o círculo a posição estimada.

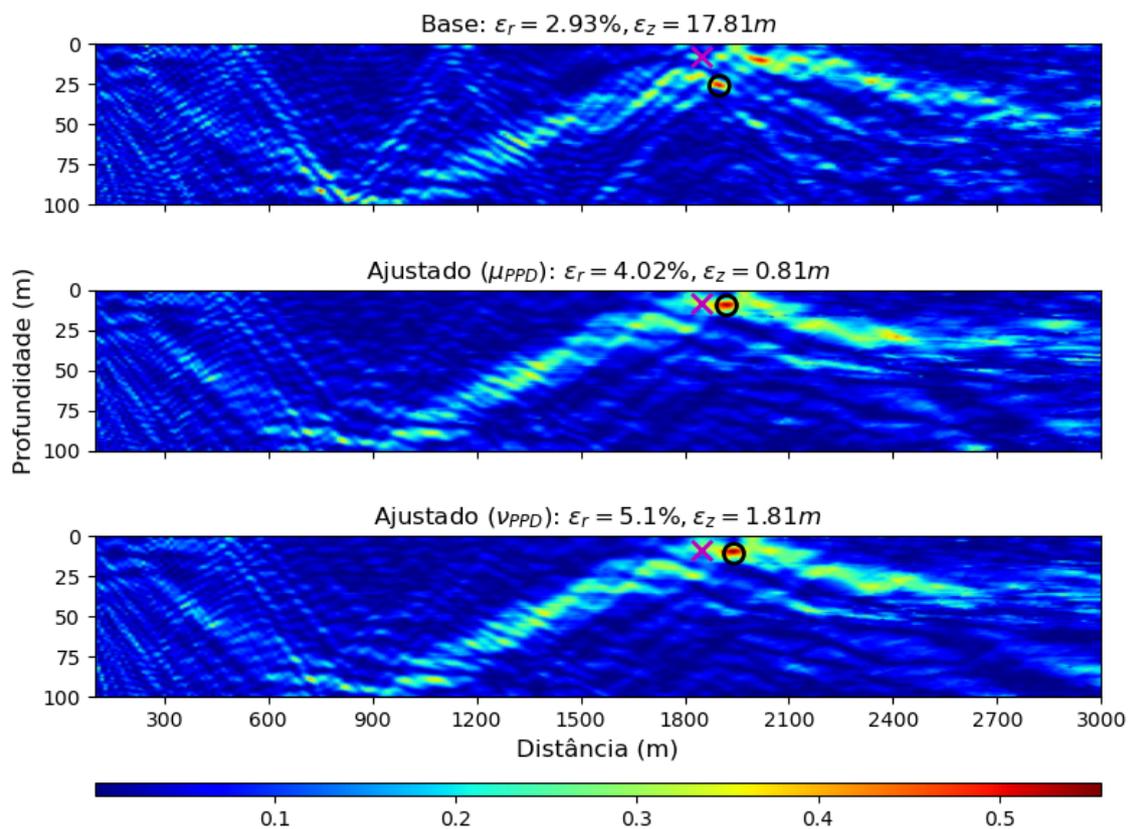


Figura B.1: Superfícies de ambiguidade para a transmissão P2-1.

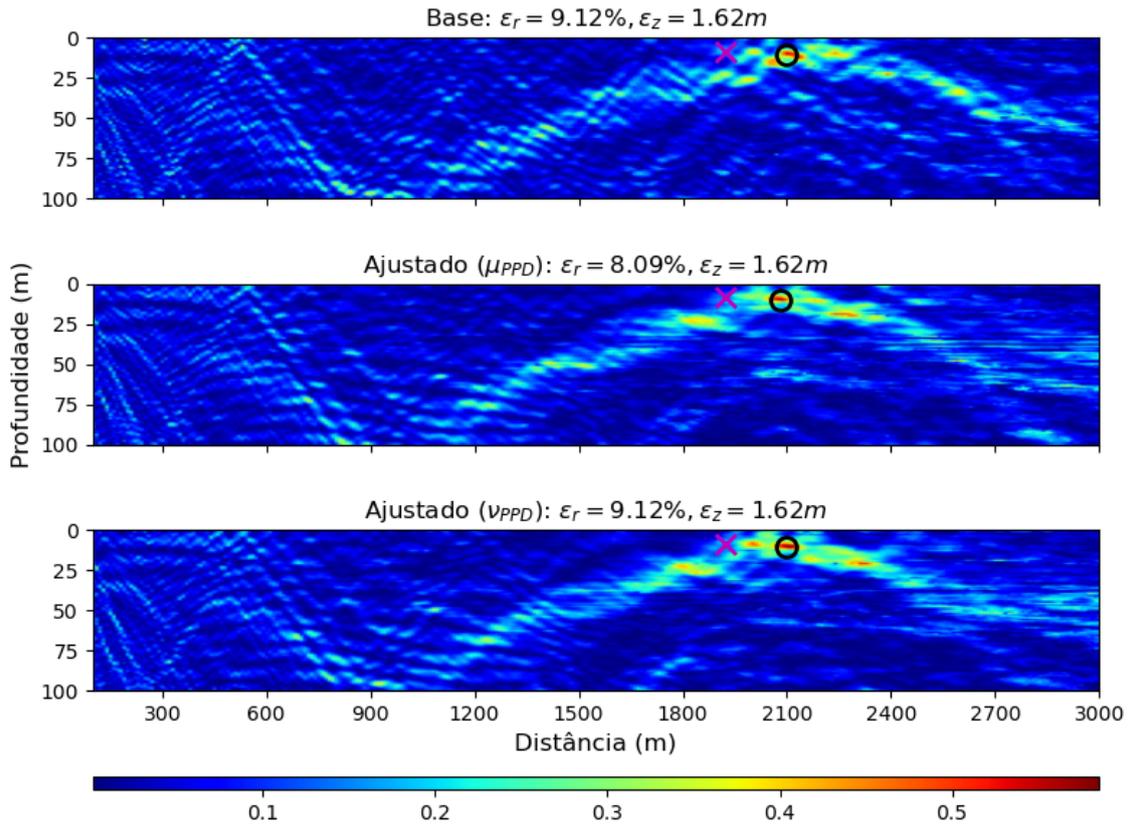


Figura B.2: Superfícies de ambiguidade para a transmissão P2-2.

