



# ESCOLA NAVAL



*ta sante obli faire*

Departamento de Ciências do Mar

Tiago Miguel Matos Calonda

**Acústica submarina:**

**Operacionalização de um array de hidrofones no âmbito do projecto Deepfloat  
e Sidenav.**

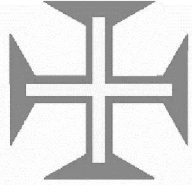
Dissertação para obtenção do grau de Mestre em Ciências Militares Navais, na especialidade de  
Marinha



Alfeite  
2018





ESCOLA  NAVAL

talant de bi-faire



**Tiago Miguel Matos Calonda**

*Acústica Submarina*

***Operacionalização de um array de hidrofones no âmbito do projeto Deepfloat e Sidenav***

**Dissertação para obtenção do grau de Mestre em Ciências Militares Navais, na especialidade de Marinha**

Orientação de:

Coorientação de:

O Aluno Mestrando

O Orientador

---

ASPOF M Matos Calonda

---

Professor Doutor Victor Lobo

Alfeite

2018



## **Epígrafe**

*“Não é preciso ter os olhos abertos para ver o sol, nem é preciso ter ouvidos afiados para ouvir o trovão. Para se ser vitorioso apenas é preciso ver o que não está visível.”*

-Sun Tzu



## **Dedicatória**

À minha família, que nunca deixou de me apoiar e nunca mediu esforços para que fosse possível tornar-me na pessoa que sou hoje e atingir os meus objetivos.



## Agradecimentos

Não poderia deixar de referir alguns contributos e colaborações que, sem as quais, não seria possível a realização e conclusão desta dissertação. Desta forma, agradeço:

- Ao Professor Doutor Victor Lobo, pela paciência e disponibilidade na orientação e ensinamentos que tornaram possível a realização desta dissertação.
- Ao meu coorientador, Professor Doutor Mário Gatta, pelos conselhos e pelo acompanhamento durante a realização deste trabalho.
- Aos Oficiais do NRP *Jacinto Cândido*, pela disponibilidade, compreensão, conselhos e ensinamentos transmitidos durante o meu estágio de embarque.
- Aos meus e amigos e camaradas do curso “CMG Henrique Quirino da Fonseca”, pelas alegrias, bons momentos e tristezas partilhadas ao longo do meu percurso na Escola Naval.
- Às minhas irmãs, Catarina e Inês, pelos incentivos e apoio constantes.
- Aos meus pais, Maria João e Francisco, pela capacidade de acreditarem e investirem em mim. Obrigado pela força, coragem, carinho e paciência que tanto me ajudou nos momentos mais difíceis. Definitivamente, sem o vosso apoio, nenhuma das minhas conquistas e sucessos seriam possíveis.



## Resumo

Atualmente, diversas operações subaquáticas realizadas em mar aberto ou rios são efetuadas por sistemas dedicados, recorrendo regularmente, ao auxílio de ROV's (*Remotely Operated Vehicles*) e AUV's (*Autonomous Underwater Vehicle*). No desenrolar destas tarefas, estes aparelhos necessitam de se mover verticalmente ao longo de uma coluna de água. É neste contexto que os projetos “*Deepfloat*” e “*Sidenav*” têm como objetivo desenvolver um sistema de variação de lastro flexível para aplicações em profundidade, recorrendo ao conceito de movimento de óleo para efetuar o bombeamento da água, e, desta forma, aumentar o leque de operações a realizar em ambientes de elevadas pressões, ao mesmo tempo que se reduz a energia consumida nas mesmas e aumentando a capacidade de carga útil e de controlo em ambientes confinados. Assim, é necessário a existência de um sistema capaz de controlar a posição destes dispositivos enquanto se encontram em operações subaquáticas. Neste contexto, a presente dissertação tem como objetivo principal criar uma rotina de *software* que possibilite a identificação, através de técnicas de *data mining*, e o *tracking* direcional de fontes sonoras relativamente a um *array* de dois hidrofones, em *Long Baseline* (LBL), baseado na estima da *Time difference of arrival* (TDOA) de sinais aos mesmos. Para este efeito, são estudadas, ao longo do enquadramento teórico, matérias teóricas consideradas pertinentes para a compreensão da propagação acústica em ambiente aquático, de arquiteturas de *arrays* de hidrofones para o posicionamento de fontes sonoras e de identificação de sinais acústicos. Os dados utilizados para testar as rotinas em *software*, foram recolhidos no exercício “*Robotics Exercise 2017*” (REX 17), coordenado pelo Centro de Investigação Naval (CINAV). No Capítulo 8 serão discutidos os resultados obtidos, que se apresentaram com taxas de erro reduzidas. Este facto poderá dever-se à utilização de um baixo número de plataforma diferentes numa área consideravelmente reduzida.

### Palavras-chave

*Time difference of arrival*, *Data mining*, *Tracking* direcional, Processamento de sinais, *Array* de hidrofones

## **Abstract**

Currently, several underwater operations performed in the open sea or rivers are carried out by dedicated systems, using normally the aid of ROV's (Remotely Operated Vehicles) and AUV's (Autonomous Underwater Vehicle). In the course of these tasks, the devices will need to move vertically along a column of water. It is in this context that the "Deepfloat" and "Sidenav" projects aim to develop a flexible ballast variation system for in-depth applications, using the concept of oil movement to pump water, increasing the range of operations to be performed in high pressure environments, while reducing the energy consumption and increasing the payload capacity and control in confined environments. Thus, it is necessary to have a system capable of controlling the position of these devices while in underwater operations. In this context, the main objective of this dissertation is to create a software routine that allows the identification, through data mining techniques, and the directional tracking of sound sources in relation to an array of two hydrophones, organized in a Long Baseline (LBL) structure, based on the estimation of Time difference of arrival (TDOA) of signals between the hydrophones. For this purpose, theoretical matters considered relevant for the understanding of acoustic propagation in the aquatic environment, of hydrophone arrays architectures used in the positioning of sound sources and the identification of acoustic signals are studied. The data used to test the software routines were collected in the "Robotics Exercise 2017" (REX 17), coordinated by Centro de Investigação Naval (CINAV). In Chapter 8 we will discuss the results obtained, which presented reduced error rates. This may be due to the use of a small number of different platforms in a considerably reduced area.

### **Keywords**

Time difference of arrival, Data mining, Directional Tracking, Signal Processing, Hydrophone array

## Conteúdo

<b>Epígrafe</b> .....	<b>III</b>
<b>Dedicatória</b> .....	<b>V</b>
<b>Agradecimentos</b> .....	<b>VII</b>
<b>Resumo</b> .....	<b>IX</b>
Palavras-chave.....	IX
<b>Abstract</b> .....	<b>X</b>
Keywords .....	X
<b>Lista de Abreviaturas e Acrónimos</b> .....	<b>XV</b>
<b>Índice de Figuras</b> .....	<b>XVII</b>
<b>Índice de Tabelas</b> .....	<b>XIX</b>
<b>Introdução</b> .....	<b>1</b>
Estrutura do Documento .....	2
<b>CAPÍTULO 1 – Aplicações da Acústica Subaquática</b> .....	<b>5</b>
<b>CAPÍTULO 2 – Enquadramento Teórico</b> .....	<b>7</b>
2.1 O som como onda acústica .....	7
2.1.1 Caracterização de ondas acústicas.....	8
2.2 Escala Logarítmica: Decibel .....	10
2.3 Acústica subaquática.....	11
2.3.1 Velocidade do som na água.....	11
2.3.2 Teoria de Propagação e <i>Ray Tracing</i> .....	13
2.3.3 Efeito de Doppler.....	16
2.3.4 Fontes de Ruído .....	18
2.3.5 Perdas na propagação .....	19
2.3.6 Equações Sonar .....	22
<b>CAPÍTULO 3 – Sistema de Posicionamento Acústico</b> .....	<b>25</b>
3.1 Dispositivos utilizados .....	25
3.2 Sincronização de transdutores (hidrofonos).....	26
3.3 Arquitetura e funcionamento de sistemas de posicionamento.....	27
3.3.1 <i>Long Baseline</i> (LBL).....	27

3.3.2	<i>Short Baseline (SBL)</i> .....	29
3.3.3	<i>Ultra Short Baseline (USBL)</i> .....	31
3.3.4	Outras arquiteturas.....	31
3.4	Localização de uma fonte acústica .....	33
3.4.1	Estimativa do <i>Time Difference of Arrival (TDOA)</i> .....	34
3.4.2	Determinação da <i>Direction of Arrival (DOA)</i> .....	36
<b>CAPÍTULO 4 – Processamento de Sinal .....</b>		<b>39</b>
4.1	Teorema da Amostragem.....	39
4.2	Transformada de Fourier.....	40
4.3	Densidade Espectral da Potência .....	41
4.4	Periodograma .....	42
4.4.1	Método de Bartlett.....	43
4.4.2	Método de Welch.....	43
4.5	<i>Leakage e Windowing</i> .....	44
<b>CAPÍTULO 5 – Identificação de Sinais Acústicos.....</b>		<b>47</b>
5.1	<i>Data mining</i> .....	47
5.2	<i>Machine Learning</i> .....	48
5.2.1	Categorização do <i>Machine Learning</i> .....	49
5.3	Aprendizagem Supervisionada .....	50
5.3.1	Classificação Vizinho mais Próximo (K-Vizinhos) .....	50
5.3.2	<i>Support Vector Machine (SVM)</i> .....	52
5.3.3	Avaliação do Desempenho de Classificadores.....	60
<b>CAPÍTULO 6 – Procedimento Experimental e Processamento de Dados .....</b>		<b>63</b>
6.1	Descrição do procedimento experimental.....	63
6.2	Tratamento de dados .....	64
<b>CAPÍTULO 7 – Testes e Resultados .....</b>		<b>67</b>
7.1	Teste da Identificação de sinais .....	67
7.1.1	Teste com o método Validação Cruzada .....	67
7.1.2	Teste com o método <i>Holdout</i> .....	71
7.1.3	Introdução de novo ficheiro para teste. ....	74
7.2	Teste de posicionamento direcional.....	77

<b>Conclusões</b> .....	<b>81</b>
Sugestões para trabalho futuro .....	83
<b>Referências</b> .....	<b>85</b>
<b>Índice Remissivo</b> .....	<b>89</b>
<b>Apêndices</b> .....	<b>93</b>
Apêndice A – Rotina de Matlab: Processamento de Sinais .....	93
Apêndice B – Rotina de Matlab: Estima da DOA .....	95
Apêndice C – Rotina de Matlab: Treino de Classificador SVM .....	97
Apêndice D – Rotina de Matlab: Treino de Classificador K-NN .....	99
Apêndice E – Rotina de Matlab: Introdução de novo ficheiro para teste do Classificador.....	101
Apêndice F – Percurso em fiadas do bote <i>Zebro</i> .....	103
Apêndice G – Percurso por fiadas da lancha <i>Mindelo</i> .....	105



## Lista de Abreviaturas e Acrónimos

<b>AUV</b>	<i>Autonomous Underwater Vehicle</i>
<b>CC</b>	<i>Cross-Correlation</i>
<b>DFT</b>	<i>Discrete Fourier Transform</i>
<b>DOA</b>	<i>Direction of Arrival</i>
<b>FFT</b>	<i>Fast Fourier Transform</i>
<b>GIB</b>	<i>GPS Intelligent Bouy</i>
<b>GPS</b>	<i>Global Positioning System</i>
<b>KDD</b>	<i>Knowledge Discovery in Database</i>
<b>K-NN</b>	<i>K Nearest Neighbour</i>
<b>LBL</b>	<i>Long Baseline</i>
<b>OVA</b>	<i>One-Versus-All</i>
<b>OVO</b>	<i>One-Versus-One</i>
<b>RADAR</b>	<i>Radio Detection And Ranging</i>
<b>REX</b>	<i>Robotics Exercise</i>
<b>ROV</b>	<i>Remotely Operated Vehicle</i>
<b>RPM</b>	Rotações por minuto
<b>SBL</b>	<i>Short Baseline</i>
<b>SI</b>	Sistema Internacional
<b>SNR</b>	<i>Signal to Noise Ration</i>
<b>SOFAR</b>	<i>Sound fixing and ranging channel.</i>
<b>SONAR</b>	<i>Sound Navigation And Ranging</i>
<b>SV</b>	<i>Support Vector</i>
<b>SVM</b>	<i>Support Vector Machine</i>
<b>TDOA</b>	<i>Time Difference of Arrival</i>
<b>TOF</b>	<i>Time of Flight</i>
<b>USBL</b>	<i>Ultra Short Baseline</i>
<b>VRU</b>	<i>Vertical Reference Unit</i>
<b>ZH</b>	Zero Hidrográfico



## Índice de Figuras

Figura 1 - Variação gráfica da pressão aquando da passagem de uma onda acústica (Hansen, 2005, p. 23) .....	9
Figura 2 - Perfil genérico da velocidade do som .....	13
Figura 3 - Representação da lei de Snell-Descartes .....	15
Figura 4 - Lei de Snell-Descartes aplicada à propagação de raios sonoros (Andersson, 2008).....	15
Figura 5 Coeficiente de atenuação em função da frequência (Waite, 2002, p. 46).....	21
Figura 6 - Sistema de posicionamento LBL .....	29
Figura 7 - Sistema de posicionamento SBL .....	30
Figura 8 - Sistema de posicionamento USBL .....	31
Figura 9 - Sistema de posicionamento GIB.....	32
Figura 10 - Sistema de posicionamento L/S/USBL (Vickery, 1998, p. 6).....	33
Figura 11 - Diagrama ilustrando o método por hiperboloides.....	36
Figura 12 - Emissão de um sinal para o array de hidrofones .....	37
Figura 13- Amostragem no domínio da frequência da Transformada de Fourier (Manolakis & Proakis, 1996, p. 395).....	41
Figura 14 - Processo de <i>Machine Learning</i> que usa as observações de um sistema para gerar aproximações do output $Y'$ (Kantardzic, 2011, p. 89).....	49
Figura 15 - Classificador K-Vizinhos para $k = 5$ (Kantardzic, 2011, p. 120) .....	52
Figura 16 - Fases do algoritmo K-NN (Santos, 2015).....	52
Figura 17 - Três hiperplanos a, b e c, como possíveis soluções para um problema bidimensional. (Lantz, 2015, p. 135).....	54
Figura 18 Ilustração de hiperplano num espaço bidimensional (Carvalho & Lorena, 2007, p. 53).....	54
Figura 19 – SVM com margens suaves em espaço bidimensional (Lantz, 2015, p. 245) .....	56
Figura 20 - Mapeamento de dados de treino não lineares de $\mathbb{R}^2$ para $\mathbb{R}^3$ (Hofmann, 2006, p. 11).....	58
Figura 21- Esquema ilustrativo da segmentação de um sinal em blocos de 1s.....	64
Figura 22- Potência espectral da Lancha Mindelo proveniente de sinais recebidos pelo SR1 e TP1.....	65

Figura 23 - Resultado da aplicação de uma função de correlação cruzada entre dois sinais .....	66
Figura 24 – Matriz de confusão do classificador K-NN com $k = 2$ pelo método Validação cruzada.....	68
Figura 25 – Matriz de confusão do classificador K-NN com $k = 4$ pelo método Validação cruzada.....	69
Figura 26 - Matriz de confusão do classificador SVM, com Kernel cúbico, pelo método Validação cruzada.....	71
Figura 27 - Matriz de confusão do classificador K-NN com $k = 2$ e $k = 3$ pelo método <i>Holdout</i> com 20% de instâncias para teste. ....	72
Figura 28 - Matriz de confusão do classificador SVM, com kernel cúbico, pelo método <i>Holdout</i> com 20% de instâncias para teste. ....	74
Figura 29 – Matriz de confusão do classificador K-NN, com $k = 2$ e $k = 3$ , após introdução de novo ficheiro .....	75
Figura 30 - Matriz de confusão do classificador SVM, com kernel cúbico, após introdução de novo ficheiro. ....	77
Figura 31 - Azimute Verdadeiro Vs. Azimute Estimado .....	79
Figura 32 - Percurso por fiadas do bote <i>Zebro</i> e localização dos hidrofones TP-1 e SR-1. ....	103
Figura 33 - Percurso por fiadas da lancha <i>Mindelo</i> e localização dos hidrofones TP-1 e SR-1 .....	105

## Índice de Tabelas

Tabela 1 - Funções Kernel mais utilizadas.....	59
Tabela 2 - Resultados do treino do classificador K-NN, com $k=2$ , utilizando o método Validação Cruzada.....	68
Tabela 3 - Resultados do classificador K-NN para vários $k$ , através do método Validação cruzada.....	70
Tabela 4 - Resultados do teste do classificador SVM, com kernel cúbico, utilizando o método validação cruzada .....	70
Tabela 5 - Resultados do teste do classificador K-NN, com $k=3$ e $k=4$ , utilizando o método <i>Holdout</i> com 20% de instâncias para teste. ....	72
Tabela 6 - Resultados do classificador K-NN para vários $k$ , através do método <i>Holdout</i> . ....	73
Tabela 7 - Resultados do teste do classificador SVM, com kernel cúbico, utilizando o método <i>Holdout</i> com 20% de instâncias para teste. ....	73
Tabela 8 - Resultados do teste do classificador K-NN, com valores de $k = 2$ e $k = 3$ , após introdução de novo conjunto de teste. ....	75
Tabela 9 - Resultados do classificador K-NN para vários $k$ , com a introdução de um novo ficheiro.....	76
Tabela 10 - Resultados do teste do classificador SVM, com kernel cúbico, após introdução de novo conjunto de teste. ....	76
Tabela 11 – Resultado para a estima do azimute da Lancha Mindelo .....	78



## Introdução

Os Oceanos e os mares cobrem mais de 70% da superfície terrestre, sendo uma fonte abundante recursos naturais. Apesar do facto dos Oceanos desempenharem um papel crucial para a nossa sobrevivência (desde o ar que respiramos, até aos padrões de clima), o nosso conhecimento acerca do mesmo é bastante limitado. A maior parte da informação que possuímos sobre o meio aquático provém da exploração de águas pouco profundas/superficiais. As partes mais profundas deste meio permanecem um mistério, apesar de, cada vez mais, dependermos mais destas áreas para obter alimento, energia e outros recursos. Como tal, seria de esperar que despertasse a curiosidade humana.

É neste contexto que se tem verificado um elevado desenvolvimento no âmbito da robótica oceânica e submarina. Assim os *Autonomous Underwater Vehicles* (AUVs) possuem o potencial de revolucionar o nosso acesso às profundezas dos mares. Ao longo dos anos com o desenvolvimento deste tipo de tecnologia surgiram diversas questões relacionadas com o emprego de AUVs, sendo uma delas o controlo da posição dos aparelhos. Muitos dos sistemas de posicionamento conhecidos e utilizados fazem uso de radiação eletromagnética. No entanto, o meio aquático, especialmente de água salgada, exibe uma elevada condutividade sendo, por esta razão, altamente dissipativa para este tipo de radiação. Assim, surgem os sistemas de posicionamento subaquático que são baseados na utilização de transdutores ou *arrays* de transdutores acústicos. A existência de um sistema que permita efetuar, não só o seguimento, mas como também a identificação de uma AUV é uma importante ferramenta auxiliar ao sistema de navegação do mesmo de modo a permitir a estima dos seus movimentos para determinar a sua posição e orientação.

Desta forma, a presente dissertação foca-se no problema de efetuar o controlo direcional (*tracking*) e identificação acústica de plataformas de superfície recorrendo ao estudo de um sistema de escuta passiva (*array* de dois hidrofones), organizado segundo uma arquitetura *Long Baseline* (LBL), com o objetivo de ser empregue em AUVs do projeto *Deepfloat* e *Sidenav*.

## Estrutura do Documento.

A presente dissertação encontra-se dividida em sete capítulos, possuindo a seguinte estrutura.

- Capítulo 1 – Introdução: É efetuada uma contextualização da temática abordada, justificando a necessidade de efetuar o presente estudo.
- Capítulo 2 – Aplicações da Acústica Subaquática: São abordadas, de forma introdutória, algumas áreas de aplicação da Acústica Subaquática, divididas em aplicações civis e aplicações militares.
- Capítulo 3 – Enquadramento teórico: É revista a natureza física do som. São abordados os processos e fenómenos associados à sua propagação, bem como alguns fatores do meio que o influenciam. É também efetuada uma abordagem aos sistemas sonar e o modo como os fatores do oceano influenciam a sua interação com o som.
- Capítulo 4 – Sistemas de Posicionamento Acústico: São estudadas vários componentes, arquiteturas de organização e funcionamento dos mesmos. É definida uma forma de estimar a direção de chegada de sinais acústicos através da diferença de tempo de chegada e da função *cross-correlation*.
- Capítulo 5 - Processamento de Sinal: É estudado o método a utilizar para o tratamento e pré-processamento dos sinais acústicos recolhidos.
- Capítulo 6 - Classificação de sinais acústicos: São abordados métodos, baseados em técnicas de *data mining*, para identificar sinais acústicos recolhidos pelo *array* de modo a associá-los a diferentes plataformas. Para esta dissertação serão abordados dois métodos de aprendizagem supervisionada: K-Vizinhos e *Support Vector Machine*.
- Capítulo 7 - Procedimento experimental e tratamento de dados: É efetuada uma descrição do modo como foram recolhidos os dados e, posteriormente, tratados de modo a poderem ser aplicados algoritmos.
- Capítulo 8 – Testes e Resultados: São apresentados os resultados da aplicação dos algoritmos de identificação e de *tracking* direcional criados, aos dados previamente tratados. Para a identificação de sinais, os classificadores foram testados de três formas diferentes: método *holdout*, validação cruzada e introdução de novo ficheiro para teste. Para o *tracking* direcional foi aplicado o

algoritmo baseado na estima da direção de chegada a 20 segundos de gravação de uma das plataformas empregadas.

- Capítulo 9 – Conclusão: É realizado um breve sumário dos resultados e uma análise dos mesmos, tendo em conta os objetivos inicialmente propostos.



