

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE  
AUTOMAÇÃO E SISTEMAS**

Breno Carneiro Pinheiro

**MODELOS BASEADOS EM FUNÇÕES KERNEL PARA  
LOCALIZAÇÃO DE VEÍCULOS AUTÔNOMOS SUBAQUÁTICOS**

Florianópolis

2015



Breno Carneiro Pinheiro

**MODELOS BASEADOS EM FUNÇÕES KERNEL PARA  
LOCALIZAÇÃO DE VEÍCULOS AUTÔNOMOS SUBAQUÁTICOS**

Esta Tese foi julgada aprovada para a obtenção do Título de “Doutor em Engenharia de Automação e Sistemas”, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Automação e Sistemas .

Florianópolis, 20 de fevereiro 2015.

---

Rômulo Silva de Oliveira, Dr.  
Coordenador do PPGEAS

---

Ubirajara Franco Moreno, Dr.  
Orientador

**Banca Examinadora:**

---

Prof. Ubirajara Franco Moreno, Dr.  
Presidente

---

Prof. Carlos Eduardo Parente Ribeiro, Dr.  
COOPE/UFRJ



---

Prof. Edson Roberto De Pieri, Dr.  
DAS/UFSC

---

Prof. Max Hering de Queiroz, Dr.  
DAS/UFSC

---

Prof. Marcelo Roberto Petry, Dr.  
UFSC/Blumenau

---

Prof. Romeu Reginatto, Dr.  
CECE/UNIOESTE



Este trabalho é dedicado à minha esposa e aos meus familiares.



“Estudo, eis tudo!”

(Waldo Vieira)



## RESUMO

Esta tese aborda a análise do sistema de localização acústica de veículos subaquáticos em uma configuração dita de base longa auxiliada por sensores inerciais. Para o processo de filtragem de dados, o filtro de Kalman, em sua versão estendida EKF (*Extended Kalman Filter*), é utilizado de modo a aproveitar toda informação relacionada aos estados do veículo proveniente dos sensores. O foco do trabalho está no processo de aprendizagem a partir de dados com vistas à identificação das medições errôneas do tempo de chegada da sonda sonora e à correção das mesmas. As técnicas exploradas para essas finalidades são o AAKR (*AutoAssociative Kernel Regression*) e o SVDD (*Support Vector Data Description*). O objetivo é melhorar a estimação dos estados do veículo (posição, velocidade e orientação) provenientes dos sensores inerciais, aproveitando um conjunto de medições corretas obtidas durante a navegação ou em missões anteriores à atual. A melhoria no desempenho do sistema de localização foi analisado por simulação utilizando dados experimentais obtidos em missões com veículos de baixo custo e modelos de propagação acústica que inserem desvios factíveis aos tempos de chegada medidos. Os resultados são comparados ao desempenho obtido com uma solução clássica para a localização acústica de veículos autônomos em ambiente subaquático. Destaca-se ainda que a arquitetura proposta não se apresenta firmemente acoplada ou fortemente dependente de qualquer outro algoritmo presente no veículo, o que a caracteriza como uma solução bastante modular com a possibilidade de estendê-la a outras aplicações.

**Palavras-chave:** Sistemas de navegação inercial, sistema de localização acústico subaquático, agregados de sensores de base longa, veículos autônomos subaquáticos, estimação de posição, filtragem de Kalman, modelos empíricos baseados em funções kernel, aprendizagem estatística, aprendizagem a partir de dados.



## ABSTRACT

This thesis deals with the analysis of an acoustic localization system in a long baseline configuration for navigation of underwater vehicles aided by inertial sensors. For the process of filtering data, the Extended Kalman Filter (EKF) is used in order to take advantage of all information related to the states of the vehicle from the sensors. The focus is on the process of learning from data with a view to identify erroneous measurements of the time of flight of the acoustic signal and correct eventual deviations in this quantity. The techniques used for these purposes are AAKR (AutoAssociative Kernel Regression) and SVDD (Support Vector Data Description). The objective is to improve the accuracy of the estimates of the vehicle's states (position, velocity and orientation) coming from the inertial sensors, taking advantage of a set of correct measurements obtained during prior navigations or in the current missions. The improved performance of the tracking system is evidenced by the data obtained using in field missions with low-cost vehicles and acoustic propagation models that insert feasible deviations to arrival times measured. The results are compared with the performance obtained with other classical solution to acoustic localization task in underwater environment of autonomous vehicles. It is highlighted also that the proposed architecture is not tightly coupled to any other algorithm running in the vehicle, which characterizes the approach as a very modular and cost-effective computing solution.

**Keywords:** Inertial navigation systems, underwater acoustic localization, long base line, autonomous underwater vehicles, position estimation, Kalman filtering, empirical models based on kernel functions, statistical learning, learning from data.



## LISTA DE FIGURAS

Figura 1	Vista do lago da usina hidrelétrica de ITAIPU Binacional. . . . .	30
Figura 2	Configurações clássicas para o sistema de localização acústico [Jesus et al. 2006]. . . . .	35
Figura 3	Contribuição do trabalho - integração dos três tópicos de pesquisa com foco na localização acústica utilizando a configuração LBL. . . . .	39
Figura 4	Blocos que compõem o sistema de navegação inercial. . . . .	41
Figura 5	Sistema de navegação. Agrupamento da unidade de medições inerciais e do algoritmo de fusão de dados. . . . .	42
Figura 6	Sistema de navegação. Agrupamento da unidade de medições inerciais, do algoritmo de fusão de dados e o auxílio de sensores externos. . . . .	43
Figura 7	Representação completa de sistema de navegação auxiliado por sensores externos. . . . .	43
Figura 8	Sistema de navegação com auxílio do sistema de localização acústico. . . . .	45
Figura 9	Estrutura de processamento de sinal acústico para determinação do tempo de chegada da onda. . . . .	47
Figura 10	Exemplo de onda sinusoidal em $10Hz$ para localização de um AUV. . . . .	48
Figura 11	Saída do filtro casado para determinação do tempo de chegada da onda. . . . .	48
Figura 12	Saída do filtro casado considerando uma relação sinal ruído de $-50 dB$ . . . . .	49
Figura 13	Exemplo de sinal modulado com deslocamento de fase por codificação binária. . . . .	49
Figura 14	Saída do filtro casado considerando uma sinal emitido com espalhamento espectral considerando uma relação sinal ruído de $-50 dB$ . . . . .	50
Figura 15	Perfil de velocidade do som ao longo da coluna d'água. . . . .	51
Figura 16	Traçamento de raios com o BELLHOP em ambiente com perfil de velocidade do som mostrado. . . . .	52
Figura 17	Detalhamento do sistema de localização acústico mostrado na figura 8. Em destaque, o módulo de avaliação de resíduos agrupado ao esquema de rejeição para fins de classificação das medições quanto à sua representatividade em relação ao banco de dados. . . . .	53
Figura 18	Detalhe do módulo de correção de medições mostrado na fi-	

gura 17, agrupado à re-análise dos resíduos pelo esquema de rejeição para fins de aceite ou descarte dos tempos de chegada medidos.....	54
Figura 19 Sistemas de coordenadas utilizados para navegação.....	58
Figura 20 Configuração do sistema de navegação inercial.....	60
Figura 21 Detalhe do processamento realizado no sistema de navegação inercial. ....	66
Figura 22 Configuração de um sistema de navegação assistido .....	67
Figura 23 Sensoriamento do sistema de localização acústico [Lee et al. 2007]. ....	69
Figura 24 Configuração do sistema de localização LBL. ....	70
Figura 25 Navegação auxiliada por DVL.....	71
Figura 26 Navegação auxiliada pelo modelo.....	72
Figura 27 Trajetória realizada pelo veículo e posicionamento dos quatro emissores acústicos do sistema LBL. ....	88
Figura 28 Trajetória do veículo estimada com o conjunto IMU/INS. Nenhuma correção foi efetuada nos desvios inerentes às medições desses sensores.....	88
Figura 29 Trajetória estimada com o conjunto IMU/INS e os sensores externos auxiliares. O filtro de Kalman estendido foi utilizado no processo de fusão de dados. ....	89
Figura 30 Hiperesfera com 10 observações de dados alvos e $s = 2$ . ....	104
Figura 31 Hiperesfera com 10 observações de dados alvos e $s = 5$ . ....	104
Figura 32 Hiperesfera com 10 observações de dados alvos, $\beta = 0.1$ e $s = 2$ . ....	106
Figura 33 Hiperesfera com 10 observações de dados alvos, $\beta = 1$ e $s = 2$ . ....	107
Figura 34 Hiperesfera contendo três observações da distribuição normal. ....	108
Figura 35 Hiperesfera isolando as observações que melhor descrevem o conjunto de dados. ....	109
Figura 36 Sistema de navegação inercial integrado à solução proposta para o sistema de localização.....	114
Figura 37 Descritor de dados em duas dimensões. O vetor de entrada será avaliado quanto à sua aceitação de acordo com sua distância ao centro da região de fronteira. ....	119
Figura 38 Descritor de dados em uma única dimensão. A região de fronteira é definida exclusivamente pelo raio $R_1$ .....	119
Figura 39 Fluxograma para o sistema de localização acústico. Análise de resíduo via descritor de dados e correção de medições via modelos de regressão kernel autoassociativos. ....	121

Figura 40	Veículo utilizado em missão para aquisição de dados. . . . .	124
Figura 41	Versão do Neptus para a área de realização dos testes. Detalhe da configuração LBL utilizada. . . . .	125
Figura 42	Dados de profundidade e altitude durante uma missão. . . . .	125
Figura 43	Exemplo de missão realizada pelo veículo. Os dados são utilizados para a composição do banco de dados com os tempos de chegada da onda acústica. . . . .	128
Figura 44	Primeira trajetória para a etapa de validação. . . . .	129
Figura 45	Valores de $\gamma_k$ para o emissor 0 considerando os casos com e sem a aplicação do AAKR. Primeira trajetória. . . . .	130
Figura 46	Valores de $\gamma_k$ para o emissor 1 considerando os casos com e sem a aplicação do AAKR. Primeira trajetória . . . . .	130
Figura 47	Segunda trajetória para a etapa de validação. . . . .	131
Figura 48	Valores de $\gamma_k$ para o emissor 0 considerando os casos com e sem a aplicação do AAKR. Segunda Trajetória. . . . .	132
Figura 49	Valores de $\gamma_k$ para o emissor 1 considerando os casos com e sem a aplicação do AAKR. Segunda Trajetória. . . . .	132
Figura 50	Região de fronteira para diferentes valores dos parâmetros $s$ e $\beta$ no algoritmo do SVDD. . . . .	137
Figura 51	Modelo de propagação dos raios acústicos. . . . .	138
Figura 52	Exemplos de medições errôneas em uma missão com o LAUV. . . . .	140
Figura 53	Valores médios da diferença entre a posição estimada e a real do veículo considerando o modelo de propagação de raios e as duas arquiteturas para o sistema de localização. No SVDD, o raio é calculado utilizando as duas dimensões e as distância calculadas em dimensões separadas. . . . .	143
Figura 54	Valores médios da diferença entre a posição estimada e a real do veículo considerando o modelo de propagação de raios e as duas arquiteturas para o sistema de localização. No SVDD, os raios e as distâncias são calculados dimensões separadas. . . . .	145
Figura 55	Trajetória realizada do veículo para validação - vista 1. . . . .	146
Figura 56	Trajetória realizada do veículo para validação - vista 2. . . . .	146
Figura 57	Trajetória realizada do veículo para validação - plano xy. . . . .	147
Figura 58	Trajetória Estimada do veículo com e sem aplicação do modelo de propagação de raios. . . . .	147
Figura 59	Valores médios da diferença entre a posição estimada e a real do veículo considerando o modelo de propagação de raios e as duas ar-	

quieturas para o sistema de localização. Segunda trajetória. . . . . 149

Figura 60 Exemplo de região de fronteira obtido a partir das simulações com a segunda trajetória do veículo. Os valores de  $s$  e  $\beta$  foram ajustados em 25 e 0.2 respectivamente. . . . . 150

## LISTA DE TABELAS

Tabela 1	Exemplos de áreas de aplicação de veículo subaquáticos. . . .	30
Tabela 2	Alguns modelos de veículos subaquáticos desenvolvidos no mundo. . . . .	31
Tabela 3	Exemplo de erros de posição. . . . .	61
Tabela 4	Dados de variância das grandezas medidas pelo IMU/INS . . .	85
Tabela 5	Dados de variância das grandezas medidas pelos sensores externos . . . . .	86
Tabela 6	Desempenho do sistema de localização com e sem aplicação do AAKR para correção dos tempos de chegada. Primeira trajetória . . .	129
Tabela 7	Desempenho do sistema de localização com e sem aplicação do AAKR para correção dos tempos de chegada. Segunda trajetória. . . .	131
Tabela 8	Evolução da raiz quadrada do erro quadrático médio da distância horizontal em função dos valores da largura de banda $h$ para medições aceitas. . . . .	134
Tabela 9	Evolução do RQ-EQM ( $m$ ) em função dos valores da largura de banda $h$ para medições rejeitadas. . . . .	134
Tabela 10	Evolução do RQ-EQM ( $m$ ) em função dos parâmetros do SVDD. . . . .	136
Tabela 11	Evolução do RQ-EQM ( $m$ ) em função dos parâmetros do SVDD. . . . .	136
Tabela 12	Comparação de valores do RQ-EQM ( $m$ ) em 10 execuções utilizando as duas arquiteturas em análise. No SVDD, o raio é calculado utilizando as duas dimensões e as distâncias calculadas em dimensões separadas. . . . .	142
Tabela 13	Comparação de valores do RQ-EQM ( $m$ ) em 10 execuções utilizando as duas arquiteturas em análise. No SVDD, os raios e as distâncias são calculados dimensões separadas. . . . .	144
Tabela 14	Comparação de valores do RQ-EQM ( $m$ ) em 10 execuções utilizando as arquiteturas em análise. No SVDD, o raio é calculado utilizando as duas dimensões e as distância calculadas em dimensões separadas. No AARK, a regressão é aplicada em uma e duas dimensões, optando-se pelo melhor resultado. . . . .	148
Tabela 15	Valores para a largura de banda do kernel do modelo autoassociativo de acordo com a distância ao centro da região de fronteira do descritor de dados. . . . .	148



## LISTA DE ABREVIATURAS E SIGLAS

AUV	Autonomous Underwater Vehicle
GNSS	Global Navigation Satellite System
SLAM	Simultaneous Localization and Mapping
PCA	Principal Component Analysis
USBL	Ultra Short Base Line
SBL	Short Base Line
LBL	Long Base Line
SVM	Support Vector Machines
AAKR	AutoAssociative Kernel Regression
SVDD	Support Vector Data Description
EKF	Extended Kalman Filter
IMU	Inertial Measurement Unit
INS	Inertial Navigation System
SNR	Signal Noise Ratio
MF	Matched Filter
MLE	Maximum Likelihood Estimator
APS	Acoustic Position System
HADCP	Horizontal Acoustic Doppler Current Profiler
i.i.d.	Independente e Identicamente Distribuído
EQM	Erro Quadrático Médio
EQM-C	Erro Quadrático Médio Cruzado
LAUV	Light Autonomous Underwater Vehicle
RQ-EQM	Raiz Quadrada do Erro Quadrático Médio



## CONTEÚDO

<b>Nomenclatura</b> .....	25
<b>1 INTRODUÇÃO</b> .....	29
1.1 LOCALIZAÇÃO DE VEÍCULOS AUTÔNOMOS .....	32
1.2 OBJETIVOS DA TESE .....	37
1.3 OBJETIVOS ESPECÍFICOS .....	38
1.4 CONTRIBUIÇÕES DA TESE .....	39
1.5 ORGANIZAÇÃO DO TEXTO .....	40
<b>2 DESCRIÇÃO DO SISTEMA DE NAVEGAÇÃO</b> .....	41
2.1 INTRODUÇÃO .....	41
2.2 SISTEMA INERCIAL .....	41
2.3 NAVEGAÇÃO ASSISTIDA POR SENSORIAMENTO EXTERNO	42
2.4 NAVEGAÇÃO ASSISTIDA POR SISTEMA DE LOCALIZA- ÇÃO ACÚSTICO .....	44
<b>2.4.1 Canal de Comunicação</b> .....	45
<b>2.4.2 Processamento do Sinal Acústico</b> .....	47
<b>2.4.3 Velocidade do Som e Reflexões Parasitas</b> .....	50
2.5 AVALIAÇÃO DE RESÍDUOS E MÓDULO DE REJEIÇÃO .....	52
2.6 CORREÇÃO .....	54
2.7 CONCLUSÃO .....	55
<b>3 SISTEMA DE NAVEGAÇÃO</b> .....	57
3.1 SISTEMAS DE COORDENADAS .....	57
<b>3.1.1 Sistema de Coordenadas Inercial</b> .....	57
<b>3.1.2 Sistema de Coordenadas Fixo à Terra</b> .....	57
<b>3.1.3 Sistema de Coordenadas de Navegação</b> .....	58
<b>3.1.4 Sistema de Coordenadas Fixo ao Corpo</b> .....	59
3.2 SISTEMA DE NAVEGAÇÃO INERCIAL .....	59
<b>3.2.1 Principais Fontes de Erro</b> .....	60
3.2.1.1 Bias e Taxa de Desvio .....	61
3.2.1.2 Temperatura .....	61
3.2.1.3 Histerese .....	61
3.2.1.4 Vibrações .....	62
<b>3.2.2 Equações de Navegação</b> .....	62
3.2.2.1 Equação da Velocidade .....	62
3.2.2.2 Equação de Orientação .....	64
3.2.2.3 Equação de Posição .....	65
3.2.2.4 Algoritmos .....	66
3.3 SISTEMA DE NAVEGAÇÃO ASSISTIDO .....	67

3.3.1	Sistemas de Localização Acústicos .....	68
3.3.2	Arquitetura .....	69
3.3.3	Doppler Velocity Log - DVL .....	69
3.3.4	Horizontal Acoustic Doppler Current Profiler - HADCP .....	71
3.3.5	Navegação assistida pelo modelo .....	72
3.4	CONCLUSÕES .....	73
4	ALGORITMO DE FUSÃO DE DADOS E A ESTIMAÇÃO DE ESTADOS .....	75
4.1	FILTRO DE KALMAN ESTENDIDO .....	75
4.1.1	Equações de Medição .....	78
4.1.1.1	Localizadores Acústicos .....	79
4.1.1.2	DVL .....	80
4.1.1.3	HADCP .....	81
4.1.1.4	Sensores de Profundidade e Orientação .....	83
4.1.2	Propagação no tempo e Correção .....	83
4.1.3	Suposições Estatísticas .....	85
4.1.4	Propriedades estatísticas .....	85
4.1.5	Limitações .....	86
4.1.6	Simulação .....	87
4.2	CONCLUSÃO .....	88
5	FUNDAMENTOS TEÓRICOS DOS MODELOS BASEADOS EM FUNÇÕES KERNEL .....	91
5.1	INTRODUÇÃO .....	91
5.2	MODELOS AUTOASSOCIATIVOS .....	91
5.2.1	Mapeamentos Autoassociativos .....	93
5.2.2	Regressão Kernel AutoAssociativa .....	93
5.2.3	Normalização .....	95
5.2.4	Métricas de Desempenho .....	96
5.2.5	Bias e Variância .....	97
5.2.6	Validação Cruzada .....	98
5.3	DESCRIÇÃO DE DADOS POR VETORES SUPORTE .....	99
5.3.1	Função Kernel .....	102
5.3.1.1	Exemplo .....	103
5.3.2	Parâmetro $\beta$ e $s$ .....	105
5.3.2.1	Exemplo .....	106
5.3.3	Treinamento com exemplos errôneos ou negativos .....	106
5.3.3.1	Exemplo .....	107
5.3.4	Aprendizagem Online .....	109
5.3.5	Aplicações .....	109
5.4	CONCLUSÕES .....	110

<b>6 ARQUITETURA PROPOSTA PARA O SISTEMA DE LOCALIZAÇÃO DE VEÍCULOS SUBAQUÁTICOS .....</b>	<b>113</b>
6.1 INTRODUÇÃO .....	113
6.2 ARQUITETURA PROPOSTA .....	113
<b>6.2.1 Processamento da Informação .....</b>	<b>114</b>
6.3 ALGORITMO.....	116
<b>6.3.1 Análise de Resíduo .....</b>	<b>118</b>
<b>6.3.2 Correção de Medições .....</b>	<b>120</b>
<b>6.3.3 Fluxograma do Sistema de Localização .....</b>	<b>120</b>
6.4 CONCLUSÃO .....	122
<b>7 ANÁLISE DE RESULTADOS COM O SISTEMA DE NAVEGAÇÃO PROPOSTO .....</b>	<b>123</b>
7.1 INTRODUÇÃO .....	123
7.2 O VEÍCULO .....	123
7.3 REJEIÇÃO DE EXEMPLOS ERRÔNEOS.....	125
7.4 MÉTODO DE ANÁLISE .....	126
7.5 MODELO AUTOASSOCIATIVO .....	127
<b>7.5.1 Composição do banco de dados .....</b>	<b>128</b>
7.6 VALIDAÇÃO .....	129
7.7 AJUSTES DE PARÂMETROS.....	133
<b>7.7.1 Parâmetro <math>h</math> - AAKR .....</b>	<b>133</b>
7.7.1.1 Medições Aceitas .....	133
7.7.1.2 Medições Rejeitadas .....	134
<b>7.7.2 Parâmetros <math>\beta</math> e <math>s</math> - SVDD .....</b>	<b>135</b>
7.7.2.1 Avaliação utilizando $d_{11}$ e $d_{22}$ com $R_{12}$ .....	135
7.7.2.2 Avaliação utilizando $d_{11}$ com $R_{11}$ e $d_{22}$ com $R_{22}$ .....	136
7.8 VALIDAÇÃO DA PROPOSTA.....	138
<b>7.8.1 Modelo de Propagação .....</b>	<b>138</b>
<b>7.8.2 Aplicação do Algoritmo Proposto - Primeira trajetória .....</b>	<b>140</b>
7.8.2.1 Avaliação do Algoritmo utilizando $d_{11}$ e $d_{22}$ com $R_{12}$ .....	141
7.8.2.2 Avaliação do algoritmo utilizando $d_{11}$ com $R_{11}$ e $d_{22}$ com $R_{22}$ ..	142
<b>7.8.3 Aplicação do Algoritmo Proposto - Segunda trajetória .....</b>	<b>143</b>
7.9 CONCLUSÕES .....	149
<b>8 CONCLUSÃO E PERSPECTIVAS FUTURAS.....</b>	<b>153</b>
8.1 CONTRIBUIÇÃO - VISÃO GERAL.....	153
8.2 OBSERVAÇÕES GERAIS .....	156
8.3 PERSPECTIVAS FUTURAS .....	157
8.4 LISTA DE PUBLICAÇÕES .....	157
<b>APÊNDICE A – Algoritmo Incremento/Decremento .....</b>	<b>161</b>
<b>Bibliografia .....</b>	<b>169</b>



## NOMENCLATURA

**I** Sistema de Coordenadas Inercial (*Inertial Frame*)

**B** Sistema de Coordenadas Fixo ao Corpo (*Body Fixed Frame*)

**E** Sistema de Coordenadas Fixo à Terra (*Earth Fixed Frame*)

**W** Sistema de Coordenadas Wind (*Wind Frame*)

**N** Sistema de Coordenadas de Navegação (*Navigation Frame*)

$C_A^B$  Matriz de cossenos diretores para transformação de um sistema de coordenadas  $A$  para um sistema de coordenadas  $B$

$R_A^B$  Matriz de rotação de um sistema de coordenadas  $A$  para um sistema de coordenadas  $B$

$\psi$  Ângulo de rotação do veículo referente à guinada

$\phi$  Ângulo de rotação do veículo referente à arfagem

$\theta$  Ângulo de rotação do veículo referente à rolagem

$k$  Instantes discretos do tempo

$Q_k$  Matriz de covariância do ruído presente nos processos dinâmicos no instante  $k$

$R_k$  Matriz de covariância do ruído presente nas medições sensoriais no instante  $k$

$P_k$  Matriz de covariância do erro de predição no instante  $k$

$K_k$  Ganho de Kalman no instante  $k$

$H_k$  Jacobiano do modelo de medição no instante  $k$

$\mathbf{P}_i$  Vetor posição de  $i$ -ésima boia acústica em relação a um referencial inercial

$\omega_{AB}^C$  Vetor velocidade angular relativa do sistema de referência  $B$  em relação ao  $A$  expresso no sistema de referência  $C$

$\Omega_{AB}^C$  Matriz antissimétrica do vetor velocidade angular relativa  $\omega_{AB}^C$  do sistema de referência  $B$  em relação ao  $A$  expresso no sistema de referência  $C$

$\Omega$  Velocidade angular em *rad/s*

$[\delta\lambda_x]$  Matriz antissimétrica com os elementos do vetor  $\delta\lambda$

$E[]$  Operador valor esperado

$R'$  Transposta da Matriz  $R$

$\langle \cdot, \cdot \rangle$  Produto interno ou produto escalar entre dois vetores

$h$  Largura de banda do kernel gaussiano do algoritmo de correção (AAKR)

$w$  Pesos aplicados às amostras de medição do banco de dados do algoritmo de correção (AAKR)

$s$  Largura de banda do kernel gaussiano do descritor de dados (SVDD)

$\beta$  Limite superior para os multiplicadores de Lagrange

$L$  Função Lagrangiana

$z$  Medições provenientes de sensores externos instalados no veículo

$\delta z$  Resíduo proveniente das medições sensoriais

$\delta x$  Vetor de estados no espaço de erro

$x$  Vetor de estados do veículo

$\hat{x}$  Estimativa do vetor de estados do veículo

$\hat{x}^-$  Estimativa inicial do vetor de estados do veículo

$\hat{x}^+$  Estimativa posterior do vetor de estados do veículo

$v_w$  Vetor velocidade das correntes de água em relação à Terra

$\mathcal{V}$  Conjunto de dados com resíduos gerados a partir de medições acústicas aceitas

$Z$  Matriz composta com medições acústicas aceitas

$c$  Velocidade do som

$a$  Centro da região de fronteira

$\Gamma$  Raio da região de fronteira

$\gamma$  Limiar superior da distância de Mahalanobis utilizado em algoritmos de rejeição de medições

$\sigma$  Desvio padrão

$\sigma^2$  Variância



## 1 INTRODUÇÃO

O interesse em plataformas autônomas subaquáticas fundamenta-se principalmente na sua ampla aplicabilidade no monitoramento e exploração do meio ambiente [Dunbabin e Marques 2012]. Devido às extensas áreas e à enorme variabilidade das condições ambientais, tanto espacial quanto temporalmente, a utilização de estações de coleta de dados, por exemplo, limita a compreensão sobre a dinâmica de um determinado ecossistema. O interesse em veículos autônomos subaquáticos, doravante denominados AUVs, está atrelado à crescente demanda da humanidade pelos recursos naturais. Exemplos dessa estreita relação estão no uso de veículos para inspeção de tubulações submersas que transportam óleo e gás natural, no levantamento batimétrico de um rio para acompanhar o processo de assoreamento ou na exploração arqueológica. Os avanços tecnológicos na área de sensores têm equipado os veículos com instrumentação capaz de coletar amostras de água somente nos instantes em que determinados parâmetros sofrem alteração [Zhang et al. 2009]. A grande maioria dessas plataformas são utilizados para pesquisas oceânicas, onde apresentam maiores vantagens em relação aos veículos operados remotamente. Em particular, o custo operacional e raio de atuação são duas importantes características que fazem dos AUVs uma opção vantajosa quando se trata de inspeções em grandes áreas. Alguns exemplos típicos de aplicações desses veículos estão detalhados na tabela 1.

Em meados do ano 2000, havia mais de 46 modelos de AUV no mundo [Yuh 2000], número que certamente vem crescendo com as novas demandas da sociedade. Alguns desses modelos, que ainda estão em operação, estão mostrados na tabela 2.

No cenário brasileiro, destaca-se a utilização de veículos subaquáticos na indústria petrolífera e monitoramento ambiental [Olivera 2007]. Além disso, por apresentar sua matriz energética baseada fundamentalmente em hidrelétricas com seus extensos lagos, a inspeção e exploração dessas regiões com os AUV tende a reduzir custos e aumentar a eficiência. Atualmente, veículos híbridos, que podem ser tanto autônomos como operados remotamente, foram utilizado na usina hidrelétrica de Lajeado para levantamento do relevo e visualização do paramento da usina [Cruz et al. 2011].

Nos ambientes de lagos de barragens, como mostrado na figura 1, os veículos costumam visitar locais com variações de temperatura, batimetria, correntes, velocidade do vento e chuvas localizadas, ou seja, fatores que impactam diretamente na qualidade e segurança da navegação. Somam-se a isso, a densa presença de vegetação e matéria orgânica em suspensão comuns nesses ambientes e que impactam sobremaneira o desempenhos dos sensores

## Aplicações

Pesquisas Científicas	Mapeamento de leitos oceânicos; Amostras geológicas, oceanografia; Pesquisas arqueológicas;
Meio - Ambiente	Monitoramento de vazamento de óleo, radiação, poluição; Inspeção de tubulações e construções subaquáticas;
Industriais	Exploração de petróleo e gás; Mineração oceânica;
Outras Aplicações	Inspeção de cascos de navios; Inspeção de instalações em usinas nucleares; Inspeção de cabos de transmissão de energia.

Tabela 1: Exemplos de áreas de aplicação de veículo subaquáticos.



Figura 1: Vista do lago da usina hidrelétrica de ITAIPU Binacional.

embarcados no veículo.

A navegação autônoma envolve problemas desafiadores quanto à orientação e ao controle dos veículos devido à dinâmica imprevisível dos ambi-

<b>Modelos</b>	<b>Aplicação</b>	<b>Desenvolvedores</b>
Hugin	Pesquisa oceânica e Comercialização	<i>Norwegian Defense Establishment, Norway</i>
REMUS	Pesquisa oceânica	<i>Woods Hole Oceanographic Institution, MA</i>
Marius	Pesquisa oceânica	IST,Portugal
Odyssey I Odyssey II B Odyssey III	Missões Científicas	<i>MIT Sea Grant, Cambridge, MA</i>
Dolphin	Monitoramento de águas	<i>Yard Ltd., Glasgow, Scotland</i>
Explorer	Inspeção de tubulações	<i>Shenyang Institute of Automation, China</i>
ALTEX AUV	Pesquisa e exploração no oceano Ártico	<i>Monteray Bay Aquarium Research Institute, CA</i>
TriMares	Inspeção de estruturas submersas e batimetria	<i>Faculdade de Engenharia da Universidade do Porto, Portugal</i>

Tabela 2: Alguns modelos de veículos subaquáticos desenvolvidos no mundo.

entes subaquáticos. As questões relativas à estabilidade da plataforma, modelagem e manutenção ou seguimento de ponto de operação são concernentes ao controle. Em outro plano, a orientação do veículo refere-se às definições de estratégias de rota, bem como ao comportamento da plataforma quanto a sua velocidade e posicionamento em relação a um referencial, tendo em vista o cumprimento eficaz de sua missão [Fossen 2006, Fossen 1994]. Em qualquer um desses contextos, os sensores são fundamentais para o funcionamento harmonioso do sistema, ou seja, tanto o controle em mais alto nível, que coordena a missão, quanto o de baixo nível, responsável pela estabilidade do veículo, beneficiam-se da fusão de informações provenientes desses equipamentos. Desse modo, no processo de navegação subaquática é a redundância de informações que favorece a melhoria das estimativas dos estados do veículo.

Dentre um universo de sensores que auxiliam a navegação, o sistema

de localização acústico constitui uma ferramenta fundamental tanto para veículos que operam submersos quanto para as plataformas robóticas terrestres que, nesse caso, ainda podem usufruir de instrumentos como o sistema de posicionamento por satélite (GNSS). Tal importância advém da necessidade de corrigir os erros inerentes às estimativas realizadas pelo sistema de navegação inercial (INS) [Geng, Martins e Sousa 2010], responsável por estimar grandezas como velocidade e orientação, bem como devido à relação direta entre a grandeza medida, nesse caso o tempo de chegada da onda sonora, e o posicionamento do veículo. Como será abordado, a utilização de ondas sonoras pelo sistema de localização deixa-o suscetível a problemas como reflexões, refrações e atenuação do sinal. Soma-se a isso, as alterações na velocidade do som ao longo da coluna d'água, presença de materiais em suspensão e ruídos periféricos, todos comuns a ambientes de lagos como o mostrado na figura 1.

Reconhecendo sua relevância na navegação autônoma, o objeto de pesquisa abordado ao longo desse trabalho refere-se ao sistema de localização acústico para veículos autônomos subaquáticos no que tange às melhorias das medições de tempo de chegada da onda sonora. Para além do que foi exposto, essa estratégia de localização ganha maior relevância quando se analisam os diversos fatores que definem o sucesso de uma missão utilizando plataformas subaquáticas. Em primeiro lugar, destaca-se a segurança, pois, com o mapeamento do ambiente e a confiável auto-localização, o veículo poderá evitar determinadas regiões consideradas proibitivas, além de evitar sua própria perda de orientação. Além disso, o grau de eficiência do sistema quanto ao cumprimento de uma determinada missão como, por exemplo, o mapeamento de uma área, depende de um sistema de localização confiável que evite falhas, como deixar de visitar determinadas localidades, e que garanta a cobertura da região desejada num tempo hábil e adequado à autonomia do veículo.

## 1.1 LOCALIZAÇÃO DE VEÍCULOS AUTÔNOMOS

Grosso modo, pode-se identificar duas abordagens clássicas para a localização de plataformas móveis autônomas. Num caso mais simples, porém não menos importante, o veículo consegue localizar-se numa região com base em sua posição relativa a determinadas marcações ou sinalizadores fixos e em posições conhecidas. Numa outra linha, não excludente em relação à primeira, a plataforma robótica se autolocaliza dentro de uma mapa desconhecido, ou seja, a localização dá-se simultaneamente ao mapeamento dentro do ambiente. Essa técnica é conhecida como SLAM (*Simultaneous Localization and Mapping*) [Durrant-Whyte e Bailey 2006, Bailey e Durrant-

whyte 2006] e tem recebido significativa atenção nas pesquisas relacionadas à robótica probabilística [Bailey 2001]. No caso de veículos subaquáticos, destacam-se os trabalhos utilizando essa abordagem como em [Barkby et al. 2009], onde utilizam-se imagens obtidas por meio de batimetria que são então correlacionadas com um mapa previamente disponibilizado ao veículo. Já em [Ribas, Ridaio e Neira 2010], a técnica do SLAM é explorada utilizando sonar de imagem em ambiente estruturado para inspeção de estruturas submersas. O trabalho desenvolvido em [Kazmi et al. 2009] mostra como essa técnica pode ser aplicada à localização da linha da parede de uma barragem hidrelétrica utilizando o mesmo sonar de imagem. Nesse caso, o veículo torna-se capaz de posicionar-se corretamente para realizar inspeções visuais da estrutura. Para ambas soluções é fundamental o conhecimento da estatística das incertezas associadas às medições realizadas comumente através de sinais acústicos. Ao encontro da primeira abordagem, o problema de localização de veículos subaquáticos é analisado em [Caiti et al. 2002, Caiti et al. 2005] através da abordagem *Set Membership*. Nesse caso, o algoritmo assume que as medições do tempo de chegada são corrompidas por erros de valores desconhecidos porém limitados com propriedades estatísticas desconhecidas. Como resultado, obtém-se um conjunto de posições admissíveis para os AUV em um espaço tridimensional.

Seguindo uma filosofia diferente, encontram-se os trabalhos que exploram os modelos de propagação da energia acústica ao longo do canal [Jensen et al. 2011]. Essas técnicas são herdadas principalmente dos estudos sísmicos para localização do epicentro do fenômeno. Em [Rakotonarivo e Kuperman 2012], por exemplo, realiza-se a localização de uma fonte acústica móvel sabendo-se que a diferença entre os campos acústicos a duas distâncias distintas contém informação sobre o deslocamento da fonte emissora. Ainda utilizando modelos de propagação e dado que as condições de propagação no canal são conhecidas, em [Jesus et al. 2000], assume-se que a pressão acústica é resultado de uma combinação linear de sinais atenuados, atrasados e descorrelacionados para determinar a posição da fonte emissora através do casamento entre o campo medido e o campo modelado utilizando traçamento de raios [Rodríguez 2008]. Apesar do pioneirismo dessas pesquisas, problemas como a necessidade de uma boa amostragem espacial do canal somada ao conhecimento razoavelmente preciso sobre as características desse canal tornam a solução ainda limitada para aplicações em robótica. Embora sejam pouco exploradas nessa área, essas soluções apresentam perspectivas promissoras, tendo em vista que são adequadas para distâncias da ordem de *km*, além de não necessitar de qualquer sincronismo de relógio entre veículo e faróis acústicos. Outra vantagem está em não apresentar qualquer problema quanto à sobreposição dos sinais acústicos, desde que isso esteja previsto no

próprio modelo a ser comparado com a pressão medida.

Numa linha mais heurística estão os resultados apresentados em [Lee et al. 2009, Lee, Ou e Huang 2009, Lee, Ou e Wang 2009]. A solução proposta refere-se ao levantamento de um mapa acústico do ambiente para ser utilizado posteriormente num esquema de predição. Desse modo, um determinado número de fontes acústicas, localizadas em pontos conhecidos, emitem sinal para o receptor que visita diversos pontos da área a ser explorada. Partindo de uma taxa de amostragem, são armazenadas amostras de sinal provenientes de cada fonte acústica. Após essa etapa, considerada de treinamento, o mapa acústico formado consistirá de uma matriz com dados relativos a essas medições nos pontos de análise. De modo a reduzir a quantidade de informação dentro dessa matriz e assim adquirir um certo grau de generalização, os dados são processados via Análise de Componente Principal (PCA), gerando uma matriz resultante com dimensão menor. Desse modo, ao posicionar o receptor em um local desconhecido e coletar novos sinais dos emissores, projeta-se essa informação no espaço definido pela matriz obtida no treinamento. Por fim, com base nas distâncias, onde foram coletadas amostras de sinais durante a etapa de treinamento descrita, calcula-se a função de probabilidade de ocorrência de uma determinada distância dado que determinada medição ocorreu. Ou seja, a distância atual será dada por uma média ponderada das distâncias medidas durante a etapa de treinamento.

Dentro de um viés mais clássico, considera-se que o veículo conhece, previamente ao início da navegação, a posição absoluta dos faróis acústicos, os quais devem emitir sinais específicos ao veículo sempre que requisitados, obedecendo um esquema de *interrogação-resposta*. Dentre as diversas configurações existentes estão os agregados de sensores de base ultra-curta (USBL - *Ultra Short Base Line*), os de base curta (SBL - *Short Base Line*) e os de base longa (LBL - *Long Base Line*) [Milne 1983], todos mostradas na figura 2. O LBL ganha especial destaque quando a área de exploração por parte do veículo é considerada extensa. Nesse caso, esses faróis acústicos são posicionados em locais fixos ou mesmo móveis em outras plataformas robóticas [Vaganay et al. 2004] de onde é possível o veículo obter sua posição relativa e conseqüentemente sua posição absoluta em relação a um referencial inercial. Nos casos em que os emissores são móveis, pode-se destacar as pesquisas voltadas à navegação cooperativa, como exemplo o sistema LBL adaptado mostrado em [Atwood et al. 1995], onde os cada AUV emite uma interrogação em intervalos de tempos programados atendendo a um esquema mestre - escavo. Inicialmente, na configuração LBL utilizavam-se emissores acústicos instalados no leito das áreas de exploração. Apesar de algumas vantagens com relação à proximidade entre veículo e localizadores a maiores profundidades, a solução é pouco flexível e tem sido substituída por boias

inteligentes equipadas com GPS [Jesus et al. 2006].

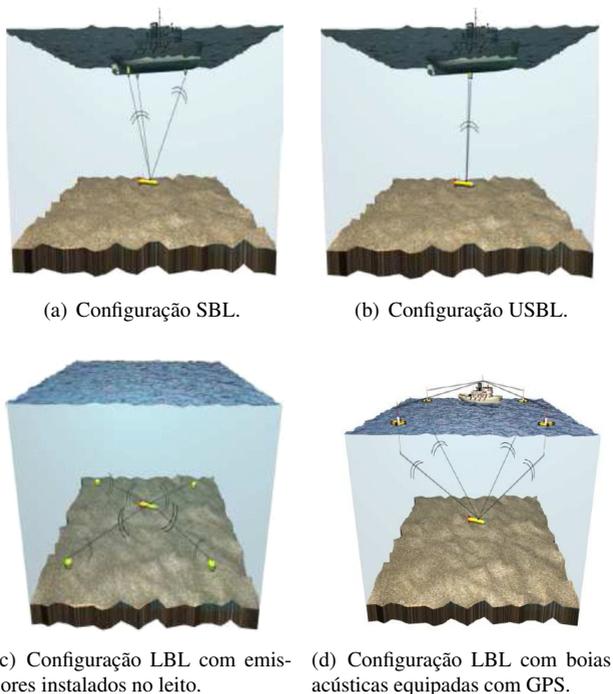


Figura 2: Configurações clássicas para o sistema de localização acústico [Jesus et al. 2006].

Apesar da configuração relativamente simples e, nos dias atuais, um relativo baixo custo para aquisição de equipamentos, os sistemas de localização acústicos apresentam problemas extremamente desafiadores do ponto de vista da precisão da medição do tempo de chegada da onda sonora e consequentemente no cálculo da distância percorrida pela onda a partir desses valores. A literatura específica enumera os diversos fatores que dificultam o estabelecimento de uma comunicação confiável entre emissor e receptor, de modo a garantir com precisão o tempo exato de chegada da onda emitida [Medwin e Clay 1997]. Estudos realizados em águas rasas [Yang 2011, Preisig 2007] confirmam que o meio acústico caracteriza-se por ser um canal atenuador da onda sonora, além de apresentar oscilações em sua resposta impulsiva dentro de intervalos de *ms*. Nesse sentido, a relação sinal/ruído (SNR) do guia de onda é fundamental para a detectibilidade da chegada do sinal e a confi-

abilidade dessa medição. Quando essa relação está em níveis satisfatórios a comunicação é dita estar num estado coerente, ou seja, é possível discernir o tempo de chegada da onda em caminho direto e as provenientes de caminhos alternativos. Entretanto, quando essa relação cai abaixo de um determinado nível, a determinação do tempo de chegada pelos filtros de estimação convencionais torna-se bastante imprecisa, caracterizando a comunicação como não coerente.

Na configuração *interrogação-resposta*, assim como a precisão quanto ao tempo de chegada da onda, é imperativo conhecer a velocidade do som no canal a fim de calcular corretamente a distância percorrida pela onda entre emissor e receptor. Por vezes, a variável velocidade do som é inserida no próprio filtro de fusão sensorial, que estima os estados do veículo a partir de informações de diferentes sensores, ou é localmente medida com sensores que medem condutividade, temperatura e pressão na posição onde se encontra o veículo [Miller, Farrell e Djapic 2010]. Não obstante possa apresentar grandes flutuações ao longo do canal, para distâncias médias (100 – 200m) e águas rasas (10 – 20m), a velocidade do som pode ser assumida constante sem maiores desvios quanto à estimação da distância percorrida pelo som. Diante desse cenário, o foco da pesquisa desenvolvida está contextualizada nos sistemas de localização LBL seguindo o modelo apresentado na figura 2(d), onde boias, dotadas de um sistema de posicionamento global, atendem às requisições provenientes do veículo emitindo um sinal acústico. Como será visto, a abordagem explorada nesse trabalho dispõe de técnicas de mapeamento autoassociativos para levantamento de uma função de regressão a fim de corrigir eventuais desvios no tempo estimado de chegada da onda por razões como: múltiplos caminhos percorridos pela onda e baixa relação sinal ruído entre outras. Além disso, por tratar-se de um meio predominantemente não-estacionário, pelas razões discutidas anteriormente, faz-se ainda necessário avaliar a validade de cada medição antes de enviá-la para o filtro de estimação de estados do veículo durante a navegação. Com esse intuito, esse trabalho traz uma abordagem inovadora quanto à utilização de modelos empíricos baseados em funções kernel para navegação, cujas bases teóricas estão fundamentadas pela teoria de aprendizagem estatística, a fim de classificar e melhorar as medições de tempo de chegada da onda sonora. Por definição, um kernel é uma função que retorna o produto escalar das imagens de seus argumentos, ou seja, os dados de entrada são mapeados para um dimensão mais elevada ou espaço de características, onde a saída da função kernel responderá ao produto escalar entre os elementos.

