



DISSERTAÇÃO DE MESTRADO

**LOCALIZAÇÃO DE SENSORES EM SISTEMAS
DE COMUNICAÇÕES ATRAVÉS DA TERRA**

ARTUR ARAÚJO RODRIGUES

BRASÍLIA, DEZEMBRO DE 2018

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

LOCALIZAÇÃO DE SENSORES EM SISTEMAS DE
COMUNICAÇÕES ATRAVÉS DA TERRA

ARTUR ARAÚJO RODRIGUES

ORIENTADOR: ANDRÉ NOLL BARRETO

DISSERTAÇÃO DE MESTRADO EM
ENGENHARIA ELÉTRICA

PUBLICAÇÃO: PPGEE.DM - 716/2018

BRASÍLIA/DF: DEZEMBRO - 2018

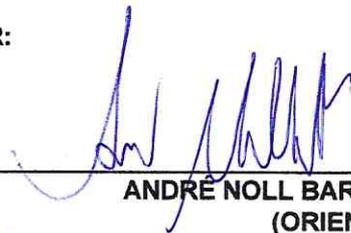
**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**LOCALIZAÇÃO DE SENSORES EM SISTEMAS DE
COMUNICAÇÕES ATRAVÉS DA TERRA**

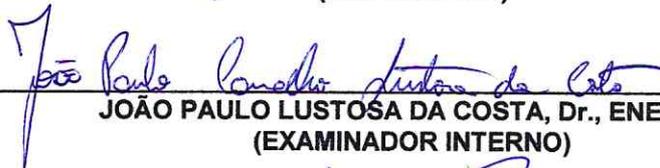
ARTUR ARAÚJO RODRIGUES

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA ELÉTRICA DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE.

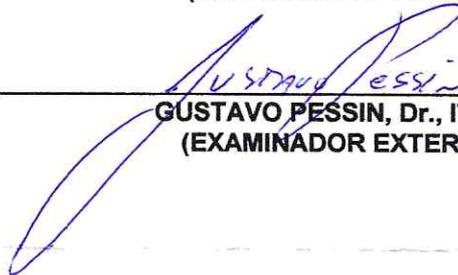
APROVADA POR:



**ANDRÉ NOLL BARRETO, Dr., ENE/UNB
(ORIENTADOR)**



**JOÃO PAULO LUSTOSA DA COSTA, Dr., ENE/UNB
(EXAMINADOR INTERNO)**



**GUSTAVO PESSIN, Dr., ITV-DS
(EXAMINADOR EXTERNO)**

Brasília, 17 de dezembro de 2018.

FICHA CATALOGRÁFICA

RODRIGUES, ARTUR ARAÚJO

Localização de Sensores em Sistemas de Comunicações Através da Terra

[Distrito Federal] 2018.

xvii, 99p., 297 mm (ENE/FT/UnB, Mestre, Engenharia Elétrica, 2018).

Dissertação de Mestrado - Universidade de Brasília.

Faculdade de Tecnologia.

Departamento de Engenharia Elétrica.

1. Comunicações Através da Terra

2. Localização de Sensores

3. Otimização Não Linear

4. Classificação Estatística

I. ENE/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

RODRIGUES., A. A. (2018). Localização de Sensores em Sistemas de Comunicações Através da Terra. Dissertação de Mestrado em Engenharia Elétrica, Publicação PP-GEE.DM - 716/2018, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 99p.

CESSÃO DE DIREITOS

NOME DO AUTOR: Artur Araújo Rodrigues.

TÍTULO DA DISSERTAÇÃO DE MESTRADO: Localização de Sensores em Sistemas de Comunicações Através da Terra.

GRAU / ANO: Mestre / 2018

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

Artur Araújo Rodrigues
QE 13 Conjunto B Casa 21, Guará II
71.050-021 Brasília - DF - Brasil.

*Dedicado às matriarcas,
Dona Terezinha (in memoriam) e Dona Gilina,
que seguem sendo ainda aquela inspiração.*

AGRADECIMENTOS

Agradeço à minha família, alicerce e suporte incondicional em todas as minhas escolhas e desafios. Aos meus queridos pais por terem me ensinado a ter persistência e a ver o valor em cada tarefa. E às minhas queridas monstrixas, por seguirem admirando em mim tudo o que eu não consigo admirar sozinho. Obrigado por estarem lá em cada almoço corrido e cada noite cansada.

Ao meu orientador, Dr. André Noll, por confiar em mim e no meu trabalho em todos esses anos de parceria, sendo sempre uma meio de auxílio e me ajudado com o seu conhecimento, independentemente da distância.

Ao grupo de pesquisa do TTE, por todo o conhecimento trocado, as reuniões esclarecedoras, os feedbacks construtivos e toda a ajuda na integração deste trabalho.

Aos meus queridos amigos Raquel e Rodrigo, pelo apoio inabalável que já atravessa uma década. Obrigado por manterem sempre o carinho e a preocupação de verdadeiros irmãos. Sei que estão muito felizes por mim.

À Vanessa, minha querida companheira de curso e amiga que trilha este mesmo caminho e compreende minhas angústias como ninguém. Obrigado por todo o encorajamento, por ter me dado a mão e caminhado comigo.

À Camila, por ter me segurado em cada tropeço e por ter sorrido para mim em cada conquista. Pela presença em cada momento e a intensidade em cada palavra. O Universo põe pouquíssimas pessoas com a sua luz nesse mundo. Sou extremamente grato por ter você ao meu lado. Deu certo, e você sempre soube.

Ao Litro de Luz, que embora tenha tomado bastante do meu tempo durante esta jornada (e me colocado em alguns becos sem saída!), foi o que me manteve são para chegar até aqui. Hoje termino esta etapa entendendo mais do que nunca que trabalho de verdade é aquele que vem com propósito. Obrigado a todas as equipes com as quais trabalhei nesse período, aos amigos que fiz, às realidades que conheci e aos moradores cujas histórias e sonhos carrego comigo. Existem muitos “Brasís” aí afora. Continuaremos lutando por eles.

Finalmente, agradeço à FINATEC, ao Instituto Tecnológico Vale e à CAPES pelo apoio financeiro que me permitiu investir nesse mestrado.

Artur Araújo Rodrigues

RESUMO

A procura por alternativas de sistemas sem fio para a mineração industrial vem gerando pesquisas importantes no ramo das comunicações subterrâneas. A possibilidade de se utilizar o solo e as rochas como meios de transmissão abriu espaço para o desenvolvimento de técnicas que reduzem a necessidade de uma infraestrutura fixa e permitem que enlaces entre a superfície e as minas subterrâneas sejam arquitetados mais facilmente.

Tais sistemas, chamados de sistemas de comunicação através da terra ou sistemas TTE (*Through-the-Earth*), estão sendo considerados como alternativas viáveis para o desenvolvimento de diversas atividades, principalmente para a otimização de processos operacionais em minas e para a comunicação crítica em situações extremas. Nesse cenário, soluções de posicionamento e referenciamento surgem como necessidades em várias aplicações práticas.

Este trabalho realiza um estudo do problema de localização quando aplicado em um ambiente TTE. Modelos de canal e de perda de potência específicos para comunicações subterrâneas são explorados por meio de técnicas de localização reconhecidas na literatura e avaliados em cenários típicos de aplicações para a mineração.

Por meio de resultados de simulação, as características dos modelos são examinadas enquanto um problema de otimização não linear e o desempenho dos métodos estabelecidos é discutido dentro dos requisitos do TTE. Como proposta, algoritmos viáveis para a estimação de coordenadas relativas são apresentados e aplicados em um processo de classificação referente a identificação de minérios.

ABSTRACT

The search for good alternatives using wireless systems in the mining industry over the past few years has brought up important researches in the field of underground communications. The possibility to use soil and rocks as a transmission medium opened up to the development of techniques that reduce the need for fixed infrastructure and enable links between the surface and the underground mines to be build more easily.

Such systems, called through-the-earth (TTE) communication systems, are being considered as a viable proposition to the deployment of many required activities, mainly for the optimization of processes in mining operation and communications, which are critic in extreme situations. In this scenario, solutions for positioning and referencing emerge as necessities in many practical applications.

This master thesis studies the localization problem when applied to a TTE environment. Channel and path loss models that are specific to underground communications are investigated by known localization techniques and evaluated at typical scenarios for mining applications. Lastly, some viable algorithms are proposed for estimating the coordinates.

By means of simulation results, the characteristics of the models are examined in detail as a nonlinear optimization problem and the methods performances are discussed for the TTE requirements. Lastly, some viable algorithms for estimating relative coordinates are presented and further used during the classification process for ore identification.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	CONTEXTUALIZAÇÃO	1
1.2	DEFINIÇÃO DO PROBLEMA E OBJETIVOS	2
1.3	CONTRIBUIÇÕES DO TRABALHO	3
1.4	ORGANIZAÇÃO DO TEXTO	3
2	REVISÃO BIBLIOGRÁFICA	5
2.1	COMUNICAÇÕES ATRAVÉS DA TERRA	5
2.1.1	Condições de Comunicações em Minas	5
2.1.2	Sistemas de Comunicações TTE	6
2.2	LOCALIZAÇÃO EM REDES DE SENSORES	8
2.2.1	Técnicas de Medição	9
2.2.2	Algoritmos para Localização	12
2.2.3	Formulação do Problema	15
2.3	CLASSIFICAÇÃO ESTATÍSTICA	17
2.3.1	Escolha de Classificadores	20
3	CARACTERIZAÇÃO DO CENÁRIO TTE	23
3.1	MODELAGEM DO CANAL	23
3.1.1	Modelo de Campo Magnético	25
3.1.2	Modelo de Canal	26
3.2	MODELO DE PERDA DE PROPAGAÇÃO	28
3.2.1	Derivação do Modelo Teórico	28
3.2.2	Aproximação para o Modelo	29
4	TÉCNICAS DE LOCALIZAÇÃO	33
4.1	LOCALIZAÇÃO COMO UM PROBLEMA DE OTIMIZAÇÃO	33
4.2	MÉTODO DE GAUSS-NEWTON	35
4.2.1	Método de Levenberg-Marquardt	38
4.2.2	Aproximação Numérica: Método da Secante	42
4.3	RECOZIMENTO SIMULADO (<i>SIMULATED ANNEALING</i>)	46
4.3.1	Descrição da Técnica	47

5	RESULTADOS DE SIMULAÇÃO	54
5.1	CENÁRIO DE SIMULAÇÃO	54
5.1.1	Estrutura do Simulador	54
5.1.2	Parâmetros de Simulação	57
5.2	RESULTADOS DE DESEMPENHO	59
5.2.1	Desempenho geral dos modelos	60
5.2.2	Contribuição do Ângulo	67
5.2.3	Problema da Estimativa Inicial	72
6	APLICAÇÃO: IDENTIFICAÇÃO DE ZONAS DE MINÉRIOS	79
6.1	DESCRIÇÃO DO PROBLEMA	79
6.2	MÉTODO DOS K-ÉSIMOS VIZINHOS MAIS PRÓXIMOS	81
6.2.1	Formalização da Técnica	83
6.3	RESULTADOS DE APLICAÇÃO	85
7	CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS	90
	REFERÊNCIAS BIBLIOGRÁFICAS	93

LISTA DE TABELAS

3.1	Zonas de campo no vácuo e em meio condutivo.	24
5.1	Parâmetros de âncoras e <i>tags</i> para a simulação.	57
5.2	Parâmetros do canal TTE para a simulação.	57

LISTA DE FIGURAS

2.1	Representação esquemática de enlace físico de sistema de transmissão TTE operando em <i>uplink</i> . Dimensões típicas de antes vão de centímetros a dezenas de metros.	7
2.2	Representação esquemática de uma rede de sensores com múltiplas âncoras e <i>tags</i>	10
2.3	Categorias consideradas para classificação de algoritmos de localização.	13
2.4	Esquema simplificado da técnica de trilateração. Ao menos 3 vértices não colineares são necessários para determinação da posição em \mathbb{R}^2	16
2.5	Técnica de trilateração quando na presença de erros de medição. A região sombreada representa todos os conjuntos de coordenadas possíveis para uma <i>tag</i> desconhecida.	17
2.6	Esquemático de um processo de classificação genérico.	19
3.1	Geometria para $\hat{\mathbf{r}}$ e $\hat{\boldsymbol{\theta}}$ para duas antenas <i>loop</i> circulares. O ângulo ϕ é resultado das rotações nos eixos \mathbf{x}' e \mathbf{y}'	27
3.2	Comparativo entre TTE e o modelo aproximado para a perda de potência para uma dada variação na distância.	31
3.3	Comparativo entre TTE e o modelo aproximado para a perda de potência para um dado ângulo θ	31
4.1	Comportamento do algoritmo de Recozimento Simulado para uma função genérica.	48
5.1	Diagrama de blocos da estrutura de simulação.	55
5.2	Topologia de cenário aleatório de localização gerado em simulador.	58
5.3	Topologia de cenário aleatório de localização gerado em simulador (vista superior).	59
5.4	Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no número de nós âncora em diferentes distâncias d da estimativa inicial e diferentes desvios padrões s da medida RSS.	61
5.5	Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no desvio padrão da medida RSS para diferentes números m de nós âncora ($d = 0$ m).	62

5.6	Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no erro máximo da estimativa inicial para diferentes números m de nós âncora ($s = 0$ dB).	62
5.7	Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no número de nós âncora e estimativas iniciais geradas aleatoriamente (erro de medição RSS nulo).	63
5.8	Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no desvio padrão da medida RSS e estimativas iniciais geradas aleatoriamente ($m = 30$ âncoras).	64
5.9	Desempenho comparativo entre o modelo TTE e suas aproximações para um aumento no número de nós âncora ($d = 10$ m e $s = 20$ dB).	65
5.10	Desempenho comparativo entre o modelo TTE e suas aproximações para um aumento no desvio padrão da medida RSS ($d = 0$ m e $m = 30$ âncoras).	65
5.11	Desempenho comparativo entre o modelo TTE e suas aproximações para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$ âncoras).	66
5.12	Desempenho entre o modelo TTE e suas aproximações para estimativas geradas aleatoriamente em comparação com estimativas geradas para $d = 10$ m (erro de medição RSS nulo).	67
5.13	Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no número de âncoras (erro de medição RSS nulo e erro de estimativa inicial nulos).	69
5.14	Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no desvio padrão da medida RSS ($d = 0$ m e $m = 30$ âncoras).	69
5.15	Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no desvio padrão da medida RSS ($d = 10$ m e $m = 30$ âncoras).	70
5.16	Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no desvio padrão da medida RSS (estimativas iniciais aleatórias e $m = 30$ âncoras).	71
5.17	Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$ âncoras).	71
5.18	Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no número de âncoras com $d = 10$ m e $s = 20$ dB.	72
5.19	Desempenho comparativo entre os métodos LM e SA com ângulos desconhecidos para um aumento no número de âncoras e estimativas iniciais geradas aleatoriamente ($s = 0$ dB).	74

5.20	Desempenho comparativo entre os métodos LM e SA com ângulos fixos para um aumento no número de âncoras e estimativas iniciais geradas aleatoriamente ($s = 0$ dB).	74
5.21	Desempenho comparativo entre os métodos LM e SA com ângulos ortogonais para um aumento no número de âncoras e estimativas iniciais geradas aleatoriamente ($s = 0$ dB).	75
5.22	Desempenho comparativo entre os métodos LM e SA com ângulos desconhecidos para um aumento no desvio padrão da medição RSS e estimativas iniciais geradas aleatoriamente ($m = 30$).	76
5.23	Desempenho comparativo entre os métodos LM e SA com ângulos fixos para um aumento no desvio padrão da medição RSS e estimativas iniciais geradas aleatoriamente ($m = 30$).	76
5.24	Desempenho comparativo entre os métodos LM e SA com ângulos ortogonais para um aumento no desvio padrão da medição RSS e estimativas iniciais geradas aleatoriamente ($m = 30$).	77
5.25	Desempenho comparativo entre os métodos LM e SA com ângulos desconhecidos para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$).	77
5.26	Desempenho comparativo entre os métodos LM e SA com ângulos fixos para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$).	78
5.27	Desempenho comparativo entre os métodos LM e SA com ângulos ortogonais para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$).	78
6.1	Identificação de zonas de minério e zonas estéreis.	80
6.2	Processo de decisão para um algoritmo KNN genérico.	82
6.3	Ponderação pelo erro de medida na perda de potência em relação a perda de potência estimada para uma âncora.	84
6.4	Seção retangular de uma região de fronteira entre minério e material estéril marcada por <i>tags</i>	86
6.5	Erro de classificação estimado por validação cruzada para diferentes valores de K	87
6.6	Identificação de zonas de minério com classificador KNN para $K = 9$	87
6.7	Identificação de zonas de minério com classificador KNN para $K = 3$	88
6.8	Identificação de zonas de minério com classificador KNN para $K = 31$	88

LISTA DE SÍMBOLOS

μ	permeabilidade magnética
ϵ	permissividade elétrica
σ	condutividade elétrica
\mathbf{H}	campo magnético
m	número de nós do tipo âncora
n	número de nós do tipo <i>tag</i>
$\boldsymbol{\alpha}_i$	vetor de parâmetros desconhecidos da <i>i</i> -ésima <i>tag</i>
d_{ij}	distância euclidiana calculada entre os pontos <i>i</i> e <i>j</i>
s_i	<i>i</i> -ésimo nó da rede de sensores
S	conjunto de todos os nós da rede de sensores
r_{ij}	distância medida entre os pontos <i>i</i> e <i>j</i>
Ω	frequência angular
δ	profundidade pelicular
λ_{rocha}	comprimento de onda em meio mineral
λ_0	comprimento de onda no vácuo
m_d	momento magnético
N_{tx}	número de voltas do <i>loop</i> transmissor
I_{tx}	corrente elétrica tonal na antena transmissora (valor RMS)
S_{tx}	área do <i>loop</i> transmissor
P_{tx}	potência dissipada no <i>loop</i> transmissor
R_{tx}	resistência do <i>loop</i> transmissor
\mathbf{H}_{qe}	campo magnético quase estático
θ	ângulo de inclinação entre o ponto indutor e o ponto de indução
$\hat{\mathbf{r}}$	vetor unitário em coordenadas esféricas na direção radial
$\hat{\boldsymbol{\theta}}$	vetor unitário em coordenadas esféricas na direção elevacional
k_{rocha}	número de onda em meio mineral
T	distância normalizada pela profundidade pelicular
$Z(\Omega)$	impedância de transferência fasorial entre <i>loops</i>
$I_{rx}(\Omega)$	corrente tonal fasorial na antena receptora
$V_{rx}(\Omega)$	tensão induzida fasorial nos terminais da antena receptora
S_{rx}	área do <i>loop</i> receptor
N_{rx}	número de voltas do <i>loop</i> receptor

φ	ângulo entre o campo magnético e o eixo do <i>loop</i> ortogonal a seu plano
\mathbf{H}_r	componente do campo magnético em \hat{r}
\mathbf{H}_θ	componente do campo magnético em $\hat{\theta}$
ϕ	ângulo de azimute entre o ponto indutor e o ponto de indução
\mathbf{x}	vetor unitário em x em coordenadas cartesianas
\mathbf{x}'	vetor unitário criado por rotação em x de θ e ϕ
\mathbf{y}	vetor unitário em y em coordenadas cartesianas
\mathbf{y}'	vetor unitário criado por rotação em y de θ e ϕ
z	vetor unitário em z em coordenadas cartesianas
θ_x	ângulo de rotação em \mathbf{x}'
θ_y	ângulo de rotação em \mathbf{y}'
$m_d(\Omega)$	momento magnético fasorial
$Z(T)$	impedância de transferência em função da distância normalizada
G_r^{tx}	ganho normalizado para a antena de transmissão na direção \hat{r}
G_r^{rx}	ganho normalizado para a antena de recepção na direção \hat{r}
G_θ^{tx}	ganho normalizado para a antena de transmissão na direção $\hat{\theta}$
G_θ^{rx}	ganho normalizado para a antena de recepção na direção $\hat{\theta}$
\mathbf{F}_r	função de transferência do canal de propagação em \hat{r}
\mathbf{F}_θ	função de transferência do canal de propagação em $\hat{\theta}$
P_{rx}	potência entregue ao <i>loop</i> receptor
R_{rx}	resistência do <i>loop</i> receptor
Φ_{tx}	abertura específica da antena transmissora
Φ_{rx}	abertura específica da antena receptora
l	raio do <i>loop</i> da antena
M	massa da antena
ρ_l	densidade de massa do fio
σ_l	condutividade elétrica do fio
PL	perda de potência em dB calculada para um ponto a distância r e ângulos θ_x e θ_y
χ	variável aleatória de distribuição gaussiana
s	desvio padrão do erro na medida da perda de potência
u	valor absoluto de \mathbf{F}_r
v	valor absoluto de \mathbf{F}_θ
ψ	fase de \mathbf{F}_r
ζ	fase de \mathbf{F}_θ
PL_{aprox}	perda de potência aproximada em dB para um ponto a distância r e ângulos θ_x e θ_y

a, b, c	parâmetros derivados do modelo de canal para modelo aproximado de perda de potência
$G(\boldsymbol{\alpha})$	função objetivo da perda de potência para parâmetros $\boldsymbol{\alpha}$
$\mathbf{g}(\boldsymbol{\alpha})$	resíduos de erro da perda de potência para parâmetros $\boldsymbol{\alpha}$
\widetilde{PL}_i	perda de potência em dB medida para a i -ésima âncora
\mathbf{p}	vetor de incrementos para $\boldsymbol{\alpha}$
$\mathbf{G}'(\boldsymbol{\alpha})$	derivada de primeira ordem de $G(\boldsymbol{\alpha})$
$\mathbf{G}''(\boldsymbol{\alpha})$	derivada de segunda ordem de $G(\boldsymbol{\alpha})$
$l(\mathbf{p})$	aproximação de \mathbf{g} na vizinhança de $\boldsymbol{\alpha}$
$\mathbf{J}(\boldsymbol{\alpha})$	matriz do Jacobiano da perda de potência para parâmetros $\boldsymbol{\alpha}$
$L(\mathbf{p})$	aproximação de G na vizinhança de $\boldsymbol{\alpha}$
$\mathbf{L}'(\mathbf{p})$	derivada de primeira ordem da aproximação $L(\mathbf{p})$
$\mathbf{L}''(\mathbf{p})$	derivada de segunda ordem da aproximação $L(\mathbf{p})$
\mathbf{p}_{gn}	vetor de incrementos obtido pelo método de Gauss-Newton
γ	fator de amortecimento para algoritmo de Levenberg-Marquardt
ρ	taxa de ganho para algoritmo de Levenberg-Marquardt
\mathbf{p}_{lm}	vetor de incrementos obtido pelo método de Levenberg-Marquardt
ε	critérios de parada para algoritmos de otimização
k	contador de iterações para algoritmos de otimização
ν	variável de ponderação do amortecimento no método de Levenberg-Marquardt
\mathbf{B}	aproximação da matrix do Jacobiano $\mathbf{J}(\boldsymbol{\alpha})$
b_{ij}	elemento da matriz \mathbf{B} para coordenadas i e j
κ	fator de ajuste do vetor de incrementos \mathbf{p}
$\Delta(G)$	variação da função objetivo $G(\boldsymbol{\alpha})$ entre duas iterações consecutivas
$\mathfrak{B}(\cdot)$	função de aceitação no algoritmo SA
\mathfrak{T}	temperatura de controle no algoritmo SA
$\mathfrak{N}(\cdot)$	função de vizinhança no algoritmo SA
\mathfrak{S}	taxa de aceitação de soluções ruins no algoritmo SA
\mathfrak{N}	número de perturbações no algoritmo SA
$q_{sucessos}$	número de iterações em sentido descendente no algoritmo SA
$\text{Proj}(\cdot)$	operador de projeção de ponto sobre o domínio
d	raio da região circular contendo a estimativa inicial
W_i	amplitude do sinal recebido na antena i

GLOSSÁRIO

ANN	<i>Artificial Neural Network</i>
AOA	<i>Angle Of Arrival</i>
BNDES	Banco Nacional de Desenvolvimento Econômico e Social
DV-HOP	<i>Distance Vector Hop</i>
ELFs	<i>Extremely Low Frequencies</i>
Finep	Financiadora de Estudos e Projetos
GN	Gauss-Newton
GPS	<i>Global Positioning System</i>
KDE	<i>Kernel Density Estimation</i>
KNN	<i>K Nearest Neighbours</i>
LM	Levenberg-Marquardt
LS	<i>Least Squares</i>
MDS	<i>Multidimensional Scaling</i>
MIC	Meio Infinito Condutivo
MINER	<i>Mine Improvement and New Emergency Response</i>
MRC	Maximal Ratio Combining
NIOSH	<i>National Institute for Occupational Safety and Health</i>
RF	Radiofrequência
REQM	Raiz do Erro Quadrático Médio
RFID	<i>Radio-Frequency Identification</i>
RMS	<i>Root Mean Square</i>
RMSE	<i>Root Mean Square Error</i>
RSS	<i>Received Signal Strength</i>
SA	<i>Simulated Annealing</i>
SDP	<i>Semidefinite Programming</i>
SVM	<i>Support Vector Machine</i>
TDOA	<i>Time Difference Of Arrival</i>
TOA	<i>Time Of Arrival</i>
TTA	<i>Through-The-Air</i>
TTE	<i>Through-The-Earth</i>
TTW	<i>Through-The-Wire</i>
WiFi	<i>Wireless Fidelity</i>

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Aplicações que utilizam informações sobre coordenadas geográficas têm ganhado cada vez mais espaço. Ainda mais do que para uso pessoal, processos de localização em redes sem fio têm se mostrado essenciais para o desenvolvimento comercial e industrial.

Englobadas na chamada Indústria 4.0 [1], novas tecnologias para a automação de equipamentos, otimização de logística, gestão de ativos, monitoramento e segurança vêm trazendo diversos avanços na área de telecomunicações. Assuntos relacionados a posicionamento e localização são hoje valiosos objetos de pesquisa de grandes empresas, que investem de forma considerável para obter retornos em aplicações cada vez mais eficientes e escaláveis.

Em vários níveis, um dos ramos que mais vem investindo nesse tipo de pesquisa é o ramo de mineração. Enquanto fontes essenciais de recursos primários, operações comuns de extração e tratamento de minérios precisam acompanhar o desenvolvimento tecnológico da indústria. Somente em 2018, a Financiadora de Estudos e Projetos (FINEP) e o Banco Nacional de Desenvolvimento Econômico e Social (BNDES) já aprovaram um investimento acima de R\$ 1,4 bilhão em pesquisa, desenvolvimento e inovação na área de mineração [2].

Nesse contexto, pesquisas no ramo das comunicações subterrâneas vêm ganhando importância. A procura por alternativas de sistemas que proporcionem a comunicação efetiva em minas e possibilitem aplicações como as de localização citadas anteriormente é um dos vários novos investimentos da indústria na academia.

Em minas subterrâneas, existem implementados e bem estabelecidos sistemas de comunicação com transmissão através de cabos, do inglês *Through-The-Wire* (TTW) e baseados na propagação através do ar, do inglês *Through-The-Air* (TTA) [3]. Todavia, a infraestrutura desses sistemas é complexa e pouco confiável em casos extremos como explosões, incêndios e inundações, onde cabos e estações repetidoras podem parar de funcionar corretamente e interromper a comunicação [4]. Nesse sentido, a possibilidade de implementação de sistemas sem fio, que sejam mais robustos e flexíveis deve ser explorada.

Uma regulamentação do congresso americano exigindo um sistema de comunicação

de emergência em minas subterrâneas de carvão capaz de operar em caso de acidentes, chamada *Mine Improvement and New Emergency Response Act (MINER Act)* impulsionou a pesquisa e o desenvolvimento de comunicações utilizando um outro meio de transmissão [5]. As comunicações através da terra, ou TTE (do inglês, *Through-The-Earth*) surgiram como essa alternativa.

Nesse tipo de sistema sem fio e bidirecional, ondas eletromagnéticas são utilizadas para estabelecer um enlace entre a superfície e o subterrâneo, por meio de indução e utilizando a própria terra como meio de transmissão. Principalmente aplicado em situações de resgate, o TTE enquanto esquema de transmissão para aplicações diversas ainda possui muito espaço para melhorias.

Devido características específicas do meio de transmissão do TTE, atividades que requeiram o uso de localização e posicionamento precisam encontrar técnicas que sejam efetivas e atuem de forma eficiente neste tipo de sistema. Desenvolver essas técnicas, visando a localização de objetos enterrados e outras aplicações exploradas neste texto, é um importante ramo de pesquisa ainda incipiente.

1.2 DEFINIÇÃO DO PROBLEMA E OBJETIVOS

A escassez de estudos mais aprofundados sobre comunicações através da terra aliada à crescente demanda por alternativas que atendam à demanda por aplicações diversas da mineração industrial trazem a necessidade por novas pesquisas na área. Pesquisas atuais vão desde a caracterização do canal TTE [6] até o estudo mais específico de interferência e ruído [7][8], entrando aos poucos na viabilização de aplicações da tecnologia. Encontrar um método de localização que seja eficiente e que permita obter o posicionamento de transceptores com exatidão e confiabilidade é o ponto de partida para diversas aplicações.

Nesse contexto, esta dissertação tem como objetivo explorar técnicas de localização compatíveis com as especificidades dos sistemas de comunicação através da terra (TTE) e avaliar o desempenho das mesmos para diferentes cenários. No decorrer deste trabalho, técnicas tradicionais de localização em redes de sensores têm seu comportamento avaliado quando aplicadas em um canal TTE.

Utilizando topologias típicas de minas de superfície, sensores são distribuídos aleatoriamente em uma pilha de minérios e têm sua posição geográfica estimada pelos diferentes algoritmos. Em simulação computacional, métricas de erro são então utilizadas para mensurar acurácia de forma comparativa.

Em resumo, espera-se obter uma avaliação objetiva do desempenho de técnicas de localização em um cenário de comunicações TTE e abrir caminho para utilização dos resultados em aplicações diversas, como por exemplo, na diferenciação de zonas de minérios de zonas estéreis.

1.3 CONTRIBUIÇÕES DO TRABALHO

Visando atingir os objetivos levantados anteriormente, este trabalho tem como contribuições específicas:

- Desenvolvimento de um simulador computacional com cenário de simulação verossímil da aplicação TTE relacionada a mineração, considerando especificidades físicas e variáveis pertinentes ao processamento em minas terrestres;
- Estudo de um modelo de perda de propagação adequado para a aplicação dos algoritmos de localização;
- Avaliação comparativa da efetividade de diferentes algoritmos de localização reconhecidos na literatura para ambientes sem fio quando aplicados em ambientes TTE; e
- Implementação de um método de classificação de minérios em regiões de detecção, por meio das estatísticas de precisão do processo de localização.

1.4 ORGANIZAÇÃO DO TEXTO

O desenvolvimento dos objetivos e contribuições levantadas é explorado de forma organizada ao longo desse texto.

No Capítulo 2, uma revisão sobre os principais conceitos necessários para o entendimento sobre comunicações através da terra é realizado, explorando histórico e especificidades de sistemas TTE, além dos requisitos da aplicação para mineração. Ainda, um resumo sobre técnicas de localização em redes de sensores é também apresentado, contextualizando as escolhas realizadas e formalizando o problema explorado. Finalmente, o texto do capítulo é finalizado com um breve estudo sobre classificação estatística, servindo de base para o problema de aplicação apresentado no penúltimo capítulo.

No seguimento, o Capítulo 3 apresenta a caracterização do modelo TTE utilizado como base de descrição do canal. O desenvolvimento matemático é realizado em algum

detalhe, culminando em um modelo de perda de potência, derivado para a uma função da distância do enlace. A formulação do canal TTE é utilizado como base de aplicação para as técnicas de localização.

O Capítulo 4 explora em detalhes as técnicas de localização implementadas. Enxergada como um problema de otimização, a localização em TTE é proposta com uma abordagem a partir de dois tipos de algoritmos. O primeiro é um métodos de mínimos quadrados não lineares, na forma de uma versão do algoritmo de Gauss-Newton. O segundo é a técnica de Recozimento Simulado, reconhecida técnica de otimização estocástica para a determinação de ótimos globais.

Os resultados do estudo são apresentados então no Capítulo 5. Através da construção de um ambiente de simulação, resultados de desempenho são mostrados para as técnicas de localização quando aplicadas em diferentes cenários de uma aplicação TTE em minas terrestres. O capítulo descreve a estrutura e as escolhas de parâmetro do simulador, assim como os mecanismos utilizados para a avaliação dos resultados.

A partir do estudo de localização, os resultados são então utilizados em uma aplicação direta para a identificação de zonas de minérios, apresentada no Capítulo 6. Explorando uma técnica de aprendizado de máquina para classificação estatística, representações visuais de regiões de minério e regiões estéreis são analisadas em mais detalhes.

Por último, o Capítulo 7 conclui o texto com considerações finais sobre os resultados do estudo e algumas propostas de continuidade para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

2.1 COMUNICAÇÕES ATRAVÉS DA TERRA

2.1.1 Condições de Comunicações em Minas

Diferentemente da maioria dos sistemas de uso comercial, comunicações em minas funcionam sob condições extremas. Tipicamente definida como uma escavação feita no solo para extrair minerais [9], uma mina é um ambiente de trabalho perigoso. Explosões, desmoronamentos, inundações, quedas e gases tóxicos são riscos frequentes. Um sistema de comunicações adequado deve ser capaz de contornar essas condições ambientais de forma segura.

Monitoramento e verificação de mudanças na composição de gases ou estrutura física da mina são tarefas constantes para se mitigar desastres. Um sistema de comunicação apropriado deve atuar com constância, provendo o serviço a todo momento [3]. Ainda, em casos em que o acidente é iminente, este mesmo sistema precisa atuar de forma rápida, para uma possível evacuação, e de forma acurada, para viabilizar operações de resgate.

No que diz respeito as operações e processos rotineiros, a comunicação necessita também corresponder à dinâmica de produtividade. Atividades de extração e deslocamento dos minérios devem utilizar de serviços de comunicação que sejam precisos e eficientes [3]. Localizar corretamente um ativo e evitar o desperdício nas etapas de separação são processos que têm bastante potencial de melhoria se realizados com uma comunicação efetiva, por exemplo. A Seção 2.2 descreve de forma mais específica as características de técnicas de localização para esse tipo de atividade.

Além dos requisitos advindos da natureza do trabalho nas minas, outra característica que é um condicional para a boa comunicação é a composição física do meio. Cada mina é um meio único que depende diretamente do tipo de minério que é explorado e de sua topologia. Variáveis como condutividade e permissividade elétrica mudam para cada tipo de material [3], afetando a perda de propagação. Formatos de pilha e de galerias subterrâneas, por sua vez, têm impacto na propagação de sinais de rádio pela mudança geográfica do meio, que altera as condições do canal com efeitos como os de guia de onda, por exemplo. Principalmente com a relação à comunicação entre

a superfície e o subterrâneo, a dificuldade de propagação de ondas eletromagnéticas é uma questão que influencia na escolha do sistema de comunicação mais adequado.

Para sistemas sem fio por rádio, a infraestrutura depende das alterações físicas do meio. Estações repetidoras devem acompanhar as mudanças na topologia das minas para garantir cobertura e qualidade do sinal, o que se traduz em um aumento dos custos e na necessidade de planejamento constante de expansão. Sistemas com cabos, por outro lado, não são afetados pelas questões de propagação, mas são suscetíveis a danos, especialmente nos casos extremos [3]. Nesses sistemas, uma maior infraestrutura também representa um aumento na quantidade de fios e cabos e, logo, um aumento dos custos.