## **CAPÍTULO 1 – Aplicações da Acústica Submarina**

Podemos definir Acústica Subaquática como o estudo da propagação do som na água, bem como a interação das ondas mecânicas que o constituem com o meio aquático e as suas barreiras. Contrastando com as ondas eletromagnéticas, que são altamente atenuadas em ambientes líquidos, as ondas sonoras propagam-se facilmente em ambientes subaquáticos (Ballard, 2017). Desta forma, as mesmas são utilizadas na água da mesma forma que as ondas eletromagnéticas são usadas na atmosfera para inúmeras aplicações científicas, industriais, militares, entre outras.

No entanto, a possibilidade de usufruir do som para aplicações humanas é, aparentemente, conhecida há muito tempo, sendo Leonardo da Vinci<sup>1</sup> referido muitas vezes como o primeiro a propor este conceito. Apesar da longevidade do conceito de utilização de ondas sonoras as suas aplicações práticas apenas foram utilizadas eficientemente em sistemas de deteção passiva durante a Primeira Guerra Mundial. Foi no período entre as duas Guerras Mundiais que a tecnologia Sonar teve um avanço considerável, beneficiando do surgimento da primeira geração de componentes eletrónicos e da tecnologia rádio (Lurton, 2002, pp. 5-6).

O desenvolvimento da acústica subaquática teve um grande crescimento no período pós-guerra, sendo atualmente uma grande parcela das atividades humanas que têm lugar no mar ou em ambientes marinhos, tendo aplicações militares ou civis. Para as aplicações militares a prioridade será a criação e o uso eficiente de sistemas baseados na equação sonar ativa ou passiva (discutidas no Capítulo 3). Estas centram-se na identificação da posição e características de alvos (submarinos e navios superfície) através da análise de assinaturas acústicas, da análise de ecos (ex. o efeito de Doppler permite, num sistema sonar ativo, estimar a velocidade do alvo), e estimativa da direção de chegada do som. A Acústica Subaquática é também utilizada na deteção e identificação de minas colocadas nos fundos oceânicos de áreas costeiras.

À semelhança das aplicações militares, a Acústica Subaquática para aplicações civis tem tido um grande desenvolvimento em diversas áreas, surgindo assim diversas categorias de sistemas acústicos:

---

<sup>1</sup>Inventor italiano do século XV.

- Sondas batimétricas: Através do envio de curtos impulsos sonoros numa direção verticalmente descendente e medindo o tempo que demora o eco a retornar é possível calcular a profundidade de uma determinada coluna de água.
- Sondas piscatórias: Utilizadas para localizar e identificar cardumes de peixes ou até mesmo unidades individuais de espécies.
- Sonares de varrimento lateral: Utilizados para criar imagens acústicas dos fundos marinhos, permitindo observações de elevado rigor.
- Sonar de multi feixe: Têm a função de mapear os fundos de ambientes aquáticos. Se o alcance angular possuir amplitude suficiente, poderá providenciar imagens acústicas à semelhança dos Sonares de varrimento lateral (Lurton, 2002, p. 9).
- Perfilador de sedimentos: São usados impulsos de baixas frequências e grandes intensidades com intuito de penetrar o fundo do mar por forma a estudar a sua estrutura interna estratificada.
- Sistemas de comunicação acústica: Utiliza-se um sinal acústico, em vez de fios de ligação, de modo a efetuar a transmissão de informação.
- Sistemas acústicos de Doppler: Recorrendo a pares de transdutores ativos, orientados obliquamente para baixo, é possível obter a velocidade de uma plataforma em relação ao fundo através do efeito de Doppler.

## CAPÍTULO 2 – Enquadramento Teórico

### 2.1 O som como onda acústica

Podemos definir som, como o movimento constante, de moléculas num meio elástico. Devido à elasticidade do material, uma perturbação local, resultará no movimento de partículas a partir de um ponto, para pontos circundantes. Deste modo, o movimento vibratório é propagado extrinsecamente à fonte da perturbação (Urick, 1983). Assim, considera-se que o som é uma forma de energia mecânica, que se propaga na forma de ondas acústicas. Esta propagação de energia poderá ocorrer em qualquer meio material, seja este sólido, líquido ou gasoso.

Assim pode-se admitir a existência de dois tipos de ondas acústicas: as ondas longitudinais e as ondas transversais. Nos fluidos (ar e água), as ondas apenas se propagam longitudinalmente pois estes não possuem resistência suficiente ao cisalhamento. Por outro lado, as ondas transversais necessitam de um meio suficientemente rígido para se propagar.

As ondas longitudinais propagam-se nos fluidos por meio de compressões e dilatações sucessivas. Este fenómeno está relacionado com a pressão, um parâmetro fundamental de uma onda acústica. Quando uma partícula é movimentada, esta exerce uma força resistente a essa perturbação. A força é sentida localmente como pressão por unidade de área (Hodges, 2010)

Uma das principais formas de representar a variação de pressão, consiste num sinal periódico descrito por funções sinusoidais. Desta forma, o sinal acústico mais simples de representar corresponderia a uma função com a oscilação da pressão  $p$  em função do tempo  $t$  (Crocker, 1998)

$$p = A \sin(\omega t - \theta) \tag{1}$$

$$p = A \cos(\omega t - \theta)$$

Considerando  $A$  a amplitude da onda,  $\omega$  a frequência angular e  $\theta$  a constante de fase.

No entanto, a existência de sons puramente sinusoidais na natureza é impossível. Estes apenas servem de base para o estudo de todos os outros sons, já que podem ser decompostos em combinações de ondas sinusoidais.

### 2.1.1 Caracterização de ondas acústicas

- **Velocidade do som**

A velocidade de propagação  $c$  de uma onda acústica corresponde à taxa de propagação de uma perturbação no meio, ou seja, a rapidez com que a onda se propaga. Esta é um parâmetro imposto diretamente pelas características do meio onde se dá a perturbação.

$$c = \sqrt{\frac{E}{\rho}} \quad (2)$$

Sendo  $\rho$  a densidade do meio e  $E$  o módulo de elasticidade. Por esta razão é que as ondas acústicas se propagam com diferentes velocidades em meios distintos (Lurton, 2002). A unidade do Sistema Internacional (SI) para  $c$  é o metro por segundo ( $m/s$ ).

- **Amplitude**

A amplitude  $A$  corresponde à medição da mudança (positiva ou negativa) de pressão no meio (compressão e rarefação de moléculas), resultando na propagação da onda acústica. Graficamente está associada ao afastamento máximo relativamente à posição de equilíbrio (correspondente ao eixo das abcissas) (Figura 1). Deste modo, uma maior amplitude corresponderá a uma maior variação de pressão no meio. A amplitude é normalmente expressa em pascal ( $Pa$ ) (como ondas de pressão).




Figura 1 - Variação gráfica da pressão aquando da passagem de uma onda acústica (Hansen, 2005, p. 23)

- **Frequência, Período e Comprimento de onda**

As ondas acústicas não são perturbações que ocorrem instantaneamente pelo que resultam de vibrações que se mantêm ao longo do tempo. Como tal, são caracterizadas pela sua frequência  $f$  isto é, o número de ciclos oscilatórios por segundo, expresso em Hertz ( $Hz$ ). Por sua vez, também podemos considerar o período  $T$ , que corresponde ao tempo que demora um ciclo a repetir-se (sendo inversamente proporcional à frequência, ou seja,  $T = \frac{1}{f}$ ). A unidade SI para este parâmetro é o segundo ( $s$ ).

O comprimento de onda  $\lambda$  corresponde à distância entre dois pontos na mesma fase de onda a uma velocidade  $c$ . Verificamos então que:

$$\lambda = cT = \frac{c}{f} \quad (3)$$

As unidades mais comuns utilizadas para os valores de  $\lambda$  são o metro ( $m$ ) ou o centímetro ( $cm$ ).

- **Intensidade e Potência**

Uma onda acústica que se propaga, transporta energia mecânica na forma de energia cinética das partículas em movimento mais a energia potencial que provoca tensão no meio elástico. Pelo facto da onda se estar a propagar, uma certa quantidade de energia por segundo, fluirá através de uma unidade de área normal à direção de propagação (Urlick, 1983, p. 12). Assim a intensidade de uma onda acústica é o valor médio do fluxo de energia por unidade de superfície e tempo.

$$I = \frac{A_0^2}{2\rho c} \quad (4)$$

Sendo  $A_0$  a amplitude de uma onda e  $\rho c^2$  a resistência acústica específica. A unidade utilizada para descrever este parâmetro é o  $Watt/m^2$ . A potência acústica por unidade de área  $S$  pode ser descrita como:

$$P = I \times S \quad (5)$$

A unidade SI para a potência é o *Watt*.

## 2.2 Escala Logarítmica: Decibel

Quando as ondas acústicas se propagam poderão existir grandes variações nos valores da sua pressão ou energia. Assim, a medição e quantificação destas alterações dinâmicas serão efetuadas recorrendo a uma escala logarítmica, tornando este processo mais simples e conveniente.

A divisão fundamental da escala logarítmica é o *bel*, que serve para expressar a razão entre duas quantidades de potência (Albers, 1965, p. 13). No entanto, convencionalmente, é utilizada a décima parte desta divisão da escala, conhecida por decibel (*dB*). Assim, por definição, o *dB* corresponde ao logaritmo de base 10 da razão entre dois valores de potência, multiplicado por dez. Tem-se que (Lurton, 2002, p. 16):

$$10 \log \left( \frac{P_1}{P_2} \right) = 10 \log \left( \frac{p_1^2}{p_2^2} \right) = 20 \log \left( \frac{p_1}{p_2} \right) \quad (6)$$

Sendo  $P_i$  um valor de potência e  $p_i$  um valor de pressão<sup>3</sup>.

Para valores como a pressão e a potência, é necessário estabelecer um valor de referência. Deste modo será possível representar, numa escala de decibéis, os valores

---

<sup>2</sup> A resistência acústica específica de um fluido consiste num fator de proporcionalidade. Para a água salgada adquire o valor  $1.5 \times 10^5 g/(cm^2)(s)$  e para o ar  $42 g/(cm^2)(s)$  (Urlick, 1983, p. 12).

<sup>3</sup> A pressão elevada ao quadrado é proporcional ao valor da potência.

absolutos destas quantidades. Isto significa que, o valor de uma variável  $x$  em  $dB$ , relativamente a uma valor de referência  $x_0$ , será:

$$dB(x) = 10 \log \left( \frac{x_i}{x_0} \right) \quad (7)$$

## 2.3 Acústica subaquática

### 2.3.1 Velocidade do som na água

Tal como descrito na Equação (2), quanto mais denso for o meio de propagação do som, menor será a velocidade com que se propaga o som. No entanto, verifica-se que a velocidade do mesmo em meio aquático (cerca de 1500 m/s) é aproximadamente quatro vezes superior ao valor da velocidade de propagação no ar (340 m/s), apesar de a água ser mais densa que o ar. Na verdade, a velocidade do som, em meios de densidade semelhantes é determinada primariamente pelo módulo de elasticidade do mesmo. No entanto, no meio aquático, existem outros fatores que influenciam a sua velocidade de propagação:

- Temperatura. De um modo geral, a temperatura do mar diminui com o aumento da profundidade, que conduz a uma correspondente diminuição da velocidade do som. Esta variação é máxima em camadas superficiais devido à mistura de superfície, aquecimento solar e correntes marítimas. Contudo, a partir de uma profundidade limite (1000 m nos Oceanos e 200 a 300m em zonas menos profundas) a temperatura mantém-se relativamente estável, diminuindo lentamente. Deste modo, podemos aferir que até à profundidade limite a temperatura é o fator que mais influencia a velocidade das ondas acústicas.
- Profundidade. Traduzida em pressão hidrostática<sup>4</sup>, é proporcional à velocidade do som devido a variações do módulo de elasticidade e da densidade. A velocidade varia com a pressão de um modo aproximadamente linear, cerca de 0.017 m/s por cada metro de profundidade (Lurton, 2002).

---

<sup>4</sup>  $P = (1.0052405(1 + 5.28 \times 10^{-3} \sin^2 \phi)z + 2.36 \times 10^{-6}z^2 + 10.196) \times 10^4$ , na qual P corresponde à pressão em Pa,  $\phi$  a latitude em graus e z a profundidade em m (Lurton, 2002).

- Salinidade. A água dos Oceanos possui, na sua constituição, sais dissolvidos ( $NaCl$ ,  $MgSO_4$ ,...) que lhe conferem um determinado grau de salinidade (nos grandes Oceanos este valor é, em média, 35 partes por milhar (*ppm*)) (Lurton, 2002). Uma variação na salinidade da água corresponderá a uma variação na densidade, provocando mudanças no valor da velocidade do som. A concentração de sais dissolvidos irá variar pouco com a profundidade. Esta apenas irá sofrer uma mudança significativa em locais onde haja mistura com água doce: estuários de rios, glaciares, etc.

Podemos inferir então, que os fatores apresentados provocarão alterações no módulo de elasticidade e na densidade, o que conduzirá a uma variação do valor da velocidade do som ao longo de uma coluna de água. Assim, a sua evolução pode ser considerada uma função da temperatura, salinidade e pressão (ou profundidade). É segundo este pensamento que Mackenzie (1981) define uma expressão empírica para a velocidade do som na água,  $c$ , em  $m/s$ :

$$\begin{aligned}
 c(T, s, z) = & 1448.96 + 4.591T - 0.591T - 0.05304T^2 + 2.374 \\
 & \times 10^{-4}T^3 + 1.34(s - 35) + 0.0163z + 1.675 \\
 & \times 10^{-7}z^2 - 0.01025T(s - 35) - 7.319 \times 10^{-13}Tz^3
 \end{aligned} \tag{8}$$

Em que  $T$  é a temperatura da água em graus Celsius,  $s$  a salinidade em *ppm*, e  $z$  a profundidade em  $m$ .

Considerando as variações que a velocidade do som sofrerá ao longo de uma coluna de água, é conveniente dividir a mesma em camadas horizontais. Esta divisão dará origem a um perfil de velocidade do som que poderá ser representado graficamente, tal como ilustrado na Figura 2.

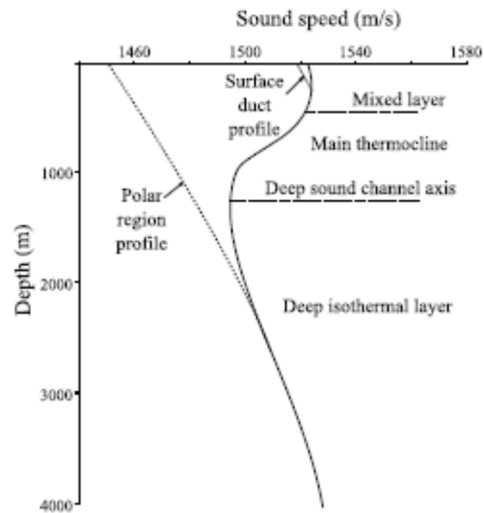


Figura 2 - Perfil genérico da velocidade do som

Tipicamente na zona mais superficial de uma coluna de água, apresenta-se uma camada homogénea, ou de mistura. Esta é suscetível a variações, diárias e locais, do aquecimento, arrefecimento e da ação do vento, que darão origem a um meio isotérmico de água. No entanto, quando estas variações não existem esta camada dá origem a um ambiente em que a temperatura decresce com a profundidade.

Por baixo da camada superficial, encontra-se a termoclina. Este termo denota um meio em que a temperatura varia devido à profundidade. É característico desta camada existir um gradiente de temperatura negativo e, conseqüentemente, a diminuição da velocidade do som. É de notar que, a profundidades superiores (inferiores à camada de mistura), existe uma termoclina sazonal, em que o gradiente térmico varia consoante a estação do ano (Urick, 1983).

Nas camadas inferiores à termoclina, a temperatura, por não possuir influências provenientes da superfície, manter-se-á constante. Desta forma, a velocidade do som sofrerá um aumento devido ao aumento da pressão.

### 2.3.2 Teoria de Propagação e *Ray Tracing*

A propagação de ondas acústicas, num meio elástico, pode ser descrita matematicamente através de soluções da equação de ondas. Esta corresponde a um diferencial parcial, relacionando a pressão  $p$  com  $u(x, y, z)$  e tempo  $t$ :

$$-\frac{1}{c^2} \frac{\partial^2 p}{\partial t^2} = \frac{\partial^2 p}{\partial u^2} \quad (9)$$

Em que  $c$  corresponde ao valor da velocidade do som que poderá variar com as coordenadas.

Existem duas aproximações teóricas para solucionar esta equação: a teoria dos modos normais e a teoria dos raios acústicos. Apesar de ambas serem hipóteses válidas, apenas será abordada a teoria dos raios acústicos, por ser uma solução mais simples e de fácil compreensão.

A teoria dos raios acústicos baseia-se nos princípios de que, ao longo das frentes de onda, a fase de onda ou a função de tempo da solução é constante e que a deslocação do som, produzido por uma fonte, no meio é descrita por raios, tal como acontece com a radiação eletromagnética nesta mesma aproximação de raios. Estes podem ser representados em diagramas de raios, dando-nos uma forma intuitiva de descrever a propagação do som. Contudo, esta teoria apresenta algumas limitações. Quando existe uma variação considerável na amplitude da pressão ao longo de uma distância equivalente ao comprimento de onda, esta não proporcionará uma solução adequada para a equação de onda. Num sentido prático, a teoria dos raios é ideal para sinais de frequências elevadas ou comprimentos de onda reduzidos (Urick, 1983), relativamente às dimensões dos objetos no seu percurso.

Um dos resultados da teoria dos raios é a aplicação da lei de Snell-Descartes (Figura 3), que descreve a refração dos raios sonoros num meio com variações de velocidade. Segundo esta lei, um raio  $\Phi_i$  a incidir, com um ângulo  $\theta_1$ , no limite de duas camadas de um meio com diferentes velocidades do som e densidades, produzirá um raio  $\Phi_r$  resultante da reflexão e um raio  $\Phi_t$  refratado com um ângulo  $\theta_2$ .




Figura 3 - Representação da lei de Snell-Descartes

Se considerarmos a divisão de uma coluna de água em camadas, como descrito na seção anterior, a lei de Snell-Descartes pode ser utilizada para prever o trajeto do raio de som dentro de água (Figura 4). Isto é conhecido como *Ray Tracing*.




Figura 4 - Lei de Snell-Descartes aplicada à propagação de raios sonoros (Andersson, 2008).

Então, tendo em conta este pressuposto, pode-se inferir que quando um sinal sonoro é emitido num meio de valores constantes de velocidade, este seguirá uma trajetória constante. Se estes valores não se mantiverem constantes ao longo da coluna de água, os raios sonoros apresentarão uma trajetória curvilínea. Deste modo as velocidades e ângulos de incidência nas diferentes camadas podem ser relacionados pela lei de Snell-Descartes através da equação:

$$\frac{\cos\theta_1}{c_1} = \frac{\cos\theta_2}{c_2} \quad (10)$$

Esta equação permite-nos constatar que os raios são refratados para a direção do meio em que a velocidade do som é menor. Após uma determinada distância percorrida, o raio sonoro atingirá o seu ângulo de incidência crítico (Equação 11). Este ângulo corresponde ao limite que, para valores inferiores ao mesmo, haja uma reflexão perfeita do raio (Andersson, 2008).

$$\theta_c = \arccos\left(\frac{c_1}{c_2}\right) \quad (11)$$

Esta situação apenas é possível se a velocidade do som na segunda camada for superior ao da primeira (Andersson, 2008)

Numa situação em que temos uma camada de água isotérmica, mantendo-se a velocidade do som constante, não haverá grandes alterações angulares do som, possibilitando deste modo um longo alcance dos raios. Por outro lado, se o gradiente da temperatura se apresentar negativo, a velocidade diminui com a profundidade, e os raios sonoros sofrerão um desvio descendente. Isto poderá criar uma zona de sombra, na qual uma onda sonora não conseguirá penetrar. O oposto acontecerá se existir um gradiente positivo da temperatura. Nesta situação os raios sonoros terão um desvio ascendente. Com este tipo de gradiente, o som possuirá um maior alcance horizontal, pois, ao serem refratados para cima, os raios sonoros serão refletidos de volta pela superfície da água. Este processo ocorrerá repetidamente, exceto se existir uma grande agitação marítima.

Quando o gradiente de velocidade negativo se sobrepõe a um gradiente positivo, é produzido um canal sonoro. Nesta situação, o som que se propaga nesta área, é refratado repetidamente numa direção até atingir o ângulo crítico, sendo refletido na direção oposta. Este mecanismo é repetido múltiplas vezes, fazendo com que o som fique confinado num canal horizontal. O mesmo poderá acontecer com apenas um gradiente positivo e a reflexão de raios sonoros na superfície.

Este fenómeno também poderá ser observado a elevadas profundidades, em regiões onde a velocidade do som é mínima, formando o canal SOFAR<sup>5</sup>.

### 2.3.3 Efeito de Doppler

O efeito de Doppler corresponde à diferença aparente entre a frequência de um sinal quando é transmitido por uma fonte e a frequência do mesmo quando alcança um alvo, causada pelo movimento relativo entre o emissor do sinal e o recetor.

Considere-se uma fonte acústica a uma distância  $D$  de um recetor estacionário, a emitir sinais com um período constante  $T$ . Caso a fonte esteja imóvel, é possível inferir que o valor de  $D$  não varia com o tempo  $t$ , ou seja, o tempo que demorará ao sinal emitido

---

<sup>5</sup> *Sound fixing and ranging channel.*

chegar à fonte será  $t = D/c$  (sendo  $c$  a velocidade de propagação do som). Neste caso não existem alterações na frequência aparente do sinal do que o seu período não sofre alterações.