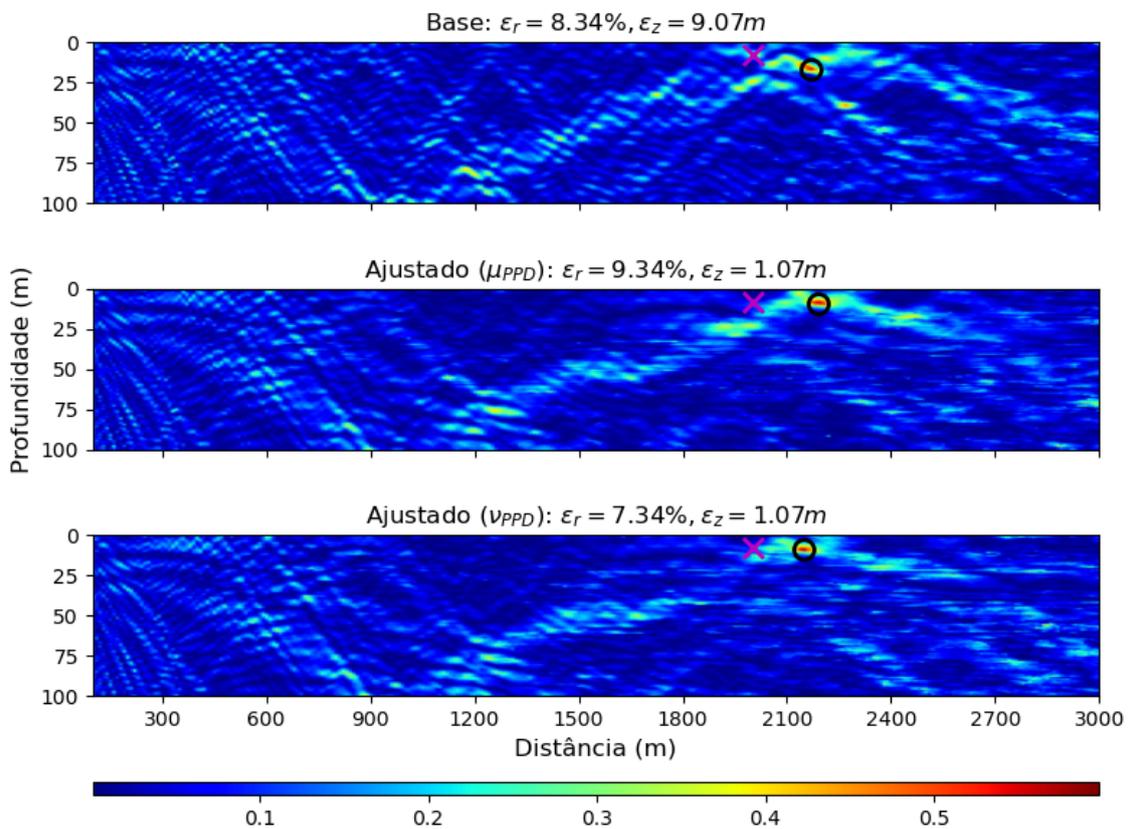


Figura B.3: Superfícies de ambiguidade para a transmissão P2-3.

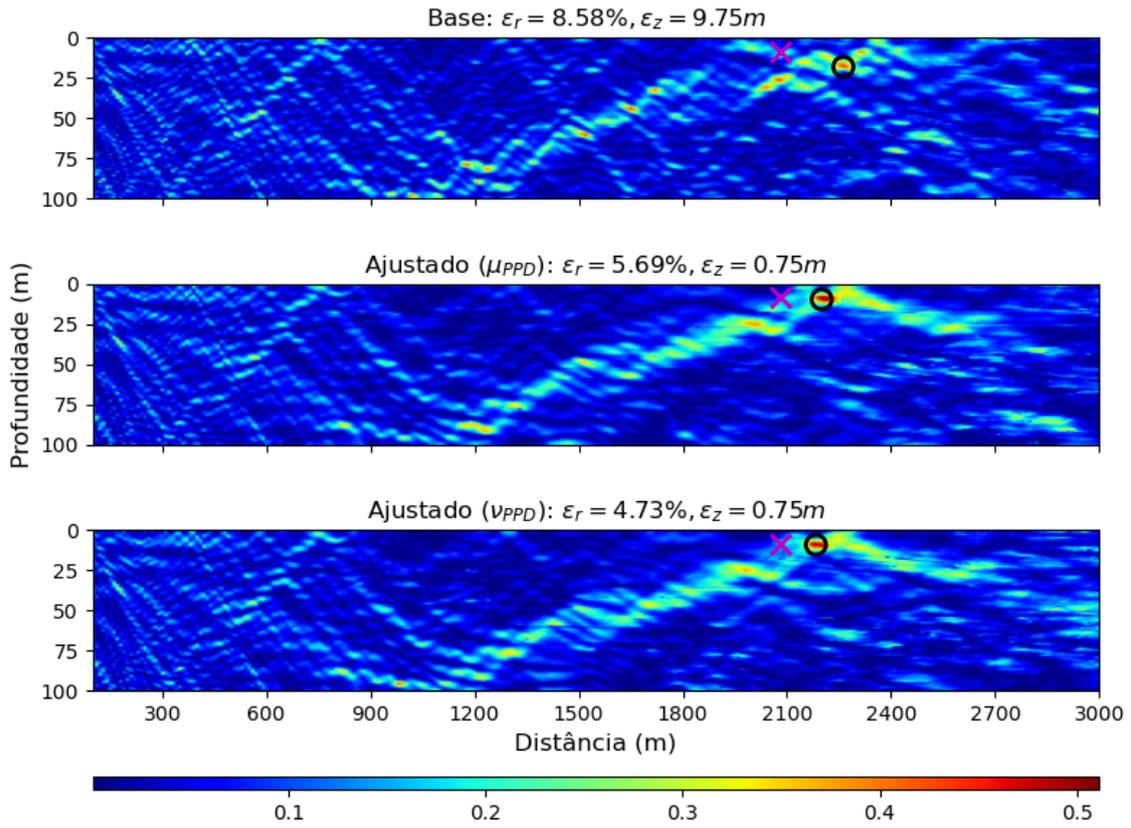


Figura B.4: Superfícies de ambiguidade para a transmissão P2-4.

