



CLASSIFICAÇÃO DE NAVIOS COM USO DE SINAIS DE SONAR PASSIVO

Gustavo Augusto Mascarenhas Goltz

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientador: José Manoel de Seixas

Rio de Janeiro
Março de 2019

CLASSIFICAÇÃO DE NAVIOS COM USO DE SINAIS DE SONAR PASSIVO

Gustavo Augusto Mascarenhas Goltz

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. José Manoel de Seixas, D.Sc.

Prof. José Antonio Apolinário Junior, D.Sc.

Prof. Carlos Eduardo Parente Ribeiro, D.Sc.

Prof. Guilherme de Alencar Barreto, D.Sc.

Prof. Charles Bezerra do Prado, D.Sc.

Dr. Leonardo Martins Barreira, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

MARÇO DE 2019

Goltz, Gustavo Augusto Mascarenhas

Classificação de Navios com Uso de Sinais de Sonar Passivo/Gustavo Augusto Mascarenhas Goltz. – Rio de Janeiro: UFRJ/COPPE, 2019.

XVII, 70 p.: il.; 29, 7cm.

Orientador: José Manoel de Seixas

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2019.

Referências Bibliográficas: p. 62 – 70.

1. Máquinas de Comitê. 2. Conhecimento Especialista.
3. Classificação de Navios. 4. Redes Neurais Artificiais.
I. Seixas, José Manoel de. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

“Porque Deus amou o mundo de tal maneira que deu o seu Filho unigênito, para que todo aquele que Nele crê não pereça, mas tenha a vida eterna.” João 3:16.

Agradecimentos

Agradeço a Deus pela vida, família e amigos, pelas oportunidades e pelo aprendizado com os erros e momentos difíceis. A meus pais, familiares e amigos agradeço pelo amor, carinho, exemplos, conselhos, amizade e ajuda.

Agradeço à minha esposa Marcella e à minha filha Lorena pelo grande amor, carinho e amizade incondicionais e que sempre buscarei retribuir de igual forma. Agradeço a Deus por me presentear com minha segunda filha, a pequena Beatriz, com a qual construirei mais um laço de amor.

Agradeço ao professor Seixas, meu orientador, pela sua figura paterna, pela sua paciência para ensinar e orientar e por sempre acreditar mais em mim do que eu mesmo, de igual modo a todos os orientadores e professores que tive até então. Agradeço aos integrantes do LPS e LabSonar pelo companheirismo, em especial ao Natanael e Venâncio, amigos que foram essenciais para que eu chegasse até aqui.

Ao pessoal da Marinha do Brasil, em especial, ao pessoal do IPqM, agradeço meus chefes pela oportunidade dada e aos meus pares e subordinados por dividirem o fardo do trabalho a bordo comigo, possibilitando minha dedicação aos estudos. Ao pessoal da Força de Submarinos, agradeço pelas inúmeras oportunidades de embarque nos submarinos e adestramentos no CIAMA, locais onde tive o privilégio de aprender, ao longo de seis anos, sobre as atividades da divisão de Operações de um submarino e, em especial, sobre o trabalho dos Operadores de Sonar. Ao pessoal do CASOP e CIAMA agradeço pelo auxílio na confecção dos dados utilizados neste trabalho.

Em suma, seria impossível a concretização deste trabalho sem a ajuda das senhoras e senhores. A todos, muito obrigado.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