Dessa forma, uma infraestrutura menos rígida é preferível para comunicações em minas. Equipamentos mais leves e menores, que se adaptem à topologia em constante alteração e, no caso de sistemas sem fio, equipamentos de baixa potência, que garantam boa duração e vida útil em condições extremas.

Desde que esses não representem um aumento na complexidade, utilizar sistemas móveis e sistemas que utilizem a própria mina como meio de transmissão são uma alternativa [3]. A Seção 2.1.2 apresenta as características de sistemas desse tipo para enlaces entre subterrâneo e superfície.

2.1.2 Sistemas de Comunicações TTE

Sistemas de comunicação através da terra, ou TTE, como o próprio nome sugere, são sistemas que utilizam a terra enquanto meio de propagação. Utilizando transmissão por indução magnética com frequências de operação na faixa abaixo de 30 kHz, são comumente aplicados em enlaces entre superfície e subterrâneo quando na comunicação em minas.

A primeira ideia de utilizar a terra como meio de transmissão foi sugerida por Nikola Tesla, em 1899. Em sua proposta, sinais em frequências extremamente baixas (ou ELFs, do inglês *Extremely Low Frequencies*) poderiam ser empregados para enviar mensagens para todo o mundo utilizando a própria Terra enquanto meio [10][11]. Nessa época, foram criados os primeiros trabalhos teóricos para estabelecer as bases matemáticas para a propagação TTE.

As primeiras aplicações práticas de comunicação em minas subterrâneas foram tentadas em 1922, pelo *Bureau of Mines*, nos Estados Unidos. A tentativa de estabelecer um enlace entre superfície e subterrâneo utilizando ondas de rádio não obteve sucesso,

mas abriu portas para o desenvolvimento dos fundamentos do TTE, principalmente no que diz respeito a dependência da frequência de onda na penetração do sinal. Em termos práticos, ficou claro que quanto maior a frequência, menor seria a distância de penetração do sinal na terra [3].

Apesar das incertezas em relação a viabilidade, principalmente devido à baixa capacidade de penetração, investimentos em sistemas TTE continuaram a ser aplicados. Em estudos mais recentes, sistemas baseados em ondas de rádio foram preteridos em favor de sistemas que utilizam indução magnética [3].

Após a regulamentação do *MINER Act*, alguns protótipos de sistemas TTE foram produzidos sob o apoio do órgão NIOSH (*National Institute for Occupational Safety and Health*). Esses protótipos chegavam a ter capacidade de prover comunicação bidirecional, de voz e texto em até 300 m (voz) e 600 m (texto) de profundidade. Frequências utilizadas iam de 3050 Hz a 4820 Hz [5]. Em boa parte desses equipamentos, a tecnologia é baseada na detecção a partir de campos magnéticos utilizando antenas *loop*. Com receptores situados na superfície, é possível estimar o posicionamento do transmissor no subterrâneo através do tratamento do sinal recebido [5].

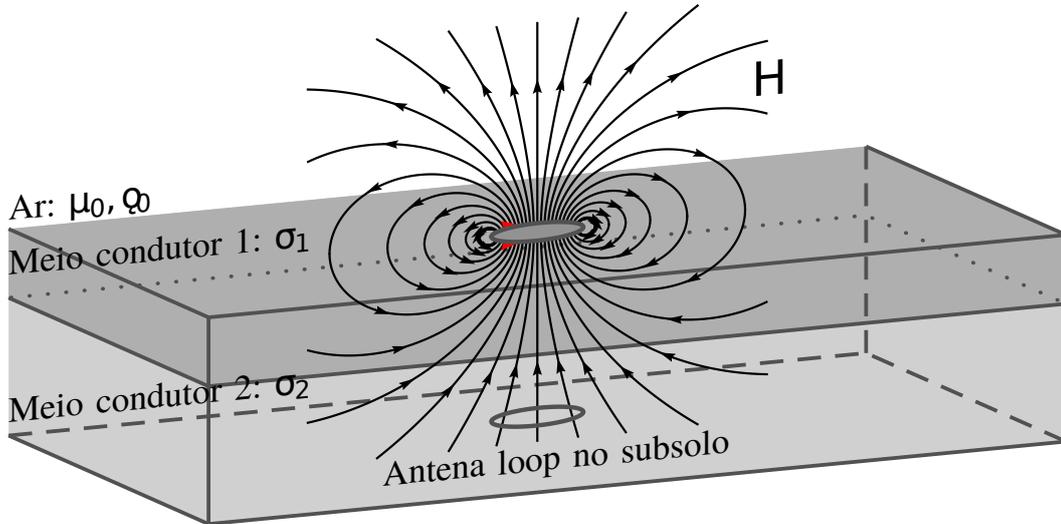


Figura 2.1: Representação esquemática de enlace físico de sistema de transmissão TTE operando em *uplink*. Dimensões típicas de antenas vão de centímetros a dezenas de metros.

Na Figura 2.1 um enlace entre superfície e subterrâneo de um sistema TTE para duas antenas *loop* é esquematizado. Operando em *uplink*, uma antena na superfície com permeabilidade μ_0 e permissividade ϵ_0 recebe o sinal de uma antena subterrânea em meios com condutividades σ_1 e σ_2 . Como mostrado, o campo H é utilizado para a transmissão por indução magnética.

Hoje é sabido que as características de um canal TTE mudam para cada tipo de mina. A capacidade de penetração do sinal varia com a formação geológica, uma vez que a condutividade elétrica do meio composto de rochas, solo, água, minérios e outros materiais é não desprezível. A propagação do sinal é profundamente atenuada para frequências altas e a banda de operação acaba sendo limitada nesse sentido [12].

Além da frequência de operação, a qualidade e o alcance da transmissão também variam de acordo com as especificações físicas das antenas e da corrente de excitação. Essas informações, em conjunto com a profundidade e as características do solo, precisam ser avaliadas para cada projeto [10].

Um dos sistemas TTE comercializados atualmente, o *MagneLink MCS*, construído pela *Lockheed Martin* após testes conjuntos com a NIOSH, é um exemplo de sistema autossuficiente e bidirecional baseado em ondas magnéticas de baixa frequência. Ele oferece suporte a voz, texto e localização, cujas validades foram atestadas para uma profundidade de 500 m utilizando uma antena de 130 m de comprimento na superfície e outra com múltiplas voltas dentro na mina [5].

A caracterização do cenário TTE tem evoluído, estabelecendo propriedades específicas do meio de forma mais clara e possibilitando a criação de modelos para propagação e perdas. Descrever e unificar as relações entre a capacidade de penetração, profundidade, frequência de transmissão e condutividade são focos de pesquisas atuais [13][14]. Em [7][8], estudos mais aprofundados sobre ruído, interferência e capacidade de canal em sistemas TTE são explorados. No Capítulo 3, um detalhamento do modelo de propagação utilizado neste trabalho é apresentado.

2.2 LOCALIZAÇÃO EM REDES DE SENSORES

Em termos gerais, uma rede de sensores se refere a qualquer rede de comunicação em que nós, dispositivos ou roteadores, obtenham localmente alguma medição de interesse [15]. Em sua maioria, principalmente nas redes sem fio que utilizam controle e monitoramento remoto, o conhecimento das coordenadas físicas dos sensores é intuitivo: uma medição só faz sentido se há referências sobre onde foi obtida.

De fato, embora muito do processo de localização efetivamente realizado hoje seja feito por sistemas GPS (*Global Positioning System*), WiFi ou até mesmo RFID (*Radio-Frequency Identification*) [16], redes que possuam algum tipo de limitação precisam de alternativas viáveis. Casos em que os custos dos dispositivos precisem ser baixos, com anos ou décadas sem substituição de bateria, e com capacidade de se auto organizar

sem muita intervenção humana apresentam um limitante de escalabilidade que deve ser considerado na escolha da técnica de localização.

No contexto estabelecido de monitoramento de ativos na mineração em sistemas TTE, por exemplo, o ambiente físico limita o uso de técnicas mais usuais. A recepção para sinais de radiofrequência e satélite é restrita e as atividades de exploração exigem dispositivos mais robustos, com pouca complexidade e baixa potência, que sustentem o uso contínuo nas condições extremas das minas [7].

Dessa forma, o foco do processo de localização de sensores utilizado neste trabalho é de estimar a posição dos dispositivos a partir de informações relativas de distância e conectividade [17]. Nesses sistemas, uma quantidade restrita de nós de referência, tipicamente denominados âncoras, é utilizada para determinar as coordenadas de uma quantidade mais ampla de sensores cuja localização *a priori* não é conhecida. A posição absoluta de cada âncora pode ser obtida através de GPS ou manualmente durante a inicialização do sistema. A partir do enlace estabelecido entre os nós da rede e as coordenadas de referência das âncoras, a posição desconhecida de cada sensor pode ser estimada. Como forma de especificar a nomenclatura e deixá-la mais próxima da aplicação TTE, os sensores cuja localização se quer estimar são referidos ao longo deste trabalho como *tags*. Um esquemático simplificado dessa arquitetura incluindo âncoras e *tags* é mostrado na Figura 2.2.

A forma que a rede obtém as coordenadas estimadas dos sensores depende da capacidade dos dispositivos e das características específicas do sistema utilizado. A depender do alcance do enlace, a técnica utilizada pode determinar a posição de uma *tag* por vez ou determinar a posição de várias *tags* simultaneamente. Para sensores com restrições de energia ou empecilhos para uma transmissão de mais longo alcance, técnicas de localização utilizadas são do tipo cooperativas, distribuídas ou multi-hop [18], se baseando na proximidade da comunicação *tag-tag* para a localização em cascata de todos os nós da rede. Por sua vez, em casos em que os sensores têm maior potência de transmissão ou a rede tem dimensões físicas reduzidas, as *tags* conseguem se comunicar diretamente com múltiplas âncoras, permitindo que técnicas centralizadas possam ser aplicadas.

2.2.1 Técnicas de Medição

Independente da escolha da técnica, a estimação de coordenadas físicas depende diretamente do tipo de medição obtida. Embora medidas absolutas possam entregar alguma informação sobre a aproximação física de sensores, medidas relativas, advindas

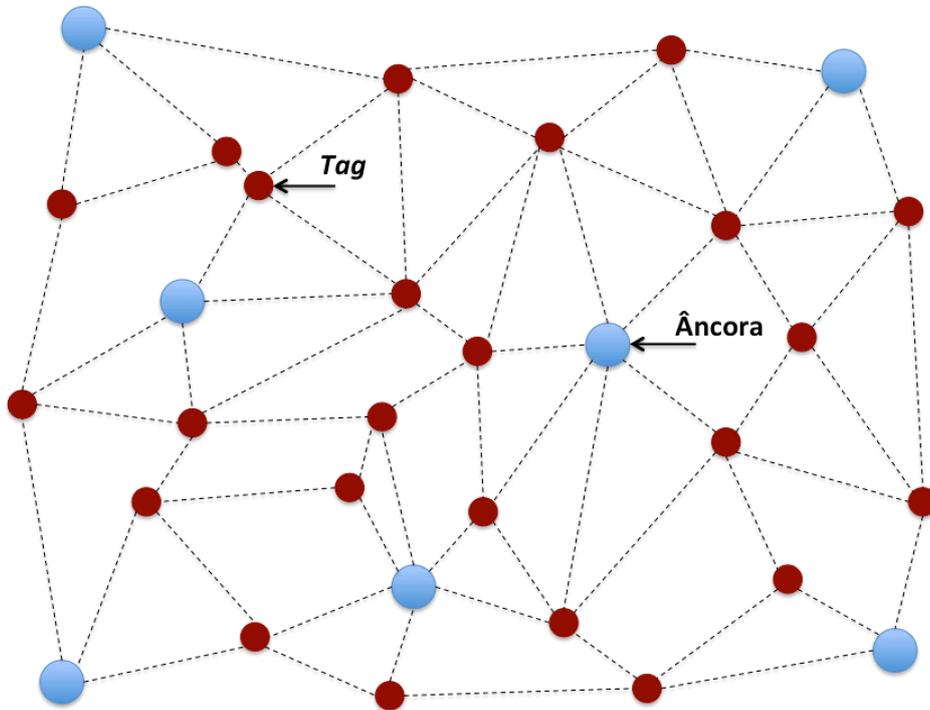


Figura 2.2: Representação esquemática de uma rede de sensores com múltiplas âncoras e *tags*.

da aferição do sinal transmitido em um enlace *tag-tag* ou *tag-âncora*, são geralmente as mais utilizadas para se obter uma estimativa da localização. Técnicas de medida que utilizam direta ou indiretamente propriedades do sinal transmitido são geralmente divididas em três categorias: medidas da potência recebida (RSS, do inglês *Received Signal Strength*), medidas do ângulo de chegada (AOA, *Angle of Arrival*) e do tempo e tempo de propagação (TOA, *Time of Arrival*) [17].

Métricas de RSS utilizam diretamente a potência ou, em alguns casos, a magnitude do sinal recebido para estimar a localização do transmissor [15]. De forma simplificada, a partir da informação sobre a energia recebida, é possível estimar um padrão de comportamento no canal e ter, de forma correspondente, uma relação da distância percorrida pelo sinal até o receptor.

As técnicas para medições de RSS utilizam geralmente uma de duas bases de estimação [19]. A primeira, baseada na distância, obtém as estimativas a partir de um modelo de perda de potência referente ao canal, retornando a informação de distância como uma função do nível de potência recebido. Por sua vez, a segunda base, utilizando traçado de perfil de comportamento, mapeia valores de potência do sinal para pontos dentro da área de cobertura, tabelando valores de distância para cada valor

de potência mapeado. Embora esta segunda apresente menor erro de estimativa em aplicações práticas [20], o mapeamento de um grande número de pontos envolve maior investimento inicial e esforço computacional, representando uma complexidade, que é aliviada no modelo baseado em distância.

Do ponto de vista de confiabilidade, o uso de RSS é bastante dependente da estrutura da rede, sendo bastante sensível a mudanças físicas no canal e atenuações típicas do processo de transmissão, como por exemplo, sombreamento e ruído [21]. Geralmente, esses erros são incorporados ao processo de localização e modelados como um fenômeno aleatório.

No entanto, mesmo com a considerável variabilidade, medidas RSS são usualmente as mais utilizadas em técnicas de localização. Por medidas de energia já serem diretamente envolvidas no processo de comunicação, técnicas que utilizam RSS exigem pouca infraestrutura adicional, aproveitando *hardwares* já existentes e reduzindo requisitos adicionais de potência, tamanho e custos.

Diferentemente de métricas de RSS, métricas de AOA utilizam informações de angulação do sinal para gerar as estimativas da localização. Nesta técnica, por meio da variação da amplitude ou da fase do sinal na antena receptora, a direção do sensor transmissor - e não mais sua distância - pode ser estimada. Por trazer essa informação da posição em um formato diferente, métricas de AOA geralmente são utilizadas de forma complementar a outras métricas [15].

O desempenho da localização utilizando AOA é intrinsecamente determinado pelas características das antenas utilizadas. Como via de regra, sistemas para esse tipo de medida são compostos por antenas diretivas, geralmente construídos a partir de arranjos de antenas ou com antenas receptoras de dimensões consideravelmente maiores do que o comprimento de onda do sinal transmitido. Em menor escala, esses sistemas também dependem das características do meio de propagação, mais notadamente da presença de multipercursos e sombreamento [22].

Finalmente, uma última categoria de métrica se baseia na avaliação do tempo de chegada (TOA) ou na diferença no tempo de chegada (TDOA) como parâmetros para obter as estimativas de localização. De forma geral, esses tipos de técnica fazem uso do tempo de propagação da onda para estimar a distância entre transmissor e receptor [23].

Mais especificamente, medidas de TOA seguem uma matemática simples de avaliação da diferença no tempo de saída do sinal e de chegada do sinal, considerando um percurso em linha de visada. Conhecendo informações de velocidade da onda no

meio, informações de distância são obtidas de forma direta. Usualmente, técnicas que utilizam TOA são divididas em medidas em sentido único, transmissor para receptor, ou como medidas de ida e volta. Neste segundo tipo, o tempo de propagação é considerado por meio do atraso entre o sinal enviado para o receptor e a resposta de confirmação devolvida ao transmissor. Medidas de ida e volta são mais utilizadas, pois apresentam menor sensibilidade a erros de propagação do que medidas em sentido único [24]. Ainda, medidas em sentido único por terem requisitos mais rígidos de sincronismo, representam em termos de projeto, um aumento de custos e de infraestrutura.

Medidas de TDOA, por sua vez, utilizam a diferença no tempo de chegada de um sinal transmitido para múltiplos receptores. Aqui, as estimativas de distância são obtidas a partir da relação entre a medição temporal em cada receptor e a distância euclidiana entre os mesmos. Historicamente, TDOA tem bastante aplicação em redes GPS e redes celulares, principalmente na localização de transmissores síncronos [23].

Em suma, métricas de AOA e TOA/TDOA apresentam maior acurácia que métricas de RSS [25]. No entanto, para o TTE a medição do tempo é feita para pequenas distâncias e com uma velocidade de transmissão que, por depender do meio, é em princípio desconhecida. Tal cenário dificulta a utilização de medidas temporais com precisão. No mais, uma maior necessidade por infraestrutura de antenas, sincronizadores e transceptores impede que essas técnicas sejam amplamente aproveitadas.

Em sistemas com limitações de hardware, métricas RSS apresentam um bom custo benefício, geralmente alcançando resultados satisfatórios. No Capítulo 3, essas métricas serão retomadas e construídas em cima de um modelo específico de propagação para sistemas TTE.

2.2.2 Algoritmos para Localização

A literatura para algoritmos de localização é extensa [26]. São várias as técnicas e métodos relevantes que provaram sua eficácia para resolver o problema apresentado nas seções anteriores. Aqui, a busca é por estimadores compatíveis que determinem a posição da forma mais adequada para as necessidades do sistema e da aplicação.

De forma genérica, um algoritmo adequado depende da arquitetura da rede como um todo. Critérios colocados anteriormente, como as características do canal e do ambiente de aplicação e a simplicidade de hardware, são importantes. Geralmente, preço, tamanho e precisão são os principais fatores de escolha para uma técnica.

Ainda, a escolha precisa apresentar escalabilidade. Redes de sensores, principalmente as redes sem fio, tendem a crescer e densificar com o tempo, uma questão que

deve ser lidada sem muitas alterações na estrutura original. Algoritmos precisam em sua maioria se auto-organizar, precisam ser tolerantes a problemas em nós individuais e eficientes em termos energéticos e computacionais [27].

Não menos importantes, os fatores de qualidade da medida são também critérios de decisão. Tanto a precisão - o quão confiável é a estimativa -, quanto a acurácia - quão próxima ela está da solução real - são métricas ponderadas em todos os algoritmos, sendo é claro, mais ou menos requeridas a depender da aplicação específica.

Em um grande leque de possibilidades, os algoritmos podem ser classificados de diversas maneiras. De forma simplificada, os métodos podem ser divididos de acordo com a informação utilizada: se baseadas em alcance (*range-based*) ou baseadas em conectividade (*range-free*) ou de acordo com o tipo de comunicação estabelecida entre os nós: algoritmos centralizados, que apresentam uma arquitetura central de processamento ou distribuídos, em que o processamento é realizado independentemente em cada nó da rede [27]. Na Figura 2.3 são mostradas as divisões consideradas neste trabalho.

As técnicas baseadas em conectividade, ou *range-free*, não dependem diretamente de medidas como RSS ou AOA para determinar a posição de todos os nós da rede. Sem levar necessariamente em consideração um sistema de coordenadas específico, a posição dos nós é estabelecida pela informação prévia de alcance entre uma *tag* e suas vizinhas. Mecanismos distribuídos ou *multi-hop* já citados anteriormente são geralmente utilizados neste tipo de algoritmo.

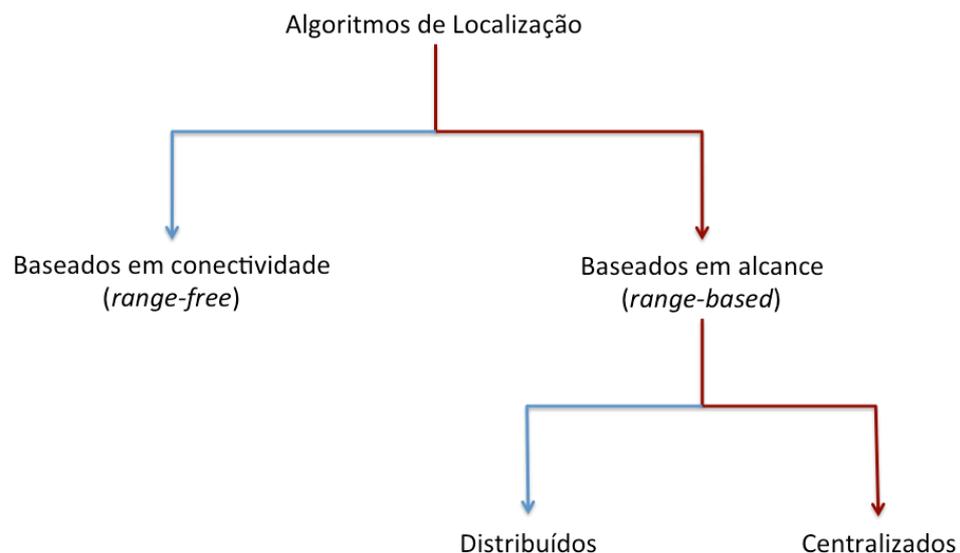


Figura 2.3: Categorias consideradas para classificação de algoritmos de localização.

De fato, embora técnicas baseadas em conectividade também possam ser dividi-

das enquanto centralizadas e distribuídas, para o escopo desta pesquisa, o foco será em algoritmos baseados em distância, mais especificamente os que utilizam uma base centralizada. Essa escolha tem como base as características estabelecidas dos cenários apresentados e os critérios requeridos para as aplicações estudadas do TTE.

Com essa base de configuração, existe uma gama de algoritmos bem estabelecidos. É possível citar alguns: DV-HOP (*Distance Vector Hop*, em que a localização das âncoras é passada para todos os nós da rede por meio da contagem de “saltos” entre *tags* vizinhas [28], Programação Semidefinida (*Semidefinite Programming*, SDP), que formula o problema como um problema de otimização convexa, utilizando métodos de pontos interiores para resolver para as posições enquanto aproximações lineares [29] e Escalonamento Multidimensional (*Multidimensional Scaling*, MDS), que se baseia na obtenção de padrões de similaridade, utilizando estruturas geométricas e relações de proximidade entre os nós da rede para a localização [30].

No geral, estes algoritmos dependem da densidade da rede e da regularidade da topologia para obterem boas estimativas [27]. Dada a simplicidade, são muito utilizados quando os requisitos da aplicação exigem apenas estimativas aproximadas da localização, sem tanta acurácia.

Por sua vez, técnicas baseadas em alcance ou distância (*range-based*), trabalham com estimativas de distância ou direção entre âncoras e *tags* para determinação da posição. Algoritmos com essa característica fazem uso direto de medições como as apresentadas na Seção 2.2.1 e geralmente definem as coordenadas das *tags* a partir de posições relativas estimadas e as coordenadas geográficas previamente estabelecidas das âncoras.

Alguns algoritmos baseados em conectividade podem ser expandidos para considerar medições de distância em sua estrutura. Este é o caso de vários algoritmos descentralizados, como os DV-Distance, por exemplo, que ainda que com os mesmos mecanismos do DV-HOP, utilizam a propagação das informações de distância ao invés das informações dos saltos para obter as estimativas da posição [28]. Alguns algoritmos centralizados como o MDS também pode incorporar as medidas de distância no problema de otimização, sendo estudado de forma mais clara em [31].

Ainda, uma das classes mais conhecidas de algoritmos centralizados baseados em distância é a que se fundamenta em otimização estocástica, utilizando variáveis aleatórias para a avaliação e solução do problema. Desse grupo, um algoritmo relativamente bem popular é o algoritmo de Recozimento Simulado (do inglês *Simulated Annealing*, SA) [32]. Por meio de estimativas aleatórias controladas, SA faz uma busca ampla em todo o domínio do problema, obtendo bons resultados na determinação de soluções globais

para as coordenadas. Este algoritmo e mais algumas técnicas são exploradas mais a fundo no Capítulo 4, onde o problema de localização é estudado como um problema de otimização.

2.2.3 Formulação do Problema

Explicitamente, o problema apresentado na Figura 2.2 pode ser abordado em uma formulação matemática.

Para esta descrição, consideramos um conjunto S de sensores distribuídos em uma geometria controlada, em que n sensores de coordenadas desconhecidas (*tags*) têm suas posição estimada a partir das informações dos m sensores com conhecimento a priori de sua localização (âncoras).

O problema de localização para o cenário 3-D pode ser resumido na procura dos $3n$ parâmetros desconhecidos do vetor $\alpha = [\alpha_x, \alpha_y, \alpha_z]$, com:

$$\alpha_x = [x_1, x_2, \dots, x_n], \alpha_y = [y_1, y_2, \dots, y_n], \alpha_z = [z_1, z_2, \dots, z_n], \quad (2.1)$$

em que x, y, z são as coordenadas retangulares da i -ésima *tag*. Aqui, quando a técnica utilizada não é do tipo distribuída e cada nó é processado de forma separada dos demais, o problema pode ser reorganizado considerando α um vetor coluna, na forma $\alpha = \alpha_i = [x, y, z]$.

Tomando como caso base aquele em que a posição é obtida a partir de uma métrica de distância estimada (ver Seção 2.2.1 para métricas utilizadas), o problema pode ser estudado a fundo dentro da teoria de grafos [33]. A partir de conceitos da geometria euclidiana, as coordenadas de todos os nós da rede podem ser obtidas utilizando as distâncias calculadas entre os próprios nós.

Em termos gerais, deve existir um mapeamento $p : S \rightarrow \mathbb{R}^3$ que atribui uma coordenada para cada sensor, de forma que $\|s_i - s_j\| = d_{ij}$, com d_{ij} a distância euclidiana entre os nós i e j , seja verdade para todos os nós $s_i \in S$. Em particular, dada uma âncora $s_{a_j} \in S$, a solução do problema se baseia no mapeamento $\|s_i - s_{a_j}\| = d_{a_{ij}}$, com $d_{a_{ij}}$ a distância conhecida da i -ésima *tag* para a j -ésima âncora.

De acordo com os conceitos de rigidez de um grafo, é possível obter as coordenadas exatas de qualquer ponto no plano a partir de 3 vértices não colineares e a partir de 4 vértices não coplanares em \mathbb{R}^3 . Dentre varias possíveis aplicações, esta condição é a base da formulação da técnica de trilateração/multilateração, mostrada na Figura 2.4.

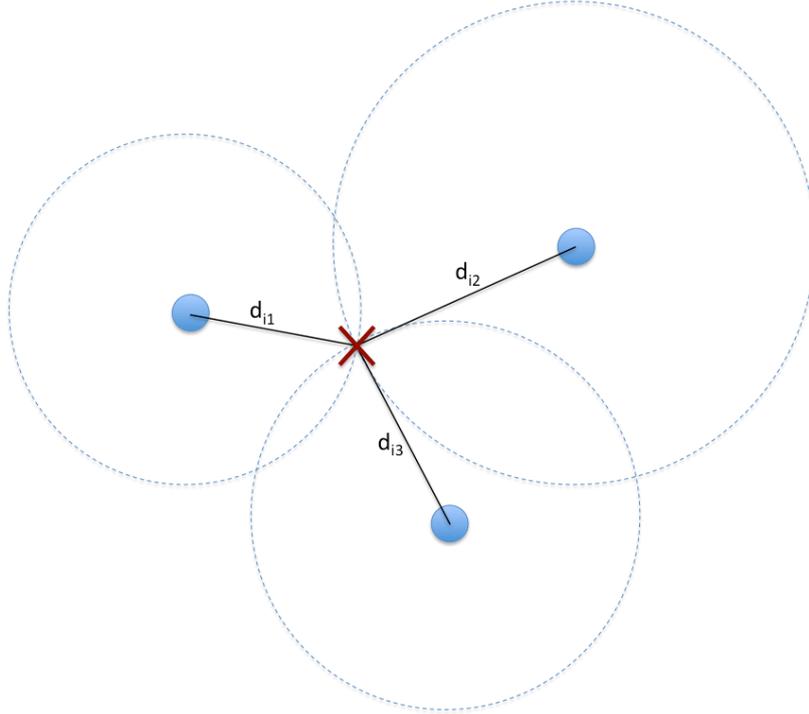


Figura 2.4: Esquema simplificado da técnica de trilateração. Ao menos 3 vértices não colineares são necessários para determinação da posição em \mathbb{R}^2 .

A esquematização do processo de trilateração é simples: conhecida a distância para uma âncora, um nó deve estar ao longo de uma circunferência centrada na âncora e de raio igual a distância âncora-tag. Notadamente, para solução única, ao menos 3 circunferências são necessárias em \mathbb{R}^2 .

Entretanto, como citado na Seção 2.2.1, as distâncias d_{ij} estabelecidas estão sujeitas a erros no processo de medição. Em cenários práticos, as circunferências da Figura 2.4 se sobrepõem em uma região ao invés de se intersectarem em um único ponto. Esta configuração mais realística é mostrada na Figura 2.5, onde r_{ij} é a distancia medida entre âncora e tag. Aqui, a solução não mais faz referência a uma posição específica mas a toda uma região possível.

Nesse cenário, utilizando a distância medida r , a estimativa das coordenadas do vetor α_i pode ser obtida pela solução do sistema de equações:

$$\begin{bmatrix} \sqrt{(x_i - x_{a_1})^2 + (y_i - y_{a_1})^2 + (z_i - z_{a_1})^2} \\ \sqrt{(x_i - x_{a_2})^2 + (y_i - y_{a_2})^2 + (z_i - z_{a_2})^2} \\ \vdots \\ \sqrt{(x_i - x_{a_m})^2 + (y_i - y_{a_m})^2 + (z_i - z_{a_m})^2} \end{bmatrix} = \begin{bmatrix} r_{i1} \\ r_{i2} \\ \vdots \\ r_{im} \end{bmatrix}, \quad (2.2)$$

que é sobredeterminado, não apresenta solução única e, portanto, buscamos a solução

com menor erro.

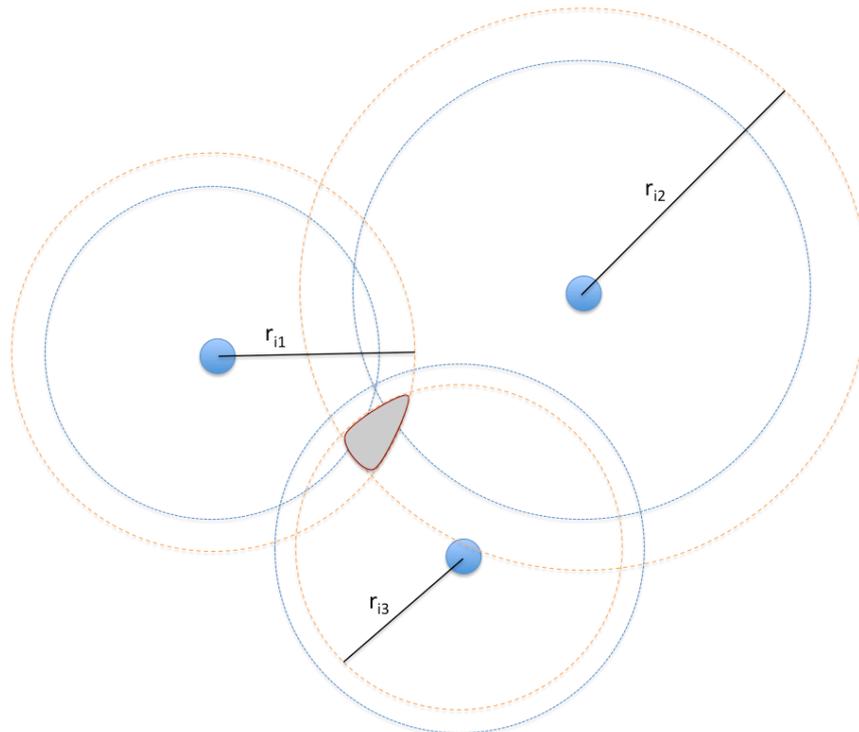


Figura 2.5: Técnica de trilateração quando na presença de erros de medição. A região sombreada representa todos os conjuntos de coordenadas possíveis para uma *tag* desconhecida.

Uma vez que as fontes de erro do processo de medição são em sua maioria aleatórios, métricas estatísticas são necessárias para a obtenção das estimativas de α . Como pontuado anteriormente, métodos para solucionar esse tipo de problema são apresentados em mais detalhes no Capítulo 4.

2.3 CLASSIFICAÇÃO ESTATÍSTICA

Em ciência de dados, classificação estatística é o procedimento de associar ou definir uma categoria (ou classe) existente dentro de uma população a um indivíduo em particular. A partir da assimilação de um conjunto de dados, define-se a qual grupo (ou subpopulação) uma nova observação pertence.

O conceito tem base direta no aprendizado de máquina e vem, mais amplamente, como derivação do grande ramo de reconhecimento de padrões. Neste, o objetivo principal é descobrir de forma automática e por meio de algoritmos computacionais, padrões de regularidade e de relação entre dados [34].

De forma geral, reconhecimento de padrões tem muita interação com sistemas de

inteligência artificial e processos de mineração de dados, podendo ser realizado de diversas formas, a depender do campo de aplicação. Problemas de classificação são apenas um dos vários segmentos com os quais reconhecimento de padrões precisa lidar. Genericamente, a mesma base é utilizada para a resolução de problemas de regressão, problemas de rotulagem de sequências e problemas de análise sintática [35].

De fato, essa base diz respeito à forma com que os dados são treinados ou aprendidos pelos algoritmos na máquina. Mais especificamente, a depender do processamento dos dados e às características desses, mesmo os problemas que em teoria envolvem diretamente o conceito de classificação têm abordagens de aprendizado diferentes.

A divisão mais comum dentro de aprendizado de máquina é entre algoritmos de aprendizado supervisionado e aprendizado não supervisionado. A diferença básica está no nível de conhecimento sobre os dados. Em aprendizado supervisionado, o treinamento é gerado por dados rotulados ou etiquetados (*labeled data*), ou seja dados em que a classe a qual cada indivíduo pertence é conhecida e utilizada para atribuir correspondentemente classes a novos valores de entrada. Por sua vez, em aprendizado não supervisionado, pressupõe-se que os dados não estão classificados previamente (ou seja, o conjunto de treinamento não possui rotulagem) e a atribuição de classes a novas instâncias é realizado a partir do reconhecimento de padrões intrínsecos nos conjuntos.

Efetivamente, classificação estatística é enquadrada dentro do conceito de aprendizado supervisionado, uma vez que utiliza do conhecimento prévio de rótulos para classificar condicionalmente novas observações. No entanto, é importante salientar que existe um processamento análogo em aprendizado não supervisionado, conhecido como agrupamento (*clustering*). Nessa técnica, nenhuma classe é conhecida *a priori* e a divisão por categorias é realizada agrupando os dados de acordo com seu grau de semelhança.