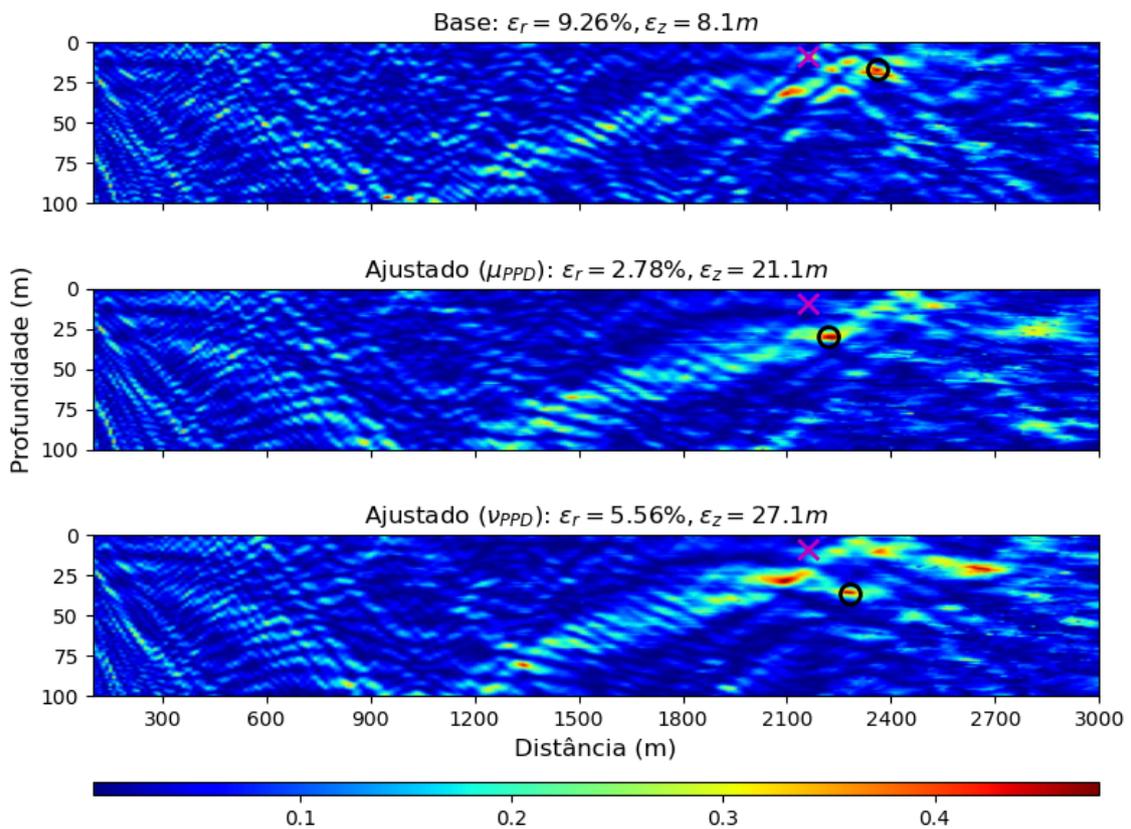


Figura B.5: Superfícies de ambiguidade para a transmissão P2-5.