Por outro lado, se houver movimento relativo entre a fonte e o recetor,  $D$  sofrerá alterações em função do tempo, isto é:

$$D(t) = D \mp v_r t \quad (12)$$

Sendo  $v_r$  a velocidade relativa entre a fonte e o recetor. Assim, o tempo entre a receção de sinais consecutivos alterar-se-á, ou seja, se um sinal for captado pelo recetor num instante  $t_1$ , um segundo sinal será recebido num instante:

$$t_2 = t + \frac{D(t_1) \mp v_r t}{c} \quad (13)$$

Desta forma tem-se que o atraso entre sinais será:

$$t_2 - t_1 = t - \frac{v_r t}{c} = t \left( 1 \mp \frac{v_r}{c} \right) \quad (14)$$

Considerando que os sinais são emitidos em espaços de tempo correspondentes ao período  $T$  do sinal, a frequência aparente do sinal é calculada por (Lurton, 2002, p. 34):

$$f = \frac{1}{T \left( 1 \mp \frac{v_r}{c} \right)} = \frac{f_0}{\left( 1 \mp \frac{v_r}{c} \right)} \approx f_0 \left( \frac{c}{c \mp v_r} \right) \quad (15)$$

A partir das equações apresentadas, é possível concluir que o valor da frequência tende a aumentar com a aproximação da fonte emissora do recetor e a diminuir com o afastamento da mesma.

Para certos casos, a fonte acústica movimenta-se segundo um determinado ângulo relativamente a uma fonte estacionária. Desta maneira, é possível relacionar esta quantidade angular com a frequência aparente do sinal emitido. Assim tem-se:

$$f = \frac{1}{T \left( 1 \mp \frac{v_r}{c} \right)} = \frac{f_0}{\left( 1 \mp \frac{v_r}{c} \right)} \approx f_0 \left( \frac{c}{c \mp v_r} \right) \quad (16)$$

Sendo  $v$  a velocidade do emissor acústico. Pode-se verificar que uma das aplicações possíveis da medição deste efeito será determinar a velocidade de um objeto que esteja ao alcance de sistemas Sonar (*Sound fixing and ranging channel*).

### 2.3.4 Fontes de Ruído

O ruído ambiente do oceano pode ser definido como todo o som, geralmente não desejado, que interfere com a operação de sistemas sonar ou outros aparelhos, em ambiente subaquático (Dyer, 1998), ou seja, é todo o som produzido por fontes sonoras que não sejam a fonte que se deseja captar. Como tal, este fenómeno pode ser considerado uma característica do próprio meio de propagação. Existem inúmeras fontes de ruído no oceano, de diversas origens físicas e pertencentes a diferentes bandas de frequência.

Ruídos que se encontram em bandas de frequência muito baixas estão normalmente associados ao movimento da própria água através de correntes marinhas e som terrestre causado por atividade sísmica e vulcões (Albers, 1965). Por possuir frequências demasiado baixas para ser detetado, este tipo de ruído não é normalmente considerado influente na operação de sistemas sonar.

Em águas costeiras e pouco profundas os dois tipos de ruído predominantes são provenientes de vida marinha ou de distúrbios antropogénicos (Albers, 1965, p. 116). Este último é predominante nas proximidades de portos ou em locais de grande densidade de tráfego marítimo. É importante referir que dentro deste tipo de ruído o fator mais predominante é o som proveniente de navios, impondo limitações o desempenho de sistemas sonar quando excede a intensidade do ruído ambiente. O ruído produzido por navios, encontra-se normalmente na banda de frequências dos 10-1.000 Hz (Lurton, 2002, p. 112), destacando-se, neste âmbito:

- O ruído gerado pelos hélices: geralmente de baixas frequências, entre 0.1 e 10 Hz, diretamente dependente da velocidade de rotação e formato do hélice. Associado a este tipo de ruído, está o ruído de cavitação, causado pelas depressões induzidas pelos movimentos das pás dos hélices.
- O ruído do movimento da água: dependente da velocidade e rumo do navio.
- O ruído gerado pelas máquinas: associado ao equipamento instalado no navio: motores, geradores, caixa redutora, hidráulicos, etc. Estes produzirão vibrações na estrutura do navio, que, por sua vez, serão transmitidas para o meio aquático.

É importante considerar o ruído produzido pela agitação da superfície da água, estando este dependente do estado do mar e das condições ambientais, não ultrapassando

as centenas de Hz em frequência. Deste modo, as condições ambientais são predominantes a baixas frequências (abaixo dos 10 Hz) na forma de turbulência, que induz variações de pressão. Este processo físico é igualmente dominante na ordem das centenas de Hz, devido às microbolhas de ar na camada de água superficial, que sofrem dilatações e rebentamentos, induzidas pelas variações de pressão originadas pelo movimento da água pela ação do vento.

### 2.3.5 Perdas na propagação

Um destes efeitos consiste em perdas na intensidade das ondas sonoras, normalmente medidas desde um ponto a 1m de distância da fonte até a uma determinada distância na água. Este efeito é um importante parâmetro de previsão de desempenho de sistemas Sonar (discutido mais adiante) e é descrito como *transmission loss (TL)*.

Quando se dá a propagação de ondas acústicas, os processos mais evidentes que se traduzem em decréscimos de intensidade das mesmas são: o espalhamento geométrico (efeito divergente) e a absorção da energia acústica pelo próprio meio de propagação (Lurton, 2002, p. 18). O primeiro fenómeno ocorre devido à propagação omnidirecional do som., isto é, a propagação sonora ocorre numa forma esférica, o que significa que a energia acústica será transmitida para uma área gradualmente maior. À semelhança dos fenómenos que ocorrem na natureza, a propagação de ondas acústicas respeita a lei da conservação de energia. Devido a este facto, a intensidade da onda diminuirá, também esta de forma gradual, com o aumento da distância percorrida pela mesma. Desta forma a alteração local da intensidade do som pode ser calculada por (Lurton, 2002, p. 19):

$$TL = \frac{I_2}{I_1} = \left(\frac{4\pi R_1}{4\pi R_2}\right)^2 = \left(\frac{R_1}{R_2}\right)^2 \quad (17)$$

Em que  $R_i$  é a distância radial à fonte. Este valor, considerado a partir da distância de referência de 1m à fonte, pode ser expresso em dB. Assim, tem-se (Albers, 1965, p. 83):

$$TL = 20\log\left(\frac{R}{R_{1m}}\right) = 20\log(R) \quad (18)$$

O segundo fenómeno associado a perdas de intensidade do som aquando da sua propagação, varia de forma diferente em relação ao espalhamento. A absorção do som

pelo meio em que se propaga envolve o processo de transformação de energia acústica em calor. Por esta razão pode-se dizer que a absorção é realmente uma perda de energia acústica, ao contrário do espalhamento geométrico que traduz-se na sua distribuição numa área mais extensa<sup>6</sup>. Assim, este processo ocorre devido a duas causas principais: a viscosidade do meio e relaxação molecular (Waite, 2002, p. 46). A absorção do som é expressa pelo coeficiente de absorção  $\alpha$  ( $dB/km$ ).

A viscosidade de um meio pode ser definida como a propriedade, de fluidos, correspondente ao transporte microscópico por difusão molecular. Isto significa que quanto maior for a viscosidade de um fluido mais energia será necessária aplicar para movimentar as suas partículas. Uma onda acústica, sendo uma forma de energia mecânica, irá provocar o movimento de partículas aquando da sua passagem. Isto significa que, para um meio mais viscoso, a sua propagação carecerá necessariamente de uma maior transferência energética para as partículas envolventes, o que se traduzirá numa diminuição da sua intensidade. A contribuição da viscosidade para as perdas de intensidade é proporcional ao quadrado da frequência ( $f^2$ ). A Figura 5 demonstra a variação de  $\alpha$  em função da frequência, em água salgada e água doce.

---

<sup>6</sup>Apesar deste facto ambas são consideradas perdas pois traduzem uma diminuição da intensidade da energia emitida relativamente àquela que é captada por um transdutor.




Figura 5 Coeficiente de atenuação em função da frequência (Waite, 2002, p. 46)

Por outro lado, a relaxação molecular apenas ocorre em ambientes de água salgada. Esta é a causa dominante de absorção do som para frequências abaixo dos 100 kHz (Urick, 1983, p. 105). Neste caso, a absorção do som é causada pela dissociação de componentes iônicos da água, causada pela variação local de pressão. Se o período desta variação for superior ao tempo necessário para as moléculas se recomorem (tempo de relaxação), este processo é repetido sucessivamente até se dar a dissipação completa da energia. (Lurton, 2002, p. 20). Este fenómeno ocorre normalmente com moléculas de sulfato de magnésio ( $MgSO_4$ ) para frequências entre os 2 e os 500 kHz (Waite, 2002, p. 47) e com moléculas de ácido bórico ( $B(OH)_3$ ) para frequências acima de 1 kHz. (Lurton, 2002, p. 20). Para frequências muito elevadas este fenómeno não ocorre naturalmente, pois as variações de pressão são demasiado rápidas para que ocorra a relaxação dos iões.

Com as perdas de intensidade causadas pela absorção, o valor de  $TL$  é obtido através da expressão em dB:

$$TL = 20 \log(R) + \alpha R \quad (19)$$

As perdas na propagação do som também ocorrem devido ao *scattering*, isto é, o desvio e espalhamento das ondas acústicas devido à sua interação com partículas do meio, e à reflexão e refração em superfícies.

### 2.3.6 Equações Sonar

Devido à facilidade de propagação do som no meio subaquático as ondas acústicas têm um variado propósito no seu uso e na exploração do oceano. O uso do som no meio subaquático está associado ao uso da tecnologia Sonar, que é implementada em sistemas que utilizam ondas acústicas no meio aquático, os sistemas Sonar.

Estes são considerados ativos quando o som é gerado por um componente do sistema chamado projetor. As ondas acústicas propagam-se no oceano até atingirem um alvo e retornam como ecos a um hidrofone, que converte o som num sinal elétrico. É possível determinar a distância do alvo em questão, através da medição do tempo entre a emissão do sinal sonoro e a sua receção

Os sistemas Sonar passivos, por outro lado, utilizam o som que é produzido pelo próprio alvo. Desta forma, as ondas acústicas propagam-se apenas unilateralmente, centrando-se, o sistema Sonar, no hidrofone que é utilizado para captar o som. Fazendo uso apenas de um hidrofone é impossível determina a posição a que o alvo se encontra. Este feito apenas é possível se conjugarmos outros equipamentos de escuta passiva. Com vários hidrofones torna-se possível fazer uma triangulação do alvo, determinando assim a sua distância/posição.

As equações Sonar permitem prever o desempenho de um sistema Sonar ou desenvolver sistemas que requeiram um determinado nível de desempenho. Para uma previsão de desempenho de um sistema Sonar, os parâmetros Sonar são previamente conhecidos sendo necessário efetuar uma estima relativamente ao desempenho de deteção. As equações são determinadas tendo em conta as perdas na propagação associadas a probabilidade de deteção de alvos ou de falsos alarmes específicas. Assim,

estas perdas são convertidas em estimativas do alcance de deteção em ambientes de interesse (Waite, 2002, p. 119)

Podemos então afirmar que as equações Sonar assentam num princípio básico de igualdade entre porções desejadas (sinal) e indesejadas (ruído) do sinal recebido. Para um sistema Sonar detetar um sinal acústico com sucesso é necessário que a intensidade do sinal seja superior à intensidade do ruído detetado.

A igualdade descrita pode ser expressa através dos parâmetros Sonar. Os mesmos podem ser convenientemente e logicamente agrupados de forma quantitativa, relacionando-se entre si pelas equações Sonar.

### **Equação Sonar Passiva**

Para um sistema Sonar passivo, a equação que relaciona os diferentes parâmetros é dada por:

$$SNR = (SL - TL) - (NL - DI) \quad (20)$$

Verifica-se que a equação que descreve a onda acústica detetada pelo recetor é composta por duas partes distintas:  $(SL - TL)$  representa o nível do sinal e  $(NL - DI)$  o nível de ruído.  $SNR$  corresponde ao *Signal-to-Noise Ratio*.

O  $SNR$  é um conceito importante no que toca a sistemas Sonar pois representa o ponto até ao qual a amplificação do sinal pode ser implementada para melhorar o mesmo. Se este for demasiado baixo, significará que o ruído é quase igual ao sinal. Neste caso a amplificação do sinal aumentará também o ruído, não proporcionando melhoras substanciais. Por outro lado, com um  $SNR$  elevado, a amplificação melhorará a magnitude do sinal relativamente ao ruído.

Como foi constatado o sinal que o equipamento recebe, consiste na diferença<sup>7</sup> de dois parâmetros distintos. Deste modo, quando uma fonte de som produz uma onda acústica, com uma intensidade de  $SL$  dB, a mesma propaga-se no meio sofrendo atenuações de energia. Quando a onda chega ao recetor, a sua intensidade terá sido reduzida pelas perdas na propagação de  $TL$  dB. Este parâmetro resume, num único valor, todos os fenómenos associados à propagação da onda que se traduzem no

---

<sup>7</sup> Como os parâmetros se encontram em dB, as adições e subtrações representam multiplicações e divisões em termos reais.

enfraquecimento do som, sejam elas devido ao *scattering*, refração ou absorção. Tipicamente as perdas na propagação estão dependentes da distância entre a fonte emissora e o recetor.

No entanto, o recetor não deteta apenas o sinal que é emitido pela fonte sonora. No meio aquático, por onde se propagam as ondas acústicas, existe ruído proveniente de fontes externas ao emissor de som. Apesar de existirem origens distintas este é representado num único parâmetro,  $NL$ . Este fator é atenuado pela diretividade do recetor,  $DI$ , pelo facto do recetor não possui ganho igual em todas as direções (se o recetor for omnidirecional  $DI$  terá o valor de 0 dB). Desta forma podemos ver que o nível de ruído total será a diferença entre os parâmetros  $NL$  e  $DI$ , ou seja,  $(NL - DI)$ .

### **Equação Sonar Ativa**

Como foi referido anteriormente, ao contrário do que acontece num sistema sonar passivo, um sistema sonar ativo tem por base a deteção de ecos. Como tal, será necessário considerar mais parâmetros de modo a prever o desempenho deste tipo de sistemas. Assim tem-se:

$$SNR = SL - 2TL + TS - (NL - DI) \quad (21)$$

Pode-se observar que o termo  $SL - TL$  da equação passiva é substituído pelo termo  $SL - 2TL + TS$ . Nesta equação o termo  $TL$  encontra-se multiplicado por dois dado que o sinal acústico tem percorrer o trajeto até ao alvo de deteção e regressar como eco, praticando o dobro da distância comparativamente a sistemas passivos (ocorrendo o dobro de perdas de propagação). O termo  $TS$ , *Target Strength*, é referente à taxa de reflexão por parte do alvo, isto é, a capacidade do alvo para refletir sinais acústicos (energia).

Nesta equação; o termo  $NL - DI$  pode ser equivalente ao *Reverberation Level*,  $RL$ , ou nível de reverberação. Este descreve o nível de ecos não desejados provenientes de estruturas submarinas e vida marinha que refletem o sinal. Este termo apenas é utilizado quando a reverberação limita a detetabilidade dos ecos do alvo (Tucholski, 2006).

## CAPÍTULO 3 – Sistema de Posicionamento Acústico

A simples transição das técnicas de navegação disponíveis baseadas em sinais eletromagnéticos para sistemas no meio subaquático não é aplicável devido à peculiaridade e constrangimentos do mesmo. As características do próprio meio impedem os sinais eletromagnéticos de se propagarem abaixo da linha da água. Assim, devido à facilidade de propagação de ondas acústicas na água, os sistemas de posicionamento acústico subaquático são uma alternativa viável para contornar os constrangimentos impostos pelas características únicas do ambiente subaquático, É deste modo que as técnicas de posicionamento acústico são adequadas para o ambiente submarino, podendo ser combinadas com algumas metodologias e algoritmos padrão utilizados no Sistema de Posicionamento Global (GPS).

### 3.1 Dispositivos utilizados

De modo a efetuar o posicionamento recorrendo a ondas acústicas existem diversos dispositivos disponíveis, que permitem receber e/ou emitir sinais sonoros. A combinação destes dispositivos depende do tipo de sistema de posicionamento acústico e do seu propósito.

Os dispositivos mais usuais, no que toca à acústica submarina, são os transdutores eletroacústicos. Estes aparelhos são essenciais para a transmissão e receção de sinais acústicos debaixo de água. Da mesma forma que conjuntos de amplificadores e microfones são utilizados para a propagação do som no ar, estes convertem energia acústica em energia elétrica, e vice-versa. (Lurton, 2002, p. 137). Tendo em conta este paralelismo, podemos equiparar os projetores a amplificadores, como fonte acústica subaquática. Os transdutores de receção, denominados hidrofones, servem de analogia para os microfones. É possível elaborar estruturas complexas a partir de vários transdutores elementares. Estas estruturas são normalmente referidas como *arrays*. O objeto de estudo desta dissertação foca-se apenas na operação de um *array* hidrofones, por isso não serão utilizados projetores para efeitos de teste.

Existem ainda outros dispositivos com funções mais específicas como é o caso do *transponder*, que consiste num dispositivo que recebe um sinal acústico proveniente de um transdutor e de seguida emite um sinal de resposta. Desta forma torna-se possível

calcular a distância entre dispositivos através do tempo que o som demora a percorrer este espaço.

O *responder* é um dispositivo bastante similar ao *transponder* excetuando o facto de ser necessário um outro aparelho (hidrofone) para receber o sinal emitido inicialmente.

O *pinger* consiste num emissor que envia continuamente e a intervalos de tempo fixos um sinal predefinido. Este dispositivo será utilizado em conjunto com o *array* de hidrofones para efeitos de estudo, nesta dissertação.

Os aparelhos acústicos subaquáticos podem recorrer a diversos processos físicos para gerar ou receber ondas acústicas. No entanto, a maioria usufrui das propriedades piezoelétricas<sup>8</sup> de alguns cristais, naturais ou artificiais (cerâmicas). Deste modo, um campo elétrico aplicado a estes materiais provoca deformações associadas à excitação elétrica. Estas deformações mecânicas, por sua vez, darão origem a ondas acústicas. Como seria de esperar, são utilizados os efeitos opostos aquando da receção de um sinal: o material piezoelétrico é pressionado pelas ondas acústicas que conduzirá à produção de energia elétrica (Lurton, 2002, p. 137).

Estes aparelhos acústicos poderão ser integrados em redes/servidores por forma a receberem/enviarem dados em tempo-real recorrendo a módulos de apoio na superfície. No presente documento é apenas estudado o funcionamento de transdutores em modo *offline*.

### **3.2 Sincronização de transdutores (hidrofones)**

Um dos requisitos comuns para o eficaz funcionamento de *arrays* de transdutores, semelhantes ao estudado na presente dissertação, consiste na sincronização temporal precisa das diferentes plataformas. Isto é feito através de *clock synchronization* ou sincronização de relógios. Desta forma, ao serem implementados em rede/servidor, os hidrofones submersos, ao possuírem, cada um deles, um relógio associado, poderão concordar relativamente ao espaço temporal a que as gravações estão a ocorrer. Assim, os cálculos efetuados pelo *array* ocorrerão em tempo-real, com os transdutores a gravar ruído simultaneamente.

---

<sup>8</sup> Consiste na capacidade de gerar um campo elétrico através da aplicação de energia mecânica (pressão).

No entanto, a sincronização de relógios não é um processo linear, visto que, os cristais osciladores que normalmente compõem relógio digitais são imperfeitos. Isto faria com que a precisão na ordem dos milissegundos apenas se manteria durante um curto espaço de tempo após os hidrofones se encontrarem a gravar conjuntamente (Efteland, 2016, p. 20).

Existem diferentes modos de sincronizar os relógios de transdutores a trabalhar em rede. Uma forma seria usar sinais acústicos provenientes de posições conhecidas entre os hidrofones. Outra forma, seria recorrer à tecnologia GPS (Efteland, 2016). Se os transdutores possuírem *hardware* de receção de sinal GPS, estes receberão informação proveniente dos satélites sobre a sua posição e configuração temporal. Deste modo, ao estarem horariamente síncronos com satélites, os hidrofones do *array* estarão igualmente sincronizados entre si.

Para esta dissertação, tal como referido anteriormente, e para efeitos de estudos teóricos, os hidrofones não foram ligados em rede. Assim, a sincronização de gravações, para aplicação posterior de algoritmos, foi efetuada *offline*.

### **3.3 Arquitetura e funcionamento de sistemas de posicionamento.**

De acordo com o objetivo de um sistema de posicionamento é possível organizar dispositivos acústicos (hidrofones, transdutores,...) de modo a ir a encontro das nossas necessidades. Desta forma, podemos admitir a existência de três arquiteturas comuns que correspondem a diferentes sistemas de posicionamento acústico: *Long Baseline* (LBL), *Short Baseline* (SBL) e *Ultra Short Baseline* (USBL). A distância entre os diferentes dispositivos que os compõem (*baseline*) é geralmente utilizada como critério de classificação para as diferentes arquiteturas disponíveis. É importante referir que dentro de cada arquitetura, é possível organizar os dispositivos de diferentes modos permitindo que ~~haja~~ **HAJA** diversos modos de operação.

#### **3.3.1 Long Baseline (LBL)**

O Sistema de posicionamento LBL adquire a sua designação pelo elevado distanciamento que separa os diversos constituintes que o constituem. Tipicamente esta

arquitetura é composta por um conjunto de transdutores com posição bem definida, no fundo do mar, e por um conjunto emissor/recetor instalado no alvo (caso seja um sistema Sonar activo). Estes componentes poderão ter uma separação na ordem dos quilómetros dependendo da área que se tenciona cobrir, contudo, estes valores não costumam ser superiores a 50~2000m (Tomczak, 2011, p. 382).