A teoria de aprendizagem estatística [Vapnik 1995, Vapnik 1999] vem avançando significativamente nas últimas décadas tanto para aplicações de classificação quanto para regressão com as funções polinomiais, redes bayesi-

anas [Margaritis 2003], redes neurais probabilísticas [Specht 1988] e as redes de funções de base radial [Scholkopf et al. 1997]. Essa expansão não se dá somente pela penetração nas mais diversas áreas do conhecimento, mas também nas técnicas de implementação dos algoritmos e associação de dados que visam à redução do tempo de treinamento e posterior predição. Em particular, os algoritmos baseados em funções Kernel como as Máquinas de Vetores Suportes ou SVM (*Support Vector Machines*), Processos Gaussianos e Redes Neurais Genéricas proveem soluções flexíveis e adaptáveis a diversos tipos de problemas [Schölkopf e Smola 2002]. As Máquinas de Vetores Suportes, por exemplo, surgiram no começo da década de 90 como uma abordagem inovadora à solução de problemas de classificação e regressão não lineares. Recentemente, as SVM têm encontrado aplicações em processamento de antenas, onde envolvem a determinação da direção de propagação da onda, ângulo de chegada e detecção de objetos [Martínez-Ramón, Xu e Christodoulou 2007]. Nas aplicações subaquáticas, modelos de regressão foram utilizados para correção do tempo de chegada da onda sonora em situações onde a relação sinal/ruído é reduzida [Apartsin, Cooper e Intrator 2012]. Nesse caso, o modelo de regressão melhorou o desempenho do filtro casado (MF - *Matched Filter*) no contexto de estimação do tempo de chegada quando o receptor encontra-se num estado dito semi-coerente. As redes de funções de base radial são utilizadas em [Caiti e Jesus 1996] para estimação de parâmetros de ambiente. Nesse estudo, modelos de propagação são utilizados para treinar a rede com base no campo acústico gerado em função da variabilidade de parâmetros de ambiente. Em se tratando de processos não estacionários, em [Yee e Haykin 1995] são utilizadas as funções de base radial regularizadas que são dinamicamente adaptadas para realizar predição de um processo não linear autoregressivo.

## 1.2 OBJETIVOS DA TESE

Face ao que foi exposto, o objetivo desse trabalho é propor um algoritmo que melhore a confiabilidade do sistema de localização de veículos autônomos subaquáticos que se utilizam da configuração clássica LBL para explorar extensas áreas, como lagos de barragens, onde o veículo autônomo costuma processar repetidas missões ao longo do tempo. Na abordagem apresentada nessa pesquisa, os faróis acústicos são considerados fixos e com suas posições absolutas conhecidas.

Avaliar-se-á a utilização de modelos de regressão baseados em funções kernel em conjunto com modelos empíricos, dedicados a identificar medições errôneas, objetivando melhorar as estimativas de tempo de chegada da onda

sonora a serem utilizadas pelo algoritmo de fusão de dados. O motivo para utilização de tal abordagem justifica-se pelo fato do veículo dispor de pouca informação sobre as condições de propagação da onda sonora, sobre a relação sinal/ruído, sobre o sincronismo dos relógios veículo/boia. O problema agrava-se devido às limitações de processamento existentes nessas plataformas, principalmente devido à influência na autonomia. Desse modo, soluções rápidas e com respostas satisfatórias, que trazem pouquíssimo impacto aos algoritmos classicamente utilizados para a navegação, possuem grande apelo por parte dos desenvolvedores dessas plataformas. Para avaliar o algoritmo proposto, algumas métricas serão utilizadas a fim de confirmar a melhoria no desempenho da navegação em comparação com uma solução clássica comumente utilizada em navegação autônoma subaquática.

### 1.3 OBJETIVOS ESPECÍFICOS

Com base no escopo teórico proposto, alguns objetivos específicos foram delineados para a realização desse trabalho a fim de atingir seu propósito final. São eles:

- Modelar a propagação de ondas sonoras em meios aquáticos, sobretudo os modelos de propagação da energia acústica, a influência do meio ambiente, os métodos para detecção da chegada do sinal e os impactos disso no sistema de localização;
- Compreensão acerca dos filtros de estimação utilizados em veículos autônomos, enfatizando sua formulação, vantagens e limitações. Avaliação quanto às especificações técnicas, modelagem e desempenho dos sensores comumente embarcados nessas plataformas, além de sua integração com o sistema inercial;
- Proposição de modelos baseados em funções kernel que visam classificar os dados quanto a sua qualidade e a corrigir medições com base num histórico.
- Definição do algoritmo a ser utilizado pelo sistema de navegação de modo a extrair as vantagens adquiridas com a solução proposta.
- Captação de dados em campo, utilizando veículos autônomos comerciais, a fim de validar a solução proposta e avaliar quantitativamente e qualitativamente seu desempenho.

Ao longo do trabalho, os tópicos supracitados serão abordados separadamente e, através de simulações, será possível compreender a influência

das fontes de erros no sistema de navegação e quais os ganhos trazidos com a utilização dos algoritmos propostos. Em um segundo momento, toda a estrutura da solução será apresentada, onde serão ressaltadas as funções exercidas por cada bloco e as informações trocadas entre eles. Por fim, os blocos serão agrupados e, com a utilização de dados experimentais, a solução será avaliada tendo como referência o desempenho do atual sistema de navegação.

#### 1.4 CONTRIBUIÇÕES DA TESE

As principais contribuições desta tese estão diretamente associadas com a introdução de uma nova estratégia para o sistema de localização acústico onde o histórico de medições é aproveitado para assistir o algoritmo de fusão de dados tanto na classificação quanto na correção das medições do tempo de chegada da onda sonora. A ideia do trabalho compreende a integração dos três conceitos mostrados na figura 3.



Figura 3: Contribuição do trabalho - integração dos três tópicos de pesquisa com foco na localização acústica utilizando a configuração LBL.

Um experimento, utilizando a configuração LBL, foi realizado para avaliar o desempenho do sistema proposto a partir de medições realizadas em campo a fim de quantificar e qualificar os resultados. Detalhadamente, as contribuições do trabalho podem ser listadas como segue:

- Uma arquitetura para o sistema de localização acústico aplicado à navegação de veículos autônomos subaquáticos.
- Integração entre o conjunto: sistema de navegação inercial, fusão de dados, sensores acústicos e modelagem heurística.

- Nova estratégia para o aproveitamento de um histórico de medições do tempo de chegada do sinal acústico para fins de correção das medições subsequentes.
- Nova estratégia para identificar medições errôneas e classificá-las de acordo com o banco de dados disponível.

## 1.5 ORGANIZAÇÃO DO TEXTO

Esta tese está dividida em oito capítulos, incluindo esta introdução. O restante deste documento está organizado da seguinte maneira:

O Capítulo 2 descreve a arquitetura do sistema de localização acústico utilizando a configuração LBL proposta nesse trabalho. A ênfase é fornecer uma visão geral de como os conceitos mostrados na fig. 3 interagem e o fluxo de informações entre os blocos que compõem o sistema.

No Capítulo 3 são apresentadas as fundamentações teóricas dos modelos autoassociativos baseado em funções Kernel (AAKR - *AutoAssociative Kernel Regression*) e descritor de dados a partir de vetores suporte (SVDD - *Support Vector Data Description*), ambos utilizados na sequência do trabalho no modelo de navegação proposto.

Na sequência, o Capítulo 4 apresenta alguns fundamentos matemáticos relacionados ao estudo de robótica subaquática, como os conceitos sobre sistemas de referências e equações de navegação inercial.

No Capítulo 5, os principais sensores utilizados nos veículos subaquáticos, a formulação das equações de estado e o filtro de Kalman estendido (EKF), utilizado na estimação de estados, são então apresentados e destacadas sua relevância, características e limitações.

No Capítulo 6, a proposta do trabalho é apresentada, ressaltando o sistema de navegação com os módulos de detecção de medições errôneas e correção de desvios. Um pseudo-código é apresentado, onde é possível compreender como integrar com os módulos comumente utilizados em sistemas de navegação subaquática e os propostos nesse trabalho.

No Capítulo 7 são trazidos alguns exemplos reais de navegação de veículos com medições realizadas em campo. Com esses exemplos, aplica-se então o modelo de navegação proposto nesse trabalho, de modo a avaliar suas melhorias e vantagens.

Por fim, o Capítulo 8 apresenta as conclusões e introduz os possíveis desdobramentos sobre esta tese na forma de trabalhos relacionados.

## 2 DESCRIÇÃO DO SISTEMA DE NAVEGAÇÃO

### 2.1 INTRODUÇÃO

Nesse capítulo, descreve-se a proposta de arquitetura para o sistema de localização acústico utilizando a configuração LBL. É dado destaque principalmente ao fluxo e às características das informações trocadas entre blocos que compõem o sistema e que foram brevemente introduzidos no capítulo anterior. O propósito é trazer uma visão geral de como os três tópicos: estimação/filtragem, correção e classificação, mencionados anteriormente, integram de modo a melhorar a precisão das estimativas de posição do veículo. Desse modo, os diagramas mostrados ao longo do capítulo trazem à luz os detalhes das etapas que definem a arquitetura. Além disso, a fim de contextualizar o esquema proposto, o capítulo também discorre sobre as dificuldades associadas à propagação da onda sonora em meio subaquático e sobre o algoritmo para determinar os tempos de chegada do sinal.

### 2.2 SISTEMA INERCIAL

O objetivo do sistema de navegação é permitir que um veículo desloque-se entre um ponto inicial e um final com a melhor precisão possível. Para tanto, um conjunto de sensores embarcados na plataforma realizam medições de grandezas que estão relacionadas aos estados do veículo como posição, velocidade e orientação. Dois blocos fundamentais para esse sistema são: a unidade de medição inercial (IMU) e o sistema de navegação inercial (INS), mostrados na figura 4.

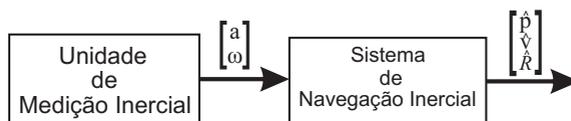


Figura 4: Blocos que compõem o sistema de navegação inercial.

A informações provenientes da unidade inercial referentes à aceleração  $a$  e deslocamento angular  $\omega$  são tratadas nos algoritmos do sistema de navegação inercial para obtenção das estimativas de velocidade, posição e orientação. Nesse último bloco, o processo de estimação ocorre em duas etapas: estabilização da orientação e integração da aceleração e velocidade.

Assim, qualquer informação referente aos ângulos de Euler ou taxa de variação angular são incorporados pelo INS para estimação da orientação do veículo, indicada na figura 4 pela matriz de rotação  $\hat{R}$ . Após a estabilização dessas grandezas, dos valores de aceleração obtém-se então a estimativas de velocidade  $\hat{v}$  e posição  $\hat{p}$  do veículo, ambas em três dimensões [Paull et al. 2014]. O desempenho do sistema de navegação inercial está amplamente relacionado à qualidade dos sensores que compõem o bloco IMU e estes são, em geral, de custo elevado. Apesar de fundamentais, o sensoriamento inercial sofre com um desvio ilimitado ao longo do tempo, apresentando erros da ordem de 0.1% da distância percorrida para os sensores mais caros e erros entre 2% e 5% para os mais acessíveis [Fallon et al. 2011]. De modo a evitar que o erro cumulativo inerente a esses sensores inviabilize a navegação autônoma, é utilizado um conjunto de sensores auxiliares e algoritmos de fusão de dados, que melhoram as estimativas iniciais do sistema de navegação inercial. Essa configuração denomina-se navegação assistida.

### 2.3 NAVEGAÇÃO ASSISTIDA POR SENSORIAMENTO EXTERNO

Numa arquitetura de navegação assistida, a estimação de estados é realizada com auxílio dos mais diversos sensores que realizam medições de grandezas como profundidade, distância relativa, velocidade da plataforma em relação ao leito e à água [Lee et al. 2004], velocidade do som, orientação e ainda imagens através de sonares e câmeras [Kazmi P. Ridao 2009, Vasconcelos et al. 2007]. O algoritmo de fusão de dados é o responsável por extrair informações dos sensores e melhorar as estimativas iniciais provenientes dos sistema inercial. Na figura 5, o vetor de estados do veículo estimados a partir da unidade de medição inercial são entradas no filtro de Kalman estendido.

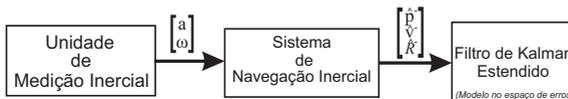


Figura 5: Sistema de navegação. Agrupamento da unidade de medições inerciais e do algoritmo de fusão de dados.

Desse modo, o vetor  $\hat{\mathbf{x}}^- = [\hat{\mathbf{p}}^- \ \hat{\mathbf{v}}^- \ \hat{\mathbf{R}}^-]'$  corresponde à estimativa iniciais (*a priori*) das grandezas envolvidas, sendo necessárias informações adicionais, providas pelo sensoriamento externo, para melhorias dessas estimativas iniciais. A figura 6 ressalta essa configuração, destacando que após as devidas correções com as quantidades  $\delta \mathbf{x} = [\delta \hat{\mathbf{p}} \ \delta \hat{\mathbf{v}} \ \delta \hat{\mathbf{R}}]'$ , o vetor de saída

corresponde às estimativas posteriores (*a posteriori*) das grandezas envolvidas. Na figura, o vetor  $\delta \hat{\mathbf{b}} = [\delta \hat{\mathbf{b}}_a \quad \delta \hat{\mathbf{b}}_\omega]'$ , são as estimativas de correções dos desvios de medição presentes na saída do acelerômetro e do giroscópio.

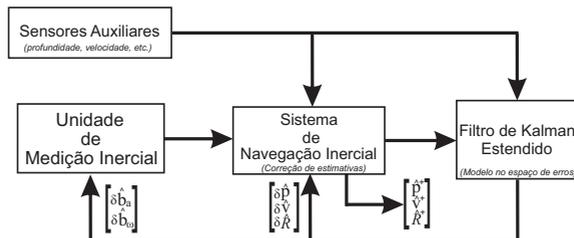


Figura 6: Sistema de navegação. Agrupamento da unidade de medições inerciais, do algoritmo de fusão de dados e o auxílio de sensores externos.

Fica claro, pelo exposto, que na ausência de dados provenientes dos sensores externos, o veículo navega somente com a informação da unidade inercial, que está sujeita a desvios ilimitados. A figura 7 resume a configuração do sistema de navegação, agrupando o sistema inercial com o algoritmo de fusão de dados representado pelo EKF e destacando os sinais de entrada e saída de cada bloco.

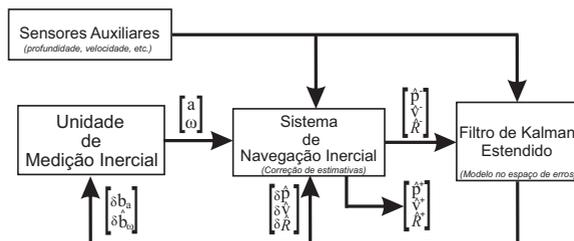


Figura 7: Representação completa de sistema de navegação auxiliado por sensores externos.

Como mostrado, tanto o algoritmo de fusão de dados realizado pelo EKF quanto o sistema inercial beneficiam-se das informações provenientes dos sensores auxiliares para melhorar suas estimativas em relação aos estados do veículo. Para o INS, qualquer informação adicional relativa aos ângulos de Euler, através de magnetômetros ou bússolas, ou às taxas de variação angular são utilizadas, em muitos casos, por um algoritmo de fusão de dados interno para melhorar a estimativa de orientação do veículo antes de estimar velocidade e posição.

O filtro de Kalman mostrado está formulado no espaço de erros, ou seja, as variáveis de estado são definidas como incrementos às grandezas associadas. Além disso, as variáveis que representam os desvios nos sensores inerciais, modeladas com *random walk*, são também inseridas no vetor de espaço de estados a fim de serem estimadas e compensadas. Uma discussão mais detalhada sobre essa formulação será apresentada em capítulos posteriores podendo ser encontrada em [Lee et al. 2007, Miller, Farrell e Djapic 2010, Morgado et al. 2006]. No esquema mostrado na figura 5, fica claro que os valores de saída do bloco IMU/INS inseridos no EKF correspondem às estimativas iniciais das grandezas posição, velocidade e orientação, enquanto as saídas do bloco INS correspondem aos valores já corrigidos pelas quantidades que foram encontradas com o EKF após medições externas.

Com vistas ao que foi exposto, fica evidente a relevância do sensoriamento externo no processo de navegação de uma plataforma robótica e em particular o sistema de localização acústico, que será abordado na sequência.

## 2.4 NAVEGAÇÃO ASSISTIDA POR SISTEMA DE LOCALIZAÇÃO ACÚSTICO

A navegação assistida por sensoriamento acústico para fins de localização está esquematizada na figura 8, onde o tempo de chegada da onda sonora determina a posição relativa do veículo em relação aos emissores. Estando os últimos em locais conhecidos, é possível determinar a posição do veículo em relação a um referencial inercial. Como já introduzido no capítulo 1, várias configurações podem ser utilizadas para realizar a localização com os sistemas acústicos. A variedade pode estar no número de emissores e na sua localização como instalados em boias [Jesus et al. 2006, Caiti et al. 2005], no leito do oceano ou em veículos de superfície que acompanham a plataforma submersa [Fallon, Papadopoulos e Leonard 2010]. O modelo de medição mostrado corresponde à expressão analítica que estima o tempo de chegada da onda sonora considerando o tempo de ida até as boias e a volta até o veículo. Para esse cálculo são necessárias informações sobre a posição estimada do veículo  $\hat{\mathbf{p}}^-$  e a posição das boias  $\mathbf{P}$ , ambas em relação a um referencial comum. As informações de saída do bloco do sistema de localização acústico correspondem aos resíduos de medição, que serão discutidos na sequência.

Para além dos problemas relativos aos ruídos presentes nessas medição, a localização através de ondas sonoras sofre influência do canal de comunicação devido às mudanças de propriedades da água, materiais em suspensão, ondas, chuva etc. [Medwin e Clay 1997]. De modo geral, um momento de ini-

cialização é fundamental para a calibração do sistema, onde a velocidade do som na água é estimada e ajustes quanto à melhor disposição dos emissores são realizados [IMCA 2009].

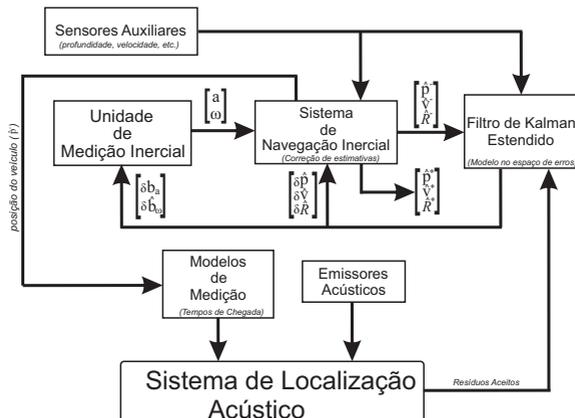


Figura 8: Sistema de navegação com auxílio do sistema de localização acústico.

De modo a entender os problemas enfrentados por esse tipo de medição, as seções seguintes tratam do problema de propagação da onda sonora em meio subaquático e a influência na determinação do tempo de chegada dessa onda.

### 2.4.1 Canal de Comunicação

Apesar de fundamental para a localização de AUV, o sistema de localização acústico sofre influências negativas do canal de comunicação. Os limites da coluna d'água - superfície e leito - exercem influência na propagação da energia acústica através das ações de reflexão, dispersão e absorção. A simples presença de bolhas de ar, por exemplo, produzidas por diversas fontes como o próprio deslocamento do veículo aquático ou a presença de matéria orgânica em suspensão formam uma camada heterogênea que altera drasticamente as características de propagação acústica do meio como [Medwin e Clay 1997]:

- Atenuação adicional ao ambiente aquático, resultando em absorção da energia do sinal e mascaramento dos equipamentos de recepção;
- Modificação local da velocidade do som, incluindo refração;

- Reflexões parasitas.

A região do leito representa um local de reflexão e de dispersão da onda, possuindo diferentes características em virtude de sua composição ser geralmente em camadas. Os principais efeitos que o leito pode provocar na propagação da onda sonora são:

- Perda de energia durante a reflexão da onda;
- Desvios na direção de propagação da onda;
- Atenuações por sedimentos;
- Geração de ruído em baixas frequências devido a atividades sísmicas.

Somam-se a isso, os ruídos de ambiente que prevalecem ou são particulares em determinadas localizações e em determinados momentos ao longo do tempo. Além desses, incluem-se os sons transientes, que ocorrem devido a circunstâncias pontuais como presença de animais, passagem de navios ou barcos. Ou seja, o ruído de ambiente corresponde aos níveis de sons residuais quando excluídas todas as outras fontes identificáveis [Medwin e Clay 1997, Etter 2003]. Apesar de muitos trabalhos assumirem o ruído em canais subaquáticos de comunicação como sendo Gaussiano, há algum tempo isso é conhecido como incorreto, sendo porém difícil determinar o espectro de frequências existentes em ruídos provenientes de ondas, de turbulências e o ruído térmico [Coates 1990].

No caso de chuvas, por exemplo, experimentos mostram que a faixa de frequência do ruído concentra-se em torno de  $15\text{KHz}$ , próximo à frequência de operação de equipamentos utilizados em sistemas de localização, e está diretamente relacionada ao impacto da gota d'água com a superfície aquática e a respectiva ressonância com as bolhas de ar.

Outra fonte de incertezas com relação às predições do tempo de chegada da onda sonora é a variação da velocidade do som ao longo da coluna d'água. O som é uma onda mecânica que viaja através de um meio pela oscilação de suas partículas e, na água, propaga-se como uma onda longitudinal (pressão), alternando compressão e rarefação [Medwin e Clay 1997, Etter 2003, Jensen et al. 2011]. Em ambientes de água salgada, por exemplo, à  $25^{\circ}\text{C}$  e profundidade de  $1\text{m}$ , a velocidade do som  $c$  é aproximadamente  $1.532\text{m/s}$ . Dentre os fatores que impactam no valor da velocidade do som destacam-se a temperatura ( $^{\circ}\text{C}$ ), a salinidade (ppt) e a profundidade (m). Em [Fofonoff e Millard 1983] são detalhados os efeitos na velocidade do som em razão das variações nesses parâmetros.

Em se tratando de canal subaquático, dificilmente haverá características típicas que possam ser replicadas para vários ambientes. As flutuações

no canal podem ocorrer dentro de um intervalo de  $ms$ , alterando significativamente suas propriedades (*coherent time*) [Preisig 2007]. Em águas rasas, para profundidades de até  $100m$  há uma predominância de propagação em múltiplos caminhos devido às transmissões omnidirecionais da maioria dos emissores acústicos. Além disso, a proximidade da superfície pode resultar em uma redução da relação sinal ruído (SNR) pela combinação da presença de sinais externos com a própria atenuação do sinal acústico em meio aquático. Quando o SNR está abaixo de um determinado limiar, a determinação exata do tempo de chegada da onda sonora torna-se inviável [Apartsin, Cooper e Intrator 2010].

## 2.4.2 Processamento do Sinal Acústico

A questão central dos sistemas de localização acústico é a determinação do tempo de chegada da onda sonora nos receptores instalados no veículo. Muitas pesquisas têm concentrado esforços na melhoria da estimação dessa variável tanto do ponto de vista do tipo de sinal emitido e o projeto de equalizadores, quanto dos receptores através da tecnologia e disposição dos receptores [Freitag et al. 2001, Bingham, Blair e Mindell 2007, Morgado 2011, Coates 1991].

O método clássico para a determinação do tempo de chegada da onda sonora emprega um filtro casado (MF) [Papoulis 1991, Kay 1998] para determinar o estimador de máxima verossimilhança (MLE). O filtro adaptado maximiza a relação sinal ruído da onda emitida na presença de um ruído aditivo, sendo o método mais clássico para detectar uma onda conhecida na presença de ruído. Entretanto, principalmente em situações onde sinais de banda curta são utilizados, a precisão do MLE é deteriorada quando a potência do ruído no receptor ultrapassa um certo limiar. Para compreender melhor essa ideia, considere um sinal real qualquer  $p(t)$  de comprimento  $T$ , onde  $p(t) = 0, \forall t \in [0, T]$ , e corrompido por um ruído aditivo assumido branco e Gaussiano conforme figura 9.

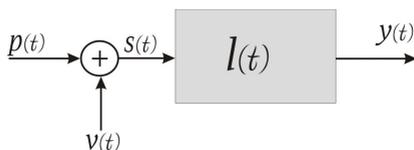


Figura 9: Estrutura de processamento de sinal acústico para determinação do tempo de chegada da onda.

A saída  $y(t)$  do filtro casado  $l(t)$  corresponde à correlação entre o sinal emitido, conhecido, e o sinal recebido adicionando o ruído  $v(t)$ . Como exemplo, supõe-se que a onda sinusoidal mostrada na figura 10 representa um sinal acústico emitido para fins de localização de AUV com a frequência em  $10\text{Hz}$  e duração de  $1\text{s}$ .

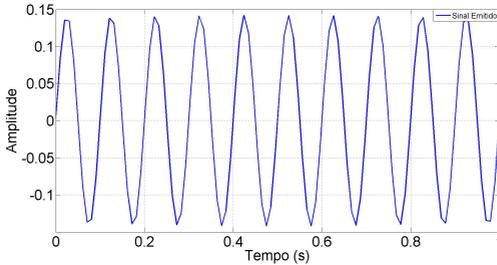


Figura 10: Exemplo de onda sinusoidal em  $10\text{Hz}$  para localização de um AUV.

A figura 11 mostra a saída do filtro casado considerando uma relação sinal ruído da ordem de  $10\text{ dB}$  e um tempo de *interrogação-resposta* em  $500\text{ ms}$ . O tempo de chegada é determinado subtraindo a duração do sinal emitido, considerada conhecida, do instante de máximo do sinal de saída do filtro.

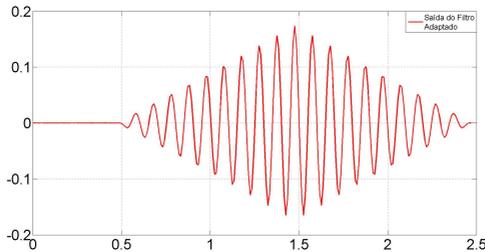


Figura 11: Saída do filtro casado para determinação do tempo de chegada da onda.

Portanto, nesse exemplo, após a emissão do sinal de requisição de duração de  $1\text{seg}$ , correspondendo ao instante  $t = 0$ , verifica-se um pico da correlação entre o sinal emitido e o recebido em  $t = 1.5\text{s}$ , de onde se conclui que o tempo de viagem da onda foi de  $500\text{ms}$ . Considerando agora uma significativa queda na relação sinal ruído para um valor de  $-50\text{ dB}$ , vê-se

claramente, pela saída do filtro mostrado na figura 12, a impossibilidade de determinar corretamente o tempo de chegada da onda.

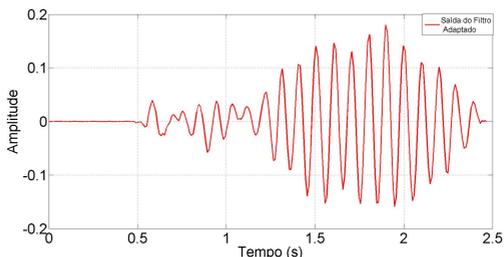


Figura 12: Saída do filtro casado considerando uma relação sinal ruído de  $-50\text{ dB}$ .

Dentre as possibilidades de alteração do sinal emitido, a fim de mitigar os efeitos de uma baixa relação sinal ruído, está o espalhamento espectral, ou seja, a distribuição da energia do sinal em uma faixa maior de frequências. Considere o sinal modulado mostrado na figura 13 como sendo o sinal emitido, em substituição ao sinal da figura 10.

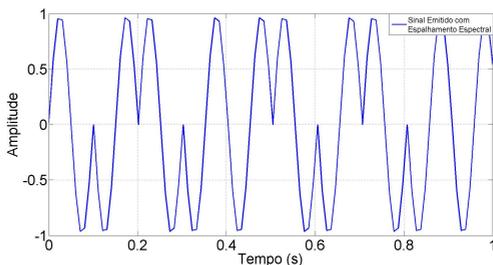


Figura 13: Exemplo de sinal modulado com deslocamento de fase por codificação binária.

A figura 14 mostra a saída do filtro casado mantendo a relação sinal ruído em  $-50\text{ dB}$ . Observa-se ainda ser possível determinar o instante de máximo do sinal de saída.

A análise precedente visa ressaltar a importância de métodos que minimizem as incertezas associadas à determinação exata do tempo de chegada da onda sonora em sistemas acústicos de localização. Somam-se ao que foi exposto, dentre outros fatores, a chegada de sinais através de múltiplos caminhos e as variações na velocidade do som ao longo da coluna d'água, o que

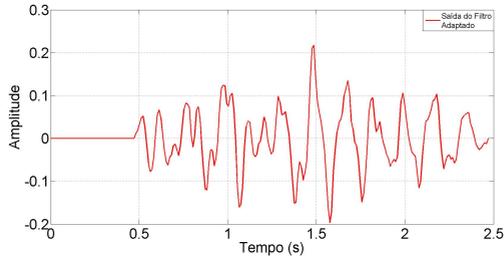


Figura 14: Saída do filtro casado considerando uma sinal emitido com espaçamento espectral considerando uma relação sinal ruído de  $-50\text{ dB}$ .

umenta as incertezas quanto ao tempo de chegada exato. Apesar de serem muito vantajosos, os sinais modulados exigem mais processamento e equipamentos com um custo mais elevado.

As secções subsequentes tratam especificamente da proposta desse trabalho, cujo objetivo é definir uma estratégia para reduzir a incerteza associada ao tempo de chegada da onda sonora. Vale observar que o método proposto não trabalha ao nível de processamento de sinal, como o caso do filtro casado, mas num instante posterior, onde procura melhorar as estimativas já realizadas quanto ao tempo de chegada.

### 2.4.3 Velocidade do Som e Reflexões Parasitas

A velocidade do som na água não é constante e depende de fatores como temperatura, salinidade e profundidade. Em [Fofonoff e Millard 1983] são detalhados os efeitos na velocidade do som em razão das variações nesses parâmetros. Basicamente dois efeitos são predominantes:

- Nas regiões com gradiente de velocidade negativo (*thermocline*), a velocidade do som decresce com a profundidade ocorrendo refração direcionada para baixo;
- Nas regiões com gradiente de velocidade positivo (*isothermal layer*), a velocidade do som cresce com a profundidade ocorrendo refração direcionada para cima.

Existem diversas formulações que buscam associar os parâmetro supracitados com a velocidade do som. Um dessas equações é conhecida como UNESCO-1983, onde a velocidade do som é expressa em termos da condu-

tividade elétrica, temperatura e pressão. Um exemplo de perfil de velocidade do som ao longo da coluna d'água está detalhado na figura 15.

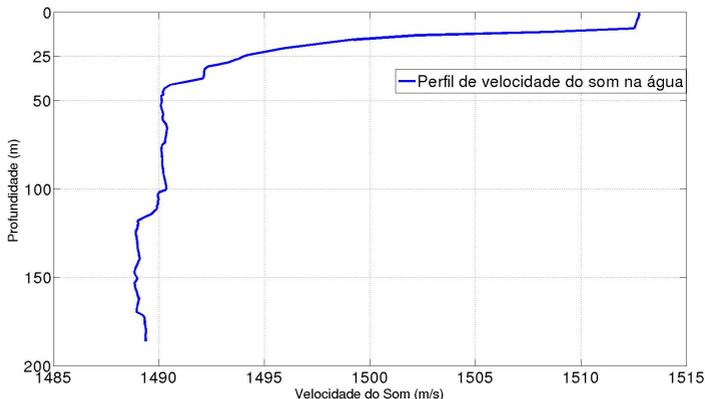


Figura 15: Perfil de velocidade do som ao longo da coluna d'água.

Além dos efeitos provocados pela mudança da velocidade do som na coluna d'água no tempos de chegada, o problema de reflexão e dispersão da onda sonora tanto na superfície quanto no leito representam significativas fontes de erro para determinação precisa dos tempos de chegada [Etter 2003]. Para situações onde a água está perfeitamente parada, a superfície age como um perfeito refletor da onda incidente devido ao descasamento de impedância entre a água e o ar. À medida que essa superfície torna-se mais irregular, com a presença de ondas, os efeitos de absorção de energia e dispersão da onda tornam-se mais acentuados.

A fim de avaliar alguns efeitos que o ambiente provoca na propagação da onda acústica, algumas ferramentas computacionais, permitem a visualização do comportamento dessa onda sob vários aspectos, conforme mostrado em [Rodríguez 2008], [Porter 1991]. Dentre os modelos utilizados está o traçamento de raios que, no contexto da acústica subaquática, é uma técnica computacional baseada na óptica geométrica, baseada no cálculo dos raios de propagação, perpendiculares às frentes de onda, e que podem ser usados para o cálculo do campo de pressão induzido na coluna de água pela presença de uma fonte acústica. A figura 16 mostra os raios de propagação da onda sonora adotando o perfil de velocidade mostrado na figura 15 e uma leve ondulação na superfície.

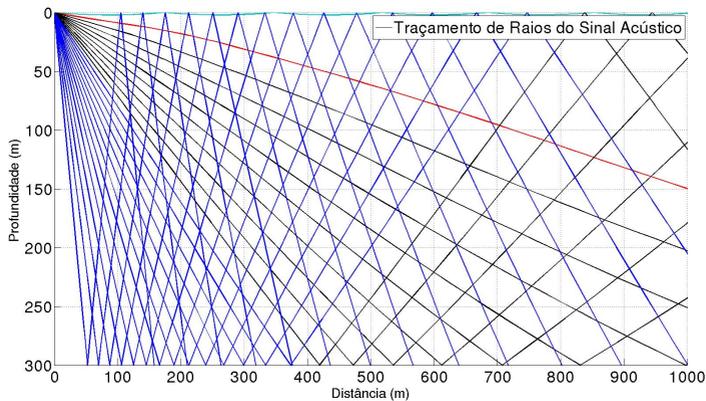


Figura 16: Traçamento de raios com o BELLHOP em ambiente com perfil de velocidade do som mostrado.

## 2.5 AVALIAÇÃO DE RESÍDUOS E MÓDULO DE REJEIÇÃO

Em navegação autônoma a redundância de informações advindas dos sensores é fundamental para as correções de estimativas dos estados do veículo. Entretanto, é necessário estabelecer critérios confiáveis antes de aceitar determinada medição, sob pena de distorcer as estimativas corrigidas de posição, velocidade e orientação. Assim, para poder avaliar uma quantidade medida, faz-se necessário estabelecer uma métrica que qualifique o que foi medido e separe as informações corretas das errôneas. Para esse propósito, o sistema proposto nesse trabalho tem, como um de seus núcleos, o bloco de avaliação de resíduos mostrado na figura 17. O resíduo é definido como a diferença entre o valor esperado de uma medição, com base um modelo matemático (modelo de medição), e o valor de saída do sensor ou valor medido. Com relação aos tempos de chegada da onda sonora do sistema LBL, o modelo de medição do tempo de chegada da onda sonora é função da posição estimada do veículo pelo sensor inercial  $\hat{\mathbf{p}}^-$ , da posição dos emissores, considerada fixa e conhecida, e da velocidade do som na água.

Uma vez calculado o resíduo, cabe ao bloco identificado como módulo de rejeição avaliar o grau de aceitação dessa medida com base num banco de dados construído previamente ou durante a navegação, a partir de medições assumidas como aceitas. Para essa análise, o algoritmo de rejeição utiliza um descritor de dados. Nesse trabalho, o descritor de dados será obtido a partir do algoritmo proposto em [Tax 2001], conhecido por SVDD (*Support Vector*

*Data Description*), a ser discutido posteriormente. Uma vez definido o descritor de dados, o objetivo é determinar a distância de um vetor de entrada com resíduos ao centro de uma região de fronteira definida. Caso essa distância seja menor que o raio, o vetor é considerado como aceito, do contrário, rejeitado.

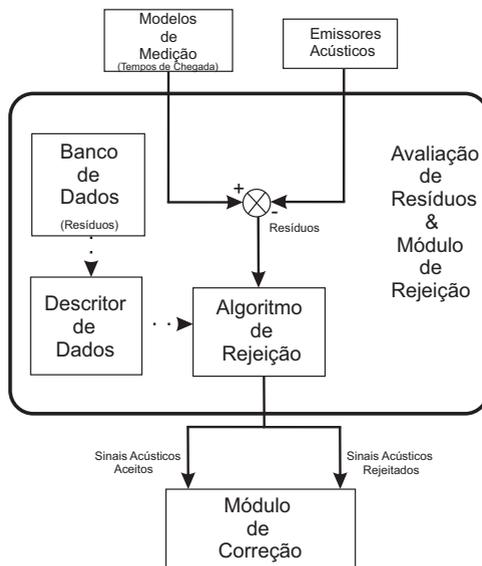


Figura 17: Detalhamento do sistema de localização acústico mostrado na figura 8. Em destaque, o módulo de avaliação de resíduos agrupado ao esquema de rejeição para fins de classificação das medições quanto à sua representatividade em relação ao banco de dados.

É importante ressaltar que a análise de rejeição poderá ser realizada em qualquer dimensão do vetor de resíduos, de modo a aproveitar o maior número de medições disponíveis no vetor com os tempos de chegada. Num caso extremo, por exemplo, poder-se-ia analisar cada medição individualmente a partir do descritor de dados.

Além de caracterizar a medição do tempo de chegada como aceito ou rejeitado, a informação da distância ao centro da região de fronteira, definida anteriormente, fornece uma ideia de quão representado pelo banco de dados está o vetor de entrada contendo os resíduos e por conseguinte os tempos de chegada. Essa informação é utilizada pelo algoritmo de correção para ajustar

seus parâmetros a fim de melhorar seu desempenho.

## 2.6 CORREÇÃO

O algoritmo de correção visa corrigir as medições atuais com base num banco de dados contendo tempos de chegada aceitos em missões anteriores ou na atual navegação. Para tanto, um modelo autoregressivo é utilizado e ajustado conforme a saída do descritor de dados anterior. Aqui, assim como na análise dos resíduos, a correção poderá ser realizada com qualquer dimensão do vetor de entrada a fim de anular o efeito de medições errôneas na correção das aceitas ou, para medições rejeitadas, ponderar todas as medições disponíveis. O algoritmo denominado AAKR (*Autoassociative Kernel Regression*), cujas bases teóricas serão apresentadas posteriormente, será utilizado nesse bloco de correção.

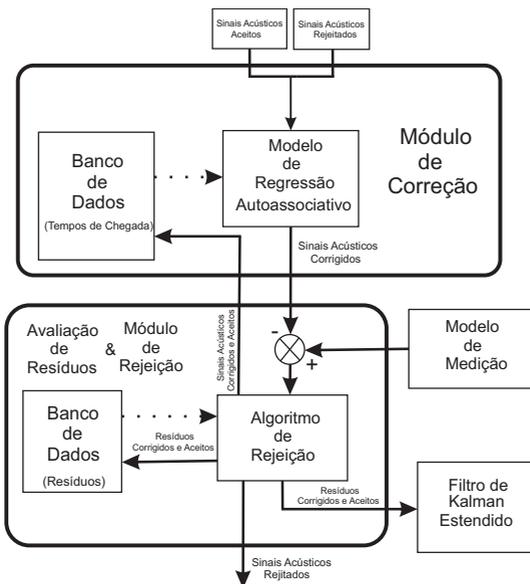


Figura 18: Detalhe do módulo de correção de medições mostrado na figura 17, agrupado à re-análise dos resíduos pelo esquema de rejeição para fins de aceite ou descarte dos tempos de chegada medidos.

Não obstante tenham passado pelo algoritmo de correção, faz-se necessário reavaliar os resíduos gerados a partir do tempos de chegada corrigi-

dos como mostrado na figura 18. Para o caso das medições aceitas ainda antes da correção, caso os resíduos gerados após a correção estejam a uma distância menor do centro da região de fronteira do que estavam antes da correção, estas serão enviadas para o EKF. Do contrário, são os resíduos gerados com as medições anteriores à correção que passarão para o filtro de estimação. Para aquelas medições rejeitadas inicialmente, caso gerem resíduos, após a correção, que estejam a uma distância menor que o raio calculado, estas também serão enviadas ao EKF. Caso contrário, serão simplesmente descartadas bem como os tempos de chegada associados.

Por fim, vale ressaltar que os bancos de dados contendo resíduos e tempo de chegada podem ser atualizados continuamente à medida que a navegação prossegue, o que permite compor essa base de dados com informações sobre o estado corrente do canal acústico.

## 2.7 CONCLUSÃO

O objetivo desse capítulo foi mostrar como os três tópicos fundamentais apresentados na figura 3 integram, a fim de melhorar a precisão das medições do tempo de chegada da onda sonora num sistema de localização com a configuração LBL. Uma visão geral sobre os três blocos principais foi discutida, incluindo alguns problemas relacionados ao processo de localização acústica.

A tríade formada pelos blocos de análise, correção e rejeição, em conjunto com o algoritmo de filtragem visa ser mais eficiente que os algoritmos convencionais para detecção de medições errôneas. O sistema busca, através das correções, aproveitar ao máximo as medições realizadas, evitando assim que o veículo navegue por longos períodos sem informações provenientes do sistema LBL, o que não ocorre com os métodos tradicionais.

Nos capítulos posteriores serão apresentados os aspectos teóricos de cada estrutura apresentada nesse capítulo e na sequência, o algoritmo completo será discutido juntamente os resultados utilizando dados obtidos em campo.



### 3 SISTEMA DE NAVEGAÇÃO

A navegação corresponde à determinação da posição, velocidade e orientação do veículo, em um determinado instante, em relação a um dado referencial. Para o estudo realizado ao longo desse trabalho, faz-se necessária uma descrição dos principais sistemas de coordenadas, da instrumentação comumente utilizada, seja ela para fornecer dados do próprio veículo (velocidade, ângulos de giro) ou informações provenientes do ambiente (câmeras, sensores hidroacústicos, sensores magnéticos etc.) e da configuração utilizada na navegação. Este capítulo, portanto, descreve essencialmente os principais aspectos relacionados ao estudo da navegação de robôs subaquáticos.

#### 3.1 SISTEMAS DE COORDENADAS

A definição de um sistema de coordenadas busca expressar as propriedades e fenômenos de interesse do sistema de um modo mais intuitivo. Para fins de navegação dos AUVs, por exemplo, posição e velocidade são tomadas em relação a um sistema de coordenadas de navegação (N) referenciado em relação ao sistema de coordenadas fixo à Terra (E), enquanto a força aplicada ao veículo devido aos propulsores pode ser considerada fixa em relação ao sistema de coordenadas do corpo (B). Os sistemas de coordenadas são ortogonais e seguem a regra da mão-direita.

##### 3.1.1 Sistema de Coordenadas Inercial

Um sistema de coordenadas onde as leis de Newton são válidas, em que a origem está em qualquer ponto que esteja desacelerado e cujas orientações dos eixos não sejam relevantes para a análise do problema, é dito inercial (I). Para análise das questões relativas à navegação, o sistema de coordenadas inercial possui a origem localizada no centro de massa da Terra e não possui rotação.

##### 3.1.2 Sistema de Coordenadas Fixo à Terra

Um sistema de coordenadas fixo à Terra (E) possui a origem localizada no centro de massa da Terra e a orientação dos eixos estão fixos em relação a mesma. Esse sistema de coordenadas é arranjado de modo a coincidir com



### 3.1.4 Sistema de Coordenadas Fixo ao Corpo

O sistema de coordenadas fixo ao corpo (B) consiste dos conhecidos eixos sobre os quais são efetuados os movimentos de rolagem (*roll*), arfagem (*pitch*) e guinada (*yaw*) e cuja origem encontra-se geralmente no centro de massa do veículo. A origem desse sistema de coordenadas não coincide necessariamente com a localização do sistema de navegação.