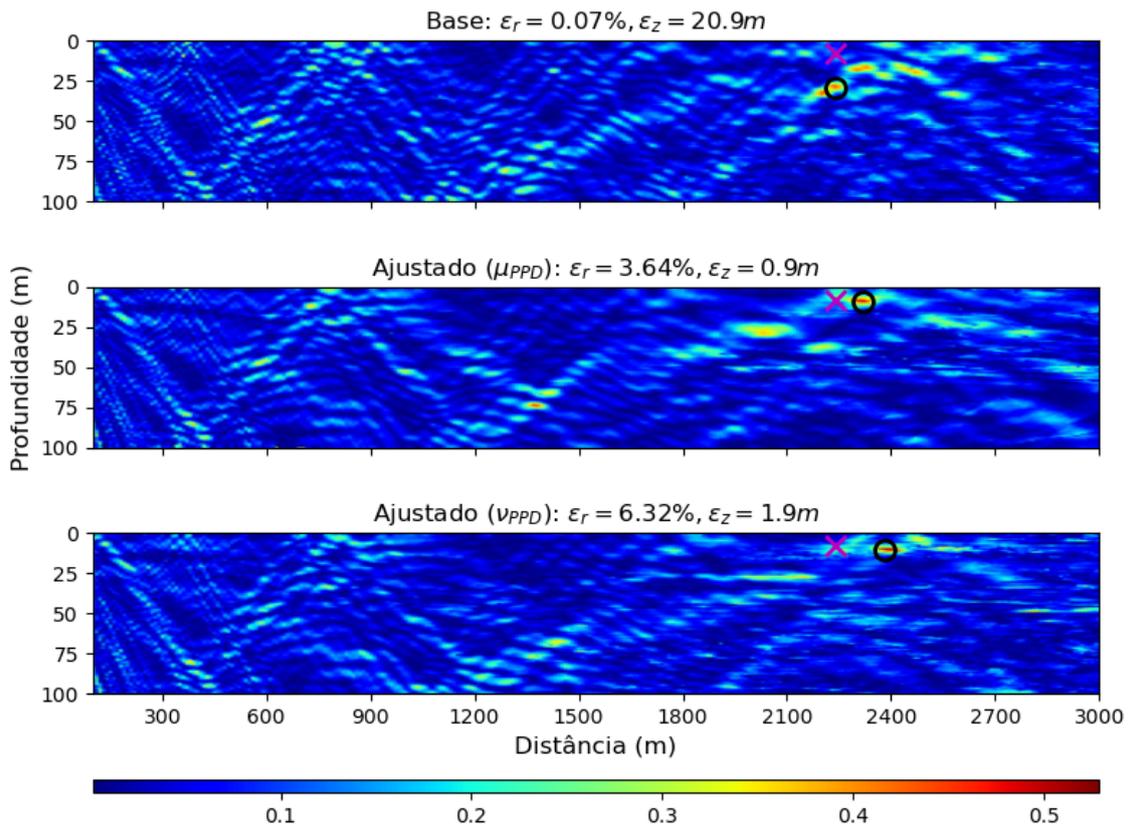


Figura B.6: Superfícies de ambiguidade para a transmissão P2-6.

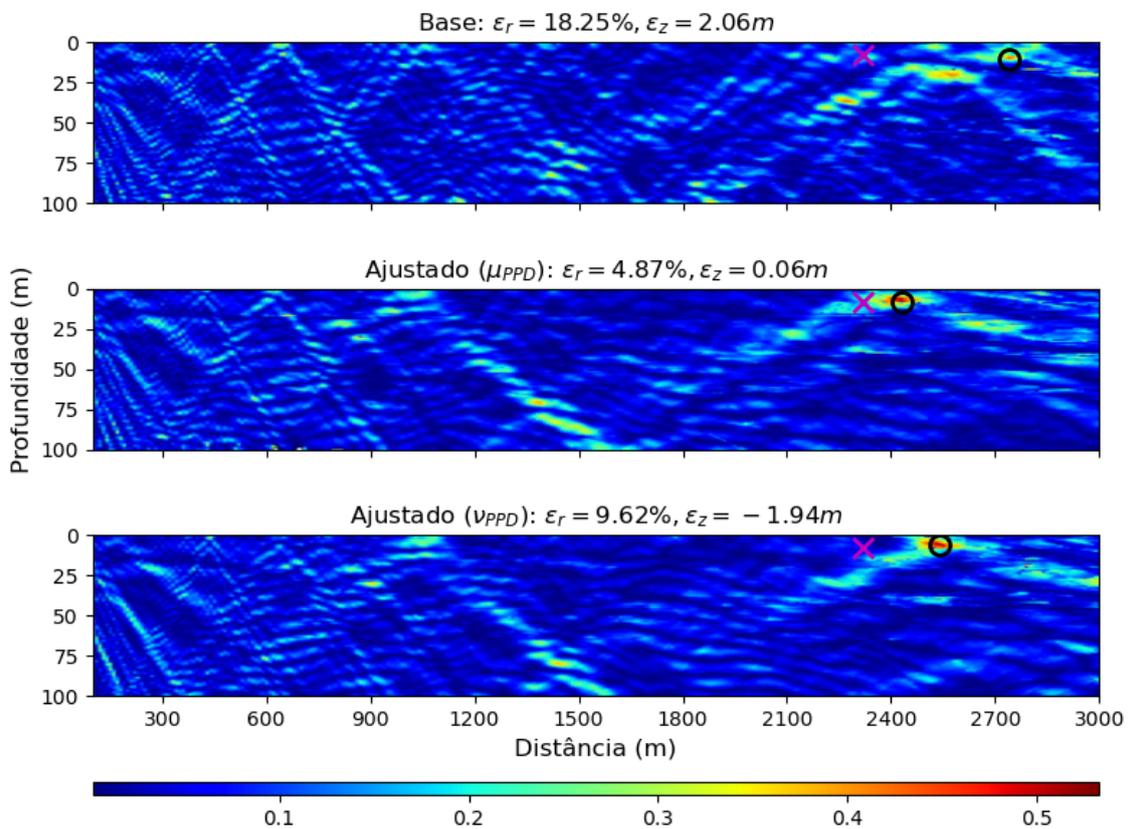


Figura B.7: Superfícies de ambiguidade para a transmissão P2-7.