Mesmo com objetivos diferentes, as técnicas para reconhecimento de padrões e mais especificamente para classificação, têm um sequência de processamento bem semelhante. A Figura 2.6 mostra um esquemático simplificado do processo de classificação.

Como ilustrado, o processo funciona em dois grandes blocos distintos, a etapa de treinamento e a etapa de predição. A partir de um grupo de treinamento, cujas classes são conhecidas, padrões são gerados utilizando um processo de treinamento que é específico de cada algoritmo classificador. Esses padrões são representados então em um modelo, de formulação fechada ou não, que é utilizado na etapa de predição para identificar a classe de novas observações.

Em aprendizado de máquina, cada observação é comumente denominada de instância,

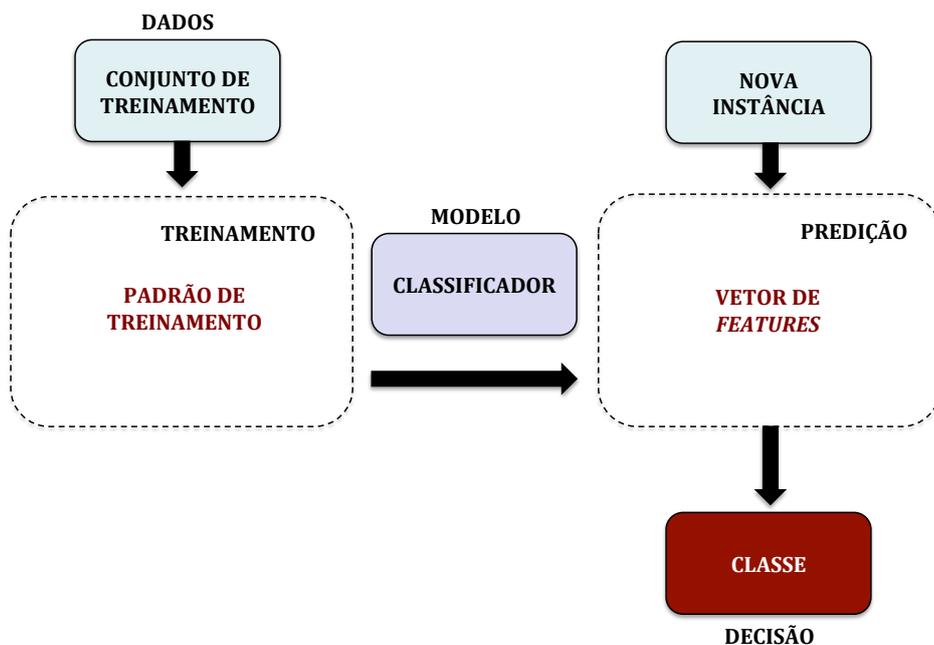


Figura 2.6: Esquemático de um processo de classificação genérico.

sendo representada como um conjunto de características (ou *features*, do inglês), que são as variáveis independentes que descrevem a observação. Essas características são geralmente armazenadas em um vetor de entrada que é avaliado computacionalmente pelo método de aprendizado escolhido, que entrega como saída a classe mais provável para aquela instância.

São vários os tipos possíveis de *features* e todos representam propriedades quantificáveis da observação. Eles podem ser categóricos, como a definição de macho ou fêmea para uma espécie ou liso, cacheado e crespo para um tipo de cabelo, podem ser ordinais, como tamanhos pequeno, médio ou grande e podem ser valores numéricos, tanto inteiros (sequências de contagem de aparições) ou reais (medidas experimentais).

Independente do tipo, no entanto, é a manipulação dessas características e suas relações com as classes que são os pontos de interesse principais dos classificadores. Daí a intenção de montar estruturas vetoriais e modelos de previsão com base matemática.

De fato, a criação desses modelos representa geralmente um compromisso de desempenho. Ao mesmo tempo em que a escolha deve apresentar um bom ajuste aos dados utilizados na etapa de treinamento, esta deve também ter capacidade de generalização suficiente para receber novas observações sem entregar resultados enviesados. Embora um desafio, a ideia aqui é que o modelo encontre um padrão que seja inteligível e robusto, mas que conjuntamente permita adaptabilidade e escalabilidade ao classificador.

Finalmente, é importante salientar que embora se fale de classificação estatística, nem sempre os classificadores empregados são probabilísticos. Diferente de algoritmos determinísticos em que se escolhe a melhor classe, os classificadores probabilísticos utilizam inferência estatística para entregar uma probabilidade da observação pertencer a cada classe possível. A melhor classe é então decidida por aquela com maior probabilidade. Na próxima seção são apresentados alguns tipos de classificadores e suas características.

2.3.1 Escolha de Classificadores

De forma geral, os vários algoritmos existentes para reconhecimento de padrões podem ser classificados de diversas maneiras, a depender do formato das classes e do método de aprendizado envolvido, por exemplo. Além da já comentada classificação entre técnicas supervisionadas e não supervisionadas e entre técnicas probabilísticas ou determinísticas, os algoritmos também são comumente divididos entre algoritmos paramétricos e não-paramétricos, a depender do conhecimento sobre a distribuição dos dados e da formulação de um modelo fechado ou não para estes.

Entre os métodos mais utilizados de classificação, um tipo que é bem simples e utiliza uma estratégia não-paramétrica é o método de Naive-Bayes [36]. Como o nome sugere, a técnica é baseada no Teorema de Bayes e funciona como fundamento para uma família de outras técnicas probabilísticas mais robustas. De forma resumida, Naive-Bayes utiliza máximo verossimilhança para identificar relações dentro do grupo de treinamento, entregando bons resultados mesmo para uma quantidade pequena de dados de teste. É o uma técnica altamente escalável, mas que utiliza como premissa a completa independência entre as características da instância, o que para alguns cenários reais é difícil de prever.

De fato, escolher um classificador apropriado é muito dependente da aplicação específica. São vários os critérios para se definir o algoritmo mais adequado e ainda assim não existe um que vá apresentar necessariamente um resultado ótimo. Algumas questões, no entanto, podem ser avaliadas de forma mais ampla e auxiliar na decisão por uma técnica ou outra.

Primeiramente, e talvez a mais presente em todos os problemas de classificação, é a relação entre viés e variância. Esta relação é estabelecida no compromisso de desempenho levantado anteriormente para um modelo e que interfere na generalização. Para as duas fontes de erro, em um mesmo conjunto de dados, a escolha de qual minimizar é conflitosa. Um modelo mais adequado ao grupo de treinamento mas

pouco generalista traz menos variância a custo de uma estimativa mais enviesada. Por sua vez, um modelo mais simples que se adapta melhor a novas instâncias é menos enviesado, mas apresenta uma variância consideravelmente maior. Este é um dilema típico de modelagem estatística e pode ser visto em mais detalhes em [37].

Ainda sobre o modelo, a avaliação da sua complexidade é importante. Altos níveis de correlação entre as componentes do vetor de features e comportamentos muito des- toantes dentro do domínio do problema exigem modelos mais complexos e, portanto, grupos de treinamento mais extensos, com muitos exemplos de vetores para um bom entendimento da função modelada. Paralelamente, a dimensionalidade desses vetores também deve ser levada em conta, uma vez que vetores com muitas características aumentam o tempo de processamento e podem apresentar redundâncias que podem trazer instabilidade ao algoritmo.

Finalmente, um último ponto de observação que deve ser considerado é em relação ao ruído. A depender do nível de ruído dos dados obtidos, por medição por exemplo, o algoritmo pode acabar encontrando uma relação com o grupo de treinamento que não condiz com a relação real e sobreajustando os resultados para novas instâncias, com uma alta variância.

Na prática, a grande maioria dos algoritmos lida de forma a equilibrar esses critérios independentemente. Dentre técnicas com muita aplicabilidade, é possível citar como exemplos os algoritmos de máquinas de vetores de suporte (SVM, do inglês *Support Vector Machine*) e os algoritmos de redes neurais.

O primeiro é uma técnica não-paramétrica que utiliza o mesmo conceito de MDS (ver Seção 2.2.2) para a representação espacial da similaridade entre pontos. Aqui, novas instâncias são mapeados no mesmo espaço criado a partir dos dados de teste e tem sua classe predita em função da região em que é posicionada. Muito utilizada em cenários com domínios complicados, SVM tende a ter um desempenho bastante robusto quando utilizar para definir categorias bem subdivididas [38].

Por sua vez, redes neurais são parte de um conceito mais vasto dentro do ramo de aprendizado de máquina e de inteligência artificial, muito utilizado em robótica e sensoriamento. De forma genérica, uma rede neural artificial (ou ANN, do inglês *Artificial Neural Network*) atua emulando a dinâmica real entre neurônios e estímulos. Para a classificação, boa parte do processamento se beneficia de redes como a perceptron [34], nas quais por retro-propagação de erro, estímulos externos (novos dados) alteram a estrutura da rede interna e, conseqüentemente o nível de resposta (classe) entregue pelo algoritmo. Mais sobre redes neurais pode ser estudado em [39].

Ainda que bem menos complexa que as redes neurais, uma outra linha de algoritmos bem conhecidos são os algoritmos de estimativas de densidade de Kernel (KDE, do inglês *Kernel Density Estimation*) [40], cuja abrangência chega a cobrir até métodos SVM em alguns casos. Esta família de algoritmos utiliza de uma formas não-paramétricas para estimar a função densidade de probabilidade de alguma distribuição desconhecida a partir de um conjunto finito de dados. Dentre esses, um que se destaca pela sua boa aplicabilidade e simplicidade é o método dos k -ésimos vizinhos mais próximos (KNN, do inglês *k-nearest neighbours*) [41], em que também por meio de uma representação espacial, novas instâncias são classificadas utilizando métricas de distância entre pontos conhecidos. Pela sua facilidade de assimilação e aproximação muito clara com o problema de localização proposto para o TTE, iremos explorar o algoritmo KNN em mais detalhes diretamente em uma aplicação no Capítulo 6.

3 CARACTERIZAÇÃO DO CENÁRIO TTE

Sistemas de comunicações TTE possuem propriedades de propagação que se diferenciam de forma significativa daquelas encontradas em sistemas sem fio que utilizam radiofrequência (RF). Devido a características intrínsecas do solo, a penetração de ondas eletromagnéticas em meio condutor é dada por difusão. Diferentemente das propriedades definidas pela equação de onda, a equação de difusão apresenta decaimento exponencial do campo para distância e frequência de operação do sistema.

Nesse cenário, modelos e infraestrutura comumente utilizados têm sua aplicabilidade questionada. Somadas às limitações físicas de espaço, limitações de frequência restringem as dimensões de antenas viáveis e colocam em cheque faixas de operações comumente utilizadas. Ainda, propriedades básicas da onda, como velocidade de propagação e comprimento de onda sofrem alterações em meio condutor e dielétrico no solo. Aproximações utilizadas na literatura para zonas de campo eletromagnético precisam então ser revisitadas e revalidadas para esse contexto específico do TTE.

Assim, surge a necessidade de construção de um modelo que seja compatível com o cenário de propagação descrito. Este capítulo apresenta a caracterização de um modelo teórico como visto em [42], [43] e [44], apresentando o equacionamento para um modelo de campo baseado em indução magnética e, na sequência, a modelagem do canal utilizando antenas *loop* e suas características.

3.1 MODELAGEM DO CANAL

A penetração de um campo magnético $\mathbf{H} = \mathbf{H}(x, y, z, t)$ ao longo do tempo t em meio condutor com permeabilidade magnética μ , permissividade elétrica ϵ e condutividade elétrica σ é regida pela equação de difusão $\nabla^2 \mathbf{H} = \mu\sigma \partial \mathbf{H} / \partial t$. Diferentemente da equação de onda $\nabla^2 \mathbf{H} = \mu\epsilon \partial^2 \mathbf{H} / \partial t^2$, na propagação por difusão, para um bom condutor, com $\sigma / (\epsilon\Omega) \gg 1$, o decaimento é exponencial. Função da frequência angular Ω , o grau desse decaimento é medido pela profundidade pelicular $\delta = \sqrt{2 / (\Omega\mu\sigma)}$, cujo comportamento é inversamente proporcional à raiz quadrada de Ω . Sendo exponencialmente atenuada para sinais de alta frequência, a transmissão nesses meios costuma utilizar frequências mais baixas, usualmente abaixo de 30 kHz.

Frequências tão baixas necessitariam de antenas de dimensões na ordem de quilômetros para radiar de forma eficiente ondas de rádio no meio. Tais requisitos são inviáveis no

cenário requerido das aplicações TTE. No entanto, a permissividade real pode ser desconsiderada para um bom condutor e o comprimento de onda que atravessa a rocha é então dado por $\lambda_{rocha} = 2\pi\delta$. Nesse caso, para um solo com $\sigma = 10^{-3}$ S/m, por exemplo, sistemas de comunicação TTE operando a 10 kHz podem reduzir o comprimento de onda em relação ao ar em 30 vezes, viabilizando a utilização de antenas de menor dimensão.

Ainda em relação ao meio condutivo, campo transmitido no solo apresenta características específicas que variam a depender da distância entre os transmissores. Para o TTE, divisões de zonas de campo classicamente exploradas para transmissão no vácuo e no ar são revistas por Gibson [42] que propõe uma subdivisão diferente.

Em regiões muito próximas à antena de transmissão, o campo possui uma natureza quase-estática seguindo leis da estática, apesar da variação no tempo, apresentando atenuação pelo inverso do cubo da distância, por exemplo. A partir do chamado campo próximo, onde ainda inexistente radiação, o meio condutor começa a contribuir em atenuação de campo. Por sua vez, na zona de campo distante, apesar das perdas devido ao meio, o campo obedece lei de atenuação com inverso linear da distância, como para o caso análogo no espaço livre. Diferentemente da zona para o vácuo, no entanto, para o meio condutivo, a radiação não parte da antena diretamente, o mecanismo de propagação é determinado por indução de correntes de Foucault geradas pelo campo magnético da antena. Finalmente, a zona de transição é uma região arbitrária, intermediária entre os campos próximo e distante.

A Tabela 3.1 mostra as aproximações propostas para um meio condutivo num comparativo com a divisão tradicionalmente proposta para o vácuo. Em ambos os casos as condições para os dois tipos de meio são determinadas para uma distância r entre as antenas.

<i>Modelo</i>	<i>Tipo de Aproximação</i>	<i>Condições</i>
Vácuo	Campo próximo reativo	$r < \lambda_0/2\pi$
	Campo próximo radiante	$\lambda_0/2\pi < r < \lambda_0$
	Zona de transição	$\lambda_0 < r < 2\lambda_0$
	Campo distante	$r > 2\lambda_0$
Meio Condutivo	Quase estático	$r \ll \lambda_{rocha}/2\pi$
	Campo próximo	$r^2 \ll (\lambda_{rocha}/2\pi)^2$
	Zona de transição	$r \approx \lambda_{rocha}/2\pi$
	Campo distante	$r \gg \lambda_{rocha}/2\pi$

Tabela 3.1: Zonas de campo no vácuo e em meio condutivo.

Como exemplo, retomando os valores colocados anteriormente para um sistema operando a 10 kHz ($\lambda_0 = 30$ km), no espaço livre com separação entre antenas de 100 m, o campo é tratado na zona de campo próximo reativo ($\lambda_0/2\pi \approx 4775$ m). Por sua vez, para um meio condutor, com $\sigma = 10^{-3}$ e $\mu = \mu_0$, $\lambda_{rocha}/2\pi = \delta \approx 160$ m $>$ 100 m e, logo, o campo pode ser tratado como num campo quase estático.

3.1.1 Modelo de Campo Magnético

Nas operações em minas terrestres, dimensões comuns são da ordem das dezenas ou centenas de metros, restringindo os serviços de transmissão através da terra para zonas de campo próximo ou quase estático. Aqui, a transferência de potência reativa por indução magnética (ou elétrica) é responsável por quase toda a potência transmitida.

Em sistemas por indução, antenas *loop* são comumente utilizadas para a transmissão por serem mais sensíveis à componente magnética do campo. O momento magnético $m_d = N_{tx}I_{tx}S_{tx}$ de uma antena *loop* representa a capacidade de transmissão indutiva da antena em função de suas características. N_{tx} é o número de voltas do loop de transmissão, I_{tx} é o valor RMS (do inglês, *Root Mean Square*) de uma corrente elétrica tonal nos filamentos da antena transmissora, e, finalmente, S_{tx} é a área do *loop*. Importante salientar que o aumento de momento magnético corresponde a um aumento da potência dissipada por calor, na forma $P_{tx} = R_{tx}I_{tx}^2$, em que a resistência R_{tx} do *loop* de transmissão aumenta com N_{tx} e/ou S_{tx} . Apesar de esta potência ser dissipada e não irradiada, ela influencia no valor de corrente usada na geração do campo magnético e, dessa forma, tem relação indireta com a potência de transmissão determinada.

Para uma aproximação do campo magnético gerado por uma antena *loop* eletricamente pequena existem várias maneiras [45]. A forma mais simples se faz considerando o vácuo como meio homogêneo infinito, sem condições de contorno, e supondo distribuição uniforme da corrente em todo o *loop*. Nesse caso, para uma distância muito próxima à fonte ($r \ll \lambda/2\pi$), a intensidade de um campo magnético variante no tempo se assemelha àquela de um campo estático calculada pela lei de Biot-Savart [46].

Para o caso explorado anteriormente de uma antena *loop* operando a uma frequência de 10 kHz (distância r na ordem de centenas de metros), um campo magnético quase-estático no vácuo, \mathbf{H}_{qe} , pode ser aproximado por:

$$\mathbf{H}_{qe} = \frac{m_d}{2\pi r^3} \{ \cos(\theta)\hat{\mathbf{r}} + 0.5\text{sen}(\theta)\hat{\boldsymbol{\theta}} \}, \quad (3.1)$$

onde $\hat{\mathbf{r}}$ e $\hat{\boldsymbol{\theta}}$ são vetores unitários em coordenadas esféricas nas direções radial e elevacional. Interessante salientar aqui que para $\theta = 180^\circ$ em configuração coaxial, desaparece

o termo de campo na direção elevacional, restando apenas o campo vertical na direção \hat{r} .

De forma direta, a adaptação do modelo de plano infinito no vácuo [45] para o de um meio infinito condutivo (MIC) modifica somente o número de onda, $k_{rocha} = (1 + j)/\delta$. Para meio condutivo, o campo quase-estático tem aproximação em coordenadas esféricas dada por:

$$\mathbf{H}_{qe} = \frac{m_d}{4\pi r^3} e^{-jT} e^{-T} \{2\cos(\theta)(1 + (1 + j)T)\hat{r} + \sin(\theta)(1 + (1 + j)T) + 2jT^2\}\hat{\theta}, \quad (3.2)$$

onde $T = r/\delta = r\sqrt{\Omega\mu\sigma/2}$ é a distância normalizada pela profundidade pelicular δ , incluindo na formulação a consideração de perdas no solo. Nesse contexto, o parâmetro T pode ainda ser interpretado como uma frequência espacial normalizada para uma dada distância r . A derivação completa de (3.2) é apresentada em [42].

Aproximações das equações de campo para os campos próximo e distante podem ser obtidas utilizando as condições dispostas na Tabela 3.1, considerando que $\delta = r/T = \lambda_{rocha}/2\pi$. Ainda, outros modelos mais complexos, que consideram uma composição com diferentes interfaces entre superfície e subterrâneo, como os propostos por Wait [43], [47] e Durkin [44] também podem ser derivados no mesmo formato do modelo proposto em (3.2). No entanto, uma vez que o foco deste trabalho é no processo de localização, estes modelos não serão abordados no texto.

3.1.2 Modelo de Canal

A partir do modelo de campo, a modelagem do canal é analisada comumente pela parametrização de quadripolos, considerando parâmetros de potência e energia. No entanto, para sistemas que operam em frequências relativamente baixas - abaixo de 100 kHz como as exploradas no TTE - o conceito de impedância de transferência é utilizado para avaliar um modelo para canal de propagação. A impedância de transferência entre os *loops* é dada por:

$$Z(\Omega) = \frac{V_{rx}(\Omega)}{I_{tx}(\Omega)}, \quad (3.3)$$

em que, $I_{tx}(\Omega)$ é corrente tonal no *loop* de transmissão e a $V_{rx}(\Omega)$ é tensão induzida nos terminais da antena receptora. Pela Lei de Faraday, a tensão induzida por um campo magnético nos terminais de um condutor de malha fechada depende da variação temporal do fluxo magnético que adentra esta malha em sentido ortogonal a seu plano [46]. Dessa forma, a tensão induzida nos terminais da antena receptora em função do

campo magnético é dada por:

$$V_{rx}(\Omega) = -j\Omega N_{rx} \int_S \mu \mathbf{H} dS = -j\Omega \mu N_{rx} S_{rx} \mathbf{H} \cos(\varphi), \quad (3.4)$$

em que N_{rx} e S_{rx} são o número de voltas e a área do *loop* de recepção, respectivamente. Da geometria do problema, φ é o ângulo entre o campo magnético \mathbf{H} e o eixo da antena ortogonal a seu plano. Expressando \mathbf{H} em coordenadas esféricas, dividido em suas componentes \mathbf{H}_r na direção $\hat{\mathbf{r}}$ e \mathbf{H}_θ na direção $\hat{\boldsymbol{\theta}}$, (3.4) se torna:

$$V_{rx}(\Omega) = -j\Omega \mu N_{rx} S_{rx} [\mathbf{H}_r \cos(\theta - \theta_x) \cos(\theta_y) - \mathbf{H}_\theta \sin(\theta - \theta_x) \cos(\theta_y)], \quad (3.5)$$

onde θ_x e θ_y são ângulos de rotação para os eixos auxiliares \mathbf{x}' e \mathbf{y}' , criados pela rotação do eixo \mathbf{z} por um ângulo ϕ , o ângulo de azimute.

A Figura 3.1 ilustra a geometria para $\hat{\mathbf{r}}$ e $\hat{\boldsymbol{\theta}}$. Importante notar que, se os planos dos *loops* de transmissão e recepção forem paralelos, então $\varphi = \theta$.

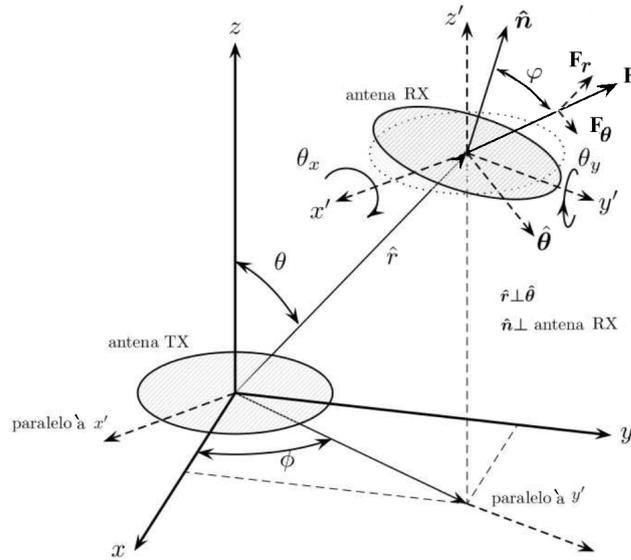


Figura 3.1: Geometria para $\hat{\mathbf{r}}$ e $\hat{\boldsymbol{\theta}}$ para duas antenas *loop* circulares. O ângulo ϕ é resultado das rotações nos eixos \mathbf{x}' e \mathbf{y}' .

Retomando para uma corrente tonal no transmissor dada a partir do momento magnético fasorial $m_d(\Omega) = N_{tx} S_{tx} I_{tx}(\Omega)$, e a tensão induzida dada em (3.5), podemos reavaliar a impedância de transferência. Para um cenário MIC com a equação de campo derivada em (3.2), a (3.3) pode ser reescrita como:

$$Z_{MIC}(T) = N_{tx} N_{rx} S_{tx} S_{rx} \left[\sqrt{G_r^{tx} G_r^{rx}} \mathbf{F}_r + \sqrt{G_\theta^{tx} G_\theta^{rx}} \mathbf{F}_\theta \right], \quad (3.6)$$

em que a frequência espacial normalizada T foi utilizada no lugar de Ω para unificar a variável dependente. Em (3.6), os ganhos normalizados para as antenas de transmissão e recepção nas direções $\hat{\mathbf{r}}$ e $\hat{\boldsymbol{\theta}}$ são $G_r^{tx} = \cos^2(\theta)$, $G_r^{rx} = \cos^2(\theta - \theta_x)\cos^2(\theta_y)$, $G_\theta^{tx} = \sin^2(\theta)$ e $G_\theta^{rx} = \sin^2(\theta - \theta_x)\cos^2(\theta_y)$.

E, finalmente, \mathbf{F}_r e \mathbf{F}_θ são as funções de transferência para o canal, dadas, respectivamente, por:

$$\mathbf{F}_r = \frac{T^2\sqrt{1+2T+2T^2}}{\pi\sigma r^5} e^T e^{j\left\{\tan^{-1}\left(\frac{T}{1+T}\right)-T-\frac{\pi}{2}\right\}} \quad (3.7)$$

e

$$\mathbf{F}_\theta = \frac{T^2\sqrt{(1+T)^2+(T+2T^2)^2}}{2\pi\sigma r^5} e^T e^{j\left\{\tan^{-1}\left(\frac{T+2T^2}{1+T}\right)-T+\frac{\pi}{2}\right\}}. \quad (3.8)$$

Na Figura 3.1 os vetores \mathbf{F}_r e \mathbf{F}_θ são apresentados para o sistema de coordenadas projetado.

3.2 MODELO DE PERDA DE PROPAGAÇÃO

O cálculo da potência entregue ao receptor em função dos parâmetros do sistema é importante para o processo de localização. Sendo potência recebida o valor obtido diretamente pela medição RSS, utilizando informações sobre a potência transmitida é possível estimar uma relação da perda de propagação no canal e, consequentemente, da distância entre transmissor e receptor.

Uma formulação para o modelo de perda de propagação faz-se então necessária e será apresentado nesta seção.

3.2.1 Derivação do Modelo Teórico

Como colocado anteriormente, a potência dissipada no *loop* de transmissão é considerada na formação do campo magnético induzido. A relação entre a potência transmitida no primeiro *loop* e entregue ao receptor do segundo *loop* é dada por:

$$\frac{P_{rx}}{P_{tx}} = \frac{|Z(T)|^2}{R_{tx}R_{rx}}, \quad (3.9)$$

de onde, abrindo a equação para abrigar as funções de transferência apresentadas em (3.7) e (3.8), obtêm-se:

$$\sqrt{P_{rx}} = \sqrt{P_{tx}} \Phi_{tx} \Phi_{rx} \left| \sqrt{G_r^{tx} G_r^{rx}} \mathbf{F}_r + \sqrt{G_\theta^{tx} G_\theta^{rx}} \mathbf{F}_\theta \right|, \quad (3.10)$$

em que Φ_{tx} e Φ_{rx} são as aberturas específicas das antenas de transmissão e recepção, respectivamente. A abertura específica de uma antena *loop* é função do seu raio l , massa M , densidade de massa ρ_l , e condutividade do fio σ_l , na forma $\Phi = 0,5l\sqrt{M\sigma_l/\rho_l}$.

Tanto $Z(T)$ quanto P_{rx}/P_{tx} carregam parâmetros intrínsecos dos *loops* utilizados. Logo, importante a observação que escolhe-se aqui usar funções de transferência \mathbf{F} que, apesar de serem dependentes da forma da antena, independem de seus parâmetros, permitindo que o modelo seja utilizado para antenas *loop* quaisquer.

Reescrevendo a expressão em (3.10) para a diferença $PL = P_{rx} - P_{tx}$ enquanto atenuação da potência do sinal, o modelo para a perda de propagação pode ser derivado para uma relação mais direta entre a distância r e a perda de potência obtida. O modelo para essa representação é dado por:

$$PL(r, \theta_x, \theta_y) = -20 \log_{10}(\Phi |G_r \mathbf{F}_r + G_\theta \mathbf{F}_\theta|). \quad (3.11)$$

Em 3.11, $PL(r, \theta_x, \theta_y)$ é a perda de potência em dB a uma distância r para ângulos θ_x e θ_y . Aqui $G_r = \sqrt{G_r^{tx} G_r^{rx}}$, $G_\theta = \sqrt{G_\theta^{tx} G_\theta^{rx}}$ e $\Phi = \Phi_{tx} \Phi_{rx}$.

Finalmente, considerando a medição RSS como o parâmetro medido na antena receptora, a perda de potência real deve ser tomada como:

$$\widetilde{PL}(r, \theta_x, \theta_y) = PL + \chi, \quad (3.12)$$

com χ uma variável aleatória de distribuição gaussiana $\mathcal{N}(0, s^2)$, representando o erro na medida da perda de potência, com desvio padrão s . Desta forma, leva-se em conta tanto o ruído de medição, como o fato de que o canal é diferente daquele previsto pelo modelo, por exemplo devido a irregularidades no meio físico.

3.2.2 Aproximação para o Modelo

O modelo proposto na literatura e derivado em (3.11), embora de fácil assimilação, apresenta uma formulação fechada cuja manipulação algébrica é complexa. Para desenvolvimentos matemáticos que exigem cálculos de formas fechadas para derivadas e integrais, por exemplo, a manipulação direta das funções de transferência apresentadas em (3.7) e (3.8) se torna inviável.

Em particular, algoritmos de otimização como os discutidos no escopo deste trabalho utilizam, em sua maioria, derivadas de primeira e segunda ordem, cuja formulação para estas funções que combinam variáveis complexas, senoidais, exponenciais e polinomiais é de difícil obtenção.

Como forma de simplificar os cálculos e aprimorar a eficiência dos métodos de localização que serão apresentados posteriormente, uma reparametrização do modelo foi desenvolvida e proposta como aproximação.

Em suma, a equação (3.11) pode ser reescrita desenvolvendo-se os termos nas funções de transferência \mathbf{F}_r e \mathbf{F}_θ , na forma:

$$PL = -20 \log_{10} \left(\Phi \sqrt{u^2 G_r^2 + 2uv \cos(\psi - \zeta) G_r G_\theta + v^2 G_\theta^2} \right), \quad (3.13)$$

em que os termos, enquanto variáveis complexas, são representados em suas formas polares. Aqui, u e v são os valores absolutos e ψ e ζ são as fases, respectivamente para \mathbf{F}_r e \mathbf{F}_θ , na forma dada em (3.7) e (3.8), sendo:

$$u = \frac{T^2}{\pi \sigma r^5} e^{-T} \sqrt{1 + 2T + 2T^2}, \quad (3.14)$$

$$v = x \sqrt{\frac{1}{4} + \frac{T^3(1+T)}{(1+T)^2 + T^2}}, \quad (3.15)$$

$$\psi = \tan^{-1} \left(\frac{T}{1+T} \right) - T - \frac{\pi}{2}, \quad (3.16)$$

e

$$\zeta = \tan^{-1} \left(\frac{T + 2T^2}{1+T} \right) - T + \frac{\pi}{2}. \quad (3.17)$$

No seguimento desse estudo, para que a derivação dos cálculos seja abordada mais facilmente, u , v , ψ e ζ são manipulados e utilizados em sua forma polinomial.

Partindo de (3.13), uma nova formulação foi então pensada para substituir as equações expressas para u , v , ψ e ζ . A proposta é substituir as funções complexas do modelo original por funções mais simples, que apresentem um comportamento similar na faixa de estudo do problema de localização. O modelo de perda de propagação aproximado aqui proposto é dado por:

$$PL_{approx} = -20 \log_{10} \left(\Phi \sqrt{a^2 G_r^2 + 2abc G_r G_\theta + b^2 G_\theta^2} \right), \quad (3.18)$$

no qual, $a = a_1 r^{-a_2}$, $b = b_1 r^{-b_2}$ e $c = c_1 \log_{10}(r + c_2)$. a_1 , a_2 , b_1 , b_2 , c_1 e c_2 são novos parâmetros derivados do modelo de canal. Os valores dos parâmetros propostos podem ser escolhidos por calibração e, subsequentemente, refinados por algoritmos de otimização, como os que serão apresentados no Capítulo 4.

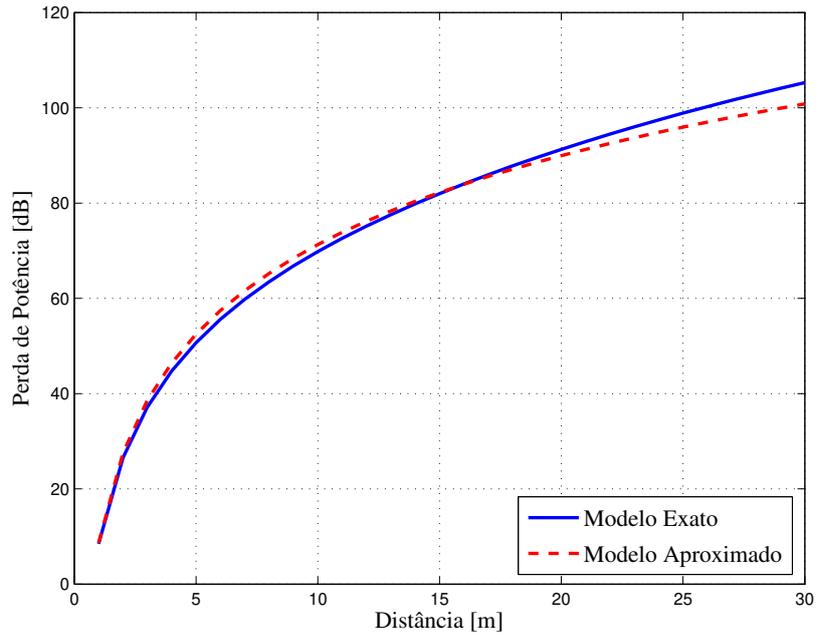


Figura 3.2: Comparativo entre TTE e o modelo aproximado para a perda de potência para uma dada variação na distância.

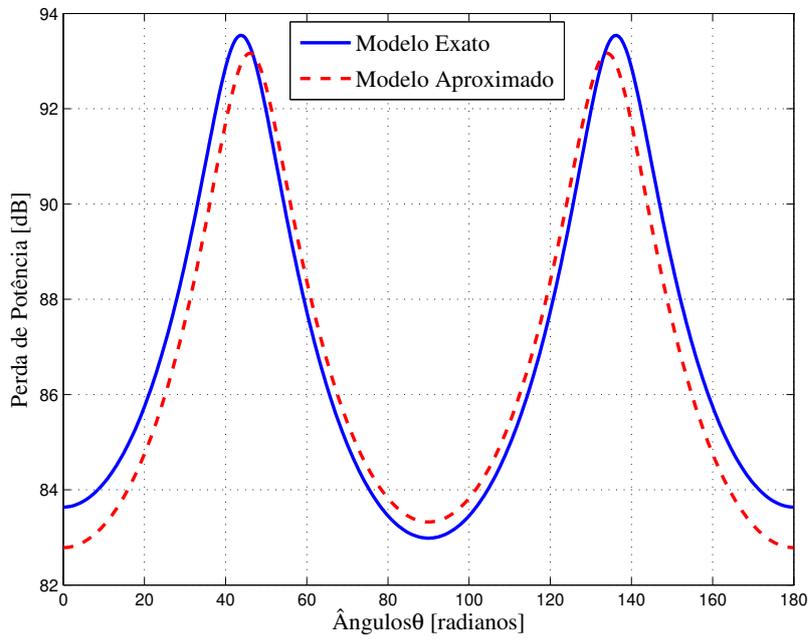


Figura 3.3: Comparativo entre TTE e o modelo aproximado para a perda de potência para um dado ângulo θ .