## 3.2 SISTEMA DE NAVEGAÇÃO INERCIAL

O problema da navegação consiste na determinação da posição, velocidade e orientação de um corpo rígido em relação a algum sistema de coordenada. De modo geral, um sistema de navegação inercial utiliza propriedades inerciais dos sensores embarcados no veículo para executar as funções de navegação. Para isso, processa dados provenientes de medições de forças e velocidade angular na IMU. Esse conjunto IMU/INS deve prover as seguintes funções:

1. Medições de um referencial: Essa função é realizada pelos giroscópios, que estão dispostos ao longo de três eixos ortogonais. Os giroscópios são corpos que apresentam características angulares vantajosas, de modo que, quando montado no veículo, correspondem ao elemento de sensibilidade em um sistema cuja grandeza é proporcional à velocidade angular. Desse modo, quando estão efetuando um giro em relação a um dado referencial, o sinal de torque é medido e analiticamente determina-se o deslocamento angular entre duas posições.

Outros giroscópios utilizam princípios diferentes com maior precisão, entretanto, a um custo mais elevado. São eles: *Ring Laser Gyro*, *Fiber-Optic Gyros*.

2. Medição de forças aplicadas: Essa função é realizada pelos acelerômetros. Esses dispositivos utilizam o princípio dinâmico do pêndulo para determinar a força aplicada ao corpo. Apesar da análise simples, é impossível distinguir os efeitos sobre um corpo da aceleração inercial e da ação gravitacional. Razão pela qual é necessário o conhecimento do campo gravitacional local.
3. Cálculo de integração: Com os dados de força e conseqüentemente aceleração, a integração no tempo fornecerá a velocidade e a segunda integração fornecerá o deslocamento.

Na configuração mais moderna, os sensores inerciais são instalados diretamente na estrutura do veículo (*strapdown*) e assim substituem a configuração mais antiga (*gimballed*), cujas principais desvantagens são o alto custo e a difícil calibração. Nessa configuração mais acoplada, os sensores (acelerômetros e giroscópios) da IMU, estão mecanicamente fixados no veículo e alinhados com o sistema de referência do corpo. Desse modo, a questão da determinação da posição, velocidade e orientação é basicamente o resultado da fusão de dados provenientes da IMU, juntamente com o modelo gravitacional.

A Figura 20 detalha essa configuração, mostrando tratar-se de um sistema composto de *hardware* e *software* para a determinação dos parâmetros de saída.

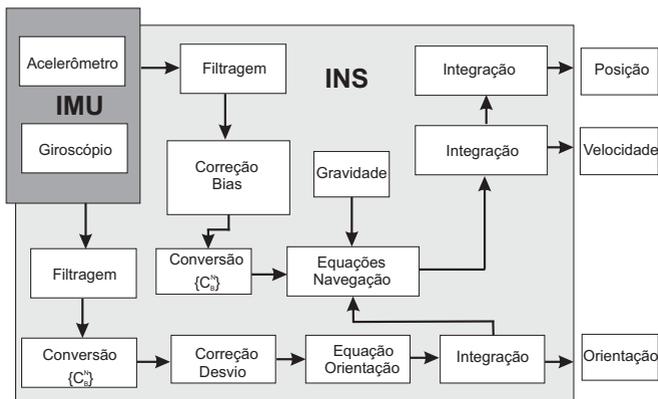


Figura 20: Configuração do sistema de navegação inercial.

### 3.2.1 Principais Fontes de Erro

O funcionamento da IMU está sujeito a algumas imprecisões devido a sua sensibilidade a algumas variáveis. A presença dessas suscetibilidades reflete em erros nas medições de posição, velocidade e orientação. Dentre as variadas fontes de erro, algumas delas são discutidas abaixo.

### 3.2.1.1 BIAS e Taxa de Desvio

Esses dois efeitos provocam os erros mais significativos na saída do dispositivo. O *bias*, que afeta os acelerômetros, e a taxa de desvio, que afeta os giroscópios, correspondem a pequenos desvios incorretos na leitura da IMU. Em [Woodman 2007] são detalhados aspectos relevantes à construção de uma IMU, onde são também exemplificados os efeitos dos fatores de erros mencionados, conforme mostrado na Tabela 3:

<b>Bias (<math>m/s^2</math>)</b>	<b>Erro de Posição (<math>m</math>) (100s)</b>	<b>Erro de Posição (<math>m</math>) (30min)</b>
0.1	500	162000
0.01	5	16200
0.001	0.5	1620
0.0001	0.05	162

Tabela 3: Exemplo de erros de posição

### 3.2.1.2 Temperatura

Apesar de não apresentar efeitos tão danosos às medições, tanto os acelerômetros quanto os giroscópios são sensíveis à temperatura. Desse modo, o *bias*, a taxa de desvio e a sensibilidade da maioria dos instrumentos utilizados em navegação sofrem alterações quando ocorrem mudanças de temperatura [Winkler S. 2003].

### 3.2.1.3 Histerese

Os efeitos de histerese são resultado do processo conhecido como *random walk*. Devido ao carácter ruidoso das medições realizadas pela IMU, tanto o *bias* quanto a taxa de desvio sofrem alterações todos os instantes em que o dispositivo é ligado, mesmo quando mantido sob as mesmas condições [Woodman 2007].

### 3.2.1.4 Vibrações

Os acelerômetros de alta precisão apresentam uma estrutura formada por uma massa de prova e um ressonador piezoelétrico. As medições são realizadas a partir dos deslocamentos da massa de prova que altera a frequência do ressonador. Face a isso, cuidados devem ser tomados para evitar que a IMU sofra vibrações, principalmente na frequência ressonante [Titterton e Weston 2004].

### 3.2.2 Equações de Navegação

O desenvolvimento a seguir baseia-se nas publicações [Titterton e Weston 2004], [Britting 2010] em cujas formulações utiliza-se a matriz de cossenos diretores, definida em 3.1, para realizar rotações entre os diferentes eixos dos diferentes sistemas de coordenadas no lugar da matriz de rotação  $R$  com os ângulos de Euler.

$$\begin{aligned} \begin{bmatrix} \hat{n}_1 \\ \hat{n}_2 \\ \hat{n}_3 \end{bmatrix} &= \begin{bmatrix} \hat{n}_1 \cdot \hat{e}_1 & \hat{n}_1 \cdot \hat{e}_2 & \hat{n}_1 \cdot \hat{e}_3 \\ \hat{n}_2 \cdot \hat{e}_1 & \hat{n}_2 \cdot \hat{e}_2 & \hat{n}_2 \cdot \hat{e}_3 \\ \hat{n}_3 \cdot \hat{e}_1 & \hat{n}_3 \cdot \hat{e}_2 & \hat{n}_3 \cdot \hat{e}_3 \end{bmatrix} \begin{bmatrix} \hat{e}_1 \\ \hat{e}_2 \\ \hat{e}_3 \end{bmatrix} \\ &= \begin{bmatrix} \cos\theta_{11} & \cos\theta_{12} & \cos\theta_{13} \\ \cos\theta_{21} & \cos\theta_{22} & \cos\theta_{23} \\ \cos\theta_{31} & \cos\theta_{32} & \cos\theta_{33} \end{bmatrix} \begin{bmatrix} \hat{e}_1 \\ \hat{e}_2 \\ \hat{e}_3 \end{bmatrix} \end{aligned} \quad (3.1)$$

Nesse caso,  $\hat{n}$  e  $\hat{e}$  correspondem aos vetores unitários expressos em  $N$  e  $E$  respectivamente e  $\theta$ , ao ângulo entre esses vetores. Essa e outras representações para a matriz de rotação utilizando ângulos de Euler e quatérnios estão detalhadas em [Murray, Li e Sastry 1994].

#### 3.2.2.1 Equação da Velocidade

Considere  $\mathbf{v}^N$  o vetor velocidade do veículo expresso no sistema de coordenadas de navegação e  $r^E$  o vetor posição expresso no sistema de coordenadas fixo à Terra. A equação 3.2 expressa a relação entre essas duas variáveis.

$$\mathbf{v}^N = C_E^N \dot{r}^E \quad (3.2)$$

onde  $\{\mathbf{v}^N, r^E\} \in \mathbb{R}^3$  e a matriz de cossenos diretores  $C_E^N \in \mathbb{R}^{3 \times 3}$ , refere-se à rotação do sistema de coordenadas do referencial  $E$ , referencial fixo à Terra para  $N$ , referencial de navegação.

Tomando-se a primeira derivada da equação 3.2 tem-se:

$$\dot{v}^N = C_E^N \dot{r}^E + \dot{C}_E^N r^E \quad (3.3)$$

Considerando que as leituras das variações angulares são tomadas em relação ao sistema de coordenadas inercial, segue-se que:

$$r^E = C_I^E r^I \quad (3.4)$$

$$\dot{r}^E = C_I^E \dot{r}^I + \dot{C}_I^E r^I \quad (3.5)$$

A derivada temporal da matriz  $C_I^E$  é dada por:

$$\dot{C}_I^E = C_I^E \Omega_{EI}^I \quad (3.6)$$

onde  $\Omega_{IE}^I = -\Omega_{EI}^I$  corresponde à matriz antissimétrica do vetor velocidade angular relativa ( $\omega$ ) do sistema de referência  $E$  em relação ao  $I$  expresso no sistema de referência  $I$  detalhado na equação 3.7.

$$\Omega_{IE}^I = [\omega_{IE \times}^I] = [\omega_X, \omega_Y, \omega_Z]^T = \begin{vmatrix} 0 & -\omega_Z & \omega_Y \\ \omega_Z & 0 & -\omega_X \\ -\omega_Y & \omega_X & 0 \end{vmatrix} \quad (3.7)$$

onde  $[X, Y, Z]$  correspondem aos eixos do referencial inercial. Substituindo a equação 3.6 na equação 3.5 e calculando a segunda derivada temporal tem-se:

$$\ddot{r}^E = C_I^E (\ddot{r}^I - 2\Omega_{IE}^I \dot{r}^I + \Omega_{IE}^I \Omega_{IE}^I r^I) \quad (3.8)$$

Considerando que a Terra possui uma velocidade angular constante ( $\dot{\Omega}_{IE}^I = 0$ ) e que  $\dot{C}_E^N = -\Omega_{EN}^N C_E^N$ , onde  $\Omega_{EN}^N$  corresponde à matriz antissimétrica do vetor velocidade angular relativa do referencial de navegação em relação ao referencial da Terra expresso no referencial de navegação, inserem-se as equações 3.8, 3.6 e 3.5 na equação 3.3, o que resulta em:

$$\dot{v}^N = C_I^N [\ddot{r}^I - (\Omega_{EN}^I + 2\Omega_{IE}^I) \dot{r}^I - \Omega_{IE}^I \Omega_{IE}^I r^I] \quad (3.9)$$

Considere agora  $a_{SF}^N$  como o sinal de saída dos acelerômetros expresso no sistema de coordenadas de navegação, onde SF refere-se a forças específicas ou não gravitacionais. O sinal de saída é portanto resultado da combinação da aceleração gravitacional e inercial:

$$a_{SF}^N = \underbrace{C_I^N \ddot{r}^I}_{\ddot{r}^N} - G^N \quad (3.10)$$

A equação reflete o observado experimentalmente, ou seja, colocando-se um acelerômetro em queda livre ( $\ddot{r}^N = G^N$ ) o sinal de saída será nulo. O termo  $G^N$  inclui a aceleração da gravidade e aceleração centrípeta resultante da rotação da Terra e é definido por:

$$G^N = g^N + \Omega_{IE}^N \Omega_{IE}^N r^N \quad (3.11)$$

A expressão final para a dinâmica de  $\mathbf{v}^N$  em função das leituras dos acelerômetros segue-se das seguintes relações:

$$\Omega_{IE}^N \Omega_{IE}^N = C_I^N \Omega_{IE}^I C_N^I C_I^N \Omega_{IE}^I C_N^I; \quad (3.12)$$

$$\ddot{r}^I = C_N^I (a_{SF}^N + g^N) + \Omega_{IE}^I \Omega_{IE}^I r^I. \quad (3.13)$$

cuja substituição em 3.9 resulta em:

$$\dot{\mathbf{v}}^N = a_{SF}^N - (\Omega_{EN}^N + 2\Omega_{IE}^N) \mathbf{v}^N + g^N \quad (3.14)$$

onde  $\mathbf{v}^N = [v_{North}, v_{East}, v_{Down}]$  é o vetor velocidade em relação à Terra expresso no referencial de navegação local.

A equação 3.14 expressa a evolução do vetor velocidade no sistema de referência de navegação. Para as situações analisadas em robótica subaquática, a baixas velocidades, o movimento da Terra não influencia na velocidade do veículo, o que simplifica as expressões desenvolvidas.

### 3.2.2.2 Equação de Orientação

A equação dinâmica da orientação é a analisada a partir da matriz de transformação  $C_B^N$ , conforme descrito pela equação diferencial abaixo:

$$\dot{C}_B^N = C_B^N \Omega_{NB}^B \quad (3.15)$$

A partir dos vetores velocidade angular abaixo:

$$\omega_{EN}^N = [\dot{l} \cos L, -\dot{L}, -\dot{l} \sin L]' \quad (3.16)$$

$$\omega_{IE}^N = [\Omega \cos L, 0, -\Omega \sin L]' \quad (3.17)$$

$$\dot{l} = \frac{v_E}{(R_0 + h) \cos L} \quad (3.18)$$

$$\dot{L} = \frac{v_N}{R_0 + h} \quad (3.19)$$

onde  $L$  e  $l$ , conforme mostrados na figura 19, correspondem à latitude e longitude respectivamente,  $\Omega$  é a velocidade de rotação da Terra em relação ao sistema inercial,  $R_0$  é o raio da Terra e  $h$  é a distância em relação à superfície terrestre. O valor de  $\Omega_{NB}^N$  é obtido através das seguintes expressões:

$$\omega_{IN}^N = \omega_{IE}^N + \omega_{EN}^N \quad (3.20)$$

$$\omega_{BN}^N = \omega_{IN}^N - C_B^N \omega_{IB}^B \quad (3.21)$$

$$\Omega_{BN}^N = [\omega_{BN}^N \times] \quad (3.22)$$

O termo  $\omega_{IB}^B$  representa o sinal de saída do giroscópio acoplado ao veículo. Análises mais elaboradas do desenvolvimento dessas expressões, onde são consideradas as imprecisões quanto ao raio terrestre e o vetor aceleração gravitacional, cujo erro pode degradar as medições de aceleração, podem ser encontradas em [Britting 2010].

### 3.2.2.3 Equação de Posição

Em geral, procura-se expressar a posição de um corpo em relação a Terra através da sua distância em relação à superfície  $h$  e sua orientação angular, expressa pela latitude  $L$  e longitude  $l$ . A equação que descreve a evolução da posição é determinada a partir da matriz de transformação  $C_N^E$ , conforme descrito pela equação diferencial abaixo:

$$\dot{h} = -v_{Down} \quad (3.23)$$

$$\dot{C}_N^E = C_N^E \Omega_{EN}^N \quad (3.24)$$

onde  $C_N^E$  expressa o vetor posição em N no sistema de referência fixo à Terra.

## 3.2.2.4 Algoritmos

No sistema de navegação inercial realiza-se a integração numérica das equações diferenciais de velocidade, posição e orientação. Em [Savage 1998] são detalhados algoritmos para solução numérica das equações apresentadas. A Figura 21 detalha o processamento realizado pelo INS.

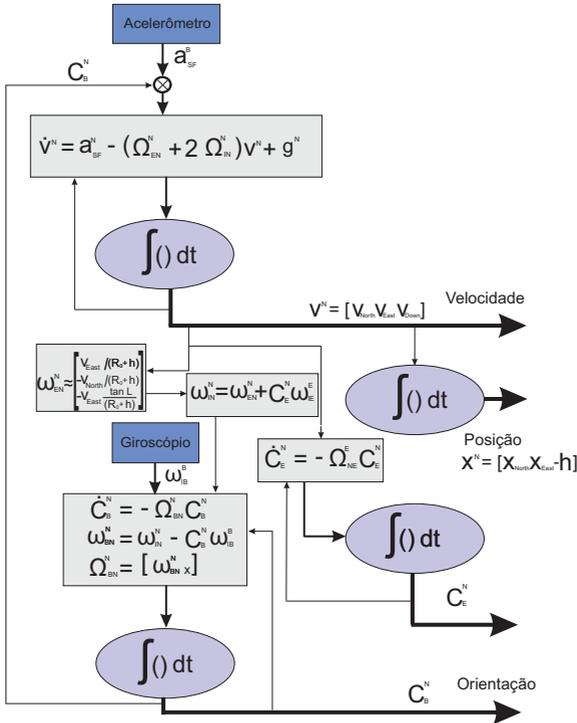


Figura 21: Detalhe do processamento realizado no sistema de navegação inercial.

Devido aos fatores mencionados anteriormente, somadas às imprecisões quanto aos valores iniciais, modelo gravitacional, por exemplo, os sinais de saída de velocidade, posição e orientação sofrem desvios ilimitados ao longo do tempo. Esse cenário sugere, portanto, um processamento extra, de modo a melhorar as estimativas dos parâmetros de navegação. Em geral, o sistema de navegação é auxiliado por um outro conjunto de sensores cujas medições servem para melhorar as estimativas de saída do conjunto IMU/INS. Nessa configuração tem-se então um sistema de navegação assistido discutido

a seguir.

### 3.3 SISTEMA DE NAVEGAÇÃO ASSISTIDO

Como mencionado, no sistema de navegação assistido, um conjunto de sensores participam do processo de estimação dos estados do veículo. Um dos modos mais comuns de integrar todas essas informações para obter uma melhor estimativa desses parâmetros está detalhado na Figura 22, onde o algoritmo de fusão de dados incorpora informações de sensores externos de modo a melhorar as estimativas iniciais quanto aos estados do veículo. As linhas tracejadas na figura indicam o processamento realizado após a inserção de informações provenientes dos sensores no filtro de estimação de estados, enquanto as linhas contínuas referem-se ao processamento realizado com as estimativas iniciais, provenientes do sistema de navegação inercial.

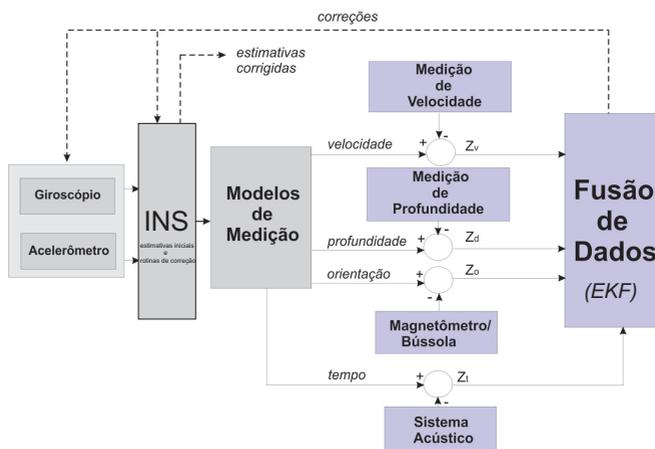


Figura 22: Configuração de um sistema de navegação assistido

Essa configuração constitui um vasto campo de pesquisa, onde soluções com filtros de Kalman estendido e outras técnicas para estimação da orientação e posição do veículo são aplicadas. Dentre essas soluções, pode-se citar abordagens como: *QUEST filters* [Shuster 1989] e *recursive QUEST* [Bar-Ithhack 1996], *Unscented filters* [Julier, Uhlmann e Durrant-Whyte 1995] e *Particle filters* [Cheng e Crassidis 2004].

### 3.3.1 Sistemas de Localização Acústicos

Visando expandir o sistema mostrado até o momento, pode-se então equipar o veículo com sensores que realizem medições diretas de estados do veículo. Um desses equipamentos é o responsável pela localização do veículo, sobre o qual essa seção irá tratar.

Um sistema de localização (posicionamento) acústico subaquático APS, é uma solução que permite essencialmente determinar a posição e efetuar o seguimento de veículos subaquáticos, mergulhadores, animais. O APS recorre à utilização de sinais acústicos para a determinação da distância e/ou direção de um (ou vários) dispositivo(s) emissor(es) em relação a um (ou vários) dispositivo(s) receptor(es). Os sistemas de posicionamento acústico são utilizados em diversas aplicações subaquáticas como construção e inspeção de plataformas petrolíferas e oleodutos, atividades militares e de vigilância, arqueologia e geologia marinha, entre outras.

Nos sistemas de posicionamento acústico são utilizados diversos dispositivos destinados a receber ou emitir (ou ambos) sinais sonoros e que apresentam diferentes formas de funcionamento. Destacam-se:

- Transducer: emissor e receptor que envia um sinal acústico e aguarda uma resposta ao sinal enviado;
- Transponder: receptor e emissor que funciona em conjunto com o transducer. Ao receber um sinal proveniente deste dispositivo envia-lhe um sinal em resposta.
- Pinger: emissor que envia continuamente e a intervalos de tempo fixos um sinal predefinido.
- Hidrofone: receptor que se instala no veículo subaquático ou numa estrutura de recepção para detectar a presença de um sinal enviado por um dos emissores indicados anteriormente.
- Responder: emissor cujo sinal será recebido por um transducer ou hidrofone.

O esquema mostrado na Figura 23 baseia-se em [Lee et al. 2007], onde se detalha a configuração do sistema de localização acústico com alguns dos sensores envolvidos e o sistema de coordenadas.

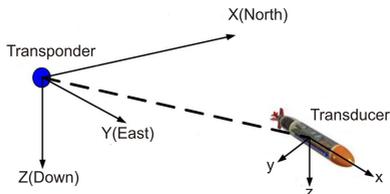


Figura 23: Sensoriamento do sistema de localização acústico [Lee et al. 2007].

### 3.3.2 Arquitetura

Classicamente existem três arquiteturas para a configuração dos sistemas de posicionamento acústico subaquático e o seu modo de funcionamento. A distância entre os dispositivos acústicos utilizados (hidrofonos, transducers, etc.), denominada de baseline, é o critério utilizado para a classificação de cada configuração. Salienta-se que mesmo dentro de cada arquitetura existem diferentes opções de projeto e modos de operação possíveis.

Nesse trabalho avaliou-se a configuração LBL explorada em [Miller, Farrell e Djapic 2010] mostrada na Figura 24, onde é utilizado um dispositivo emissor instalado no veículo cujo sinal enviado deve ser detectado por, pelo menos, três receptores instalados em bóias, de forma a determinar a posição relativa do veículo. Por meio do esquema interrogação/resposta, possibilita-se a determinação da distância ao emissor. Com a tecnologia atual, todo o ciclo de interrogação/resposta leva em torno de  $2s$  para uma área de cobertura de aproximadamente  $350 \times 350m^2$  [Miller, Farrell e Djapic 2010].

### 3.3.3 Doppler Velocity Log - DVL

O DVL trabalha com o princípio do efeito Doppler, que refere-se à mudança na frequência entre o sinal transmitido e o recebido pelo movimento do veículo. Um transdutor transmite um feixe contínuo de vibrações do som em um ângulo de  $60^\circ$  enquanto um segundo recebe o sinal refletido difusamente a partir do leito. Assim esse dispositivo registra a mudança na frequência entre o sinal transmitido e o sinal recebido e calcula a velocidade da embarcação

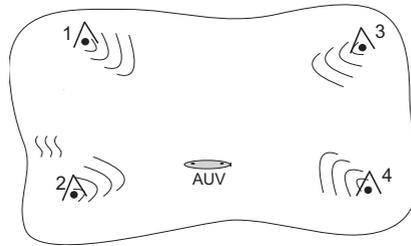


Figura 24: Configuração do sistema de localização LBL.

com base no valor da mudança de frequência.

Os feixes do DVL são contínuos, estreitos (cerca de  $3^\circ$  de abertura), frequência em torno de  $300\text{KHz}$  a  $600\text{KHz}$  dependendo da proximidade do veículo em relação ao leito. Além de definir um transdutor para a frente, há um segundo conjunto transdutor de frente para trás. Essa é a conhecida configuração Janus e permite que o sistema calcule a mudança de frequência em duas direções, garantindo assim uma medição de velocidade mais precisa. A unidade de transdutor Doppler possui quatro transdutores emissores de feixe orientados para baixo a cerca de  $30^\circ$  do eixo vertical do instrumento. O desvio-padrão do erro de medição varia de acordo com frequência e configuração do instrumento. Tipicamente, um Doppler trabalhando a  $1.200\text{kHz}$  apresenta um desvio padrão  $0.3\%$  para uma velocidade nominal de  $1\text{m/s}$  [Liu Da-jun Sun 2009, Xiong-fei, Bing-cheng e Xi 2009, Hegre-naes e Hallingstad 2011].

O sistema Doppler calcula a velocidade em relação ao leito, com uma precisão de cerca de  $0.5\%$  da distância percorrida, funcionando bem para todas as velocidades atuais utilizadas em AUVs e com altitude mínima de  $1.5\text{ m}$  até uma máxima de cerca de  $600\text{ m}$ . Em água doce, o alcance do DVL é maior que em água salgada. A Figura 25 ilustra o sistema Doppler para medição de velocidade em relação ao leito.

Como pode ser observado, devido às irregularidades na geografia do leito, em alguns momentos a leitura do DVL pode não estar disponível. Além disso, camadas de água com elevada densidade e a baixas temperaturas facilitam a reflexão do feixe emitido, provocando leituras com baixa precisão. Alguns equipamentos conseguem definir um parâmetro para a qualidade da medição da velocidade, descartando aquelas de menor confiabilidade. Experimentos científicos [Whitcomb, Yoerger e Singh 1999] demonstram que os erros de medição nos sensores de orientação do veículo estão entre as maiores fontes de erros nas informações de velocidade fornecidas pelo DVL. Outros aspectos são:

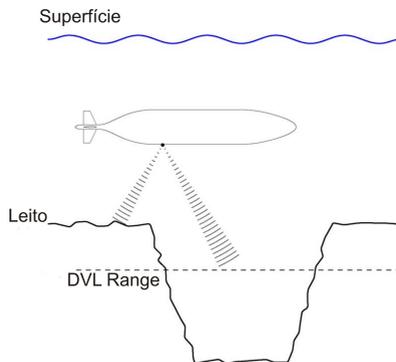


Figura 25: Navegação auxiliada por DVL.

1. Altitude do veículo ou distância em relação ao leito;
2. Sensibilidade do sensor quanto à velocidade do veículo;
3. Velocidade do som no meio;

### 3.3.4 Horizontal Acoustic Doppler Current Profiler - HADCP

No ambiente subaquático, o veículo subaquático poderá encontrar correntes aquáticas com características espaço-temporais variáveis. Para navegação em oceanos, é comum utilizar modelos numéricos das correntes oceânicas para prover uma predição atual e futura da variabilidade das águas do oceano, ou seja, essas equações são integradas ao longo do tempo para determinar a evolução do comportamento do fluido tanto na horizontal como na vertical. Esses modelos referem-se a parâmetros do fluido que variam lentamente com o tempo e são avaliados para grandes áreas.

Por razões de segurança, é interessante avaliar a variabilidade do ambiente em escalas menores e com maior rapidez de modo a estimar as condições do veículo em determinado instante. Como os modelos numéricos não conseguem fornecer previsões tão imediatas [Alvarez, Oliver e Garau 2006], faz-se necessário o uso de sensores que realizem uma leitura das condições

do fluido nas proximidades do veículo. O HADCP é um equipamento de monitoramento que emite um feixe estreito (300KHz) para “varrer” horizontalmente uma determinada área afim de determinar a velocidade da correnteza em diferentes direções.

Assim como o DVL, o HADCP utiliza-se do efeito Doppler, baseando-se principalmente no retorno da onda sonora refletida nas partículas (pequenos seres vivos, material orgânico, etc.) presentes na água, uma vez que as mesmas movem-se na presença de correntes aquáticas. Portanto, para ambientes com elevada concentração de material em suspensão como lagos, o HADCP pode ser fundamental para o sistema de navegação [Medagoda et al. 2006], [Medagoda et al. 2011].

### 3.3.5 Navegação assistida pelo modelo

Durante a navegação, o veículo está sujeito à perda de sinais tanto do DVL e HADCP como do LBL, uma vez que, sendo esses sinais acústicos, as variações das propriedades da água como temperatura, salinidade, densidade ou o nível de ruído presente podem atenuar o sinal deteriorando a informação a ser extraída. Para efeitos de implementação, costuma-se adotar uma métrica de qualidade, onde as medições devem estar dentro de um intervalo de  $3\sigma$  ou três vezes o desvio padrão da medida estimada.

Para tornar o sistema mais confiável e preparado para esse tipo de situação, recorre-se a uma solução onde o próprio modelo do veículo, quando bem determinado, é utilizado como uma fonte de informação para a navegação assistida [Hegrenaes e Berglund 2009], [Hegrenaes e Hallingstad 2011], [Morgado et al. 2006].

O esquema baseado nessa solução está detalhado na Figura 26:

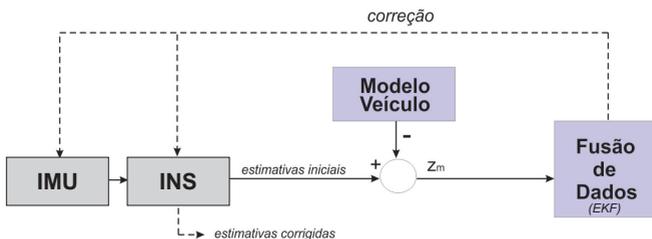


Figura 26: Navegação auxiliada pelo modelo.

Detalhes sobre modelagem e limitações dos modelos de veículos subaquáticos são abordados em [Antonelli 2004], [Fossen 1994], [Fossen e

Balchen 1991], entre outros. A limitação no uso desse método está essencialmente na confiabilidade do modelo não-linear adotado, principalmente devido a imprecisões na determinação da matriz de inércia e de arrasto e sustentação do veículo.

### 3.4 CONCLUSÕES

A formulação apresentada nesse capítulo para o sistema de navegação está diretamente relacionada à velocidade do veículo analisado. Para plataformas robóticas subaquáticas, onde as velocidades são pequenas, as grandezas referentes ao movimento da Terra, como sua velocidade em relação ao referencial inercial, podem ser desprezadas, o que simplifica as expressões desenvolvidas.

Vale destacar que a instrumentação de um veículo autônomo deve levar em conta fatores que estendem a idéia de capacidade de sensoriamento, como a presenças de ruídos de diferentes naturezas. Certamente, a fusão de informações correlacionadas auxilia o sistema de navegação e melhora a precisão das grandezas estimadas. No entanto, o acréscimo de sensores implica em maior consumo de energia e principalmente peso adicional ao veículo. Além disso, os aspectos estruturais devem ser avaliados a fim de acomodar a instrumentação necessária.

Outro aspecto relevante, não tratado ao longo desse trabalho, refere-se ao alinhamento dos sensores. Como observado, várias transformações de coordenadas são realizadas através da matriz de cossenos ou matriz de rotação, o que requer o alinhamento correto entre os eixos de sensores como a IMU e os eixo do veículo bem como a determinação correta da posição do centro de gravidade do veículo. A depender das dimensões do veículo, erros não compensados devido a falta de alinhamento podem ser desastrosos quando acumulados ao longo do tempo.

O posicionamento de sensores acústicos como hidrofones, emissores, DVL etc. deve ser cuidadosamente estudado afim de evitar que o movimento do veículo gere zonas de sombra e eventuais perdas de sinal. Além disso, a distância entre a posição do sensor e o centro de gravidade do veículo deve ser compensada nos cálculos referentes ao modelo de medição.



## 4 ALGORITMO DE FUSÃO DE DADOS E A ESTIMAÇÃO DE ESTADOS

No capítulo anterior, o foco esteve na descrição do sistema de navegação composto de sensores inerciais IMU, algoritmos para cálculos numéricos e sensores externos, que auxiliam o processo de estimação da posição, orientação e velocidade do veículo subaquático.

Conforme visto, as informações advindas dos sensores auxiliares são comparadas com a saída do bloco INS e inseridas no bloco de fusão de dados ou filtragem. Este capítulo trata especificamente dos aspectos relativos ao processo de estimação dos estados do veículo, ressaltando a formulação matemática e os detalhes do algoritmo empregado para esse fim. Pretende-se também mostrar, através de simulações, como a navegação assistida, juntamente com esse bloco de filtragem, melhora as estimativas obtidas com o conjunto IMU/INS.

### 4.1 FILTRO DE KALMAN ESTENDIDO

O filtro de Kalman estendido é amplamente utilizado nos sistemas de navegação de qualquer classe de veículo. Em [Britting 2010] e [Titterton e Weston 2004] detalha-se a utilização dessa técnica de filtragem nos sistemas de navegação auxiliado. Diversos trabalhos [Batista, Silvestre e Oliveira 2010], [Hegrenaes e Berglund 2009], [Hegrenaes e Hallingstad 2011] e [Morgado et al. 2006] utilizam essa abordagem apresentando resultados satisfatórios para os diversos conjuntos de sensores e tipos de veículos.

O EKF é exaustivamente discutido na literatura [Maybeck 1982], [Simon 2006], com sua formulação discreta dada pelo seguinte conjunto de equações:

*Equações não lineares do sistema dinâmico e de medição:*

$$x_k = f_{k-1}(x_{k-1}, u_{k-1}, \rho_{k-1}) \quad (4.1)$$

$$z_k = h_k(x_k, \vartheta_k) \quad (4.2)$$

$$\rho_k \sim (0, Q_k) \quad (4.3)$$

$$\vartheta_k \sim (0, S_k) \quad (4.4)$$

onde o modelo do processo  $f_{k-1}$  é função de  $u_k$ , que representa o sinal de controle, e  $\rho_k$  e  $\vartheta_k$ , que são ruídos brancos gaussianos de média zero decorrelacionados com matrizes de covariância conhecidas  $Q_k$  e  $S_k$  respectivamente. O subscrito  $k$  corresponde ao instante discreto de tempo.

*Inicialização do filtro:*

$$\hat{x}_0^+ = E(x_0) \quad (4.5)$$

$$P_0^+ = E[(x_0 - \hat{x}_0^+)(x_0 - \hat{x}_0^+)^T] \quad (4.6)$$

onde  $x_0$  corresponde às condições iniciais das variáveis de estado,  $\hat{x}_0^+$  e  $P_0^+$ , às estimativas iniciais de estado e a matriz de covariância do erro de estimação respectivamente e o operador  $E$  corresponde ao valor esperado.

*Para os instantes discretos de tempo  $k = 1, 2, \dots$ , segue:*

(a) *Cálculo das derivadas parciais:*

$$F_k = \left. \frac{\partial f_k}{\partial x} \right|_{\hat{x}_k^+} \quad (4.7)$$

$$L_k = \left. \frac{\partial f_k}{\partial \rho} \right|_{\hat{x}_k^+} \quad (4.8)$$

(b) *Propagação temporal da estimativa das variáveis de estado e da matriz de covariância:*

$$\hat{x}_{k+1}^- = f_k(\hat{x}_k^+, u_k, 0) \quad (4.9)$$

$$P_{k+1}^- = F_k P_k^+ F_k' + L_k Q_k L_k' \quad (4.10)$$

(c) *Cálculo das derivadas parciais:*

$$H_{k+1} = \left. \frac{\partial h_{k+1}}{\partial x} \right|_{\hat{x}_{k+1}^-} \quad (4.11)$$

$$M_{k+1} = \left. \frac{\partial h_{k+1}}{\partial \vartheta} \right|_{\hat{x}_{k+1}^-} \quad (4.12)$$

(d) *Correção das variáveis de estado e da matriz de covariância preditas:*

$$K_{k+1} = P_{k+1}^- H_{k+1}^T (H_{k+1} P_{k+1}^- H_{k+1}^T + M_{k+1} S_{k+1} M_{k+1}^T)^{-1} \quad (4.13)$$

$$\hat{x}_{k+1}^+ = \hat{x}_{k+1}^- + K_{k+1} [z_{k+1} - h_{k+1}(x_{k+1}^-, 0)] \quad (4.14)$$

$$P_{k+1}^+ = (I - K_{k+1} H_{k+1}) P_{k+1}^- \quad (4.15)$$

onde  $I$  refere-se à matrix identidade e  $K_k$  ao ganho de Kalman.

Apesar das desvantagens da formulação parametrizada do EKF descrito acima devido à necessidade do conhecimento prévio das matrizes  $Q$  e  $S$ , essa abordagem tem sido explorada em diversos sistemas de navegação de

plataformas robóticas.

Para as plataformas robóticas subaquáticas, a formulação do filtro é realizada no espaço de erro, onde assim evita-se a utilização direta do modelo dinâmico do veículo (abordagem passiva) ou modelos cinemáticos (*dead reckoning*). Nesse caso, são comparadas as saídas do sistema de navegação inercial, no referencial inercial, com a saída dos sensores externos auxiliares. A formulação apresentada a seguir baseia-se nos modelos apresentados em [Batista, Silvestre e Oliveira 2010], [Morgado et al. 2006], [Morgado et al. 2008], embora alguns trabalhos como em [Hegrenaes e Berglund 2009], [Hegrenaes e Hallingstad 2011], [Miller, Farrell e Djapic 2010] apresentem variações dessa formulação. Considere o que se segue:

$$\delta \mathbf{p} = \mathbf{p} - \bar{\mathbf{p}}; \quad (4.16)$$

$$\delta \mathbf{v} = \mathbf{v} - \bar{\mathbf{v}}; \quad (4.17)$$

$$\mathbf{R}_B^N(\delta \lambda) = \mathbf{R}_B^N \bar{\mathbf{R}}_B^{N'} \simeq \mathbf{I}_{3 \times 3} + [\delta \lambda_{\times}]; \quad (4.18)$$

$$\delta \mathbf{b}_a = \mathbf{b}_a - \bar{\mathbf{b}}_a; \quad (4.19)$$

$$\delta \mathbf{b}_\omega = \mathbf{b}_\omega - \bar{\mathbf{b}}_\omega; \quad (4.20)$$

onde  $\mathbf{p}$  e  $\mathbf{v}$  correspondem à posição e velocidade do veículo em relação ao referencial NED respectivamente,  $\bar{\mathbf{x}}$  refere-se ao valor nominal do vetor  $\mathbf{x}$  e  $\delta \lambda$  ao erro de orientação. A expressão  $[\delta \lambda_{\times}]$ , assim como mostrado em 3.7, corresponde à matriz antissimétrica com os elementos do vetor  $\delta \lambda$  e os índices  $a$  e  $\omega$  referem-se ao acelerômetro e giroscópio respectivamente. Tomando-se a derivada temporal de  $\delta \mathbf{p}$ , tem-se:

$$\delta \dot{\mathbf{p}} = \delta \mathbf{v}; \quad (4.21)$$

Sabe-se que o acelerômetro mede a aceleração do veículo no referencial do corpo, uma vez que se trata de um sensor inercial. Portanto:

$$\mathbf{a}_{SF}^B = \bar{\mathbf{a}}^B + \bar{\mathbf{g}}^B - \delta \mathbf{b}_a + n_a; \quad (4.22)$$

onde novamente  $B$  refere-se ao sistema referencial do corpo,  $\mathbf{g}$  à aceleração da gravidade assumida aqui como um vetor constante e  $_{SF}$  às forças específicas atuantes no veículo. O termo  $\delta \mathbf{b}_a = \mathbf{b}_a - \bar{\mathbf{b}}_a$  corresponde à compensação de *bias* no acelerômetro, conforme mostrado na figura 7, onde  $\mathbf{b}$  é o *bias* compensado. Conforme visto no capítulo anterior, a leitura do acelerômetro, mostrada na equação 4.22, é distorcida pelo ruído branco  $n_a$  e por um *random walk* (RW) *bias*  $\dot{\bar{\mathbf{b}}}_a = n_{ba}$ , que expressa como o *bias* de um dispositivo pode variar num determinado intervalo de tempo. Detalhes sobre esses e outros

processos estocásticos estão bem detalhados em [Kasdin 1995].

O sinal do acelerômetro é transformado para o referencial fixo computacionalmente no IMU através da matriz de rotação  $\mathbf{R}_B^N$  mostrada. Doravante, para fins de simplificação da notação,  $\mathbf{R}_B^N \equiv \mathbf{R}$ .

Devido ao erro de orientação entre os instantes de integração em 4.17, tem-se:

$$\delta \dot{\mathbf{v}} = -\mathbf{R} \delta \mathbf{b}_a - [\mathbf{R} \mathbf{a}_{SF}^B \times] \delta \lambda + \mathbf{R} n_a; \quad (4.23)$$

Para a leitura do giroscópio, tem-se a seguinte expressão:

$$\boldsymbol{\omega} = \bar{\boldsymbol{\omega}} - \delta \mathbf{b}_\omega + n_\omega; \quad (4.24)$$

cuja leitura também é distorcida pelo ruído branco  $n_\omega$  e por um *random walk bias*,  $\dot{\mathbf{b}}_\omega = n_{b\omega}$ . A partir desta expressão pode-se determinar a taxa do erro de orientação:

$$\delta \dot{\lambda} = -\mathbf{R} \delta \mathbf{b}_\omega + \mathbf{R} n_\omega; \quad (4.25)$$

Por fim, de acordo com [Britting 2010], a representação simplificada do sistema no espaço de estados de erros é :

$$\delta \dot{\mathbf{p}} = \delta \mathbf{v}; \quad (4.26)$$

$$\delta \dot{\mathbf{v}} = -\mathbf{R} \delta \mathbf{b}_a - [\mathbf{R} \mathbf{a}_{SF}^B \times] \delta \lambda + \mathbf{R} n_a; \quad (4.27)$$

$$\delta \dot{\lambda} = -\mathbf{R} \delta \mathbf{b}_\omega + \mathbf{R} n_\omega; \quad (4.28)$$

$$\delta \dot{\mathbf{b}}_a = -n_{ba}; \quad (4.29)$$

$$\delta \dot{\mathbf{b}}_\omega = -n_{b\omega}. \quad (4.30)$$

Observa-se pelas equações acima, tratar-se de um sistema não-linear, uma vez que a matriz de rotação  $\mathbf{R}$  advém do INS e que fora corrigida a partir do erro de orientação pela expressão  $\mathbf{R}^+ = \mathbf{R}'(\delta \hat{\lambda}) \mathbf{R}^-$ , que depende da variável  $\delta \lambda$ . Portanto, recorre-se a implementação do EKF para o processo de estimação.

#### 4.1.1 Equações de Medição

Um dos pontos fundamentais na formulação do filtro de Kalman entendido é a modelagem das medições realizadas pelos sensores, ou seja, além da representação do sistema dado pelas equações 4.27 a 4.30, é necessário encontrar um modelo de medição em função das variáveis de estados mostradas. Detalhes desse desenvolvimento podem ser encontrados em [Batista,

Silvestre e Oliveira 2010], [Lee et al. 2007], [Morgado et al. 2006].

#### 4.1.1.1 Localizadores Acústicos

O sistema de localização acústico mede o tempo de chegada da onda sonora propagando no meio aquático. O sistema consiste de quatro faróis acústicos espaçadamente localizados em posições conhecidas no referencial NED e um emissor/receptor fixado ao veículo. Em determinado instante de tempo  $t_0$ , o veículo emite um sinal de interrogação aos quatro *transponders*. Ao receber a requisição, cada *transponder*  $j \in 1, 2, 3, 4$  espera um intervalo de tempo previamente definido  $T_j$  para emitir a resposta. O tempo total de viagem da onda acústica  $\mathbf{z}_t \in \mathbb{R}^{1 \times 4}$  corresponde à soma do tempo de viagem ao transponder somado ao tempo de espera conhecido mais o tempo de retorno da onda proveniente de cada um. Desse modo, tem-se:

$$\mathbf{z}_t = \frac{1}{c(t_0)} \|\mathbf{P}_j - \mathbf{p}(t_0)\| + \frac{1}{c(t_j)} \|\mathbf{P}_j - \mathbf{p}(t_i)\| + T_j + n_t \quad (4.31)$$

onde  $t_0$  é o instante e tempo da emissão do sinal de interrogação,  $t_i$  é o instante e tempo da recepção do sinal de resposta,  $c(t)$  corresponde à velocidade do som na água,  $\mathbf{P}_j$  é a posição do *transponder* instalado na boia  $j$ , o vetor  $\mathbf{p}(t)$  a posição do *transducer* instalado no veículo no instante  $t$  e no referencial NED e  $n_t$  é modelado como um ruído branco gaussiano de média zero.

O próximo passo é descrever a equação de medição em função das variáveis de estado de erro apresentadas anteriormente. Vale notar que, a depender da velocidade do veículo, o intervalo de tempo  $[t_0, t_i]$  de interrogação/resposta dos sensores acústicos pode ser suficiente para levar a incertezas consideráveis quanto ao estado do veículo.