No caso de se aplicar um sistema Sonar ativo, a posição do alvo é adquirida através da triangulação baseada na posição dos transdutores (que nesta situação serão *transponders*). Inicialmente o transdutor instalado no alvo emitirá um sinal acústico de interrogação, que será recebido pelo *array* de *transponders*. Posto isto, cada *transponder* enviará um sinal de resposta para o transdutor no alvo. Deste modo, é medido o tempo que o sinal acústico inicial demora a atingir cada *transponder* e o tempo que cada sinal de resposta demora a atingir o alvo. Tendo conhecimento da velocidade do som na área a cobrir é possível converter estas medições de tempo diretamente em distâncias. Com o cálculo da distância a que se encontra cada *transponder* do alvo, é obtido um ponto onde estas distâncias se intersectam. Este ponto corresponderá a posição do alvo. Para realizar este processo são necessários no mínimo três *transponders*. A realização desta operação com apenas dois *transponders* resultará na obtenção de dois pontos de interseção das distâncias. Por outro lado, a implementação de um maior número de *transponders* conduz a uma maior fiabilidade nos resultados e permitirá cobrir uma área mais extensa. Uma vez que existe mais do que um emissor torna-se necessário que os sinais de resposta sejam distinguíveis, para que haja uma transmissão simultânea de sinais. Este feito é alcançado através do recurso a diferentes frequências ou codificações por parte de cada emissor. É importante referir que a escolha das frequências é crucial para a fiabilidade do processo visto que quanto maior a frequência, menor será a precisão do sistema (Tomczak, 2011)

Uma outra alternativa será o uso de um sistema de escuta passiva. É possível adquirir a posição de um alvo através da deteção do seu ruído por um *array* de hidrofones inserido num referencial centrado numa posição de coordenadas bem definidas. Este processo, contrariamente à triangulação descrita anteriormente, não se baseia na medição do tempo que um sinal acústico demora a percorrer o espaço, ida e volta ou *Time of Flight* (TOF), entre o alvo e o *array* de transdutores. Neste caso, o cálculo da direção de onde é proveniente o ruído, ou *Direction of Arrival* (DOA), está na base para determinar a posição do alvo em relação à origem do referencial. Para isso é necessário estimar o tempo de diferença de chegada ou *time difference of arrival* (TDOA) do ruído a cada par de

hidrofonos. Existem dois métodos primários para determinar a DOA, a triangulação e a multilateração, que serão abordados mais adiante. Para determinar a distância, é necessário recorrer a relações trigonométricas, tendo em conta diferentes DOA.

Independentemente do tipo de sistema Sonar aplicado neste tipo de arquitetura, podemos afirmar que é um sistema de posicionamento que proporciona uma elevada exatidão na determinação da posição de um determinado alvo, independentemente da profundidade em que opera e da área que cobre. Contudo, para retirar os melhores resultados deste sistema é exigido um elevado grau de complexidade e, para reduzir as parcelas mais significativas do erro associado a determinação da posição do alvo, é necessário um rigoroso processo de calibração dos dispositivos (Oliveira, 2009, p. 6)




Figura 6 - Sistema de posicionamento LBL

### 3.3.2 *Short Baseline (SBL)*

Este tipo de arquitetura, ao contrário do posicionamento LBL, recorre ao auxílio de uma plataforma de apoio (normalmente um navio) para efetuar o cálculo da posição de um alvo. Na mesma são instalados transdutores de receção que normalmente distam entre si 20 a 50m. À semelhança do que ocorre com o sistema LBL, o alvo submerso, cuja posição se pretende determinar, poderá ser guarnecido com um emissor acústico. Desta forma, a sua posição será calculada com base no TDOA do sinal emitido dos diferentes recetores que se encontram na plataforma de apoio. Neste contexto, com a utilização de três ou mais recetores apenas é possível determinar a direção a que se encontra o alvo. Deste modo, para determinar a posição do alvo é necessário estimar a profundidade à qual o mesmo se encontra. Este método está associado a um menor grau

de exatidão devido à estimativa da profundidade. Apesar desta condição, possibilita uma maior taxa de atualização (Oliveira, 2009, p. 7).

Alternativamente a este processo, para determinar a distância a que o alvo se encontra, sem recorrer à estima da profundidade, é necessário utilizar um *transponder*, instalado no alvo submergido e, além dos hidrofones, um conjunto de projetores na plataforma de apoio. Com o dinamismo de interrogação/resposta tornar-se-á possível calcular a distância do alvo através do TOF do sinal entre os dispositivos, assumindo que se tem conhecimento da velocidade de propagação do som. Este é o método mais comum de utilização da arquitetura SBL.

Qualquer valor de distância e de direção do alvo é referente aos dispositivos instalados na plataforma de apoio. Desta forma, o sistema SBL requer o auxílio de ferramentas adicionais como a Unidade de Referência Vertical (VRU), giroscópio e um sistema de navegação de superfície (como o GPS), de modo a providenciar uma posição relativa a um sistema de referência terrestre.

Podemos verificar que o sistema SBL está associado a um menor grau de complexidade, relativamente ao sistema LBL, possuindo uma taxa de atualização aceitável e uma boa precisão ao utilizar o método baseado no TOF. No entanto, este sistema não é ideal para ser aplicado em zonas de grande profundidade ( $\geq 30\text{m}$ ), sendo necessário uma calibração complexa dos equipamentos. Além disto, a precisão na determinação da posição do alvo está dependente de sensores adicionais (VRU, GPS,...)




Figura 7 - Sistema de posicionamento SBL

### 3.3.3 *Ultra Short Baseline (USBL)*

A arquitetura do sistema de posicionamento USBL é baseado na arquitetura apresentado anteriormente, por isso podemos afirmar que mesmo é uma evolução do sistema SBL. O processo de posicionamento tem, na mesma, por base a emissão de um sinal por parte de um transdutor instalado no alvo submerso que será captado por, pelo menos, três hidrofones posicionados numa plataforma de apoio. Da mesma forma, o processo de interrogação/resposta com o *transponder* e os projetores também pode ser igualmente aplicado com esta arquitetura. A diferença entre o posicionamento por USBL e SBL prende-se ao facto dos dispositivos presentes na plataforma de apoio apresentarem um distanciamento na ordem dos centímetros. Deste modo, os recetores estarão todos sujeitos às mesmas influências do meio, o que resultará numa maior fiabilidade no sistema. Além disso a redução da distância entre os recetores torna o sistema mais versátil e fácil de montar (Oliveira, 2009, p. 7). No entanto, à semelhança do sistema SBL, um aumento da profundidade a que o alvo se encontra provoca um deterioramento na precisão da posição calculada.




Figura 8 - Sistema de posicionamento USBL

### 3.3.4 **Outras arquiteturas**

Tal como referido anteriormente, ~~de modo a efetuar~~ o posicionamento acústico de um alvo é efetuado recorrendo maioritariamente às três arquiteturas fundamentais apresentadas. Contudo as desvantagens e limitações de cada sistema têm levado ao aparecimento de novas arquiteturas, resultantes do aperfeiçoamento dos sistemas convencionais.

## ***GPS Intelligent Buoys (GIB)***

O sistema GIB consiste numa arquitetura formada por bóias de superfície equipadas com recetores DGPS e hidrofones submersos. É possível fazer um paralelismo com o sistema LBL convencional, apresentando-se como uma versão invertida do mesmo (os dispositivos encontram-se à superfície e não no fundo do mar). Contudo, o modo de funcionamento baseia-se nos mesmos princípios. Cada hidrofone recebe o sinal acústico emitido pelo transdutor instalado no alvo, registando o TOA. Posteriormente, os recetores DGPS comunicam com a estação central, situada na plataforma de apoio, que calculará a posição do alvo. Com este sistema é também possível determinar a profundidade a que se encontra o mesmo. Se o transdutor for codificado para enviar dois sinais sucessivos a cada ciclo de emissão, a diferença do TOA entre os dois será proporcional à profundidade do alvo (Alcocer, Oliveira, & Pascoal, 2018)




Figura 9 - Sistema de posicionamento GIB

## **Combinação de arquiteturas**

É possível recorrer à utilização simultânea de mais do que um tipo de sistema de posicionamento. Desta forma estes sistemas combinam os benefícios das arquiteturas fundamentais e providenciam uma maior fiabilidade e redundância na determinação da posição do alvo. No entanto, este método de posicionamento acaba por se tornar muito mais complexo do que os sistemas simples.

A combinação de sistemas providencia uma grande variedade de arquiteturas (Vickery, 1998, p. 6)

- Long and Ultra Short Baseline (L/USBL)
- Long and Short Baseline (L/SBL)

- Short and Ultra Short -Baseline (S/USBL)
- Long, Short, Ultra Short Baseline (L/S/USBL)




Figura 10 - Sistema de posicionamento L/S/USBL (Vickery, 1998, p. 6)

### 3.4 Localização de uma fonte acústica

Um dos objetivos do estudo efetuado nesta dissertação será aplicar um processo para determinar a localização de uma fonte emissora acústica relativamente a um ponto de referência determinado, fazendo o uso de um *array* de dois hidrofones. Assim, uma fonte acústica que se encontre na área de operações poderá ser localizada com o conhecimento dos TDOAs medidos pelo par de dispositivos.

As técnicas de localização passivas mais práticas são normalmente baseadas no cálculo do TDOA através de sistemas conceptualmente simples, além de serem razoavelmente eficazes em ambientes que apresentem um nível de reverberação moderada. Deste modo, o seu diminuto grau de complexidade computacional torna este tipo de técnicas bastante adequadas para implementações, em tempo real, de diversos sensores.

Tipicamente, os métodos de localização passivos baseados em TDOA são divididos em duas fases fundamentais (Tellakula, 2007, pp. 7-8)

1. A primeira fase será estimar o TDOA entre os diferentes recetores, normalmente encontrando o máximo de uma função *cross-correlation* ou correlação cruzada (CC). Estes valores poderão, posteriormente, ser convertidos em medições de

distância entre os sensores, resultando num hiperboloide que corresponderá aos locais de TDOA iguais.

2. A segunda fase será recorrer a algoritmos para estimar a posição da fonte emissora tendo por base a direção (DOA) obtida através do hiperboloide calculado

### 3.4.1 Estimativa do *Time Difference of Arrival* (TDOA)

Existem dois métodos para obter o TDOA dos diferentes sensores. O primeiro processo baseia-se na subtração das medições do tempo de chegada, ou *time of arrival* (TOA) dos dispositivos. Este método é aplicável se for possível medir os TOAs absolutos de cada recetor. No entanto, se estes valores forem disponibilizados, não existe nenhuma vantagem prática em convertê-los em valores de TDOA, pois a posição da fonte emissora poderá facilmente ser triangulada<sup>9</sup> utilizando diretamente os valores de TOA. Por outro lado poderá servir de redundância e aumentar a precisão do posicionamento, eliminando erros oriundos das possíveis reflexões do sinal (Ahmed, Wei, Memon, Du, & Xie, 2013, p. 166)

O segundo processo para estimar o TDOA é, como já referido anteriormente, através do uso de métodos baseados em funções de *cross-correlation*, em que o sinal recebido num dos sensores (o sensor de referência) é correlacionado com o sinal recebido noutra sensor. A correlação de sinais é muitas das vezes utilizada em operações de processamento de RADAR<sup>10</sup> e SONAR, comunicações digitais e outras áreas das ciências e engenharias.

Para efeitos de estudo e de procedimentos experimentais apenas será abordado nesta dissertação o segundo método apresentado.

#### **Método *Cross-Correlation* (CC)**

Já foi anteriormente referido que as funções CC são regularmente utilizadas para mensurar o TDOA, devido às suas capacidades de ocultar o ruído ambiente. Este processo consiste em determinar o atraso do sinal recebido num hidrofone relativamente ao sinal recebido noutra hidrofone. Isto resultará numa relação entre a similaridade das duas séries com o atraso de um relativamente ao outro. O pico máximo da função de correlação indica

---

<sup>9</sup> Apenas possível se for conhecido *a priori* o momento exato da transmissão do sinal acústico.

<sup>10</sup> *Radio Detection And Ranging*

o instante no tempo em que os sinais são mais semelhantes. É neste momento que teremos o valor mais correto do atraso entre sinais.

Seja  $s(t)$  um sinal transmitido pela fonte emissora, a uma longa distância. O modelo geral para representar atraso entre os sinais recebido nos dois sensores, isto é,  $x_1(t)$  e  $x_2(t)$  será dado por (Ahmed, Wei, Memon, Du, & Xie, 2013)

$$x_1(t) = A_1 s(t - \tau_1) + n_1(t) \quad (22)$$

$$x_2(t) = A_2 s(t - \tau_2) + n_2(t)$$

Onde  $A$  é a amplitude da atenuação, os valores representados por  $\tau$  correspondem ao tempo de atraso relativamente ao sinal original e as parcelas  $n$  correspondem ao ruído ambiental.

No entanto, é possível simplificar as equações. Assumindo que o ruído é Gaussiano e estacionário, e que  $\tau_1 > \tau_2$  podemos escrever que, para  $t = 0, 1, \dots, N - 1$ :

$$x_1(t) = s(t) + n_1(t) \quad (23)$$

$$x_2(t) = \alpha s(t - \tau) + n_2(t)$$

Em que  $\tau$  corresponde à diferença nos tempos de chegada nos recetores,  $\alpha$  é o coeficiente de atenuação do sinal que atinge o segundo recetor e  $N$  é o número de amostras de cada segmento do sinal recebido nos hidrofones. Num sentido prático, o objetivo de correlacionar os dois sinais será estimar o valor de  $D$ , num período finito de observações  $t$ , assumindo que o sinal  $s(t)$ ,  $n_1(t)$  e  $n_2(t)$  são processos estacionários e aleatórios. Desta forma podemos definir a função CC como:

$$R_{x_1 x_2}(\tau) = R_{ss}(t - \tau) + R_{n_1 n_2}(t) \quad (24)$$

Atualmente foram desenvolvidas várias técnicas baseadas neste processo, de forma a estimar o TDOA com inúmeros graus de precisão. Por isso, as técnicas de CC convencionais, introduzidas para resolver o problema de estima do TDOA, são referidas usualmente como métodos de correlação generalizados. Estes processos correlacionam versões filtradas dos sinais recebido nos hidrofones, o que irá fazer sobressair frequências

para as quais o SNR é mínimo, atenuando a potência do ruído. A fórmula utilizada para o cálculo da correlação dos sinais num período discreto será:

$$R_{x_1x_2}(\tau) = \frac{1}{N} \sum_0^{N-1} x(\tau)x(n + \tau) \quad (25)$$

É possível efetuar este processo recorrendo à correlação das potências espectrais dos sinais, obtidas pela aplicação da transformada de Fourier (que será abordada no capítulo seguinte), por forma a melhorar a precisão da estima do TDOA.

### 3.4.2 Determinação da *Direction of Arrival* (DOA)

Após determinar o TDOA dos sinais recebidos nos diferentes recetores, torna-se possível calcular o DOA do sinal emitido pela fonte. A forma mais conhecida e usual para este feito é por meio da triangulação da fonte. No entanto, dado a metodologia estudada nesta dissertação, não será possível recorrer a este método. A utilização de dois hidrofones não nos permite saber a posição precisa da fonte, pois da triangulação resultarão duas posições distintas das quais não se pode concluir a correta.

Pode-se considerar que as posições possíveis da fonte acústica, dado um TDOA, formam um hiperboloide que nos dará o valor da direção da fonte emissora, tal como ilustrado na Figura 6. Deste modo, é abordado um método que recorre a uma solução trigonométrica por forma a determinar a direção a que se encontra o emissor.




Figura 11 - Diagrama ilustrando o método por hiperboloides

Para este modelo, é considerada uma perspectiva *far field*, isto é, assume-se que a distância da fonte emissora ao *array* é consideravelmente superior à distância entre os dois hidrofones. Assim, os sinais acústicos emitidos apresentam-se como frentes de onda planas, tal como ilustrado na Figura 12.

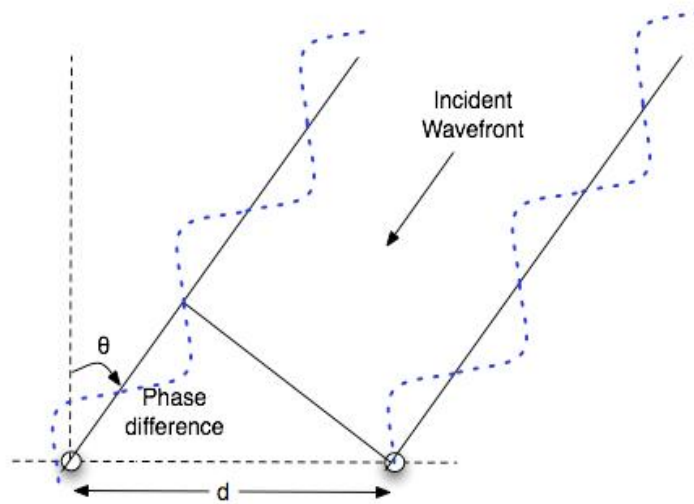


Figura 12 - Emissão de um sinal para o array de hidrofones

Considerando que existe uma diferença temporal de chegada do sinal aos diferentes hidrofones, é possível constatar que, associado a este valor, existem também uma diferença de fase de chegada do sinal. Esta diferença pode ser traduzida num valor superior de distância,  $d_s$ , que o sinal tem de percorrer para atingir o segundo hidrofone (hidrofone da esquerda na Figura 12). Desta forma tem-se que:

$$d_s = \tau \cdot c \quad (26)$$

Sendo  $\tau$  a TDOA, previamente calculada e  $c$  a velocidade do som na água.

Após determinar o valor de  $d_s$ , torna-se possível determinar o ângulo  $\phi$ , adjacente ao segundo hidrofone. Para tal é necessário recorrer à regra dos cossenos:

$$\cos\phi = \frac{d_s}{d} \quad (27)$$

Assim a determinação da DOA do sinal acústico emitido é conseguida através do ângulo  $\phi$ :

$$\theta = 90 - \phi \quad (28)$$

O ângulo  $\theta$  é igualmente válido para o centro do *array*, correspondente à posição  $\frac{d}{2}$ , que é utilizado como ponto de referência para o posicionamento direcional de fontes acústicas.

## CAPÍTULO 4 – Processamento de Sinal

### 4.1 Teorema da Amostragem

A amostragem (instantânea) de um sinal ou forma de onda analógica é o processo pelo qual o sinal passa a ser representado por um conjunto discreto de números. Estes números, ou amostras, são iguais ao valor do sinal em instantes bem determinados (os instantes de amostragem). As amostras devem ser obtidas de maneira a que seja possível reconstituir o sinal com exatidão. Ou seja, a forma de onda original, definida em tempo “contínuo”, passa a ser representada em tempo “discreto” por amostras obtidas em instantes de amostragem espaçados convenientemente. O tempo que decorre entre cada instante corresponde ao Período de amostragem. Como seria de esperar, este valor é inversamente proporcional à frequência de amostragem sendo:

$$T_s = \frac{1}{f_s} \quad (29)$$

A frequência de amostragem corresponde à taxa uniforme segundo a qual o processo de amostragem de um sinal é realizado. Este valor denota a taxa a que os valores discretos do sinal são retirados.

O Teorema da amostragem de Shannon diz-nos que um determinado sinal, apenas pode ser reconstruído se a frequência de amostragem for superior ao dobro da frequência máxima do sinal do sinal estudado. Desta forma, podemos definir frequência de Nyquist como:

$$f_{Ny} = \frac{1}{2} f_s \quad (30)$$

Assim, vemos que um sinal contínuo com frequência  $f \leq f_{Ny}$  será preservado quando o sinal é amostrado a uma frequência constante de  $f_s \geq 2f_{Ny}$  (Burgess, 1998, p. 1066). Caso contrário ocorre um fenómeno denominado *aliasing*, isto é, se um sinal analógico possuir uma frequência máxima superior à frequência de Nyquist, as frequências do sinal digital correspondente sofrerão *aliasing*. Isto significa que o sinal resultante apresentará uma frequência diferente da do sinal original. Devido a este facto, o espectro do sinal digital poderá diferir do espectro do sinal analógico original. Por forma a contrariar este fenómeno, são geralmente implementados filtros anti-*aliasing* (AAF). Estes são,

tipicamente, filtros passa-baixo com uma baixa taxa de atenuação para frequências abaixo da frequência de Nyquist (Pope, 1998, p. 1345)

## 4.2 Transformada de Fourier

Originalmente, a aplicação da Transformada de Fourier deve-se aos estudos de Jean Baptiste Joseph Fourier que, no século XIX, utilizou técnicas de decomposição sinusoidal para resolver problemas de transferência de calor. Desde então, a sua técnica tem tido um vasto uso nas áreas da ciência e da engenharia (Lobo, 2002). A Transformada de Fourier apresenta-se como uma função complexa, com partes imaginárias e reais, e é correspondente à expressão do sinal original no domínio da frequência. A representação do sinal neste domínio é designada por Espectro do sinal.

Por definição temos a Transformada de Fourier  $X(\omega)$  de um sinal  $x(t)$  como:

$$X(\omega) = \mathcal{F}[x(t)] = \int_{-\infty}^{\infty} x(t)e^{-i\omega t} dt \quad (31)$$

Considera-se que  $\omega = \frac{2\pi}{T}$  corresponde à frequência angular. Fazendo uso da identidade de Euler, pode-se verificar que a parte sinusoidal do sinal é tida por  $e^{-i\omega t} = \cos(\omega t) - i\sin(\omega t)$ . A componente  $i$  corresponde à parte imaginária da função e equivale a  $\sqrt{-1}$ . É possível calcular a Transformada de Fourier inversa, expressando o sinal novamente como uma função no domínio do tempo:

$$x(t) = X(\omega)^{-1} = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega)e^{i\omega t} d\omega \quad (32)$$

Para sinais em que apenas se conhece  $N$  instantes equidistantes no tempo, isto é, um conjunto finito de dados, tal apresentado na Figura 13, utilizamos a *Discrete Fourier Transform* (DFT), equivalente à Transformada de Fourier em sinais contínuos.

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-i2\pi nk/N} \quad (33)$$

Em que  $X(k)$  corresponde ao valor da DFT, sendo  $k$  um valor entre 0 e  $N - 1$ . Como  $X(k)$  é uma função periódica, com período de  $2\pi$ , a frequência angular  $\omega$  apresentará valores entre 0 e  $2\pi$ .  $x(n)$  é a função original para valores de  $n$  entre 0 e  $N - 1$ .  $N$  é o número de amostras da sequência de entrada e o número de pontos no domínio da frequência da DFT de saída (Santos, 2015).