CLASSIFICAÇÃO DE NAVIOS COM USO DE SINAIS DE SONAR PASSIVO

Gustavo Augusto Mascarenhas Goltz

Março/2019

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

A classificação de navios através do seu ruído acústico irradiado no mar é uma das tarefas essenciais realizadas a bordo de um submarino. Diversos classificadores de ruído de navios têm sido propostos na literatura, porém nenhum deles tem enfoque operacional, principalmente em relação aos dados utilizados e à significativa quantidade de classes que ocorre num ambiente operativo. Além da contribuição acadêmica de desenvolver um classificador mais próximo da realidade de um submarino, este trabalho também atende a uma das demandas do desenvolvimento do submarino nuclear brasileiro, um classificador autóctone. São abordados quatro classificadores: uma rede neural do tipo Perceptron de Múltiplas Camadas, um comitê de classes especialistas composto por redes neurais, um comitê de classes especialistas composto por Máquinas de Vetor de Suporte e um comitê de redes neurais dispostas hierarquicamente, construído com base em conhecimento especialista em navios. A Análise de Componentes Principais de Discriminação foi empregada no treinamento dos classificadores. Foram utilizados dois banco de dados experimentais: um oriundo de gravações de sinais acústicos coletados de sonares passivos de submarinos em operação (contendo 24 classes) e outro oriundo de gravações de sinais acústicos coletados de um sonar passivo monitorando tráfego marítimo numa região portuária (contendo 31 classes).

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

SHIP CLASSIFICATION USING PASSIVE SONAR SIGNALS

Gustavo Augusto Mascarenhas Goltz

March/2019

Advisor: José Manoel de Seixas

Department: Electrical Engineering

The classification of ships by their acoustic noise radiated at sea is one of the essential tasks carried out on board of a submarine. Several ship classifiers have been proposed in the literature, but none of them has an operative focus, mainly in relation to the data used, and the significant number of classes that occur in an operating environment. In addition to the academic contribution of developing a classifier closer to the reality of a submarine, this work also meets one of the demands of the development of the Brazilian nuclear submarine, an autochthonous classifier. Four classifiers are designed: multilayer perceptron (MLP), class expert committees (one based on MLP and other based on Support Vector Machines - SVM) and a hierarchical committee which is built up on expert knowledge on vessels. The input data dimensionality reduction is performed through the Principal Components of Discrimination. The classifiers were applied to two experimental databases: one from recordings of acoustic signals collected from passive sonars of submarines in operation (with 24 classes) and another from recordings of acoustic signals collected from a sonar passive platform monitoring the maritime traffic in a port region (with 31 classes).

Sumário

Lista de Figuras	x
Lista de Tabelas	xiii
Lista de Símbolos	xiv
Lista de Abreviaturas	xv
1 Introdução	1
2 Sistema de Sonar e Classificação de Navios	6
2.1 Sistemas de Sonar	6
2.2 Classificação Realizada por um Operador de Sonar	10
2.3 Desenvolvimentos na Classificação Automática de Navios em Sonar Passivo	14
3 Máquinas de Comitê	20
4 Método	27
4.1 Pré-Processamento dos Sinais	27
4.2 Compactação dos Sinais	28
4.3 Rede Neural do Tipo MultiLayer Perceptron	29
4.4 Comitê de Classes Especialistas	29
4.5 Comitê Hierárquico	31
4.5.1 A Hierarquia de Classes na Análise dos Resultados	33
5 Resultados	35
5.1 Conjuntos de Dados Utilizados	35
5.2 Figuras de Mérito	37
5.2.1 Resultados para a Rede Neural do tipo MultiLayer Perceptron	39
5.2.2 Resultados para o Comitê de Classes Especialistas com MLP .	40
5.2.3 Resultados para o Comitê de Classes Especialistas com Máquinas de Vetores de Suporte	44

5.2.4	Resultados para o Comitê Hierárquico	45
5.2.5	Síntese dos Resultados e Análise Hierárquica	47
6	Discussão, Conclusões e Trabalhos Futuros	56
6.1	Discussão	56
6.2	Conclusões	58
6.3	Trabalhos Futuros	60
	Referências Bibliográficas	62