A abordagem apresentada em [Miller, Farrell e Djapic 2010] procura compensar essa incerteza através do acúmulo da matriz de transição de estados como descrito a seguir. Para formular a expressão de medição residual, expande-se a norma-2 apresentada na equação 4.31 dada por  $d = \frac{1}{c(t)} \|\mathbf{P}_j - \mathbf{p}(t)\|$  utilizando a série de Taylor truncada:

$$d = \hat{d} + \frac{\partial d}{\partial \mathbf{x}} (\mathbf{x} - \hat{\mathbf{x}}) + \frac{1}{2!} \frac{\partial^2 d}{\partial \mathbf{x}^2} (\mathbf{x} - \hat{\mathbf{x}})^2 + \dots \approx \hat{d} + \frac{\partial d}{\partial \mathbf{x}} \Big|_{\hat{\mathbf{x}}} \delta \mathbf{x}. \quad (4.32)$$

$\delta \mathbf{x}$  representa as variáveis de estado de erro. Desse modo, a equação de medição residual ou resíduo de medição será dada por:

$$\begin{aligned}\delta \mathbf{z}_t &= d(t_0) + d(t_i) + T_i + n_t - \hat{d}(t_0) - \hat{d}(t_i) - T_j = \\ &= [D(t_0)\Phi(t_0, t_i) + D(t_i)] \delta \mathbf{x} + n_t.\end{aligned}\quad (4.33)$$

onde  $D(t) = \frac{\partial d}{\partial \mathbf{x}} \Big|_{\hat{\mathbf{x}}}$  e  $\Phi(t_0, t_i)$  representa a matrix de transição de estado, que propaga o estado de erro estimado do instante  $t_i$  de volta ao instante de interrogação  $t_0$ . Ou seja, a cada período de amostragem, a matrix de transição é acumulada através de  $\Phi(t + \Delta t, t_0) = \Phi(t + \Delta t, t) \Phi(t, t_0)$ , onde a matriz  $\Phi(t + \Delta t, t)$  é obtida a partir da linearização do sistema de equação não-linear e  $\Phi(t_0, t_i) = \Phi^{-1}(t_i, t_0)$ .

#### 4.1.1.2 DVL

Da mesma forma, é necessário modelar a equação de medição em função das variáveis de estado anteriores para o sensor DVL. Por estar acoplado ao veículo, o valor de velocidade determinado pelo DVL está expresso no referencial do corpo  $\mathbf{v}^B$ , sendo portanto necessário aplicar a matrix de rotação  $R$  a essa grandeza a fim de poder compará-la com a saída do INS, expressa no referencial de navegação  $\mathbf{v}^N$ . Segue-se então o modelo conforme desenvolvido em [Hegrenaes e Hallingstad 2011] e [Lee et al. 2007]:

$$\begin{aligned}\delta z_v &= \mathbf{v}_{DVL}^N - \mathbf{v}_{INS}^N = R \bar{\mathbf{v}}^B + R \Delta_v - \mathbf{v}_{INS}^N = \\ &= R \bar{\mathbf{v}}^B + R \Delta_v - (\bar{\mathbf{v}}^N + \delta \mathbf{v})\end{aligned}\quad (4.34)$$

A partir da relação  $\mathbf{R}_B^N(\delta \lambda) = R \bar{\mathbf{R}}^T \simeq \mathbf{I}_{3 \times 3} + [\delta \lambda_{\times}]$ , é possível chegar a seguinte expressão para 4.35:

$$\begin{aligned}\delta \mathbf{z}_v &= (\mathbf{I}_{3 \times 3} + [\delta \lambda_{\times}]) \bar{R} \bar{\mathbf{v}}^B + R \Delta_v - (\bar{\mathbf{v}}^N + \delta \mathbf{v}) = \\ &= -\delta \mathbf{v} + [\delta \lambda_{\times}] \bar{\mathbf{v}}^N + \mathbf{R} \Delta_v = \\ &= -\delta \mathbf{v} - [\bar{\mathbf{v}}_{\times}^N] \delta \lambda + \mathbf{R} \Delta_v,\end{aligned}\quad (4.35)$$

onde  $\bar{\mathbf{R}}$  corresponde ao valor nominal da matrix de rotação  $\mathbf{R}$ .

Nota-se em 4.35 que há necessidade de determinar o valor nominal de  $\bar{\mathbf{v}}^N$ , que não é possível obter diretamente. Nesse caso, recorre-se a melhor estimativa *a priori* para  $\bar{\mathbf{v}}^N$  a partir do EKF.

O termo  $\mathbf{R} \Delta_v$  é frequentemente tratado como a soma de um ruído autocorrelacionado (*colored noise- $b_v$* ) com um ruído branco gaussiano de média

zero ( $n_v$ ) [Hegrenaes e Hallingstad 2011], de modo semelhante ao acelerômetro e giroscópio. Nesse caso, tem-se:

$$\Delta \mathbf{v} = \mathbf{b}_v + n_v \quad (4.36)$$

O ruído autocorrelacionado ou colorido passa então a fazer parte das variáveis de estado do filtro de Kalman estendido numa configuração expandida, sendo comumente modelado como um processo de Markov de primeira ordem [Simon 2006] excitado por um ruído branco ( $n_{bv}$ ):

$$\dot{\mathbf{b}}_v = -\mathbf{T}^{-1} \mathbf{b}_v + n_{bv} \quad (4.37)$$

O sucesso desse modelo será maior quanto melhor for a escolha de  $\mathbf{T}(\cdot)$ , modelado como uma matriz diagonal com os termos de autocorrelação, e o conhecimento da matriz de covariância de  $n_{bv}$ .

#### 4.1.1.3 HADCP

Seguindo a mesma nomenclatura até o momento, busca-se um modelo de medição a ser utilizado pelo EKF modelado no espaço de estados de erro. Conforme modelagem utilizada em [Hegrenaes e Berglund 2009], [Hegrenaes e Hallingstad 2011], o erro de medição da velocidade  $\delta \mathbf{z}_w$  utilizando o HADCP é dado por:

$$\delta \mathbf{z}_w = \mathbf{v}^N - \mathbf{v}_{INS}^N \quad (4.38)$$

onde  $\mathbf{v}_{INS}^N$  corresponde à saída do bloco INS correspondendo ao vetor velocidade do veículo expresso no referencial de navegação. Considerando um ambiente de navegação com correntes de água, tem-se:

$$\mathbf{v}^N = \mathbf{v}_w^N + \mathbf{R} \mathbf{v}_r^B \quad (4.39)$$

onde  $\mathbf{v}^N$  é a velocidade do veículo no referencial de navegação,  $\mathbf{v}_w^N$  é a velocidade da água (correntes) em relação a Terra expressa no referencial de navegação e  $\mathbf{v}_r^B$  ( $\mathbf{v}_{HADCP}$ ) é a velocidade relativa, ou seja, a velocidade do veículo em relação às correntes de água no referencial do corpo, cujo valor é medido pelo HADCP, enquanto a matriz de rotação  $\mathbf{R}$  provém do INS.

Substituindo 4.39 em 4.38, chega-se a seguinte expressão para a medição residual:

$$\delta \mathbf{z}_w = \mathbf{v}_w^N + \mathbf{R} \mathbf{v}_r^B - \mathbf{v}^N \quad (4.40)$$

onde a indicação de INS foi suprimida, sabendo-se que o mesmo mede a

velocidade do veículo em relação ao referencial NED. O termo  $\mathbf{v}_w^N$ , referente à velocidade das correntes de água em relação ao referencial NED, terá seu valor estimado pelo sistema de navegação com o EKF. Inicialmente, o valor atribuído a essa grandeza é zero, o que representa a melhor estimativa inicial (*a priori*) sobre seu valor nominal.

Considerando as fontes de erro relacionadas ao HADCP ( $\Delta\mathbf{v}_w^N$  e  $\Delta\mathbf{v}_r^B$ ) e o erro do INS ( $\delta\mathbf{v}^N$ ), que corresponde a um dos estados no EKF descrito anteriormente, tem-se:

$$\delta\mathbf{z}_w = \underbrace{(\bar{\mathbf{v}}_w^N + \Delta\mathbf{v}_w^N)}_{=0} + (I_{3 \times 3} + [\delta\lambda_{\times}]) \bar{\mathbf{R}} (\bar{\mathbf{v}}_r^B + \Delta\mathbf{v}_r^B) - (\bar{\mathbf{v}}^N + \delta\mathbf{v}^N) \quad (4.41)$$

Utilizando a equação 4.39, descartando os termos  $[\delta(\cdot)_{\times}] \delta(\cdot)$  para pequenos erros de orientação e considerando a estimativa inicial para  $\mathbf{v}_w^N$ , após algumas manipulações algébricas em 4.41, chega-se a:

$$\delta\mathbf{z}_w = \Delta\mathbf{v}_w^N + \bar{\mathbf{R}} \Delta\mathbf{v}_r^B - \delta\mathbf{v}^N - [\bar{\mathbf{v}}_{\times}^N] \delta\lambda \quad (4.42)$$

onde os valores nominais  $\bar{\mathbf{R}}$  e  $\bar{\mathbf{v}}^N$  são substituídos pelas melhores estimativas *a priori*, ou seja, a melhor estimativa antes da correção realizada pelo EKF.

Os valores de erro  $\Delta\mathbf{v}_w^N$  e  $\Delta\mathbf{v}_r^B$  são modelados como uma soma de ruídos autocorrelacionados com ruído branco gaussiano de média zero. Portanto:

$$\Delta\mathbf{v}_w^N = \mathbf{b}_{v_w^N} + n_{v_w^N} \quad (4.43)$$

$$\Delta\mathbf{v}_r^B = \mathbf{b}_{v_r^B} + n_{v_r^B} \quad (4.44)$$

O ruído autocorrelacionado é modelado como um processo de Markov de média zero de primeira ordem [Simon 2006]. Logo:

$$\dot{\mathbf{b}}_{v_w^N} = -\mathbf{T}^{-1} \mathbf{b}_{v_w^N} + n_{bv_w^N} \quad (4.45)$$

$$\dot{\mathbf{b}}_{v_r^B} = -\mathbf{T}^{-1} \mathbf{b}_{v_r^B} + n_{bv_r^B} \quad (4.46)$$

onde ambos termos  $\dot{\mathbf{b}}$  passariam a pertencer às variáveis de estado do EKF aumentado.

Por fim, dada a estimativa *a priori*  $\mathbf{v}_w^N = 0$ , tem-se que  $\mathbf{b}_{v_w^N}$ , que é a estimativa de  $\Delta\mathbf{v}_w^N$ , quando multiplicado por  $(-1)$ , representará a nova estimativa da velocidade nominal das correntes de água.

Vale destacar que existem inúmeras alternativas para a modelagem da

correlação destacada nas equações 4.45, 4.46 e 4.37 dentre elas o *random walk* (RW), que equivale a um processo de Markov de primeira ordem. Entretanto, no RW a incerteza cresce indefinidamente com o tempo enquanto, especificando  $\mathbf{T}(\cdot)$ , é possível limitar a amplitude dessa incerteza em regime permanente.

#### 4.1.1.4 Sensores de Profundidade e Orientação

As expressões que representam os modelos de medição para os sensores de profundidade (pressão) e guinada (*heading sensor*) são mais simples por não envolverem em geral mudanças de referencial. Conforme desenvolvido em [Lee et al. 2007], assumindo que a posição dos mesmos coincide com o centro de gravidade do veículo e que os *bias* de ambos é conhecido, as expressões para os erros de profundidade  $\delta z_d$  e de guinada  $\delta z_\psi$ :

$$\delta z_d = (d + n_d) - \hat{d} = (d + n_d) - (d + \delta d) = -\delta d + n_d \quad (4.47)$$

$$\delta z_\psi = (\psi + n_\psi) - \hat{\psi} = (\psi + n_\psi) - (\psi + \delta \psi) = -\delta \psi + n_\psi \quad (4.48)$$

onde  $\hat{d}$  e  $\hat{\psi}$  são as estimativas de profundidade e guinada do veículo respectivamente e ambos  $n_d$  e  $n_\psi$  são modelados como ruídos brancos gaussianos de média zero.

### 4.1.2 Propagação no tempo e Correção

De acordo com a formulação do filtro de Kalman estendido, em sua implementação discreta, discutido na seção 4.1, e partindo do vetor de estados de erro definidos pelas equações 4.17 a 4.20, representado por:

$$\delta \mathbf{x} = [\delta \mathbf{p}^T \quad \delta \mathbf{v}^T \quad \delta \lambda^T \quad \delta \mathbf{b}_a^T \quad \delta \mathbf{b}_\omega^T]^T. \quad (4.49)$$

tem-se:

$$\delta \mathbf{x}_{k+1}^- = \Phi_k \delta \mathbf{x}_k^+ \quad (4.50)$$

$$\mathbf{P}_{k+1}^- = \Phi_k \mathbf{P}_k^+ \Phi_k^T + \mathbf{Q}_{k+1} \quad (4.51)$$

onde a matriz  $Q_k$  quantifica a matriz de ruído do processo no tempo discreto  $k$  através de  $Q_k = Q\Delta T$ , onde  $\Delta T = t_{k+1} - t_k$  corresponde ao intervalo de amostragem.

Os sensores detalhados nas secções anteriores apresentam taxas de atualização diferentes, sendo, por exemplo, a leitura dos sonares de localização muito mais lentos que as leituras dos sensores de profundidade e orientação. No instante em que uma medição válida está disponível, é possível corrigir a estimativa inicial  $\delta \mathbf{x}_{k+1}^-$  e  $\mathbf{P}_{k+1}^-$  através das seguintes expressões:

$$\mathbf{K}_{k+1} = \mathbf{P}_{k+1}^- \mathbf{H}_{k+1}^T (\mathbf{H}_{k+1} \mathbf{P}_{k+1}^- \mathbf{H}_{k+1}^T + \mathbf{S}_{k+1})^{-1} \quad (4.52)$$

$$\delta \mathbf{z}_{k+1} = \mathbf{z}_{k+1} - \mathbf{h}(\hat{\mathbf{x}}_{k+1}^-) \quad (4.53)$$

$$\delta \mathbf{x}_{k+1}^+ = \delta \mathbf{x}_{k+1}^- + \mathbf{K}_{k+1} (\delta \mathbf{z}_{k+1} - \mathbf{H}_{k+1} \delta \mathbf{x}_{k+1}^-) \quad (4.54)$$

$$\mathbf{P}_{k+1}^+ = (\mathbf{I} - \mathbf{K}_{k+1} \mathbf{H}_{k+1}) \mathbf{P}_{k+1}^- \quad (4.55)$$

onde  $\mathbf{K}_k$  refere-se ao ganho de Kalman,  $\mathbf{S}_k$  é matriz de covariância do ruído de medição no tempo discreto ( $\mathbf{S}_k = \frac{\mathbf{S}}{\Delta T}$ ),  $\mathbf{P}_k$  é a matriz de covariância do erro de predição,  $\mathbf{h}(\hat{\mathbf{x}}_{k+1}^-)$  representa o valor predito das medições dos sensores a partir das estimativas iniciais do vetor de estados do veículo e  $\mathbf{H}_k$  o jacobiano dessas expressões em relação às variáveis de estado no espaço de erro.

Vale ressaltar que, a cada novo valor de  $\delta \mathbf{x}_{k+1}^+$ , a respectiva estimativa da grandeza  $\mathbf{x}_{k+1}^-$  é corrigida por:

$$\hat{\mathbf{x}}_{k+1}^+ = \hat{\mathbf{x}}_{k+1}^- + \delta \mathbf{x}_{k+1}^+ \quad (4.56)$$

Nessa formulação, a melhor estimativa inicial para as variáveis de estado é  $\delta \mathbf{x} = 0$ , não sendo mais necessária a equação 4.50, portanto, as variáveis de estado são propagadas como uma quantidade nula até ocorrência de medição dos sensores externos. Para a correção dos erros nos ângulos de orientação é necessário corrigir a matriz de rotação utilizada a cada intervalo de tempo  $k$ :

$$\mathbf{R}_k^{k+1}(\delta \lambda_{k+1}^+) = \mathbf{I}_{3 \times 3} + \frac{\sin \|\delta \lambda_{k+1}^+\|}{\|\delta \lambda_{k+1}^+\|} [\delta \lambda_{k+1}^+ \times] + \quad (4.57)$$

$$+ \frac{1 - \cos \|\delta \lambda_{k+1}^+\|}{\|\delta \lambda_{k+1}^+\|^2} [\delta \lambda_{k+1}^+ \times]^2$$

$$\mathbf{R}_{k+1}^+ = \mathbf{R}_{k+1}^T(\delta \lambda_{k+1}^+) \mathbf{R}_{k+1}^- \quad (4.58)$$

onde  $\mathbf{R}_k = R/\delta t$  é a matriz de covariância do erro de medição em tempo

discreto e  $\delta t$ , a taxa de medição da grandeza correspondente.

### 4.1.3 Suposições Estatísticas

Expressando resumidamente todo o ruído do processo pela variável  $\rho_k$  e ruído de medição pela variável  $\vartheta_k$ , conforme 4.4 e 4.4, o desenvolvimento mostrado assume as seguintes propriedades estatísticas:

- $\mathbf{x}_0, \rho_0, \rho_1, \dots, \vartheta_0, \vartheta_1, \dots$ , são conjuntamente Gaussianos e independentes;
- $\rho_k$ , são i.i.d<sup>1</sup> com  $E[\rho_k] = 0$ ;
- $\vartheta_k$ , são i.i.d  $E[\vartheta_k] = 0$ ;
- As matrizes  $\mathbf{Q}$  e  $\mathbf{S}$  são positivas definidas e limitadas ( $\mathbf{Q} > 0$ ,  $\mathbf{S} > 0$ );
- Propriedade de processo de Markov: o processo  $\mathbf{x}$  é definido como um processo de Markov, ou seja, conhecendo as variáveis de estado num instante  $k$ , o conhecimento de  $\mathbf{x}_{k-1}, \dots, \mathbf{x}_0$  não fornece informações adicionais sobre  $\mathbf{x}_{k+1}$ . Assim:

$$\mathbf{x}_{k+1} | \mathbf{x}_0, \dots, \mathbf{x}_k = \mathbf{x}_{k+1} | \mathbf{x}_k$$

### 4.1.4 Propriedades estatísticas

Com base nos trabalhos relacionados e nos manuais de fabricantes, os ruídos das medições realizadas pelo IMU estão distribuídos de acordo com  $\mathbf{N}(0, \sigma_a^2 \mathbf{I})$ ,  $\mathbf{N}(0, \sigma_{b_a}^2 \mathbf{I})$ ,  $\mathbf{N}(0, \sigma_{\omega}^2 \mathbf{I})$ ,  $\mathbf{N}(0, \sigma_{b_{\omega}}^2 \mathbf{I})$ , cujos valores estão detalhados na tabela 4:

IMU/INSI (100Hz)	Variância Ruído( $\sigma$ )
$\sigma_a^2$	$(0.01m(s\sqrt{s}))^2$
$\sigma_{b_a}^2$	$(1 \times 10^{-4}m(s^2\sqrt{s}))^2$
$\sigma_{\omega}^2$	$(1 \times 10^{-4}rad/\sqrt{s})^2$
$\sigma_{b_{\omega}}^2$	$(1 \times 10^{-6}rad/(s\sqrt{s}))^2$

Tabela 4: Dados de variância das grandezas medidas pelo IMU/INS

<sup>1</sup>i.i.d.: Independentes e Igualmente Distribuídas.

Para os sensores auxiliares, o ruído de medição também está distribuído de acordo com  $\mathbf{N}(0, \sigma_t^2 \mathbf{I})$ ,  $\mathbf{N}(0, \sigma_v^2 \mathbf{I})$ ,  $\mathbf{N}(0, \sigma_w^2 \mathbf{I})$ ,  $\mathbf{N}(0, \sigma_z^2 \mathbf{I})$ ,  $\mathbf{N}(0, \sigma_\psi^2 \mathbf{I})$ , cujos valores estão discriminados na Tabela 5.

Sensor	Taxa de Atualização	Variância Ruído( $\sigma$ )
$\sigma_t^2$	1Hz	$(1ms)^2$
$\sigma_v^2$	10Hz	$(0.03m/s)^2$
$\sigma_w^2$	7Hz	$(0.03m/s)^2$
$\sigma_d^2$	10Hz	$(194Pa)^2$
$\sigma_\psi^2$	10Hz	$(0.1rad/s)^2$

Tabela 5: Dados de variância das grandezas medidas pelos sensores externos

Para os valores de variância mostrados na Tabela 5, o subscrito  $t$  refere-se ao tempo de chegada do sinal acústico,  $v$  à velocidade absoluta,  $w$  à velocidade relativa, obtidas com o DVL e o HADCP respectivamente,  $d$  à profundidade com o sensor de pressão e  $\psi$  à guinada do veículo através da bússola ou magnetômetro.

#### 4.1.5 Limitações

Como mencionado, não obstante ser extensivamente utilizado como solução de integração ou associação de dados para estimação de estados, o filtro de Kalman apresenta limitações no que se refere à robustez. Esse fato decorre dos seguintes fatores [Simon 2006]:

- Necessidade de conhecer a média e a correlação dos ruídos de medição ( $n_{[.]}$ ) e do processo ( $n_{[.]}$ ) em cada instante de tempo;
- Necessidade de conhecer as matrizes de covariância do ruído de medição  $\mathbf{S}_k$  e do processo  $\mathbf{Q}_k$ . Como ambos termos constituem parâmetros de projeto do filtro, eventuais erros nessas matrizes podem levar a instabilidades na solução;
- O filtro de Kalman é um estimador de mínima variância somente se o ruído for Gaussiano, caso contrário, o filtro é o estimador linear de mínima variância;
- Para situações onde se deseja minimizar outras funções custo, que não seja o desvio padrão do erro de estimação, como o erro de estimação de pior caso *worst-case estimation error*, o filtro de Kalman não será a melhor escolha;

- Necessidade de conhecer bem tanto a matriz de propagação dos estados  $\Phi_k$  como o modelo de medição  $\mathbf{H}$ , sem os quais o processo de estimação e a correção ficam comprometidos;
- Para o caso de linearização do modelo do processo e/ou modelo de medição, como o ocorre na versão estendida do filtro, erros associados à propagação das estatísticas do sistema podem não refletir o que ocorre de fato.

Várias soluções alternativas à utilização do filtro de Kalman estendido, como as formulações utilizando ( $H_\infty$ ) e filtros não parametrizados como *Unscented Kalman Filter* [Julier, Uhlmann e Durrant-Whyte 1995], [He et al. 2009], *Particle Filter* [Cheng e Crassidis 2004], também são explorados para os sistemas de navegação e contornam alguns dos problemas associados ao EKF.

#### 4.1.6 Simulação

A fim de avaliar o que foi exposto anteriormente, na sequência apresenta-se uma simulação em ambiente Matlab<sup>®</sup> utilizando o modelo de veículo autônomo (INFANTE) desenvolvido em [Encarnação e Pascoal 2000]. A navegação é realizada utilizando o sistema LBL com quatro emissores em posição conhecidas. Todos os ruídos de medição são supostamente conhecidos e atendem aos valores da tabela 5. O período de amostragem é de 10 ms para o sistema inercial e a cada 10 amostras de tempo ocorre uma medição acústica voltada para a localização do veículo. O veículo é considerado equipado somente com o sistema de localização acústico e um sensor de profundidade, usualmente preciso. Nas simulações o veículo desloca-se a uma velocidade de 3 *knots* ou aprox. 1,5 m/s.

No caso mostrado na figura 28 ratifica-se a dependência de um sensoriamento externo por parte do sistema de navegação inercial tendo em vista o erro cumulativo, propagado ao longo do tempo, devido aos desvios inerentes aos sensores inerciais.

As figuras 27(a) e (b) atestam quanto à importância do processo de fusão de dados para a melhoria das estimativas dos estados do veículo advindas do sistema de navegação inercial. A ausência do sensoriamento externo levaria ao acúmulo de erros que, quando não são compensados, inviabilizam uma navegação de tempo mais longo.

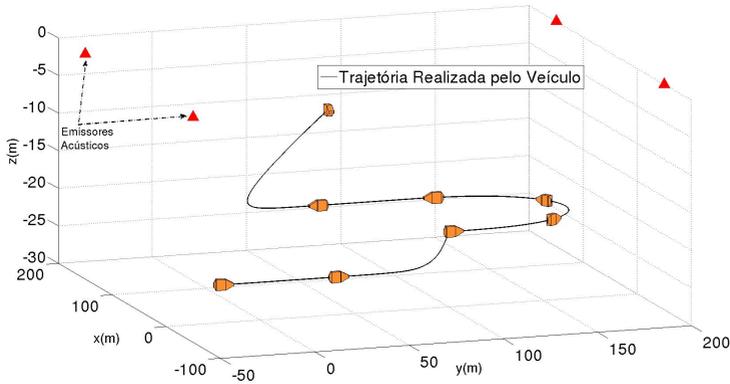


Figura 27: Trajetória realizada pelo veículo e posicionamento dos quatro emissores acústicos do sistema LBL.

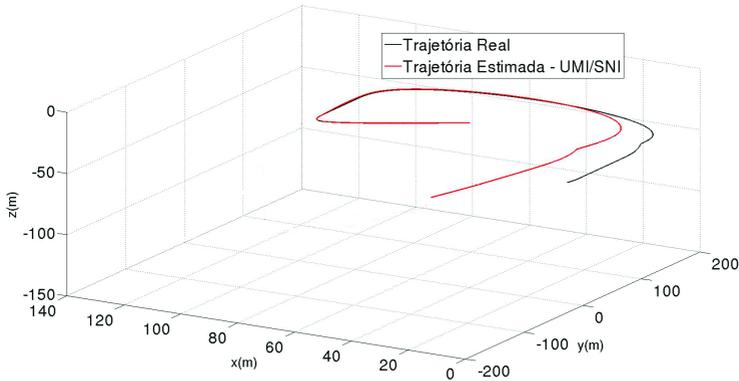
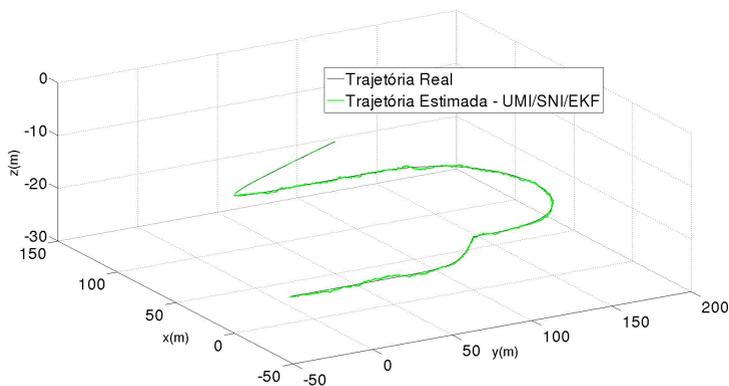


Figura 28: Trajetória do veículo estimada com o conjunto IMU/INS. Nenhuma correção foi efetuada nos desvios inerentes às medições desses sensores.

## 4.2 CONCLUSÃO

Embora apresente algumas limitações quanto ao seu uso, como discutido ao longo desse capítulo, o filtro de Kalman estendido ainda é amplamente utilizado para o processo de fusão dos dados e correção da estimativa



(a) Trajetória real e estimada do veículo.

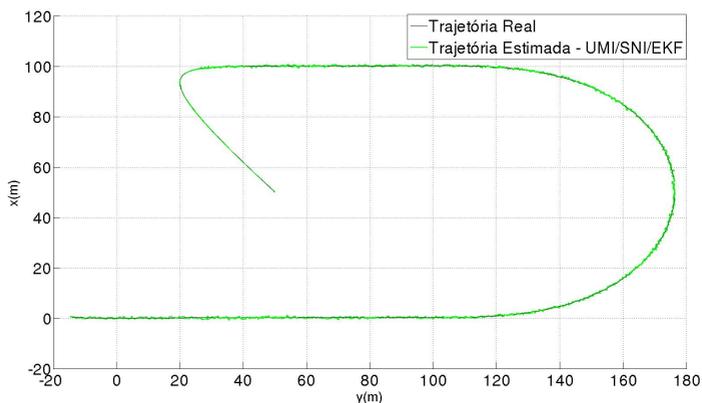
(b) Trajetória real e estimada do veículo (plano  $xy$ ).

Figura 29: Trajetória estimada com o conjunto IMU/INS e os sensores externos auxiliares. O filtro de Kalman estendido foi utilizado no processo de fusão de dados.

dos estados do sistema. Soluções que visam a melhoria do filtro quanto a sua robustez são estudadas há várias décadas e discutidas em trabalhos como em [Kun, Shao-Ji e Yong-jie 2007], [Mehra 1970], [Mehra 1972], [Zhou e Frank 1972], o que atesta sua ampla aceitação nos processos de estimação.

Algumas considerações quanto à implementação do algoritmo podem

ser destacadas: (i) a matriz de covariância do erro de predição ( $P_k$ ) deve ser garantida simétrica, definida positiva, o que pode ser conseguido com pequenos ajustes como  $P_k = \frac{1}{2}(P_k + P_k')$ , (ii) antes da correção dos ângulos de orientação, tomados a partir da matriz de rotação, faz-se necessário sua normalização para garantir  $\det = 1$ .

## 5 FUNDAMENTOS TEÓRICOS DOS MODELOS BASEADOS EM FUNÇÕES KERNEL

### 5.1 INTRODUÇÃO

Nesse capítulo, os fundamentos teóricos dos modelos baseados em funções kernel utilizados nesse trabalho serão apresentados. O objetivo é compreender as bases teóricas, as principais características e os parâmetros a serem ajustados nesses modelos. Na primeira parte, o capítulo discorre sobre os modelos autoassociativos baseados em funções kernel utilizados na etapa de correção das medições acústicas. No segundo momento, o modelo utilizado como descritor de dados para a análise das medições será apresentado bem como alguns exemplos que ilustram o efeito das diferentes escolhas em seus parâmetros.

### 5.2 MODELOS AUTOASSOCIATIVOS

Os modelos autoassociativos são amplamente utilizados para a descrição de processos a partir do mapeamento do espaço de entrada nele mesmo. Esses modelos são especialmente interessantes devido às possibilidades de controle da complexidade desse mapeamento, através, por exemplo, da imposição de funções de restrição e funções custo a serem minimizadas. Essencialmente, os modelos buscam capturar ou descrever o comportamento de um determinado processo. A formulação, bem como a notação utilizada a seguir, baseia-se na modelagem apresentada em [Specht 1991] no contexto teórico das redes neurais genéricas.

Desse modo, considere  $f(\mathbf{z}, y)$  uma função densidade de probabilidade conjunta de uma variável aleatória vetorial  $\mathbf{z} \in \mathbb{R}^{1 \times p}$  e uma variável aleatória escalar  $y$ . Por definição, o valor esperado de  $y$  condicionado a uma observação  $\mathbf{z}$  de um conjunto de observações  $\mathbf{Z} \in \mathbb{R}^{n \times p}$  é dado por:

$$E[y|\mathbf{z}] = \frac{\int_{-\infty}^{\infty} y f(\mathbf{z}, y) dy}{\int_{-\infty}^{\infty} f(\mathbf{z}, y) dy} \quad (5.1)$$

A expressão 5.1 é definida como a regressão de  $y$  baseado em  $\mathbf{z}$ , onde se observa que sua determinação requer o conhecimento de  $f(\mathbf{z}, y)$ , usualmente desconhecido. Uma das formas de obter essa função distribuição é, partindo de observações de  $\mathbf{z}$ , através dos estimadores propostos por Parzen (*Parzen Kernel Density Estimation*) [Parzen 1962]. Assim, considerando  $n$

observações de  $\mathbf{z}$  com dimensão  $p$  e de  $y$ , o estimador  $f(\mathbf{z}, y)$  para um dado  $(\mathbf{z}, y)$ , definido como  $\hat{f}(\mathbf{z}, y)$ , pode ser obtido a partir das  $n$  observações por:

$$\hat{f}(\mathbf{z}, y) = \frac{1}{(2\pi)^{\frac{(p+1)}{2}} \sigma^{p+1}} \cdot \frac{1}{n} \sum_{i=1}^n \exp \left[ -\frac{(\mathbf{z} - \mathbf{Z}_i)^T (\mathbf{z} - \mathbf{Z}_i)}{2\sigma^2} \right] \cdot \exp \left[ -\frac{(y - Y_i)^2}{2\sigma^2} \right] \quad (5.2)$$

onde  $\mathbf{Z}_i$  e  $\mathbf{Y}_i$  representam observações  $i$  das  $n$  observações de  $\mathbf{z}$  e  $y$  respectivamente, e  $\mathbf{z}$  e  $y$  correspondem à ocorrências das variáveis aleatórias  $\mathbf{z}$  e  $y$  respectivamente.

A expressão indica a estimativa da função  $f(\mathbf{z}, y)$  a partir do somatório das probabilidades das observações  $(\mathbf{z}, y)$  com desvio padrão  $\sigma$  em relação a cada amostra no conjunto  $(\mathbf{Z}, \mathbf{Y})$ . Substituindo 5.2 em 5.1, obtém-se a expressão para a regressão de  $y$  em função de  $\mathbf{z}$ ,  $\hat{y}(\mathbf{z})$ :

$$\hat{y}(\mathbf{z}) = \frac{\sum_{i=1}^n \mathbf{Y}_i \exp\left(\frac{-d_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(\frac{-d_i^2}{2\sigma^2}\right)} \quad (5.3)$$

onde a função  $d_i$  refere-se à distância Euclideana entre cada observação  $\mathbf{Z}_i$  e os valores  $\mathbf{Z}$ :

$$d_i^2 = (\mathbf{z} - \mathbf{Z}_i)^T (\mathbf{z} - \mathbf{Z}_i). \quad (5.4)$$

A expressão 5.3 afirma que a saída estimada  $\hat{y}(\mathbf{z})$  é resultado de um média ponderada de todas as saídas observadas  $\mathbf{Y}_i$ , cujos pesos são funções exponenciais de acordo com as distâncias Euclidianas entre  $\mathbf{Z}_i$  e  $\mathbf{Z}$ . Vale ressaltar que os estimadores de funções densidade de probabilidade como 5.2 são escolhas apropriadas quando a função original  $f$  é contínua e suave, ou seja, as derivadas parciais de  $f$  avaliadas em qualquer  $\mathbf{z}$  são pequenas [Parzen 1962, Specht 1991]. Além disso, o comportamento do valor de  $\sigma$  deve ser uma função decrescente de  $n$ , ou seja:

$$\lim_{n \rightarrow \infty} \sigma(n) = 0 \quad (5.5)$$

$$\lim_{n \rightarrow \infty} n\sigma(n) = \infty. \quad (5.6)$$

A condição 5.5 garante localidade, ou seja, os estimadores na forma expressa em 5.2 convergem assintoticamente para a verdadeira função densidade de probabilidade  $f(\mathbf{z}, y)$  à medida que o número de exemplos de treinamento cresce. Já a condição 5.6 garante que o número de exemplos de treinamento efetivamente cresce. Com respeito à variável  $\sigma$ , valores elevados desse parâmetro forçam a função distribuição estimada ser mais suave, ao passo que valores menores, apesar de permitir formas não Gaussianas para a função estimada, tornam a mesma bastante sensível a exemplos errôneos (ruidosos) presentes em  $\mathbf{Z}$ .

### 5.2.1 Mapeamentos Autoassociativos

Nos mapeamentos autoassociativos, o espaço de entrada e de saída são os mesmos. Assim, estendendo a análise anterior para variáveis de saída vetoriais onde  $\mathbf{y} \in \mathbb{R}^{1 \times q}$ , tem-se:

$$E[\mathbf{z}|\mathbf{Z}] = \int_{-\infty}^{\infty} \mathbf{z}f(\mathbf{z}|\mathbf{Z})d\mathbf{z} \quad (5.7)$$

onde a representação do vetor de saída  $\mathbf{y}$  foi momentaneamente substituída por  $\mathbf{z}$  para destacar que o vetor de saída está definido no mesmo espaço do vetor de entrada da matriz  $\mathbf{Z}$ . Definindo  $\Phi(\mathbf{z} - \mathbf{Z}_i) = \exp(-\frac{d_i^2}{2\sigma^2})$ , pode-se reescrever 5.3 resumidamente como:

$$\hat{\mathbf{z}} = \frac{\sum_i \Phi(\mathbf{z} - \mathbf{Z}_i)\mathbf{Z}_i}{\sum_i \Phi(\mathbf{z} - \mathbf{Z}_i)}. \quad (5.8)$$

Por fim, vale ressaltar que a função kernel Gaussiana, utilizada em 5.8, pode ser substituída por outras funções, definidas com janelas de Parzen [Bishop 1995].

### 5.2.2 Regressão Kernel AutoAssociativa

A regressão kernel autoassociativa ou AAKR (*Autoassociative Kernel Regression*) é uma técnica de modelagem não paramétrica baseada em similaridades onde se procura comparar um vetor de dados de entrada com um histórico de treinamento a fim de representar o processo por trás dessas informações. Sua fundamentação teórica está pautada na descrição da secção

anterior onde, a partir de exemplos ou observações idealmente livres de desvios ou falhas, estima-se a saída corrigida como uma ponderação dos exemplos de treinamento. Desse modo, essa solução será explorada no módulo de correção, mostrado na figura 18, para corrigir eventuais desvios nos tempos de chegada da onda sonora no sistema LBL de localização de veículos.

Essa técnica tem sido frequentemente utilizada como um eficiente método de análise e detecção de falhas em ambientes industriais [Hines e Garvey 2008, Henkel 2011]. Sua aplicação estende-se principalmente ao monitoramento de estruturas complexas como plantas de usinas nucleares, onde a complexidade dos fenômenos observados e as não linearidades envolvendo as variáveis analisadas tornam o desenvolvimento de modelos uma tarefa extremamente difícil.

Mesmo considerando um grande conjunto de dados de treinamento, busca-se selecionar uma amostra de dados que seja representativa do processo em questão, minimizando o custo computacional. Exemplos de técnicas aplicadas a essa seleção de dados são *fuzzy c-means* [Tyagi, Cai e Manry 2011], *min-max* [Visalakshi e Suguna 2009].

O algoritmo aplicado no AAKR consiste na estimação de estados através da comparação da saída no instante  $k$  ( $\mathbf{y}_{1 \times p}^k$ ) com um banco de dados representado por um histórico de  $m$  medições  $\mathbf{Z}_{m \times p}$  idealmente livres de perturbações.

$$\mathbf{Z} = \begin{bmatrix} \mathbf{Z}_1 \\ \mathbf{Z}_2 \\ \vdots \\ \mathbf{Z}_m \end{bmatrix} = \begin{bmatrix} z_{11} & z_{12} & \cdots & z_{1p} \\ z_{21} & z_{22} & \cdots & z_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ z_{m1} & z_{m2} & \cdots & z_{mp} \end{bmatrix} \quad (5.9)$$

A base de dados é então composta de  $m$  medições com  $p$  sinais ou variáveis, ou seja,  $z_{ij}$  representa a  $i^{\text{ésima}}$  observação da  $j^{\text{ésima}}$  variável. A comparação entre a saída  $\mathbf{y}$  e a matriz  $\mathbf{Z}$  é obtida calculando-se uma medida de similaridade que resulta num vetor de pesos  $\mathbf{w} \in \mathbb{R}^{m \times 1}$ .

Assim, a saída estimada  $\hat{\mathbf{z}}$  é dada por:

$$\hat{\mathbf{z}} = \bar{\mathbf{w}}^T \mathbf{Z} \quad \text{com} \quad \bar{\mathbf{w}} = \mathbf{w} / \|\mathbf{w}\|_1 \quad (5.10)$$

Os pesos  $w_i$  de  $\mathbf{w}$  são calculados utilizando a seguinte expressão:

$$w_i(\mathbf{y}, \mathbf{Z}_i) = \frac{1}{\sqrt{2\pi h^2}} \exp\left(-\frac{\|\mathbf{y} - \mathbf{Z}_i\|_2^2}{h^2}\right) \quad (5.11)$$

onde  $h$  corresponde à largura de banda do kernel. Desse modo, os parâmetros a serem otimizados no AAKR são a matriz  $\mathbf{Z}$  e o parâmetro  $h$ .

A largura de banda ( $h$ ), assim como o parâmetro  $\sigma$  em 5.3, refere-

se a um parâmetro de suavização. Observando 5.11, nota-se que valores muito elevados de  $h$  levam a uma estimativa que corresponde a uma média dos valores de treinamento, enquanto valores muito pequenos de  $h$  levam a uma saída  $\hat{\mathbf{z}}$  polarizada pela observação  $\mathbf{y}$  mais próxima dos exemplos em  $\mathbf{Z}$ . A determinação desse parâmetro é realizada em geral via procedimentos de busca entre um conjunto de valores (*grid-search*) e pela avaliação de métricas de desempenho na estimação de valores conhecido previamente (*k-fold cross validation, leave-one-out*), como descrito em [An, Heo e Chang 2011].

Além da distância Euclideana ( $d_E$ ), outras distâncias podem ser empregadas como, por exemplo, a distância de Mahalanobis [Mahalanobis 1936], comumente utilizada em métodos de classificação e análise de grupos:

$$d_M = \sqrt{(\mathbf{y} - \mathbf{Z}_i)^T \mathbf{M} (\mathbf{y} - \mathbf{Z}_i)} \quad (5.12)$$

onde

$$\mathbf{M} = \begin{bmatrix} m_1 & \dots & 0 \\ & m_j & \\ 0 & \dots & m_p \end{bmatrix} \quad (5.13)$$

Com essa abordagem, é possível contabilizar o efeito de pesos diferentes dados aos diversos sensores no cálculo da distância, ou seja, através dos fatores  $m_j$  pode-se deixar o cálculo da distância insensível a determinado dado de entrada. Outra variação no cálculo das distância entre a matriz de exemplos e o vetor de entrada é apresentada em [Garvey e Hines 2006], onde a maior distância Euclideana entre o vetor de entrada e o  $j$ -ésimo vetor na memória é removido. Analiticamente, o cálculo dessa distância Euclideana robusta ( $d_{ER}$ ) é alterado para:

$$d_{ER}^i = \sqrt{\sum_{j=1}^p (y_{1j}^k - z_{ij})^2 - \max_{j=1, \dots, p} [(y_{1j}^k - z_{ij})]} \quad (5.14)$$

### 5.2.3 Normalização

Uma etapa de pré processamento dos dados é fundamental antes da sua utilização para as funções de regressão, principalmente quando um número limitado de exemplos é utilizado. Essa etapa consiste na normalização dos dados, de modo a possuírem amplitudes dentro de uma mesma faixa de valores ou a mesma variância. A justificativa para isso está no fato da função densidade de probabilidade verdadeira estar sendo estimada com uma função

kernel que possui a mesma largura de banda em todas as direções [Specht 1991].

### 5.2.4 Métricas de Desempenho

O desempenho dos métodos de monitoramento *on-line* é medido fundamentalmente utilizando-se três critérios:

1. Precisão: capacidade de um determinado modelo prever o valor medido por um determinado sensor ( $j$ ). A expressão para o cálculo dessa métrica é dada pelo erro quadrático médio (EQM). Assim, considerando  $n$  leituras  $y \in \mathbb{R}^{1 \times p}$ , tem-se:

$$\text{EQM}_j = \frac{1}{n} \sum_{i=1}^n (\hat{y}_{ij} - y_{ij})^2, \text{ para } j = 1 \dots p. \quad (5.15)$$

Alternativamente, o erro quadrático médio cruzado (EQM-C) pode ser calculado pela seguinte expressão:

$$\text{EQM-C} = \frac{1}{n} \sum_{i=1}^n r_i \text{ para } i = 1 \dots n, \quad (5.16)$$

onde:

$$r_i = \frac{1}{p} [\hat{\mathbf{y}}_i - \mathbf{y}_i] [\hat{\mathbf{y}}_i - \mathbf{y}_i]^T. \quad (5.17)$$

2. Auto-Sensibilidade e Sensibilidade Cruzada: também denominada de robustez, refere-se à capacidade de realizar previsões corretas mesmo quando algum sinal é corrompido por algum tipo de falha. Ou seja, um modelo robusto é definido com um modelo que produz pequenas alterações em sua saída para pequenos erros em sua entrada. Para avaliar essa métrica, é necessário analisar inicialmente a resposta do modelo para entradas não corrompidas e, em seguida, a resposta da previsão quando ocorrem desvios artificiais nos dados de entrada.