Figura 13- Amostragem no domínio da frequência da Transformada de Fourier (Manolakis & Proakis, 1996, p. 395)

No entanto, a computação da DFT torna-se pouco viável devido ao elevado número de amostras associadas ao seu cálculo. Assim, a *Fast Fourier Transform* (FFT) é um algoritmo computacional mais eficiente utilizado para calcular a DFT. O tempo de computação requerido para uma FFT de  $N$  Pontos é aproximadamente  $N \log_2 N$ , enquanto que, para a computação direta de uma DFT, é aproximadamente  $N^2$ .

### 4.3 Densidade Espectral da Potência

A potência espectral de uma série temporal  $x(t)$  descreve a distribuição da potência em componentes da frequência desse sinal. Tendo em conta a análise de Fourier qualquer sinal físico pode ser decomposto num número discreto de frequências. Quando a energia de um sinal se encontra concentrada num intervalo de tempo finito é calculada a Densidade Espectral de Potência.

A função Densidade Espectral de Potência permite-nos demonstrar a intensidade das variações de energia de um sinal como uma função da frequência, ou seja, atribui unidades de potência a cada unidade de frequência. Assumindo que qualquer sinal inserido no domínio do tempo, de energia finita, pode ser decomposto unicamente na soma de uma infinidade de sinais sinusoidais elementares, trata-se da representação, da potência por Hz em relação à frequência (Santos, 2015, p. 17)

Consideremos que  $y(n)$  ( $n = 0, \pm 1, \pm 2, \dots$ ) denota uma sequência determinística e discreta no tempo, obtida através da amostragem de um sinal contínuo  $y_a(t)$  a uma frequência de amostragem  $\omega$ . Assim, obtemos uma estimativa do espectro real do sinal a partir de uma sequência  $y(n)$  finita. Desta forma, podemos assumir que  $y_a(t)$  é uma sinal de energia finita, o que significa que:

$$E = \sum_{t=-\infty}^{\infty} |y_a(t)|^2 < \infty \quad (34)$$

Assim, conclui-se que  $y_a(t)$  possui uma DFT definida por:

$$Y_a(\omega) = \sum_{t=-\infty}^{\infty} y_a(t)e^{-i\omega t} \quad (35)$$

Sendo a sua inversa:

$$y(t) = \frac{1}{2\pi} \int_{-\pi}^{\pi} Y_a(\omega)e^{i\omega t} d\omega \quad (36)$$

Através do teorema de Parseval temos que:

$$E = \sum_{t=-\infty}^{\infty} |y_a(t)|^2 = \frac{1}{2\pi} \int_{-\pi}^{\pi} |Y_a(\omega)|^2 d\omega \quad (37)$$

Aqui  $|Y_a(\omega)|^2$  representa a distribuição da energia do sinal como uma função da frequência, sendo assim considerada a Densidade Espectral da Potência (Manolakis & Proakis, 1996, p. 897)

#### 4.4 Periodograma

O Periodograma é utilizado para efetuar uma estima da Densidade de Potência Espectral, para um número discreto de instâncias, sendo este definido da seguinte forma (Moses & Stoica, 2004, p. 22)

$$P(\omega) = \frac{1}{N} \left| \sum_{t=1}^N y_a(t)e^{-i\omega t} \right|^2 = \frac{1}{N} |Y_a(\omega)|^2 \quad (38)$$

Sendo  $N$  o número de amostras e  $Y_a(\omega)$  correspondente à DFT do sinal  $y_a$ .

Contudo, este método não é totalmente eficaz na estima da Densidade de Potência Espectral. Esta constatação deve-se ao facto da variância da frequência não diminuir significativamente com o aumento de  $N$ . Com o aumento do número de pontos utilizados para a computação do Periodograma, observamos um aumento da resolução espectral. No entanto, a confiança na estima dada pelas amostras adicionais é deteriorada pela variância residual.

#### 4.4.1 Método de Bartlett

O conceito básico por de trás deste método é reduzir grandes oscilações do Periodograma, subdividindo a amostra de  $N$  observções em  $K = \frac{N}{M}$  segmentos, sem *overlapping*, com  $M$  observações cada um.

Desta forma a computação do Peridograma para cada segmento  $P_s(\omega)$  é dada por:

$$P_s(\omega) = \frac{1}{M} \left| \sum_{n=0}^{M-1} x_i(n) e^{-i\omega n} \right|^2 \quad (i = 0, 1, \dots, K-1) \quad (39)$$

Por fim efetuamos a média dos Periodogramas para os  $K$  segmentos para obter a Estima da Potência do Espectro de Bartlett:

$$P_B(\omega) = \frac{1}{K} \sum_{i=0}^{K-1} P_s(\omega) \quad (40)$$

#### 4.4.2 Método de Welch

Este método é obtido através da modificação do método de Bartlett em dois aspetos. Primeiramente, Welch demonstrou que, em vez de apenas dividir a sequência de dados em segmentos mais pequenos, é mais vantajoso permitir o *overlap* de segmentos adjacentes até 50%. Desta forma, possuímos mais Periodogramas para realizar uma média e assim, reduzir eficazmente a variância para a Densidade Espectral da Potência estimada. A segunda alteração ao método de Bartlett é a aplicação de uma função janela (*window*) aos segmentos de dados antes do cálculo do Periodograma. O resultado disto será um Periodograma modificado (Manolakis & Proakis, 1996, p. 911)

$$P_{sw}(\omega) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n) w(n) e^{-i\omega n} \right|^2 \quad (i = 0, 1, \dots, L-1) \quad (41)$$

Em que  $U$  corresponde ao peso da função *window*  $w(n)$  (Moses & Stoica, 2004, p. 47)

A estima da Densidade Espectral da Potência de Welch será a média destes Periodogramas modificados:

$$P_W(\omega) = \frac{1}{L} \sum_{n=0}^{K-1} P_{sw}(\omega) \quad (42)$$

#### 4.5 Leakage e Windowing

Quando extraímos uma porção de um sinal e aplicamos a DFT (ou a FFT), estamos a assumir que esse segmento se repete para além do intervalo amostral que estamos a estudar. Desta forma, a equação da DFT assume que o segmento retirado é contínuo e periódico (conceptualmente, existe uma justaposição dos segmentos repetidos). Este mecanismo é equivalente a multiplicar o sinal, que se repete infinitamente, a uma função  $w(n)$  sendo que (Burgess, 1998):

$$w(n) = \begin{cases} 1, & 0 \leq n < N - 1 \\ 0, & \text{qualquer outro valor de } n \end{cases} \quad (43)$$

Sendo  $N$  o comprimento finito dos segmentos e  $b(n)$  uma função *window*. Por isso, podemos denominar este processo como *windowing*. A função descrita a acima é normalmente conhecida como *retangular window*. Quando aplicada a um sinal periódico no espaço amostral, o resultado será um espectro semelhante ao original. No entanto, tal fenómeno não se verifica quando aplicado a sinusoides não periódicos, ou seja, caso o período amostral não corresponda a um número inteiro. Deste modo, a descontinuidade existente no espectro resultante da computação da DFT, irá resultar no aparecimento de componentes da frequência que não estavam presentes no sinal original. Por outras palavras, as descontinuidades entre os segmentos do sinal causarão um espalhamento de energia. Este fenómeno é conhecido como *leakage*, ou *spectral leakage*.

Para minimizar este efeito é possível aplicar outro tipo de *windows* à computação da DFT. Por conseguinte, as funções *window* podem ser utilizadas para melhorar as estimativas espectrais calculadas pela DFT (Pope, 1998). A aplicação das mesmas reduzirá a amplitude das descontinuidades nos limites de cada segmento finito. Assim, cada segmento terá uma variação mais suave e gradual, a tender para zero, nas suas extremidades. Idealmente, isto faria com que as mesmas coincidissem com o segmento adjacente, não havendo descontinuidades.

Existem várias funções *window* e a aplicação de cada uma depende do tipo de sinal que se pretende analisar. De um modo geral, a função de *Hanning* (*Hann*) é tida como a mais satisfatória para casos em que a natureza do sinal é desconhecida sendo descrita por (Moses & Stoica, 2004):

$$w(n) = \begin{cases} 0.5 + 0.5\cos\left(\frac{\pi n}{N}\right), & 0 \leq n < N - 1 \\ 0, & \text{qualquer outro valor de } n \end{cases} \quad (44)$$



## CAPÍTULO 5 – Identificação de Sinais Acústicos

### 5.1 *Data mining*

O *Data mining*, também conhecido como *Knowledge Discovery in Database* (KDD), pode ser definido como a extração de informação implícita, previamente desconhecida e potencialmente útil de dados que se inserem em *databases* (Osmar, 1999, p. 3), isto é, o processo de extrair padrões e conhecimento de um conjunto de dados. De um modo geral o *Data mining* pode ser aplicado a qualquer tipo de dados, desde que os mesmos sejam pertinentes para a aplicação desejada (Han, Kamber, & Pei, 2012, p. 10). No entanto, normalmente os dados utilizados em aplicação do *Data mining* provêm de *data warehouses* e *databases e transacional data*.

- *Databases*: correspondem a um conjunto de dados, relacionados entre si, e ao *software* utilizados para o acesso e processamento de dados (Han, Kamber, & Pei, 2012, p. 9)
- *Data warehouses*: são estruturas e repositórios que integram dados provenientes de múltiplas fontes (*databases*) (Miller & Han, 2000). Estes são armazenados num esquema único, o que permite que sejam processados segundo as mesmas condições.
- *Transacional data*: são dados obtidos através de transações (Santos, 2015, p. 30), cada uma com um indicador temporal, identificador e um conjunto de itens (Osmar, 1999, p. 5).

De modo a converter dados em conhecimento, o processo iterativo de *data mining*, engloba várias fases (Fayyad, Piatetsky-Shapiro, & Smyth, 1996, p. 42):

- O primeiro passo deste processo é compreender em que contexto se enquadra o domínio da aplicação e identificar o conhecimento *a priori* necessário e o objetivo principal do processo.
- Seguidamente, seleciona-se o conjunto de dados alvo de onde se irá retirar conhecimento.

- Em terceiro lugar, é necessário efetuar o pré-processamento dos dados ou *data cleaning*. É nesta fase que se efetuam operações básicas de remoção de ruídos<sup>11</sup>.
- O quarto passo destina-se a reduzir a dimensão do conjunto de dados. Isto é conseguido através da seleção de características que representem os dados, dependendo do objetivo do processo. Seleciona-se ainda um método de *data mining* adequado para a análise e procura de padrões.
- O quinto passo destina-se a interpretar os padrões de interesse resultantes do passo anterior.
- Por fim, são tomadas ações perante o conhecimento descoberto: a informação resultante é implementada noutros sistemas ou é documentada.

Sendo um processo iterativo é possível que existam ciclos entre duas fases adjacentes.

Existem diversos fins para os quais é utilizado o *data mining*. Destes destacam-se a descrição, estima, predição, classificação, *clustering* e associação (Larose, 2005, pp. 11-17). Tendo em conta o problema explorado nesta dissertação, apenas se irá recorrer à classificação de dados. Para este caso, é utilizada uma função que classifica dados numa das várias classes pré-definidas.

## **5.2 Machine Learning**

O *Machine Learning* é uma área das ciências computacionais, enquadrada no *Data Mining*, que confere aos sistemas de inteligência artificial a capacidade de aprendizagem sem que sejam explicitamente programados para tal (Samuel, 1959). Esta aprendizagem é efetuada através da criação de algoritmos indutivos que, com base em  $n$  amostras de um *data set*, identificam padrões e efetuam previsões. Cada algoritmo possui um objetivo, variando consoante a informação disponível, as estratégias de aprendizagem e a representação dos dados.

Uma das formas mais comuns, e fundamentais, de abordar problemas de categorização (ou classificação) é recorrendo ao *Machine Learning* indutivo: processo que gera de forma automática um classificador através da aprendizagem. Desta forma, é

---

<sup>11</sup> Neste contexto ruído é referente a dados que não podem ser percebidos e interpretados por programas. Isto deve-se, normalmente, a erros de medição de dados ou o conjunto de dados é demasiado complexo para ser modelado.

possível estimar uma dependência input-output desconhecida previamente, usando um número limitado de observações (Kantardzic, 2011, p. 89)

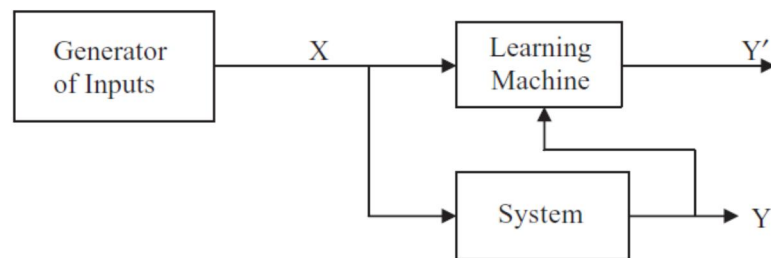


Figura 14 - Processo de *Machine Learning* que usa as observações de um sistema para gerar aproximações do output  $Y'$  (Kantardzic, 2011, p. 89)

A partir deste conceito, podemos concluir que a qualidade e quantidade dos dados utilizados para elaborar algoritmos afetarão diretamente o desempenho de algoritmos na aprendizagem e na previsão.

### 5.2.1 Categorização do *Machine Learning*

Tendo em conta o tipo de problema apresentado e o conjunto de dados correspondentes, podemos dividir o *machine learning* em três categorias distintas: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço. Podemos ainda associar estas categorias a problemas específicos de cada uma.

A aprendizagem supervisionada, em que indicamos ao algoritmo o que deve prever, está associada a problemas de regressão e classificação. Os problemas de regressão consistem na previsão de um valor numérico. O exemplo mais comum deste tipo de problemas é encontrar a reta mais adequada para dividir os dados e efetuar uma generalização dos mesmos. Nos problemas de classificação, o objetivo é efetuar uma previsão da classe na qual uma determinada instância de dados se enquadra.

Em oposição à aprendizagem supervisionada encontra-se a categoria da aprendizagem não supervisionada. Neste conjunto de tarefas, não existem valores objetivo para os dados a tratar. Os problemas tipicamente associados à aprendizagem não supervisionada são o *clustering* e a estima da densidade. Quando pretendemos associar um conjunto de instâncias semelhantes num grupo trata-se de um problema de *clustering*.

Por outro lado, quando pretendemos encontrar valores estatísticos que estejam associados a dados, trata-se de estima da densidade (Harrington, 2012)

Um dos objetivos desta dissertação é estudar a identificação de sinais acústicos em ambiente subaquático. Desta forma, será utilizada a aprendizagem supervisionada de modo a classificar os sinais recebidos pelo *array* de hidrofones e, por esta razão, será a única categoria a ser abordada em pormenor.

## 5.3 Aprendizagem Supervisionada

### 5.3.1 Classificação Vizinho mais Próximo (K-Vizinhos)

O classificador Vizinho mais Próximo tem sido vastamente utilizado na área do reconhecimento de padrões, tendo ganho popularidade a partir dos anos 60 com o aumento do poder computacional que permitiria o processamento de grandes conjuntos de dados (Han, Kamber, & Pei, 2012, p. 423)

Este tipo de classificação é efetuado com base na aprendizagem por analogia, isto é, comparando um conjunto de atributos com conjuntos de treino, que apresentem semelhanças entre si. Deste modo, a classificação Vizinho mais Próximo é adequada para situações em que as relações entre características e as classes em estudo são numerosas e complexas, apesar de serem homogéneas entre instâncias semelhantes (Lantz, 2015, p. 66).

A classificação por este método é tipicamente concretizada através do algoritmo K-Vizinhos (K-NN). Este obtém esta designação pelo facto de utilizar informação acerca dos  $k$ -Vizinhos mais próximos para classificar instâncias. A letra  $k$  é uma variável que traduz o número de vizinhos mais próximos a considerar. Posteriormente à seleção de um  $k$  adequado, este algoritmo requer um conjunto composto por exemplos previamente classificados para estabelecer um conjunto de treino. Deste modo, por cada instância que se pretenda classificar, o algoritmo K-NN identifica os  $k$  conjuntos de treino que se encontrem mais “perto”, em termos de similaridades. Assim o conjunto a classificar será enquadrado na classe associada à maioria dos  $k$  vizinhos mais próximos (Lantz, 2015, p. 67) Podemos então considerar que a classificação baseada em algoritmos K-NN é *lazy*. Esta designação deve-se ao facto da aprendizagem ser feita com base no armazenamento e comparação de instâncias.

De modo a determinar a “proximidade” de características entre conjunto de teste e o conjunto de treino é necessário utilizar uma função de distância  $d(x, y)$  para o efeito. Esta função possui as seguintes propriedades (Larose, 2005, p. 99)

1.  $d(x, y) \geq 0$  e  $d(x, y) = 0$  apenas se  $x = y$
  2.  $d(x, y) = d(y, x)$
  3.  $d(x, z) \leq d(x, y) + d(y, z)$
- (45)

Tipicamente, esta “proximidade” de conjuntos corresponde à distância Euclidiana dos mesmos. Deste modo, a distância entre os conjuntos  $X_1 = (x_{11}, x_{12}, \dots, x_{1n})$  e  $X_2 = (x_{21}, x_{22}, \dots, x_{2n})$  é definida por (Han, Kamber, & Pei, 2012, p. 423)

$$dist(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2}$$
(46)

É importante notar que certos atributos possuem uma maior magnitude de valores comparativamente a outros. Isto fará com que a medição da distância seja fortemente dominada pelos atributos com maior magnitude. A solução para este problema será normalizar os atributos de modo a que todos os valores pertençam ao intervalo  $[0,1]$ . Para tal é utilizado o processo de normalização max-min. Este consiste na subtração do valor mínimo do atributo  $X$  a cada valor, sendo este posteriormente dividido pela amplitude de valores de  $X$ . Este processo é descrito pela Equação 47 (Lantz, 2015, p. 73)

$$X_{norm} = \frac{X - \min(X)}{\max(X) - \min(X)}$$
(47)

A escolha de um  $k$  para o algoritmo K-NN pode ser efetuada por iterações, através de um conjunto de teste. Utilizando inicialmente  $k = 1$ , podemos estimar o erro associado ao classificador para este valor. O processo é repetido sucessivamente, incrementando uma unidade ao valor de  $k$  por forma a considerar mais um vizinho do que no teste anterior. O valor de  $k$  que apresentar menor taxa de erro será o mais adequado para a classificador (Han, Kamber, & Pei, 2012, p. 424).

Por outro lado, o parâmetro  $k$  poderá ser selecionado com base na experiência ou conhecimento acerca problema de classificação em questão. Tipicamente deve ser escolhido um valor ímpar para  $k$ , de modo a não existir um número igual de vizinhos de classes diferentes, o que causaria inúmeras indecisões na classificação. O valor de  $k$  escolhido para o classificador deve ser grande o suficiente para que ruído indesejado não

afete em demasia a classificação e pequeno o suficiente para que uma classe não domine outra.

Na Figura 19 podemos observar um exemplo do classificador K-Vizinhos. Neste exemplo existem 3 classes ( $\omega_1$ ,  $\omega_2$  e  $\omega_3$ ) que representam um conjunto de treino. O objetivo será enquadrar a instância de teste  $x_u$  numa das classes. Para tal é utilizado um  $k = 5$  e uma função de distância Euclidiana.




Figura 15 - Classificador K-Vizinhos para  $k = 5$  (Kantardzic, 2011, p. 120)

Em suma, o algoritmo K-NN pode ser dividido nas seguintes fases:

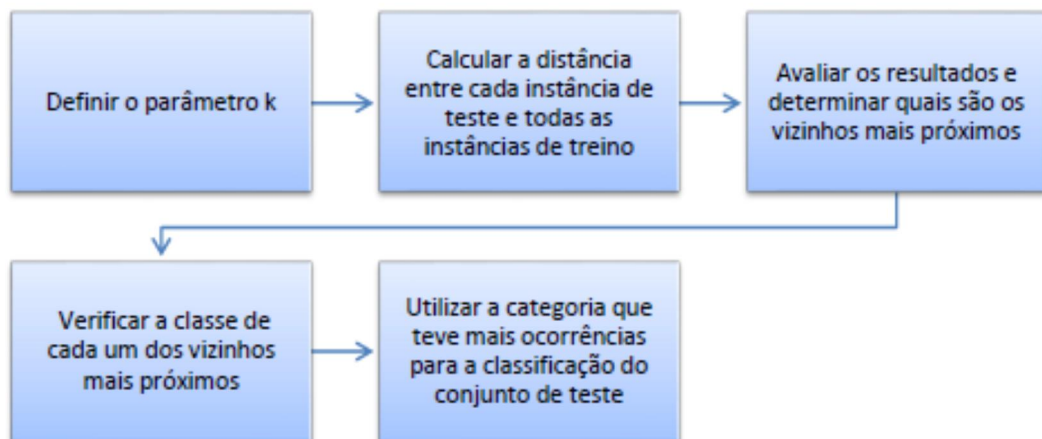


Figura 16 - Fases do algoritmo K-NN (Santos, 2015)

### 5.3.2 *Support Vector Machine (SVM)*

O método de classificação com recurso a SVMs consiste na obtenção de uma fronteira classificativa que permita a separação de conjuntos de dados distintos. As SVMs lidam primariamente com problemas de dados linearmente separáveis, podendo estas ser

reformuladas para definir fronteiras sobre conjuntos de dados mais gerais (Carvalho & Lorena, 2007, p. 53). Assim, a partir de SVMs lineares, é possível definir fronteiras não lineares aplicáveis a diversos grupos de dados. De modo a efetuar a separação de dados lineares ou não lineares, pertencentes à mesma classe, as SVMs recorrem a fronteiras designadas hiperplanos.