As Figuras 3.2 e 3.3 apresentam um comparativo do comportamento da perda de potência relativa em aos modelos em (3.13) e (3.18) para variações da distância r e do ângulo θ .

Como pode ser visto, a curva do modelo teórico aproximado segue a curva do modelo teórico original de forma satisfatória dentro de uma faixa de valores esperada nas aplicações TTE em estudo.

Nos próximos capítulos, o modelo aproximado pela reparametrização será utilizado em paralelo com o modelo teórico original nas técnicas de localização consideradas e terá seu desempenho avaliado de forma comparativa, avaliando a viabilidade da simplificação proposta.

4 TÉCNICAS DE LOCALIZAÇÃO

A aplicação bem sucedida de uma técnica de localização está diretamente ligada à adequação do algoritmo ao cenário proposto. Mesmo para um cenário TTE típico, a depender do problema considerado na aplicação, diferentes técnicas apresentam maior ou menor viabilidade para um mesmo desempenho desejado.

No cenário de *tags* de baixa complexidade e potência, por exemplo, o escopo de informações sobre as coordenadas é limitado. Como estabelecido na Seção 2.2, o problema descrito para a rede de sensores prevê a obtenção de estimativas de distância por meio de medidas RSS. Essas medidas, devido a erros inerentes ao canal e ao processo de medição, quando utilizadas na trilateração não mais estabelecem um ponto de intersecção exato, mas sim toda uma região de coordenadas possíveis. O problema se torna então a resolução de um sistema de equações não lineares de solução não única (ver Seção 2.2.3), cuja abordagem segue aquela de problemas de otimização: encontrar a melhor solução possível dentre as viáveis.

Este capítulo constrói o problema de localização como um problema de otimização e apresenta abordagens possíveis para sua solução. Técnicas que lidam com resolução de sistemas não lineares são exploradas e suas características quando aplicadas ao TTE são apresentadas na forma de métodos de mínimos quadrados não lineares e em uma aplicação de otimização estocástica.

4.1 LOCALIZAÇÃO COMO UM PROBLEMA DE OTIMIZAÇÃO

Na matemática, processos de otimização são processos que buscam encontrar a melhor solução para um problema dentro de um conjunto de cenários (ou valores) possíveis [48].

Muitos problemas práticos envolvem problemas de otimização, procurando maximizar ou minimizar “custos” existentes, como por exemplo a determinação do melhor preço a partir das leis de oferta e demanda na economia e a formulação de compostos químicos estáveis pela relação de equilíbrio entre reagentes e produtos.

Para esses tipos de problema, um número finito de parâmetros é estimado a partir do melhor ajuste de um conjunto de dados a um certo modelo. Nesse sentido, o problema de localização estabelecido pode ser visto também como um problema de otimização.

Estimar as coordenadas mais adequadas de uma região de pontos possíveis a partir de medidas obtidas nada mais é do que minimizar os erros dessas medidas em relação a um modelo existente.

Geralmente, esse procedimento envolve encontrar mínimos ou máximos para a chamada função objetivo, representativa do custo associado ao evento que se quer otimizar. Quando a função objetivo $G(\boldsymbol{\alpha})$ é a soma dos quadrados de funções não lineares [49] o problema de otimização é também chamado de problema de mínimos quadrados (ou LS, do inglês *Least Squares*) não linear, pois são minimizadas as somas dos quadrados de funções $g(\boldsymbol{\alpha})$, na forma:

$$G(\boldsymbol{\alpha}) = \frac{1}{2} \sum_{i=1}^m (g_i(\boldsymbol{\alpha}))^2 = \frac{1}{2} \|\mathbf{g}(\boldsymbol{\alpha})\|^2. \quad (4.1)$$

Para a questão proposta de localização, cujas equações que relacionam a perda de potência à posição relativa são não lineares, a abordagem segue a de problemas desse tipo.

Em termos práticos, queremos minimizar a soma dos erros $g(\boldsymbol{\alpha})$ - comumente denominadas resíduos - de cada relação de medida de potência entre *tag* e âncora. Queremos encontrar $\boldsymbol{\alpha}^*$ para uma *tag* de maneira que:

$$\boldsymbol{\alpha}^* = \arg \min_{\boldsymbol{\alpha}} G(\boldsymbol{\alpha}) = \arg \min_{\boldsymbol{\alpha}} \sum_{i=1}^m (g_i(\boldsymbol{\alpha}))^2. \quad (4.2)$$

Aqui, pelo modelo obtido no Capítulo 3 para a perda de potência, $\boldsymbol{\alpha} = [x, y, z, \theta_x, \theta_y]$ e $g_i(\boldsymbol{\alpha}) = \widetilde{PL}_i(\boldsymbol{\alpha}) - PL_i(\boldsymbol{\alpha})$, em que \widetilde{PL}_i é a medida de perda de potência e PL_i é a perda de potência estimada pelo modelo em (3.11) para a âncora i em dB, sendo m o número de âncoras. Ao minimizar $G(\boldsymbol{\alpha})$, encontramos os parâmetros $\boldsymbol{\alpha}$ que correspondem de forma mais acurada ao modelo para os dados observados em cada âncora.

O problema colocado em (4.2) é geralmente bem difícil de ser resolvido. Soluções para sistemas de equações não lineares são mais complicados do que aqueles que apresenta apenas equações lineares, de forma que até determinar se uma solução existe é difícil.

No caso específico de problemas LS, nem sempre é possível encontrar um minimizador global para $G(\boldsymbol{\alpha})$. São vários os métodos para se resolver problemas de otimização desse tipo, mas a maioria alcança apenas minimizadores locais. Técnicas como o método do gradiente, método de Newton ou método de pesquisa linear, por exemplo,

encontram valores mínimos apenas dentro de uma região controlada em torno de uma estimativa inicial e não em todo o domínio da função [50].

Ainda assim, existem métodos específicos para problemas LS não lineares cujo desempenho apresenta melhor eficiência, alcançando convergências melhores que lineares e por vezes até convergência quadrática. Tais técnicas, em sua maioria iterativas, geralmente encontram bastante aplicabilidade na resolução de problemas práticos e são base de muitas soluções robustas em sistemas de localização.

Na próxima seção, um dos algoritmos mais conhecidos para solução de problemas LS não lineares, o método de Gauss-Newton, é apresentado em mais detalhes para o problema de localização.

4.2 MÉTODO DE GAUSS-NEWTON

O Método de Gauss-Newton (aqui por vezes abreviado GN) é uma modificação do conhecido método de Newton, comumente utilizado para a aproximação das raízes de uma função. Também iterativo, os algoritmos de Gauss-Newton são geralmente aplicados em problemas de regressão não-linear, estimando parâmetros do modelo que estejam em concordância com os dados observados.

Diferentemente de outros métodos, Gauss-Newton não utiliza de derivadas de segunda ordem do modelo para a obtenção das estimativas dos parâmetros. Tal característica representa uma vantagem em termos de viabilidade para problemas cujo cálculo de formulações fechadas é complexo, como é o caso aqui em estudo (Ver Seção 3.2.2 para mais detalhes).

Assim como para os métodos de Newton, algoritmos GN funcionam como base para algoritmos mais complexos com foco maior em convergência e acurácia. Um desses algoritmos, o método de Levenberg-Marquardt, será estudado em mais detalhes na Seção 4.2.1.

A ideia básica do método de Gauss-Newton é aproximar um modelo não linear por um modelo linear na vizinhança de $\boldsymbol{\alpha}^*$ a partir de derivadas de primeira ordem e então refinar as estimativas de forma iterativa. De forma geral, o que se procura é minimizar os resíduos e encontrar o vetor $\boldsymbol{\alpha}^*$ de forma que, como condição necessária:

$$\nabla G(\boldsymbol{\alpha}^*) = \left[\frac{\partial G}{\partial x} \frac{\partial G}{\partial y} \frac{\partial G}{\partial z} \frac{\partial G}{\partial \theta_x} \frac{\partial G}{\partial \theta_y} \right]^T = 0. \quad (4.3)$$

As raízes de (4.3) podem ser encontradas através da solução do sistema de equações formado pelas derivadas parciais de $G(\boldsymbol{\alpha})$, cuja interpretação pode ser facilitada se

reescrita em forma matricial. De fato, da (4.1):

$$G(\boldsymbol{\alpha}) = \frac{1}{2} \sum_{i=1}^m (g_i(\boldsymbol{\alpha}))^2 = \frac{1}{2} \|\mathbf{g}(\boldsymbol{\alpha})\|^2 = \frac{1}{2} \mathbf{g}(\boldsymbol{\alpha})^T \mathbf{g}(\boldsymbol{\alpha}). \quad (4.4)$$

Como comentado, para o desenvolvimento do algoritmo GN é importante a obtenção das derivadas da função objetivo. Supondo que \mathbf{g} possui derivadas parciais de segunda ordem, pode-se escrever sua expansão em série de Taylor para um incremento \mathbf{p} como:

$$\mathbf{g}(\boldsymbol{\alpha} + \mathbf{p}) = \mathbf{g}(\boldsymbol{\alpha}) + \mathbf{J}(\boldsymbol{\alpha})\mathbf{p} + O(\|\mathbf{p}\|^2), \quad (4.5)$$

em que $\mathbf{J} \in \mathbb{R}^{m \times n}$ é o Jacobiano, cujas entradas são as derivadas parciais de primeira ordem das componentes de \mathbf{g} , ou seja,

$$(\mathbf{J}(\boldsymbol{\alpha}))_{ij} = \frac{\partial g_i}{\partial \alpha_j}(\boldsymbol{\alpha}). \quad (4.6)$$

Logo, para as derivadas da função objetivo, segue de (4.4) que:

$$\frac{\partial G}{\partial \alpha_j}(\boldsymbol{\alpha}) = \sum_{i=1}^m g_i(\boldsymbol{\alpha}) \frac{\partial g_i}{\partial \alpha_j}(\boldsymbol{\alpha}), \quad (4.7)$$

e o gradiente em (4.3) se torna:

$$\mathbf{G}'(\boldsymbol{\alpha}) = \mathbf{J}(\boldsymbol{\alpha})^T \mathbf{g}(\boldsymbol{\alpha}). \quad (4.8)$$

Da mesma forma, para o Hessiano de G , podemos escrever, a partir de (4.7), que:

$$\frac{\partial^2 G}{\partial \alpha_j \partial \alpha_k}(\boldsymbol{\alpha}) = \sum_{i=1}^m \left(\frac{\partial g_i}{\partial \alpha_j}(\boldsymbol{\alpha}) \frac{\partial g_i}{\partial \alpha_k}(\boldsymbol{\alpha}) + g_i(\boldsymbol{\alpha}) \frac{\partial^2 g_i}{\partial \alpha_j \partial \alpha_k}(\boldsymbol{\alpha}) \right), \quad (4.9)$$

mostrando que a derivada de segunda ordem pode ser dada então por:

$$\mathbf{G}''(\boldsymbol{\alpha}) = \mathbf{J}(\boldsymbol{\alpha})^T \mathbf{J}(\boldsymbol{\alpha}) + \sum_{i=1}^m g_i(\boldsymbol{\alpha}) \mathbf{g}_i''(\boldsymbol{\alpha}). \quad (4.10)$$

Para se obter a aproximação linear na qual se baseia o método GN, retomamos a expansão em série de Taylor apresentada em (4.5) para valores pequenos de $\|\mathbf{p}\|$. A função \mathbf{g} na vizinhança de $\boldsymbol{\alpha}$ pode ser então aproximada por um modelo \mathbf{l} em que:

$$\mathbf{g}(\boldsymbol{\alpha} + \mathbf{p}) \simeq \mathbf{l}(\mathbf{p}) \equiv \mathbf{g}(\boldsymbol{\alpha}) + \mathbf{J}(\boldsymbol{\alpha})\mathbf{p}. \quad (4.11)$$

Utilizando a aproximação (4.11) na definição em (4.4) e manipulando a equação, temos, para $\mathbf{g} = \mathbf{g}(\boldsymbol{\alpha})$ e $\mathbf{J} = \mathbf{J}(\boldsymbol{\alpha})$, que:

$$\begin{aligned} G(\boldsymbol{\alpha} + \mathbf{p}) &\simeq L(\mathbf{p}) \equiv \frac{1}{2} \mathbf{l}(\mathbf{p})^T \mathbf{l}(\mathbf{p}) \\ &= \frac{1}{2} \mathbf{g}^T \mathbf{g} + \mathbf{p}^T \mathbf{J}^T \mathbf{g} + \frac{1}{2} \mathbf{p}^T \mathbf{J}^T \mathbf{J} \mathbf{p} \\ &= G(\boldsymbol{\alpha}) + \mathbf{p}^T \mathbf{J}^T \mathbf{g} + \frac{1}{2} \mathbf{p}^T \mathbf{J}^T \mathbf{J} \mathbf{p}. \end{aligned} \quad (4.12)$$

E, de forma direta, derivando para o gradiente e o Hessiano de $L(\mathbf{p})$ temos:

$$\mathbf{L}'(\mathbf{p}) = \mathbf{J}^T \mathbf{g} + \mathbf{J}^T \mathbf{J} \mathbf{p}, \quad (4.13a)$$

$$\mathbf{L}''(\mathbf{p}) = \mathbf{J}^T \mathbf{J}. \quad (4.13b)$$

Conhecendo $L(\mathbf{p})$, o incremento do algoritmo de Gauss Newton é aquele que, da definição de otimização, minimiza $L(\mathbf{p})$, ou seja,

$$\mathbf{p}_{gn} = \arg \min_{\mathbf{p}} L(\mathbf{p}). \quad (4.14)$$

Logo, dado que $\mathbf{L}''(\mathbf{p})$ independente de \mathbf{p} , se as colunas de \mathbf{J} são linearmente independentes, i.e. tem posto completo, então a matriz do Hessiano é definida positiva, podendo-se afirmar que a função objetivo $G(\boldsymbol{\alpha})$ possui um minimizador que é único [51].

Dessa forma, a partir de (4.14) o incremento de Gauss-Newton pode ser encontrado pela solução de:

$$(\mathbf{J}^T \mathbf{J}) \mathbf{p}_{gn} = -\mathbf{J}^T \mathbf{g}. \quad (4.15)$$

que se considerando o processo gerado por uma estimativa inicial $\boldsymbol{\alpha}^{(0)}$, então, pode ser substituído como passo iterativo na forma:

$$\boldsymbol{\alpha}^{(k+1)} = \boldsymbol{\alpha}^{(k)} + (\mathbf{J}^T \mathbf{J})^{-1} \mathbf{J}^T \mathbf{g}(\boldsymbol{\alpha}^{(k)}), \quad (4.16)$$

que é a equação que expressa o método de Gauss-Newton para um modelo específico.

O incremento gerado no passo de Gauss Newton tem sentido descendente e o seu tamanho pode ser ponderado por métodos de pesquisa linear [50]. No algoritmo tradicional, considerado na formulação aqui mostrada, este fator de ponderação é unitário.

Notadamente, dado o sentido descendente, se o algoritmo converge, o limite é um ponto estacionário do domínio, atingido para $\mathbf{J}_k^T \mathbf{p}_{gn,k} = 0$. Nesse caso, (4.3) é satisfeita

e mais iterações não são necessárias. Contudo, o algoritmo pode ainda convergir lentamente ou não convergir, caso a matriz aproximada do Hessiano esteja mal condicionada ou a estimativa inicial esteja muito longe do ponto de mínimo.

Na prática, a aproximação da derivada de segunda ordem obtida em $\mathbf{L}''(\mathbf{p})$ reduz a complexidade dos cálculos e economiza um tempo considerável de processamento computacional, ponto forte da grande aplicabilidade do algoritmo. Para isso, no entanto, pressupõe-se que a função \mathbf{g} é derivável e o Jacobiano existe para o modelo considerado. Como colocado anteriormente, é imposta a condição de que o Jacobiano tenha posto completo em todas as etapas iterativas, sendo o seu cálculo essencial. No caso específico da localização TTE, essa condição reforça a necessidade que as equações de perda de potência sejam manipuláveis, permitindo a correta aplicação do método.

De forma geral, embora apresente bom desempenho e convergência rápida quando próximo a solução - convergência quadrática em casos específicos -, o método GN pode falhar, não encontrando um minimizador local de forma satisfatória. Versões modificadas são geralmente utilizadas em aplicações reais por apresentarem um melhor desempenho global e mais robustez. A próxima seção trata uma dessas versões, na forma do algoritmo de Levenberg-Marquardt.

4.2.1 Método de Levenberg-Marquardt

Desenvolvido por Levenberg em 1944 e posteriormente por Marquardt em 1963, o método de Levenberg-Marquardt (ou método LM) é uma das mais utilizadas versões modificadas do algoritmo de Gauss-Newton. Amplamente reconhecido como a versão mais robusta do método original, o método LM se diferencia por utilizar um fator de amortecimento para controlar de forma mais precisa a direção e o tamanho do passo em cada iteração do algoritmo.

Não sendo necessário um método de pesquisa linear para ponderar a iteração e utilizando da mesma aproximação do algoritmo GN para a matriz do Hessiano, a modificação da equação (4.15) para a inclusão do fator de amortecimento γ é direta, na forma:

$$(\mathbf{A} + \gamma \mathbf{I})\mathbf{p}_{lm} = -\mathbf{q}, \quad (4.17)$$

com $\mathbf{q} = \mathbf{J}^T \mathbf{g}$, $\mathbf{A} = \mathbf{J}^T \mathbf{J}$ e $\gamma \geq 0$. As aglutinações em \mathbf{A} e \mathbf{q} são utilizadas para facilitar a explicação do algoritmo e, como já feito anteriormente, $\mathbf{g} = \mathbf{g}(\boldsymbol{\alpha})$ e $\mathbf{J} = \mathbf{J}(\boldsymbol{\alpha})$.

Importante notar que sendo o fator de amortecimento sempre positivo, é garantido que a matriz inversa existe e é sempre definida positiva. Tal característica assegura

que as iterações seguem sempre em sentido descendente do incremento.

Avaliando o amortecimento em mais detalhes, é possível notar que quando γ é grande, temos $\mathbf{p} = \mathbf{J}^T \mathbf{g} / \gamma$ e, portanto, passos curtos na direção descendente ($\boldsymbol{\alpha}^{(k+1)}$ muito próximo de $\boldsymbol{\alpha}^{(k)}$). Esta configuração traz um progresso lento da convergência, o que é preferível se o estado atual está longe da solução.

Por outro lado, se o fator lambda é muito pequeno, os passos são mais largos ($\boldsymbol{\alpha}^{(k+1)}$ mais distante de $\boldsymbol{\alpha}^{(k)}$) e estes se aproximam do passo de GN dado em 4.16. Tal configuração é desejável nos últimos estágios da iteração, quando $\boldsymbol{\alpha}$ está próximo de $\boldsymbol{\alpha}^*$ e a convergência deve ser mais rápida.

A escolha do valor do fator de amortecimento a cada iteração deve então ser controlada de forma a corresponder ao estado atual da minimização e ao passo que se pretende dar. Para um valor inicial γ_0 , a escolha é relacionada com o tamanho dos elementos da matriz \mathbf{A} , pela escolha de,

$$\gamma_0 = \tau \max_i \{a_{ii}^{(0)}\} \quad (4.18)$$

em que τ é um fator definido pelo usuário, geralmente pequeno e com pouca influência no desempenho do algoritmo [51]. Na aplicação realizada neste trabalho utilizamos $\tau = 10^{-3}$.

A atualização de γ segue então controlada pela chamada taxa de ganho, dada pela equação:

$$\varrho = \frac{G(\boldsymbol{\alpha}) - G(\boldsymbol{\alpha} + \mathbf{p}_{lm})}{L(\mathbf{0}) - L(\mathbf{p}_{lm})} \quad (4.19)$$

na qual o denominador pode ser reescrito para representar o ganho previsto em (4.12) pela linearização. Manipulando a expressão matemática em (4.19), obtemos:

$$\begin{aligned} L(\mathbf{0}) - L(\mathbf{p}_{lm}) &= -\mathbf{p}_{lm}^T \mathbf{J}^T \mathbf{g} - \frac{1}{2} \mathbf{p}_{lm}^T \mathbf{J}^T \mathbf{J} \mathbf{p}_{lm} \\ &= -\frac{1}{2} \mathbf{p}_{lm}^T (2\mathbf{q} + (\mathbf{J}^T \mathbf{J} + \gamma \mathbf{I} - \gamma \mathbf{I}) \mathbf{p}_{lm}) \\ &= \frac{1}{2} \mathbf{p}_{lm}^T (\gamma \mathbf{p}_{lm} - \mathbf{q}). \end{aligned} \quad (4.20)$$

Logo, dados os dois termos na soma final de (4.20) positivos, então o denominador $L(\mathbf{0}) - L(\mathbf{p}_{lm})$ é sempre positivo.

A relação em (4.19) é um comparativo entre a redução real existente da diferença no conjunto de dados medidos, representados nas funções objetivo do numerador, e a redução prevista pela aproximação linear proposta, pautada no denominador. Se temos um valor alto da taxa de ganho, isso indica que $L(\mathbf{p}_{lm})$ é próximo de $G(\boldsymbol{\alpha} + \mathbf{p}_{lm})$

e podemos então reduzir o fator de amortecimento, aproximando do passo de GN. Por outro lado, se a taxa de ganho é baixa ou tem valor negativo, ou seja $G(\boldsymbol{\alpha}) - G(\boldsymbol{\alpha} + \mathbf{p}_{lm}) > 0$, então a função objetivo não está mais em sentido descendente e a aproximação $L(\mathbf{p}_{lm})$ é uma aproximação ruim. Nesse cenário, devemos aumentar o valor de γ , retomando o sentido na próxima iteração e aumentando as chances de uma convergência mais rápida.

4.2.1.1 Apresentação do Algoritmo

O algoritmo como implementado neste trabalho é derivado de [51] e mostrado no Algoritmo 1 para os parâmetros ε como critérios de parada e as variáveis k e ν para a contagem de iterações e a ponderação do amortecimento, respectivamente.

Para as aplicações aqui realizadas, as alterações para aumento ou redução no fator de amortecimento a cada iteração são feitas com base na estratégia proposta em [52], que representa uma alternativa com transições mais fluidas para γ do que as propostas originalmente por Marquardt em [53].

Ainda, importante pautar a boa escolha dos fatores de parada ε . No Algoritmo 1, ε_1 reflete que a função objetivo atingiu valores próximos do ponto de mínimo ($\mathbf{G}'(\boldsymbol{\alpha}^*) = \mathbf{g}(\boldsymbol{\alpha}^*) = 0$) e, portanto, o processo iterativo pode ser interrompido. Da mesma forma, ε_2 para o algoritmo se a mudança observada em alpha é muito pequena entre duas iteração subsequentes, o que na no caso final representa $\boldsymbol{\alpha}^{(k+1)} = \boldsymbol{\alpha}^{(k)}$, que acontece apenas quando $\mathbf{J}^T(\boldsymbol{\alpha}^{(k)})\mathbf{g}(\boldsymbol{\alpha}^{(k)}) = 0$ (condição de optimalidade alcançada). Finalmente, k_{max} entra como parâmetro padrão para impedir a continuação de um loop infinito. Para todas as implementações aqui realizadas, os valores ε foram escolhidos como $\varepsilon_1 = \varepsilon_2 = 10^{-8}$ e $k_{max} = 200$.

Analicamente, o algoritmo de Levenberg-Marquardt pode ser interpretado também como a implementação de um método de região de confiança, em que o incremento \mathbf{p}_{lm} a cada iteração é tomado dentro de uma esfera cujo raio varia com a lógica inversa da variação do fator de amortecimento. Nesse cenário, se o modelo aproximado está próximo dos dados observados (taxa ρ alta), aumentamos o raio da região de confiança e permitimos passos mais largos do algoritmo, caso análogo àquele em que γ assume baixos valores. Por outro lado, se ρ é pequeno, reduzimos o raio da região de confiança e limitamos o tamanho do incremento \mathbf{p}_{lm} , reduzindo a velocidade de convergência e controlando melhor a iteração, que é exatamente o que ocorre quando γ é grande.

Algoritmo 1: MÉTODO DE LEVENBERG-MARQUARDT

Entrada: $\alpha^{(0)}, \varepsilon_1, \varepsilon_2, k_{max}$ **Saída:** Estimativa α

```
1 início
2    $k := 0$ 
3    $v := 2; \gamma_0 := \tau \max_i \{a_{ii}^{(0)}\}$ 
4    $\alpha := \alpha^{(0)}$ 
5    $\mathbf{q} := \mathbf{J}^T(\alpha)\mathbf{g}(\alpha); \mathbf{A} := \mathbf{J}^T(\alpha)\mathbf{J}(\alpha)$ 
6   found :=  $(\|\mathbf{q}\|)_\infty \leq \varepsilon_1$ 
7   enquanto (not found) e  $(k < k_{max})$  faça
8     Resolver  $\mathbf{p}_{lm}$  para (4.17)
9     se  $(\|\mathbf{p}_{lm}\| \leq \varepsilon_2(\alpha^{(k)} + \varepsilon_2))$  então
10      found := True
11    senão
12       $\alpha^{(k+1)} := \alpha^{(k)} + \mathbf{p}_{lm}$ 
13      Calcular  $\varrho$  por (4.19)
14      se  $\varrho > 0$  então
15         $\alpha^{(k)} := \alpha^{(k+1)}$ 
16        Recalcular  $\mathbf{A}$  e  $\mathbf{q}$ 
17        found :=  $(\|\mathbf{q}\|)_\infty \leq \varepsilon_1$ 
18         $\gamma := \gamma \max\{\frac{1}{3}, 1 - (2\varrho - 1)^3\}; v := 2$ 
19      senão
20         $\gamma := v\gamma; v := 2v$ 
21    fim
22  fim
23   $k := k + 1$ 
24 fim
25 fim
26 retorna  $\alpha$ 
```

A derivação do Método LM utilizando o artifício de regiões de confiança é mostrado em mais detalhes em [54].

Usualmente, métodos LM têm desempenho bem superior aos alcançados pelo método GN por terem mais controle sobre a influência do Hessiano. Via de regra, Levenberg-Marquardt apresenta resultados com melhor acurácia com o contraponto de precisar de mais iterações quando as estimativas estão distantes do mínimo, sendo especialmente

aplicados quando a formulação de \mathbf{J} apresenta problemas conhecidos em relação à independência linear ou não é controlável a cada iteração. Nesses casos, Gauss-Newton deixa de ser efetivo e as alternativas se torna necessária.

4.2.2 Aproximação Numérica: Método da Secante

Nos algoritmos apresentados anteriormente cuja base é o método de Newton, supomos que a função g é diferenciável, ou seja, o Jacobiano existe. No entanto, em algumas aplicações práticas não é possível encontrar uma formulação fechada para as derivadas da função em estudo ou, como é o caso para o modelo TTE apresentado no Capítulo 3, suas formulações são complexas e de difícil manipulação.

Enxergar a função modelada $g(\boldsymbol{\alpha})$ como uma “caixa preta”, em que apenas entradas e saídas são visualizadas embasou a derivação da técnica apresentada nesta seção. A otimização para problemas de mínimos quadrados é aplicada mantendo a lógica operacional dos métodos estudados anteriormente. Partindo do método mais robusto de Levenberg-Marquardt, a ideia aqui é utilizar o comportamento do modelo no ponto de cada iteração para obtenção de aproximações de suas derivadas. Tal realização pode ser alcançada por diferenciação numérica, na forma do método da secante [48].

Bem tradicional, o método da secante pode ser pensado como uma aproximação por diferenças finitas do método de Newton. O processo consiste em aproximar os elementos do Jacobiano a partir de uma relação de recorrência. A matriz $\mathbf{J}(\boldsymbol{\alpha})$ é substituída por \mathbf{B} , cujas elementos seguem a fórmula:

$$\frac{\partial g_i}{\partial \alpha_j}(\boldsymbol{\alpha}) \simeq \frac{g_i(\boldsymbol{\alpha} + \xi \mathbf{e}_j) - g_i(\boldsymbol{\alpha})}{\xi} \equiv b_{ij}, \quad (4.21)$$

em que \mathbf{e}_j é o vetor unitário na direção da j -ésima coordenada e ξ é um número real extremamente pequeno. De fato, para cada iteração em $\boldsymbol{\alpha}$ são realizadas $n + 1$ avaliações da função \mathbf{g} , uma para cada coordenada do vetor $\boldsymbol{\alpha}$. A eficiência do método depende então de forma direta da quantidade de parâmetros a serem otimizados. Para o caso de um único parâmetro, ou seja, $\boldsymbol{\alpha}$ como escalar, teríamos o método da secante tradicional. Como $\boldsymbol{\alpha}$ é um vetor coluna, costuma-se denominar essa técnica de método da secante generalizado.

Para adaptação do método LM, considerando a aproximação linear em (4.11), na substituição da matriz do Jacobiano pela matriz aproximada \mathbf{B} , temos que:

$$\mathbf{g}(\boldsymbol{\alpha} + \mathbf{p}) \simeq \mathbf{o}(\boldsymbol{\alpha}) \equiv \mathbf{g}(\boldsymbol{\alpha}) + \mathbf{B}\mathbf{p} \quad (4.22)$$

que continuando para a próxima iteração prevê \mathbf{B}_{k+1} com:

$$\mathbf{g}(\boldsymbol{\alpha}^{(k+1)} + \mathbf{p}) \simeq \mathbf{g}(\boldsymbol{\alpha}^{(k+1)}) + \mathbf{B}_{k+1}\mathbf{p} \quad (4.23)$$

Procuramos a igualdade $\mathbf{p} = \boldsymbol{\alpha}^{(k)} - \boldsymbol{\alpha}^{(k+1)}$, de forma que:

$$\mathbf{g}(\boldsymbol{\alpha}^{(k)}) = \mathbf{g}(\boldsymbol{\alpha}^{(k+1)}) + \mathbf{B}_{k+1}(\boldsymbol{\alpha}^{(k)} - \boldsymbol{\alpha}^{(k+1)}). \quad (4.24)$$

No entanto, temos m equações (m dados retirados de cada âncora) para a matriz \mathbf{B} de $m \times n$ elementos. Para suprir essa condição, uma substituição é sugerida em [55], em que:

$$\begin{aligned} \mathbf{B}_{k+1} &= \mathbf{B}_k + \mu \mathbf{p}^T, \quad \text{onde } \mathbf{p} = \boldsymbol{\alpha}^{(k+1)} - \boldsymbol{\alpha}^{(k)} \\ e \mu &= \frac{1}{\mathbf{p}^T \mathbf{p}} [\mathbf{g}(\boldsymbol{\alpha}^{(k+1)}) - \mathbf{g}(\boldsymbol{\alpha}^{(k)}) - \mathbf{B}_k \mathbf{p}] \end{aligned} \quad (4.25)$$

Para esta aproximação do Jacobiano na forma da matriz \mathbf{B} , Powell mostra que, se o conjunto de vetores $\boldsymbol{\alpha}^{(1)}, \boldsymbol{\alpha}^{(2)}, \dots$ converge para $\boldsymbol{\alpha}^*$, e os incrementos do conjunto $\{\mathbf{p}^{(k)}\}$ são linearmente independentes para todo $k \geq n$, então o conjunto de aproximações $\{\mathbf{B}_k\}$ converge para $\mathbf{J}(\boldsymbol{\alpha}^*)$, independentemente da escolha de $\{\mathbf{B}_0\}$ [56].

No entanto, esta condição nem sempre é atendida no processo iterativo. Por vezes, \mathbf{B} é uma aproximação tão pouco próxima da matriz original do Jacobiano que o incremento \mathbf{p} avaliado em determinada iteração não consegue sequer assumir o sentido descendente.

Em iterações desse tipo, pelo algoritmo LM, o valor de $\boldsymbol{\alpha}$ deve permanecer inalterado enquanto o fator de amortecimento γ é aumentado. Contudo, se em iterações subsequentes a aproximação \mathbf{B} continuar sendo uma aproximação pouco verossímil, o fator de amortecimento continuará aumentando indefinidamente enquanto a estimativa $\boldsymbol{\alpha}$ permanece afastada da solução $\boldsymbol{\alpha}^*$.

Para solucionar esse problema, a adição de etapas para recalculer o valor de \mathbf{B} em casos de não conformidade foi pensada. A solução aplicada neste trabalho considera um processo de atualizações cíclicas da matriz \mathbf{B} considerando coordenada-a-coordenada.

Aqui, para cada coordenada j (com $j = 1, \dots, n$) em uma determinada iteração de incremento $\{\mathbf{p}^{(k)}\}$, a relação entre o tamanho da coordenada e o tamanho do incremento é avaliada. Tal avaliação é feita por:

$$|p_j| < \kappa \|\mathbf{p}\| \quad (4.26)$$

em que, se o critério é atendido para um determinado fator arbitrário κ , então a aproximação para a coluna j é considerada ruim e a matriz \mathbf{B} é recalculada. Este novo cálculo de \mathbf{B} considera $\boldsymbol{\alpha}^{(k+1)} = \boldsymbol{\alpha}^{(k)} + \eta \mathbf{e}_j$, sendo:

$$\text{se } \alpha_j = 0, \text{ então } \eta := k^2, \quad (4.27a)$$

$$\text{se não, } \eta := k|\alpha_j|. \quad (4.27b)$$

Assim, através de um número maior de avaliações da função \mathbf{g} , procura-se mitigar o efeito de aproximações numéricas pouco verossímeis. Via de regra, enquanto o incremento \mathbf{p} é atualizado apenas se o critério da taxa de ganho (sentido descendente) é atendido, a aproximação \mathbf{B} é recalculada em todas as iterações, de forma que o gradiente \mathbf{q} pode ser alterado mesmo que $\mathbf{g}(\boldsymbol{\alpha})$ permaneça o mesmo.

4.2.2.1 Apresentação do Algoritmo

A sequência de passos de Levenberg-Marquardt adaptada para o método da secante é mostrada no Algoritmo 2.

Como é possível notar, o monitoramento do fator de amortecimento permanece o mesmo daquele presente no Algoritmo 1, sendo acrescentada apenas a etapa de avaliação da aproximação \mathbf{B} .

Na aplicação realizada neste trabalho, o fator κ é definido 0,8, para consideração de um cenário pessimista, como indicado em [51]. Ainda, \mathbf{B}_0 é calculado por (4.21), com ξ igual a 10^{-7} . Os outros parâmetros permanecem inalterados do Algoritmo 1.

Em termos práticos, o método da secante apresenta desempenho tão robusto quanto aquele do método LM original, mesmo sem o conhecimento prévio do formato do Jacobiano. No entanto, as múltiplas aproximações recalculadas para \mathbf{B} fazem com que a velocidade de convergência deste algoritmo seja bem mais baixa que a daquele. Portanto, se existem informações prévias sobre o gradiente da função, é sempre mais vantajoso utilizar o método LM original.

Em suma, Gauss-Newton e em especial sua versão na forma do algoritmo de Levenberg-Marquardt possuem desempenho muito bons na resolução de problemas de mínimos quadrados não lineares. Dentre outros métodos possíveis [57], os aqui estudados conseguem apresentar resultados expressivos em taxas de convergência sem perda de acurácia.