No caso da auto-sensibilidade, a métrica envolve as seguintes variáveis: previsão de saída  $j$  sem ocorrência de desvios  $\hat{y}_{1j}$ , previsão da mesma saída com ocorrência de desvios  $\hat{y}_{1j}^{desvio}$ , variável de entrada sem desvio  $x_{1l}$  e entrada com desvio  $x_{1l}^{desvio}$ . Para  $n$  leituras, a matriz de sensibilidade é calculada através da seguinte expressão:

$$S_{lj} = \frac{1}{n} \sum_{k=1}^n \left| \frac{\hat{y}_{ij}^{desvio} - \hat{y}_{ij}}{x_{il}^{desvio} - x_{il}} \right| \quad (5.18)$$

Como brevemente discutido, o parâmetro  $h$  em 5.11, que reflete a complexidade do modelo utilizado, para sinais de entrada correlacionados e quando escolhido próximo a zero, pode amplificar o ruído de entrada aumentando a variância da estimação (*overfitting*) e, portanto, diminuir a robustez. Essa relação entre desvio e variância nos estimadores é discutida na sequência.

### 5.2.5 Bias e Variância

A relação entre variância e bias reflete a complexidade em ajustar um modelo a um conjunto de dados. Considerando um conjunto de treinamento representado pela matriz  $\mathbf{Z}$ , busca-se levantar um modelo com uma boa capacidade de generalização de modo a descrever adequadamente o processo por trás das observações realizadas.

O erro quadrático médio mostrado em 5.15 é uma métrica de fundamental importância para a análise de desempenho, pois a mesma está diretamente relacionada ao problema do grau ajuste do modelo ao conjunto de treinamento e ao sistemático desvio entre o valor real e o valor predito, que reflete na incapacidade do modelo representar o processo em questão. Analisando uma saída  $j$  e retomando a equação 5.15, avalia-se o seu valor esperado em todo o conjunto de treinamento de tamanho  $n$  como segue:

$$\begin{aligned} E[EQM] &= E \left[ \frac{1}{n} \sum_{i=1}^n (\hat{y}_{ij} - y_{ij})^2 \right] = & (5.19) \\ &= E \left[ \frac{1}{n} \sum_{i=1}^n (\hat{y}_{ij} - E[\hat{y}_{ij}] + E[\hat{y}_{ij}] - y_{ij})^2 \right] = \\ &= E \left[ \frac{1}{n} \sum_{i=1}^n (\hat{y}_{ij} - E[\hat{y}_{ij}])^2 \right] + E \left[ \frac{1}{n} \sum_{i=1}^n (E[\hat{y}_{ij}] - y_{ij})^2 \right] + \\ &+ E \left[ \frac{1}{n} \sum_{i=1}^n 2(\hat{y}_{ij} - E[\hat{y}_{ij}])(E[\hat{y}_{ij}] - y_{ij}) \right]. \end{aligned}$$

Ao analisar o valor esperado do erro quadrático médio considerando todos os possíveis conjuntos de treinamento de tamanho  $n$  e calculando a

média desses valores, vê-se que a última parcela da expressão 5.19 será nula, uma vez que  $(E[\hat{y}_{ij}] - y_{ij})$  independe do conjunto de treinamento, portanto pode ser retirado do valor esperado  $E$  e a primeira parcela  $(\hat{y}_{ij} - E[\hat{y}_{ij}])$  do valor esperado anular-se-á. Como resultado, a expressão 5.19 resume-se a:

$$\begin{aligned} E[EQM] &= E \left[ \frac{1}{n} \sum_{i=1}^n (\hat{y}_{ij} - E[\hat{y}_{ij}])^2 \right] + & (5.20) \\ &+ E \left[ \frac{1}{n} \sum_{i=1}^n (E[\hat{y}_{ij}] - y_{ij})^2 \right] = \\ &= \text{variância} + \text{bias}^2. \end{aligned}$$

O resultado da expressão 5.20, conhecido como o dilema bias-variância, mostra que um modelo adequado a um determinado conjunto de dados deve procurar minimizar essa relação, uma vez que ambas contribuem igualmente para o erro quadrático médio. A variância reflete a sensibilidade da função de estimação ao conjunto de treinamento, ou seja, menos sensibilidade implica em estimativas mais estáveis ante as variações nas observações. Já o bias representa o quão próximo, na média, a função estimadora é capaz de seguir a função original ou processo em análise [Friedman e Fayyad 1997]. Por fim, deve-se buscar um modelo flexível o suficiente para generalizar ou capturar o comportamento por trás das observações realizadas, porém simples ou suave o suficiente para evitar um alto grau de ajuste aos dados de treinamento.

### 5.2.6 Validação Cruzada

No algoritmo apresentado, tanto o tamanho do conjunto de dados de treinamento em  $\mathbf{Z}$  como a lagura de banda da função kernel Gaussiana precisam ser otimizados. Uma das principais estratégias adotadas para definir esses valores é a validação cruzada. Em particular, o método “deixe-um-de fora” (*leave-one-out*) [Cherkassky e Mulier 1998] será utilizado ao longo do trabalho para definir o parâmetro  $h$ . Desse modo, ao utilizar os  $n$  vetores de  $p$  medições disponíveis no conjunto de dados, em cada iteração, o algoritmo retira um elemento diferente  $\mathbf{z}_i$  e procura estimá-lo a partir das  $\mathbf{Z}_{(n-1) \times p}$  observações restantes. O objetivo é encontrar um valor de  $h$  que minimize, por exemplo, o erro quadrático médio. Para o caso de um vetor de medições, tem-se:

$$r_i = \frac{1}{p} [\hat{\mathbf{z}}_i - \mathbf{z}_i] [\hat{\mathbf{z}}_i - \mathbf{z}_i]^T, \text{ para } i = 1 \dots n, \quad (5.21)$$

onde  $\hat{\mathbf{z}}_i$  corresponde à estimativa de  $\mathbf{z}_i$  quando a mesma está ausente no conjunto de treinamento. Por fim, o melhor  $h$  será aquele que fornece o menor EQM-C após todas as observações em  $\mathbf{Z}$  serem avaliadas, ou seja:

$$h(\mathbf{Z}) = \arg \min_h \left( \frac{1}{n} \sum_{i=1}^p r_i \right). \quad (5.22)$$

O restante do capítulo estará dedicado à apresentação do modelo utilizado para o descritor de dados, utilizado no esquema de navegação apresentado no capítulo 2 para a análise dos resíduos com as medições dos tempos de chegada da onda sonora.

### 5.3 DESCRIÇÃO DE DADOS POR VETORES SUPORTE

A descrição do domínio de dados refere-se à caracterização de um determinado conjunto de dados. Assim, uma boa descrição deve conter toda a informação possível desse conjunto sem inserção de informações redundantes ou supérfluas. Além da caracterização, o limite que define o conjunto de dados pode ser utilizado para detectar um dado novo ou um caso de rejeição ou ainda classificar essa informação quanto à sua representação junto ao conjunto armazenado. Como mencionado no capítulo 2, essa descrição de dados a partir de vetores suporte <sup>1</sup> será utilizada no bloco de avaliação de resíduos e módulo de rejeição mostrado na figura 17.

O desenvolvimento teórico do SVDD (*Support Vector Data Description*) [Tax 2001] assemelha-se ao estabelecido e difundido SVC (*Support Vector Classifier*) [Schölkopf e Smola 2002]. Sua principal característica é a de resolver problemas de classificação quando somente uma classe está disponível ou quando uma das classes é sub-amostrada em relação às outras.

A formulação teórica discutida a seguir baseia-se no trabalho apresentado em [Tax e Duin 2004], cujos resultados estão resumidamente apresentados em [Tax 2001]. A descrição de dados ou classificação baseada em uma classe consiste em estabelecer uma descrição do conjunto de dados de treinamento e detectar quais novos objetos assemelham-se a esse conjunto de treinamento. Assim, o método pode ser útil na detecção de exemplos errô-

---

<sup>1</sup>Na teoria de aprendizagem estatística, os vetores suportes são os dados mais relevantes do conjunto de treinamento, pois somente eles participam da equação do hiperplano (SVM) ou da região de fronteira (SVDD) que separam os dados.

neos (*outliers*) a partir desse conjunto de treinamento. Em geral, bons classificadores ou boas funções de regressão provêm resultados confiáveis para dados que estão próximos aos dados de treinamento. Formalmente, o objetivo do método é obter um limite ou borda de decisão, a menor possível, para um determinado conjunto de dados, de modo a minimizar a possibilidade de aceitação de exemplos errôneos na classificação de um conjunto de dados. Desse modo, procura-se obter uma hipersfera, caracterizada por um raio  $\Gamma > 0$  e um centro  $\mathbf{a}$  que contenha todo o conjunto de dados aceitos  $\mathbf{Z}$ , ou seja, definir o menor raio possível para a hipersfera demandando que a mesma contenha os exemplos que representam a verdadeira distribuição desse conjunto com dados aceitos. Portanto, a função objetivo pode ser definida como:

$$F(\Gamma, \mathbf{a}) = \Gamma^2. \quad (5.23)$$

e o problema de otimização é definido por:

$$\min F(\Gamma, \mathbf{a}) \quad (5.24)$$

$$s.a \|\mathbf{z}_i - \mathbf{a}\|^2 \leq \Gamma^2, \quad \forall i, \quad (5.25)$$

Como o próprio conjunto de dados de treinamento pode apresentar exemplos errôneos, as distâncias não precisam se restringir àquelas menores que  $\Gamma^2$  porém, valores maiores devem ser penalizados. Para tanto, introduz-se a variável de folga  $\xi_i \geq 0$  (*slack variable*), alterando a função erro e o problema de minimização para:

$$F(\Gamma, a) = \Gamma^2 + \beta \sum_i \xi_i, \quad \forall i. \quad (5.26)$$

agora com a restrição de que quase todos os dados estão dentro da hipersfera, definido por:<sup>2</sup>

$$\|\mathbf{z}_i - \mathbf{a}\|^2 \leq \Gamma^2 + \xi_i, \quad \xi_i \geq 0, \quad \forall i. \quad (5.27)$$

Por tratar-se de um problema de otimização com função e restrições convexas, introduz-se os multiplicadores de Lagrange incorporando as restrições à função de minimização:

---

<sup>2</sup>O termo hipersfera será utilizado doravante independentemente do formato da borda e representará toda região limítrofe utilizada para a descrição dos dados.

$$L(\Gamma, \mathbf{a}, \alpha_i, \gamma_i, \xi_i) = \Gamma^2 + \beta \sum_i \xi_i \quad (5.28)$$

$$- \sum_i \alpha_i \{ \Gamma^2 + \xi_i - (\| \mathbf{z}_i \|^2 - 2\mathbf{a} \cdot \mathbf{z}_i + \| \mathbf{a} \|^2) \} - \sum_i \gamma_i \xi_i.$$

com os multiplicadores de Lagrange  $\alpha_i \geq 0$  e  $\gamma_i \geq 0$ . Assim,  $L$  deve ser minimizado com respeito a  $\Gamma$ ,  $\mathbf{a}$ ,  $\xi_i$  e maximizado com respeito a  $\alpha_i$  e  $\gamma_i$ . Avaliando as derivadas e igualando-as a zero, chega-se diretamente a seguinte expressão a ser maximizada:

$$L = \sum_i \alpha_i (\mathbf{z}_i \cdot \mathbf{z}_i) - \sum_{i,j} \alpha_i \alpha_j (\mathbf{z}_i \cdot \mathbf{z}_j), \quad (5.29)$$

$$0 \leq \alpha_i \leq \beta. \quad (5.30)$$

Com base no exposto, quando um objeto  $\mathbf{z}_i$  satisfaz a inequação  $\| \mathbf{z}_i - \mathbf{a} \|^2 < \Gamma^2 + \xi_i$ , a restrição é satisfeita e o correspondente multiplicador de Lagrange é zero ( $\alpha_i = 0$ ). Por outro lado, quando  $\| \mathbf{z}_i - \mathbf{a} \|^2 = \Gamma^2 + \xi_i$ , a restrição deve ser reforçada e o multiplicador torna-se diferente de zero ( $\alpha_i > 0$ ).

Como o limite superior para os multiplicadores é  $\beta$ , como mostrado em 5.30, quando, a um determinado dado, é atribuído  $\alpha_i = \beta$ , o mesmo será considerado errôneo e portanto não será aceito pela descrição dos dados. O centro da esfera é encontrado pela seguinte expressão:

$$\mathbf{a} = \sum_i \alpha_i \mathbf{z}_i, \quad (5.31)$$

$$\sum_i \alpha_i = 1. \quad (5.32)$$

Assim, para testar um determinado objeto  $\mathbf{y}$ , a distância ao centro da hipersfera deve ser calculada e o aceite de  $\mathbf{y}$  condicionado à distância ao centro ser menor ou igual ao raio.

$$\| \mathbf{y} - \mathbf{a} \|^2 = (\mathbf{y} \cdot \mathbf{y}) - 2 \sum_i \alpha_i (\mathbf{y} \cdot \mathbf{z}_i) + \sum_{i,j} \alpha_i \alpha_j (\mathbf{z}_i \cdot \mathbf{z}_j) \leq \Gamma^2. \quad (5.33)$$

Por definição,  $\Gamma^2$  é a distância do centro da esfera  $\mathbf{a}$  até qualquer vetor suporte nos limites da esfera, ou seja, aqueles vetores com  $\alpha_i = \beta$  são

excluídos.

$$\Gamma^2 = (\mathbf{z}_k \cdot \mathbf{z}_k) - 2 \sum_i \alpha_i (\mathbf{z}_i \cdot \mathbf{z}_k) + \sum_{i,j} \alpha_i \alpha_j (\mathbf{z}_i \cdot \mathbf{z}_j). \quad (5.34)$$

para qualquer  $\mathbf{z}_k \in SV_{<\beta}$ , conjunto de vetores suporte com  $\alpha_k < \beta$ .

Por fim, define-se a função de classificação baseada em uma classe  $f_{SVDD}(z; \alpha, \Gamma)$  como:

$$f_{SVDD}(z; \alpha, \Gamma) = I(\|\mathbf{y} - \mathbf{a}\|^2 \leq \Gamma^2) = \quad (5.35)$$

$$I(\|\mathbf{y} - \mathbf{a}\|^2 = (\mathbf{y} \cdot \mathbf{y}) - 2 \sum_i \alpha_i (\mathbf{y} \cdot \mathbf{z}_i) + \sum_{i,j} \alpha_i \alpha_j (\mathbf{z}_i \cdot \mathbf{z}_j) \leq \Gamma^2)$$

on  $I$  representa a função indicadora:

$$I(A) = \begin{cases} 1, & \text{se } A \text{ é verdadeiro} \\ 0, & \text{se } A \text{ é falso} \end{cases} \quad (5.36)$$

Assim como em outros classificadores ou funções de regressão, o produto interno mostrado nas expressões anteriores poderá ser substituído por uma função Kernel ( $K(\cdot, \cdot)$ ), cuja função é substituir o cálculo do produto escalar com os dados já mapeados para o espaço dito de características, o que facilita aos modelos de hiperesferas adequarem-se à estrutura dos dados. Desse modo, a expressão em 5.35 pode ser substituída por:

$$f_{SVDD}(z; \alpha, \Gamma) = \quad (5.37)$$

$$I(K(\mathbf{y}, \mathbf{y}) - 2 \sum_i \alpha_i K(\mathbf{y}, \mathbf{z}_i) + \sum_{i,j} \alpha_i \alpha_j K(\mathbf{z}_i, \mathbf{z}_j) \leq \Gamma^2)$$

A função Lagrangeana a ser maximizada em 5.29 passa então a ser reescrita como:

$$L = - \sum_{i,j} \alpha_i \alpha_j K(\mathbf{z}_i, \mathbf{z}_j), \quad (5.38)$$

$$0 \leq \alpha_i \leq \beta.$$

### 5.3.1 Função Kernel

A função kernel  $K$  realiza o produto escalar entre os dados quando estes são mapeados para o espaço dito de características, ou seja, com uma dimensão mais elevada. Implícito à função kernel está o mapeamento desses dados. Esse processo é chamado de *kernel trick* [Vapnik 1999] e não

representa um custo computacional significativo ao processo de minimização descrito anteriormente, exceto pelo cálculo da função  $K(\mathbf{z}_i, \mathbf{z}_j)$ .

Cada função kernel possui sua particularidade, sendo algumas delas mais úteis que outras, quando se trata de representação por hiperesferas. A função kernel Gaussiana em 5.39 é frequentemente utilizada nos problemas de classificação e será adotada para as análises ao longo desse trabalho.

$$K(\mathbf{z}_i, \mathbf{z}_j) = \exp\left(-\frac{\|\mathbf{z}_i - \mathbf{z}_j\|^2}{s^2}\right) \quad (5.39)$$

Esta função kernel apresenta características interessantes como a independência da posição do dado em relação à origem (norma), pois utiliza a distância  $\|\mathbf{z}_i - \mathbf{z}_j\|$  entre objetos. Além disso,  $K(\mathbf{z}_i, \mathbf{z}_i) = 1$ , ou seja, os objetos mapeados possuem norma unitária, enquanto objetos muito distantes um do outro são vistos como perpendiculares no espaço de características, pois  $K(\mathbf{z}_i, \mathbf{z}_j) = 0$ . Visto dessa forma, os dados parecem ser mapeados para uma esfera de raio unitário, além do que, é possível inserir um número infinito de dados no espaço definido pela função kernel.

O parâmetro  $s$  desempenha um papel fundamental no comportamento da função kernel Gaussiana. Observando a expressão 5.39 vê-se que, para pequenos valores de  $s$ , exemplos diferentes são praticamente descartados e portanto a função Lagrangiana em 5.38 será minimizada quando todos os exemplos tornarem vetores suporte para a descrição dos dados. Por outro lado, valores de  $s$  muito grandes aproximam, pela expansão em série de Taylor, a função kernel Gaussiana 5.39 para uma função polinomial, o que torna difícil a representação dos dados por meio de uma esfera.

Por fim, para valores intermediários de  $s$ , vê-se que valores grandes de  $K(\mathbf{z}_i, \mathbf{z}_j)$  levam a multiplicadores  $\alpha_i$  e  $\alpha_j$  tenderem a zero. Portanto, serão considerados vetores suporte exemplos com certo grau de dessemelhança, ou seja, quando  $K(\mathbf{z}_i, \mathbf{z}_j)$  é pequeno, controlado pelo valor de  $s$ .

### 5.3.1.1 Exemplo

O efeito da escolha do valor de  $s$  comentado anteriormente pode ser visto simplificada nos resultados mostrados nas figuras 30 e 31. Observa-se que o aumento do valor de  $s$  resulta num decréscimo do número de vetores suporte, ou seja, objetos que estão na borda ou fora dela como ressaltado pelas setas nas figuras.

Conforme mencionado anteriormente, o valor de  $s$  controla a avaliação do quão semelhante é uma observação em relação a outra, e portanto o valor de  $K(\mathbf{z}_i, \mathbf{z}_j)$  na função Lagrangiana. Desse modo, fixando a distância  $d$

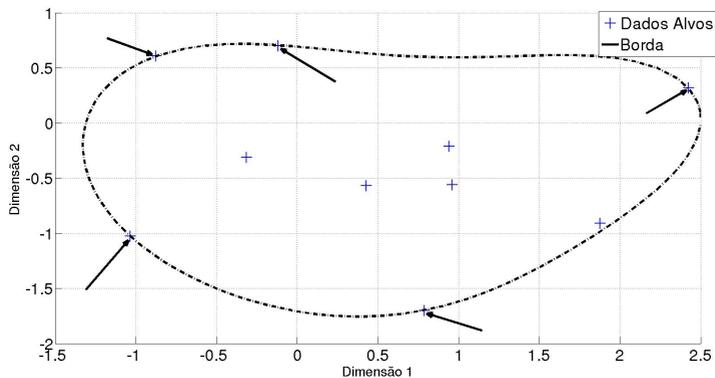


Figura 30: Hiperesfera com 10 observações de dados alvos e  $s = 2$ .

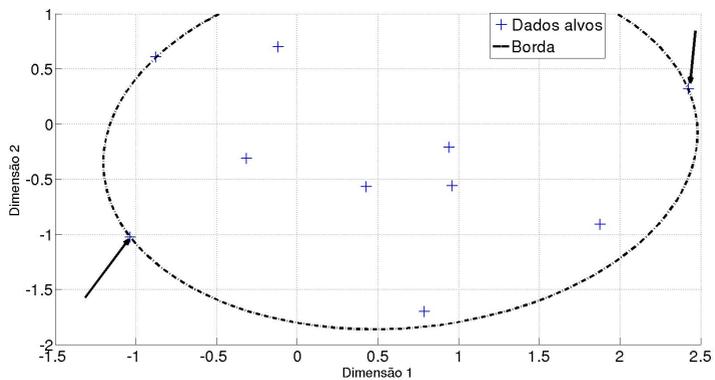


Figura 31: Hiperesfera com 10 observações de dados alvos e  $s = 5$ .

de duas observações, ao aumentar o valor de  $s$ , aumenta a chance de uma ou ambas deixarem de ser vetores suporte. Por outro lado, ao diminuir  $s$ , pequenas distâncias podem ser consideradas dessemelhanças suficientes para tornar as duas observações em vetores suporte.

### 5.3.2 Parâmetro $\beta$ e $s$

A análise a seguir trata da importância da escolha do parâmetro  $\beta$  mostrado em 5.26 e sua relação com o parâmetro  $s$ , brevemente discutido na secção 5.3.1. As relações 5.30 e 5.32 são fundamentais para determinação de  $\beta$  e assim para a determinação dos vetores suporte, ou seja, observações com  $\alpha_i > 0$ . Partindo do pressuposto que o conjunto de treinamento é uma amostra representativa da verdadeira distribuição dos dados, a fração de exemplos que se tornam vetores suporte reflete o erro de classificação cometido no conjunto alvo. Essa estimativa do erro ( $\mathcal{E}$ ) pode ser obtida aplicando o *leave-one-out* [Vapnik 1999] no conjunto de treinamento e é resumida pela relação:

$$\mathcal{E} \leq f_{SV}^{borda} + f_{SV}^{fora} = f_{SV} = \frac{n_{SV}}{N} \quad (5.40)$$

onde  $f_{SV}^{borda}$  e  $f_{SV}^{fora}$  representam a fração de exemplos de treinamento que se tornaram vetores suporte e estão na borda da esfera  $\left(\frac{n_{SV}^{borda}}{N}\right)$  e fora dela  $\left(\frac{n_{SV}^{fora}}{N}\right)$  respectivamente. Partido dessa relação de erro e lembrando que, para exemplos fora da esfera, tem-se  $\alpha_i \equiv \beta$  com  $\sum_i \alpha_i = 1$ , e onde portanto deve ser válido que  $n_{SV}^{fora} \beta \leq 1$ , a escolha de  $\beta$  pode ser obtida a partir de:

$$\beta \leq \frac{1}{N f_{SV}^{fora}}. \quad (5.41)$$

ou seja, o valor de  $\beta$  fornece uma medida do grau de aceitação que os próprios exemplos de treinamento devem ter durante a classificação. Assim, a diminuição do valor de  $\beta$ , que implica numa restrição cada vez maior aos valores de  $\alpha_i$ , associado ao fato de  $\sum_i \alpha_i = 1$ , implicará na inserção de mais exemplos de treinamento como vetores suporte. Além disso, a diminuição de  $\beta$  resulta da redução do volume da hipersfera, o que pode aumentar o erro de classificação do conjunto alvo. Quando se sabe *a priori* que o conjunto de treinamento não possui exemplos negativos, ou seja, todos os exemplos de treinamento devem ser aceitos, o valor de  $\beta$  é ajustado para 1 ou maior, o que significa que o termo  $N f_{SV}^{fora}$  em 5.41, ou o número de exemplos fora da esfera, é pequeno.

Como dito anteriormente, ao aumentar o valor de  $s$  em 5.39, o número de vetores suporte tende a diminuir, o que resulta na diminuição de  $\mathcal{E}$  em 5.40 e portanto uma diminuição do erro esperado na classificação do conjunto alvo. Sendo assim, variando  $s$ , para um dado valor de  $\beta$ , é possível controlar o valor de  $\mathcal{E}$  a partir de  $f_{SV}^{borda}$ . Como regra geral, conforme apresentado em [Tax

2001] e em [Schölkopf e Smola 2002] no estudo do  $v - SVC$ , quando muitos exemplos no conjunto de treinamento devem ser rejeitados, o ajuste em  $\beta$  deve ser realizado. Para o caso onde um número limitado desses exemplos deve ser rejeitado, o ajuste do parâmetro  $s$  é suficiente.

### 5.3.2.1 Exemplo

Seguindo a ideia anterior para avaliação do efeito da escolha do parâmetro  $s$  no formato da hipersfera, os exemplos mostrados nas figuras 32 e 33 ilustram como a escolha do parâmetro  $\beta$  interfere na abrangência da hipersfera e na classificação dos dados.

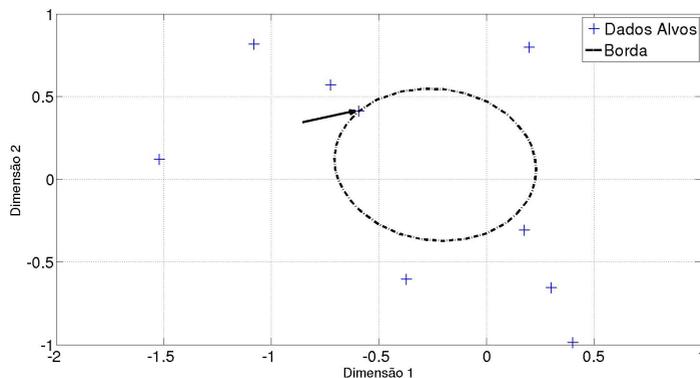


Figura 32: Hipersfera com 10 observações de dados alvos,  $\beta = 0.1$  e  $s = 2$ .

Observa-se nitidamente, na figura 33, que o ajuste de  $\beta = 1$  impõe que todos os exemplos alvos do conjunto de treinamento sejam considerados aceitos e portanto apresentem distância ao centro da hipersfera menores que o raio, ou seja,  $\| \mathbf{z}_i - \mathbf{a} \| \leq \Gamma^2$

### 5.3.3 Treinamento com exemplos errôneos ou negativos

O SVDD também pode ser treinado com a inserção de exemplos negativos, a fim de melhorar a descrição dos dados. Assim, dados corretos devem estar presentes no interior da esfera, enquanto os exemplos negativos devem obrigatoriamente estar fora dela. A utilização de exemplos negativos auxilia

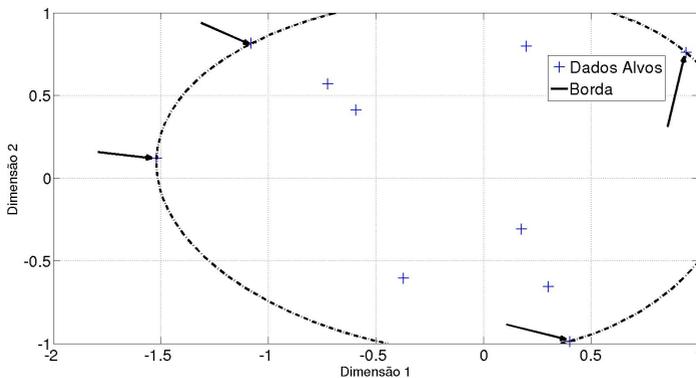


Figura 33: Hiperesfera com 10 observações de dados alvos,  $\beta = 1$  e  $s = 2$ .

numa delimitação mais precisa em torno dos dados alvos.

Uma fundamental vantagem do uso do SVDD no processo de descrição do conjunto de dados está no fato dos exemplos negativos serem, em geral, escassos ou subamostrados. Em comparação com outros classificadores clássicos, onde há distinção entre duas ou mais classes sem um foco específico em uma delas, o SVDD apresenta um melhor desempenho quando não há um número razoável de exemplos errôneos ou negativos e/ou quando as classes envolvidas não estão bem representadas pelo conjunto de dados disponíveis. Entretanto, a inserção de exemplos negativos auxilia na descrição e identificação correta de uma determinada classe.

O custo computacional da inserção de exemplos negativos é estritamente o mesmo quando comparado com a inserção de mais um dado de treinamento válido. Entretanto, os exemplos negativos auxiliam na determinação mais precisa da hiperesfera que envolve os dados. Assim, quando um exemplo errôneo está dentro da hiperesfera, que fora treinada sem esse exemplo, o volume da mesma precisa ser novamente minimizado para que esse novo caso seja colocado para fora. Nesse sentido, todo o conjunto de dados válidos até então sofrerá alterações, podendo haver novas exclusões ou novas inserções.

### 5.3.3.1 Exemplo

Para ilustrar o efeito da inserção de exemplos errôneos, segue um exemplo que atesta quão útil pode ser o SVDD na caracterização de dados.

As características do experimentos são:

- Classe Alvo : Amostras i.i.d obtidas de uma distribuição uniforme:  
 $\mathbf{A} \sim \mathcal{U}(0, 1)$
- Classe Errônea : Amostras i.i.d obtidas de uma distribuição normal:  
 $\mathbf{B} \sim \mathcal{N}(0, 1)$

Inicialmente,  $n = \{3 \times 2\}$  observações obtidas de  $\mathbf{B}$  são classificadas como observações da classe alvo. A figura 34 mostra a menor hiperesfera contendo as três observações mencionadas.

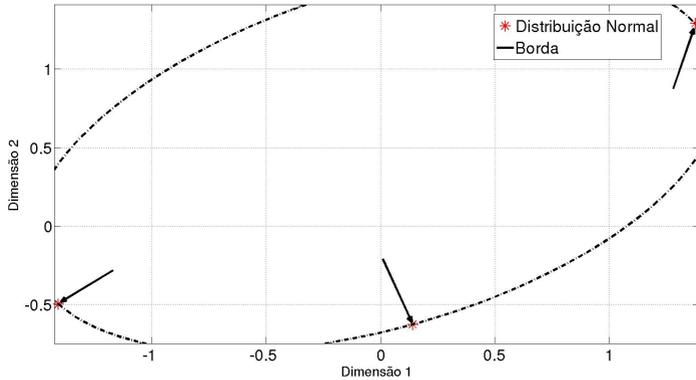


Figura 34: Hiperesfera contendo três observações da distribuição normal.

O passo seguinte é inserir observações de  $\mathbf{A}$  como exemplos alvo bem como inserir novas observações de  $\mathbf{B}$  agora como exemplos negativos. Vale ressaltar que os três exemplos iniciais, continuam inseridos dentro do conjunto de exemplos alvo. O objetivo é observar como, à medida que novas observações são inseridas como exemplos alvos ou negativos, as três observações iniciais acabam sendo excluídas da região de borda que melhor descreve o conjunto de dados alvos. A figura 35 mostra o resultado dessa iteração, onde se observa que após a inserção de  $\pm 20$  novas amostra de  $\mathbf{A}$  e  $\mathbf{B}$ , os três pontos iniciais, declarados como corretos inicialmente, acabam sendo excluídos.

É possível avaliar esse efeito observando também a distância dos três pontos iniciais ao centro da hiperesfera. Ou seja, à medida que novos exemplos alvos são inseridos, a distância desses três pontos iniciais ao centro da esfera deverá apresentar um comportamento crescente, podendo chegar a ser maior que o raio da hiperesfera.

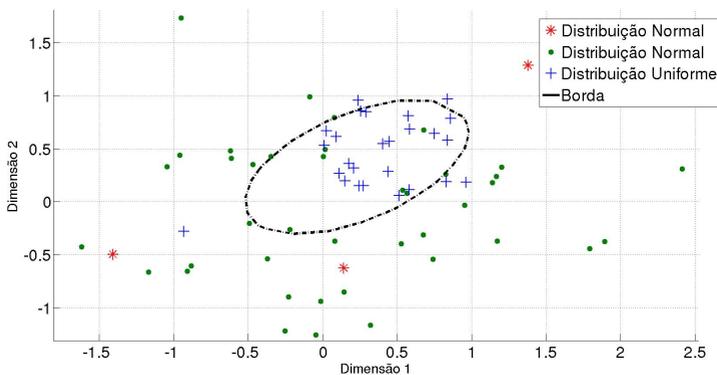


Figura 35: Hipersfera isolando as observações que melhor descrevem o conjunto de dados.

### 5.3.4 Aprendizagem Online

Apesar da formulação apresentada nesse capítulo, recentemente, algoritmos que viabilizam a aprendizagem de modo *online* e que são aplicáveis às máquinas de vetores suporte assim como os vetores suporte para descrição de dados vêm sendo desenvolvidas com foco na metodologia de aprendizagem e na seleção dos dados de treinamento. O algoritmo incremento/decremento apresentado no apêndice A detalha como realizar o processo de otimização convexa mostrado sem aplicação dos algoritmos de minimização convencionais que demandariam elevada capacidade computacional. O algoritmo incremento/decremento apresentado foi utilizado nas etapas de simulação e validação da proposta apresentada nesse trabalho.

### 5.3.5 Aplicações

Desde seu desenvolvimento teórico em [Tax 2001], o SVDD vem sendo utilizado, melhorado e aplicado em diversas situações onde o processo de classificação é baseado em apenas uma classe. Esse tipo de classificação encontra ampla aceitação principalmente em detecção de falhas em máquinas e rede de sensores. Em [Ypma, Tax e Duin 1999], aplicou-se esse método de classificação para detectar falhas numa instalação submersa de uma bomba d'água. Os resultados apresentam melhorias quando comparados a méto-

dos tradicionais como o algoritmo do vizinho mais próximo e a densidade de Parzen. Algumas pesquisas combinam o SVDD com outras técnicas para melhor descrever os dados de treinamento e reduzir o tamanho de exemplos necessários. Em [Luo et al. 2010], por exemplo, o SVDD é aplicado a subconjuntos do conjunto de dados de treinamento e os resultados são posteriormente combinados para encontrar uma borda de decisão comum entre eles. Já em [Xu, Yao e Ni 2011], o algoritmo *K-means* é utilizado previamente ao SVDD, de modo a separar o conjunto de dados referentes às operações normais. Após essa etapa uma melhor descrição dos dados é então obtida pelo SVDD. Em [Huang e Shen 2008] o resultado do processo de descrição dos dados é utilizado para ponderar os exemplos de treinamento utilizados em funções de regressão baseada nas máquinas de vetores suporte (SVM).

#### 5.4 CONCLUSÕES

A abordagem heurística para levantamento de modelos é amplamente utilizada em problemas de robótica, seja para o sistema de controle, para a estimação de estados ou desvio de obstáculos [Janglova 2004], [Minyong, Sakhivel e Chung 2007], [Yin et al. 2010].

As técnicas discutidas nesse capítulo apresentam potencialidades que podem ser exploradas para melhorar os algoritmos de navegação dos veículos autônomos principalmente por serem rápidas e poderem ser facilmente modificadas para ajustar-se às diferentes situações encontradas nas missões desses veículos. As questões referentes ao custo computacional, quando disponível um tamanho considerável de exemplos de treinamento são problemas comumente tratados no campo da modelagem não parametrizada. Entretanto, como visto sobre os sensoriamento acústico para localização, por trata-se de sensores cuja frequência de operação é baixa, o sistema tem que lidar com um tamanho de dados de treinamento da ordem de centenas de dados, o que é perfeitamente suportado pelas plataformas computacionais atuais.

No caso do SVDD, fica claro que uma das importantes aplicações dessa abordagem está na detecção de exemplos errôneos. Tendo em vista que, em sistemas dinâmicos, comportamentos desviados da operação normal são difíceis de serem obtidos ou apresentam riscos para a coleta de dados, a classificação baseada em uma classe, como proposto pelo SVDD, mostra-se extremamente adequada para detecção de falhas ou análise da evolução temporal dos dados.

No contexto abordado nesse trabalho, a utilização desses modelos, juntamente com a fusão sensorial, visa minimizar os efeitos danosos à comunicação acústica entre veículo e bóias para fins de localização. Na sequência

do trabalho, será apresentado o sistema de navegação, ressaltando as etapas que envolvem todo o processo e o fluxo de dados entre os blocos.



## **6 ARQUITETURA PROPOSTA PARA O SISTEMA DE LOCALIZAÇÃO DE VEÍCULOS SUBAQUÁTICOS**

### **6.1 INTRODUÇÃO**

Nesse capítulo, discute-se o sistema de navegação proposto nesse trabalho e apresenta-se detalhadamente a integração entre os blocos de filtragem, análise e correção já introduzidos nos capítulos precedentes. O algoritmo utilizado no processo de análise e correção é detalhado, bem como é possível visualizar o fluxo e o tipo de informações trocadas entre os blocos que compõem o sistema de localização acústico.

### **6.2 ARQUITETURA PROPOSTA**

O sistema de navegação proposto neste trabalho está destacado na figura 36, onde é possível ver em detalhe o esquema utilizado tanto para rejeição de medições quanto para a correção delas. No bloco referente à análise de resíduo e rejeição é processado o algoritmo responsável por calcular a hipersfera, com base nos exemplos ou resíduos alvos e naqueles considerados errôneos. No entanto, antes de rejeitar ou aceitar completamente uma medição, o sistema aciona o algoritmo de autoassociação de dados de modo a melhorar a medição com base num histórico recente de medições.

Algumas características desse sistema são fundamentais, como:

1. Não interfere na estrutura do algoritmo de estimação nem restringe-se a uma solução particular, ou seja, qualquer que seja a formulação utilizada poderá utilizar a arquitetura proposta;
2. A base de dados utilizada pelo SVDD é composta pelos resíduos gerados ao longo na navegação ou ainda de resíduos obtidos de medições pretéritas;
3. A base de dados utilizada pelo AAKR é composta pelas medições de tempo total de propagação da onda sonora, que compreende todo o processo de interrogação/resposta. Assim como nos resíduos, a base de dados é composta por medições obtidas durante a navegação ou em missões anteriores;
4. Os outros sensores auxiliares não sofrem qualquer alteração em sua taxa de amostragem nem seu processamento;

5. A solução proposta não exclui a necessidade de ajuste de parâmetros tanto para a rejeição de medições quanto para as correção das mesmas;

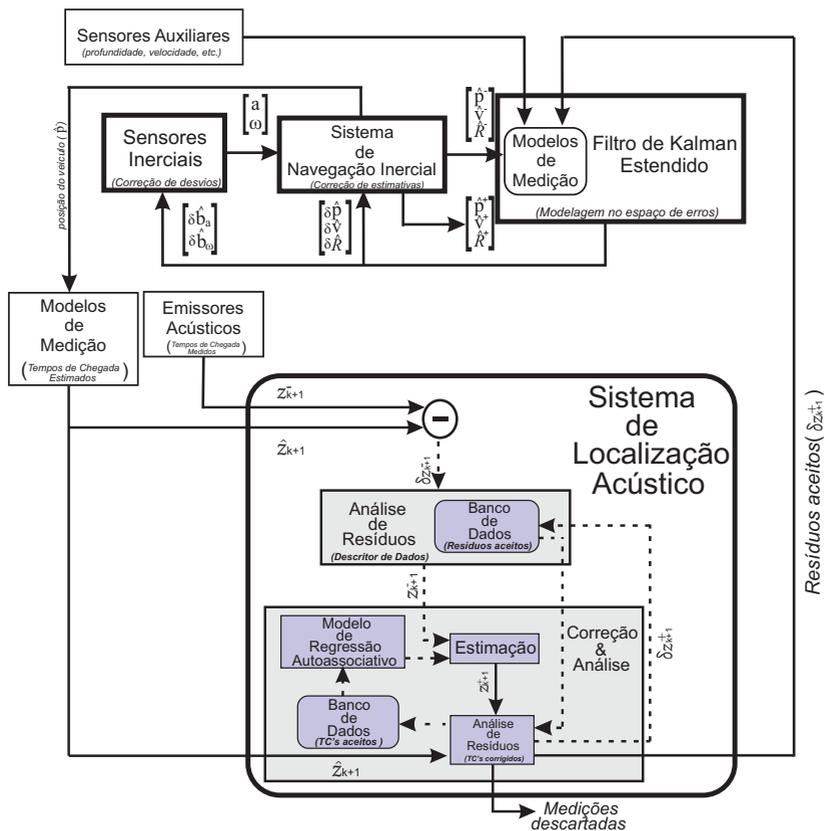


Figura 36: Sistema de navegação inercial integrado à solução proposta para o sistema de localização.

## 6.2.1 Processamento da Informação

Na arquitetura proposta para o sistema de localização, as etapas do processo de fusão de dados, detalhado no capítulo 4, permanecem inalteradas exceto pelo cálculo do resíduo, ou seja, pela diferença entre o tempo de chegada medido e o tempo de chegada estimado. Como mostrado na figura 36,

o tempo de chegada estimado  $h(\hat{x}_{k+1}^-)$  está representado por  $\hat{z}_{k+1}$  enquanto o resíduo passará a ser calculado em dois instantes:

$\delta z_{k+1}^- = z_{k+1}^- - h(\hat{x}_{k+1}^-)$ , resíduos calculados a partir das medições anteriores à correção  $z_{k+1}^-$ .

$\delta z_{k+1}^+ = z_{k+1}^+ - h(\hat{x}_{k+1}^-)$ , resíduos calculados a partir das medições após a correção  $z_{k+1}^+$ .

A variável  $z_{k+1}$  representa o vetor com os tempos de chegada da onda sonora provenientes dos emissores instalados nas boias. Assim, tanto as medições que não passaram pelo algoritmo de correção, através do modelo auto-associativo,  $z_{k+1}^-$  quanto as corrigidas por esse algoritmo  $z_{k+1}^+$  geram resíduos  $\delta z_{k+1}$  que são posteriormente analisados quanto a sua validade pelo descritor de dados. As melhores medições serão encaminhadas para o EKF a serem utilizadas. Para maior clareza quanto ao processamento seguem-se as etapas adicionadas à formulação do algoritmo de filtragem apresentado no capítulo 4.

- 1ª Etapa - Cálculo inicial do resíduo:  $\delta \mathbf{z}_{k+1}^- = \mathbf{z}_{k+1}^- - h(\hat{\mathbf{x}}_{k+1}^-)$ ,
- 2ª Etapa - Análise inicial do resíduo (SVDD):  $\delta \mathbf{z}_{k+1}^- \in \text{Hiperesfera?}$ ,
- 3ª Etapa - Correção das medições (AAKR):  $\mathbf{z}_{k+1}^+ = \text{AAKR}(\mathbf{z}_{k+1}^-)$ ,
- 4ª Etapa - Cálculo do novo resíduo:  $\delta \mathbf{z}_{k+1}^+ = \mathbf{z}_{k+1}^+ - \hat{\mathbf{z}}_{k+1}$ ,
- 5ª Etapa - Análise do novo resíduo (SVDD):  $\delta \mathbf{z}_{k+1}^+ \in \text{Hiperesfera?}$ ,
- 6ª Etapa - Envio ao EKF:  $\delta \mathbf{x}_{k+1}^+ = \delta \mathbf{x}_{k+1}^- +$   
 $+ \mathbf{K}_{k+1} (\delta \mathbf{z}_{k+1}^+ - \mathbf{H}_{k+1} \delta \mathbf{x}_{k+1}^-)$ .

É fundamental destacar que o modelo de medição do tempo de che-

gada da onda sonora, utilizado para a geração do resíduo, foi definido pela equação 4.31, enquanto o modelo de medição utilizado no filtro de Kalman, formulado no espaço de erro, foi definido pela equação 4.33. As equações estão repetidas abaixo para facilitação da análise:

$$d_{k+1} = \frac{1}{c_{k+1}} \|\mathbf{P}_j - \mathbf{p}_{k+1}\|, \quad (6.1)$$

$$h(\hat{\mathbf{x}}_{k+1}^-) = \frac{1}{c_{k+1}} \|\mathbf{P}_j - \hat{\mathbf{p}}_{k+1}^-\| + \frac{1}{c_{k_i}} \|\mathbf{P}_j - \mathbf{p}_{k_i}\| + T_j, \quad (6.2)$$

$$\begin{aligned} \mathbf{H}_{k+1} \delta \mathbf{x}_{k+1}^- &= d_{k+1} + d_{k_i} + T_j + n_t - \hat{d}_{k+1} - \hat{d}_{k_i} - T_j = \\ &= [D_{k+1} \Phi(k+1, k_i) + D_{k_i}] \delta \mathbf{x}_{k+1}^-, \end{aligned} \quad (6.3)$$

onde o subscrito  $k_i$  corresponde ao instante do envio da interrogação e  $k+1$ , ao instante de tempo da chegada da resposta emitida pelos emissores nas boias.