Lista de Figuras

2.1	O ruído no mar. Ilustração com uso autorizado.	7
2.2	Sonar ativo de casco usado em navios para caça de submarinos. Em detalhe, seu arranjo cilíndrico de transdutores.	7
2.3	Sonar ativo rebocado usado em navios para caça de submarinos.	8
2.4	Os sonares presentes em um submarino militar.	9
2.5	LOFAR (abaixo) e lofargrama (acima).	11
2.6	DEMON (abaixo) e demongrama (acima).	12
2.7	Processo de classificação de um contato por um operador de sonar.	13
4.1	Pré-processamento dos sinais dos navios.	28
4.2	Comitê hierárquico para as 24 classes provenientes das gravações do Sonar de submarino.	32
4.3	Comitê hierárquico para as 31 classes provenientes do VIPP.	32
5.1	VIPP e seu arranjo semi elíptico de <i>staves</i>	36
5.2	Distribuição dos exemplos do conjunto de dados de 24 classes entre os 10 <i>fold</i> s criados.	38
5.3	Distribuição dos exemplos do conjunto de dados de 31 classes entre os 10 <i>fold</i> s criados.	39
5.4	Índices SP médios para diversas quantidades de neurônios na camada oculta da MLP, para o conjunto de dados de 24 classes.	40
5.5	Eficiências médias da MLP com 150 neurônios na camada oculta para as 24 classes.	40
5.6	Índices SP médios para diversas quantidades de neurônios na camada oculta da MLP, para o conjunto de dados de 31 classes.	41
5.7	Eficiências médias da MLP com 200 neurônios na camada oculta para 31 classes.	41
5.8	Índices SP médios e seus desvios-padrões para cada especialista do comitê de classes especialistas MLP, calculados como valor médio para cada <i>fold</i> de treinamento, para 24 classes.	42

5.9	Eficiências médias e seus desvios-padrões do Comitê de Classes Especialistas MLP para o conjunto de dados de 24 classes.	42
5.10	Índices SP médios e seus desvios-padrões para cada especialista do comitê de classes especialistas MLP, calculados como valor médio para cada <i>fold</i> de treinamento, para 31 classes.	43
5.11	Eficiências médias e seus desvios-padrões do Comitê de Classes Especialistas MLP para o conjunto de dados de 31 classes.	44
5.12	SP médios para os valores de C usados no processo de treinamento das SVM, para ambos os conjuntos de dados.	44
5.13	Quantidade de Vetores de Suporte para cada especialista do comitê de SVM, para o conjunto de dados de 24 e 31 classes.	45
5.14	Eficiências médias e seus desvios-padrões do Comitê de Classes Especialistas SVM para o conjunto de dados de 24 classes.	45
5.15	Eficiências médias e seus desvios-padrões do Comitê de Classes Especialistas SVM para o conjunto de dados de 31 classes.	46
5.16	Variação do índice SP em função da quantidade de neurônios para cada membro do comitê hierárquico, calculados como valor médio para cada <i>fold</i> de treinamento para 24 classes.	47
5.17	Índices SP médios e seus desvios-padrões para cada membro do comitê hierárquico, calculados como valor médio para cada <i>fold</i> de treinamento para 24 classes.	48
5.18	Eficiências médias e seus desvios-padrões do Comitê Hierárquico para o conjunto de dados de 24 classes.	48
5.19	Variação do índice SP em função da quantidade de neurônios para cada membro do comitê hierárquico, calculados como valor médio para cada <i>fold</i> de treinamento para 31 classes.	49
5.20	Índices SP médios e seus desvios-padrões para cada membro do comitê hierárquico, calculados como valor médio para cada <i>fold</i> de treinamento para 31 classes.	49
5.21	Eficiências médias e seus desvios-padrões do Comitê Hierárquico para o conjunto de dados de 31 classes.	50
5.22	Classes estimadas pela MLP com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.	51
5.23	Classes estimadas pelo comitê de especialistas MLP com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.	51

5.24	Classes estimadas pelo comitê de especialistas SVM com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.	52
5.25	Classes estimadas pelo comitê Hierárquico com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.	52
5.26	Classes estimadas pela MLP com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.	53
5.27	Classes estimadas pelo comitê de especialistas MLP com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.	53
5.28	Classes estimadas pelo comitê de especialistas SVM com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.	54
5.29	Classes estimadas pelo comitê Hierárquico com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.	54