### **Dados Lineares: SVM com margens rígidas**

Em problemas que envolvem dados linearmente separáveis, isto é, que podem ser separados graficamente por figuras retilíneas, a escolha de um hiperplano ideal é crucial para a otimização do classificador. Considere-se um cenário em que é necessário separar duas classes  $C_1$  e  $C_2$  de um conjunto  $D = \{x_i, y_i\}$  de dados de treino num espaço bidimensional. Neste contexto, podemos utilizar as classificações  $y_i = -1$  e  $y_i = 1$  para cada classe respetivamente. O hiperplano que separa estas classes pode ser definido como:

$$w \cdot x + b = 0 \quad (48)$$

Sendo  $w \cdot x$  o produto escalar entre os vetores  $x$  e  $w$ , correspondendo, respetivamente ao conjunto de dados e ao vetor normal ao hiperplano. Desta forma, a separação das classes pode ser baseada em condições referentes a esta equação. Assim tem-se que:

$$\begin{aligned} w \cdot x + b &\geq 1 \quad \text{para } Classe_1 = 1 \\ w \cdot x + b &\leq -1 \quad \text{para } Classe_2 = -1 \end{aligned} \quad (49)$$

Estas condições podem ser expressas numa única equação:

$$y_i(w \cdot x + b) \geq 1 \quad (50)$$

No entanto, para obtermos o melhor classificador possível não basta apenas que as amostras do conjunto  $D$  se encontrem no lado correto do hiperplano (Alpaydın, 2010, p. 311). Verifica-se assim que, para o mesmo conjunto de dados de treino, é possível encontrar diversas soluções, tal como ilustrado na Figura 16.




Figura 17 - Três hiperplanos a, b e c, como possíveis soluções para um problema bidimensional.  
(Lantz, 2015, p. 135)

Deste modo, é necessário que as instâncias se encontrem a uma determinada distância do hiperplano para que o classificador obtenha uma generalização mais eficaz. Então, a distância do hiperplano às instâncias mais próximas dos dois lados é definida como margem, ilustrada como variável  $d$  na Figura 18. De modo a obter a melhor generalização possível de um hiperplano é necessário maximizar o valor da margem. Esta é delimitada pelos hiperplanos  $H_1$  e  $H_2$  resultantes das condições descritas na Equação 49.




Figura 18 Ilustração de hiperplano num espaço bidimensional (Carvalho & Lorena, 2007, p. 53)

Tendo em conta a geometria de vetores, a distância  $d$  que separa os hiperplanos  $H_1$  e  $H_2$  pode ser definida por:

$$\frac{2}{\|w\|} \tag{51}$$

Em que  $\|w\|$  indica a norma Euclideana, isto é, a distância da origem ao vetor  $w$  (Lantz, 2015, p. 244). Por isso, para maximizar  $d$  é necessário minimizar o denominador da fração descrita acima. Assim, a minimização de  $\|w\|$  é expressa por:

$$\min \frac{1}{2} \|w\|^2 \quad (52)$$

Esta operação é sujeita à condição:

$$y_i(w \cdot x_i - b) \geq 1, \forall i \quad (53)$$

Deste modo, deparamo-nos com um problema de otimização de uma função quadrática, cuja resolução determinará diretamente os valores de  $w$  e  $b$ . Um dos métodos mais usuais para resolver este tipo de problemas é através de multiplicadores de Lagrange  $\alpha_i$ . Obtém-se assim uma nova formulação do problema:

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i [y_i(w \cdot x_i + b) - 1] \quad (54)$$

Esta formulação corresponde a um problema de otimização quadrático convexo devido ao seu termo principal convexo. Desta forma, fazendo uso das condições de Kuhn-Tucker, podemos resolver de forma equivalente o problema dual. O dual desta formulação consiste em maximizar  $L_p$  em ordem a  $\alpha_i$ , considerando que as derivadas em função de  $w$  e  $b$  têm o valor zero e que  $\alpha_i \geq 0$  (Alpaydin, 2010, p. 312). Isto significa que:

$$\begin{aligned} \frac{\partial L_p}{\partial w} = 0 &\Rightarrow w = \sum_i \alpha_i y_i x_i \\ \frac{\partial L_p}{\partial b} = 0 &\Rightarrow \sum_i \alpha_i y_i = 0 \end{aligned} \quad (55)$$

Tendo em conta estas equações, o dual é (Harrington, 2012, p. 105):

$$L_d = \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (56)$$

Sabendo que:

$$\begin{cases} \alpha_i \geq 0, \forall i = 1, \dots, N \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (57)$$

A Equação 56 pode ser resolvida por métodos de otimização quadráticos. Observa-se assim, que a dimensão do dual depende do número de dados, isto é, de  $N$  e não de  $d$ .

Denota-se também que apenas alguns dados possuem um valor de  $\alpha_i > 0$ . Este conjunto de  $x_i$  designam-se por *support vectors* (SVs) que satisfazem a condição:

$$y_i(w \cdot x_i + b) = 1 \quad (58)$$

Isto significa que os mesmos coincidem com os hiperplanos que delimitam a margem. Apenas os dados que correspondem a SVs são utilizados para o cálculo de  $w$ , tal como denota a Equação 58.

O valor  $b$  do hiperplano é obtido fazendo uso dos SVs (Alpaydin, 2010, p. 313):

$$b = y_i - w \cdot x_i \quad (59)$$

Neste caso, as restrições impostas não permitem a existência de dados de treino entre as duas margens. Por esta razão, a SVM computada por este método, obtém a designação de SVM de margens rígidas.

### Dados não Lineares: SVMs com margens suaves

Em situações reais, são raros os casos em que os problemas em questão envolvem dados linearmente separáveis. Por esta razão, torna-se necessário adaptar SVMs lineares para que possam lidar com conjuntos de treino mais gerais. A solução para esta situação prende-se na introdução de variáveis de folga  $\xi_i$ . Estas permitirão que certos dados possam permanecer do lado errado do hiperplano, tal como ilustrado na Figura 19. Os dados podem ainda encontrar-se do lado correto, mas não suficientemente afastados do hiperplano por forma a serem corretamente classificados.




Figura 19 – SVM com margens suaves em espaço bidimensional (Lantz, 2015, p. 245)

Assim, denota-se que as variáveis  $\xi_i$  representam erros “permitidos” no conjunto de treino dos dados. De modo a incluir estes erros, a Equação X que define os hiperplanos é reformulada como:

$$y_i(w \cdot x + b) \geq 1 - \xi_i \quad (60)$$

Verifica-se que, para valores de  $\xi_i \geq 1$ , os dados em questão encontram-se erroneamente classificados.

Associado a estas variáveis, um valor de custo (representado pela variável  $C$ ) é aplicado a todos os pontos que violem os constrangimentos impostos inicialmente. Como tal, o problema de otimização da Equação 61 é reescrito da seguinte forma (Lantz, 2015, p. 245)

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \left( \sum_{i=1}^n \xi_i \right) \quad (61)$$

Deste modo, tem-se como objetivo maximizar a margem de classificação e, simultaneamente, minimizar o erro permitido. Tendo em conta o problema de otimização associado às SVMs de margem rígida, podemos, da mesma forma, resolver este problema recorrendo a uma função de Lagrange (Equação 56). Contudo neste caso as restrições serão:

$$\begin{cases} 0 \leq \alpha_i \leq C, \quad \forall i = 1, \dots, n \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (62)$$

Tendo em conta estas restrições, denota-se que a introdução do parâmetro  $C$  terá uma grande influência no classificador.

### **Dados não Lineares: aplicação de Kernels**

Nos exemplos anteriormente descritos foi sempre assumido que os problemas em questão podiam ser resolvidos através de SVMs lineares. No entanto, para inúmeras aplicações as mesmas não são um método viável para classificar dados (mesmo atribuindo variáveis de folga). Deste modo, é necessário adaptar, mais uma vez, as SVMs para a resolução de problemas não lineares. Para este efeito, são utilizados as funções Kernel para dados não linearmente separáveis.

Antes da aplicação de uma função Kernel é necessário mapear o conjunto de treino do seu espaço original para um espaço de maiores dimensões. Isto vai fazer com que uma relação não linear entre dados se torne, aparentemente, linear (Figura 20). Para tal, é utilizada uma função  $\phi$  que irá mapear o espaço de dados não lineares. Isto significa que, a partir de um espaço bidimensional de atributos é criado um espaço tridimensional através da introdução de uma característica que expressa uma relação matemática entre as características inicialmente mensuradas. Para estes casos, define-se a função  $\phi$  como (Hofmann, 2006, p. 10):

$$\phi(x) = (x_1^2, \sqrt{2}x_1x_2, x_2^2)^T \quad (63)$$

Como se pode observar do lado direito da Figura 19, com a adição de um novo atributo, isto é, de uma nova dimensão aos dados de treino, as classes tornam-se linearmente separáveis.




Figura 20 - Mapeamento de dados de treino não lineares de  $\mathbb{R}^2$  para  $\mathbb{R}^3$  (Hofmann, 2006, p. 11)

Assim, posteriormente à mapeação dos dados inicialmente não lineares, é possível aplicar a SVM linear sobre o novo espaço de dados.

Devido à aplicação de  $\phi$ , é possível que o novo espaço de dados possua uma dimensão muito elevada (podendo mesmo ser infinita), o que levará a uma computação de dados extremamente complexa e inviável. Para contrariar esta limitação, apenas é necessário otimizar o cálculo de produtos escalares entre os dados no espaço de características (Carvalho & Lorena, 2007, p. 61). Esta operação é simplificada através da implementação de funções Kernel.

As funções Kernel aplicam as transformações de  $\phi$  a dois vetores  $x_i$  e  $x_j$  do espaço de entradas e calcula o seu produto escalar no espaço de características. Assim tem-se:

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (64)$$

A aplicação das funções Kernel ocorre de forma recorrente, dado que podem ser empregues sem que se conheça o mapeamento resultante da aplicação de  $\phi$ . Desta forma, foram desenvolvidas várias funções, para diferentes domínios de dados, representadas na Tabela 2

Tipo de Kernel	Função $K(x_i, x_j)$	Parâmetros
Polinomial	$(\delta(x_i \cdot x_j) + \kappa)^d$	$\delta, \kappa$ e $d$
Gaussiano	$\exp(-\sigma \ x_i - x_j\ ^2)$	$\sigma$
Sigmoidal	$\tanh(\delta(x_i \cdot x_j) + \kappa)$	$\delta$ e $\kappa$

Tabela 1 - Funções Kernel mais utilizadas

Não existe nenhum fator definitivo para associar uma função Kernel a uma tarefa de aprendizagem específica. O grau de satisfação do desempenho das mesmas depende do contexto do problema em questão e da quantidade de dados de treino associada. Normalmente, a escolha da função Kernel mais eficaz é efetuada através de tentativas e erros, sendo escolhida a que apresentar a melhor performance perante uma determinada situação (Lantz, 2015, p. 248)

### SVMs para problemas de múltiplas classes

As aplicações de SVMs exploradas anteriormente apenas se enquadram na resolução de problemas de classificação binários. Assim, para a classificação em problemas que envolvem mais do que uma dualidade de classes, podem ser utilizados dois métodos: *one-versus-one* (OVO) e o *one-versus-all* (OVA) (Chao, 2011, p. 50). Estes classificadores são baseados nas SVMs descritas anteriormente, variando no modo de emprego para possibilitar a classificação de  $n$  classes.

O classificador OVO desenvolve um total de  $n(n - 1)/2$  classificadores binários para cada par das  $n$  classes. Assim, para uma dada amostra, cada um dos classificadores prevê uma possível classe na qual se insere a mesma. A classe atribuída à amostra será aquela que obtiver mais “votos” entre os  $n(n - 1)/2$  classificadores (Chao, 2011, p. 50)

Por outro lado o classificador OVA constrói um classificador binário para uma classe (considerada positiva) contra todas as outras classes (consideradas negativas), criando assim um total de  $n$  classificadores binários, o que será computacionalmente menos complexo comparativamente ao OVO. Neste caso, a classe que apresentar uma

resposta positiva do classificador perante uma amostra, será considerada a classe prevista da mesma (Chao, 2011, p. 51)

### 5.3.3 Avaliação do Desempenho de Classificadores

De modo a determinar o classificador mais eficaz perante um conjunto de dados será necessário avaliar o desempenho de cada um destes. Este processo é efetuado através da comparação do índice de desempenho, determinado pelos métodos de avaliação, dos vários classificadores. Nesta dissertação serão abordados dois métodos de avaliação: o método *cross-validation*, ou validação cruzada e o método *holdout*.

- **Método Validação Cruzada**

O método de validação cruzada é normalmente aplicado a conjuntos de dados pequenos, ou seja, não é viável selecionar dados para serem utilizados apenas para teste. Deste forma este método permite estimar com eficácia o desempenho de um classificador, isto é, a taxa de erro, sem recorrer a um conjunto de dados de grandes dimensões.

Inicialmente, o conjunto de treino original é dividido em  $k$  partes iguais, ficando o mesmo definido como  $T = X_1, X_2, \dots, X_k$ . De seguida, retira-se uma das partes, combinando as restantes num conjunto de treino com  $k - 1$  elementos. É efetuado um teste com o conjunto obtido, registando-se a taxa de erro. Este processo é repetido  $k$  vezes, excluindo um elemento do conjunto original de cada vez. A taxa de erro total é estimada através da média aritmética das restantes taxas obtidas através deste processo. Assim, tem-se que (Santos, 2015, p. 45):

$$\overline{Erro} = \sum_{i=1}^k e_i \quad (65)$$

Este processo é eficaz visto que não recorre a amostras aleatórias repetidas retiradas do conjunto, o que poderia gerar o mesmo resultado várias vezes. Desta forma, é garantida a obtenção de uma estima fiável da taxa de erro.

- **Método Holdout**

O método *Holdout* recorre a dois conjuntos com funções distintas, provenientes da divisão do conjunto de dados original: o conjunto de treino e o conjunto de teste. O primeiro é utilizado para gerar um modelo de classificação. O segundo será aplicado aos modelos gerados, de onde se poderá retirar conclusões no que diz respeito ao desempenho

dos mesmos. Tipicamente, para o conjunto de treino, são selecionados entre 70% a 80% dos dados (Gupta, 2011). Esta percentagem poderá variar consoante a quantidade de dados e informação disponível.



## CAPÍTULO 6 – Procedimento Experimental e Processamento de Dados

### 6.1 Descrição do procedimento experimental

Nos dias 11, 12 e 13 de Julho de 2017, no âmbito do exercício “*Robotics Exercise 2017 (REX 17)*”, tendo como foco primário efetuar provas de mar e testar equipamentos da área da robótica, foram recolhidos dados referentes a ruído submarino correspondente a várias plataformas, fazendo uso de dois hidrofones: o SR-1 e o TP-1. Estas atividades foram realizadas no canal do Arsenal do Alfeite, em que os hidrofones foram colocados nas posições 38° 39' 56" N, 9° 8' 18" W e 38° 39' 53" N, 9° 8' 24"W, respetivamente. Atendendo ao facto que os hidrofones teriam de permanecer sempre submersos e com o melhor rigor de posicionamento possível, era necessário contrariar o obstáculo de deriva de posicionamento dos hidrofones e das respetivas boias de amarração por efeito das correntes/maré. Assim, os hidrofones foram montados num cabo amarrado a poitas no fundo e a uma boia que ficasse sempre submersa a fim de assegurar a verticalidade da amarração e salvaguardar a estabilidade no posicionamento espacial dos hidrofones. Dessa boia submersa, corre depois um cabo que vai amarrar a uma outra boia, de superfície, que permitisse depois a fácil localização do dispositivo aquando da recolha do sistema e o cabo de ligação á boia de superfície com comprimento suficiente que permita, a esta boia, acompanhar a variação de nível do mar pelo efeito de marés e corrente. Para salvaguardar que a boia submersa se manteria sempre abaixo da superfície, mesmo na maré baixa, o comprimento de cabo para que esta boia submersa ficasse sempre abaixo da cota do Zero hidrográfico (ZH). Sendo que a profundidade do ZH para o local previsto de lançamento do Hidrofone SR-1 seria próximo dos 2 metros, este sensor terá ficado a uma altura do fundo, ligeiramente inferior aos 2 metros. O TP-1 terá ficado abaixo dos 3 metros.

Na seguinte fase, os ficheiros de som são gravados continuamente pelos hidrofones, desde que são ligados, até serem recolhidos. Os mesmos são divididos num conjunto de registos sucessivos com a duração de 5 minutos cada um. Os ficheiros de som correspondem às plataformas que, nos dias 12 e 13 de Julho, efetuaram várias fiadas nas a várias distâncias do *array* de hidrofones. É necessário ter em conta a realização simultânea de outros projetos, pelo que os ficheiros poderão apresentar ruído indesejados provenientes dos mesmos.

## 6.2 Tratamento de dados

Após a recolha dos dados é necessário pré-processar os mesmos, por forma a possibilitar a aplicação dos métodos abordados anteriormente. Para este efeito, foram criados vários *scripts* através do *MATrix LABoratory* (MATLAB), uma linguagem de alto desempenho utilizada para computação técnica, sendo uma excelente ferramenta para aprendizagem e investigação (Houcque, 2005, p. 1).

O pré-processamento de dados é uma etapa importante para o tratamento deste tipo de sinais, pois as amostras recolhidas possuem grandes dimensões. Com a existência de um elevado número de atributos, torna-se computacionalmente exigente para os algoritmos processarem e armazenarem os dados. Por esta razão, as gravações sucessivas de 5 minutos, foram divididas em blocos de 1s.

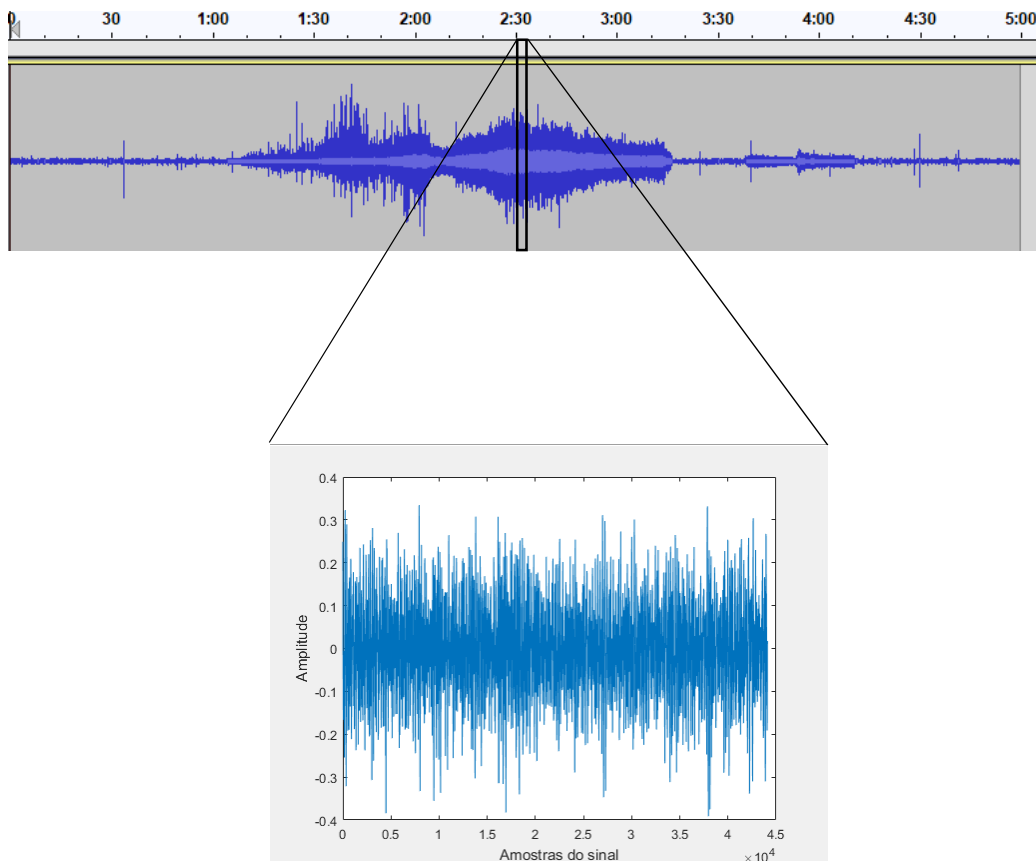


Figura 21- Esquema ilustrativo da segmentação de um sinal em blocos de 1s

No entanto, cada um destes blocos ainda possui ruído indesejado, que poderá comprometer os resultados da aplicação de algoritmos. Deste modo, os blocos de 1s foram, por sua vez, divididos em 8 segmentos, calculando-se a média das estimas da

potência espectral, fazendo uso da FFT (com uma *window* de Hamming) com um *overlap* de 50% (método de Welch). Deste método, de cada bloco de 1s, resulta um conjunto de 1024 atributos, correspondente às primeiras 1024 frequências do espectro<sup>12</sup>, tal como demonstrado da Figura 22. De forma a ser possível comparar os espectros resultantes, é necessário ainda normalizar os mesmos




Figura 22- Potência espectral da Lancha Mindelo proveniente de sinais recebidos pelo SR1 e TP1

Assim cada atributo corresponderá a um valor do espectro de frequências apresentado. É deste modo que os algoritmos de *machine learning* conseguirão comparar densidades espectrais (atributos) dos sinais processados e, posteriormente, associar cada um a uma plataforma.

Paralelamente, foi criado, em MATLAB, um *script* que calcula o azimute da fonte acústica, em relação ao centro do *array*, baseado no *TDOA* de sinais entre os dois hidrofones. Para este efeito, utilizou-se uma parte das gravações de uma das fiadas realizadas pela lancha Mindelo (neste caso, a segunda fiada a altas *RPMs*). A mesma tem a duração de 20 segundos, sendo posteriormente dividida em secções de 1s. Cada secção corresponderá a um azimute da lancha em relação ao *array*. Estes sinais, possuem uma frequência de amostragem de 44100 *Hz*.

Para calcular o *TDOA* dos sinais recebidos nos hidrofones, foi aplicada uma função de correlação cruzada, tendo resultado num gráfico semelhante ao ilustrado na Figura 23. Após a obtenção deste valor (valor máximo da correlação) procedeu-se, através de uma

---

<sup>12</sup> Este espectro contém as frequências mais significativos de sinais com origem antropogénica (Santos, 2015, p. 49)

solução trigonométrica, à estima da DOA dos sinais, relativamente a um ponto médio do *array*.