Como discutido, a variável  $\delta \mathbf{x}_{k+1}$  será nula todas as vezes que as variáveis de estado do veículo forem corrigidas por:

$$\hat{\mathbf{x}}_{k+1}^+ = \hat{\mathbf{x}}_{k+1}^- + \delta \mathbf{x}_{k+1}^+ \quad (6.4)$$

Em uma arquitetura onde os sensores apresentam taxas de amostragem distintas, ficará ao encargo do projetista decidir em qual momento, após um conjunto de medições externas disponíveis, a variável  $\hat{\mathbf{x}}_{k+1}^+$  deverá ser corrigida e o valor de  $\delta \mathbf{x}_{k+1}^+$  igualado a zero.

### 6.3 ALGORITMO

Na sequência, vê-se dois pseudocódigos referentes à informação processada tanto no bloco de análise de resíduos enquanto no algoritmo de correção das medições. Para facilitar a compreensão do algoritmo, o conjunto de dados de treinamento utilizado pelo SVDD, composto por resíduos, será identificado por  $\mathcal{V}$  enquanto o utilizado pelo AAKR, composto por tempos de chegada, por  $\mathcal{L}$ .

Nas situações onde não há qualquer exemplo compondo o conjunto de medições alvo tanto para o SVDD quanto para o AAKR, o veículo iniciará sua navegação utilizando o método clássico com o limiar de aceite até obter uma quantidade de exemplos ( $n$ ) que possa ser utilizada para classificação e correção. Na linha 11 do algoritmo 1, essa quantidade de exemplos iniciais está expressa pela variável  $n$ .

---

**Algorithm 1** Algoritmo para avaliação de medições do tempo de chegada de sinais acústicos - EKF/SVDD.

---

```

1:  $\mathcal{V}$ ; ▷ conjunto de resíduos aceitos.
2:  $\mathcal{A}$ ; ▷ conjunto de medições aceitas (LBL).
3:  $h_1 \leftarrow$  constante; ▷ largura de banda do kernel para medições acei-
   tas.
4:  $h_2 \leftarrow$  constante; ▷ largura de banda do kernel para medições rejei-
   tadas.
5:  $(\Gamma, \mathbf{a})$ ; ▷ definição da hiperesfera.

6: while EKF ativo do
7:   verificar sistema LBL;
8:   if resposta acústica ( $z_{k+1}^-$ ) disponível then
9:      $\hat{z}_{k+1} \leftarrow h(\hat{x}_{k+1}^-)$ 
10:     $\delta z_{k+1}^- \leftarrow z_{k+1}^- - \hat{z}_{k+1}$ ; ▷ resíduo.
11:     $d_{k+1}^- \leftarrow \|\delta z_{k+1}^- - \mathbf{a}\|$ ; ▷ equação 5.33.
12:    if  $d_{k+1}^- < \Gamma$  then
13:       $z_{k+1}^+ \leftarrow$  AAKR( $z_{k+1}^-$ ,  $\mathcal{A}$ ,  $h_1$ ); ▷ Algoritmo 2.
14:       $\delta z_{k+1}^+ \leftarrow z_{k+1}^+ - \hat{z}_{k+1}$ ; ▷ resíduo com a medição corrigida.
15:       $d_{k+1}^+ \leftarrow \|\delta z_{k+1}^+ - \mathbf{a}\|$ ;
16:      if  $d_{k+1}^+ \leq d_{k+1}^-$  then
17:         $\delta z_{k+1} \leftarrow \delta z_{k+1}^+$ ; ▷ enviar para EKF com a medição corri-
          gida.
18:      else
19:         $\mathcal{V} \leftarrow \mathcal{V} \cup \{\delta z_{k+1}^-\}$ ;
20:         $\mathcal{A} \leftarrow \mathcal{A} \cup \{z_{k+1}^-\}$ ;
21:         $\delta z_{k+1} \leftarrow \delta z_{k+1}^-$ ; ▷ enviar para EKF resíduo sem a corre-
          ção.
22:         $(\Gamma, \mathbf{a})$ ; ▷ calcular nova hiperesfera.
23:      end if
24:    else
25:       $z_{k+1}^+ \leftarrow$  AAKR( $z_{k+1}^-$ ,  $\mathcal{A}$ ,  $h_2$ );
26:       $\delta z_{k+1}^+ \leftarrow z_{k+1}^+ - \hat{z}_{k+1}$ ;
27:       $d_{k+1}^+ \leftarrow \|\delta z_{k+1}^+ - \mathbf{a}\|$ ;
28:      if  $d_{k+1}^- < \Gamma$  then
29:         $\delta z_{k+1} \leftarrow \delta z_{k+1}^+$ ; ▷ enviar para EKF resíduo com a corre-
          ção.
30:      end if
31:    end if
32:  end if
33: end while

```

---

No algoritmo 2, os valores de  $h_1$  e  $h_2$  devem ser ajustados a partir de uma análise prévia à navegação observando que  $h_1$  refere-se à largura de banda do kernel quando aplicado aos exemplos que geraram resíduos aceitos enquanto  $h_2$  aos outros casos.

---

**Algorithm 2** Algoritmo para correção das medições - AAKR.

---

**Input:**  $z_{k+1}^- = [z_{t_1}^-, z_{t_2}^-, \dots, z_{t_n}^-]^T, \mathcal{A}, h.$   
 calcular os pesos;  $\triangleright$  equação 5.10  
 calcular  $z_{k+1}^+ = [z_{t_1}^+, z_{t_2}^+, \dots, z_{t_n}^+]^T$ ;  $\triangleright$  equação 5.11.  
**return**  $z_{k+1}^+$ ;  $\triangleright$  medição corrigida.

---

### 6.3.1 Análise de Resíduo

O bloco análise de resíduos mostrado na figura 36 compreende o cálculo da distância de um vetor de entrada ao centro da hipersfera ou região de borda que delimita o conjunto de dados aceitos bem como a comparação dessa distância com o raio dessa hipersfera, conforme mostrado nas linhas 8 e 23 do algoritmo 1. Entretanto, o descriptor de dados permite variações tanto para o cálculo do raio da hipersfera quanto para o cálculo da distância ao centro da mesma.

Para ilustrar isso, considere um caso em duas dimensões mostrado na figura 37, onde os exemplos alvos, a região de fronteira e o centro já estão definidos, e um vetor de entrada será avaliado quanto à sua aceitação pelo descriptor de dados.

O processo de avaliação pode ser realizado calculando tanto o raio quanto a distância ao centro considerando as duas dimensões simultaneamente ou apenas uma delas isoladamente. Desse modo, a região de fronteira e a localização do seu centro são definidos utilizando os vetores em duas dimensões, mas a comparação poderá ser realizada entre  $d_{12}$  com  $R_{12}$  ou  $d_{11}$  com  $R_{11}$  e  $d_{22}$  e  $R_{22}$ .

Para os dois últimos modos de comparação entre distância e raio é possível identificar individualmente quais medições de tempo de chegada pertencentes ao vetor de entrada são válidas. Nos resultados mostrados ao longo desse trabalho a comparação realizada na linha 8 do algoritmo 1, cujo resultado impactará na escolha da largura de banda do kernel utilizado no algoritmo 2, será realizada entre a distância  $d_{12}$  e raio  $R_{12}$ . No entanto, a fim de aproveitar o maior número de medições, a comparação realizada na linha 11 do algoritmo 1 dar-se-á utilizando as distâncias  $d_{11}$  e  $d_{22}$  com os raios  $R_{11}$  e  $R_{22}$  respectivamente.

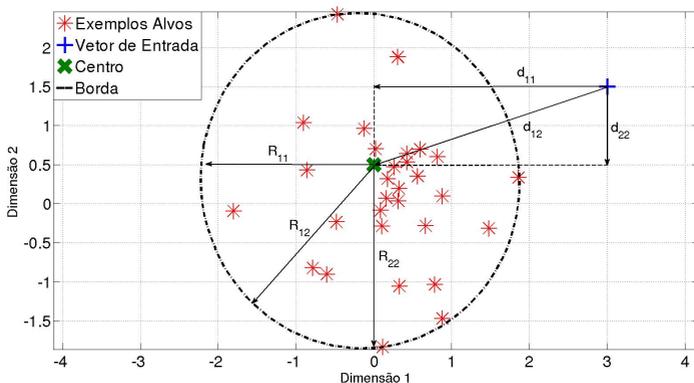


Figura 37: Descritor de dados em duas dimensões. O vetor de entrada será avaliado quanto à sua aceitação de acordo com sua distância ao centro da região de fronteira.

Em um contexto particular, onde o conjunto de medições é composto por dados em uma única dimensão, ainda é possível definir um descritor de dados com um raio e um centro com o qual possa ser realizada a comparação entre a distância e o raio. A figura 38 mostra essa situação, onde não é mais possível obter uma curva representando a região de fronteira.

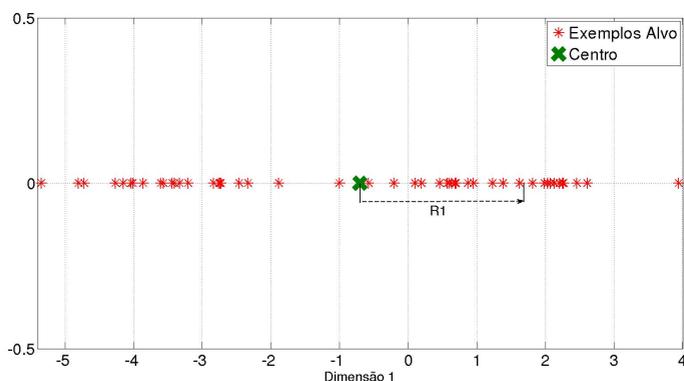


Figura 38: Descritor de dados em uma única dimensão. A região de fronteira é definida exclusivamente pelo raio  $R_1$ .

### **6.3.2 Correção de Medições**

Para reforçar o que fora discutido no capítulo 5, destaca-se que a aplicação do modelo de regressão nos tempos de chegada também poderá ser realizada com qualquer dimensão do vetor de entrada. Como exemplo, num determinado momento onde uma ou mais medições são rejeitadas, é possível tornar o cálculo dos pesos  $w$  insensíveis a essas medições e aplicar a correção apenas àquelas aceitas com um  $h$  apropriado. Em um segundo momento, retomam-se os valores que foram rejeitados para o cálculo dos pesos de modo a corrigir esses valores agora com um novo valor de  $h$ .

### **6.3.3 Fluxograma do Sistema de Localização**

Considerando o que fora exposto sobre a análise de resíduos e correção das medições através do modelo de regressão e de modo a deixar claro todo o fluxo de informação processada e trocada entre os blocos, o fluxograma da solução proposta nesse trabalho para o sistema de localização está representado na figura 39.

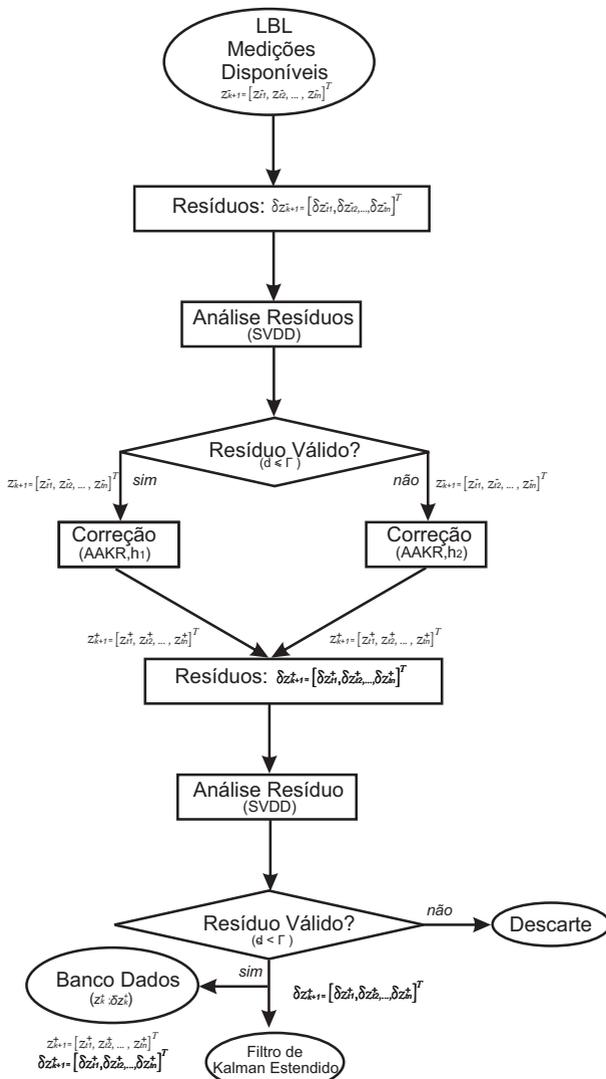


Figura 39: Fluxograma para o sistema de localização acústico. Análise de resíduo via descritor de dados e correção de medições via modelos de regressão kernel autoassociativos.

Mais uma vez, destaca-se a mudança no valor da largura de banda do kernel da função de regressão de acordo com o resultado da análise de resíduo

executado por função de classificação.

## 6.4 CONCLUSÃO

Esse capítulo dedicou-se à descrição da proposta apresentada nesse trabalho para o sistema de localização de veículos autônomos subaquáticos. Algumas observações pertinentes em relação à solução proposta são: i) não interferência na formulação do filtro de estimação; ii) algoritmos de fácil implementação que não tendem a sobrecarregar o sistema computacional; iii) assim como outras soluções, necessitam de ajuste de parâmetros à medida que novas missões forem sendo realizadas.

Como visto, não se pretende apenas detectar os exemplos errôneos e evitar que os mesmos sejam inseridos no filtro de estimação, mas ao mesmo tempo aplicar modelo de regressão a fim de corrigir eventuais desvios nessas medições. A inserção dos modelos baseados em função kernel aproveitam a própria estrutura do filtro de Kalman estendido e da presença de outros sensores para melhorar seu desempenho tanto na classificação de medições quanto na correção dos desvios. A proposta no entanto não exclui o experimentador de realizar ajustes nos parâmetros dos algoritmos de acordo a própria experiência de navegações em locais onde serão realizadas missões ou com base na qualidade dos equipamentos e seniores embarcados no veículo.

O próximo passo é aplicar essa estrutura em exemplos reais, coletados em campo com veículo instrumentados com sistema LBL, sensores de profundidade, de velocidade do som e velocidade absoluta.

## 7 ANÁLISE DE RESULTADOS COM O SISTEMA DE NAVEGAÇÃO PROPOSTO

### 7.1 INTRODUÇÃO

Nesse capítulo analisar-se-á o desempenho da solução proposta nesse trabalho utilizando dados reais de navegação obtidos durante missões com um típico veículo subaquático na configuração de torpedo. Devido às boas condições de operação nos locais do experimento, somado à qualidade dos equipamentos, o sistema de localização LBL apresenta excelente precisão. Tomando essas medições de tempo de chegada, serão inseridos erros exógenos factíveis que provocam desvios nessas quantidades medidas. O objetivo é avaliar o comportamento do sistema de localização e comparar a solução proposta com o método utilizado atualmente nesses veículos. Para isso, será avaliado inicialmente o desempenho do sistema quando utilizando o modelo autoassociativo em um exemplo de navegação com a ocorrência de um grande número de medições errôneas. Posteriormente, de posse de um novo conjunto de medições, será determinada a largura de banda do kernel utilizado nesse modelo utilizando medições previamente aceitas pelo algoritmo de análise em execução nos veículos. Por fim, já com dados de uma nova missão, o algoritmo completo, apresentado no capítulo anterior, será utilizado e avaliado através de métricas de desempenho também apresentadas ao longo do capítulo.

### 7.2 O VEÍCULO

O veículo utilizado para a coleta de dados está mostrado na figura 40 e é conhecido como LAUV (*Light Autonomous Underwater Vehicle*) devido a seu pequeno porte e leveza. Tanto o veículo quanto as ferramentas de análise de ajuste de missão foram desenvolvidos pela equipe do Laboratório de Sistemas e Tecnologia Subaquática (LSTS) da Faculdade de Engenharia da Universidade do Porto (FEUP).

Dentre as principais características dessas plataformas, destacam-se:

1. Dimensões: 110 X 15 cm
2. Máxima Profundidade: 50 m;
3. Autonomia: 8hs a 1,5 m/s;
4. Velocidade máxima: 3 m/s;



Figura 40: Veículo utilizado em missão para aquisição de dados.

Os principais sensores embarcados no veículo são:

1. Modem Acústico;
2. Sensor de condutividade, temperatura e profundidade (CTD);
3. Sensor de qualidade da água;
4. Sensor de velocidade do som;
5. Sistema de localização LBL (Teledyne Benthos UAT-376);
6. Sensor de velocidade DVL;
7. Sensor inercial de alta precisão para aplicações militares (Honeywell, HG-1700; IMAR, IFOG-IMU-1-A);

Os testes foram realizados na área do Porto dos Leixões na cidade do Porto/Portugal, onde o veículo navegou em águas oceânicas na ausência de ondas. Durante a missão, o veículo foi programado a visitar várias profundidades mantendo sua velocidade constante e de aproximadamente  $1\text{ m/s}$ . O veículo navegou em uma área de pouca e aproximadamente constante profundidade ( $< 10\text{ m}$ ) a distâncias em relação aos emissores não superiores a  $200\text{ m}$ . As figuras 41 e 42 mostram a área de realização das manobras com o veículo e as medições realizadas com os sensores de profundidade e batimetria respectivamente. Os gráficos foram obtidos diretamente do programa de ajuste de missão Neptus [Pinto et al. 2013] a partir dos dados obtidos pelos sensores.

Dadas essas condições, é possível afirmar que a velocidade do som sofre pouca alteração e portanto pode ser assumida constante. Além disso, devido às pequenas distâncias, um número limitado de reflexões ocorrem durante a trajetória da onda acústica até o veículo.

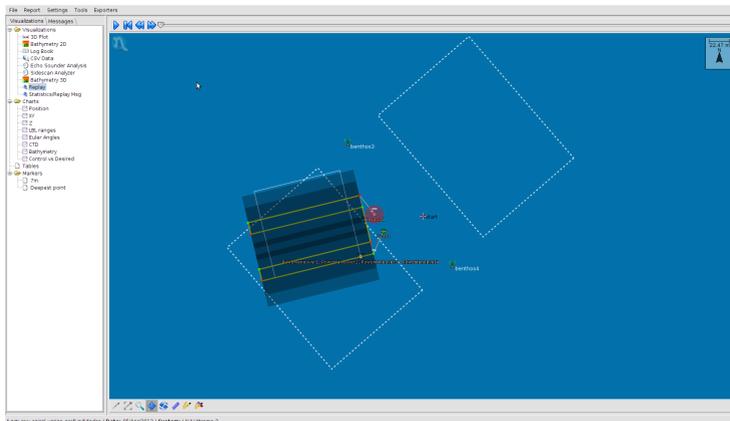


Figura 41: Versão do Neptus para a área de realização dos testes. Detalhe da configuração LBL utilizada.

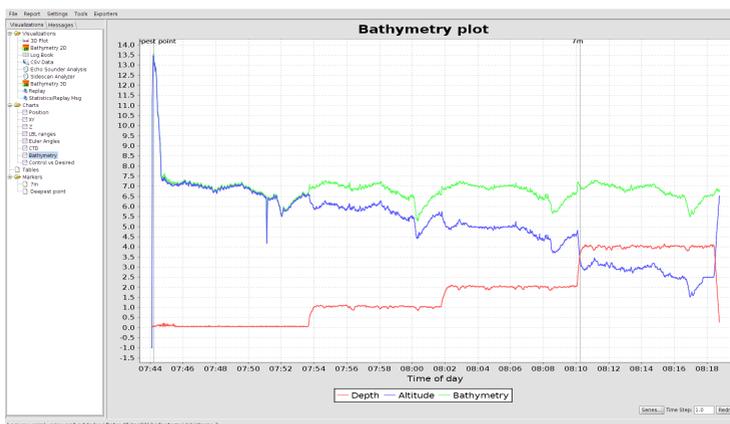


Figura 42: Dados de profundidade e altitude durante uma missão.

### 7.3 REJEIÇÃO DE EXEMPLOS ERRÔNEOS

O sistema de navegação do veículo mostrado dispõe de uma estratégia para identificação de medições de tempos de chegada errôneas. Na ocorrência de tais exemplos, a medição é simplesmente descartada e o veículo navega com o valor estimado pelo sistema inercial. O algoritmo utilizado nessa identificação foi proposto em [Vaganay, Leonard e Bellingham 1996],

onde a distância de Mahalanobis  $\gamma$  entre o valor estimado e o valor medido é calculada e comparada com um valor de referência  $\gamma_{ref}$ . Esse valor é definido de modo empírico a partir de experiências de navegações anteriores e é ajustado de acordo com a qualidade dos equipamentos instalados no veículo e do ambiente de navegação. O parâmetro  $\gamma$  é então definido como:

$$\gamma_{ki} = \delta z_{ki}^T \mathbf{S}_{ki}^{-1} \delta z_{ki} < \gamma_{ref} \quad (7.1)$$

com

$$\begin{aligned} \delta z_{ki} &= t_{ki} - \hat{t}_{ki}, \\ \mathbf{S}_k &= \mathbf{H}_k \mathbf{P}_{k+1}^- \mathbf{H}_k^T + \sigma_{ti}^2 \end{aligned}$$

onde  $\hat{t}_{ki}$  é o valor estimado do tempo de viagem da onda sonora emitida pelo emissor  $i$ ,  $\mathbf{P}_{k+1}^-$  refere-se à estimativa inicial da matriz de covariância do erro de estimação, definida na equação 4.50,  $\mathbf{H}_k$ , o Jacobiano do modelo de medição do tempo de viagem da onda sonora para cada emissor e  $\sigma_{ti}^2$  é a variância do ruído de medição. A quantidade  $\mathbf{S}_{ki}$  corresponde ao elemento  $i, i$  da matriz  $\mathbf{S}$ . A cada instante de tempo  $k$ , quando disponíveis, os tempos de chegada  $t_{ki}$  são avaliados individualmente de acordo com a desigualdade 7.1 e aceitos quando  $\gamma_{ki} \leq \gamma_{ref}$ .

Vale destacar aqui a importância do modelo de medição e portanto, da posição estimada do veículo. Observa-se na expressão 7.1 que estimativas precisas para o valor de  $\hat{t}_{ki}$  são fundamentais para avaliar se uma medição será aceita ou não num instante  $k$ . Assim, caso o veículo navegue longos períodos somente com informações provenientes dos sensores inerciais, ou seja, sem as correções promovidas pelos sensoriamento acústico externo e o algoritmo de fusão de dados, o critério para avaliação da qualidade da medição será prejudicado ou mesmo perdido. Diante disso, a aplicação dos modelos autoassociativos busca essencialmente evitar que esse critério para a validação das medições seja deteriorado devido a um significativo número de descarte de medições.

## 7.4 MÉTODO DE ANÁLISE

A método de análise utilizado nesse trabalho faz uso das informações concernentes à navegação do veículo subaquático, que estão disponíveis num banco de dados. Todos esses dados podem ser carregados via plataforma Neptus, como mostrado nas figuras 41 e 42, a fim de avaliar como o sistema comportou-se durante uma determinada missão. Dentre esse conjunto de dados, encontram-se os tempos de chegada da onda sonora durante a navegação,

bem como posição, velocidade e orientação do veículo antes e após a correção realizada pelo filtro de Kalman estendido.

No procedimento para análise da arquitetura proposta, além do algoritmo de navegação embarcado no veículo, utilizam-se as informações dos tempos de chegada aceitos e rejeitados da onda sonora. O objetivo inicial é avaliar e ajustar o algoritmo de correção das medições, ou seja, buscar valores apropriados para a largura de banda  $h$  do kernel Gaussiano utilizado no AAKR, tanto para a melhoria das medições aceitas como para correção das medições errôneas. Nessa análise, a navegação ocorre de acordo com a configuração original, onde se utiliza o algoritmo de rejeição apresentado na seção 7.3 para decidir sobre a validade da medição realizada.

Num segundo momento, o algoritmo de rejeição proposto, que explora o descritor de dados discutido na seção 5.3, substitui a solução original para a análise de medições. Como anteriormente, todo o algoritmo de navegação permanece como o original, sendo realizadas inferências e alterações somente nas medições do sistema de localização acústico. Finalmente, as duas soluções para correção e análise são agrupadas conforme algoritmos 1 e 2 mostrados no capítulo 6. Nessa etapa da análise, as medições armazenadas do tempo de chegada da onda acústica foram corrompidos propositadamente, predominantemente e aleatoriamente por reflexões dessa onda. Assume-se, portanto, que a trajetória real do veículo corresponde àquela carregada via Neptus com suas respectivas medições sensoriais. O algoritmo de navegação é então iniciado, porém são inseridos erros exógenos às medições de tempos de chegada do sistemas de localização antes de passar pelos algoritmos de correção e análise propostos nesse trabalho. Na condição de aceitas, as medições serão enviadas para o EKF executado ao longo da navegação.

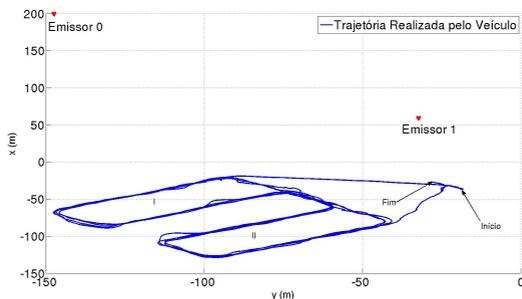
Ao final, a posição estimada pelo sistema de navegação é comparada, via métrica apropriada, com a posição obtida na navegação original que fora assumida como verdadeira. Através dessa comparação, é possível ver o ganho obtido com a solução proposta em relação ao obtido com o algoritmo atualmente disponível no veículo.

## 7.5 MODELO AUTOASSOCIATIVO

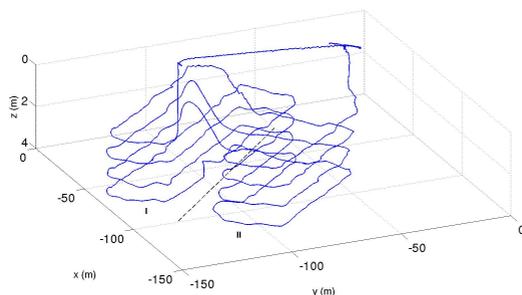
Nessa seção, será analisado exclusivamente o efeito da aplicação do modelo autoassociativo no sistema de localização visando à correção de desvios nos tempos de chegada. Para tanto, separa-se a análise em duas etapas: i) composição do banco de dados; ii) validação. Nessa análise, será utilizado o algoritmo de rejeição discutido na seção 7.3,

### 7.5.1 Composição do banco de dados

Considere a trajetória realizada pelo veículo mostrado na figura 43, que será utilizada para a composição do banco de dados com os tempos de chegada aceitos pelo esquema de rejeição.



(a) Trajetória realizada pelo veículo utilizada para ajuste de parâmetros (plano  $xy$ ).



(b) Trajetória realizada do veículo.

Figura 43: Exemplo de missão realizada pelo veículo. Os dados são utilizados para a composição do banco de dados com os tempos de chegada da onda acústica.

A configuração LBL mostrada na figura 41 é composta por emissores colocados a uma profundidade de aprox.  $2m$ , e pelo transdutor Neptune T257 instalado no veículo. Os emissores respondem simultaneamente a uma requisição do veículo utilizando frequências diferentes o que permitem serem diferenciados. Com o algoritmo de rejeição utilizando um limiar de referência ajustado em 4, foi possível armazenar 706 pares de medições de tempos de chegada aceitas através de uma missão com ampla cobertura do local de

exploração e em várias profundidades. Quanto ao valor  $\gamma_{ref} = 4$  mencionado, seu ajuste baseia-se em missões pretéritas bem sucedidas, realizadas na área de navegação analisada.

## 7.6 VALIDAÇÃO

Para a etapa de validação, considere a primeira trajetória mostrada na figura 44, realizada nas proximidades da trajetória mostrada na figura 43.

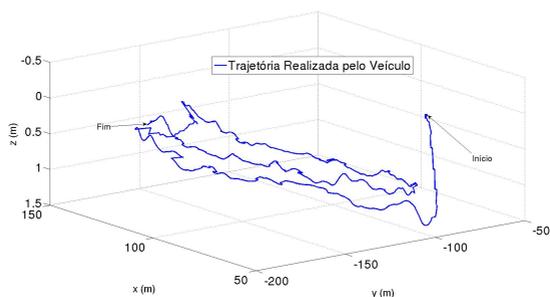


Figura 44: Primeira trajetória para a etapa de validação.

Utilizando as medições de tempo de chegada aceitas pelo esquema de rejeição durante a trajetória da figura 43 para compor o banco de dados, o modelo de regressão corrigiu algumas medições durante a trajetória da figura 44, como mostrado na tabela 6.

Tabela 6: Desempenho do sistema de localização com e sem aplicação do AAKR para correção dos tempos de chegada. Primeira trajetória

<b>Emissor</b>	<b>Total de Medições</b>	<b>Total de Rejeições</b>	<b>Total de Correções (AAKR)</b>
0	97	44	20
1	101	25	17

A fim de reduzir o custo computacional do algoritmo de correção através do AAKR, o banco de dados foi dividido de acordo com a proximidade entre a área de navegação e os emissores. Portanto, identificada, a partir dos tempos de chegada da onda sonora, em qual das regiões I e II mostradas na figura 43(a) realiza-se determinada navegação, a matriz  $\mathbf{Z}$  com o histórico de

dados a ser utilizada em 5.10 será composta exclusivamente com as medições referentes àquela região num determinado instante. As figuras 45 e 46 mostram os valores de  $\gamma_{ki}$  antes e após as correções realizadas nas medições dos emissores  $i = 0$  e 1.

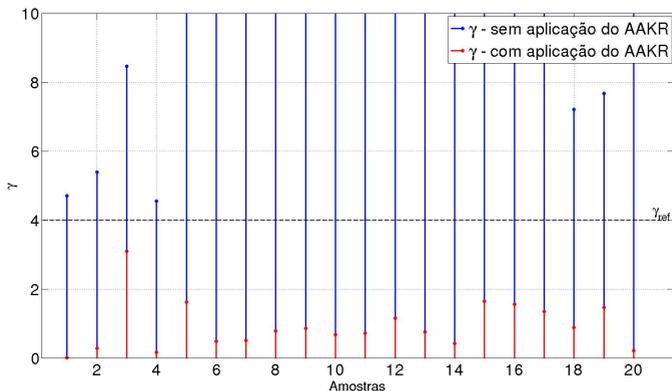


Figura 45: Valores de  $\gamma_k$  para o emissor 0 considerando os casos com e sem a aplicação do AAKR. Primeira trajetória.

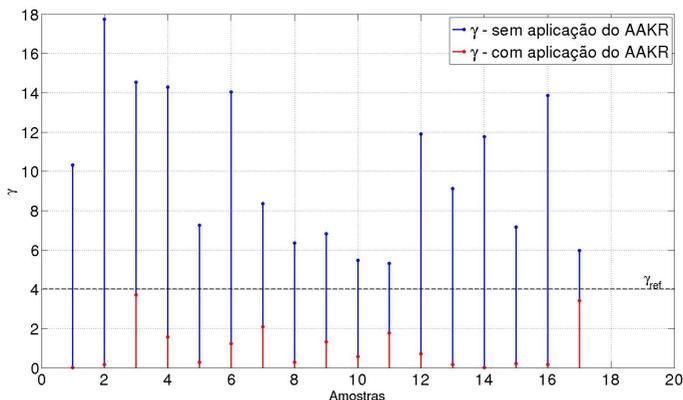


Figura 46: Valores de  $\gamma_k$  para o emissor 1 considerando os casos com e sem a aplicação do AAKR. Primeira trajetória

Considerando uma outra trajetória, mostrada na figura 47, aplicou-se

o AAKR com o mesmo banco de dados anterior obtendo-se os resultados apresentados na tabela 7.

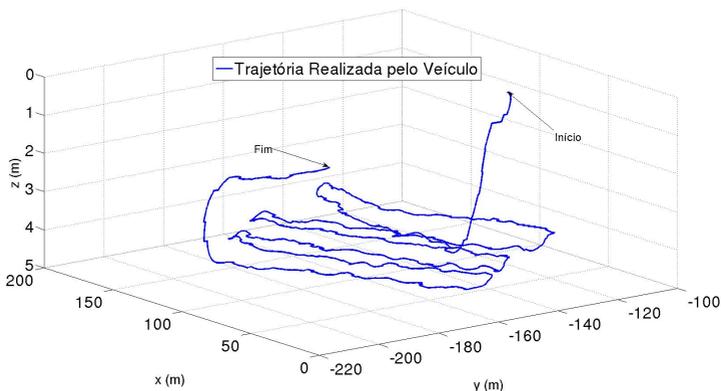


Figura 47: Segunda trajetória para a etapa de validação.

Tabela 7: Desempenho do sistema de localização com e sem aplicação do AAKR para correção dos tempos de chegada. Segunda trajetória.

<b>Emissor</b>	<b>Total de Medições</b>	<b>Total de Rejeições</b>	<b>Total de Correções (AAKR)</b>
0	251	92	27
1	266	79	39

Novamente, as figuras 48 e 49 detalham os valores de  $\gamma_{ki}$  antes e após a aplicação da correção utilizado o modelo autoassociativo.

Tendo em vista a qualidade do sistema inercial instalado no veículo e as condições ambientais favoráveis à navegação e à comunicação acústica, a redução dos valores de  $\gamma$  confirmam uma melhoria nas medições do tempo de chegada. Desse modo, os resultados mostrados nas figuras 45, 46, 48 e 49 ratificam a relevância da aplicação das correções efetuadas com os modelos autoassociativos. Apesar do erro estimado de posição não ser significativo em ambos os casos, devido às medições errôneas terem ocorrido em instantes de tempo bem espaçados, é possível observar que, ao realizar correções dessa natureza, poder-se-ia evitar navegações sem as correções nos desvios presentes nas medições inerciais por longos períodos. Além disso, na ocorrência

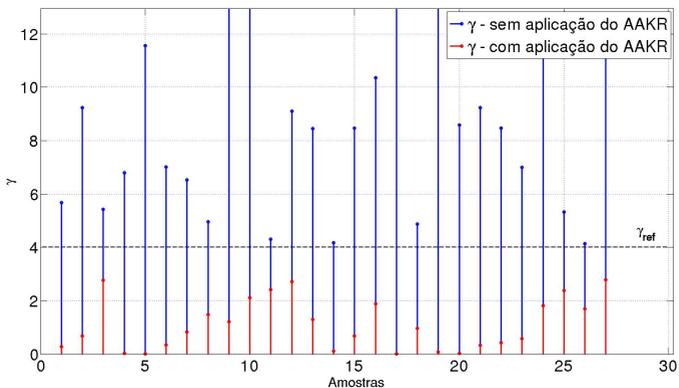


Figura 48: Valores de  $\gamma_k$  para o emissor 0 considerando os casos com e sem a aplicação do AAKR. Segunda Trajetória.

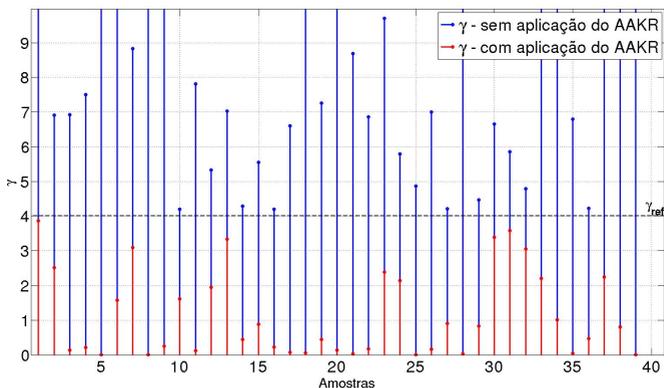


Figura 49: Valores de  $\gamma_k$  para o emissor 1 considerando os casos com e sem a aplicação do AAKR. Segunda Trajetória.

dessas correções as estimativas de posição do veículo e consequentemente o critério para validação de futuras medições do tempo de viagem da onda sonora tendem a melhorar continuamente. Valores diferentes para  $\gamma_{ref}$  podem ser definidos, como em [Miller, Farrell e Djapic 2010, Vaganay, Leonard e Bellingham 1996], de acordo com os equipamentos instalados no veículo ou algum conhecimento prévio sobre a qualidade do canal de comunicação.

## 7.7 AJUSTES DE PARÂMETROS

Na sequência, são detalhados os métodos utilizados para definir alguns parâmetros de entrada do sistema de navegação proposto. Nesse caso, algumas análises mostram uma tendência do comportamento do sistema com a variação de alguns desses valores. Primeiramente, a largura de banda  $h$  utilizada no kernel Gaussiano do AAKR será analisada para os casos de medições aceitas e rejeitadas. Posteriormente, será estudado o comportamento do sistema com a variação dos parâmetros  $s$ , do kernel Gaussiano do SVDD, e  $\beta$  do algoritmo de minimização.

Para as análises ao longo desse capítulo, a raiz quadrada do erro quadrático médio (RQ-EQM) da distância horizontal ou o erro de localização no plano  $xy$  em relação ao referencial inercial, definida como:

$$\text{RQ-EQM} = \sqrt{\frac{1}{N} \sum_{k=1}^N \left( (\hat{x}_k - x_k)^2 + (\hat{y}_k - y_k)^2 \right)}. \quad (7.2)$$

será a métrica fundamental para avaliação do desempenho do sistema.

### 7.7.1 Parâmetro $h$ - AAKR

#### 7.7.1.1 Medições Aceitas

Para a determinação do parâmetro  $h$  a ser utilizado no kernel Gaussiano do modelo autoassociativo na ocorrência de medições aceitas utilizar-se-á o conjunto de tempos de chegada aceitos na missão detalhada na figura 43, onde os tempos de chegada foram calculados sem a coordenada de posição  $z$ . O método de validação cruzada *leave-one-out*, descrito na seção 5.2.6, foi novamente utilizado para identificar a melhor largura de banda. Os resultados obtidos durante esse procedimento foram:

1. Tamanho da amostra (LBL): 706 leituras aceitas de cada emissor;
2. Escolha de  $h$ : algoritmo de busca entre um vetor de valores;
3. Normalização dos dados: Média zero e variância unitária;
4. Relação entre  $h$  e a raiz quadrada do erro quadrático médio da distância horizontal:

Como visto, os resultados mostrados na tabela 8 foram transformados para uma métrica de distância ( $m$ ) a partir da velocidade do som medida em

$h$	0.01	0.1	0.5	1.0	2.0
RQ-EQM ( $m$ )	0.85	1.46	2.40	4.17	4.37

Tabela 8: Evolução da raiz quadrada do erro quadrático médio da distância horizontal em função dos valores da largura de banda  $h$  para medições aceitas.

cada instante de modo a facilitar a avaliação do resultado. Fica explícita a influência do parâmetro  $h$  na capacidade do modelo de realizar boas estimativas a partir do vetor de entrada, ou seja, para os casos de boa representatividade do banco de dados disponível em relação aos dados de entrada, valores pequenos para a largura de banda serão mais eficientes. Do contrário, buscar-se-á uma média ponderada de todos os exemplos no banco de dados utilizando valores mais elevados para  $h$ .

Com vistas ao que foi exposto, no próximo passo, o parâmetro  $h$  será analisado com base nos exemplos negativos obtidos durante a mesma missão.

#### 7.7.1.2 Medições Rejeitadas

Nessa etapa analisam-se os resultados com a aplicação do AAKR, que utiliza um banco de dados construído ao longo da navegação, e as medições rejeitadas. Para esse procedimento, tem-se:

1. Tamanho da amostra (LBL): 26 leituras rejeitadas(emissor 0) e 24 leituras rejeitadas(emissor 1);
2. RQ-EQM ( $m$ ) entre a posição do veículo considerando a navegação com e sem o esquema de rejeição:  $10m$ ;
3. Escolha de  $h$ : busca entre um vetor de valores;
4. Normalização dos dados: Média zero e variância unitária;
5. Relação entre  $h$  e a raiz quadrada do erro quadrático médio da distância horizontal:

$h$	0.01	0.8	1.0
RQ-EQM ( $m$ )	6.0	3.16	3.0

Tabela 9: Evolução do RQ-EQM ( $m$ ) em função dos valores da largura de banda  $h$  para medições rejeitadas.

Os resultados das tabelas 8 e 9 confirmam o que fora mencionado no capítulo 5 acerca da influência do parâmetro  $h$  do kernel Gaussiano no resultado do modelo de regressão. Quando o vetor de entrada está bem representado pelo banco de dados disponível, valores pequenos de  $h$  elevam a ponderação nos exemplos mais próximos aos de entrada, polarizando a estimação. Por outro lado, nos caso de medições rejeitadas, valores maiores de  $h$  tendem a contabilizar a influência de todas as medições do banco de dados uma vez que a medição não está bem representada pelo conjunto de medições presentes no banco de dados.

### 7.7.2 Parâmetros $\beta$ e $s$ - SVDD

Na sequência o ajuste dos parâmetros  $\beta$  na equação 5.26 e  $s$  na equação 5.39 será avaliado. Para isso, serão analisadas combinações de valores desses parâmetros e o desempenho do algoritmo quando aplicado à detecção de medições errôneas. A avaliação da distância do vetor de entrada ao centro da região de fronteira, mostrado na figura 37, será realizada comparando as distâncias  $d_{11}$  e  $d_{22}$  com o raio em duas dimensões  $R_{12}$  e posteriormente a distância  $d_{11}$  com o raio  $R_{11}$  e a distância  $d_{22}$  com o raio  $R_{22}$ , todos detalhados na seção 6.3.1. Em ambos os casos, a métrica RQ-EQM será calculada com base nas estimativas de posição  $(x,y)$  obtidas na navegação mostrada na figura 43 onde mais uma vez utilizou-se  $\gamma_{ref} = 4$  para a desigualdade 7.1 do algoritmo de rejeição.

#### 7.7.2.1 Avaliação utilizando $d_{11}$ e $d_{22}$ com $R_{12}$

A tabela 10 traz o comportamento do RQ-EQM para uma combinação de valores dos parâmetros  $\beta$  e  $s$  tendo em vista que as distâncias calculadas em cada uma das dimensões foram comparadas com o raio calculado a partir dos pares de resíduos, como detalhado na figura 37. Nas simulação realizadas, valores de  $s$  acima de 50 não implicaram em reduções nos valores de RQ-EQM, enquanto valores muito inferiores a 0.2 para  $\beta$  reduziam o número de exemplos alvos utilizados na determinação da região de fronteira, o que eleva o custo computacional sem uma melhoria significativa nos resultados. O banco de dados com os resíduos aceitos é atualizado em tempo de execução e uma nova região de fronteira com um novo raio é obtida a cada nova inserção.

$\beta$	$s$			
	5	15	25	50
0.2	$9.6 \times 10^{-1}$	$9.0 \times 10^{-1}$	$9.0 \times 10^{-1}$	$9.4 \times 10^{-1}$
0.5	$5.5 \times 10^{-1}$	$1.6 \times 10^0$	$1.0 \times 10^0$	$1.0 \times 10^0$
1.0	$5.5 \times 10^{-1}$	$6.5 \times 10^{-1}$	$6.5 \times 10^{-1}$	$6.5 \times 10^{-1}$

Tabela 10: Evolução do RQ-EQM ( $m$ ) em função dos parâmetros do SVDD.7.7.2.2 Avaliação utilizando  $d_{11}$  com  $R_{11}$  e  $d_{22}$  com  $R_{22}$ 

O resultado mostrado na tabela 11 refere-se ao comportamento do RQ-EQM ( $m$ ) para as mesmas combinações de valores dos parâmetros  $\beta$  e  $s$ , mas, nesse caso, comparando as distâncias ao centro da região de fronteira com os raios calculados numa mesma dimensão.

$\beta$	$s$			
	5	15	25	50
0.2	$3.5 \times 10^{-1}$	$5.0 \times 10^{-1}$	$5.0 \times 10^{-1}$	$5.5 \times 10^{-1}$
0.5	$1.0 \times 10^{-2}$	$1.0 \times 10^{-1}$	$2.0 \times 10^{-2}$	$2.0 \times 10^{-2}$
1.0	$1.5 \times 10^{-2}$	$1.5 \times 10^{-1}$	$1.6 \times 10^{-1}$	$1.6 \times 10^{-1}$

Tabela 11: Evolução do RQ-EQM ( $m$ ) em função dos parâmetros do SVDD.