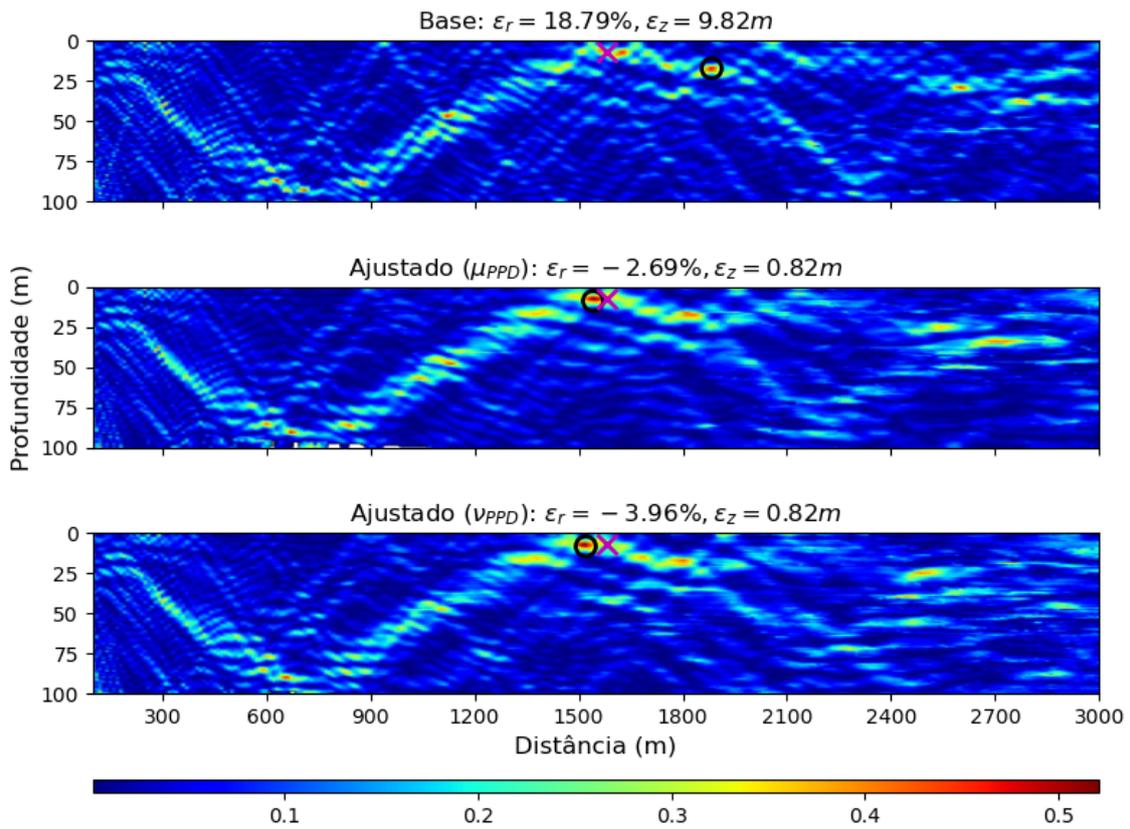


Figura B.8: Superfícies de ambiguidade para a transmissão P6-1.

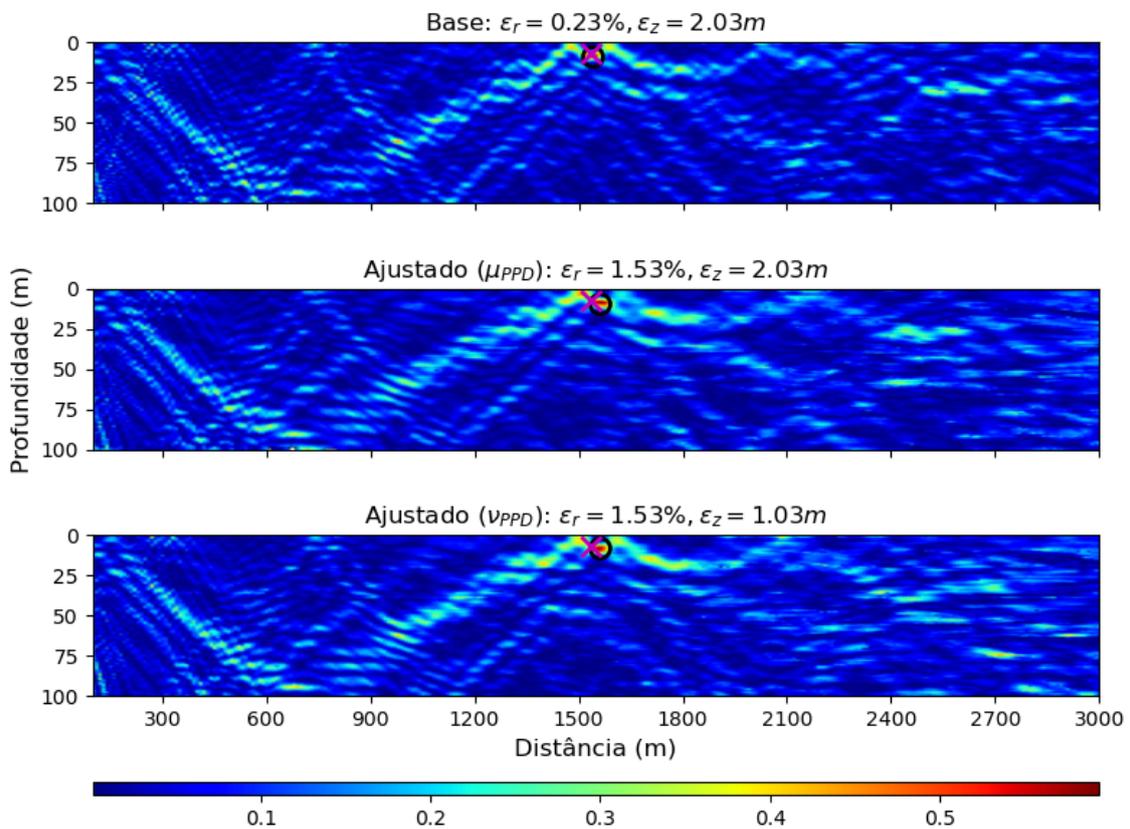


Figura B.9: Superfícies de ambiguidade para a transmissão P6-2.