Figura 23 - Resultado da aplicação de uma função de correlação cruzada entre dois sinais

## CAPÍTULO 7 – Testes e Resultados

Após a definição e utilização de um método para efetuar o pré-processamento dos sinais recolhidos pelo hidrofone SR-1, é necessário classificar os mesmos, para, posteriormente, determinar a posição da fonte emissora de um grupo de sinais. Assim, foi utilizado o MATLAB para determinar se é possível efetuar um reconhecimento eficaz de sinais, recorrendo a dois classificadores diferentes, e o consequente posicionamento dos mesmos.

### 7.1 Teste da Identificação de sinais

De modo a testar a identificação de sinais provenientes de diferentes plataformas, introduziu-se no MATLAB um conjunto de dados, previamente processados, para serem utilizados como conjunto de teste, com o objetivo de treinar classificadores. Este conjunto possui um total de 276 instâncias, correspondendo a 74 instâncias associadas à Lancha Mindelo a navegar com a máquina a altas rotações por minuto (RPM), 74 instâncias associadas à mesma plataforma a navegar com a máquina a baixas RPM, 74 instâncias correspondentes a ruído ambiente e as restantes 74 associadas ao bote pneumático Zebro. De seguida, foi adicionado um outro conjunto de dados, correspondente à Lancha Mindelo a navegar com altas RPM, como conjunto de teste.

Para efetuar a validação do conjunto de treino, foi utilizado o método *Holdout*, com 80% do conjunto para treino, e o método Validação Cruzada com 10 partições nos classificadores K-NN e SVM.

#### 7.1.1 Teste com o método Validação Cruzada

O primeiro teste dos classificadores foi efetuado recorrendo ao método Validação Cruzada. Para este caso foram utilizadas 10 partições do conjunto de treino para teste.

- K-NN

Para o classificador K-NN, foram obtidos os melhores resultados com  $k = 2$ : e  $k = 4$

<b>k = 2 e k = 4</b>	Instâncias classificadas = 296
	Taxa de classificação com sucesso = 95,6%
	Taxa de classificação com insucesso = 4,4%

Tabela 2 - Resultados do treino do classificador K-NN, com k=2, utilizando o método Validação Cruzada

Pode-se verificar que, através deste classificador, foram obtidas taxas de sucesso extremamente elevadas.

As matrizes de confusão associadas a estes modelos Figura 24, possibilitam a discriminação de instâncias incorretamente classificadas.




Figura 24 – Matriz de confusão do classificador K-NN com k = 2 pelo método Validação cruzada

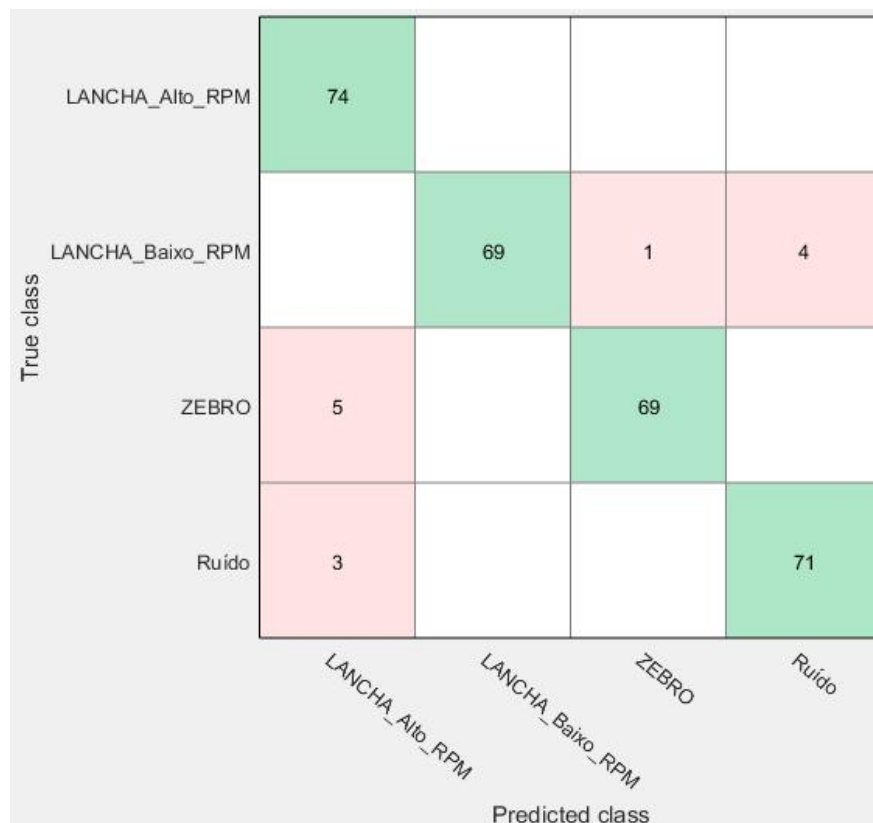


Figura 25 – Matriz de confusão do classificador K-NN com  $k = 4$  pelo método Validação cruzada

Para os restantes valores de  $k$  associados a este classificador, foram obtidas taxas de sucesso na classificação das instâncias inferiores.

Valor de $k$	% de Class. com sucesso
$K = 1$	94.9%
$K = 3$	94.6%
$K = 5$	93.9%
$K = 6$	94.3%
$K = 7$	91.2%
$K = 8$	91.9%
$K = 9$	90.9%
$K = 10$	91.6%
$K = 15$	87.8%
$K = 20$	80.4%
$K = 30$	75.7%
$K = 40$	74.3%

K = 50	77.4%
K = 60	76.7%

Tabela 3 - Resultados do classificador K-NN para vários k, através do método Validação cruzada

Constata-se que este classificador tem uma taxa de sucesso superior para a classificação da Lancha a altas RPMs e de ruído ambiente.

- **SVM (Kernel cúbico)**

Para o classificador SVM, recorrendo a um Kernel cúbico, os resultados obtidos foram os seguintes:

<b>Validação Cruzada</b>	Instâncias Classificadas = 296
	Taxa de classificação com sucesso = 99.0%
	Taxa de classificação com insucesso = 1.0%

Tabela 4 - Resultados do teste do classificador SVM, com kernel cúbico, utilizando o método validação cruzada

True class	LANCHA_Alto_RPM	73			1
	LANCHA_Baixo_RPM		73		1
	ZEBRO			74	
	Ruído		1		73
		LANCHA_Alto_RPM	LANCHA_Baixo_RPM	ZEBRO	Ruído
		Predicted class			

Figura 26 - Matriz de confusão do classificador SVM, com Kernel cúbico, pelo método Validação cruzada

Denota-se que, apesar de alguns erros de classificação, este modelo é eficaz na classificação de todo o tipo de instâncias apresentadas.

### 7.1.2 Teste com o método *Holdout*

Seguidamente, testou-se o desempenho dos classificadores recorrendo ao método *Holdout*, utilizando, para este efeito, 20% das instâncias do conjunto para teste.

- K-NN

Para o classificador K-NN, foram obtidos os melhores resultados com  $k = 2$ : e  $k = 3$

<b>k = 2 e k = 3</b>	Instâncias classificadas = 58
<b>Holdout</b>	Taxa de classificação com sucesso = 98,3%
	Taxa de classificação com insucesso = 1,7%

Tabela 5 - Resultados do teste do classificador K-NN, com  $k=3$  e  $k=4$ , utilizando o método *Holdout* com 20% de instâncias para teste.

A matriz de confusão do classificador K-NN resultante, para ambos os valores de  $k$ , foi a seguinte:

True class	LANCHA_Alto_RPM	14			
	LANCHA_Baixo_RPM		15		
	ZEBRO	1		14	
	Ruído				14
		LANCHA_Alto_RPM	LANCHA_Baixo_RPM	ZEBRO	Ruído
		Predicted class			

Figura 27 - Matriz de confusão do classificador K-NN com  $k = 2$  e  $k = 3$  pelo método *Holdout* com 20% de instâncias para teste.

Foi obtida uma taxa de classificações bem-sucedidas extremamente elevada. Para outros valores de  $k$ , foram obtidos as seguintes taxas de sucesso:

Valor de $k$	% de Class. com sucesso
$K = 1$	96.6%
$K = 4$	94.8%
$K = 5$	96.6%
$K = 6$	96.6%
$K = 7$	93.1%
$K = 8$	94.8%
$K = 9$	93.1%
$K = 10$	93.1%

K = 15	84.5%
K = 20	86.2%
K = 30	79.3%
K = 40	77.6%
K = 50	79.3%
K = 60	74.1%

Tabela 6 - Resultados do classificador K-NN para vários k, através do método *Holdout*.

- **SVM (Kernel cúbico)**

Para o classificador SVM, recorrendo a um Kernel cúbico, os resultados obtidos foram os seguintes:

<b><i>Holdout</i></b>	Instâncias Classificadas = 58
	Taxa de classificação com sucesso = 100.0%
	Taxa de classificação com insucesso = 0.0%

Tabela 7 - Resultados do teste do classificador SVM, com kernel cúbico, utilizando o método *Holdout* com 20% de instâncias para teste.

Através deste classificador foi obtida a seguinte matriz de confusão:

True class	LANCHA_Alto_RPM	14			
	LANCHA_Baixo_RPM		15		
	ZEBRO			15	
	Ruído				14
		LANCHA_Alto_RPM	LANCHA_Baixo_RPM	ZEBRO	Ruído
		Predicted class			

Figura 28 - Matriz de confusão do classificador SVM, com kernel cúbico, pelo método *Holdout* com 20% de instâncias para teste.

Neste caso, obteve-se 100% de sucesso na classificação de instâncias com o classificador SVM com kernel cúbico.

### 7.1.3 Introdução de novo ficheiro para teste.

Nesta fase, de modo a testar a eficácia dos classificadores, foi introduzido um novo ficheiro para teste. Este contém um conjunto de teste diferente com 60 instâncias associada à lancha Mindelo (30 instâncias correspondente a altas RPMs e as restantes 30 a baixas RPMs). Assim, poderá ser efetuado um teste aos classificadores, averiguando se os mesmos são bem-sucedidos aquando da classificação de uma “nova” plataforma.

- **K-NN**

As taxas de sucesso de classificação obtidas foram ótimas para valores de  $k = 2$  e  $k = 3$

<b>k = 2 e k = 3</b>	Instâncias classificadas = 60
<b>Holdout</b>	Taxa de classificação com sucesso = 90,0%

---

Taxa de classificação com insucesso = 10,0%

---

Tabela 8 - Resultados do teste do classificador K-NN, com valores de  $k = 2$  e  $k = 3$ , após introdução de novo conjunto de teste.

Desta forma, a matriz de confusão para  $k = 2$  e  $k = 3$  obtida foi a seguinte:

Classe real	LANCHA_Alto_RPM	27	2	0	1
	LANCHA_Baixo_RPM	0	27	0	3
	ZEBRO	0	0	0	0
	Ruido	0	0	0	0
		LANCHA_Alto_RPM	LANCHA_Baixo_RPM	ZEBRO	Ruido
		Estima			

Figura 29 – Matriz de confusão do classificador K-NN, com  $k = 2$  e  $k = 3$ , após introdução de novo ficheiro

Apesar dos restantes valores de  $k$  serem inferiores, as percentagens de sucesso obtidas são consideravelmente elevadas. Através do classificador K-NN foram obtidos os seguintes resultados para o novo conjunto:

Valor de $k$	% de Class. com sucesso
$K = 1$	88.0%
$K = 4$	88.3%
$K = 5$	85.0%
$K = 6$	86.7%
$K = 7$	80.0%
$K = 8$	81.7%

K = 9	81.7%
K = 10	85%
K = 15	76.7%
K = 20	76.7%
K = 30	70.0%
K = 40	70.0%
K = 50	65.0%
K = 60	86.7%

Tabela 9 - Resultados do classificador K-NN para vários k, com a introdução de um novo ficheiro.

- **SVM**

Com a introdução de um novo conjunto de teste, os resultados para o classificador SVM com kernel cúbico são os seguintes:

<b>Novo conjunto</b>	Instâncias Classificadas = 60
<b>de teste</b>	Taxa de classificação com sucesso = 85.0%
	Taxa de classificação com insucesso = 15.0%

Tabela 10 - Resultados do teste do classificador SVM, com kernel cúbico, após introdução de novo conjunto de teste.

Classe real	LANCHA_Alto_RPM	22	2	5	1
	LANCHA_Baixo_RPM	0	29	0	1
	ZEBRO	0	0	0	0
	Ruído	0	0	0	0
		LANCHA_Alto_RPM	LANCHA_Baixo_RPM	ZEBRO	Ruído
		Estima			

Figura 30 - Matriz de confusão do classificador SVM, com kernel cúbico, após introdução de novo ficheiro.

Constata-se que, apesar de algumas instâncias do conjunto de teste não se encontrarem corretamente classificadas, a taxa de sucesso para este classificador é bastante elevada.

## 7.2 Teste de posicionamento direcional

Tal como referido anteriormente, por forma a estimar a direção a que se encontrava a fonte sonora foi utilizado um algoritmo baseado no cálculo da TDOA entre hidrofones, sendo por sua vez, este valor obtido através de uma função *cross-correlation*. Este algoritmo foi aplicado a um bloco de 20s de gravação de uma das fiadas da lancha Mindelo. Desta forma, os resultados obtidos foram os seguintes:

Azimuth Verdadeiro (°)	TDOA calculado (s)	Azimuth Estimado (°)	Erro (°)
119,84°	0.0460	120,81°	0,97°

119,33°	0.0467	120,47°	1,14°
118,82°	0.0473	120,17°	1,35°
118,29°	0.0487	119,47°	1,18°
117,74°	0.0493	119,17°	1,74°
117,27°	0.0500	118,82°	1,55°
116,75°	0.0513	118,16°	1,41°
116,25°	0.0520	117,80°	1,55°
115,73°	0.0533	117,13°	1,40°
115,17°	0.0540	116,77°	1,60°
114,55°	0.0547	116,44°	1,89°
113,91°	0.0560	115,74°	1,83°
113,25°	0.0567	115,39°	2,14°
112,58°	0.0580	114,70°	2,12°
111,85°	0.0593	114,03°	2,18°
111,14°	0.0607	113,28°	2,14°
110,40°	0.0620	112,59°	2,19°
109,63°	0.0626	112,22°	2,59°
108,41°	0.0626	111,30°	2,89°
107,90°	0.0626	110,90°	3,01°

Tabela 11 – Resultado para a estima do azimute da Lancha Mindelo

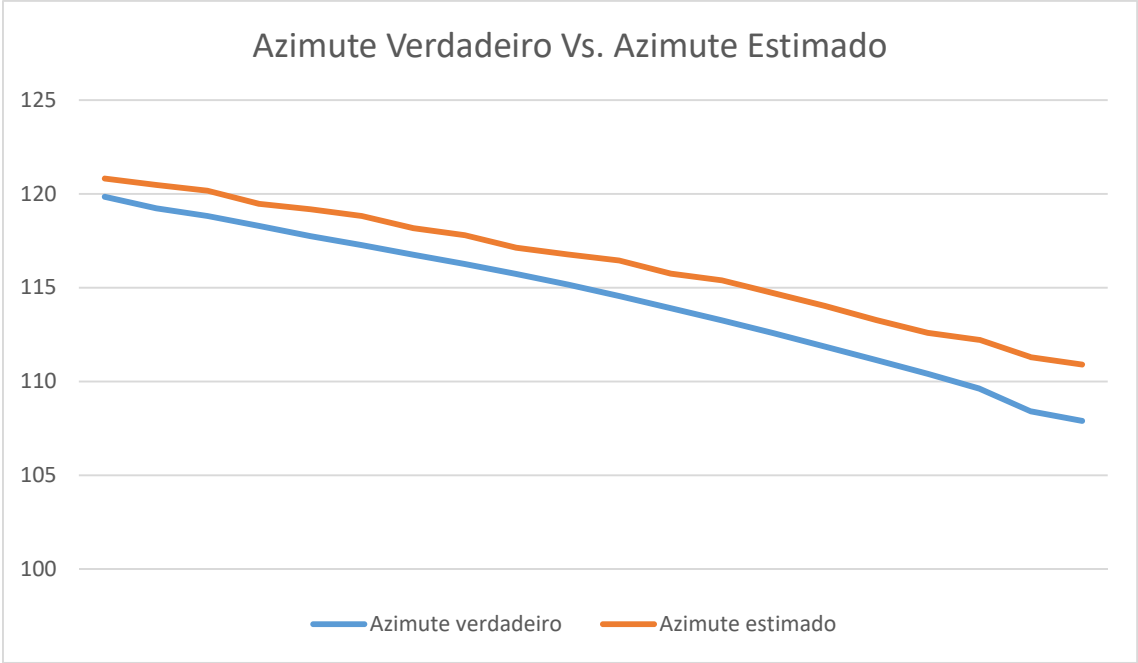


Figura 31 - Azimute Verdadero Vs. Azimute Estimado



## Conclusões

O trabalho apresentado dissertação teve como o estudo e conceção um sistema de escuta submarina passiva que identificasse e efetuasse o *tracking* de fontes acústicas distintas. Através de gravações de mar e posterior processamento de dados foram elaborados *scripts* capazes de identificar contactos e determinar a DOA. Para este efeito utilizou-se um *array* composto por dois hidrofones, dispostos numa arquitetura em LBL. A escolha desta disposição para os aparelhos deve-se ao facto da sua futura aplicação para os projetos *Deepfloat* e *Sidenav*, que irão requisitar o controlo de posição de AUVs ao longo de grandes distâncias. Para testar o desempenho da identificação de sinais e do *tracking* fontes, foram efetuados dois testes separadamente.

Para o teste de identificação de sinais, foram utilizados ficheiros correspondentes a ruídos emitidos pelo bote *Zebro*, pela lancha *Mindelo* (altas e baixas RPMs) e de fontes desconhecidas (ruído ambiente), que foram recolhidos pelo *array* enquanto efetuavam fiadas. Posteriormente à aplicação de técnicas de pré-processamento (estudadas no capítulo 3) nos ficheiros recolhidos, aplicaram-se algoritmos baseados em *Machine Learning* aos espectros obtidos de modo a serem associados a uma plataforma. Para este efeito foram utilizados dois classificadores: K-vizinhos (K-NN) e *Support Vector Machine* (SVM).

Para ambos os classificadores foram utilizados os métodos *holdout* e *cross-validation* para o conjunto de treino, e, para teste, foi utilizado um novo conjunto de dados. Para o K-NN denotou-se que os melhores resultados foram obtidos quando usados valores de  $K = 3$  e  $K = 4$  para o teste *holdout*, obtendo 98.3% das instâncias corretamente classificadas. Com o classificador SVM os melhores resultados foram observados no teste *holdout* com, 100% das instancias corretamente classificadas. Através da análise dos resultados dos classificadores pode-se concluir que, na maior parte dos testes efetuados, os valores obtidos pelo classificador SVM foram mais satisfatórios no geral. Apesar deste facto, considera-se que o classificador K-NN obteve resultados igualmente satisfatórios.

Deste modo é possível retirar algumas conclusões:

- SVM: Ideal para empregar em problemas que poderão não ser linearmente separáveis e se os dados se inserirem num espaço de dimensões elevadas (como é o caso do problema apresentado nesta dissertação). No entanto, o

tempo de treino não é idealmente rápido pois, para uma grande quantidade de amostras, torna-se computacionalmente mais complexo.

- K-NN: Revela-se ser robusto ao tratar dados que possuem muito ruído, sendo eficaz para conjuntos de treino com muitas instâncias. Apesar de ser mais simples, é necessário determinar o valor de K ideal. O tempo de computação também acaba por ser elevado pois é necessário calcular a distância de cada instância ao conjunto de treino.

Deste modo, apesar de ambos os classificadores demonstrarem resultados bastante satisfatórios, conclui-se que, para o contexto desta dissertação, o classificador SVM é preferível para a classificação de AUVs.

Para o teste do *tracking* direcional da fonte ruidosa, os resultados foram bastante satisfatórios, obtendo-se um erro mínimo de  $0.97^\circ$  e máximo de  $3.01^\circ$ . É facilmente observável que a taxa de erro aumenta com a aproximação da fonte ao *array*. Este facto poderá dever-se às reflexões que o som sofre no fundo, criando ruído adicional, visto que, o teste foi realizado numa zona pouco profunda. Apesar disto, conclui-se que de facto, este sistema é eficaz no controlo azimutal de fontes sonoras em movimento.

É necessário notar, no entanto, que existiram algumas limitações ao longo da realização desta dissertação. A primeira prende-se ao facto das gravações terem sido efetuadas todas no mesmo local e num curto espaço de tempo. Assim, as condições de propagação do som permaneceram semelhantes o que resultou na obtenção constante de sinais semelhantes, o que facilita o processo de identificação. A segunda limitação tem a ver com a variedade de plataformas a serem utilizadas para teste. Idealmente para garantir um teste mais eficaz de classificadores seria necessário o uso de mais fontes sonoras distintas. A terceira limitação é relativa ao local de testes. No mesmo dia que se efetuaram os testes com os hidrofones, estavam simultaneamente a decorrer outras atividades de provas de mar, o que acrescentou ruído adicional às gravações. Por fim, o facto de apenas serem utilizados dois hidrofones para a estima da DOA, fez com que existisse uma redundância de direções, isto é, uma indeterminação se a plataforma se encontrava à direita ou à esquerda do alinhamento dos hidrofones. Assim, foi necessário assumir de que lado é que se aproximava a fonte sonora. Esta limitação é facilmente colmatada com a adição de um hidrofone ao *array*. Apesar das limitações existentes na elaboração do

presente estudo, é possível concluir que o sistema a aplicar no projeto Deepfloat e Sidenav funciona de forma satisfatória.

### **Sugestões para trabalho futuro**

Relativamente à identificação de sinais é pertinente efetuar testes com uma maior variedade de fontes acústicas e em ambientes de condições de propagação de som diferentes. Assim, considerando o que já foi estudado nesta dissertação, efetuar-se-iam mais testes de classificadores e seria possível construir bases de dados.