A figura 50 mostra as alterações no formato da região de fronteira para cada combinação de valores utilizada. É importante ressaltar que os valores obtidos nas tabelas refletem o desempenho do algoritmo de rejeição utilizando o SVDD quando comparado às estimativas de posição da navegação com  $\gamma_{ref} = 4$ , o que não representa necessariamente a posição real do veículo. Desse modo, não é possível identificar precisamente qual a melhor opção de parâmetros, mas percebe-se que uma redução em  $s$  faz a borda moldar-se de acordo com a distribuição dos dados, enquanto um decréscimo em  $\beta$  reflete no número de exemplos considerados errôneos na base de dados. Essas características dos parâmetros  $s$  e  $\beta$  precisam ser devidamente exploradas, ou seja, com o aumento de  $s$ , maior será a área de cobertura da região de fronteira e menor o número de vetores suportes, ao passo que, um decréscimo em  $\beta$  resultará numa diminuição dessa área e portanto a exclusão de alguns exemplos considerados alvos no banco de dados.

A análise da figura 50 é fundamental para avaliar a sensibilidade do algoritmo em relação às escolhas dos parâmetros  $s$  e  $\beta$ , bem como identificar a região de concentração dos dados e os exemplos que foram retirados da linha

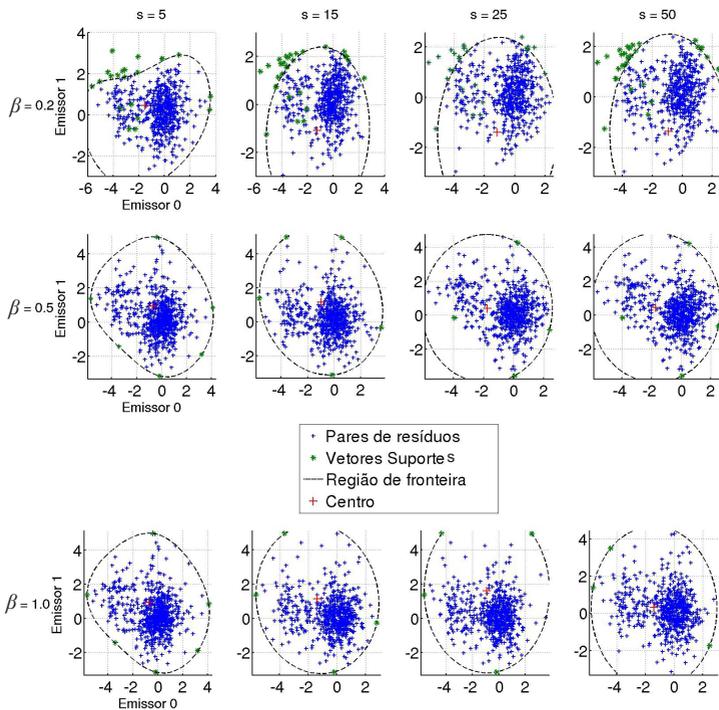


Figura 50: Região de fronteira para diferentes valores dos parâmetros  $s$  e  $\beta$  no algoritmo do SVDD.

limítrofe. Com esse resultado, busca-se ajustar esses parâmetros de modo que o algoritmo consiga rejeitar os exemplos conhecidos como negativos a partir da amostragem dos exemplos positivos, ambos oriundos da mesma missão. Os valores de  $s$  e  $\beta$  que resultaram num comportamento mais próximo ao resultado obtido com o algoritmo atualmente utilizado no sistema de navegação do veículo serão os valores de partida para as próximas análises.

## 7.8 VALIDAÇÃO DA PROPOSTA

Nas secções subsequentes será analisado o desempenho da arquitetura proposta discutida no capítulo 6. Antes, porém, faz-se necessário caracterizar uma fonte de erro exógena, a ser utilizada durante as simulações, utilizando os dados reais de navegação e que servirão para comparar a estratégia atualmente em execução nos veículos com a solução proposta nesse trabalho para o sistema de localização acústico.

### 7.8.1 Modelo de Propagação

Para melhor descrever a fonte de erro exógena a ser inserida nas análises subsequentes, utilizou-se o modelo de traçamento de raios mostrado na figura 51, considerando a leito do local do experimento sem relevo acentuado e velocidade do som constante ao longo da coluna d'água. Nessa situação, os raios apresentam ângulos de incidência e reflexão iguais, o que permite definir geometricamente a distância percorrida pelo raio acústico até atingir o receptor.

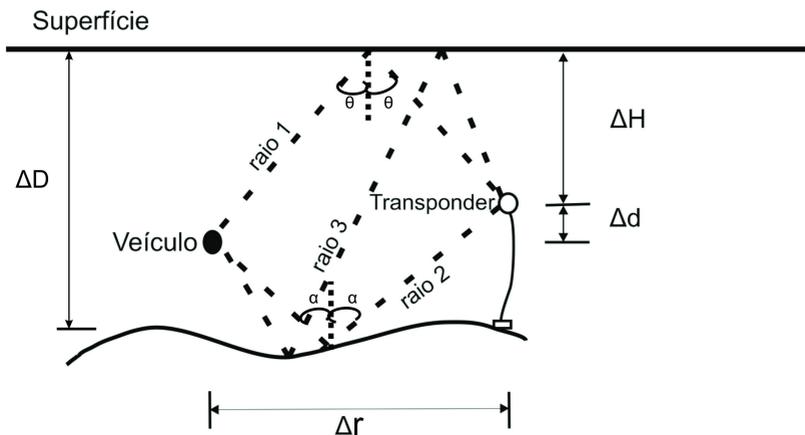


Figura 51: Modelo de propagação dos raios acústicos.

Nesse caso, o parâmetro  $\Delta r$  corresponde à distância entre o emissor e o veículo,  $\Delta H$  à profundidade do emissor,  $\Delta d$  à profundidade do veículo em relação ao emissor e  $\Delta D$  à profundidade do local de navegação. Com base nesse modelo, pode-se assumir que na propagação da onda sonora três fenô-

menos ou hipóteses  $H p_k$  possuem probabilidade ( $Pr$ ) de ocorrência: caminho direto (CD), múltiplos caminhos (MC) e medições errôneas (ER). Seguindo o modelo apresentado em [Bingham e Seering 2006], em todos esses três casos, o tempo de chegada  $t_k$  é modelado pelas relações em 7.3.

$$t_k = \begin{cases} \frac{1}{c} \|B - \mathbf{p}(t)\| + n_{CD}, & H p_k = CD; \\ f_{mp}(\mathbf{p}(t), B, \Phi) + n_{MC}, & H p_k = MC; \\ n_{er}, & H p_k = ER; \end{cases} \quad (7.3)$$

onde

$$\begin{aligned} n_{CD} &\sim N(0, \sigma_{CD}^2) \\ n_{MC} &\sim N(0, \sigma_{MC}^2) \\ n_{ER} &\sim \text{Uniforme} \end{aligned} \quad (7.4)$$

e os parâmetros  $B$  e  $\mathbf{p}(t)$  são os mesmos definidos em 4.31. O parâmetro  $\Phi$  está relacionado a algumas variáveis relativas ao posicionamento dos emissores fixados, como a sua profundidade, e à profundidade do veículo. Considerando a velocidade do som constante ao longo da coluna d'água, o ângulo de reflexão é igual ao de incidência e assim é possível chegar à seguinte relação para a distância percorrida pelo raio 1 da figura 51 ( $d_{MC_1}$ ) [Bingham e Seering 2006]:

$$\begin{aligned} d_{MC_1} &= \frac{\Delta r}{\sin(\theta)}, \\ \theta &= \arctan\left(\frac{\Delta x}{2H - \Delta d}\right) \end{aligned} \quad (7.5)$$

onde  $\theta$  refere-se ao ângulo de reflexão na superfície e  $\alpha$  ao ângulo de reflexão no leito. Com esse modelo de propagação e com o posicionamento dos emissores durante as missões analisadas, obtém-se um erro adicional de aprox. 1.5m para cada 100m de distância entre os emissores e o veículo.

Dado que a profundidade ( $\Delta D$ ) é assumida constante e conhecida em aproximadamente 7,0m, uma expressão equivalente a 7.5 pode ser obtida para a distância percorrida pelo raio 2 ( $d_{MC_2}$ ). Para o raio 3, assumindo reflexão total da onda sonora e  $\alpha = \theta$ , devido à não alteração na velocidade do som ao longo da coluna d'água, chega-se a seguinte expressão para a distância percorrida para esse raio:

$$d_{MC_3} = \frac{\Delta r}{\sin(\theta)}, \quad (7.6)$$

$$\theta = \arctan\left(\frac{\Delta r}{2Z - \Delta d}\right)$$

Os exemplos não modelados como múltiplos caminhos, definidos anteriormente como exemplos errôneos, variam num intervalo  $\pm 15 m$  a partir da posição do veículo. Esse valor foi escolhido com base em navegações anteriores que apresentaram desvios significativos entre o valor medido e o estimado. Como exemplo, vê-se na figura 52 que algumas medições divergiram da posição esperada em torno de  $15 m$ , considerando distâncias do emissor ao veículo entre 100 e 200  $m$ , ou seja aprox. 10%.

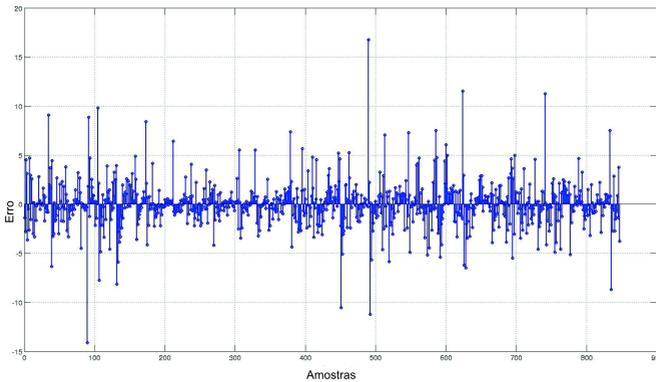


Figura 52: Exemplos de medições errôneas em uma missão com o LAUV.

Portanto, para as simulações que se seguem, será necessário definir previamente a probabilidade  $Pr(Hp_k)$  de ocorrência de cada hipótese  $Hp_k$  levantadas em 7.3 em cada instante  $k$  que ocorre uma medição.

### 7.8.2 Aplicação do Algoritmo Proposto - Primeira trajetória

Antes de avaliar o desempenho dos algoritmos, definem-se as probabilidades das hipóteses supracitadas para o caminho direto (CD), reflexões ou múltiplos caminhos (MC) e medições errôneas (ER). Para as simulações

seguintes, adotou-se o critério abaixo:

- Probabilidade de ocorrência de propagação em caminho direto (CD): 30%;
- Probabilidade de ocorrência de propagação em múltiplos caminhos (MC): 20% para cada um dos raios 1, 2 e 3;
- Probabilidade de ocorrência de medições errôneas (ER): 10%;

Os valores de probabilidade acima justificam-se por resultarem em valores de RQ-EQM para a distância horizontal entre veículo e emissores acústicos da ordem de 1 a 3 *m*. Valores de probabilidades inferiores para a ocorrência de múltiplos caminhos principalmente implicam em erros de posição de pouca significância e de difícil análise quanto ao desempenho das duas abordagens. Por outro lado, valores muito superiores para essas probabilidades implicariam em erros que não justificariam o emprego de um sistema de localização acústico, além de dificultar sobremaneira o processo de treinamento exigido no algoritmo de navegação proposto.

Desse modo, como primeiro exemplo de aplicação do sistema de localização, será considerada novamente a navegação mostrada na figura 43. O objetivo dessa análise é identificar qual a melhor estratégia para o descarte das medições de entrada dentre aquelas mostradas na figura 37. Além disso, identificar-se-á qual o melhor ajuste para os parâmetros  $\beta$  e  $s$  na faixa de valores mostrados na figura 50.

#### 7.8.2.1 Avaliação do Algoritmo utilizando $d_{11}$ e $d_{22}$ com $R_{12}$

Como anteriormente, a avaliação será realizada comparando as distâncias em cada dimensão com o raio obtido a partir dos pares de exemplos. A tabela 12 mostra os valores de RQ-EQM da distância horizontal obtidos com a utilização do descritor de dados para o algoritmo de rejeição bem como os valores obtidos com a solução atual considerando seus melhores resultados. Nesse caso, os pares de resíduos aceitos foram utilizados para calcular a região de fronteira, o centro e o raio, sendo esse comparado com as distâncias em dimensões separadas.

Os valores entre parênteses em subscrito correspondem ao  $\gamma_{ref}$  utilizado que gerou os resultados mostrados. Para o SVDD, o parâmetro  $s$  foi ajustado em 25 e  $\beta$  em 0.2 para todos os casos.

As figuras 53(a) e 53(b) mostram os valores médios da raiz quadrada do erro de posição em  $x$  e  $y$  considerando novamente as duas abordagens estudadas.

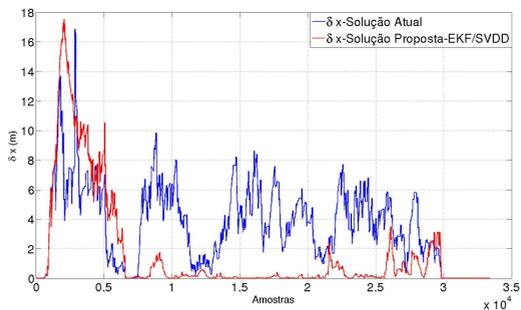
Nº	Arquiteturas	
	Arquitetura Atual	Arquitetura Proposta
1	2.72 <sub>(0.65)</sub>	1.94
2	2.42 <sub>(0.65)</sub>	1.67
3	2.54 <sub>(0.80)</sub>	1.73
4	2.56 <sub>(0.80)</sub>	1.82
5	2.60 <sub>(0.80)</sub>	1.30
6	2.64 <sub>(0.80)</sub>	2.08
7	2.76 <sub>(0.90)</sub>	1.85
8	2.71 <sub>(0.80)</sub>	1.77
9	2.53 <sub>(0.80)</sub>	1.93
10	2.50 <sub>(0.80)</sub>	2.00

Tabela 12: Comparação de valores do RQ-EQM ( $m$ ) em 10 execuções utilizando as duas arquiteturas em análise. No SVDD, o raio é calculado utilizando as duas dimensões e as distâncias calculadas em dimensões separadas.

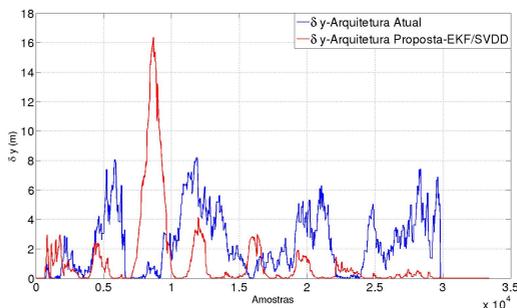
#### 7.8.2.2 Avaliação do algoritmo utilizando $d_{11}$ com $R_{11}$ e $d_{22}$ com $R_{22}$

Novamente, para essa análise, as distâncias serão comparadas separadamente aos respectivos raios nas dimensões correspondentes. A tabela 13 mostra os valores de RQ-EQM da distância horizontal para o caso onde as comparações entre o raio da região de descrição dos dados e a distância do vetor de entrada ao ponto central foram realizadas em dimensões separadas. Também nessa simulação, tanto a região de fronteira como centro foram obtidos a partir dos pares de resíduos. Novamente, para o SVDD, os parâmetros  $s$  e  $\beta$  foram ajustados em 25 e 0.2 respectivamente.

Os resultados mostrados nas tabelas 12 e 13 não deixam dúvidas quanto à melhoria no RQ-EQM ao utilizar a segunda abordagem para as comparações entre as distâncias de cada exemplo ao centro e o raio da região de fronteira. Assim, os pares de resíduos são utilizados para definir a região de fronteira (raio e centro) enquanto a definição sobre o aceite ou rejeição de uma dada medição é realizada em dimensões separadas. Nessas simulações, os resultados mostraram significativa sensibilidade às variações nos parâmetros  $s$  e  $\beta$ , o que implica na necessidade de um ajuste adequado desses valores.



(a) Valores médios de  $\delta x$  considerando as duas arquiteturas em análise.



(b) Valores médios de  $\delta y$  considerando as duas arquiteturas em análise.

Figura 53: Valores médios da diferença entre a posição estimada e a real do veículo considerando o modelo de propagação de raios e as duas arquiteturas para o sistema de localização. No SVDD, o raio é calculado utilizando as duas dimensões e as distância calculadas em dimensões separadas.

### 7.8.3 Aplicação do Algoritmo Proposto - Segunda trajetória

Nessa seção, o algoritmo proposto será utilizado e avaliado quanto ao seu desempenho e novamente comparado à solução que é atualmente utilizada nos veículos subaquáticos. Nas figuras 55 a 57 destaca-se a trajetória 2 realizada com o LAUV e que será utilizada nessa etapa de validação. O banco de dados inicial será composto por um conjunto de medições de tempos de chegada aceitas e os respectivos resíduos obtidos na trajetória 1 mostrada na figura 43.

O sistema de navegação instalado no veículo reportou seguintes resultados referentes às medições do LBL:

Arquiteturas	
Arquitetura Atual	Arquitetura Proposta
2.72	1.10
2.42	2.33
2.54	2.84
2.56	1.80
2.60	1.15
2.64	2.50
2.76	2.15
2.71	1.96
2.53	2.43
2.50	2.12

Tabela 13: Comparação de valores do RQ-EQM ( $m$ ) em 10 execuções utilizando as duas arquiteturas em análise. No SVDD, os raios e as distâncias são calculados dimensões separadas.

1. Número de total medições (LBL): 920 leituras de cada emissor;
2. Amostras Rejeitadas: 5 amostras do emissor 0 e 7 amostras do emissor 1;

Para visualizar o efeito da aplicação do modelo de raios mencionado, a figura 58 compara a trajetória com e sem a aplicação desse modelo e com o algoritmo de rejeição utilizado atualmente nos veículos.

A tabela 12 compara os valores da raiz quadrada do erro quadrático médio da distância horizontal em relação ao referencial inercial real e estimada, quando os algoritmos atual e proposto são aplicados. É possível observar uma significativa melhora no processo de localização do veículo, principalmente quando o efeito da aplicação do modelo de raios resulta em valores maiores para RQ-EQM.

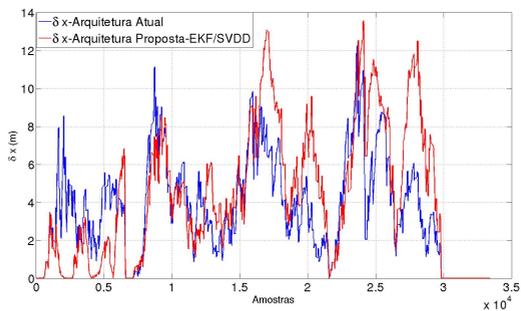
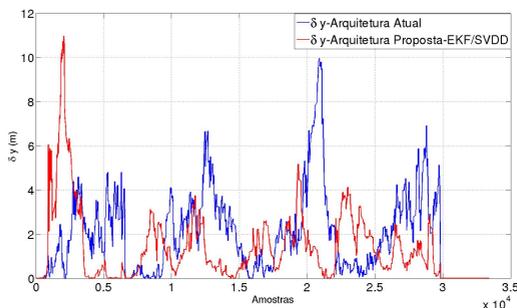
(a) Valores médios de  $\delta x$  considerando as duas arquiteturas em análise.(b) Valores médios de  $\delta y$  considerando as duas arquiteturas em análise.

Figura 54: Valores médios da diferença entre a posição estimada e a real do veículo considerando o modelo de propagação de raios e as duas arquiteturas para o sistema de localização. No SVDD, os raios e as distâncias são calculados dimensões separadas.

Os valores de largura de banda do kernel Gaussiano ( $h$ ) utilizado no AAKR foi ajustado com base nos resultados das simulações de modo a atingir um maior número de correções para os tempos de chegada. A tabela 15 mostra os valores obtidos de acordo com a distância do vetor de entrada ao centro da região de descrição dos dados.

É importante salientar que os valores de  $h$  mostrados estão associados diretamente aos parâmetros  $s$  e  $\beta$  do SVDD de modo que novos ajustes nesses parâmetros exigiria um novo procedimento para a escolha mais adequada dos valores de  $h$ . A aplicação do AAKR em conjunto com o SVDD resultou em:

1. Número de medições rejeitadas e corrigidas:

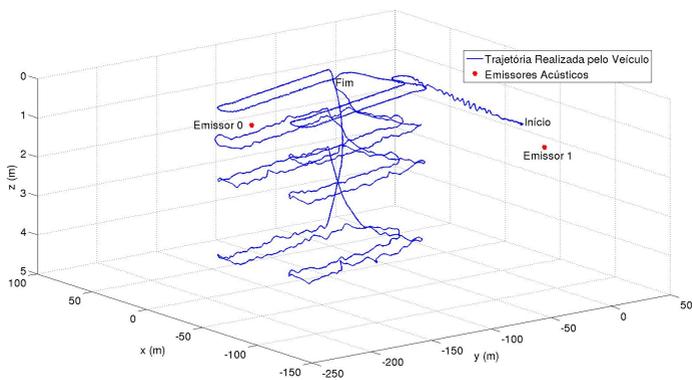


Figura 55: Trajetória realizada do veículo para validação - vista 1.

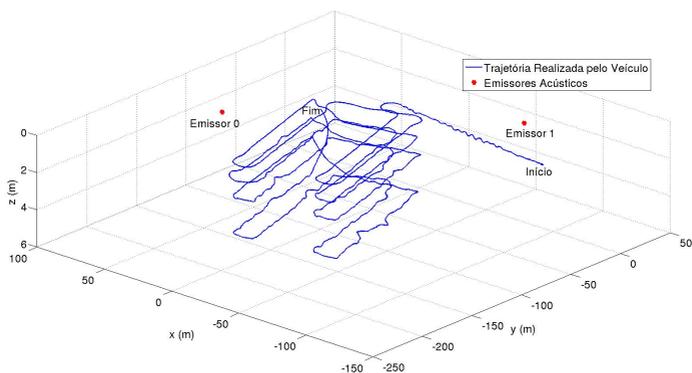


Figura 56: Trajetória realizada do veículo para validação - vista 2.

- Emissor 0 : 11 medições;
- Emissor 1 : 17 medições;

2. Número de medições aceitas e corrigidas:  $> 120$ ;

Como esperado, para os casos onde ocorrem pequenos erros de posição, as duas arquiteturas tendem a apresentar desempenhos semelhantes, como os mostrados nas tabelas 10 e 11. A figura 59 mostra os valores da raiz

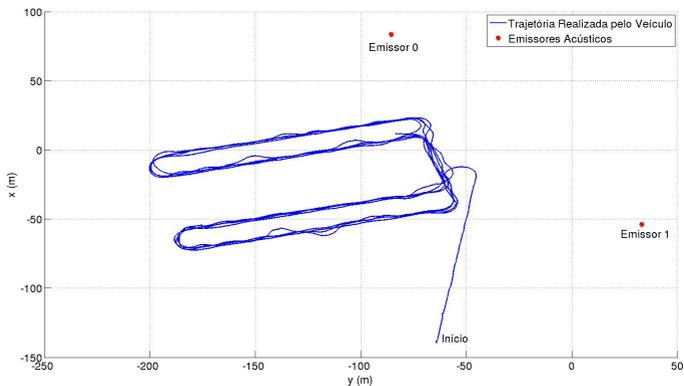


Figura 57: Trajetória realizada do veículo para validação - plano  $xy$ .

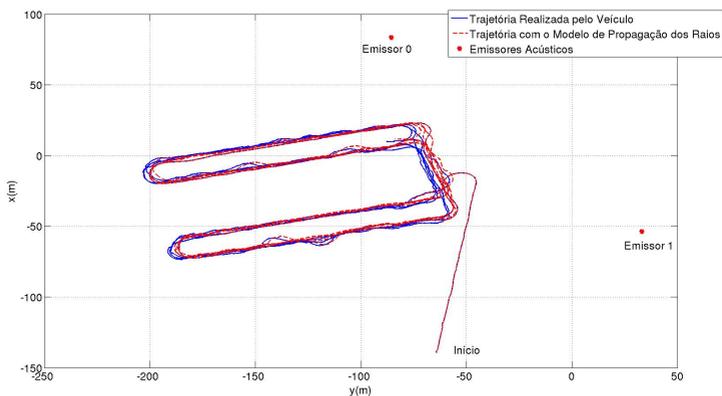


Figura 58: Trajetória Estimada do veículo com e sem aplicação do modelo de propagação de raios.

quadrada do erro de posição do veículo em  $x$  e  $y$  para essa segunda trajetória com a aplicação da arquitetura proposta em comparação com a solução atual.

Para o SVDD, a figura 60 mostra um exemplo de região de fronteira para um dos casos mostrados na tabela 14. A fim de reduzir o custo computacional para obtenção da região descritora de dados, é pertinente recalcular uma nova região de fronteira com os respectivos raios e centro somente quando potenciais vetores suportes são identificados, ou seja, vetores de en-

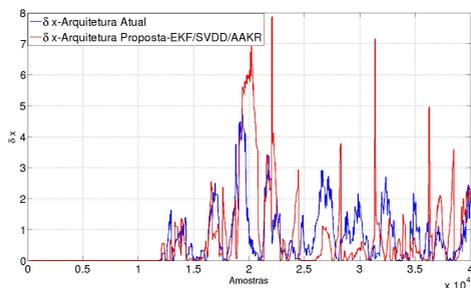
Arquiteturas	
Arquitetura Atual	Arquitetura Proposta SVDD/AAKR
2.57 <sub>(0.80)</sub>	1.08
2.21 <sub>(0.65)</sub>	$7.5 \times 10^{-1}$
2.17 <sub>(0.80)</sub>	$9.7 \times 10^{-1}$
2.04 <sub>(0.80)</sub>	$8.5 \times 10^{-1}$
2.07 <sub>(0.80)</sub>	$8.8 \times 10^{-1}$
2.00 <sub>(0.65)</sub>	$9.9 \times 10^{-1}$
1.99 <sub>(0.65)</sub>	1.20
1.49 <sub>(0.50)</sub>	1.00
1.18 <sub>(0.45)</sub>	1.05
$9.4 \times 10^{-1}$ <sub>(0.45)</sub>	$8.2 \times 10^{-1}$

Tabela 14: Comparação de valores do RQ-EQM ( $m$ ) em 10 execuções utilizando as arquiteturas em análise. No SVDD, o raio é calculado utilizando as duas dimensões e as distância calculadas em dimensões separadas. No AARK, a regressão é aplicada em uma e duas dimensões, optando-se pelo melhor resultado.

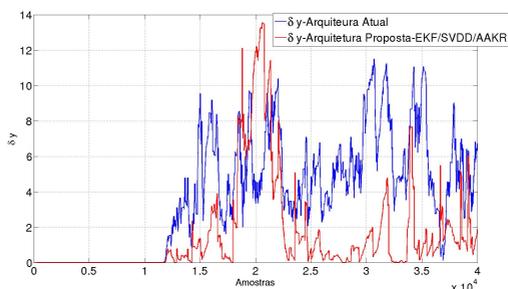
Distância ao centro da região de fronteira( $d$ )	Largura de banda do Kernel ( $h$ )
$d \leq R$	$h = 0.01$
$R < d \leq 1.5R$	$h = 0.15$
$1.5R < d \leq 2R$	$h = 0.25$
$2R < d$	$h = 0.5$
$3R < d$	$h = 1.0$
$4R < d \leq 5R$	$h = 2.0$
$5R < d$	$h = 2.5$

Tabela 15: Valores para a largura de banda do kernel do modelo autoassociativo de acordo com a distância ao centro da região de fronteira do descritor de dados.

trada menores que o raio, mas que estão próximos à borda dessa região. Para os exemplos muito próximos do centro da região, uma nova execução do algoritmo pouco ou em nada contribuirá para definir um novo descritor de dados. Assim, nos exemplos mostrados, a região de fronteira foi redefinida somente quando os exemplos de entrada estavam na faixa de  $0.5R \leq d \leq R$ .



(a) Valores médios de  $\delta x$  considerando as duas arquiteturas em análise. Segunda trajetória



(b) Valores médios de  $\delta y$  considerando as duas arquiteturas em análise. Segunda trajetória.

Figura 59: Valores médios da diferença entre a posição estimada e a real do veículo considerando o modelo de propagação de raios e as duas arquiteturas para o sistema de localização. Segunda trajetória.

## 7.9 CONCLUSÕES

Os resultados discutidos nesse capítulo atestam a eficácia do algoritmo proposto nesse trabalho. Para tanto, três etapas fundamentais foram destacadas: i) ajuste de parâmetros; ii) treinamento; iii) validação. No ajuste de parâmetros, as tabelas 8 e 9 confirmaram a influência da largura de banda do kernel Gaussiano  $h$  no processo de correção das medições aceitas, com valores menores, e das medições rejeitadas, com valores maiores. Quanto aos parâmetros  $\beta$  e  $s$ , pertinentes ao algoritmo de rejeição, são certamente os mais difíceis de serem ajustados devido ao custo computacional associado a uma determinada escolha e seu efetivo ganho na qualidade da classificação das medições. A utilização de um banco de dados confiável, abrangendo medi-

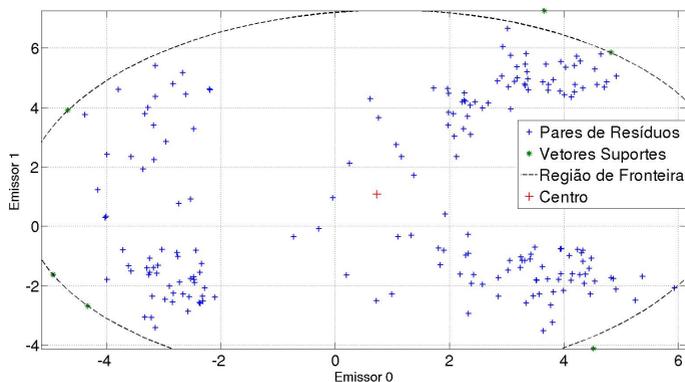


Figura 60: Exemplo de região de fronteira obtido a partir das simulações com a segunda trajetória do veículo. Os valores de  $s$  e  $\beta$  foram ajustados em 25 e 0.2 respectivamente.

ções nas diversas regiões a serem navegadas, possibilita a varredura de ampla faixa de valores desses parâmetros, como mostrado na figura 50, e assim a escolha apropriada.

Nas análises realizadas nesse capítulo, o banco de dados utilizado tanto para correção quanto para identificação de medições errôneas foi composto com dados aceitos provenientes de missões anteriores e da missão corrente. Essa composição de dados, fundamental no algoritmo proposto nesse trabalho, corresponde a etapa de treinamento. Para validação, o modelo de propagação utilizado procurou ser fiel aos tipos de ocorrências na propagação acústica em ambiente aquático, principalmente em curtas distâncias, onde a velocidade do som é praticamente constante. Além disso, por serem utilizadas num filtro de estimação, um maior número de medições precisa ser aproveitado. Desse modo, as análises realizadas em uma dimensão permitiram avaliar as medições separadamente, como mostrado nas tabelas 12 e 13, a fim de serem aproveitadas pelo algoritmo de fusão de dados.

Definidos todos esses parâmetros e observado o desempenho nas etapas individuais de correção e identificação de exemplos errôneos, o algoritmo proposto foi aplicado de modo completo na execução da segunda trajetória e mostrou, como observado pelos resultados da tabela 14, suas vantagens em relação à solução atualmente utilizada nos veículos.

Por fim, é importante salientar que o veículo utilizado para a coleta dos dados apresentados é equipado como unidade de medição inercial de

excelente precisão. Desse modo, mesmo na ausência de um sistema de localização acústico preciso, apenas pequenos desvios na trajetória são esperados, quando o veículo opera em condições normais e ambiente favorável. Destaca-se ainda as condições da água e as características do local onde foram realizados os testes. A região portuária apresenta um relevo de fundo pouco acidentado, águas paradas com pouca perturbação de agentes externos como embarcações e chuvas. Todo esse cenário favorece a propagação acústica e as manobras do veículo, o que também viabiliza, por meio de comparações, a validação do sistema implementado com a instrumentação utilizada.



## 8 CONCLUSÃO E PERSPECTIVAS FUTURAS

Esta tese abordou o problema da localização de veículos autônomos subaquáticos que utilizam sinais acústicos para determinar sua posição relativa aos emissores e assim sua localização em relação a um referencial inercial. A configuração analisada é conhecida como *Long Base Line* cujo uso é bastante difundido em navegações com essas plataformas robóticas. A principal contribuição da tese concerne à arquitetura do sistema de localização do ponto de vista do algoritmo, cujas principais funções são: classificação das medições e correção de desvios. Em conjunção com o conjunto de sensores embarcados no veículo e o filtro de fusão de dados, procura-se estabelecer um novo critério para identificação de medições corretas de modo a também classificá-las e corrigi-las apropriadamente. Este capítulo apresenta uma visão geral do que foi abordado ao longo desse trabalho e aponta algumas perspectivas futuras quanto ao que foi pesquisado.

### 8.1 CONTRIBUIÇÃO - VISÃO GERAL

A principal contribuição do trabalho desenvolvido nessa tese refere-se à integração dos três conceitos fundamentais detalhados na figura 3 no capítulo 1. Tendo o foco principal na localização acústica, em particular no sistema LBL, o trabalho apresentou uma nova arquitetura para o sistema de localização, estabelecendo um novo critério para aceitação ou descarte de medições dos tempos de chegada da onda sonora, bem como a correção de eventuais desvios nessas quantidades devido às flutuações no canal de comunicação. Os objetivos específicos lançados inicialmente foram alcançados ao longo do desenvolvimento do trabalho de modo a culminar na arquitetura final para o sistema de localização.

#### 1. Modelar a propagação de ondas sonoras em meios aquáticos:

Alguns problemas encontrados em localização acústica foram apresentados e quantificados por meio de simulações no capítulo 2. As questões relativas à relação sinal/ruído, à variação da velocidade do som e reflexões da onda sonora foram apresentadas com o intuito de justificar a relevância da pesquisa conduzida nesse trabalho. De modo geral, a arquitetura proposta para o sistema de localização independe do filtro utilizado para detectar o tempo de chegada da onda sonora ou o tipo de sinal emitido por ambos agentes, veículo e boias. Apesar disso, o filtro adaptado com um pulso de curta duração foi avaliado e a influência de uma baixa relação sinal ruído, comum em

navegação subaquática, sobre as estimativas do tempo de chegada foram avaliadas. Ainda nesse mesmo capítulo, as bases da arquitetura foram descritas bem como detalhados cada um dos blocos relativos à filtragem, classificação e correção.

2. Avaliar as especificações técnicas, modelos e desempenho dos sensores comumente embarcados em veículos subaquáticos, além de sua integração com o sistema inercial:

Os capítulos seguintes trouxeram detalhes dos aspectos teóricos que envolvem a navegação autônoma. Em particular, foram definidos os sistemas de referência e o sistema de navegação inercial responsável pelas estimativas de posição, velocidade e orientação do veículo. Como visto, devido às inerentes fontes de erro dos sensores inerciais, uma plataforma multisensorial é imprescindível para a tarefa de correção e melhoria na precisão das grandezas estimadas, como observado pelas simulações com o modelo do veículo INFANTE. Com respeito a essa fusão de dados sensoriais, apesar de inúmeras variações e novos métodos de filtragem, com abordagens parametrizadas ou não e ainda diferentes combinações de estratégias, o filtro de Kalman estendido foi apresentado e seu equacionamento detalhado devido a sua ampla aceitação em robótica probabilística. Nesse ponto, destacam-se a identificação das variáveis a serem utilizadas posteriormente nos algoritmos de classificação e correção, qual informação é retornada por esses algoritmos e onde esses novos dados são inseridos no algoritmo de filtragem. Na sequência do trabalho, o sensoriamento externo comumente utilizado em veículos dessa natureza foi apresentado e foram detalhados seus modelos matemáticos, a fim de serem compreendidos e utilizados no processo de fusão de dados. Sensores como o de velocidade absoluta, de velocidade relativa à água e de posicionamento são os principais destacados nessa etapa do trabalho.

3. Propor modelos baseados em funções kernel que visam a classificar os dados quanto a sua qualidade e a corrigir medições:

No capítulo 5 foram apresentados os aspectos teóricos dos modelos baseados em funções kernel utilizados na arquitetura proposta para as tarefas de classificação e correção. Para essa, uma função de regressão com base num modelo autoassociativo busca melhorar as medições de tempos de chegada com base em um histórico de medições obtidas em navegações anteriores ou na própria missão. Dentre suas principais vantagens, estão a simplicidade na implementação do algoritmo e sua adaptação a qualquer tipo de solução utilizada para o algoritmo de navegação. Como principais desvantagens estão a pouca capacidade de extrapolação, ou seja, corrigir medições sem forte correlação com os exemplos disponíveis no banco de dados e a necessidade de um

treinamento ou armazenamento de dados. Para classificação, um descritor de dados foi utilizado de modo a identificar exemplos errôneos e classificá-los quanto a sua representatividade do banco de dados disponível. Dentre as vantagens em utilizar esse método, está a possibilidade de inserir outros tipos de informações relativos à propagação da onda sonora em meio subaquático de modo a ser possível estabelecer critérios mais precisos quanto à validade de uma determinada medição. Como principal desvantagem, destaca-se a inserção de um novo algoritmo e assim uma nova carga computacional ao sistema de navegação. Entretanto, diferentes estratégias poderiam ser adotadas de modo a minimizar esse custo ao sistema embarcado.

4. Definir o algoritmo a ser utilizado pelo sistema de navegação de modo a extrair as vantagens adquiridas com a solução proposta:

No capítulo 6 o algoritmo completo foi discutido e nele detalhou-se principalmente a integração entre os módulos, que foram apresentados separadamente no capítulo 2, além do tipo de informação que transita entre eles. O fluxograma também apresentado no capítulo sintetiza o processo almejado pela proposta para o sistema de localização. O algoritmo mostrou suas características quanto à adaptabilidade às características do meio. Ressalta-se nessa arquitetura a importância do algoritmo de correção, realizado pelo AAKR, pois, ao realizar eventuais correções em tempos de chegada, impede que o veículo navegue longos períodos sem as medições referentes à localização, o que inviabilizaria as soluções para identificação de medições errôneas.

5. Realizar experimentos em campo, utilizando veículos autônomos comerciais, a fim de validar a solução proposta e avaliar quantitativamente e qualitativamente seu desempenho:

Por fim, no capítulo 7, a análise de desempenho do sistema foi apresentada utilizando dados de missões reais com um veículo comercial. Através da comparação com a solução corrente para o sistema de localização nos veículos utilizados para testes, foi possível quantificar o ganho com a utilização da arquitetura proposta como mostram os resultados apresentados na tabela 14.

O desenvolvimento tecnológico nas áreas de sensoriamento, principalmente nos sensores inerciais, garantem, em condições normais, uma excelente precisão na navegação de veículos autônomos. Assim, pequenos erros são esperados mesmo quando o canal de comunicação não é favorável ou quando há falhas nos equipamentos de medição. Assim como as diversas soluções apresentadas na literatura para os sistemas de localização, a arquitetura apresentada nesse trabalho exige um ajuste refinado de parâmetros dos algoritmos com base em navegações prévias nos locais de exploração. Destaca-se

a relação entre os parâmetros do descritor de dados, que controlam a abrangência da região de fronteira e assim o seu raio, com a largura do kernel do modelo de regressão utilizado na etapa de correção.

## 8.2 OBSERVAÇÕES GERAIS

A solução apresentada para o sistema de localização caracteriza-se por ser mais versátil que as atuais, apesar de não terem sido exploradas, em todas as etapas mencionadas diferentes estratégias tanto para a seleção de dados de treinamento como ajuste de parâmetros e seleção de funções kernel a serem utilizadas nos modelos. Uma vez disponíveis informações adicionais relacionadas à posição do veículo, a dimensão da região que descreve os dados será ampliada e diferentes critérios para identificação de dados errôneos bem como estratégias para o algoritmo de correção poderão ser exploradas. Além disso, dispondo dessas informações adicionais oriundas do sinal acústico, será possível explorar outras características do algoritmo de descrição de dados como a aprendizagem com exemplos errôneos.

Apesar dos resultados mostrarem as potencialidades da arquitetura proposta em relação à solução atual, devido ao número limitado de experimentos e a pobre diversificação de ambientes e contextos de navegação, não se pode afirmar categoricamente que o sistema apresentado substitui o atual. A solução proposta ainda carece de validações mais rigorosas e precisa ser embarcada num veículo para ser testada nas mais diversas situações e com diferentes conjuntos de sensores.

Com respeito ao custo computacional da solução apresentada, algumas estratégias podem ser utilizadas a fim de não sobrecarregar o sistema. É possível, por exemplo, dispor da região de decisão no início da navegação, ou seja, realizar todo o processo de definição da hipersfera de decisão de modo *off line*. Nessa situação, o algoritmo de análise com o descritor de dados apresentaria uma baixa complexidade assim como a solução para correção das medições com o modelo autoassociativo. Mesmo na hipótese de realizar um treinamento *on line*, ainda assim é possível estabelecer critérios antes de decidir inserir um novo dado, tendo em vista que exemplos somente os exemplos aceitos que estão próximos da borda da hipersfera são potenciais vetores suportes e portanto podem mudar a hipersfera de decisão num eventual novo treinamento.

### 8.3 PERSPECTIVAS FUTURAS

Como perspectiva futura está a expansão da utilização desse tipo de veículo para a inspeção de estruturas submersas ou monitoramento de lagos de barragem hidrelétricas. Como exemplo, destacam-se os lagos de hidrelétricas que sofrem com o processo de assoreamento e cujo leito precisa ser periodicamente analisado. Além disso, amostras de água em diferentes pontos podem ser facilmente coletadas e geo-referenciadas de modo a guiar estratégias de preservação ambiental. Esse tipo de aplicação é bem adequado ao sistema apresentado nesse trabalho uma vez que o veículo navega periodicamente numa mesma região para o acompanhamento do ecossistema.

Diversas técnicas para localização de fonte acústica são estudadas na literatura técnica principalmente para localização de epicentros de terremotos. Muitas dessas técnicas fazem uso da energia acústica que atinge um conjunto de hidrofones instalados ao longo da coluna d'água e, através de modelos de propagação e do ambiente, procuram indentificar a posição da fonte emissora. A proposta apresentada nessa tese poderia, por exemplo, explorar esse tipo de informação para melhorar os critérios de avaliação da medições dos tempos de chegada. Outro exemplo a ser avaliado refere-se à utilização do próprio modelo de propagação da onda acústica, em execução no veículo, para auxiliar na identificação dos tempos de chegada mais favoráveis à correção de posição.

Destacam-se ainda as diferentes funções kernel existentes que podem ser avaliadas utilizando essa proposta bem como novos modelos tanto para regressão quanto para classificação. Nesse os *Support Vector Machines* (SVM) são excelentes candidatos a serem observados.

No algoritmo incremento/decremento diferentes soluções são discutidas em trabalhos técnicos e que poderiam ser exploradas na solução apresentada. Por fim, vale destacar que com a utilização de veículos subaquáticos e a realização exaustiva de experimentos, será possível atingir um amadurecimento tanto na modelagem quanto na metodologia apresentada.

### 8.4 LISTA DE PUBLICAÇÕES

#### **Artigos em Conferências**

[1] Pinheiro, B., Moreno, U. F., dos Santos, Carlos H. F., Localization System for Autonomous Underwater Vehicle during Operations in Lakes of

Hydroelectric Dams. Proceedings of the IFACWorkshop - Navigation, Guidance and Control of Underwater Vehicles (NGCUV), 2012,Porto-Portugal.

[2] Pinheiro, B., Moreno, U. F., Sousa, J. T. and Rodriguez, O., Improvements in the estimated time of flight of acoustic signals for auv localization, in OCEANS - Bergen, 2013 MTS/IEEE, 2013, pp. 1-6.

[3] Pinheiro, B., Moreno, U. F., Empirical Models for AUV Localization. Proceedings of the Navcomp2014, 2014, Rio Grande/RS-Brasil.

[4] Pinheiro, B., Sousa, J. T. B., Moreno, U. F., Unmanned Vehicles Network: Platforms and Software Toolchain. 3<sup>rd</sup> International Conference on Applied Robotics for the Power Industry, 2014, Foz do Iguaçu/PR-Brasil.