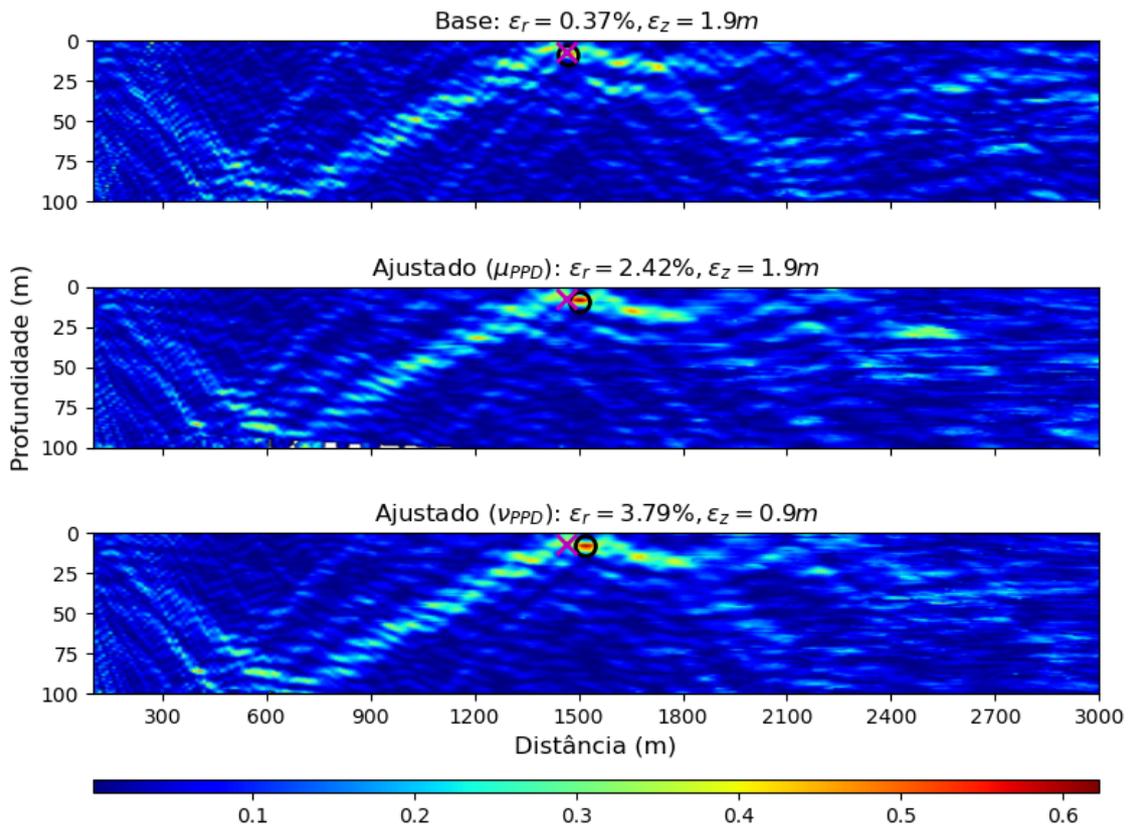


Figura B.10: Superfícies de ambiguidade para a transmissão P6-3.

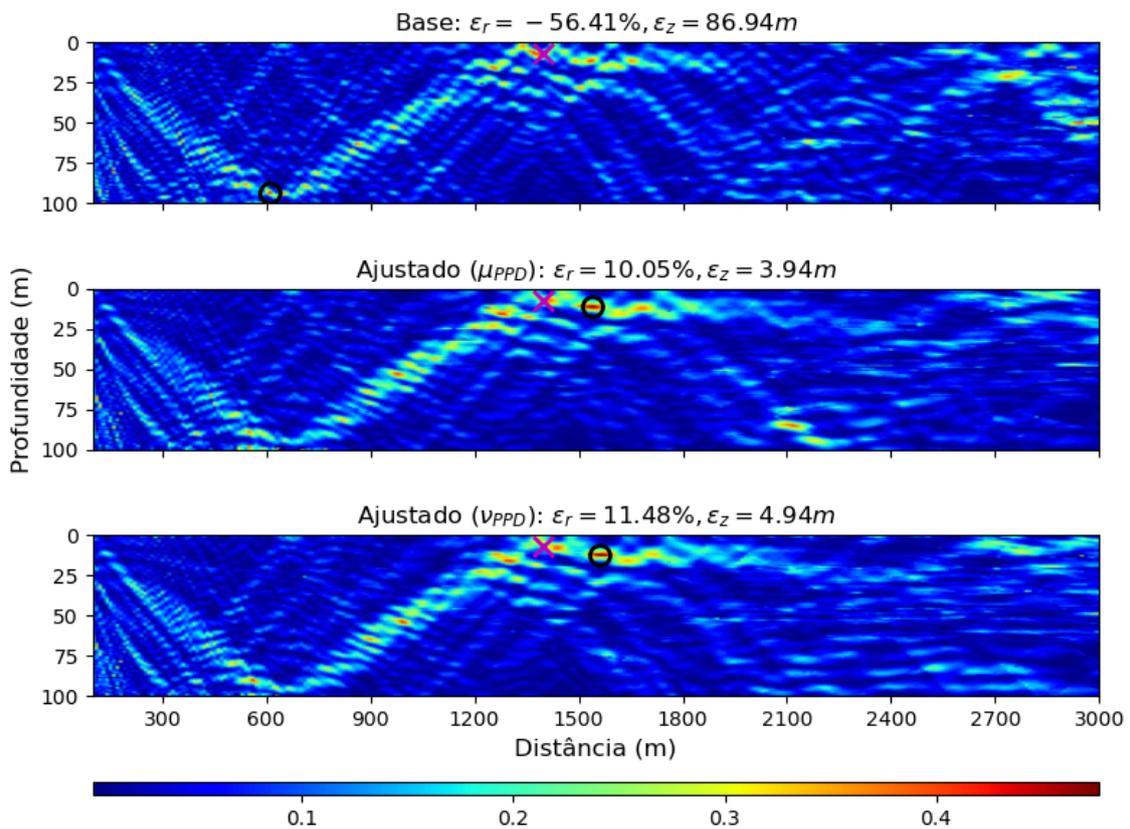


Figura B.11: Superfícies de ambiguidade para a transmissão P6-4.