No que diz respeito ao controlo direcional de fontes sonoras, futuramente de modo a criar um sistema de posicionamento mais complexo, e tendo em conta os métodos explorados, seria interessante efetuar testes com um *array* de três hidrofones. Desta forma, seria possível obter o cruzamento de dois azimutes, permitindo atribuir coordenadas geográficas ao mesmo.

Para aplicações futuras com UAVs, seria benéfico o desenvolvimento dos algoritmos explorados em *Arduino*<sup>13</sup> por forma a permitir executar os programas em sistemas de *tracking* em tempo-real.

Os métodos estudados poderão ter aplicações para além do proposto inicialmente. Os algoritmos criados poderão ser implementados em sistemas de monitorização de navios junto a costa, ou até mesmo a bordo de unidades navais para controlo de posição de semirrígidas.

---

<sup>13</sup> Plataforma *open-source* de criação de protótipos eletrónicos que permite aos utilizadores criar componentes eletrónicos interativos.



## Referências

- Ahmed, H. I., Wei, P., Memon, I., Du, Y., & Xie, W. (2013). Estimation of Time Difference of Arrival (TDOA) for the Source Radiates BPSK Signal. *International Journal of Computer Science Issues*, Vol.10, Issue 3, No 2, 164-171.
- Albers, V. M. (1965). *Underwater Acoustics Handbook - II*. Pennsylvania: Pennsylvania State University Press.
- Alcocer, A., Oliveira, P., & Pascoal, A. (28 de Janeiro de 2018). *Underwater Acoustic Positioning Systems Based on Bouys with GPS*. Obtido de Research Gate: <https://www.researchgate.net/publication/242392025>
- Alpaydin, E. (2010). *Introduction to Machine Learning*. Massachusetts: The MIT Press.
- Andersson, S. (2008). *Modelling of Wave Propagation in Shallow Water Environment*. Norwegian University of Science and Technology.
- Ballard, M. (2017). Underwater Acoustics. *Acoustics Today*, 63-65.
- Burgess, J. C. (1998). Practical Considerations in Signals Processing. Em M. J. Crocker, *Handbook of Acoustics* (pp. 1063-1083). John Wiley & Sons, Inc.
- Carvalho, A. C., & Lorena, A. C. (2007). Uma introdução às Support Vector Machines. *RITA Volume XIV Número 2*, 43-67.
- Chao, W.-L. (2011). *Machine Learning Tutorial*. National Taiwan University.
- Crocker, M. J. (1998). Introduction. Em M. J. Crocker, *Handbook of Acoustics* (pp. 3-21). John Wiley & Sons, Inc.
- Dyer, I. (1998). Ocean Ambient Noise. Em M. J. Crocker, *Handbook of Acoustics* (pp. 425-433 ). New York: John Wiley & Sons, Inc.
- Efteland, J. I. (2016). *Underwater Acoustic Positioning System for Real-time Fish Tracking*. Norwegian University of Science and Technology.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From Data Mining to Knowledge Discovery in Databases. *AI Magazine Volume 17 Number 3*, 37-54.
- Gupta, G. (2011). *Introduction to data mining with case studies*. PHI Learning Pvt. Ltd.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques (third edition)*. Waltham: Elsevier Inc.
- Hansen, C. H. (2005). *Fundamentals of Acoustics*. Adelaide: University of Adelaide.
- Harrington, P. (2012). *Machine Learning in Action*. Shelter Island: Manning Publications Co.
- Hodges, R. P. (2010). *Underwater Acoustics Analysis, Design and Performance of Sonar*. Reino Unido: Wiley.

- Hofmann, M. (2006). Support Vector Machines - Kernels and the Kernel Trick. *Reading Club: Support Vector*.
- Houcq, D. (2005). *Introduction to MATLAB for engineering students*. Northwestern University.
- Kantardzic, M. (2011). *Data Mining: Concepts, Models, Methods, and Algorithms*. John Wiley & Sons.
- Lantz, B. (2015). *Machine Learning with R (second edition)*. Birmingham: Packt Publishing Ltd.
- Larose, D. T. (2005). *Discovering Knowledge in Data: an Introduction to Data Mining*. John Wiley & Sons.
- Lobo, V. J. (2002). *Ship Noise Classification - A contribution to prototype based classifier design*. Lisboa.
- Lurton, X. (2002). *An Introduction to Underwater Acoustics*. Chichester: Praxis Publishing Ltd.
- Mackenzie, K. V. (1981). Nine-term equation for sound in the oceans. *The Journal of the Acoustical Society of America*, 807-812.
- Manolakis, D. G., & Proakis, J. G. (1996). *Digital Signal Processing - Principles, Algorithms, and Applications (Third Edition)*. New Jersey: Prentice-Hall International, INC.
- Miller, H. J., & Han, J. (2000). *Geographic Data Mining and Knowledge Discovery: an overview*.
- Moses, R., & Stoica, P. (2004). *Spectral Analysis of Signals*. New Jersey: Prentice Hall.
- Oliveira, J. S. (2009). *Desenvolvimento de um Sistema de Posicionamento Acústico USBL e Validação com Testes de Mar*. Lisboa: Instituto Superior Técnico.
- Osmar, Z. R. (1999). *Principles of Knowledge Discovery in Databases*. Alberta: University of Alberta.
- Pope, J. (1998). Analyzers. Em M. J. Crocker, *Handbook of Acoustic* (pp. 1341-1355). John Wiley & Sons, Inc.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *Journal of Research and Development*, 210-229.
- Santos, C. P. (2015). *Acústica Submarina: Classificação de navios aplicando algoritmos de aprendizagem supervisionada (data mining)*. Alfeite: Escola Naval.
- Tellakula, A. K. (2007). *Acoustic Source Localization Using Delay Estimation*. Bangalore: Indian Institute of Science.
- Tomczak, A. (2011). Modern Methods of Underwater Positioning Applied in Subsea Mining. *Górnictwo i Geoinżynieria* 35/4/1 (2011), 381-394.

- Tucholski, E. J. (2006). Underwater Acoustics and Sonar SP411 Handouts and Notes .  
U.S. Naval Academy.
- Urick, R. J. (1983). *Principles of Underwater Sound*. McGraw-Hill Inc.
- Vickery, K. (1998). Acoustic Positioning Systems - "A Practical Overview of Current  
Systems". *Dynamic Positioning Conference*. Dynamic Positioning Committee.
- Waite, A. (2002). *Sonar for Practising Engineers*. Chichester: John Wiley & Sons Ltd.



# Índice Remissivo

## A

Acústica Subaquática .....2, 5  
Amplitude ..... 6, 7, 8, 10, 14, 35, 44, 51  
Amplitude de onda .....7  
Aprendizagem não supervisionada ....49  
Aprendizagem por reforço .....49  
Aprendizagem supervisionada .2, 49, 50  
AUV .....III, 1

## C

Comprimento de onda .....9, 14  
*Cross-correlation*.....2, 33, 34, 77

## D

*Data mining* .....III, VI, 2, 47, 48, 83, 84  
*Data warehouses* .....47  
*Databases* .....47, 83, 84  
Decibel .....10  
Densidade do meio.....8  
*Direction of Arrival*VI, 2, 3, 28, 34, 36,  
37, 66, 90  
*Discrete Fourier Transform* .....40  
Distância Euclidiana .....51, 52  
Doppler .....V, 5, 6, 16

## F

*Fast Fourier Transform* .....41  
FrequênciaIX, 7, 9, 16, 17, 18, 19, 20, 21,  
28, 39, 40, 41, 42, 44, 65

Frequência angular ..... 7, 40

## G

GPS .....25, 27, 30, 32, 83

## H

*Hanning*..... 45  
Hidrofone...III, IX, 1, 22, 25, 26, 27, 28,  
29, 30, 31, 32, 33, 35, 36, 37, 50, 63,  
65, 66, 77, 79, 80, 81  
Hiperplano ..... 53, 54, 56

## I

Intensidade .....10, 18, 19, 20, 22, 23, 41

## K

Kernel.....X, XI, 57, 58, 59, 70, 71, 73, 84  
K-NN .....*See Vizinho mais Próximo*  
K-Vizinhos .....*See Vizinho mais Próximo*

## L

*Leakage*..... 44  
Lei de Snell-Descartes..... IX, 14, 15  
*Long Baseline* ..... III, V, 1, 27

## M

*Machine Learning*VI, IX, 48, 49, 79, 83,  
84  
*Método cross-validation*..... 60  
*Método de Bartlett*..... VI, 43

Método de Welch.....	VI, 43	<i>Scattering</i> .....	22, 24
Método <i>Holdout</i> .....	60	<i>Short Baseline</i> .....	V, 27, 29, 31, 32, 33
Método Validação CruzadaSee Método <i>cross-validation</i>		<i>Signal-to-Noise Ratio</i> .....	23
Multiplicadores de Lagrange .....	55	Sincronização de relógios .....	26, 27
<b>N</b>		SOFAR.....	16
Normalização max-min.....	51	SomV, IX, 2, 5, 7, 8, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 28, 30, 37, 63, 80	
Nyquist.....	39	Sonar .....	5, 6, 17, 19, 22, 23, 24, 83, 85
<b>O</b>		<i>Support Vector Machine</i> .....	VI, 2, 52, 79
Ondas acústicasV, 7, 8, 9, 10, 11, 13, 19, 22, 24, 25, 26		<b>T</b>	
<i>One-versus-All</i> .....	59	<i>Target Strength</i> .....	24
<i>One-versus-One</i> .....	59	TDOAIII, VI, 2, 28, 29, 33, 34, 35, 36, 37, 65, 66, 77, 83	
<b>P</b>		Temperatura .....	11
Período ... 5, 9, 16, 17, 21, 35, 36, 40, 44		Teorema da amostragem de Shannon .....	39
Periodograma .....	VI, 42, 43	Teoria dos modos normais .....	14
<i>Pinger</i> .....	26	Teoria dos raios acústicos.....	14
Potência acústica .....	10	Termoclina .....	13
PressãoIX, 7, 8, 9, 10, 11, 12, 13, 14, 19, 21, 26		<i>Time of Flight</i> .....	28
Profundidade .....	11	<i>Transacional data</i> .....	47
<b>R</b>		Transdutor .....	20, 25, 28, 31, 32
<i>Responder</i> .....	26	Transformada de Fourier ... VI, IX, 40, 41	
<i>Reverberation Level</i> , .....	24	<i>Transmission loss</i> .....	19
ROV .....	III	<i>Transponder</i> .....	25, 26, 28, 30, 31
Ruído18, 23, 26, 28, 34, 36, 48, 51, 63, 65, 67, 70, 79, 80		<b>U</b>	
<b>S</b>		<i>Ultra Short Baseline</i> .....	27
Salinidade .....	12	<b>V</b>	
		Valor de custo .....	57

Velocidade de propagação .8, 11, 17, 30

Vizinho mais Próximo ..... VI, 50

**W**

*Window* .....43, 44, 45, 65



## Apêndices

### Apêndice A – Rotina de Matlab: Processamento de Sinais

Esta rotina tem como objetivo ler um ficheiro “.wav”, previamente gravado por um hidrofone, por forma a calcular a densidade espectral da potência de um sinal. É aplicada uma função do método de Welch, com uma janela de Hanning, para as 1024 primeiras frequências com a resolução de um *bit* (1 Hz). Cada secção de um bit é dividida em 8 secções com *overlap* de 50%.

```
%% Extração de dados
A = [];
files = dir(filename);
length = length(files);
audio = cell(1,length);
for k = 1:length
    audio{k} = audioread(files(k).name);
end

%% Pré-processamento de dados
for i = 1:length
    x = cell2mat(audio(i));
    nx = max(size(x));
    fs = 44100;
    na = 8;
    w = hanning(floor(nx/na));
    f = 0:1:1024;
    noverlap = 50;
    [pxx,f] = pwelch(x,w,noverlap,f,fs);

%% Normalização da estima da PSD
    pxx_max = max(pxx);

    hh = pxx/ppxx_max;
    A= [A; hh]; %#ok<AGROW>

end
A = table(A);
```



## Apêndice B – Rotina de Matlab: Estima da DOA

A presente rotina de Matlab tem com objetivo estimar a diferença de tempo de chegada de um sinal acústico para os diferentes hidrofones.

```
% Diferença temporal de chegada
files = dir(filename);
length = length(files);
for k = 1:length
    [audio{k},fs] = audioread(files(k).name);
end
SR1_1 = cell2mat(audio(2));
TP1_1 = cell2mat(audio(1));

%Correlação de sinais da primeira posição
[acor,lag] = xcorr(SR1_1,TP1_1); %efetua a correlação de dois sinais,
devolvendo um vetor com a sequência de correlação, acor, e o índice de
atraso, lag.

[~,I] = max(abs(acor)); %devolve o máximo valor da sequência de
correlação.
lagDiff = lag(I); %expressa o atraso em amostras
TDOA1 = vpa((lagDiff/fs),8);%expressa o atraso em segundos

%% Calcular a nova Referência para possibilitar o calculo do azimuth
da fonte relativamente ao centro do array
az = vpa(azimuth(38.664747,-9.14012,38.665765,-9.138415),8);
NR = vpa(az - 90,8);
if NR > 180
    NR = NR - 360;
end
PTMediolat = (38.664747 + 38.665765)/2;
PTMediolon = (-9.14012 + -9.138415)/2;

%% Calcular DOA
% DOA
AB1 = vpa(1500 * TDOA1,8);
b = radtodeg(acos(AB1/186));
%Levantamento da indeterminação relativa ao lado em que se encontra a
fonte
if Quadr < 0
```

```
        b = b + 90;
    end
%%

    x = vpa(180 - (b + NR), 5);
    azimuth = b + NR;
    disp('AZIMUTE')
    fprintf('%g°', azimuth)
```

## Apêndice C – Rotina de Matlab: Treino de Classificador SVM

O objetivo desta rotina é treinar e criar uma função para um classificador SVM (Kernel cúbico), por forma a possibilitar a classificação de sinais previamente pré-processados. (Esta rotina pode ser gerada automaticamente pela *Classification App* do Matlab).

```
% Extrair variáveis e respostas
% Esta rotina processa os dados na formatação correta para treinar o
modelo
inputTable = trainingData;
% Divide matrizes da tabela de inputs em vetores
inputTable =
[inputTable(:, setdiff(inputTable.Properties.VariableNames,
{Tabela_de_dados})),
array2table(table2array(inputTable(:, {Tabela_de_dados})),
'VariableNames', {Variáveis})];

predictorNames = {nomes_das_colunas_de_variaveis};
predictors = inputTable(:, predictorNames);
response = inputTable.Classes;
isCategoricalPredictor = [false]

% Estabelecer condições da validação holdout
cvp = cvpartition(response, 'Holdout', 0.2);
trainingPredictors = predictors(cvp.training, :);
trainingResponse = response(cvp.training, :);
trainingIsCategoricalPredictor = isCategoricalPredictor;

% Treinar Classificador
template = templateSVM(...
    'KernelFunction', 'polynomial', ...
    'PolynomialOrder', 3, ...
    'KernelScale', 'auto', ...
    'BoxConstraint', 1, ...
    'Standardize', false);
classificationSVM = fitcecoc(...
    predictors, ...
    response, ...
```

```

'Learners', template, ...
'Coding', 'onevsall', ...
'ClassNames', categorical({Classe1; Classe2; Classe3; Classe4}, {
Classe1; Classe2; Classe3; Classe4});

% Criar struct de resultado com função de previsão
splitMatricesInTableFcn = @(t)
[t(:,setdiff(t.Properties.VariableNames, {Tabela_de_dados})),
array2table(table2array(t(:,{Tabela_de_dados})), 'VariableNames', {
Variáveis})];
extractPredictorsFromTableFcn = @(t) t(:, predictorNames);
predictorExtractionFcn = @(x)
extractPredictorsFromTableFcn(splitMatricesInTableFcn(x));
svmPredictFcn = @(x) predict(classificationSVM, x);
trainedClassifier.predictFcn = @(x)
svmPredictFcn(predictorExtractionFcn(x));

% Efetuar Validação Cruzada
partitionedModel = crossval(trainedClassifier.ClassificationSVM,
'KFold', 10);

% Computar resultados da validação Validação Cruzada
[validationPredictions, validationScores] =
kfoldPredict(partitionedModel);

% Computar resultados da validação Holdout
validationPredictors = predictors(cvp.test, :);
validationResponse = response(cvp.test, :);
[validationPredictions, validationScores] =
validationPredictFcn(validationPredictors);

```

## Apêndice D – Rotina de Matlab: Treino de Classificador K-NN

O objetivo desta rotina é treinar e criar uma função para um classificador K-NN, por forma a possibilitar a classificação de sinais previamente pré-processados. (Esta rotina pode ser gerada automaticamente pela *Classification App* do Matlab).

```
% Extrair variáveis e respostas
% Esta rotina processa os dados na formatação correta para treinar o
modelo
inputTable = trainingData;
% Divide matrizes da tabela de inputs em vetores
inputTable =
[inputTable(:,setdiff(inputTable.Properties.VariableNames,
{Tabela_de_dados})),
array2table(table2array(inputTable(:,{Tabela_de_dados})),
'VariableNames', {Variáveis})];

predictorNames = {nomes_das_colunas_de_variaveis};
predictors = inputTable(:, predictorNames);
response = inputTable.Classes;
isCategoricalPredictor = [false]

% Estabelecer condições da validação holdout
cvp = cvpartition(response, 'Holdout', 0.2);
trainingPredictors = predictors(cvp.training, :);
trainingResponse = response(cvp.training, :);
trainingIsCategoricalPredictor = isCategoricalPredictor;

% Treinar Classificador
classificationKNN = fitcknn(...
    predictors, ...
    response, ...
    'Distance', 'Euclidean', ...
    'Exponent', [], ...
    'NumNeighbors', "número de vizinhos", ...
```

```

'DistanceWeight', 'Equal', ...
'Standardize', false, ...
'ClassNames', categorical({Classe1; Classe2; Classe3; Classe4}, {
Classe1; Classe2; Classe3; Classe4});

% Criar struct de resultado com função de previsão
splitMatricesInTableFcn = @(t)
[t(:,setdiff(t.Properties.VariableNames, {Tabela_de_dados})),
array2table(table2array(t(:,{Tabela_de_dados})), 'VariableNames', {
Variáveis})];
extractPredictorsFromTableFcn = @(t) t(:, predictorNames);
predictorExtractionFcn = @(x)
extractPredictorsFromTableFcn(splitMatricesInTableFcn(x));
knnPredictFcn = @(x) predict(classificationKNN, x);
trainedClassifier.predictFcn = @(x)
knnPredictFcn(predictorExtractionFcn(x));

% Efetuar Validação Cruzada
partitionedModel = crossval(trainedClassifier.ClassificationKNN,
'Kfold', 10);

% Computar resultados da validação Validação Cruzada
[validationPredictions, validationScores] =
kfoldPredict(partitionedModel);

% Computar resultados da validação Holdout
validationPredictors = predictors(cvp.test, :);
validationResponse = response(cvp.test, :);
[validationPredictions, validationScores] =
validationPredictFcn(validationPredictors);

```

## Apêndice E – Rotina de Matlab: Introdução de novo ficheiro para teste do Classificador

O objetivo desta rotina é aplicar as funções de classificadores

```
% Introdução de novo ficheiro para classificação
% Loading da tabela de dados e classificador
A.Properties.VariableNames{1} = Tabela_Dados;
load('trainedClassifier.mat')

%%Executar classificador
yfit = trainedClassifier.predictFcn(A);

%Loading das classes para a classificação
load(Classes.mat)

Classes1 = Classes(1:q,1);

labels = unique(Classes);

labels = labels.';

%Computação de uma matriz de confusão com os resultados
Conf_Mat = confusionmat(Classes1,yfit);

h = heatmap(labels,labels,Conf_Mat);

h.XLabel = 'Estima';
h.YLabel = 'Classe real';

idx = (Classes1()== 'Classe1');
idy = (Classes1()== 'Classe2');
idz = (Classes1()== 'Classe3');
idw = (Classes1()== 'Classe4');

p = length(Classes(idx));
n = length(Classes(idy));
m = length(Classes(idz));
w = length(Classes(idw));

N = p+n+m+w;
```

```

tp = sum(Classes1(idz) == yfit(idz));
tn = sum(Classes1(idy) == yfit(idy));
tm = sum(Classes1(idz) == yfit(idz));
tw = sum(Classes1(idz) == yfit(idw));

tp_taxa = tp/p;
tn_taxa = tn/n;
tm_taxa = tm/m;
tw_taxa = tw/w;

Sucesso = (tp+tn+tm+tw)/N;
Insucesso = 1 - Sucesso;
Sucesso = Sucesso * 100;
Insucesso = Insucesso * 100;

disp('')
X = [num2str(Sucesso), '%'];
disp('Sucesso')
disp(X)
disp('')
Y = [num2str(Insucesso), '%'];
disp('Insucesso')
disp(Y)

```

## Apêndice F – Percurso em fiadas do bote *Zebro*

A imagem em apêndice, retirada do *software* Google Earth, ilustra o percurso, em fiadas, efetuado pelo bote *Zebro* no dia 12 de Julho de 2017, por forma a efetuar a gravação do ruído subaquático produzido pelo mesmo. Na imagem também é possível observar a localização do *array* de hidrofones relativamente à plataforma.



Figura 32 - Percurso por fiadas do bote *Zebro* e localização dos hidrofones TP-1 e SR-1.



## Apêndice G – Percurso por fiadas da lancha *Mindelo*

A imagem em apêndice, retirada do *software* Google Earth, ilustra o percurso, em fiadas, efetuado pela lancha *Mindelo* no dia 13 de Julho de 2017, por forma a efetuar a gravação do ruído subaquático produzido pela mesma. Na imagem também é possível observar a localização do *array* hidrofones relativamente à plataforma.



Figura 33 - Percurso por fiadas da lancha *Mindelo* e localização dos hidrofones TP-1 e SR-1