Algoritmo 2: LEVENBERG-MARQUARDT COM MÉTODO DA SECANTE

Entrada: $\alpha^{(0)}, \varepsilon_1, \varepsilon_2, k_{max}$ **Saída:** Estimativa α

```
1 início
2    $k := 0$ 
3    $v := 2; \gamma_0 := \tau \max_i \{a_{ii}^{(0)}\}$ 
4    $\alpha := \alpha^{(0)}$ 
5    $j := 0; \mathbf{B} := \mathbf{B}_0$ 
6    $\mathbf{q} := \mathbf{B}^T(\alpha)\mathbf{g}(\alpha); \mathbf{A} := \mathbf{B}^T(\alpha)\mathbf{B}(\alpha)$ 
7   found :=  $(\|\mathbf{q}\|)_\infty \leq \varepsilon_1$ 
8   enquanto (not found) e  $(k < k_{max})$  faça
9     Resolver  $\mathbf{p}_{lm}$  para (4.17)
10    se  $(\|\mathbf{p}_{lm}\| \leq \varepsilon_2(\alpha^{(k)} + \varepsilon_2))$  então
11      found := True
12    senão
13       $j := \text{mod}(j, n) + 1$ 
14      se  $(|p_j| < \kappa\|\mathbf{p}\|)$  então
15        Atualizar  $\alpha$  usando (4.27)
16         $\alpha^{(k+1)} := \alpha^{(k)} + \eta\mathbf{e}_j$ 
17        Calcular  $\mathbf{B}_{k+1}$  por Broyden (4.25)
18      fim
19       $\alpha^{(k+1)} := \alpha^{(k)} + \mathbf{p}_{lm}$ 
20       $\mathbf{B}_k := \mathbf{B}_{k+1}$ 
21      Calcular  $\varrho$  por (4.19)
22      se  $\varrho > 0$  então
23         $\alpha^{(k)} := \alpha^{(k+1)}$ 
24         $\gamma := \gamma \max\{\frac{1}{3}, 1 - (2\varrho - 1)^3\}; v := 2$ 
25      senão
26         $\gamma := v\gamma; v := 2v$ 
27      fim
28      Recalcular  $\mathbf{A}$  e  $\mathbf{q}$ 
29      found :=  $(\|\mathbf{q}\|)_\infty \leq \varepsilon_1$ 
30    fim
31     $k := k + 1$ 
32  fim
33 fim
34 retorna  $\alpha$ 
```

No entanto, a dependência de uma estimativa inicial minimamente próxima da solução final faz com que a aplicação desse tipo de algoritmo acabe se limitando em problemas cuja busca por mínimos locais é suficiente. Para os cenários em comunicações TTE, isto nem sempre é possível, sendo a aproximação da estimativa inicial um problema com o qual precisamos lidar.

A próxima seção apresenta um algoritmo que lida com a existência de mínimos globais de maneira mais robusta, contornando o problema dos métodos apresentados até então.

4.3 RECOZIMENTO SIMULADO (*SIMULATED ANNEALING*)

Métodos de otimização estocástica, nos quais a busca por uma configuração mínima ou máxima é realizada de forma probabilística, são uma categoria de algoritmos muito utilizados em problemas práticos. Diferentemente dos algoritmos explorados anteriormente, estes não são dependentes de derivadas e aproximações numéricas, podendo ser aplicados de forma mais ampla em cenários onde não é possível ou é muito complexo encontrar uma solução para as derivadas da função objetivo.

O método de Recozimento Simulado, ou SA (do inglês, *Simulated Annealing*) é um dos tipos mais conhecidos dessa categoria de técnicas estocásticas. Mais especificamente, Recozimento Simulado faz parte de uma classe de algoritmos que procuram emular padrões de otimização a partir de processos existentes na natureza. Nascidas como meta-heurísticas, técnicas que utilizam otimização por enxame de partículas, colônia de formigas, e algoritmos genéticos, por exemplo, encontram cada vez mais aplicabilidade atualmente, principalmente no ramo da inteligência artificial [58] [59].

Em particular, o método SA é baseado em um princípio da termodinâmica de partículas, bastante utilizado na metalurgia em um processo chamado de recozimento. Nesse processo, um metal é aquecido até altas temperaturas e depois lentamente resfriado de forma controlada até atingir um estado de baixa energia. Durante a etapa de resfriamento, átomos do metal tendem a se organizar em estruturas uniformes que minimizam a energia do sistema, resultando em um material de mais alta qualidade, mais estável e com propriedades melhores.

O princípio aqui é de que dando mais energia para os átomos se moverem livremente, mas mantendo o arrefecimento controlado, existem probabilidades maiores destes alcançarem uma configuração com menor energia interna. De fato, como um processo natural de base estocástica, o movimento nem sempre é previsível, com alguns pontos

de equilíbrio térmico ao longo do resfriamento do material podendo encontrar configurações de maior energia interna.

4.3.1 Descrição da Técnica

Como técnica, o método SA pode ser visto como uma interpretação mais avançada do Algoritmo de Metropolis [60], mesclando os princípios de mecânica estatística em um processo de otimização combinatória.

Como descrição mais utilizada na prática, um estado inicial é gerado no domínio da função e sua configuração é perturbada continuamente de forma iterativa. Se uma configuração com menor energia (ou seja, uma solução melhor) é encontrada, então a mudança é aceita, se a configuração apresenta maior energia (ou seja, é uma solução pior), a mudança não é rejeitada de cara e ainda pode ser aceita, mas com uma probabilidade definida.

Nessa propriedade entra a analogia direta com o processo de resfriamento: estados de maior energia interna podem ocorrer, contrariando o movimento descendente durante o equilíbrio térmico. Essa redução da temperatura é emulada em cada iteração e quanto maior a temperatura, maior a componente aleatória que define a probabilidade de aceite ou não de uma solução pior.

Esta propriedade do algoritmo em aceitar soluções piores durante o processo tem como função permitir que o mesmo escape da estagnação e de falsos mínimos. O movimento em sentido ascendente de maneira controlada surge como forma de evitar convergências prematuras e abrir espaço para o progresso em direções ainda mais descendentes, conseguindo possivelmente encontrar um ótimo global. Tal característica vai de encontro às propriedades estudadas anteriormente nas técnicas que seguem o método do gradiente, em que a configuração atual é perturbada exclusivamente em sentido descendente, podendo ficar facilmente presa em mínimos locais. Na Figura 4.1 um exemplo do funcionamento do método SA para uma função objetivo genérica é apresentado, mostrando que a partir de movimentos ascendentes é possível que o algoritmo encontre caminhos melhores.

No geral, o método SA pode ser visto em duas etapas: no início como uma exploração livre e ampla do domínio do problema, no qual movimentos ascendentes e descendentes são comuns, e em seguida, com a redução da temperatura e a probabilidade de soluções piores, como um processo de escalada estocástica (*hill-climbing*), refinando localmente as estimativas através de perturbações incrementais até uma possível solução ótima.

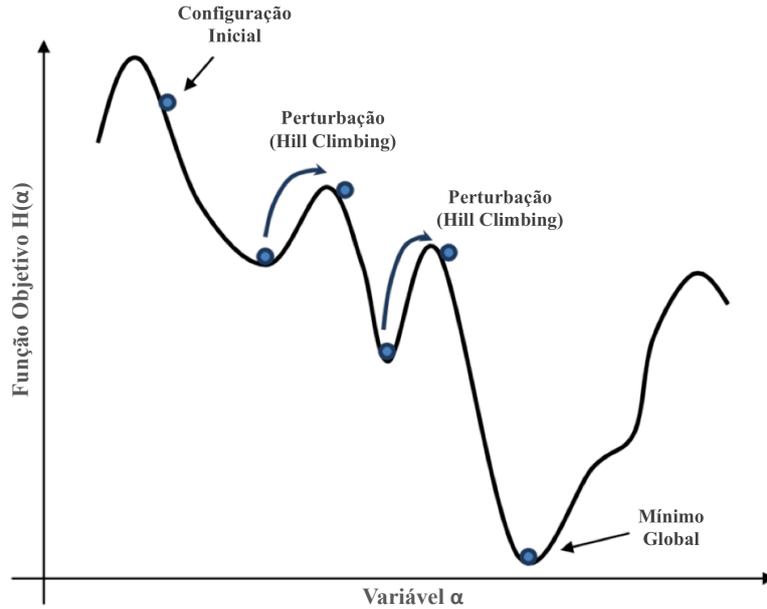


Figura 4.1: Comportamento do algoritmo de Recozimento Simulado para uma função genérica.

Assim, em termos matemáticos, o método prevê a avaliação de α em todo o domínio da função objetivo, com o intuito de encontrar uma solução ótima sem que a estimativa fique presa em mínimos locais.

No cenário das redes de sensores TTE, a partir de estimativas aleatórias da posição inicial das *tags*, em cada iteração do algoritmo, uma perturbação é realizada alterando os parâmetros em α (posições estimadas e ângulos) em direções e sentidos aleatórios, gerando assim um novo valor $\alpha^{(k)}$. A função objetivo $G(\alpha)$ é então recalculado para a nova estimativa de localização e a mudança $\Delta(G) = G(\alpha^{(k+1)}) - G(\alpha^{(k)})$ é avaliada.

Se $\Delta(G) \leq 0$, a função objetivo assume um valor menor que o da iteração anterior e, portanto, os parâmetros encontrados apresentam menor erro de medida em relação às âncoras. A nova coordenada é então utilizada como ponto inicial para a próxima iteração. Para $\Delta(G) > 0$, situação em que as novas coordenadas apresentam maior erro em relação às âncoras e estão possivelmente mais distantes, a aceitação entra no modelo probabilístico do método.

Para reproduzir as características do processo natural, onde o aceite é mais provável a altas temperaturas e bastante improvável a temperaturas reduzidas, o fator de Boltzmann, derivado originalmente em [60] é utilizado para calcular essa probabilidade. A

função de aceitação é dada por:

$$\mathfrak{B}(\Delta) = \begin{cases} 1, & \text{se } \Delta \leq 0 \\ \exp\left(\frac{-\Delta}{\mathfrak{T}}\right), & \text{c.c.} \end{cases}, \quad (4.28)$$

em que a função de probabilidade depende da diferença de energia entre os estados e de um parâmetro global, \mathfrak{T} , comumente denominado temperatura como referência ao processo natural e que varia de forma estritamente decrescente a partir de uma função chamada função de resfriamento.

A partir de 4.28, escolhida em cada iteração uma variável c aleatoriamente dentro do intervalo $[0, 1]$, faz-se então:

- $\mathfrak{B}(\Delta) \geq c$, a solução pior é aceita;
- $\mathfrak{B}(\Delta) < c$, a solução pior é rejeitada.

Durante o processo de aceite, a variável \mathfrak{T} determina a sensibilidade do sistema a variações de energia e, por conseguinte, à evolução do algoritmo. A medida que \mathfrak{T} diminui, a função \mathfrak{B} também diminui e, portanto, maior a probabilidade de uma solução ruim ser rejeitada. No caso limite em que $\mathfrak{T} = 0$, a função aceita apenas movimentos descendentes, no sentido de soluções melhores.

Interessante notar ainda que a função \mathfrak{B} é ponderada pela diferença $\Delta(G)$ de forma inversamente proporcional: se a variação na energia aumenta, a função \mathfrak{B} diminui. Para grandes alterações na energia do sistema, a possibilidade de aceitação de uma solução pior é menor, ou seja, mudanças mais próximas para estados piores são mais aceitas. Essa propriedade ajuda a reduzir a ocorrência de movimentos muito drásticos.

4.3.1.1 Apresentação do Algoritmo

O método SA como utilizado neste trabalho é apresentado em seu pseudocódigo no Algoritmo 3.

Como comentado anteriormente, o estado inicial $\alpha^{(0)}$ é escolhido de forma aleatória e a temperatura \mathfrak{T}_0 é inicializada com um valor alto. Nas simulações realizadas, foi utilizado \mathfrak{T}_0 igual a 100.

A função de vizinhança diz respeito a perturbação no estado atual em cada iteração. Ela é importante principalmente quando a progressão da função objetivo apresenta localmente muitos picos envoltos por vales profundos em seu domínio. Este

é o caso encontrado no modelo de perda de potência do TTE, cuja influência dos ângulos de rotação θ_x e θ_y promove características senodais à função $G(\boldsymbol{\alpha})$.

Dentre várias alternativas, foi escolhida a função de vizinhança rápida [61], dada por:

$$\mathfrak{R}(\boldsymbol{\alpha}) : \boldsymbol{\alpha}^{(k+1)} = \boldsymbol{\alpha}^{(k)} + \mathbf{J}w, \quad (4.29)$$

em que $w \in \mathfrak{D}$ é um vetor aleatório com $\|w\| = 1$.

Notadamente, o algoritmo pode ser enxergado como sendo repetido para os dois ciclos formados pelos *loops* interno e externo. O *loop* interno realiza a perturbação no sistema e o procedimento de decisão, a partir dos cálculos probabilísticos e do critério estabelecido na função de aceitação. Por sua vez, o *loop* externo realiza o procedimento de resfriamento, promovendo a redução da temperatura de forma controlada até que os critérios de parada sejam atendidos para uma estimativa ótima do vetor $\boldsymbol{\alpha}$.

No *loop* externo, a função de resfriamento existe para garantir que a temperatura seja atualizada apenas quando o equilíbrio térmico é atingido. Dentre algumas opções na literatura, esse comportamento é representado aqui pela equação de resfriamento rápido:

$$\mathfrak{T}_{novo} = \mathfrak{T}_0/k, \quad (4.30)$$

cuja resposta é bem equilibrada em termos de desempenho, velocidade e simplicidade, como mostrado em [61].

Como comentado, a escolha de um valor suficientemente alto para \mathfrak{T}_0 é necessária para que o algoritmo faça uma busca ampla por \mathfrak{D} . No entanto, não é interessante que isto se repita por um grande número de iterações e dificulte o movimento final de convergência. Para manter um ritmo adequado no *loop* de resfriamento e definir o ponto de equilíbrio térmico, uma taxa de aceitação, \mathfrak{S} , é estabelecida e contabiliza a razão entre soluções ruins aceitas em relação ao total de perturbações realizadas para uma determinada temperatura.

Definida como 0,8 (valor retirado da literatura para [62]), uma vez atingida a taxa de aceitação, o equilíbrio térmico é considerado alcançado e o *loop* externo atualiza a temperatura utilizando (4.30). Para as execuções realizadas neste trabalho, se \mathfrak{S}_0 não é atingido em no máximo 100 perturbações ($\mathfrak{N}_0 = 100$), o *loop* interno para e a temperatura é atualizada de qualquer maneira.

Algoritmo 3: MÉTODO DE RECOZIMENTO SIMULADO

Entrada: $\mathfrak{T}_0, \mathfrak{S}_0, \mathfrak{N}_0, \varepsilon_1, k_{max}$

Saída: Estimativa α

```
1 início
2    $k := 0$ 
3    $\mathfrak{T} := \mathfrak{T}_0$ 
4   Escolha aleatória  $\alpha^{(0)} \in \mathfrak{D}$ 
5    $found := False$ 
6   enquanto (not found) e ( $k < k_{max}$ ) faça
7     Inicializar estado ( $\alpha^{(k)}, G(\alpha^{(k)})$ )
8     Inicializar quantidade de perturbações  $\mathfrak{N}$  e taxa de aceitação  $\mathfrak{S}$ 
9      $q_{sucessos} := 0$ 
10    enquanto ( $\mathfrak{S} < \mathfrak{S}_0$ ) e ( $\mathfrak{N} < \mathfrak{N}_0$ ) faça
11      Aplicar função de vizinhança  $\mathfrak{N}(\alpha^{(k)})$ 
12      Calcular  $\Delta(G) = G(\alpha^{(k+1)}) - G(\alpha^{(k)})$ 
13      se ( $\Delta(G) < 0$ ) então
14         $\alpha^{(k)} := \alpha^{(k+1)}$ 
15         $q_{sucessos} := q_{sucessos} + 1$ 
16      senão
17        Calcular  $c \in \text{Rand}(0, 1)$ 
18        se ( $c \leq \mathfrak{B}(\Delta)$ ) então
19           $\alpha^{(k)} := \alpha^{(k+1)}$ 
20        fim
21      fim
22      se ( $\Delta(G) \leq \varepsilon_1$ ) então
23         $found := True$ 
24      fim
25       $\mathfrak{N} := \mathfrak{N} + 1$ 
26    fim
27    Aplicar função de resfriamento por (4.30)
28     $k := k + 1$ 
29    se ( $p_{sucessos} = 0$ ) então
30       $found := True$ 
31    fim
32  fim
33 fim
34 retorna  $\alpha$ 
```

De forma geral, o algoritmo para quando algum dos critérios de parada estabelecidos é alcançado. Aqui, como nos algoritmos mostrados na Seção 4.2, o número de iterações máximo (k_{max}) e a pequena variação no valor da função objetivo $G(\boldsymbol{\alpha})$ (ε_1) são definidos como critérios de parada e inicializados com os mesmos valores dados na Seção 4.2.1. Como terceiro critério, adicionamos $p_{sucessos}$ para contabilizar a não existência de iterações em sentido descendente para uma determinada temperatura. Uma vez alcançadas zero iterações descendentes, tal parâmetro representa a estabilidade do sistema e possivelmente o alcance de um mínimo local.

Ainda, para manter o algoritmo mais robusto e eficiente, duas modificações foram implementadas. A primeira diz respeito à memória do sistema, em que a melhor solução para uma determinada temperatura (e melhor geral até aquele momento) é armazenada em um *buffer* temporário na forma $(\boldsymbol{\alpha}_{best}, G_{best})$ e utilizada como ponto inicial da iteração seguinte. Esta proposta, base do método de seleção elitista [63], é feita com o objetivo de que o efeito de memória auxilie na convergência do algoritmo.

A segunda alteração é a adição de uma função de recuo, cujo objetivo é impedir que o novo ponto $\boldsymbol{\alpha}$ gerado após uma perturbação saia do domínio \mathcal{D} . Principalmente para impedir que coordenadas da posição caiam fora do espaço físico determinado, a função de recuo é representada pela combinação convexa:

$$\boldsymbol{\alpha}_{cc} = \zeta \text{Proj}(\boldsymbol{\alpha}^{(k+1)}) + (1 - \zeta)(\boldsymbol{\alpha}^{(k)}) \quad (4.31)$$

em que ζ é um número aleatório no intervalo $[0, 1]$ e $\text{Proj}(\cdot)$ é o operador que projeta qualquer ponto fora do domínio de volta em sua fronteira mais próxima.

De forma ampla, o algoritmo SA apresenta muita adaptabilidade em suas formulações e em suas estratégias de iteração, podendo utilizar diferentes procedimentos de resfriamento, aceitação e avaliação da função objetivo. As vantagens no uso de métodos SA são visíveis na facilidade com que a técnica é aplicada para muitos problemas reais bem distintos [64] e nos bons resultados de convergência alcançados em cenários práticos [65].

No comparativo com as técnicas de Gauss-Newton e Levenberg-Marquardt, o método de Recozimento Simulado surge como contraponto para cobrir as questões de dependência de uma estimativa inicial e de dificuldade em lidar com mínimos locais. Embora as primeiras apresentem melhor capacidade de refinamento, o fato de SA aceitar soluções ruins de forma controlada traz possibilidades de melhores caminhos para um mínimo global do sistema. Da mesma forma, a busca ampla pelo domínio da função permite testar pontos por vezes distantes da estimativa atual, conseguindo en-

tregar uma independência maior ao processo de pesquisa e assim mais liberdade na aplicação.

Essas características são importantes em um cenário como o do TTE, em que informações de posição e de funcionamento da rede de sensores ao longo do tempo podem não ser facilmente obtidas.

O próximo capítulo explora a aplicação das técnicas aqui apresentadas para o cenário TTE, explorando resultados comparativos de desempenho dos métodos de localização para cenários típicos de minas terrestres.

5 RESULTADOS DE SIMULAÇÃO

Ambientes de simulação são utilizados frequentemente em telecomunicações para testes iniciais de técnicas e algoritmos sob estudo. A possibilidade de simular previsões de comportamento de forma controlada antes de partir para o campo prático é um caminho extremamente útil, que permite que refinamentos, ajustes de compatibilidade e em diferentes interações entre cenários possam ser realizados sem grandes gastos de recursos.

A avaliação das técnicas de localização apresentadas no Capítulo 4 para o cenário TTE seguirá esse caminho. A ideia aqui é levantar, a partir da simulação das técnicas consideradas, questionamentos e possíveis soluções relativas à localização em sistemas TTE, antecipando situações reais e embasando melhores tomadas de decisão.

Este capítulo apresenta resultados de desempenho para os modelos e métodos descritos anteriormente, entregando comparativos e observações sobre diferentes cenários estudados, assim como o detalhamento da escolha dos parâmetros e do formato de simulação escolhidos.

5.1 CENÁRIO DE SIMULAÇÃO

A escolha de um cenário de simulação deve corresponder de forma verossímil ao ambiente prático pretendido. Nesse sentido, a escolha de um cenário de mineração, onde a maior parte das aplicações TTE tem uso direto, é justificada como uma representação realística da utilização de sistemas de comunicação através da terra.

Para a construção do cenário foi escolhido o caso base de minas terrestres de superfície, em que pilhas de material mineral de diferentes consistências químicas e físicas são desmontadas e têm suas partes espalhadas de forma aleatória em um terreno. Tal construção deve considerar as especificidades pertinentes ao processamento da exploração nessas condições, cujas características devem ser refletidas nos parâmetros de simulação.

5.1.1 Estrutura do Simulador

A implementação do simulador foi realizada em linguagem *Python*, como forma de prover mais acessibilidade ao projeto e menor dependência de plataformas e pacotes

específicos. A estrutura de código foi pensada como modular e a construção foi realizada orientada a objetos, permitindo uma variação mais controlada de parâmetros de entrada e facilitando a inserção futura de *features* e melhorias.

Todo o código utilizado no simulador que se refere ao processo de localização é autoral e baseado nas referências bibliográficas da área, que foram exploradas em mais detalhes no Capítulo 4. Bibliotecas adicionais foram, no entanto, buscadas em domínio público para a viabilização de funções matemáticas específicas e para a criação de gráficos e estruturas geométricas.

Para facilitar o entendimento, a divisão por módulos (ou classes) foi realizada representando cada parte integrante de um sistema de localização TTE separadamente e explicitando suas interações. A divisão pensada para o simulador é mostrada no diagrama de blocos da Figura 5.1, em que dividiu-se nas classes:

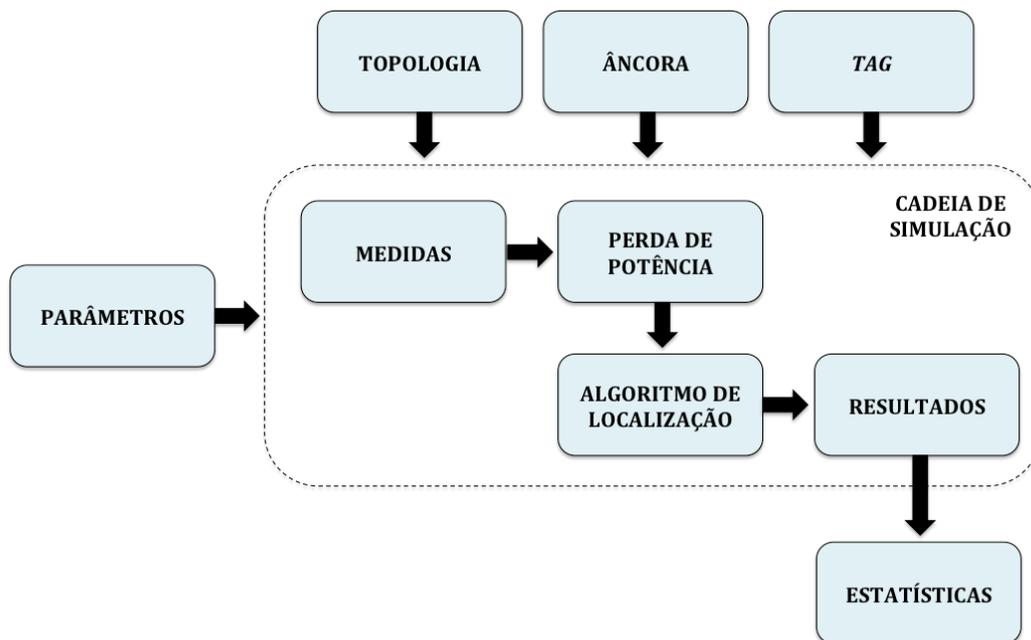


Figura 5.1: Diagrama de blocos da estrutura de simulação.

Parâmetros que define todos os parâmetros de simulação representativos para a localização em minas, como número de *tags*, número de âncoras, tipo de distribuição, potência máxima de transmissão, frequência de operação, etc;

Topologia onde é construído o modelo de estrutura física e a geometria

	da simulação, aqui considerando o formato e as dimensões da pilha, além da distribuição de tags e âncoras;
<i>Tag</i>	que instancia os objetos de cada <i>tag</i> do sistema, armazenando informações de ângulo e posição e dados de transmissão como potência máxima e características da antena;
Âncora	que constrói os objetos de cada âncora e, assim como a Classe <i>Tag</i> , possui informações de posição e de antena de recepção. Diferentemente das tags criadas pelo simulador, a posição de cada âncora é fixa, conhecida e pré-determinada pelo usuário, podendo ser numa posição escolhida ou seguindo alguma distribuição solicitada;
Medidas	cujas funções são a realização e o armazenamento de medidas de distância e angulação (reais e estimadas) a serem utilizados durante a simulação;
Perda de Potência	que realiza o cálculo de perda de potência para medida de RSS de acordo com modelo escolhido e os níveis de ruído do canal. No caso, utilizamos o modelo TTE apresentado no Capítulo 3.
Algoritmo de Localização	onde efetivamente as técnicas de localização apresentadas no Capítulo 4 são aplicadas;
Cadeia de Simulação	que roda todo o corpo da simulação e realiza o controle das iterações;
Resultados	onde as estimativas finais dos parâmetros são armazenadas juntamente com um indicador de qualidade correspondente, entregando ainda a representação gráfica dos resultados alcançados; e
Estatísticas	em que, finalmente, os resultados obtidos em cada iteração do algoritmo são compilados e calculados para a plotagem de curvas de desempenho.

De forma geral, a avaliação estatística das técnicas é realizada através de simulações de Monte Carlo [66]. Em cada ciclo de simulação, 100 ensaios são realizados com topologias geradas aleatoriamente. Em cada ensaio, amostras para n tags são distribuídas

uniformemente dentro de um volume delimitado, representativo da mina terrestre. As m âncoras, cujas posição são fixas e podem ser pré-determinadas *a priori*, são então posicionadas espaçadas sobre a superfície do volume.

Para cada posição desconhecida, o algoritmo é executado e um erro de localização é obtido. O resultado de um ensaio específico é armazenado em um indicador da qualidade do conjunto e ao final de cada ciclo uma estatística da simulação é retirada. Aqui utilizamos como métrica qualitativa da estimativa a raiz do erro quadrático médio (REQM ou RMSE, em inglês), fazendo referência ao erro na distância entre a posição estimada e a posição real de cada tag. Por sua vez, para a estatística de cada cenário, retiramos a média simples do conjunto de valores RMSE obtidos.

5.1.2 Parâmetros de Simulação

A escolha dos parâmetros utilizados para âncoras, *tags* e para o canal são mostradas nas Tabelas 5.1 e 5.2.

Parâmetros da Âncora	
Raio	1 m
Massa	10 kg
Densidade	8890 kg/m ³
Condutividade	$5,85e^7$ S/m
Parâmetros da <i>Tag</i>	
Raio	0,05 m
Massa	0,1 kg
Densidade	8890 kg/m ³
Condutividade	$5,85e^7$ S/m
Potência de Transmissão	30 mW

Tabela 5.1: Parâmetros de âncoras e *tags* para a simulação.

Parâmetros do Canal	
Permeabilidade	$4\pi 10^{-7}$ H/m
Condutividade	0,1 S/m
Frequência de operação	30 kHz

Tabela 5.2: Parâmetros do canal TTE para a simulação.

Os valores escolhidos para âncoras e tags consideram antenas *loop* formadas quase

inteiramente por cobre, sendo os valores de condutividade e densidade relativos a esse material. Notadamente, as dimensões das antenas para as tags são pequenas e sua potência é baixa, dados os limitantes da aplicação. As antenas das âncoras, por sua vez, podem ser maiores, o que reflete em uma maior abertura específica no modelo de perda de potência (equação 3.10).

Para os parâmetros do canal, a frequência de operação de 30 kHz foi escolhida considerando que as dimensões físicas da mina modelada são pequenas. A condutividade e a permeabilidade para o solo foram retiradas de [6] a partir dos estudos de Lincan em [67]. Em tempo, a variação na condutividade depende da formação das rochas e afeta, de forma geral, a formação do canal. Entretanto, a influência dessa variável no processo de localização não foi foco de estudo neste trabalho.

Como comentado no início da seção, o caso base escolhido para as simulações realizadas refere-se a uma mina terrestre de superfície marcada por *tags* que após o desmonte têm suas posições alteradas para coordenadas desconhecidas.

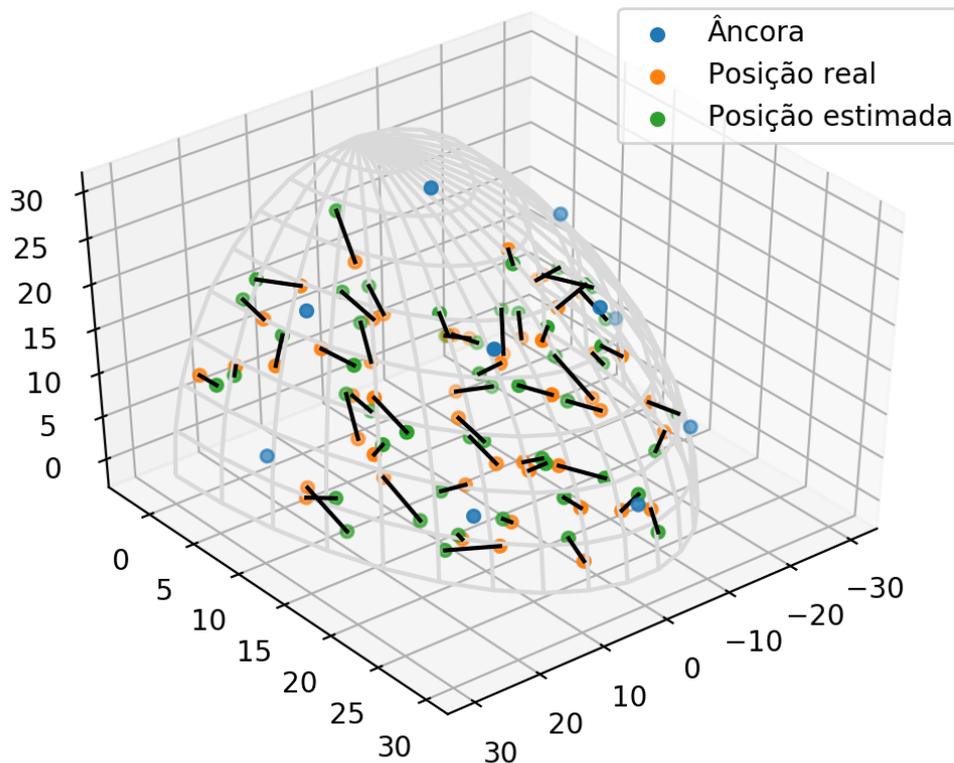


Figura 5.2: Topologia de cenário aleatório de localização gerado em simulador.

Para a representação da pilha desmontada foi escolhido como volume uma região semi-hemisférica centrada em $(0,0)$ e raio de 30 m. Em seu interior, 50 *tags* são

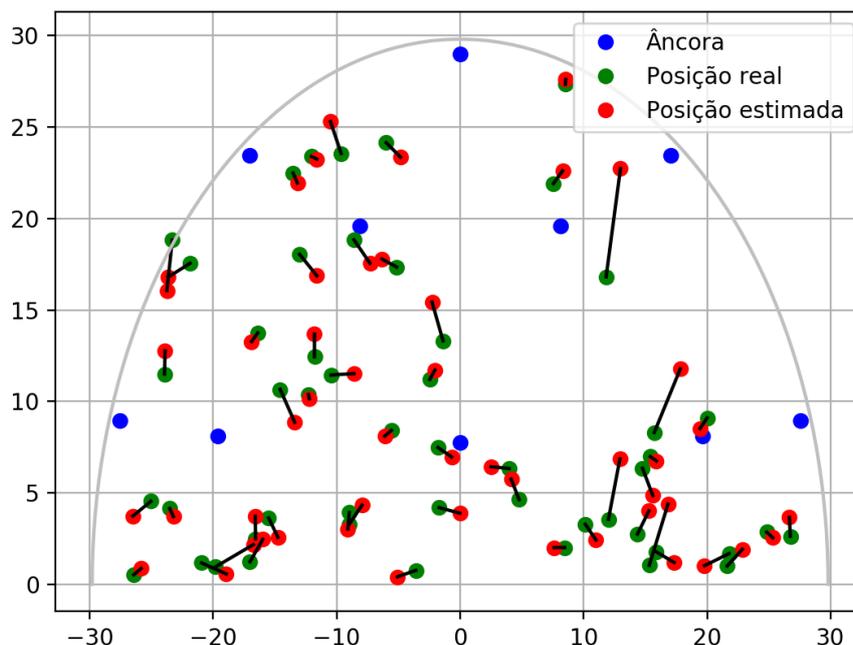


Figura 5.3: Topologia de cenário aleatório de localização gerado em simulador (vista superior).

espalhadas aleatoriamente a partir de uma distribuição uniforme. As Figuras 5.2 e 5.3 geradas no simulador para um cenário aleatório mostram essa topologia para uma visão 3D e uma vista superior em 2D, respectivamente. Cada posição estimada tem sua distância da posição real medida e representada geometricamente.

É importante salientar que para as topologias geradas, as âncoras são posicionadas apenas externamente. Tal condição é estabelecida para que cada *tag* possa se comunicar com todas as âncoras em uma geometria parecida, o que é uma proposição razoável em um cenário em que a pilha consegue ser lida em toda a sua extensão.

Aqui, a quantidade de âncoras utilizadas influencia na acurácia da estimativa de localização obtida (ver Seção 2.2), de forma que o seu valor é um variável considerada na avaliação de desempenho das técnicas. Os resultados para essa avaliação e a de outras variáveis são apresentados na próxima seção.

5.2 RESULTADOS DE DESEMPENHO

As análises realizadas observam a variação na qualidade da estimativa quando em diferentes cenários, considerando o comportamento do erro de localização (valor RMSE) em função de três variáveis do sistema: número de âncoras, erro na medição RSS e

estimativa inicial.

Intuitivamente, a avaliação para um crescente número de âncoras (m) foi escolhida por ter influência direta na acurácia alcançada pela trilateração. Quanto mais pontos amostrais, mais informações sobre a distância da tag procurada e, portanto, mais precisa é a estimativa. Como colocado na Seção 2.2.3, é necessário um mínimo de 4 âncoras para a determinação de um ponto no espaço. Consideraremos valores estudados a partir de 5 posições de âncora, subindo gradativamente até um total de 80 posições. Embora pareça inverossímil, supondo que o cenário é invariante no tempo, é possível alcançar um número grande de âncoras utilizando antenas com mobilidade, que variem sua posição a cada instante.