Lista de Tabelas

5.1	Quantidades de janelas para cada classe de navios do conjunto de dados proveniente de submarino.	37
5.2	Quantidades de janelas para cada classe de navios do conjunto de dados proveniente do VIPP.	37
5.3	Topologias com melhores SP médios para cada especialista para o conjunto de dados com 24 classes.	41
5.4	Topologias com melhores SP médios para cada especialista para o conjunto de dados com 31 classes.	43
5.5	Índices SP médios (e seus desvios padrões) para cada classificador abordado para cada conjunto de dados (24 e 31 classes).	48
5.6	Maiores confusões produzidas pelos classificadores. O valor de confusão é a razão entre o número de exemplos confundidos com determinada classe e o número de exemplos da classe esperada.	50
5.7	Análise hierárquica das classes 13 (do conjunto de 24 classes) e 16 (do conjunto de 31 classes) e suas respectivas eficiências de classificação para cada classificador. FPIP: razão entre o número de Falsos Positivos de Irmãs e Primas e o número de falsos positivos totais para a classe em análise.	55

Lista de Símbolos

\mathbb{R}	conjunto dos números reais, p. 21
C	Parâmetro de penalidade usado no treinamento de uma SVM, p. 30
Hz	Hertz, p. 18
KHz	1000 Hz, p. 18
dB	decibel, p. 17

Lista de Abreviaturas

AKC	<i>Adaptive Kernel Classifier</i> , p. 14
ART	<i>Adaptive Resonance Theory</i> , p. 14
BAGGING	<i>Bootstrap AGGREGatING</i> , p. 23
CHA	<i>Cylindrical Hull Array</i> , p. 8
CNC-N	Classe e Não Classe Normalizada, p. 20
CODOG	<i>Combined Diesel or Gas</i> , p. 56
DECORATE	<i>Diverse Ensemble Creation by Oppositional Relabeling of Artificial Training Examples</i> , p. 24
DEMON	<i>DEModulation On Noise</i> , p. 10
DNN	<i>Deep Neural Network</i> , p. 25
DWT	<i>Discrete Wavelet Transform</i> , p. 14
EB	Exército Brasileiro, p. 1
EQM	Erro Quadrático Médio, p. 21
FAB	Força Aérea Brasileira, p. 1
FA	<i>Flank Array</i> , p. 8
FFAA	Forças Armadas, p. 1
FFT	<i>Fast Fourier Transform</i> , p. 15
GHA	<i>Generalized Hebbian Algorithm</i> , p. 14
GPS	<i>Global Positioning System</i> , p. 1
ICA	<i>Independent Component Analysis</i> , p. 16
KNN	<i>K-Nearest Neighbor</i> , p. 17

L-SML	<i>Latent Spectral Meta Learner</i> , p. 26
LOFAR	<i>LOw Frequency Analysis and Recording</i> , p. 10
MB	Marinha do Brasil, p. 1
MFFC	<i>Mel-Frequency Cepstral Coefficient</i> , p. 18
MLP	<i>MultiLayer Perceptron</i> , p. 14
NLPCA	<i>NonLinear Principal Component Analysis</i> , p. 14
OS	Operador de sonar, p. 3
PARAFAC	<i>PARAllel FACTor analysis</i> , p. 17
PCA	<i>Principal Component Analysis</i> , p. 14
PCD	<i>Principal Component Discrimination</i> , p. 14
PNN	<i>Probabilistic Neural Network</i> , p. 17
PROSUB	PROgrama de desenvolvimento de SUBmarinos, p. 1
PRS	<i>Passive Ranging Sonar</i> , p. 8
RBF	<i>Radial Basis Function</i> , p. 17
RBM	<i>Restricted Boltzmann Machine</i> , p. 25
RNA	Rede Neural Artificial, p. 3
RPM	Rotação Por Minuto, p. 10
SDAC	Sistema de Detecção, Acompanhamento e Classificação de Contatos, p. 34
SIR	<i>Signal-to-Interference Ratio</i> , p. 16
SNR	<i>Signal-to-Noise Ratio</i> , p. 16
SOM	<i>Self Organizing Map</i> , p. 15
SONAR	<i>SOund NAVigation and Ranging</i> , p. 2
SP	Soma-Produto, p. 16
SVM	<i>Suport Vector Machine</i> , p. 14
SisGAAz	Sistema Gerenciamento da Amazônia Azul, p. 3