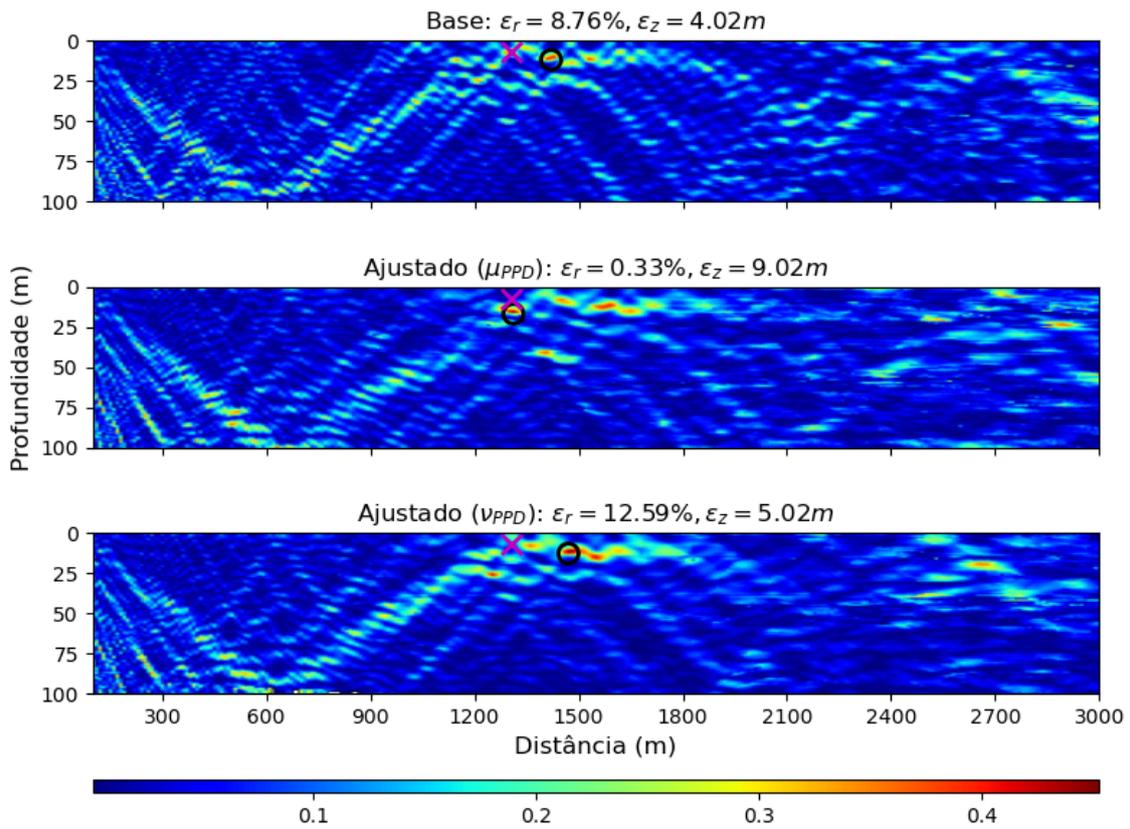


Figura B.12: Superfícies de ambiguidade para a transmissão P6-5.

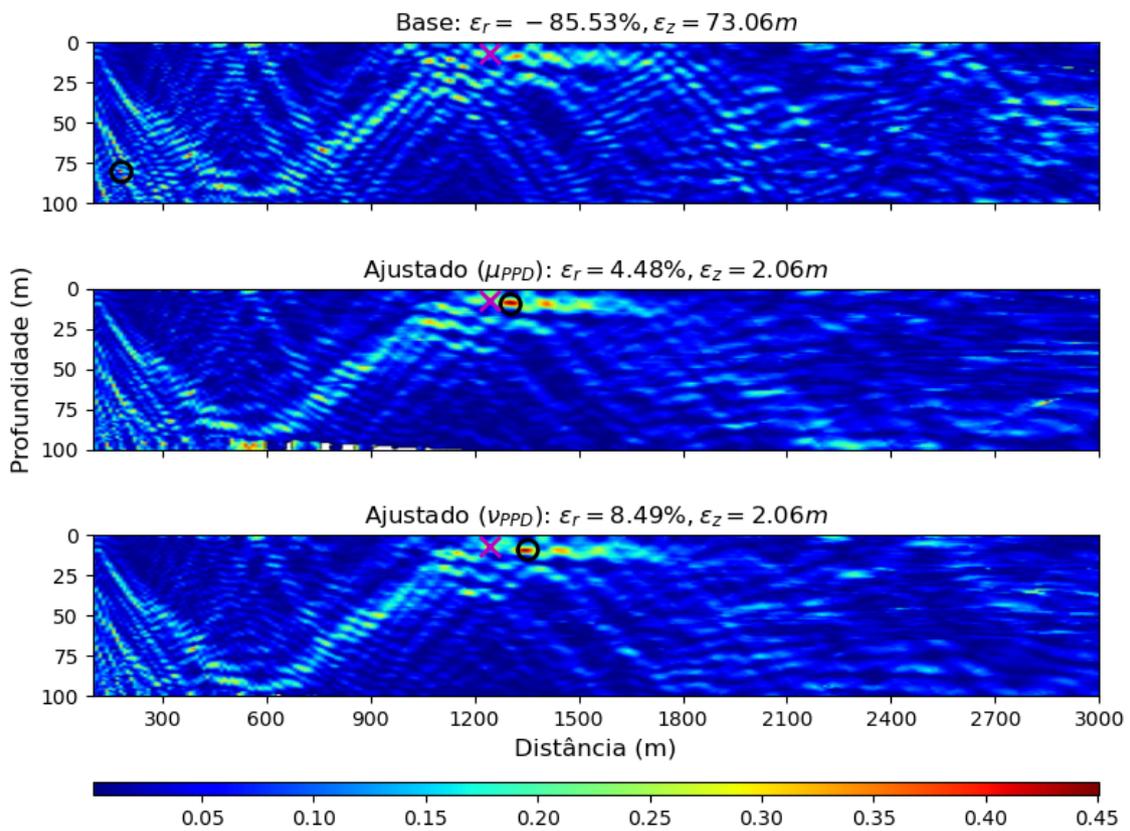


Figura B.13: Superfícies de ambiguidade para a transmissão P6-6.