Por sua vez, o erro na medição RSS considera a variação obtida entre o valor calculado pelo modelo e o valor obtido pela medição. Principal fonte de erro do sistema, este diz respeito a ruídos, inconsistências entre o modelo adotado e o canal prático e outros imprecisões decorrentes do processo de medição. Na simulação, esta variação é considerada a partir do desvio padrão s da variável aleatória de erro introduzida em (3.12). Os valores utilizados começam em 0 dB, caso extremo onde não existiriam erros de medição, e vão até cerca de 50 dB de desvio.

Finalmente, a determinação de uma estimativa inicial é utilizada como ponto de partida nos algoritmos de otimização e portanto, a sensibilidade da localização a essa escolha deve ser avaliada. No geral, nas aplicações consideradas não há conhecimento prévio sobre a posição das *tags*, uma vez que durante o desmonte é possível que estas se espalhem de forma aleatória dentro do alcance da detonação, como foi feito aqui. Para considerar essa situação, a estimativa inicial para a *tag* é tomada em cada ensaio a uma distância uniformemente distribuída a partir de sua posição real. Mais especificamente, considera-se que a estimativa inicial está uniformemente distribuída dentro de uma região circular de raio d equivalente ao alcance máximo da detonação. Na simulação, consideramos desde o caso em que a estimativa inicial está a 0 m da posição real (ou seja, conhece-se a posição *a priori* da *tag*), até uma distância máxima com $d = 20$ m.

5.2.1 Desempenho geral dos modelos

Primeiramente, avaliamos o desempenho considerando a aplicação da técnica de Levenberg-Marquadt para um cenário de crescentes número de nós âncora. Os resultados são apresentados na Figura 5.4 para diferentes valores de erro na medição RSS e na estimativa inicial.

Como esperado, o erro RMS na estimativa da posição diminui para um aumento

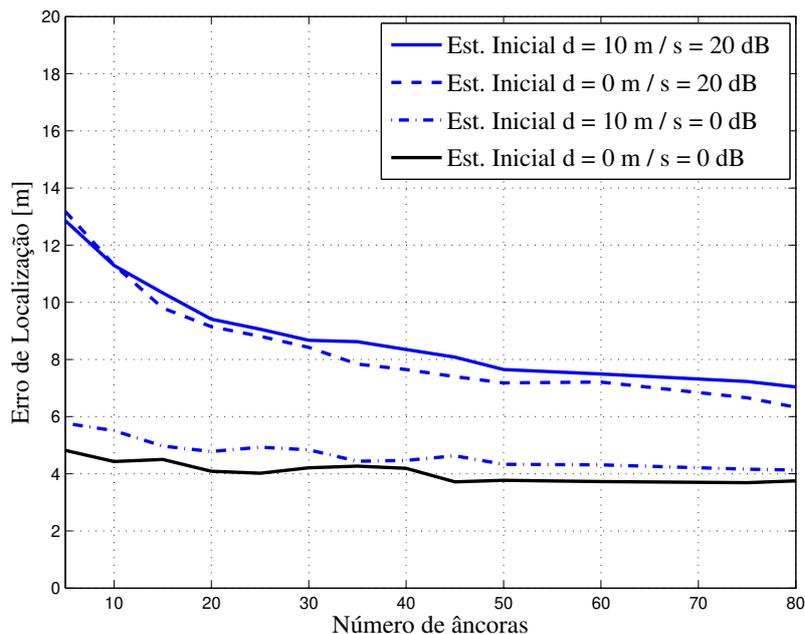


Figura 5.4: Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no número de nós âncora em diferentes distâncias d da estimativa inicial e diferentes desvios padrões s da medida RSS.

gradativo no número de âncoras, apresentando uma queda mais acentuada quando na presença de erros de medição. Em um cenário não ideal, para uma estimativa inicial dentro de um raio de 10 m da posição real e uma medida com desvio padrão de 20 dB, o erro de localização apresenta redução significativa já para algumas posições de âncora a mais.

Interessante notar que mesmo para o cenário específico em que erros na medida RSS seriam nulos e a conhecesse-se a posição real da *tag*, ainda assim existe um erro de localização associado, de aproximadamente 4m. Esse erro tem ligação com os ângulos θ_x e θ_z , que, podendo assumir qualquer valor entre 0 e 360°, têm grande influência no ganho associado.

Nas Figuras 5.5 e 5.6, o comportamento do erro de localização em relação aos erros de medida e de estimativa inicial, são mostrados em mais detalhes.

Novamente, em ambos os cenários, quanto maior é a quantidade de nós âncora, melhor é a estimativa da posição. Avaliando em escala, é possível notar que a técnica é menos sensível a alterações na estimativa inicial do que a alterações no erro na medição do RSS, alcançando erros quase três vezes maior para este segundo cenário. De forma geral, a influência do erro nas medidas RSS é muito significativa, dada a incerteza

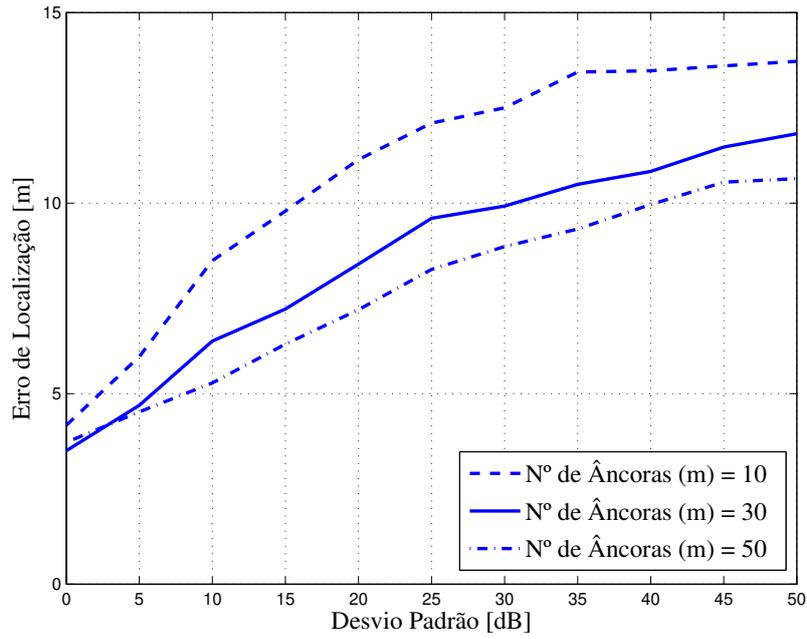


Figura 5.5: Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no desvio padrão da medida RSS para diferentes números m de nós âncora ($d = 0$ m).

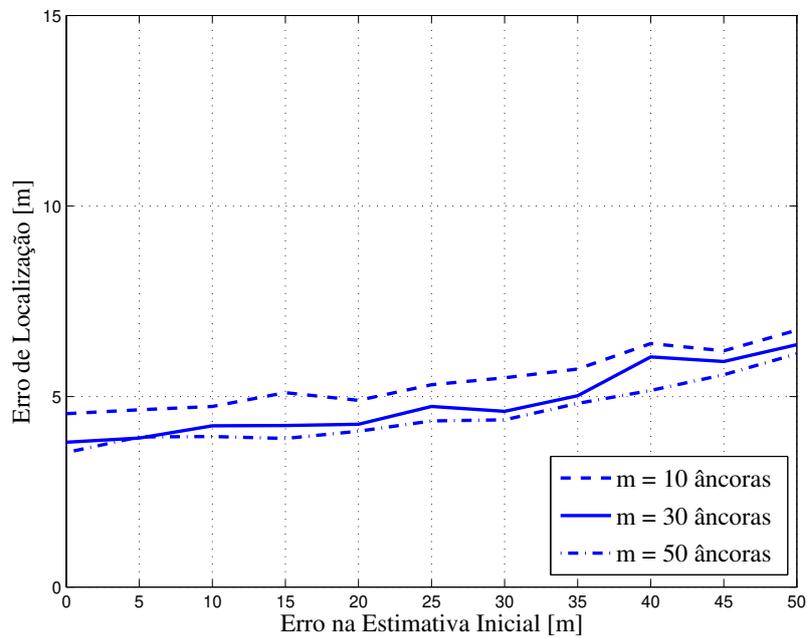


Figura 5.6: Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no erro máximo da estimativa inicial para diferentes números m de nós âncora ($s = 0$ dB).

gerada na trilateração.

Como detalhado no Capítulo 4, para métodos LS, uma estimativa inicial minimamente relacionada com a posição real é importante para o processo de otimização. No geral, a depender da função, posições iniciais aleatórias podem alcançar mínimos locais muito distantes das posições reais.

Essa situação é avaliada nas Figuras 5.7 e 5.8, em que o desempenho para um número crescente de âncoras e para um aumento do desvio padrão s é analisado quando pontos gerados aleatoriamente são comparados com aqueles gerados para estimativas iniciais dentro de um alcance conhecido.

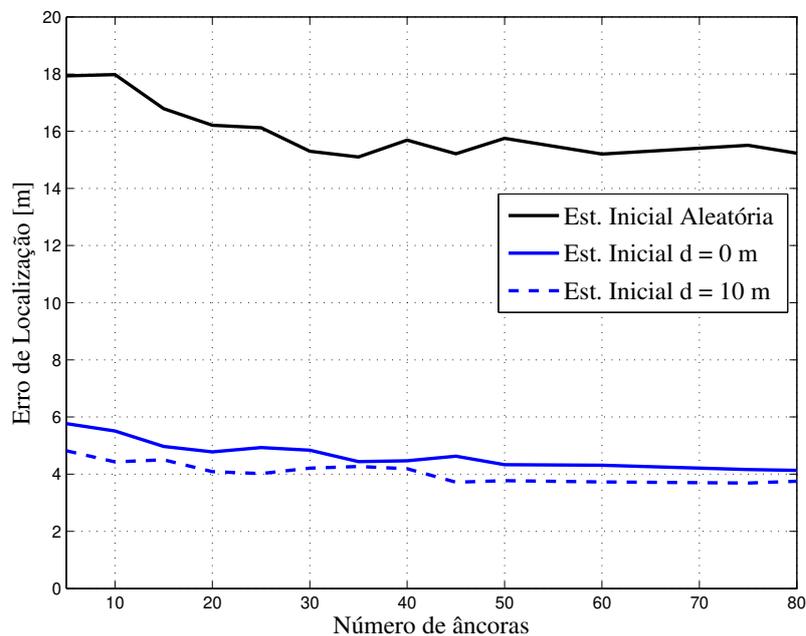


Figura 5.7: Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no número de nós âncora e estimativas iniciais geradas aleatoriamente (erro de medição RSS nulo).

Para as duas situações apresentadas, o erro de localização é bastante alterado para estimativas iniciais aleatórias, crescendo cerca de três vezes em relação ao cenário cujas posições são conhecidas. Esse resultado comprova a necessidade de métodos para lidar com a problema da estimativa inicial em algoritmos LS. Tal cenário é retomado na seção 5.2.3, onde o método SA é utilizado como contraponto.

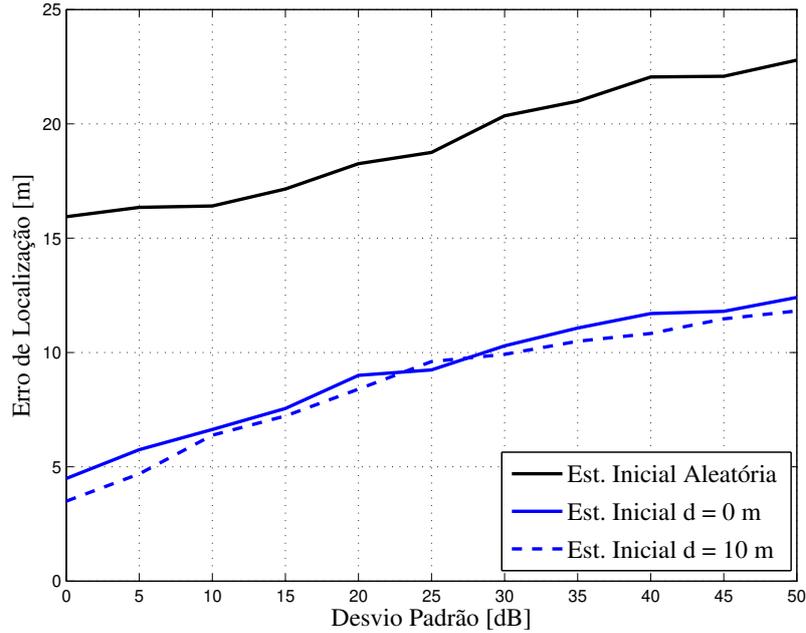


Figura 5.8: Desempenho do algoritmo LM aplicado ao modelo TTE para um aumento no desvio padrão da medida RSS e estimativas iniciais geradas aleatoriamente ($m = 30$ âncoras).

5.2.1.1 Desempenho comparativo para as aproximações do modelo

Os cenários anteriores são revisitados para a aproximação numérica do método LM a partir do método da secante (apresentada em 4.2.2) e para a aproximação por reparametrização derivada no Capítulo 3.

Na Figura 5.9 são apresentados os resultados de desempenho comparativo para um crescente número de âncoras em um cenário realístico. Como é possível notar, as curvas das aproximações apresentam erros relativamente maiores que os obtidos para o modelo original. As curvas se encontram com cerca de 1 m e 2 m a mais de erro para os modelos por aproximação numérica e reparametrizado, respectivamente. De forma geral, estes erros podem ser vistos como constantes e intrínsecos à aproximação realizada.

Os mesmos resultados são enxergados nas curvas das Figuras 5.10 e 5.11 para erro de medição RSS e erro de estimativa inicial, com desvios da curva original agora na faixa de 2 a 4 m. Importante notar a maior sensibilidade do modelo reparametrizado a erros de estimativa inicial, uma vez que o modelo pode afastar ainda mais o valor estimado a depender do ponto da curva obtido.

Finalmente, a Figura 5.12 mostra novamente o comparativo entre estimativas inici-

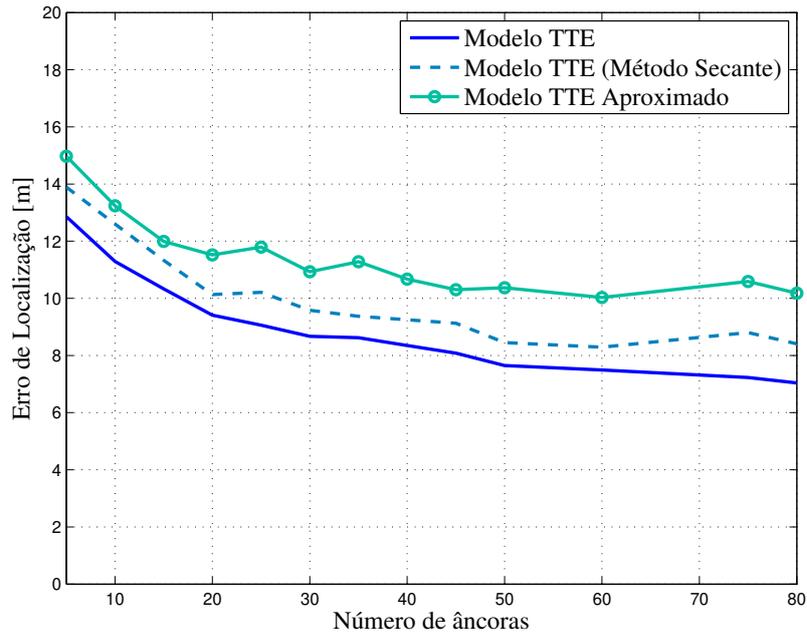


Figura 5.9: Desempenho comparativo entre o modelo TTE e suas aproximações para um aumento no no número de nós âncora ($d = 10$ m e $s = 20$ dB).

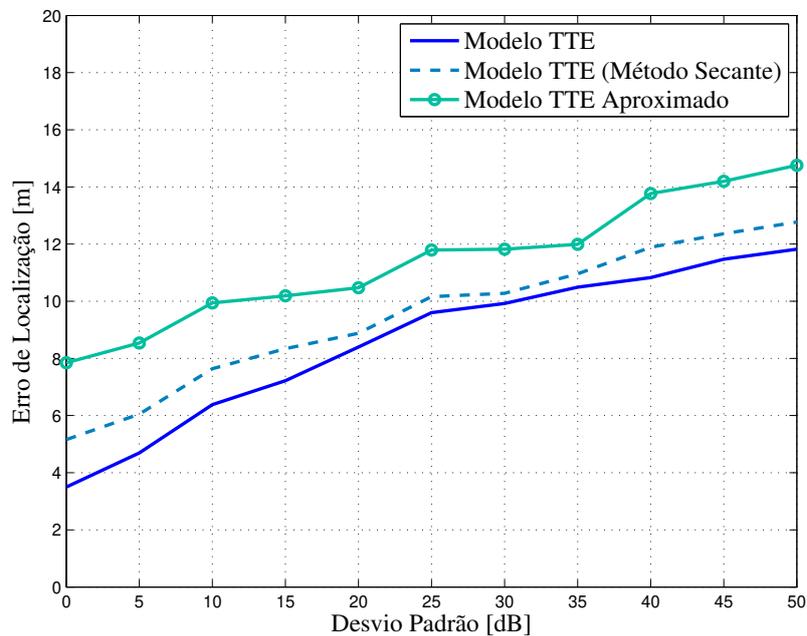


Figura 5.10: Desempenho comparativo entre o modelo TTE e suas aproximações para um aumento no desvio padrão da medida RSS ($d = 0$ m e $m = 30$ âncoras).

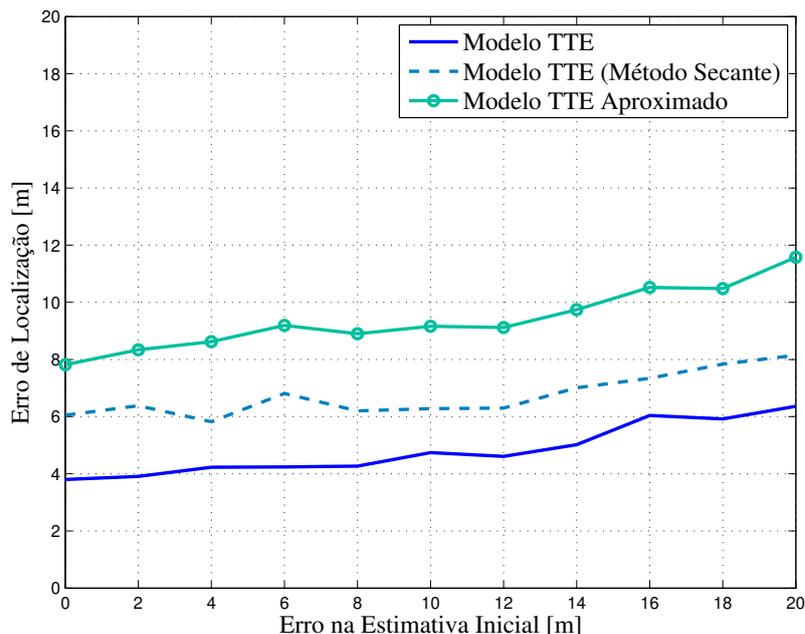


Figura 5.11: Desempenho comparativo entre o modelo TTE e suas aproximações para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$ âncoras).

ais geradas aleatoriamente e estimativas com alcance conhecido. Aqui, o erro associado ao modelo reparametrizado para o caso aleatório alcança valores muito próximos às dimensões da pilha, se mostrando inefetivo para esse caso em particular.

É interessante considerar nesse comparativo também uma métrica de velocidade. Olhando para o tempo de execução de cada algoritmo, a execução do método da secante se mostrou 4 vezes mais lenta do que quando utilizado somente o método LM. Como levantado no Capítulo 4, a razão desse processo mais exaustivo reside na maior quantidade de iterações para a avaliação da aproximação do Jacobiano.

Por sua vez, o modelo reparametrizado apresenta uma execução até 3 vezes mais rápida do que o modelo original. Esse ganho se deve à simplificação das funções de transferência, que reduzem a complexidade das componentes do gradiente e, conseqüentemente, a complexidade do algoritmo como um todo.

Dessa forma, embora com pior desempenho, a utilização do método da secante e do modelo aproximado podem ser alternativas viáveis em algumas aplicações TTE. O primeiro em cenários onde a derivação do modelo a partir dos parâmetros do canal seja complexa, exigindo uma aproximação numérica, e o segundo naqueles onde a capacidade de processamento seja limitada.

Possíveis melhorias para o desempenho geral dos algoritmos são exploradas nas

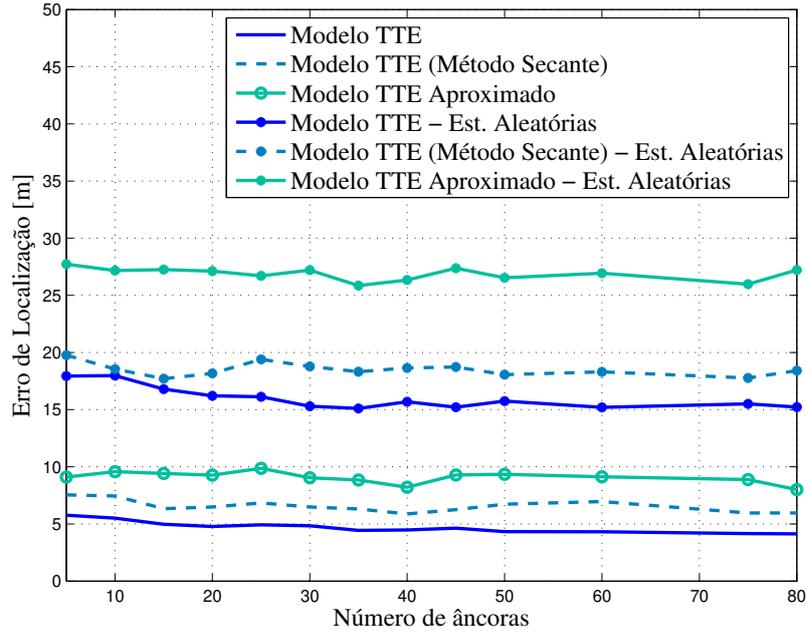


Figura 5.12: Desempenho entre o modelo TTE e suas aproximações para estimativas geradas aleatoriamente em comparação com estimativas geradas para $d = 10$ m (erro de medição RSS nulo).

próximas seções.

5.2.2 Contribuição do Ângulo

A existência dos ângulo de rotação enquanto parâmetros desconhecidos é uma questão difícil de lidar no processo de localização. Uma vez que os ângulos podem assumir qualquer valor entre 0 e 360° , a contribuição dos ganhos dados em (3.6) é grande em qualquer ponto do espaço. Para uma mesma posição, variações pequenas na angulação poder gerar grandes variações na perda de potência. Da mesma forma, para diferentes pontos no espaço, a existência das componentes senoidais tem ainda a característica de trazer múltiplos pontos de mínimos locais. Ambas as situações dificultam a convergência dos algoritmos de otimização.

Como soluções possíveis, foram pensadas duas alternativas. A primeira, e mais óbvia, diz respeito a fixação dos ângulos de rotação. Mantendo os ângulos fixos e conhecidos para cada *tag*, retiramos os parâmetros referentes a eles do processo de minimização e contornamos as questões levantadas anteriormente. Em um cenário prático, essa alternativa pode ser alcançada com um sistema mecânico de pesos e contrapesos, como a ideia do brinquedo infantil “João-bob”. Mantendo o centro de

gravidade estável para um encapsulamento da antena, é possível manter a antena numa mesma posição independente da sua configuração após o desmonte.

A segunda alternativa considera implementar diversidade de recepção. Utilizando, em vez de apenas uma, três antenas *loop* ortogonais entre si, é possível cobrir, na teoria, as três dimensões espaciais e assim aproveitar o máximo de ganho em todas as direções.

Diversidade de recepção é geralmente utilizada para combater efeitos de sombreamento e de multipercurso. Assim como para os ângulos fixos, a utilização dessa alternativa aqui possibilita remover ou ao menos mitigar os efeitos da angulação na estimação dos parâmetros. Considerando o canal TTE invariante no tempo, a redundância espacial é gerada pelas antenas perpendiculares, de forma a fazer com que os ganhos se compensem.

A alteração é realizada considerando o sinal recebido como a combinação dos sinais em cada uma das antenas. Essa combinação pode ser realizada de diversas maneiras, sendo aqui entregue como um valor MRC (*Maximal Ratio Combining*) [68], cuja representação é dada pela soma ponderada:

$$P_{rx, mrc} = \frac{P_{rx,1}W_1 + P_{rx,2}W_2 + P_{rx,3}W_3}{W_1 + W_2 + W_3} \quad (5.1)$$

em que W_i é a amplitude do sinal recebido na antena i , cuja relação com a potência recebida é escrita como $W_i = 1/\sqrt{P_{rx,i}}$.

Mantendo valores nulos tanto para a o erro de medição quanto para o erro associado à estimativa inicial, é possível avaliar a influência da incerteza dos ângulos nos resultados isoladamente. Na Figura 5.13 o desempenho para os três casos considerados é mostrado para um aumento no número de âncoras nessas condições.

Logicamente, para ângulos fixos, os parâmetros referentes a θ_x e θ_y são eliminados do processo de otimização e o erro de localização depende apenas das estimativas para as coordenadas, sendo então nulo quando os erros são nulos. Já o caso que utiliza ângulos ortogonais por sua vez, embora não anule completamente o efeito do ganho das antenas, alcança resultados de desempenho consideravelmente melhores do que aqueles para o caso em que os ângulos são completamente desconhecidos.

O mesmo comparativo é avaliado para um cenário onde erros são inseridos no processo. Na Figura 5.14, os casos são analisados para o aumento no desvio padrão da medida RSS. Curiosamente, a estratégia de fixação do ângulo apresenta resultados melhores para valores mais baixos de erro de medida, mas têm seu desempenho superado pelo caso de ângulos desconhecidos para valores mais altos.

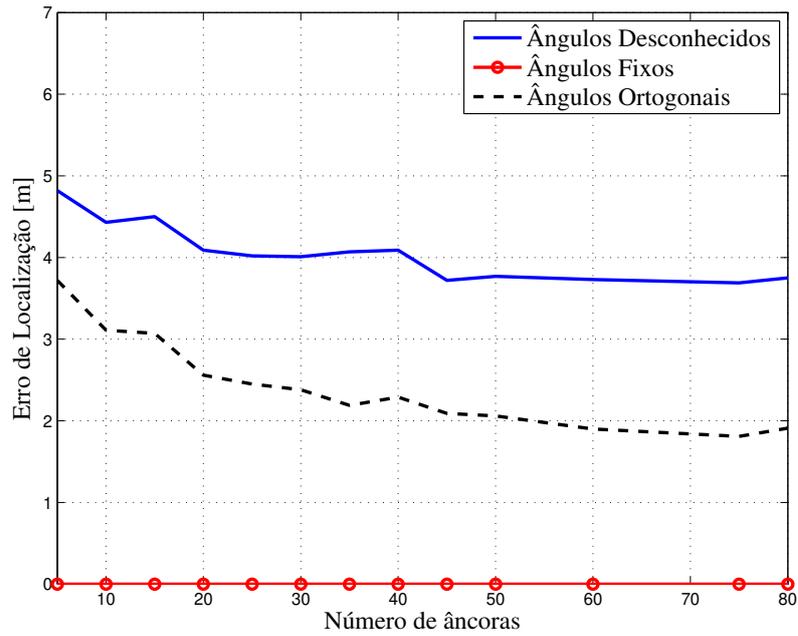


Figura 5.13: Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no número de âncoras (erro de medição RSS nulo e erro de estimativa inicial nulos).

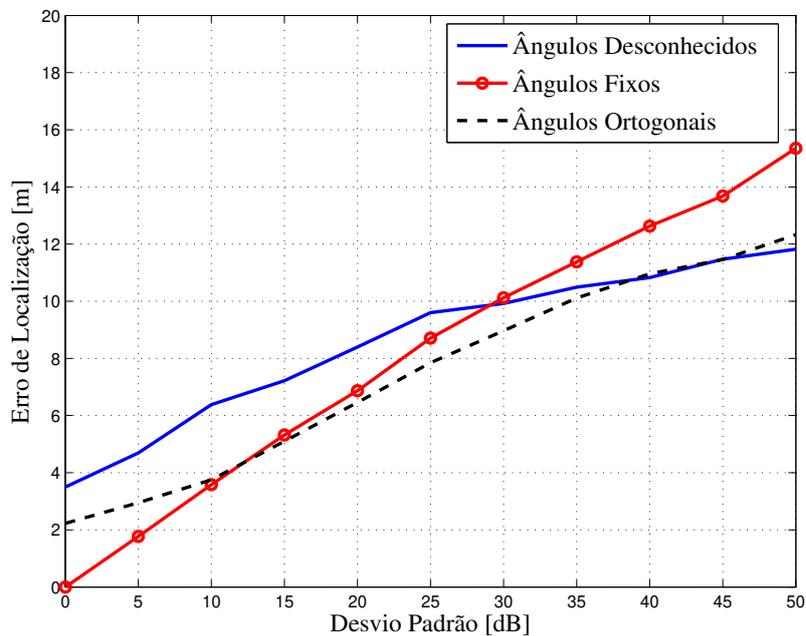


Figura 5.14: Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no desvio padrão da medida RSS ($d = 0$ m e $m = 30$ âncoras).

Este resultado pode ser interpretado a partir da ótica do ganho das antenas *loop*. Uma vez que a perda de potência pode apresentar grandes variações de magnitude a depender da inclinação da *tag*, perdas referentes à aferição de distância conseguem possivelmente ser compensadas pelos ganhos obtidos para algum ângulo específico.

Nesse sentido, os parâmetros no algoritmo referentes a θ_x e θ_y podem acabar "absorvendo" erros advindos da medição durante o processo de otimização. Para um mínimo local, erros significativos podem ser parcialmente atribuídos aos ângulos, reduzindo sua contribuição no resultado final e entregando assim resultados um pouco melhores. As Figuras 5.15 e 5.16 mostram que à medida que erros de estimativa inicial vão dominando o cenário, esse fenômeno é reduzido, até não ser mais visível para o caso extremo em que as estimativas iniciais são geradas aleatoriamente.

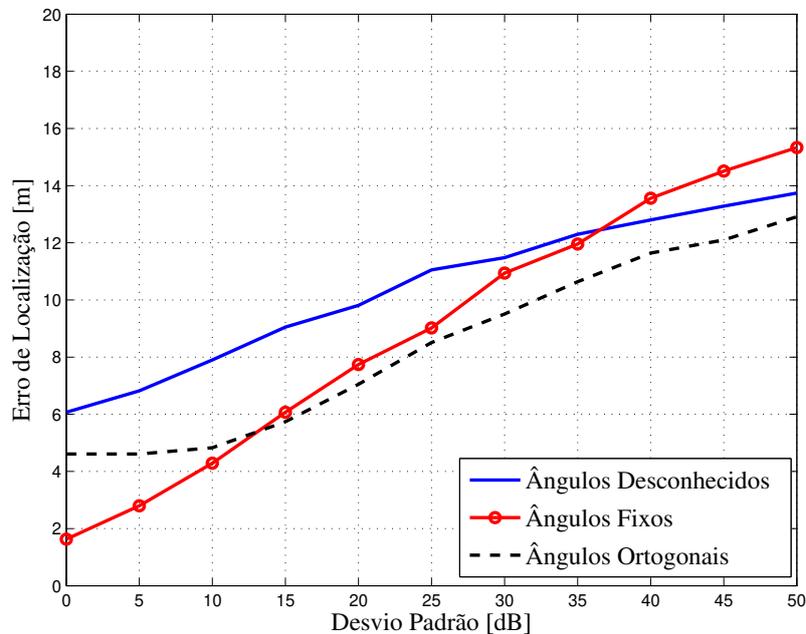


Figura 5.15: Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no desvio padrão da medida RSS ($d = 10$ m e $m = 30$ âncoras).

Por sua vez, em todos os cenários analisados, o caso que utiliza as antenas ortogonais apresenta resultados melhores do que o caso em que apenas uma antena de angulação desconhecida é utilizada. Tal comportamento também é repetido no comparativo que considera a influência da estimativa inicial separadamente, como expresso na Figura 5.17, que mostra ainda que ângulos fixos têm o desempenho mais satisfatório nessas condições.

Fora dessas condições, arranjos de ângulos ortogonais perdem para o de ângulos

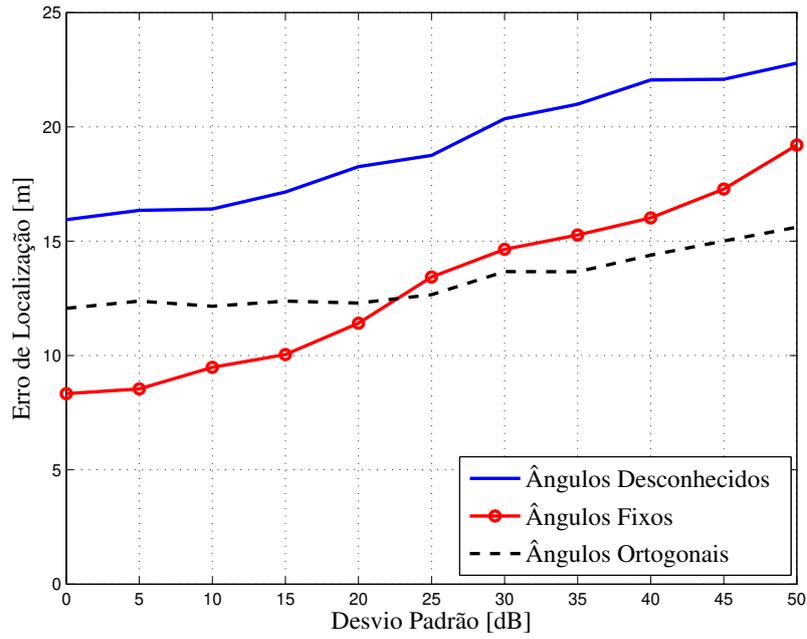


Figura 5.16: Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no desvio padrão da medida RSS (estimativas iniciais aleatórias e $m = 30$ âncoras).

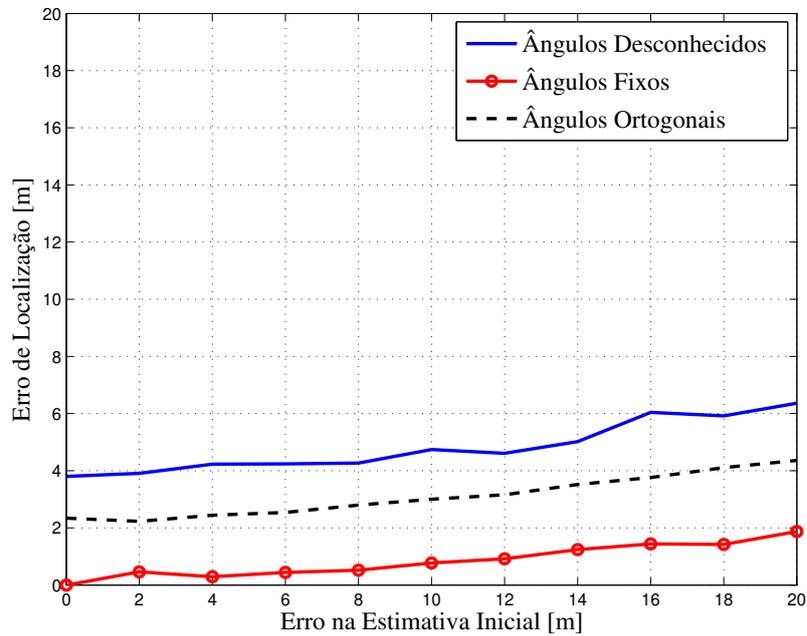


Figura 5.17: Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$ âncoras).

fixos apenas em cenários com erros de medição RSS pequenos, tendo desempenho bem próximo em todos os outros casos.