### **Artigos em Revista Científica**

[5] Pinheiro, B., Moreno, U. F., Sousa, J. T. and Rodriguez, O., Kernel Functions Based Models for Acoustic Localization of Underwater Vehicle. IEEE Journal of Oceanic Engineering, 2014. (submetido)

## **APÊNDICE A – Algoritmo Incremento/Decremento**



## A.1 INTRODUÇÃO

Esse capítulo discute a abordagem algorítmica utilizada para obter os vetores suportes necessários para a descrição dos dados visto no capítulo 5. O contexto apresentado corresponde à aprendizagem de máquinas em tempo de execução, ou seja, o conjunto de dados de treinamento não é fornecido previamente. Dentre as vantagens dessa abordagem está o fato de não ser necessário armazenar em memória uma grande conjunto de dados, o que é típico em métodos que aplicam funções kernel, além de ser adequado em situações onde os dados são coletados continuamente ao longo do tempo ou onde novos conceitos sobre esses dados devem ser aprendidos.

Muitas abordagens vem sendo estudadas com o propósito de realizar a aprendizagem de máquina à medida que novas amostras são disponibilizadas [Cauwenberghs e Poggio 2000, Romero, Barrio e Belanche 2007, Martin 2002]. Nessas propostas, busca-se inserir ou retirar amostras do conjunto de dados, observando o comportamento do restante da informação sem a aplicação dos algoritmos de minimização das funções quadráticas apresentadas anteriormente. Seguindo uma abordagem mais rigorosa quanto às garantias de convergência encontra-se o algoritmo apresentado em [Kivinen, Smola e Williamson 2004], onde a minimização da função risco empírica regularizada, além de reduzir o tempo necessário para treinamento, também garante um limite superior para o número de operações realizadas em cada passo.

O desenvolvimento a seguir refere-se ao processo de aprendizagem em tempo de execução aplicado aos problemas considerados não supervisionados, ou seja, situações onde o rótulo associado ao exemplo não é disponível. Como visto anteriormente, a evolução dos dados coletados permitirá definir a que classe os mesmos pertencem. Essa formulação é apresentada nos trabalhos [Tax e Laskov 2003] e [Cauwenberghs e Poggio 2000], com diversas variações como em [Hua 2011, Li, Liu e Wang 2011].

## A.2 INCREMENTO/DECREMENTO SVM

Considere o problema clássico de otimização convexa aplicado às máquinas de vetores suportes em contextos de classificação de dados, escrito de modo genérico como:

$$\max_b \min_{\substack{0 \leq \alpha_i \leq C, \forall i=1, \dots, m; \\ \mathbf{y}^T \alpha + k = 0}} : W = -c^T \alpha + \frac{1}{2} \alpha^T \mathbf{Q} \alpha + b(\mathbf{y}^T \alpha + k),$$

onde  $b$  refere-se ao limiar, que define o deslocamento do hiperplano em relação à origem dos eixos,  $Q_{ij} = y_i y_j K(\mathbf{x}_i, \mathbf{x}_j)$  é uma matriz definida positiva com a função kernel  $K$ , que garante a característica convexa do problema de minimização. Os multiplicadores de Lagrange estão representados por  $\alpha$  e  $C$  é a constante de regularização.

No caso clássico de vetores suportes aplicados a problemas de classificação (SVC), tem-se  $\mathbf{c} = \mathbf{1}$  e  $k = 0$ , enquanto nos  $\nu$ -SCV o valor de  $C = \frac{1}{N\nu}$ , onde  $\nu$  representa tanto o limite superior da fração de exemplos classificados erroneamente ou dentro das margem delimitada pelos hiperplanos quanto o limite inferior da fração de exemplos que se tornam vetores suportes. Para os problemas de classificação baseado em uma classe, como o SVDD, tem-se  $\mathbf{c} = \text{diag}(Q)$  e  $k = -1$ . O algoritmo de incremento ou decremento refere-se ao procedimento de adicionar ou remover exemplos a partir de uma soução ou condição ótima previamente atingida. Assim, quando uma nova amostra é adicionada, a seu valor de  $\alpha$  é atribuído zero enquanto os outros multiplicadores e o valor de  $b$  precisam ser atualizados. Do mesmo modo, quando a amostra é removida, seu multiplicado também recebe o valor nulo enquanto os outros valores precisam ser atualizados.

### A.2.1 Incremento

A idéia central desse algoritmo é atualizar o estado da nova amostra a ser inserida mantendo as restantes em seu estado de otimalidade. Considere as condições de KKT <sup>1</sup> obtidas a partir da análise do gradiente da função  $W$ :

$$g_i = \frac{\partial W}{\partial \alpha_i} = \sum_j Q_{ij} \alpha_j + y_i b - 1 = y_i f(\mathbf{x}_i) - 1 \quad \begin{cases} \geq 0; & \alpha_i = 0 \\ \leq 0; & \alpha_i = C \\ = 0; & 0 < \alpha_i < C \end{cases} \quad (\text{A.1})$$

$$\frac{\partial W}{\partial \alpha_i} = \sum_j y_j \alpha_j = 0;$$

O resultado mostrado em A.1 permite a partição do conjunto de treinamento  $\mathcal{X}^T$  associado aos multiplicadores ( $\alpha_i$ ) de seus elementos e ao deslocamento  $b$ . O conjunto  $\mathcal{S}$  é formado pelo exemplos de treinamento estritamente na margem dos hiperplanos, ou seja, são vetores suportes que resultam  $y_i f(\mathbf{x}_i) = 1$ . O conjunto  $\mathcal{E}$ , formado pelos vetores suportes, corretamente classificados ou não, que estão fora da margem dos hiperplanos. Por fim, o

---

<sup>1</sup>Karush-Kuhn-Tucker.

conjunto  $\mathcal{R}$ , que contém os exemplos que não formam o conjunto dos vetores suportes, ou seja, que estão entre os hiperplanos, dentro da margem.

A inserção de uma nova amostra, a qual se atribui inicialmente  $\alpha_n = 0$ , é seguida da alteração dos valores dos coeficientes  $\alpha_i$  dos elementos no conjunto de treinamento, de modo que as condições de KKT sejam mantidas. A análise incremental de  $g_i$  leva a:

$$\begin{aligned}\Delta g_i &= Q_{ic}\Delta\alpha_n + \sum_{j \in \mathcal{S}} Q_{ij}\Delta\alpha_j + y_i\Delta b \quad \forall i \in \mathcal{X}^{tr} \cup \{c\} \quad (\text{A.2}) \\ 0 &= y_n\Delta\alpha_n + \sum_{j \in \mathcal{S}} y_j\Delta\alpha_j\end{aligned}$$

haja visto que somente os vetores suportes em  $\mathcal{S}$  possuem uma variação em  $\alpha_i \neq 0$ . Dado que, para esse conjunto  $\mathcal{S}$ ,  $g_i \equiv 0$ , o equacionamento A.2 resulta em:

$$\mathcal{Q} \begin{bmatrix} \Delta b \\ \Delta\alpha_{s_1n} \\ \vdots \\ \Delta\alpha_{s_mn} \end{bmatrix} = - \begin{bmatrix} y_n \\ Q_{s_1n} \\ \vdots \\ Q_{s_mn} \end{bmatrix} \Delta\alpha_n \quad (\text{A.3})$$

onde  $\mathcal{Q}$  é uma matriz simétrica definida por:

$$\mathcal{Q} = \begin{bmatrix} 0 & y_{s_1} & \cdots & y_{s_m} \\ y_{s_1} & Q_{s_1s_1} & \cdots & Q_{s_1s_m} \\ \vdots & \vdots & \ddots & \vdots \\ y_{s_m} & Q_{s_ms_1} & \cdots & Q_{s_ms_m} \end{bmatrix} \quad (\text{A.4})$$

As equações mostram que no equilíbrio, ou seja, mantidas as condições de KKT, tem-se:

$$\begin{aligned}\Delta b &= \beta\Delta\alpha_n; \\ \Delta\alpha_j &= \beta_j\Delta\alpha_n, \quad \forall j \in \mathcal{X}^{tr}.\end{aligned} \quad (\text{A.5})$$

onde  $\beta$  corresponde à sensibilidade dos coeficientes em condição de otimalidade parametrizados pelo coeficiente da amostra a ser inserida.

$$\begin{bmatrix} \beta \\ \beta_{s_1} \\ \vdots \\ \beta_{s_m} \end{bmatrix} = -\mathcal{T} \cdot \begin{bmatrix} y_n \\ Q_{s_1 n} \\ \vdots \\ Q_{s_m n} \end{bmatrix} \quad (\text{A.6})$$

onde  $\mathcal{T} = \mathcal{Q}^{-1}$  e  $\beta_j \equiv 0$  para os vetores suportes não pertencentes à  $\mathcal{S}$ . Retornando às condições de KKT em A.2, equaciona-se às variações na margem definida pelos hiperplanos como:

$$\Delta g_i = \gamma_i \Delta \alpha_n, \quad \forall i \in \mathcal{X}^{tr} \cup \{c\}. \quad (\text{A.7})$$

onde  $\gamma_i$  corresponde à sensibilidade ou ao gradiente da variação da margem dos hiperplanos definido por:

$$\begin{aligned} \gamma_i &= Q_{in} + \sum_{j \in \mathcal{S}} Q_{ij} \beta_j + y_i \beta, \quad \forall i \notin \mathcal{S}; \\ \gamma_i &\equiv 0, \quad \forall i \in \mathcal{S}. \end{aligned} \quad (\text{A.8})$$

Dadas as condições e relações mostradas, uma questão central do algoritmo está na escolha da variação do multiplicador da amostra a ser inserida,  $\alpha_n$ . Deve-se, no entanto, considerar que essa variação não pode implicar em alterações nos conjuntos  $\mathcal{S}$ ,  $\mathcal{E}$  e  $\mathcal{R}$ , a fim de manter as relações anteriores válidas. Visto que os multiplicadores  $\alpha_j$  e o parâmetro  $g_i$  sofrem alterações com  $\alpha_n$ , dadas por A.5 e A.7, é necessário checar as condições abaixo afim de determinar o máximo valor permitido a  $\Delta \alpha_n$ . Assim, incremento em  $\alpha_n$  deverá ser o menor dentre os valores que resultem em:

1.  $g_n = 0$ , quando a amostra a ser inserida é inserida em  $\mathcal{S}$ ;
2.  $\alpha_n = C$ , quando o multiplicador atinge o valor superior e inserida em  $\mathcal{E}$ ;
3.  $\alpha_i = 0$  ou  $\alpha_i = C$ ,  $\forall i \in \mathcal{S}$ , quando um vetor suporte  $i$  em  $\mathcal{S}$  move-se para  $\mathcal{R}$  ou  $\mathcal{E}$  respectivamente;
4.  $g_i = 0$ ,  $\forall i \in \mathcal{R} \cup \mathcal{E}$ , quando vetor suporte  $i$  em  $\mathcal{E}$  movem-se  $\mathcal{R}$  ou a amostra  $i$  move-se para  $\mathcal{S}$ .

O algoritmo procede iterativamente, atualizando os valores de  $\beta$  e  $\gamma$ , parando quando uma das situações 1 e 2 é satisfeita. Os passos realizados

são:

*Passo 1:* Inicializar o multiplicador  $\alpha_n = 0$ ;

*Passo 2:* Se  $g_n > 0$ : fim. (A nova amostra não será inserida como vetor suporte);

*Passo 3:* Se  $g_n \leq 0$ : aplicar o maior **incremento** possível para  $\alpha_n$ , de modo que a primeira dentre as condições abaixo ocorra:

- a.  $g_n = 0$ , adicionar a nova amostra ao conjunto  $\mathcal{S}$ , atualizar a matriz  $\mathcal{R}$  e finalizar;
- b.  $g_n = C$ , adicionar a nova amostra ao conjunto  $\mathcal{E}$  e finalizar;
- c. Ocorrência de migração entre exemplos dos conjuntos  $\mathcal{S}$ ,  $\mathcal{E}$  ou  $\mathcal{R}$ . Atualizar os conjuntos, a matriz  $\mathcal{T}$ , caso o conjunto  $\mathcal{S}$  seja alterado, e repetir o processo;

Em [Cauwenberghs e Poggio 2000], mostra-se um método recursivo para atualização da matriz  $\mathcal{T}$  quando a amostra é inserida no conjunto  $\mathcal{S}$ :

$$\mathcal{T} \leftarrow \begin{bmatrix} & & 0 \\ & \mathcal{T} & \vdots \\ 0 & \dots & 0 & 0 \end{bmatrix} + \frac{1}{\gamma_i} \begin{bmatrix} \beta \\ \beta_{s_1} \\ \vdots \\ \beta_{s_m} \\ 1 \end{bmatrix} \cdot [ \beta \ \beta_{s_1} \ \dots \ \beta_{s_m} \ 1 ] \quad (\text{A.9})$$

### A.2.2 Decremento

O processo de retirada de uma amostra do conjunto de treinamento é realizado observando a condição de  $g_n$ , o que determinará, após a saída da amostra, se a mesma foi corretamente classificada. Os passos apresentados em [Cauwenberghs e Poggio 2000], considerando o estado inicial de otimalidade da solução, são:

*Passo 1:* Se a amostra não pertence aos conjuntos  $\mathcal{S}$  ou  $\mathcal{E}$ , ou seja, aos conjuntos de elementos na margem dos hiperplanos ou fora dela respectivamente: Fim, a amostra pode ser retirada e está corretamente classificada.

*Passo 2:* Se a amostra pertence a um dos conjuntos  $\mathcal{S}$  ou  $\mathcal{E}$  e mantém  $g_n < -1$ : Fim, amostra classificada erroneamente.

*Passo 3:* Se a amostra pertence a um dos conjuntos  $\mathcal{S}$  ou  $\mathcal{E}$  e mantém  $g_n \geq -1$ : aplicar o maior **decremento** possível para  $\alpha_n$ , de modo que a primeira dentre as condições abaixo ocorra:

- a.  $g_n < -1$ : Fim, classificação incorreta;
- b.  $\alpha_n = 0$ : Fim, classificação correta;
- c. Ocorrência de migração entre exemplos dos conjuntos  $\mathcal{S}$ ,  $\mathcal{E}$  ou  $\mathcal{R}$ . Atualizar os conjuntos, a matriz  $\mathcal{T}$ , caso o conjunto  $\mathcal{S}$  seja alterado, e repetir o processo.

### A.3 INCREMENTO/DECREMENTO SVDD

O algoritmo utilizado no *Support Vectors Data Description* segue o mesmo procedimento mostrado para o *Support Vectors Machines*, uma vez que a distinção entre as duas técnicas está na formulação inicial do problema de otimização, onde, para o SVDD,  $\mathbf{c} = \text{diag}(Q)$  e  $k = -1$ . Conforme discutido em [Tax e Laskov 2003], a inicialização do algoritmo requer alguns ajustes iniciais de modo a atender as condições de otimalidade impostas por  $\sum_{i=1}^m y_i \alpha_i = 1$  e  $0 \leq \alpha_i \leq C$ , uma vez que, para um número de amostras inferior a  $\lceil \frac{1}{C} \rceil$ , essa condição não será satisfeita. Os passos descritos são:

*Passo 1:* Atribui-se  $\alpha_i = C$  aos primeiros  $\lfloor \frac{1}{C} \rfloor$  exemplos e coloca-os no conjunto  $\mathcal{E}$ .

*Passo 2:* Aos exemplos restantes, atribui-se  $\alpha_i = 1 - \lfloor \frac{1}{C} \rfloor$  e coloca-os no conjunto  $\mathcal{S}$ .

*Passo 3:* Calcular  $g_i$  para todos os exemplos disponíveis, garantindo, através do parâmetro  $b$ , que aqueles pertencentes ao conjunto  $\mathcal{E}$  tenham um gradiente inferior ou igual a zero, ou seja:

$$\mu = -\max_{i \in \mathcal{E}} g_i$$

*Passo 3:* Entrar no laço principal do algoritmo incremento/decremento descrito para as máquinas de vetores suportes.

### A.4 CONSIDERAÇÕES PRÁTICAS

Usualmente, o processo de aprendizagem apresentado resulta em uma parcela pequena dos exemplos de treinamento como vetores suportes. Além disso, esses dados descrevem completamente as propriedades do conjunto de dados disponíveis. O algoritmo incremento/decremento procura analisar as alterações no conjunto dos vetores suportes, com base na condições de KKT, quando uma nova amostra é inserida ou removida.

Algumas considerações de ordem prática, discutidas em [Tax e Laskov

2003, Hua 2011], podem ser observadas a fim de descartar as amostras desnecessárias e manter os exemplos que agregam informação além de melhorar a eficiência do algoritmo.

1. *Propriedade 1*: Se as amostras, no novo conjunto de treinamento, satisfazem as condições de KKT, o conjunto de vetores suportes permanece inalterado. Isso implica que a nova amostra não fornece qualquer informação nova ao conjunto de treinamento prévio e pode portanto ser descartada.
2. *Propriedade 2*: Se as amostras inseridas no novo conjunto de treinamento violam as condições de KKT, alguma delas tornar-se-ão vetores suportes. Essa propriedade indica que as amostras que violam as condições de KKT não podem ser descartadas, uma vez que sua informação não fora inserida no conjunto de treinamento prévio.
3. *Propriedade 3*: Se as amostras inseridas no novo conjunto de treinamento violam as condições de KKT, os exemplos que não são vetores suportes no conjunto prévio podem vir a tornar-se vetores suportes. Essa propriedade mostra que as amostras que não eram vetores suportes no conjunto de treinamento prévio, não podem ser completamente descartadas. Para isso, adota-se uma regra simples, onde somente os exemplos próximos à borda da esfera, ou seja, com distância ao centro próxima ao raio  $R$  são mantidas:

$$R - \theta \leq f(z) \leq R, \quad \theta \in [0, R]$$



## BIBLIOGRAFIA

- ALVAREZ, A.; OLIVER, G.; GARAU, B. Auv navigation trough turbulent ocean environments supported by onboard h-adcp. **Proceedings of 2006 IEEE International Conference on Robotics and Automation, USA**, v. 36, p. 3556–3561, May 2006.
- AN, S. H.; HEO, G.; CHANG, S. H. Detection of process anomalies using an improved statistical learning framework. **Expert Systems with Applications**, Elsevier Ltd, v. 38, n. 3, p. 1356–1363, 2011.
- ANTONELLI, G. Open control problems in underwater robotics. **4th International Workshop on Robot Motion and Control**, p. 219–229, 2004.
- APARTSIN, A.; COOPER, L.; INTRATOR, N. Snr-dependent filtering for time of arrival estimation in high noise. In: **Machine Learning for Signal Processing (MLSP), 2010 IEEE International Workshop on**. [S.l.: s.n.], 2010. p. 427–431. ISSN 1551-2541.
- APARTSIN, A.; COOPER, L.; INTRATOR, N. Semi-coherent time of arrival estimation using regression. **J Acoust Soc Am**, v. 132, n. 2, p. 832–7, 2012.
- ATWOOD, D. K. et al. An acoustic navigation system for multiple vehicles. In: **Proc. Int. Symp. on Unmanned Untethered Submersible Technology**. [S.l.: s.n.], 1995. p. 202–208.
- BAILEY, T. **Mobile Robot Localisation and Mapping in Extensive Outdoor Environments**. Tese (Doutorado) — Australian Centre for Field Robotics Department of Aerospace, Mechanical and Mechatronic Engineering. The University of Sydney, Sydney, Australia, august 2001.
- BAILEY, T.; DURRANT-WHYTE, H. Simultaneous localisation and mapping (slam): Part ii state of the art. **Computational Complexity**, v. 13, n. 3, p. 1–10, 2006.
- BAR-ITZHACK, I. Y. Request: A recursive quest algorithm for sequential attitude determination. **Journal of Guidance, Control and Dynamics**, v. 19, n. 5, p. 1034–1038, 1996.
- BARCKBY, S. et al. An efficient approach to bathymetric slam. **2009 IEEEERSJ International Conference on Intelligent Robots and Systems**, Ieee, p. 219–224, 2009.

- BATISTA, P. T. M.; SILVESTRE, C.; OLIVEIRA, P. J. R. Optimal position and velocity navigation filters for autonomous vehicles. **Automatica**, v. 46, n. 4, p. 767–774, 2010.
- BINGHAM, B.; BLAIR, B.; MINDELL, D. On the design of direct sequence spread-spectrum signaling for range estimation. In: **OCEANS 2007**. [S.l.: s.n.], 2007. p. 1–7.
- BINGHAM, B.; SEERING, W. Hypothesis grids: improving long baseline navigation for autonomous underwater vehicles. **Oceanic Engineering, IEEE Journal of**, v. 31, n. 1, p. 209–218, 2006. ISSN 0364-9059.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. New York, NY, USA: Oxford University Press, Inc., 1995. ISBN 0198538642.
- BRITTING, K. R. **Inertial Navigation Systems Analysis**. Norwood, MA: Artech House, 2010.
- CAITI, A. et al. Acoustic tracking of autonomous underwater vehicles by a set-membership approach. In: \_\_\_\_\_. **Proc of IFAC World Congress**. [S.l.: s.n.], 2002.
- CAITI, A. et al. Localization of autonomous underwater vehicles by floating acoustic buoys: A set-membership approach. **IEEE Journal of Oceanic Engineering**, v. 30, n. 1, p. 140–152, Jan. 2005.
- CAITI, A.; JESUS, S. M. Acoustic estimation of seafloor parameters: a radial basis functions approach. **J. Acoust. Soc. Am**, v. 100, p. 1473–1481, 1996.
- CAUWENBERGHS, G.; POGGIO, T. Incremental and Decremental Support Vector Machine Learning. In: **Neural Informaion Proceedings Systems**. [S.l.: s.n.], 2000. p. 409–415.
- CHENG, Y.; CRASSIDIS, J. L. Particle filtering for sequential spacecraft attitude estimation. In: **AIAA Guidance, Navigation, and Control Conference**. Providence, RI: [s.n.], 2004.
- CHERKASSKY, V.; MULIER, F. **Learning from data : concepts, theory and methods**. New York: J. Wiley, 1998. A Wiley-Interscience publication. ISBN 0-471-15493-8. Disponível em: <<http://opac.inria.fr/record=b1080965>>.
- COATES, R. F. W. **Underwater Acoustic Systems**. [S.l.]: Academic Press, 1990.

COATES, R. F. W. The design of transducers and arrays for underwater data transmission. **Oceanic Engineering, IEEE Journal of**, v. 16, n. 1, p. 123–135, 1991. ISSN 0364-9059.

CRUZ, N. et al. Trimares - a hybrid auv/rov for dam inspection. **OCEANS**, p. 1–7, Sept 2011.

DUNBABIN, M.; MARQUES, L. Robots for environmental monitoring: Significant advancements and applications. **Robotics Automation Magazine, IEEE**, v. 19, n. 1, p. 24–39, 2012. ISSN 1070-9932.

DURRANT-WHYTE, H.; BAILEY, T. Simultaneous localisation and mapping (slam): Part i the essential algorithms. **IEEE ROBOTICS AND AUTOMATION MAGAZINE**, v. 2, p. 2006, 2006.

ENCARNAÇÃO, P.; PASCOAL, A. 3d path following for autonomous underwater vehicle. In: **Proc. 39th IEEE Conference on Decision and Control**. [S.l.: s.n.], 2000.

ETTER, P. C. **Underwater Acoustic Modeling and Simulation**. third. New Fetter Lane, London: Spon Press, 2003. ISBN 0-203-41910-3.

ETTER, P. C. **Underwater Acoustic Modeling and Simulation**. third. London, UK: Spon Press, 2003. ISBN 0-203-41910-3.

FALLON, M. et al. Efficient auv navigation fusing acoustic ranging and side-scan sonar. In: **Robotics and Automation (ICRA), 2011 IEEE International Conference on**. [S.l.: s.n.], 2011. p. 2398–2405. ISSN 1050-4729.

FALLON, M.; PAPADOPOULOS, G.; LEONARD, J. Cooperative auv navigation using a single surface craft. In: HOWARD, A.; IAGNEMMA, K.; KELLY, A. (Ed.). **Field and Service Robotics**. [S.l.: Springer Berlin Heidelberg, 2010, (Springer Tracts in Advanced Robotics, v. 62). p. 331–340.

FOFONOFF, N.; MILLARD, R. **Algorithms for computation of fundamental properties of seawater**. Paris, 1983. 53 pp.

FOSSEN, A. R. T. Advances in unmanned marine vehicles. In: \_\_\_\_\_. UK: The Institution of Electrical Engineers, 2006. (69), cap. 2, p. 13–42.

FOSSEN, T. I. **Guidance and Control of Ocean Vehicles**. England: John Wiley Sons, 1994. 480 p.

FOSSEN, T. I.; BALCHEN, J. G. **The NEROV Autonomous Underwater Vehicle**. [S.l.], 1991.

FREITAG, L. et al. Analysis of channel effects on direct-sequence and frequency-hopped spread-spectrum acoustic communication. **Oceanic Engineering, IEEE Journal of**, v. 26, n. 4, p. 586–593, 2001. ISSN 0364-9059.

FRIEDMAN, J. H.; FAYYAD, U. On bias, variance, 0/1-loss, and the curse-of-dimensionality. **Data Mining and Knowledge Discovery**, v. 1, p. 55–77, 1997.

GARVEY, D. R.; HINES, J. W. Robust distance measures for on-line monitoring: Why use euclidean. In: **Applied Artificial Intelligence. Proceedings of 7th International FLINS Conference**. [S.l.]: World Scientific Publishing Co. Pte. Ltd., 2006. p. 922–929.

GENG, Y.; MARTINS, R.; SOUSA, J. Accuracy analysis of dvl/imu/magnetometer integrated navigation system using different imus in auv. In: **2010 8th IEEE International Conference on Control and Automation (ICCA)**. [S.l.: s.n.], 2010. p. 516–521. ISSN 1948-3449.

HE, B. et al. Localization and map building based on particle filter and unscented kalman filter for an auv. **4th IEEE Conference on Industrial Electronics and Applications**, Ieee, p. 3926–3930, 2009.

Hegrenaes, O.; Berglund, E. Doppler water-track aided inertial navigation for autonomous underwater vehicle. **OCEANS**, p. 1–10, May 2009.

Hegrenaes, O.; Hallingstad, O. Model-aided ins with sea current estimation for robust underwater navigation. **IEEE Journal of Oceanic Engineering**, v. 36, n. 2, p. 316–337, April 2011.

HENKEL, J. **Development of a Safeguards Monitoring System for Special Nuclear Facilities**. Tese (PhD diss) — University of Tennessee, 2011.

HINES, J. W.; GARVEY, D. Development and application of fault detectability performance metrics for instrument calibration verification and anomaly detection. **Journal of Pattern Recognition Research**, v. 1, n. 1, p. 2–15, 2008.

HUA, S. D. X. Incremental learning algorithm for support vector data description. **Journal of Software**, 2011.

HUANG, W.; SHEN, L. Weighted support vector regression algorithm based on data description. In: **Computing, Communication, Control, and Management, 2008. CCCM '08. ISECS International Colloquium on**. [S.l.: s.n.], 2008. v. 1, p. 250–254.

IMCA. **Deep Water Acoustic Positioning**. [S.l.], 2009. 82 pp.

JANGLOVA, D. Neural networks in mobile robot motion. **International Journal of Advanced Robotic Systems**, v. 1, p. 15–22, 2004.

JENSEN, F. B. et al. **Computational Ocean Acoustics**. second. NY, USA: Springer Science+Business Media, 2011. (Modern Acoustics and Signal Processing). ISBN 1-4419-8677-1.

JESUS, E. S. M. et al. **Underwater Acoustic Positioning System Based on Buoys with GPS**. 2006. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.65.3736>>.

JESUS, E. S. M. et al. **Underwater Acoustic Positioning System Based on Buoys with GPS**. 2006. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.65.3736>>.

JESUS, S. et al. Single hydrophone source localization. **Oceanic Engineering, IEEE Journal of**, v. 25, n. 3, p. 337–346, 2000. ISSN 0364-9059.

JULIER, S. J.; UHLMANN, J. K.; DURRANT-WHYTE, H. F. A new approach for filtering nonlinear systems. In: . Seattle,WA: Proceedings of American Control Conference, 1995. p. 1628–1638.

KASDIN, J. Discrete simulation of colored noise and stochastic processes and  $1/f^\alpha$  power law noise generation. **Proceedings of the IEEE**, v. 83, n. 5, p. 802–827, 1995.

KAY, S. M. **Fundamentals of statistical signal processing: detection theory**. [S.l.]: Prentice-Hall PTR, 1998. Hardcover. (Prentice hall signal processing series).

KAZMI P. RIDAO, D. R. E. H. W. Dam wall detection and tracking using a mechanically scanned imaging sonar. **IEEE International Conference on Robotics and Automation**, p. 3595–3600, 2009.

KAZMI, W. et al. Dam wall detection and tracking using a mechanically scanned imaging sonar. In: **IEEE International Conference on Robotics and Automation**, Kobe, Japan, p. 12–17, 2009. ISSN 1050-4729.

- KIVINEN, J.; SMOLA, A.; WILLIAMSON, R. Online learning with kernels. **Signal Processing, IEEE Transactions on**, v. 52, n. 8, p. 2165–2176, 2004. ISSN 1053-587X.
- KUN, X.; SHAO-JI, F.; YONG-JIE, P. Strong tracking adaptive kalman filters for underwater vehicle dead reckoning. **Journal of Marine Science and Application**, v. 6, n. 2, p. 19–24, 2007.
- LEE, K.-C.; OU, J.-S.; HUANG, M.-C. Underwater acoustic localization by principal components analyses based probabilistic approach. **Applied Acoustics**, v. 70, n. 9, p. 1168 – 1174, 2009. ISSN 0003-682X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0003682X09000991>>.
- LEE, K.-C. et al. A novel location estimation based on pattern matching algorithm in underwater environments. **Applied Acoustics**, v. 70, n. 3, p. 479 – 483, 2009. ISSN 0003-682X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0003682X08000960>>.
- LEE, K.-C.; OU, J.-S.; WANG, L.-T. Underwater acoustic localization by probabilistic fingerprinting in eigenspace. In: **OCEANS 2009, MTS/IEEE Biloxi - Marine Technology for Our Future: Global and Local Challenges**. [S.l.: s.n.], 2009. p. 1–4.
- LEE, P. et al. An integrated navigation system for autonomous underwater vehicles with two range sonars, inertial sensors and doppler velocity log. In: **OCEANS '04. MTT/IEEE TECHNO-OCEAN '04**. [S.l.: s.n.], 2004. v. 3, p. 1586–1593 Vol.3.
- LEE, P.-M. et al. Simulation of an inertial acoustic navigation system with range aiding for an autonomous underwater vehicle. **IEEE Journal of Oceanic Engineering**, v. 32, p. 327–345, April 2007.
- LI, C.; LIU, K.; WANG, H. The incremental learning algorithm with support vector machine based on hyperplane distance. **Applied Intelligence**, Springer US, v. 34, n. 1, p. 19–27, 2011.
- Liu DA-JUN Sun, D.-I. Z. De-zhu. Acoustic doppler velocity log's echo simulation, velocity estimation and performance statistics based on ellipse scattering model. In: **International Conference on Computer Engineering and Technology**. [S.l.: s.n.], 2009. p. 308–311.
- LUO, J. et al. A fast svdd algorithm based on decomposition and combination for fault detection. In: **Control and Automation (ICCA), 2010 8th IEEE International Conference on**. [S.l.: s.n.], 2010. p. 1924–1928. ISSN 1948-3449.

- MAHALANOBIS, P. C. On the generalised distance in statistics. In: **Proceedings National Institute of Science, India**. [s.n.], 1936. v. 2, n. 1, p. 49–55. Disponível em: <<http://ir.isical.ac.in/dspace/handle/1/1268>>.
- MARGARITIS, D. **Learning Bayesian Network Model Structure from Data**. Tese (Doutorado) — School of Computer Science, Carnegie-Mellon University, Pittsburgh, PA, May 2003. Available as Technical Report CMU-CS-03-153.
- MARTIN, M. On-line support vector machine regression. In: **Proceedings of the 13th European Conference on Machine Learning**. London, UK, UK: Springer-Verlag, 2002. (ECML '02), p. 282–294. ISBN 3-540-44036-4. Disponível em: <<http://dl.acm.org/citation.cfm?id=645329.650050>>.
- MARTÍNEZ-RAMÓN, M.; XU, N.; CHRISTODOULOU, C. Antenna array processing for radar applications with support vector machines. In: BAUM, C.; STONE, A.; TYO, J. (Ed.). **Ultra-Wideband Short-Pulse Electromagnetics 8**. [S.l.]: Springer New York, 2007. p. 143–151. ISBN 978-0-387-73045-5.
- MAYBECK, P. S. **Stochastic models, estimation, and control**. New York, USA: Academic Press, Inc., 1982. ISBN 0-12-480702-X.
- MEDAGODA, L. et al. Water column current profile aided localisation for autonomous underwater vehicles. **OCEANS10 IEEE SYDNEY**, IEEE, p. 1–10, 2006.
- MEDAGODA, L. et al. Water column current profile aided localisation combined with view-based slam for autonomous underwater vehicle navigation. In: **ICRA**. [S.l.]: IEEE, 2011. p. 3048–3055.
- MEDWIN, H.; CLAY, C. S. **Fundamentals of Acoustical Oceanography (Applications of Modern Acoustics)**. 1st. ed. [S.l.]: Academic Press, 1997. Hardcover. ISBN 012487570X.
- MEHRA, R. On the identification of variance and adaptive kalman filtering. **IEEE Transaction of Automatic Control**, AC-15, p. 175–184, 1970.
- MEHRA, R. Approaches to adaptive filtering. **IEEE Transaction of Automatic Control**, AC-17, p. 693–698, 1972.
- MILLER, P. A.; FARRELL, J. A.; DJAPIC, V. Y. Z. Autonomous underwater vehicle navigation. **IEEE Journal of Oceanic Engineering**, v. 35, n. 3, p. 663–678, July 2010.

- MILNE, P. H. **Underwater Acoustic Positioning Systems**. illustrated edition. [S.l.]: Gulf Publishing Company, 1983. Hardcover. ISBN 0872010120.
- MINYONG, C.; SAKTHIVEL, R.; CHUNG, W. K. Neural network-aided extended kalman filter for slam problem. **In:IEEE International Conference on Robotics and Automation**, Roma, Italy, 2007.
- MORGADO, M. et al. Usbl/ins tightly-coupled integration technique for underwater vehicles. **9th International Conference on Information Fusion**, Florence, p. 1–8, July 2006.
- MORGADO, M. et al. Vehicle dynamics aiding technique for usbl/ins underwater navigation systems. **Proceedings of CAMS 2007 - IFAC Conference on Control Applications in Marine Systems**, Croatia, July 2006.
- MORGADO, M. et al. Improving aiding techniques for usbl tightly-coupled inertial navigation sistem. In: CONTROL, T. I. F. of A. (Ed.). **In: Proceedings of the the 17th World Congress**. Seoul, Korea: [s.n.], 2008.
- MORGADO, M. M. **Advanced Ultra-Short Baseline Inertial Navigation Systems**. Tese (PhD diss) — Universidade Técnica de Lisboa, Lisboa, Portugal, 2011.
- MURRAY, R. M.; LI, Z.; SASTRY, S. S. **A Mathematical Introduction to Robotic Manipulation**. [S.l.]: CRC Press, 1994.
- OLIVERA, M. de. Robôs aquáticos. **Pesquisa FAPESP**, 2007.
- PAPOULIS, A. **Probability, Random Variables and Stochastic Processes**. 3rd. ed. [S.l.]: McGraw-Hill Companies, 1991. Hardcover. ISBN 0070484775.
- PARZEN, E. On estimation of a probability density function and mode. **The Annals of Mathematical Statistics**, v. 33, n. 3, p. 1065–1076, 1962.
- PAULL, L. et al. Auv navigation and localization: A review. **Oceanic Engineering, IEEE Journal of**, v. 39, n. 1, p. 131–149, 2014. ISSN 0364-9059.
- PINTO, J. et al. The lsts toolchain for networked vehicle systems. In: **OCEANS - Bergen, 2013 MTS/IEEE**. [S.l.: s.n.], 2013. p. 1–9.
- PORTER, M. B. **The KRAKEN normal mode program**. La Spezia, sep 1991.

PREISIG, J. Acoustic propagation considerations for underwater acoustic communications network development. **SIGMOBILE Mob. Comput. Commun. Rev.**, ACM, New York, NY, USA, v. 11, p. 2–10, Oct. 2007. ISSN 1559-1662.

RAKOTONARIVO, S.; KUPERMAN, W. Model-independent range localization of a moving source in shallow water. **J Acoust Soc Am**, v. 132, n. 4, p. 2218–23, 2012.

RIBAS, D.; RIDAO, P.; NEIRA, J. **Underwater SLAM for Structured Environments Using an Imaging Sonar**. Heidelberg, Alemania: Springer Verlag, 2010. (Springer Tracts in Advanced Robotics, 65).

RODRÍGUEZ, O. C. **General description of the BELLHOP ray tracing model**. [S.l.], June 2008.  
[Http://www.siplab.fct.ualg.pt/models/bellhop/manual/index.html](http://www.siplab.fct.ualg.pt/models/bellhop/manual/index.html).

ROMERO, E.; BARRIO, I.; BELANCHE, L. Incremental and decremental learning for linear support vector machines. In: **Proceedings of the 17th international conference on Artificial neural networks**. Berlin, Heidelberg: Springer-Verlag, 2007. (ICANN'07), p. 209–218. ISBN 3-540-74689-7, 978-3-540-74689-8. Disponível em: <<http://dl.acm.org/citation.cfm?id=1776814.1776838>>.

SAVAGE, P. G. Strapdown inertial navigation integration algorithm design part 1: Attitude algorithms. **Journal of Guidance, Control, and Dynamics**, v. 21, n. 1, p. 19–26, Jan.-February 1998.

SCHÖLKOPF, B.; SMOLA, A. J. **Learning with kernels : support vector machines, regularization, optimization, and beyond**. [S.l.]: MIT Press, 2002. (Adaptive computation and machine learning).

SCHOLKOPF, B. et al. Comparing support vector machines with gaussian kernels to radial basis function classifiers. **Signal Processing, IEEE Transactions on**, v. 45, n. 11, p. 2758–2765, Nov 1997. ISSN 1053-587X.

SHUSTER, M. D. A simple kalman filter and smoother for spacecraft attitude. **The Journal of the Astronautical Sciences**, v. 37, n. 1, p. 89–106, Jan.-Mar. 1989.

SIMON, D. **Optimal State Estimation**. New Jersey, USA: John Wiley & Sons, Inc., 2006. ISBN 13 978-0-471-70858-2.

SPECHT, D. F. Probabilistic neural networks for classification, mapping, or associative memory. In: **Neural Networks, 1988., IEEE International Conference on**. [S.l.: s.n.], 1988. p. 525–532 vol.1.

- SPECHT, D. F. A general regression neural network. **Neural Networks, IEEE Transactions on**, v. 2, n. 6, p. 568–576, 1991. ISSN 1045-9227.
- TAX, D. M. J. **One-class classification - Concept-learning in the absence of counter-examples**. Tese (PhD diss) — Delft University of Technology, 2001.
- TAX, D. M. J.; DUIN, R. P. W. Support vector data description. **Mach. Learn.**, Kluwer Academic Publishers, Hingham, MA, USA, v. 54, n. 1, p. 45–66, jan 2004. ISSN 0885-6125.
- TAX, D. M. J.; LASKOV, P. Online svm learning: from classification to data description and back. In: **Neural Networks for Signal Processing, 2003. NNSP'03. 2003 IEEE 13th Workshop on**. [S.l.: s.n.], 2003. p. 499–508. ISSN 1089-3555.
- Titterton, D. H.; Weston, J. L. **Strapdown Inertial Navigation Technology**. Virginia, USA: Institution of Electrical Engineers, 2004. ISBN 0-86341-358-7.
- TYAGI, K.; CAI, X.; MANRY, M. Fuzzy c-means clustering based construction and training for second order rbf network. In: **Fuzzy Systems (FUZZ), 2011 IEEE International Conference on**. [S.l.: s.n.], 2011. p. 248–255. ISSN 1098-7584.
- VAGANAY, J.; LEONARD, J.; BELLINGHAM, J. Outlier rejection for autonomous acoustic navigation. In: **Robotics and Automation, 1996. Proceedings., 1996 IEEE International Conference on**. [S.l.: s.n.], 1996. v. 3, p. 2174–2181 vol.3. ISSN 1050-4729.
- VAGANAY, J. et al. Experimental validation of the moving long base-line navigation concept. In: **Autonomous Underwater Vehicles, 2004 IEEE/OES**. [S.l.: s.n.], 2004. p. 59–65.
- VAGANAY, J.; LEONARD, J. J.; BELLINGHAM, J. G. Outlier rejection for autonomous acoustic navigation. **Proceedings of IEEE International Conference on Robotics and Automation**, Ieee, v. 3, n. April, p. 2174–2181, 1996.
- VAPNIK, V. An overview of statistical learning theory. **IEEE Transactions on Neural Networks**, v. 10, n. 5, p. 988–999, 1999.
- VAPNIK, V. An overview of statistical learning theory. **IEEE Transactions on Neural Networks**, v. 10, n. 5, p. 988–999, 1999.

VAPNIK, V. N. **The nature of statistical learning theory**. New York, NY.: Springer-Verlag New York, Inc., 1995. ISBN 0-387-94559-8.

**Landmark Based Nonlinear Observer for Rigid Body Attitude and Position Estimation**. New Orleans, LA: Proceedings of the 46th IEEE Conference on Decision and Control, 2007. 12-14 p.

VISALAKSHI, N.; SUGUNA, J. K-means clustering using max-min distance measure. In: **Fuzzy Information Processing Society, 2009. NAFIPS 2009. Annual Meeting of the North American**. [S.l.: s.n.], 2009. p. 1–6.

WHITCOMB, L. I.; YOERGER, D.; SINGH, H. Advances in doppler-based navigation of underwater robotic vehicles. In: **in Proc. Int. Conf. on Robotics and Automation**. [S.l.: s.n.], 1999. p. 399–406.

WINKLER S., B. M. K. T. S.-H.-W. V. P. Mems-based imu development, calibration and testing for autonomous mav navigation. In: **Proceedings of the 59th Annual Meeting of The Institute of Navigation and CIGTF 22nd Guidance Test Symposium**. [S.l.: s.n.], 2003. p. 128–134.

WOODMAN, O. J. **An introduction to inertial navigation**. Cambridge, UK, August 2007.

XIONG-FEI, H.; BING-CHENG, Y.; XI, C. **A Study of Characteristics and Processing Method of Broadband Doppler velocity log Echo**. 2009. 2009 International Forum on Information Technology and Applications.

XU, J.; YAO, J.; NI, L. Fault detection based on svdd and cluster algorithm. In: **Electronics, Communications and Control (ICECC), 2011 International Conference on**. [S.l.: s.n.], 2011. p. 2050–2052.

YANG, T. C. Characteristics of underwater acoustic communication channels in shallow water. In: **OCEANS, 2011 IEEE - Spain**. [S.l.: s.n.], 2011. p. 1–8.

YEE, P.; HAYKIN, S. A dynamic regularized gaussian radial basis function network for nonlinear, nonstationary time series prediction. In: **Acoustics, Speech, and Signal Processing, 1995. ICASSP-95., 1995 International Conference on**. [S.l.: s.n.], 1995. v. 5, p. 3419–3422 vol.5. ISSN 1520-6149.

YIN, B. et al. An auv integrated navigation method based on improved genetic neural network. **International Conference on Artificial Intelligence and Education (ICAIE), 2010**, p. 675–678, 2010.

YPMA, A.; TAX, D. M. J.; DUIN, R. P. W. Robust machine fault detection with independent component analysis and support vector data description. In: **Neural Networks for Signal Processing IX, 1999. Proceedings of the 1999 IEEE Signal Processing Society Workshop**. [S.l.: s.n.], 1999. p. 67–76.

YUH, J. Design and control of autonomous underwater robots: A survey. **Autonomous Robots**, v. 24, p. 7–24, 2000.

ZHANG, Y. et al. An adaptive triggering method for capturing peak samples in a thin phytoplankton layer by an autonomous underwater vehicle. In: **OCEANS 2009, MTS/IEEE Biloxi - Marine Technology for Our Future: Global and Local Challenges**. [S.l.: s.n.], 2009. p. 1–5.

ZHOU, D.; FRANK, P. Strong tracking kalman filtering of nonlinear time-varying stochastic systems with colored noise: application to parameter estimation and empirical robustness analysis. **International Journal of Control**, v. 65, n. 2, p. 295–307, 1972.