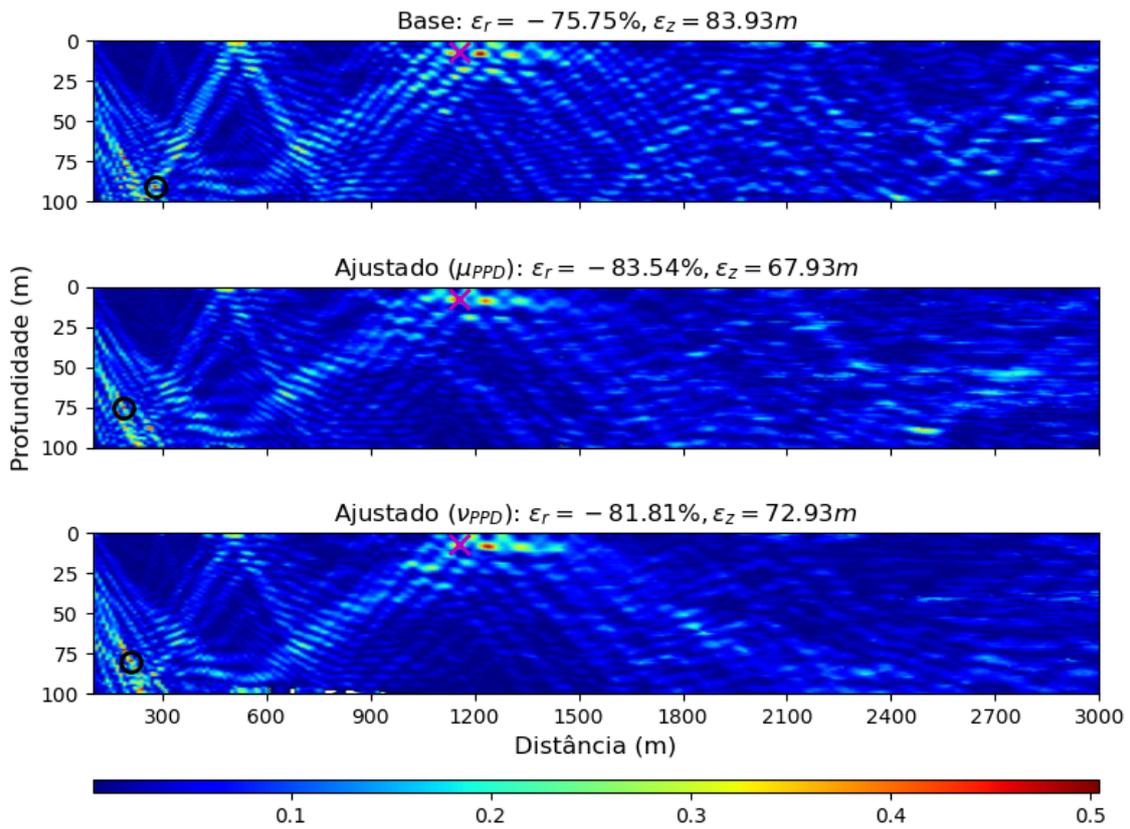


Figura B.14: Superfícies de ambiguidade para a transmissão P6-7.

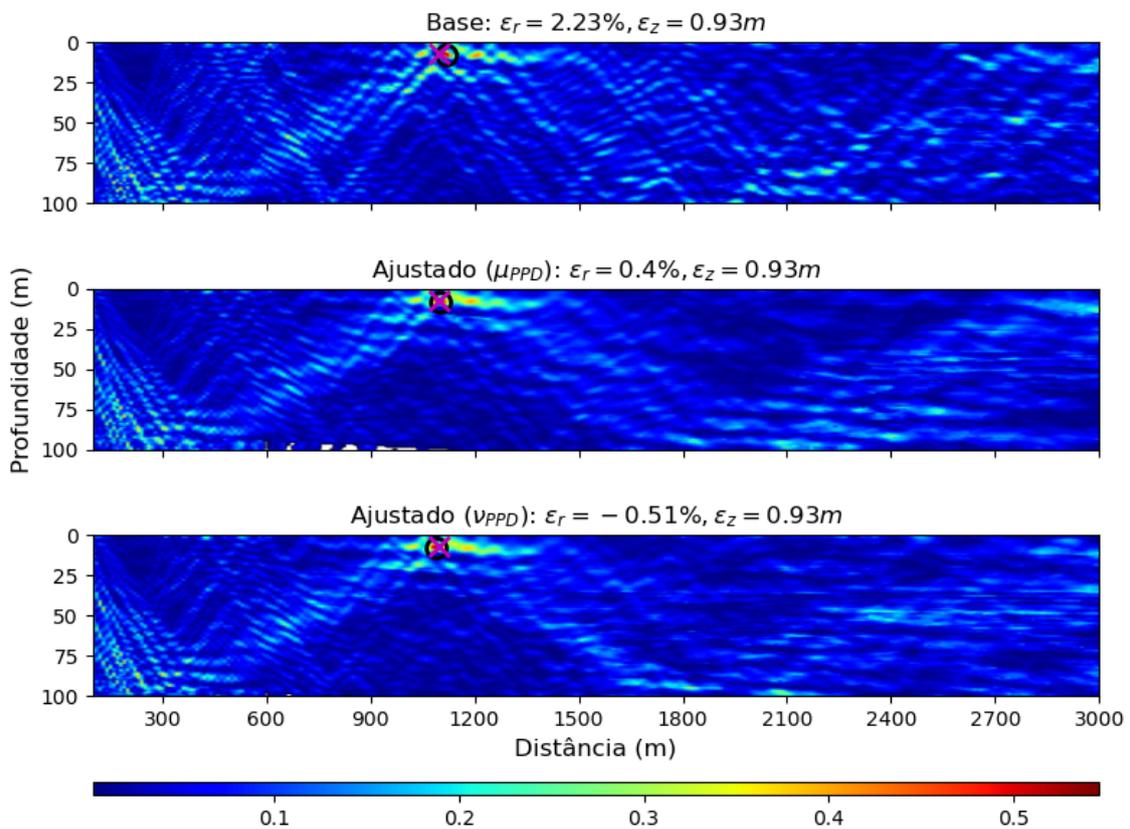


Figura B.15: Superfícies de ambiguidade para a transmissão P6-8.