De fato, para um cenário mais realístico, como o mostrado na Figura 5.18 para erros consideráveis de medida e de estimativa inicial, o arranjo de antenas ortogonais apresenta um desempenho no geral melhor do que aquele para uma antena de ângulos fixos. Associado ao comparativo com o caso base, esse resultado mostra que ambas as opções são bastante viáveis para a mitigação do efeito da angulação.

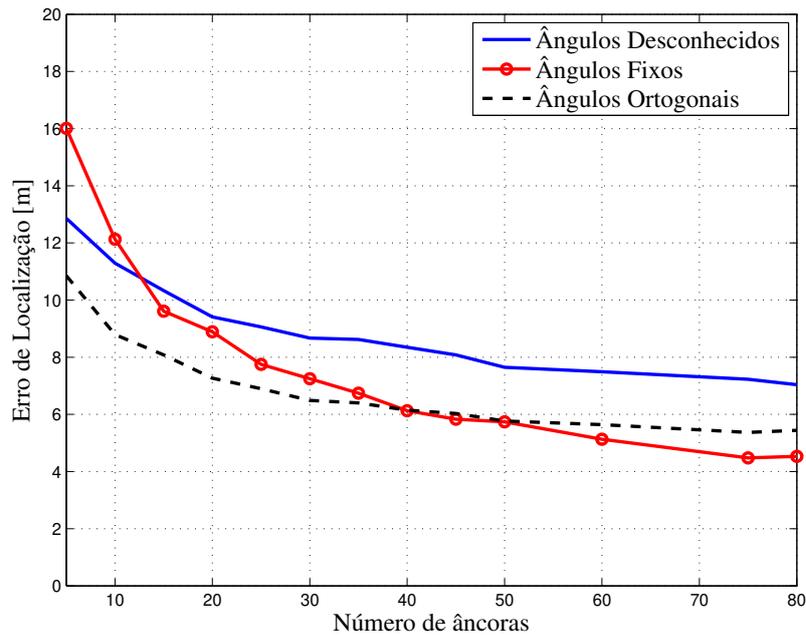


Figura 5.18: Desempenho comparativo entre diferentes arranjos de ângulos para um aumento no número de âncoras com $d = 10$ m e $s = 20$ dB.

5.2.3 Problema da Estimativa Inicial

Como mostrado nas curvas das Figuras 5.7 e 5.8, os resultados obtidos quando as estimativas iniciais são geradas aleatoriamente apresentam desempenho pouco satisfatório e uma discrepância grande em relação àqueles em que se conhecesse algo, ainda que mínimo, sobre a posição original da *tag*.

Muito dessa questão vem das dificuldades de métodos LS em lidarem com a minimização quando a estimativa inicial é pouco relacionada. A depender do ponto, a estimativa pode em determinado momento da iteração encontrar uma região de mínimo local e permanecer confinada a ela, sem possibilidades de melhoria.

No Capítulo 4 foi apresentada uma alternativa para lidar com esse problema, na forma do algoritmo de Recozimento Simulado. A partir dos mecanismos de busca ampla e de minimização estocástica associados, o algoritmo SA consegue em teoria superar falsos mínimos e ter maiores chances de encontrar um possível ótimo global.

A aplicação dos dois métodos é avaliada de forma comparativa nesta seção. A análise considerada equipara os desempenhos dos algoritmos tanto para os casos em que eles são aplicados individualmente como também para o caso em que eles são aplicados em cascata, iniciando com o método SA e finalizando com o método LM. A ideia aqui é compreender se o uso das estimativas geradas pelo algoritmo SA são melhores chutes iniciais para o método LM do que os utilizados anteriormente.

Primeiramente, o caso principal que se quer lidar, de estimativas iniciais geradas aleatoriamente, é avaliado para um crescente número de âncoras sem a influência do erro na medição RSS. Os resultados estão expressos nas Figuras 5.19, 5.20 e 5.21 para os três casos possíveis de ângulo.

De fato, quando aplicada separadamente, SA só se mostrou um método mais efetivo do que LM para o caso de ângulos fixos, onde o algoritmo não precisa lidar com a variação do ângulo e, portanto, tem mais chances de, pelo mecanismo de busca ampla no domínio, encontrar o ótimo global. Embora o desempenho tenha sido bem próximo, a influência do ângulo em Recozimento Simulado é alta, uma vez que ele pode assumir uma gama grande de valores possíveis, o que dificulta o processo estocástico. Aqui, o método de busca pode acabar entrando em diferentes pontos de mínimo local muito próximos, mesmo para pequenas variações no ângulo, e acabar não conseguindo sair deles.

No entanto, e muito importante, ao se combinar as duas técnicas de forma sequencial, em todos os cenários foram obtidos resultados de desempenho consideravelmente melhores do que quando os métodos são utilizados individualmente. Este resultado corrobora a ideia levantada anteriormente de que SA provendo estimativas de posição iniciais mais próximas para o algoritmo LM, auxilia para que este promova o processo de refinamento por aproximação linear de forma mais eficaz, mitigando os efeitos esperados de uma estimativa pouco relacionada.

Dando continuidade, avaliamos o desempenho comparativo quando na presença de erros de medição, ainda para estimativas iniciais geradas aleatoriamente. Na Figuras 5.22, 5.23 e 5.24 são apresentados os resultados para os três casos de ângulo. Aqui é possível notar, mais uma vez, o ganho de desempenho existente quando as duas técnicas são aplicadas em conjunto. Para qualquer situação do ângulo, utilizar a técnica SA seguida da técnica LM obtém erros de localização menores.

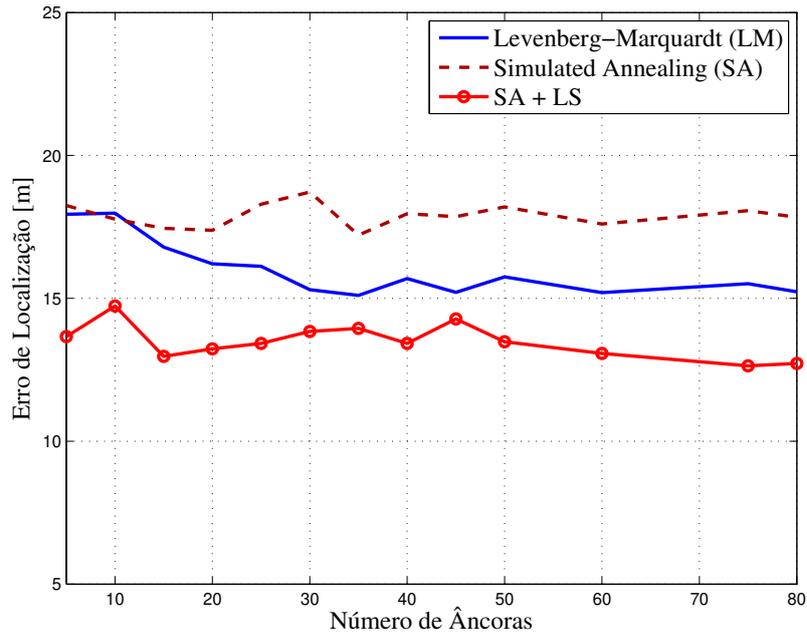


Figura 5.19: Desempenho comparativo entre os métodos LM e SA com ângulos desconhecidos para um aumento no número de âncoras e estimativas iniciais geradas aleatoriamente ($s = 0$ dB).

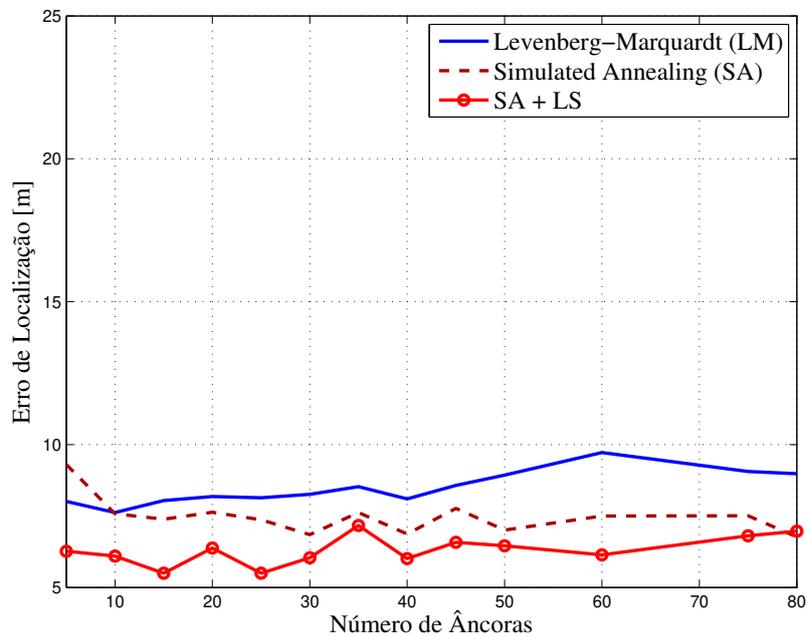


Figura 5.20: Desempenho comparativo entre os métodos LM e SA com ângulos fixos para um aumento no número de âncoras e estimativas iniciais geradas aleatoriamente ($s = 0$ dB).

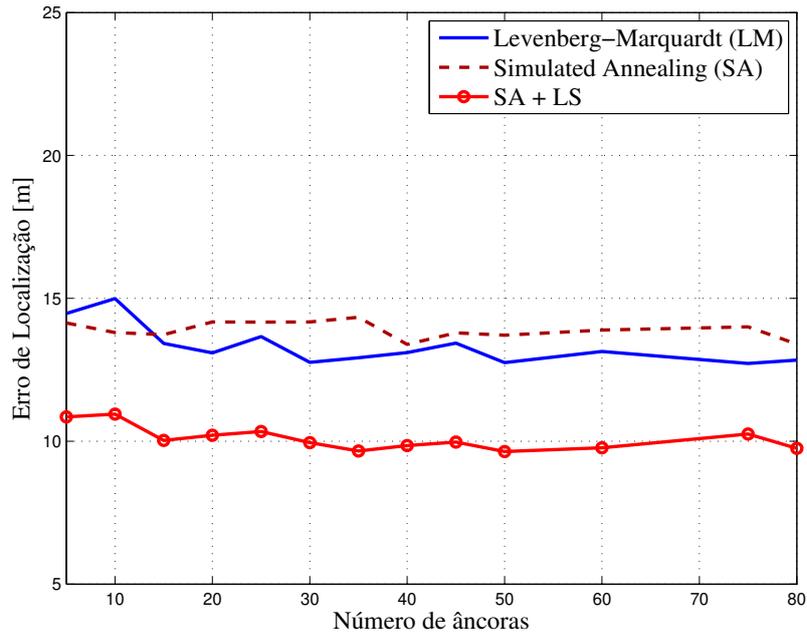


Figura 5.21: Desempenho comparativo entre os métodos LM e SA com ângulos ortogonais para um aumento no número de âncoras e estimativas iniciais geradas aleatoriamente ($s = 0$ dB).

Separadamente, as curvas para os métodos apresentam comportamentos ainda mais próximos do que quando o erro de medição não estava presente e, em particular, para o caso de ângulos ortogonais, SA apresenta um desempenho até um pouco melhor do que LM, muito provavelmente devido aos efeitos da diversidade de recepção.

Finalmente, consideramos o cenário onde as estimativas iniciais estão dentro de um alcance conhecido, em contraponto com o apresentado anteriormente para estimativas aleatórias. Este são apresentados de forma comparativa para os três casos de ângulo nas Figuras 5.25, 5.26 e 5.27.

Mesmo com a mudança de cenário, os resultados encontrados anteriormente permanecem verdadeiros para a combinação das duas técnicas. O desempenho para o uso de LM após a otimização por SA alcançou resultados bem satisfatórios em relação aos usos individuais, mostrando que as técnicas conjuntas são uma solução com ganhos também para este caso.

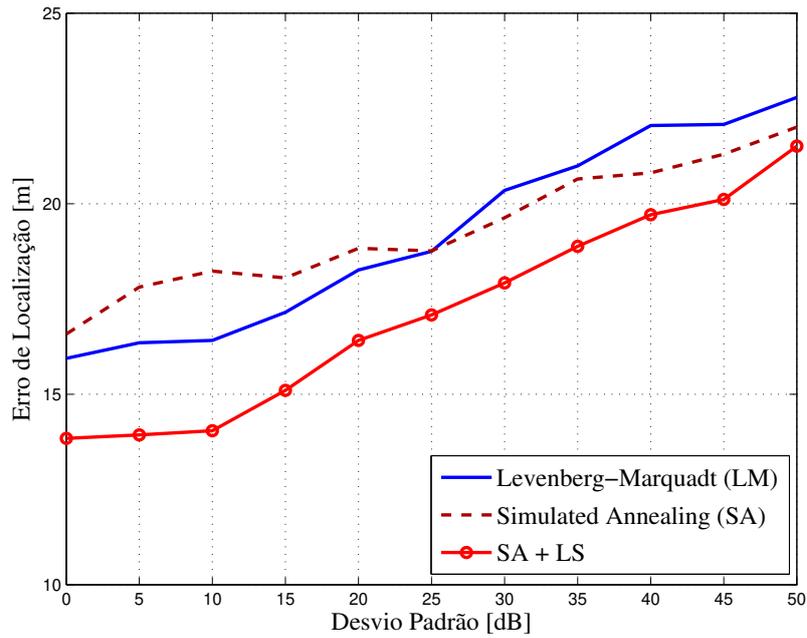


Figura 5.22: Desempenho comparativo entre os métodos LM e SA com ângulos desconhecidos para um aumento no desvio padrão da medição RSS e estimativas iniciais geradas aleatoriamente ($m = 30$).

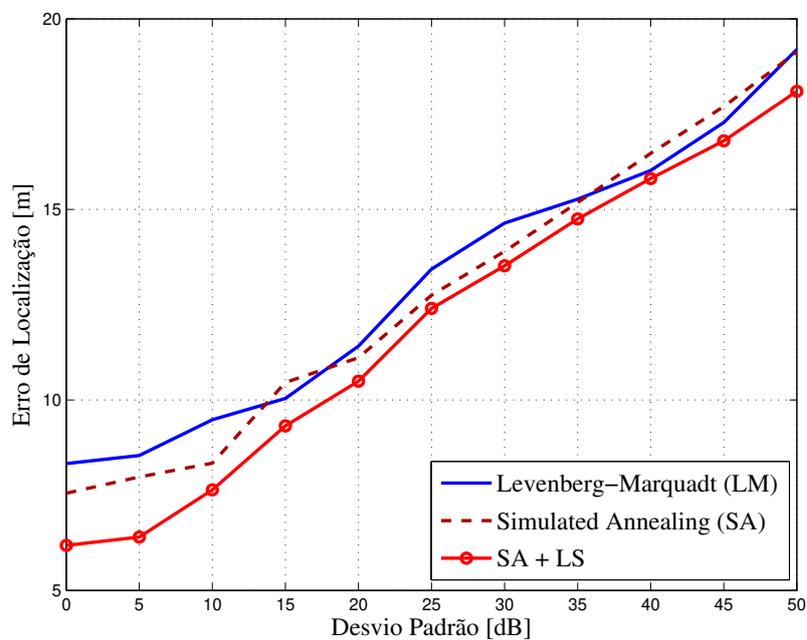


Figura 5.23: Desempenho comparativo entre os métodos LM e SA com ângulos fixos para um aumento no desvio padrão da medição RSS e estimativas iniciais geradas aleatoriamente ($m = 30$).

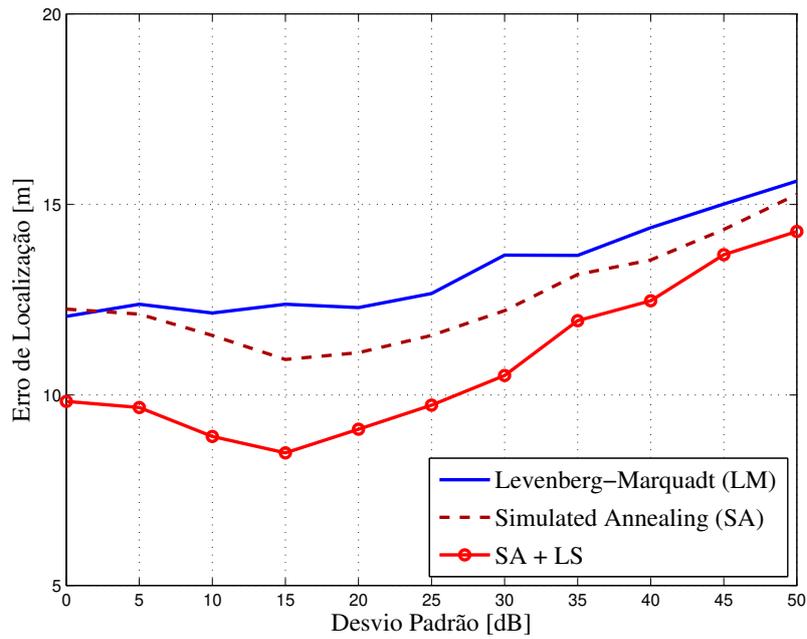


Figura 5.24: Desempenho comparativo entre os métodos LM e SA com ângulos ortogonais para um aumento no desvio padrão da medição RSS e estimativas iniciais geradas aleatoriamente ($m = 30$).

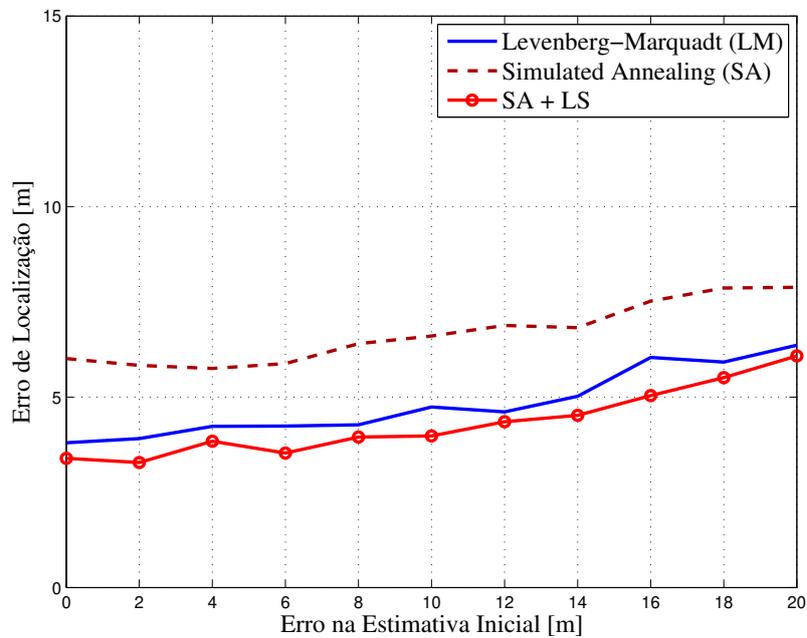


Figura 5.25: Desempenho comparativo entre os métodos LM e SA com ângulos desconhecidos para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$).

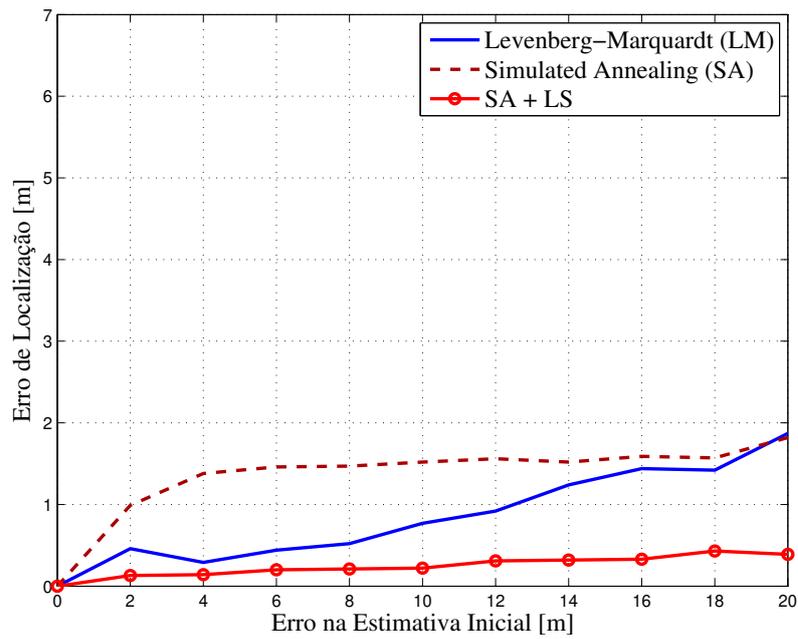


Figura 5.26: Desempenho comparativo entre os métodos LM e SA com ângulos fixos para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$).

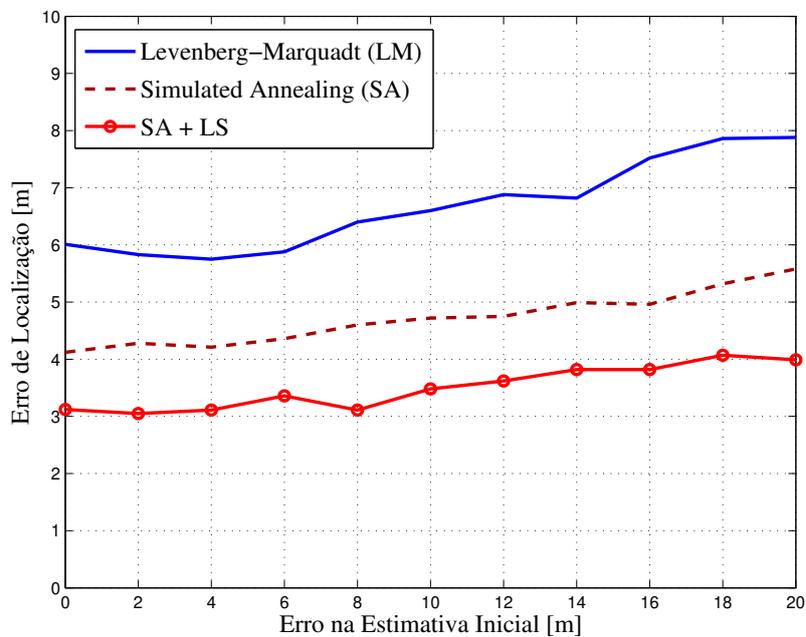


Figura 5.27: Desempenho comparativo entre os métodos LM e SA com ângulos ortogonais para um aumento no erro máximo da estimativa inicial ($s = 0$ dB e $m = 30$).

6 APLICAÇÃO: IDENTIFICAÇÃO DE ZONAS DE MINÉRIOS

Retomando a proposta do trabalho, a motivação principal para se estudar um processo de localização que seja compatível com as especificidades de sistemas TTE é poder viabilizar aplicações que requeiram relações de distância e coordenadas geográficas. De posse de algoritmos que entregam estimativas de razoável acurácia, o próximo passo é olhar para processos industriais que hoje não são possíveis ou são pouco efetivos e entender como a localização pode afetar seu desempenho.

Dentro dos processos de mineração existentes, a eficiência na extração, desmonte, lavragem e recuperação da área é cada vez mais importante para a sustentabilidade da exploração e a escalabilidade da produção. Além da atuação em casos de desastre ou problemas operacionais, a atuação de caráter preventivo na preservação e aproveitamento de recursos é igualmente necessária.

Nesse sentido, uma aplicação que encontra grandes ganhos de utilidade com uma localização bem sucedida é a de identificação de minérios. Conseguir identificar zonas de diferente conteúdo mineral é muito interessante para a tornar a exploração mais direcionada e com menor impacto logístico e ambiental.

Neste capítulo, um formato possível dessa aplicação é apresentado em sua relação com processo de localização. As próximas seções descrevem o problema enquanto um problema de ciência de dados e classificação, assim como o método pensado e aplicado, na forma do algoritmo KNN. Por fim, alguns resultados de simulação obtidos para o cenário TTE são apresentados.

6.1 DESCRIÇÃO DO PROBLEMA

O objetivo principal da aplicação consiste em identificar mais facilmente as zonas de minérios após o desmonte. Um esboço do problema é desenhado na Figura 6.1 para dois tipos de minérios diferentes.

A ideia é conseguir encontrar com algum nível de clareza a localização de rochas e substâncias específicas, diferenciando as fronteiras entre o que é útil e o que é estéril. No caso, a proposta é de utilizar as referências estabelecidas pela localização das tags para identificar cada ponto no espaço.



Figura 6.1: Identificação de zonas de minério e zonas estéreis.

De forma geral, esse processo é bem simples. Em etapas:

1. As *tags* são inseridas em posições estratégicas da mina identificando o que é região de minério e o que é região estéril;
2. Após a detonação, as rochas são desmontadas e a posição de cada *tag* e, consequentemente das zonas, é alterada;
3. Em seguida, o processo de localização é realizado, utilizando as técnicas do Capítulo 4;
4. Finalmente, utilizando as informações de coordenadas estimadas como referência, os pontos ao redor das *tags* são avaliados quanto ao seu tipo a partir de um método de inferência adequado.

De forma específica, o problema pode ser entendido dentro de um processo de classificação estatística, igual àqueles apresentados no Capítulo 2. Aqui, todas as partes típicas apresentadas na Figura 2.6 podem ser derivadas diretamente. As classes são divididas em duas, categóricas, minério ou estéril (com possibilidade de expansão para mais níveis, a depender da quantidade de minérios). O vetor de *features* é dado diretamente pelo vetor de coordenadas retangulares (x, y, z) de cada ponto, uma vez que a posição relativa representa se o material pertence a uma classe ou outra, e, é claro, o conjunto de treinamento são as próprias *tags*, cujas posições foram determinadas pelo algoritmo de localização e a classe é conhecida previamente.

Evidentemente, algumas premissas básicas são necessárias para a aplicação no formato proposto. A primeira é de que a localização relativa das zonas, ou parte delas, seja conhecida previamente ao desmonte, com cada *tag* sendo posicionada com sua marcação referente ao local a que está atrelado (minério A, minério B, estéril, etc). A segunda de que quando a detonação separa blocos de rocha identificados pelas *tags*, estes permanecem, em sua maioria, atrelados a elas. Isto serve para garantir que cada tag represente uma região próxima de si que é do tipo previsto.

No entanto, essas questões podem ser relativizadas. A depender de uma maior capacidade de processamento nas *tags*, as informações sobre as zonas podem ser inferidas durante o processo ou estimadas a partir da utilização de medições locais, por exemplo.

Importante salientar que, em um cenário onde a informação sobre a identificação da classe das tags não possa ser transmitida, métodos de aprendizado não-supervisionado como agrupamento (*clustering*) podem ser utilizados no lugar de classificação. Apesar disso, nesta aplicação não faremos essa suposição.

A próxima seção apresenta o método escolhido para lidar com o problema e a representação do classificador correspondente.

6.2 MÉTODO DOS K-ÉSIMOS VIZINHOS MAIS PRÓXIMOS

O algoritmo dos k -ésimos vizinhos mais próximos, ou KNN (do inglês *K Nearest Neighbours*) é um método de aprendizado supervisionado muito utilizado na função de classificador. O seu formato de predição é baseado no conceito de similaridade de características, no qual o quão próximas as *features* de uma instância estão do grupo de treinamento determina como aquele ponto será classificado [41].

O procedimento em KNN é realizado utilizando métricas de distância (euclidiana, de Hamming, Chebychev, etc), de forma a desenhar uma disposição espacial das características das observações. A partir das informações de similaridade, a categorização na saída é então dada por voto majoritário, considerando a classe mais comum entre os K vizinhos mais próximos, e K um número inteiro positivo. Na Figura 6.2 um exemplo genérico de decisão é mostrado para $K = 3$.

Usualmente utilizado como *benchmark* para métodos mais complexos como SVM e redes neurais, KNN é bastante simples, mas entrega valores muito acurados a depender da tarefa, conseguindo ser bem competitivo com métodos mais complexos de classificação.

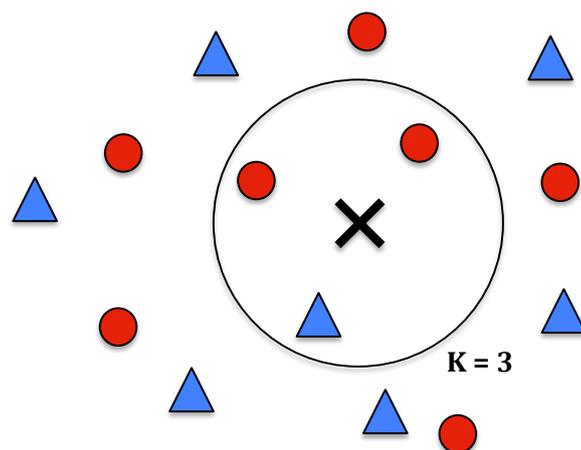


Figura 6.2: Processo de decisão para um algoritmo KNN genérico.

De fato, a escolha de utilizar KNN como o método mais apropriado para a identificação de minérios se deve à sua clara analogia ao problema. Uma vez que o vetor de features é o próprio vetor de coordenadas geográficas e a avaliação requerida do classificador é uma descrição categórica do espaço, as métricas estabelecidas e o formato de processamento de KNN têm aplicação direta. Já utilizando os dados das *tags*, o algoritmo não precisa armazenar informações extras e o peso em processamento é minimizado.

Ainda, o classificador KNN é um classificador não-paramétrico, ou seja não faz suposições prévias sobre a distribuição dos dados em uma função fechada. Esta característica é muito útil para o problema proposto, uma vez que conhecer a forma com que as classes serão distribuídas após a detonação é geralmente inviável, mesmo dentro de modelos aleatórios.

Outro ponto interessante de KNN é que seu algoritmo é baseado em instâncias, não aprendendo explicitamente um modelo a partir dos dados. Aqui, a generalização ocorre apenas quando se procura uma instância nova no sistema, sendo a referência em cada avaliação o conjunto de treinamento como um todo. Essa característica, também as vezes conhecida como aprendizado preguiçoso (*lazy learning*), faz com que a maior parte do tempo de processamento do algoritmo esteja na fase de consulta e predição, com uma fase de treinamento muito pequena. Isso acaba fazendo com que a técnica lide bem com mudanças no domínio da função, tendo vantagens na aproximação de alvos localmente, como é o caso requisitado.

6.2.1 Formalização da Técnica

Formalmente, KNN pode ser entendido como o cálculo de uma probabilidade condicional para cada ponto [41]. De forma efetiva, para uma nova observação x e uma métrica de similaridade (distância) d , o algoritmo executa duas fases distintas:

- Calcula a distância d entre x e todas as instâncias do conjunto de treinamento, selecionando as K mais próximas em um conjunto \mathcal{A} ;
- Estima a probabilidade condicional da classe Y assumir o valor possível y dentro do domínio \mathcal{A} , com:

$$P(Y = y|X = x) = \frac{1}{K} \sum_{i \in \mathcal{A}} I(Y^{(i)} = y) \quad (6.1)$$

em que $I(\cdot)$ é uma função indicadora que retorna 1 caso o argumento seja verdadeiro e 0 caso contrário.

De forma mais genérica, no entanto, KNN pode ser entendido também como a definição de uma fronteira de decisão entre as classes, e a utilização desse fronteira como critério de classificação. No caso, quanto mais longe da fronteira, mais provável que a observação pertença aquela classe específica.

Contudo, para a escolha no cenário da identificação de minérios, é importante considerar ainda duas outras questões relevantes. A primeira é de que quanto mais próxima de uma *tag* de referência, maior a chance de aquele ponto no espaço ser do mesmo tipo que ela, independente das outras $K - 1$ possibilidades. E a segunda de que, dados possíveis erros na estimativa de localização, não sabemos com segurança se a região delimitada pela *tag* é realmente de uma classe ou de outra.

Como solução para tais questões, foi pensada a aplicação de um formato de ponderação no voto majoritário. Em primeiro momento, a partir da distância: *tags* mais próximas possuem maior peso na decisão do que *tags* mais distantes. E em segundo momento, considerando a incerteza na medida: quanto maior o grau de confiança da estimativa de localização, maiores chances do ponto ser do mesmo tipo e maior então o peso daquela *tag* na decisão.

Para essa medida de confiança, utilizamos um indicador de qualidade referente ao tamanho da região de probabilidade gerada pelo método de trilateração (ver Figura 2.5). Quanto maior a região, menos confiável a medida.

Uma vez que o tamanho está relacionado a erros de medição, decidiu-se utilizar como indicador a raiz do erro quadrático médio (RMSE) da perda de potência entre a

tag e as âncoras. Tal valor é mostrado na Figura 6.3, para PL_{med} a perda de potência obtida na medição RSS e PL_{est} a perda de potência estimada a partir da posição estimada pelo processo de localização.

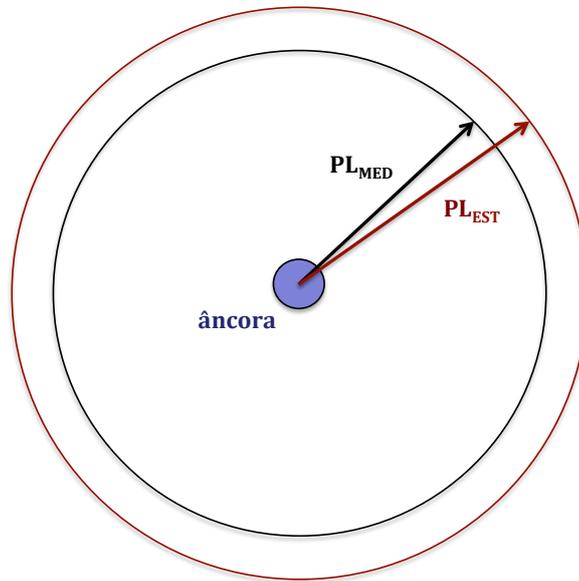


Figura 6.3: Ponderação pelo erro de medida na perda de potência em relação a perda de potência estimada para uma âncora.

Em suma, a ideia da ponderação é mitigar os possíveis vieses que venham a existir em decorrência do descompasso na quantidade de *tags* de um determinado tipo na região do ponto.

Finalmente, o valor de K também têm bastante influência no desempenho do algoritmo. Sendo um hiperparâmetro, sua escolha não é condicional, mas é base para o melhor ajuste possível dos dados, podendo ser visto como aquele que controla o formato das fronteiras de decisão.

Efetivamente, sua escolha está ligada ao compromisso entre viés e variância, explorado na Seção 2.3. Para valores pequenos de K , estamos no cenário de viés baixo e variância alta. Aqui o espaço é menos relacionado com a distribuição geral dos pontos e mais ajustado para cada observação específica, fazendo com que as fronteiras de decisão sejam mais claras, porém também mais irregulares. Por sua vez, valores maiores de K consideram mais votantes no cálculo e portanto reduzem o efeito do ruído (mais viés e menos variância). Nesse caso as fronteiras são mais suaves, entretanto, são menos distintas.

Para uma boa escolha de K , optamos por utilizar a técnica de validação cruzada [34] pelo método "*k-fold*", particionando o conjunto de dados entre dados de treinamento e

dados de validação e avaliando os subconjuntos de forma rotativa. De forma resumida para este método, através da observação do desempenho do algoritmo para diferentes valores de K , a escolha é feita para o valor que obtiver o melhor resultado estatístico após a alternância do grupo de validação por todo o conjunto de dados. Tal medida garante uma medida mais representativa da acurácia e, portanto, mais respaldo à escolha.

Na próxima seção os resultados da simulação do algoritmo quando aplicado no cenário TTE são apresentados. Em tempo, a escolha do parâmetro K e uma avaliação da acurácia do método são também exploradas.

6.3 RESULTADOS DE APLICAÇÃO

Como previsto anteriormente, a inserção do classificador acontece a partir do ponto final do processo de localização. Nesse ponto, escolhemos continuar utilizando as mesmas configurações de âncora, *tag* e canal empregadas nas simulações do Capítulo 5, com 50 *tags* distribuídas uniformemente e 12 posições de nós âncora posicionados na superfície do volume representativo da mina.

Para a avaliação do cenário de localização, consideramos o caso de ângulos fixos, com um erro de medição RSS em 10 dB e uma estimativa inicial, agora representativo diretamente do alcance da detonação, dentro de um raio máximo de 5 m da posição real.

Como forma de facilitar a visualização e a interpretação dos dados, optou-se por utilizar apenas duas classes na predição: minério e estéril. Pelo mesmo motivo, a região de identificação também foi limitada a uma fronteira entre duas zonas, como explicitado na Figura 6.4 para a vista superior de um corte em volume retangular.

Como é possível notar, a disposição das *tags* foi realizada de forma a delimitar a região de separação e assim, garantir uma melhor identificação das alterações na fronteira. De fato, a topografia na Figura 6.4 é alterada com o desmonte e deixamos de conhecer a estrutura da mina. O papel visual do classificador aqui fica então mais claro: prever como fica a disposição das rochas no após a detonação.

Uma vez que consideramos que as informações de identificação de classe são recebidas após as estimativas de posição de todas *tags*, podemos então iniciar o método KNN.

O classificador começa com a fase de treinamento em que apenas o valor de K é determinado através de validação cruzada. Em etapas, dividimos os dados em 5

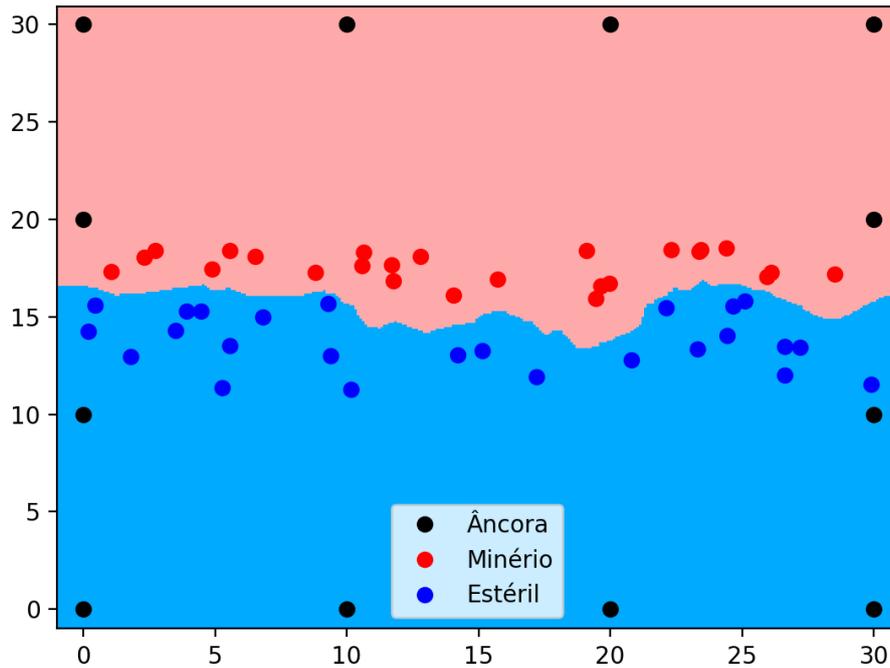


Figura 6.4: Seção retangular de uma região de fronteira entre minério e material estéril marcada por *tags*.

subconjuntos com 10 *tags* cada. Separamos 4 grupos para treinamento e um quinto para validação. Rodamos o algoritmo dentro do grupo de controle até que todos fossem utilizados como validação e obtivemos estimativas de acurácia em cada rodada.

As médias dessas medidas, na forma do erro de classificação (porcentagem de *tags* classificadas erroneamente), são mostradas na Figura 6.5 para diferentes valores de K . Importante salientar que foi decidido considerar apenas valores ímpares do parâmetro, como forma de evitar empates.

Escolhemos então $K = 9$, cuja acurácia foi de 86%, como explicitado no gráfico. Em um cenário prático, este valor pode ser utilizado para prever o desempenho do classificador naquela configuração do espaço, e estabelecer assim, um nível de confiança para o algoritmo.

Em seguida, rodamos para a etapa de predição do algoritmo KNN, escolhendo para cada ponto no espaço os 9 vizinhos mais próximos e calculando o voto de cada um na formação da fronteira de decisão. Nessa etapa, consideramos a ponderação pela distância e pelo erro de medição na perda de potência.

O resultado para as fronteiras de decisão e disposição estimada das rochas é mostrado na Figura 6.6.

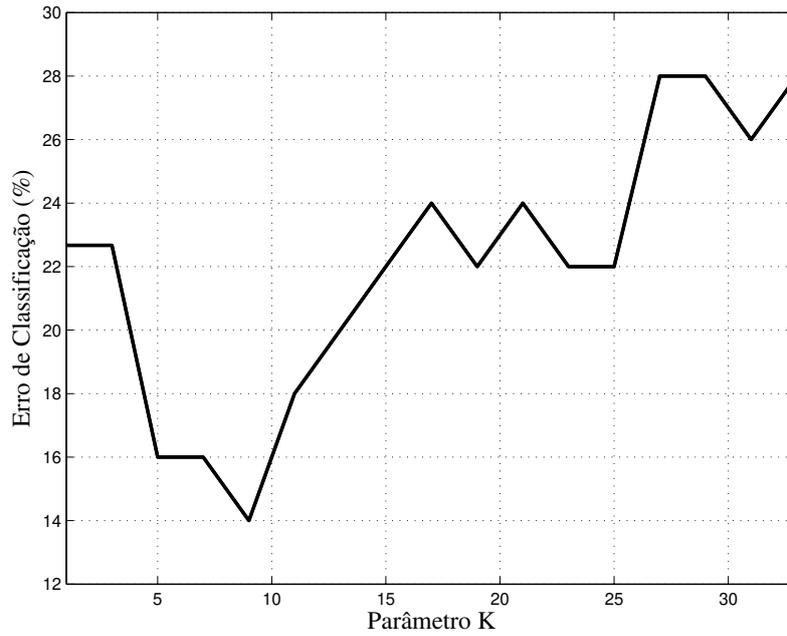


Figura 6.5: Erro de classificação estimado por validação cruzada para diferentes valores de K.

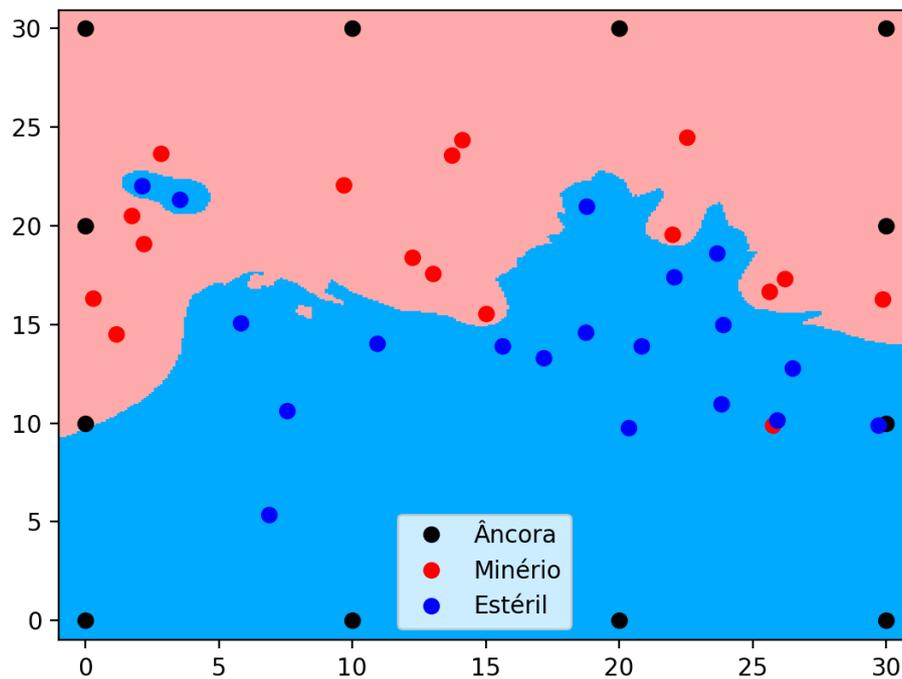


Figura 6.6: Identificação de zonas de minério com classificador KNN para $K = 9$.

Como é possível notar, a fronteira entre as zonas de minério e a zona estéril são bem definidas para o valor escolhido de K sem deixar de moldar áreas mais concentradas,

mostrando um bom equilíbrio entre viés e variância. Comparativamente, as Figuras 6.7 e 6.8 mostram o mesmo cenário para um valor baixo de K e um valor alto de K , respectivamente.

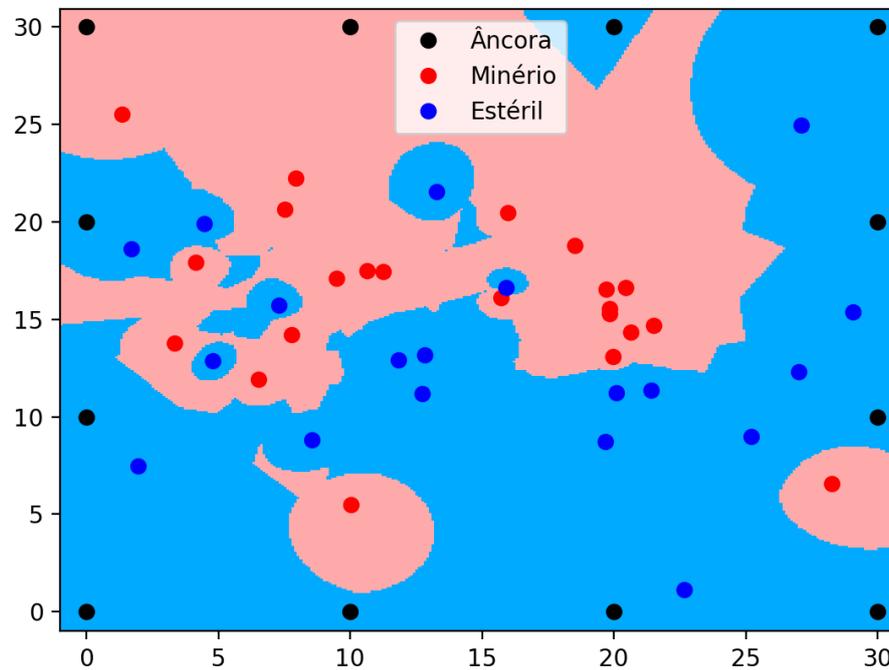


Figura 6.7: Identificação de zonas de minério com classificador KNN para $K = 3$.

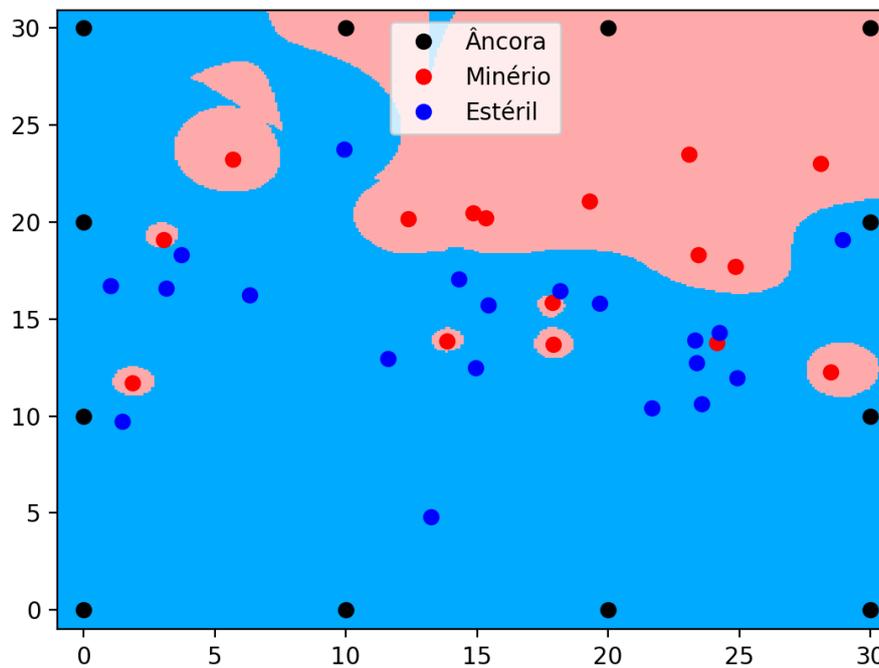


Figura 6.8: Identificação de zonas de minério com classificador KNN para $K = 31$.

Em ambas as figuras é possível notar a solução de compromisso. Na Figura 6.7, temos as fronteiras bem flexíveis, se moldando de forma bastante específica em torno de cada *tag*, mostrando a alta variância do modelo. Por sua vez, na Figura 6.8, as fronteiras são mais suaves, mas deixam algumas regiões não correlacionadas, aumentando o viés da predição.

Finalmente, alcançando uma visualização para a estimativa de classificação em todo o volume, calculamos uma nova estimativa de acurácia, agora para alguns pilotos de teste cuja classe conhecida. Utilizando um grupo com 100 pilotos espalhados juntamente com as tags durante a detonação, calculamos a média do erro de classificação para 100 simulações e obtivemos o valor de 78%. Este valor está um pouco abaixo do valor calculado pela validação cruzada, o que representa algo esperado pela influência da distribuição aleatória desconhecida dos pilotos após a detonação. Com mais dificuldade de encontrar um modelo que se encaixe para as *tags* e os pilotos, o erro tende então a aumentar.

Em síntese, o classificador KNN quando utilizado como aplicação direta da localização das tags se mostrou bastante adequado. Embora apenas um começo do estudo do problema, o método é de fácil interpretação e desempenho satisfatório, sendo uma possibilidade que utiliza os dados já entregues pelas estimativas de posição sem grande adição de complexidade.

7 CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS

Motivada pelas aplicações crescentes em ramos industriais e em especial na mineração, a busca por uma solução para o problema de localização de sensores em ambientes de comunicações através da terra se mostrou um tópico importante de pesquisa e, mais do que isso, um caminho necessário para o desenvolvimento de sistemas TTE realmente escaláveis.

Nos cenários mais utilizados de operações rotineiras em minas e em situações críticas, os requisitos estabelecidos de infraestrutura, potência e complexidade acabam limitando de forma geral as possibilidades de utilização de tecnologias já praticas e bem estabelecidas para comunicações sem fio, como WiFi e GPS. Dessa forma, foi necessário pensar o problema de forma a garantir uma alternativa viável.

A proposta parte da criação de uma rede de sensores, em que através de um sistema formado por *tags* e âncoras fosse possível estabelecer um enlace de comunicação e, conseqüentemente, a estimação da posição dos nós cujas coordenadas geográficas fossem desconhecidas.

Para a viabilização desse processo, utilizaram-se técnicas de medição RSS e do método de trilateração. Estes mecanismos foram aplicados em um modelo de canal TTE baseado em indução magnética, que utiliza de antenas loop para a transmissão e recepção e cuja formulação considera as especificidades típicas de um meio condutivo como a terra. Aqui, a derivação do canal para um modelo não-linear da perda de potência é utilizada enquanto função relativa da distância entre âncoras e *tags*.

Relacionando matematicamente a medida RSS às coordenadas desconhecidas, o problema de localização pode ser enxergado como um problema de otimização e assim, pensado dentro de processos típicos da literatura para regressão de dados.

Como base para os testes, foram estudados e propostos algoritmos baseados em métodos de mínimos quadrados não-lineares, na forma do algoritmo de Gauss-Newton e em sua versão mais robusta, o método de Levenberg-Marquardt. Estas técnicas utilizam de aproximações lineares e cálculo de derivadas para obter aproximações de um ponto de ótimo, podendo ser utilizadas nesse formato para a minimização do erro de medição e, conseqüentemente, a determinação de estimativas para as coordenadas.

A avaliação dos métodos propostos foi realizada por meio de simulação computacional em um cenário típico de aplicação da exploração em minas terrestres, considerando desempenho para diferentes parâmetros de entrada. O comportamento dos algoritmos é considerado em mudanças no número de nós âncora empregadas, no erro da medição RSS previsto para o canal e na distância máxima da estimativa inicial utilizada para a otimização.

Os resultados alcançados mostraram que o desempenho do método de Levenberg-Marquardt em um sistema TTE se relaciona de maneira inversamente proporcional com a quantidade de âncoras empregadas, em uma relação de decaimento que se estabiliza para um número grande de âncoras. Ainda, o erro de medida tem grande influência na efetividade da técnica, mesmo se comparado com o erro causado por estimativas iniciais muito. De fato, embora ambos os erros sejam representativos para os resultados finais, a relação diminui de forma mais acentuada para o aumento no erro da medição RSS.

Ainda assim, o desempenho se mostra muito dependente da estimativa inicial ser minimamente relacionada com a posição real. Como mostrado para estimativas iniciais geradas aleatoriamente, o erro de localização aumenta bastante, retirando acurácia do método. Somado isso à grande influência da variação do ângulo de rotação das antenas, enxergam-se dois problemas que precisam ser considerados.

Para a questão da contribuição do ângulo foram propostos duas soluções na forma de fixação dos eixos de rotação das antenas e na utilização de três antenas ortogonais para diversidade de recepção. Ambas as soluções apresentaram desempenho melhor do que a situação com ângulos desconhecidos, tendo o caso utilizando ângulos ortogonais apresentado um desempenho geral melhor para os cenários avaliados, enquanto os ângulos fixos se mostraram mais acurados para determinados cenários específicos.

Por sua vez, para o problema da estimativa inicial, o método de Recozimento Simulado foi proposto enquanto mecanismo de otimização estocástica para lidar com mínimos locais de uma maneira mais efetiva. Embora não tenha apresentado desempenho superior ao algoritmo LM quando avaliado individualmente, os resultados para o erro de localização quando as técnicas foram aplicadas em conjunto apresentaram desempenho consideravelmente maior. De fato, a utilização conjunta dos métodos SA e LM se mostrou uma alternativa mais viável não apenas para estimativas iniciais geradas aleatoriamente, mas também para casos em que informações em relação a posição real fossem conhecidas.

Em tempo, foi também analisado o comparativo para o modelo TTE pela utilização da aproximação numérica proposta com o método da secante e para a reparametrização

considerada no Capítulo 3. Em ambos os casos, os resultados tiveram desempenho pior, mesmo se mostrando relativamente próximos dos resultados do modelo original. Ainda assim, são aproximações aceitáveis em cenários que não conseguem lidar com alta complexidade, seja por falta de informações do modelo ou por limitações de processamento.

No geral, os mecanismos e técnicas para localização de sensores aqui avaliados se mostraram opções viáveis em sistemas de comunicações TTE. Mesmo para uma limitação de complexidade e alcance típica dos requisitos da aplicação na mineração, os resultados de simulação apresentaram um desempenho satisfatório em cenários verossímeis. Os algoritmos atingiram boas faixas de erro de localização, principalmente se considerando premissas razoáveis de manipulação dos ângulos, casos em que a estimativa de posição não distava mais de 2 metros da posição almejada.

Finalmente, uma aplicação direta da localização foi explorada para a detecção de zonas de minérios em cenários pós-detonação. Como visto no Capítulo 6, o problema pode ser encarado inteiramente como um problema de classificação estatística e, portanto, avaliado sob a ótica de métodos de aprendizado de máquina reconhecidos da literatura.

Utilizando as estimativas de localização obtidas e o classificador KNN, foram obtidos resultados de acurácia bastante satisfatórios, representando sucesso na predição em aproximadamente 80 % dos casos. De simples implementação, o classificador entregou estimativas gráficas das fronteiras entre regiões de minério e regiões estéreis, provendo uma ferramenta interessante para maior eficiência nos processos de extração.

Resultados melhores ainda podem ser alcançados, no entanto. Se flexibilizados os requisitos de potência e complexidade, uma série de outras técnicas e algoritmos podem ser explorados e a acurácia pode ser ainda mais refinada, para a localização e, conseqüentemente para aplicações como a de classificação.

Dessa forma, é alinhado com esse pensamento que ficam de propostas de trabalhos futuros:

- Avaliação das técnicas estudadas em um modelo de canal TTE experimental, com parâmetros mais representativos da composição específica dos solos;
- Aplicação de versões mais avançadas de métodos LS, além do comparativo com outras técnicas de otimização, como as baseadas em aprendizado de máquina, por exemplo;
- Teste de outros classificadores mais robustos para a etapa de identificação de zonas, como SVM e ANN; e

- Modelagem de cenários mais específicos de aplicação na mineração, para estudo comparativo.

Finalmente, é importante ressaltar que os resultados alcançados de simulação são referência para base de testes e a criação de protótipos. De forma que o principal avanço para esta pesquisa será a avaliação das técnicas propostas em um ambiente prático de aplicação.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ROJKO, A. Industry 4.0 concept: Background and overview. *iJIM - International Journal of Interactive Mobile Technologies*, v. 11, n. 5, 2017.
- [2] FINEP. "Finep e BNDES vão financiar projetos de inovação no setor mineral no valor de R\$ 1,4 bi". 2018. Sítio - <http://www.finep.gov.br/noticias/todas-noticias/5597-finep-e-bndes-vaio-financiar-projetos-de-inovacao-no-setor-mineral-no-valor-de-r-1-4-bi>. Acessado em: 18 de Junho de 2018.
- [3] YARKAN, S. et al. Underground mine communications: A survey. *IEEE Communications Surveys e Tutorials*, v. 11, n. 3, p. 125–142, 2009.
- [4] BARKAND, T. D.; DAMIANO, N. W.; SHUMAKER, W. A. Through-the-earth, two-way, mine emergency, voice communication systems. In: *Conference Record of the 2006 IEEE Industry Applications Conference Forty-First IAS Annual Meeting*. Tampa, FL, EUA: IEEE, 2006.
- [5] YENCHEK, M. R. et al. NIOSH-sponsored research in through-the-earth communications for mines - A status report. *IEEE Transactions on Industry Applications*, n. 5, p. 1700–1707, 2012.
- [6] CARRENO, J. D. P. *Channel Modeling for Through-the-Earth (TTE) Communications Systems*. 97 p. Dissertação (Mestrado) — Universidade de Brasília, 2016.
- [7] NEVES, S. O. de A. *Análise de Ruído e Simulação de Enlace em Comunicações Através da Terra*. 58 p. Dissertação (Mestrado) — Universidade de Brasília, 2017.
- [8] SILVA, L. S. e. *Interferência Intersimbólica, Ruído e Capacidade de Canal em um Sistema de Comunicação Através da Terra*. 61 p. Dissertação (Mestrado) — Universidade de Brasília, 2017.
- [9] HARTMAN, H. L.; MUTMANSKY, J. M. *Introductory mining engineering*. 2. ed. [S.l.]: John Wiley e Sons, 2002. (S.1).
- [10] FOROOSHANI, A. E. et al. A survey of wireless communications and propagation modeling in underground mines. *IEEE Communications Surveys Tutorials*, v. 15, n. 4, p. 1524–1545, 2013.

- [11] WHEELER, H. A. Radio-wave propagation in the earth's crust. *Journal of Research of the National Bureau of Standards*, v. 65, n. 2, p. 189–191, 1961.
- [12] RAAB, F. H.; JOUGHIN, I. R. Signal processing for through-the-earth radio communication. *IEEE Transactions on Communications*, IEEE, v. 43, n. 12, p. 2995–3003, 1995.
- [13] DURKIN, J. Electromagnetic detection of trapped miners. *IEEE Communications Magazine*, v. 22, n. 2, p. 37–46, 1984.
- [14] DURKIN, J. *Apparent earth conductivity over coal mines as estimated from through-the-earth electromagnetic transmission tests*. 1984.
- [15] PATWARI, N. *Location Estimation of Sensor Networks*. Tese (Doutorado) — Universidade de Michigan, 2005.
- [16] RUSU, S. R.; HAYES, M. J. D.; MARSHALL, J. A. Localization in large-scale underground environments with RFID. In: *24th Canadian Conference on Electrical and Computer Engineering (CCECE)*. Niagara Falls, ON, Canadá: IEEE, 2011.
- [17] MAO, G.; FIDAN, B.; ANDERSON, B. D. O. Wireless sensor network localization techniques. *Computer Networks*, v. 51, n. 10, p. 2529–2553, 2007.
- [18] SAVARESE, C.; RABAEY, J.; BEUTEL, J. Locationing in distributed ad-hoc wireless sensor networks. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings*. Salt Lake City, UT, EUA: IEEE, 2001.
- [19] ELNAHRAWY, E.; LI, X.; MARTIN, R. The limits of localization using signal strength: a comparative study. In: *First Annual IEEE Communications Society Conference on Sensor and Ad Hoc Communications and Networks*. Santa Clara, CA, EUA: IEEE, 2004.
- [20] BAHL, P.; PADMANABHAN, V. RADAR: an in-building RF-based user location and tracking system. In: *Conference on Computer Communications. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies*. Tel Aviv, Israel: IEEE, 2000.
- [21] BERGAMO, P.; MAZZINI, G. Localization in sensor networks with fading and mobility. In: *The 13th IEEE International Symposium on Personal, Indoor and Mobile Radio Communications*. Pavilhao Atlantico, Lisboa, Portugal: IEEE, 2002.
- [22] VEEN, B. V.; BUCKLEY, K. Beamforming: A versatile approach to spatial filtering. *IEEE ASSP Magazine*, v. 5, n. 2, p. 4–24, 1988.

- [23] SHIN, D.-H.; SUNG, T.-K. Comparisons of error characteristics between TOA and TDOA positioning. *IEEE Transactions on Aerospace and Electronic Systems*, v. 38, n. 1, p. 307–311, 2002.
- [24] BORRAS, J.; HATRACK, P.; MANDAYAM, N. Decision theoretic framework for NLOS identification. In: *48th IEEE Vehicular Technology Conference. Pathway to Global Wireless Revolution*. Ottawa, Ont., Canadá: IEEE, 1998.
- [25] PATWARI, N. et al. Locating the nodes: cooperative localization in wireless sensor networks. *IEEE Signal Processing Magazine*, v. 22, n. 4, p. 54–69, 2005.
- [26] SAVVIDES, A. et al. *Localization in sensor networks*. Boston, MA, EUA: Springer Science+Business Media, LLC, 2004.
- [27] VARGA, A. K. Localization techniques in wireless sensor networks. *Production Systems and Information Engineering*, v. 6, p. 81–90, 2012.
- [28] NICULESCU, D.; NATH, B. Ad-hoc positioning system (APS). In: *IEEE Global Telecommunications Conference*. San Antonio, TX, EUA: IEEE, 2002.
- [29] DOHERTY, L.; PISTER, K.; GHAOUI, L. E. Convex position estimation in wireless sensor networks. In: *Proceedings IEEE INFOCOM 2001. Conference on Computer Communications. Twentieth Annual Joint Conference of the IEEE Computer and Communications Society*. Anchorage, AK, EUA: IEEE, 2001.
- [30] BORG ngwer; GROENEN, P. J. *Modern multidimensional scaling: theory and applications*. 2. ed. Nova Iorque, EUA: Springer, 2005.
- [31] SHI, W.; WONG, V. W. MDS-based localization algorithm for RFID systems. In: *IEEE International Conference on Communications (ICC)*. Kyoto, Japão: IEEE, 2011.
- [32] KANNAN, A.; MAO, G.; VUCETIC, B. Simulated annealing based localization in wireless sensor network. In: *The IEEE Conference on Local Computer Networks 30th Anniversary (LCN'05)*. Sydney, NSW, Australia: IEEE, 2005.
- [33] ANDERSON, B. D. O. et al. Graphical properties of easily localizable sensor networks. *Wireless Networks*, v. 15, n. 2, p. 177–191, 2009.
- [34] BISHOP, C. M. *Pattern Recognition and Machine Learning*. 1. ed. [S.l.]: Springer, 2006.
- [35] CHISWELL, I. *Mathematical logic*. 1. ed. [S.l.]: Oxford University Press, 2007. 34 p.

- [36] WEBB, G. I.; BOUGHTON, J. R.; WANG, Z. Not so naive bayes: Aggregating one-dependence estimators. In: *Machine Learning*. [S.l.]: Springer, 2005. v. 58, n. 1, p. 5–24.
- [37] SAMMUT, C.; WEBB, G. I. *Encyclopedia of Machine Learning*. 1. ed. [S.l.]: Springer, 2011.
- [38] CRISTIANINI, N.; SHAWE-TAYLOR, J. *An Introduction to Support Vector Machines and other kernel-based learning methods*. 1. ed. [S.l.]: Cambridge University Press, 2000.
- [39] AGGARWAL, C. C. *Neural Networks and Deep Learning: A Textbook*. 1. ed. [S.l.]: Springer, 2018.
- [40] TERRELL, G. R.; SCOTT, D. W. Variable kernel density estimation. *The Annals of Statistics*, v. 20, n. 3, p. 1236–1265, 1992.
- [41] DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. 2. ed. [S.l.]: Wiley-Interscience, 2000.
- [42] GIBSON, A. D. W. *Channel Characterisation and System Design for Sub-Surface Communications*. Tese (Doutorado) — Universidade de Leeds, 2003.
- [43] WAIT, J. R. Electromagnetic induction technique for locating a buried source. *Geoscience Electronics, IEEE Transactions*, v. 9, n. 2, p. 95–98, 1971.
- [44] DURKIN, J. Surface vertical magnetic field produced by a finite loop buried in an earth containing a thin conducting sheet. *Radio Science, Wiley Online Library*, v. 32, n. 1, p. 19–23, 1997.
- [45] STARKEY, D. B. Electromagnetic transmission and detection at deep depths. In: *Proceedings of Thru-the-Earth Electromagnetics*. Colorado, EUA: Acceptance Technology Division 8344, Sandia Laboratories, 1973. p. 140–148.
- [46] GRIFFITHS, D. J. *Introduction to Electrodynamics*. 4. ed. [S.l.]: Pearson, 2013.
- [47] WAIT, J. R.; SPIES, K. Subsurface electromagnetic fields of a circular loop of current located above ground. *Antennas and Propagation, IEEE Transactions*, v. 20, n. 4, p. 520–522, 1972.
- [48] PRESS, W. H. et al. *Numerical Recipes: The Art of Scientific Computing*. 3. ed. Nova Iorque, EUA: Cambridge University Press, 2007.

- [49] NOCEDAL, J.; WRIGHT, S. *Numerical Optimization*. 2. ed. Nova Iorque, EUA: Springer-Verlag New York, 2006.
- [50] E., D. J.; R.B., S. *Numerical Methods for Unconstrained Optimization and Non-linear Equations*. 2. ed. Berlim, Alemanha: Springer-Berlin, 2006.
- [51] MADSEN, K.; NIELSEN, H.; TINGLEFF, O. *Methods For Non-Linear Least Squares Problems, Informatics and Mathematical Modeling*. 2. ed. Copenhagen, Dinamarca: Technical University of Denmark, 2004.
- [52] NIELSEN, H. *Damping Parameter in Marquardt's Method*. Copenhagen, Dinamarca, 1999.
- [53] MARQUARDT, D. W. An algorithm for least squares estimation on nonlinear parameters. *Journal of the Society for Industrial and Applied Mathematics*, v. 11, n. 2, p. 431–441, 1963.
- [54] CROEZE, L. P. A.; REYNOLDS, W. *Solving Nonlinear Least-Squares Problems with the Gauss-Newton and Levenberg-Marquardt Methods*. 2012.
- [55] BROYDEN, C. G. A class of methods for solving nonlinear simultaneous equations. *Mathematics of Computation*, v. 92, n. 19, p. 577–593, 1965.
- [56] POWELL, M. J. D. *A Hybrid Method for Non-Linear Equations*. [S.l.]: Gordon and Breach, 1970.
- [57] GILL, P. E.; MURRAY, W. Algorithms for the solution of the nonlinear least-squares problem. *SIAM Journal on Numerical Analysis*, v. 5, n. 15, p. 977–992, 1978.
- [58] GALVEZ, A.; IGLESIAS, A. Efficient particle swarm optimization approach for data fitting with free knot b-splines. *Computer-Aided Design*, v. 43, n. 12, p. 1683–1692, 2011.
- [59] YOSHIMOTO, T. H. F.; YOSHIMOTO, Y. Data fitting with a spline using a real-coded genetic algorithm. *Computer-Aided Design*, v. 35, n. 8, p. 751–760, 2003.
- [60] METROPOLIS, N. et al. Equation of state calculations by fast computing machines. *Journal of Chemical Physics*, v. 21, n. 6, p. 1087–1092, 1953.
- [61] LOUCERA, C.; GALVEZ, A.; IGLESIAS, A. Simulated annealing algorithm for bezier curve approximation. In: *Proceedings of the International Conference on Cyberworlds*. Santander, Espanha: IEEE Computer Society Press, 2014. p. 182–189.

- [62] AARTS, E. H.; LAARHOVEN, P. J. V. Statistical cooling: a general approach to combinatorial optimization problems. *Philips Journal of Research*, v. 40, n. 4, p. 193–226, 1985.
- [63] CHAMPLIN, R. *Selection Methods of Genetic Algorithms*. [S.l.], 2018.
- [64] SUMAN, B.; KUMAR, P. A survey of simulated annealing as a tool for single and multi-objective optimization. *Journal of the Operational Research Society*, v. 57, n. 10, p. 1143–1160, 2005.
- [65] LOCATELLI, M. Simulated annealing algorithms for continuous global optimization: convergence conditions. *Journal of Optimization Theory and Applications*, v. 104, n. 1, p. 121–133, 2000.
- [66] HROMKOVIC, J. *Algorithms for hard problems: Introduction to combinatorial optimization, randomization, approximation, and heuristics*. 2. ed. Heidelberg, Alemanha: Springer-Verlag, 2004.
- [67] YAN, L. et al. Mathematical modeling and measurement of electric fields of electrode-based through-the-earth (TTE) communication. *Radio Science*, American Geophysical Union, v. 52, n. 9, p. 731–742, 2017.
- [68] KAHN, L. R. Ratio squarer. *Proc. IRE*, v. 42, n. 11, p. 1704, 1954.