TPSW	<i>Two-Pass Split Window</i> , p. 14
UFRJ	Universidade Federal do Rio de Janeiro, p. 2
USP	Universidade de São Paulo, p. 2
VIPP	Vigilância e Informações Passivas em Portos, p. 3

Capítulo 1

Introdução

Num cenário de conflito, a superioridade tecnológica de uma força em relação a sua oponente traz enorme vantagem, de tal modo que manter esta superioridade é uma constante preocupação das maiores forças militares mundiais [1][2].

Não só a superioridade tecnológica é importante, mas também o domínio da tecnologia empregada pela força, o que não ocorreu, por exemplo, no uso de mísseis franceses pelos argentinos na Guerra das Malvinas, onde os ingleses obtiveram conhecimento técnico dos franceses para sabotar mísseis Exocet argentinos, segundo o então Secretário de Defesa britânico na época do conflito [3]. Outro exemplo é a atual utilização em diversas armas, aeronaves, navios e carros de combate, de vários países, do Sistema de Posicionamento Global, ou *Global Positioning System* (GPS), de poder norte americano, cujo sinal pode ser negado inopinadamente.

As Forças Armadas (FFAA) brasileiras têm buscado, ao longo dos anos, o domínio de tecnologias, consideradas pelas FFAA como de maior importância [4]: propulsão nuclear em submarinos, por parte da Marinha do Brasil (MB), o domínio do ambiente cibernético, por parte do Exército Brasileiro (EB), e o desenvolvimento e construção de satélites e seus veículos lançadores, por parte da Força Aérea Brasileira (FAB).

Uma excelente forma de dissuasão de forças inimigas, num cenário marítimo, é a presença de submarinos neste cenário, devido à característica de discrição destes. Um submarino nuclear possui maior capacidade de discrição que um submarino convencional, pois a propulsão nuclear não necessita de oxigênio, logo, o submarino não necessita expor-se à superfície para abastecer-se de oxigênio. Estes e outros fatores levaram a MB a optar pelo uso de submarinos (convencionais e nucleares) para defesa da Amazônia Azul [4], termo utilizado para referenciar a área marítima sob jurisdição brasileira. O desenvolvimento e construção de submarinos convencionais e nucleares brasileiros estão a cargo do PROSUB: Programa de Desenvolvimento de Submarinos, da MB [4].

Neste contexto, o domínio das várias áreas do conhecimento empregadas no de-

envolvimento e construção de um submarino nuclear brasileiro torna-se necessário, desde o enriquecimento de urânio empregado como combustível, o desenvolvimento de seu reator, casco, armamento, sensores, até as necessidades logísticas como, por exemplo, uma base naval específica que atenda a um submarino nuclear, entre muitos outros fatores necessários.

A complexidade de se dominar as tecnologias ligadas a um submarino nuclear torna esta tarefa um esforço que ultrapassa as competências da MB, o que a levou a buscar parceiros, como as Universidades, Centros de Pesquisa e Empresas, no Brasil e no exterior e, no segundo caso, com a busca pela transferência de tecnologia ao Brasil.

Dentre as tecnologias ligadas ao submarino nuclear, destaca-se a importância de seus sensores, imprescindíveis para o emprego do submarino. Como este opera quase a todo momento abaixo d'água, seu principal sensor é o sonar (*Sound Navigation and Ranging*) que utiliza, como princípio de funcionamento, a propriedade da propagação do som na água [5].

A propagação do som na água, oriundo de uma fonte sonora, já havia despertado interesse em Leonardo da Vinci [6]. O emprego de submarinos dotados de sonar se deu na Primeira Guerra Mundial, porém bastante limitado em relação às frequências de operação e distância de detecção de alvos [6]. Desde então, sonares de emprego militar, instalados em navios e submarinos, têm sido aperfeiçoados.

No Brasil, um trabalho pioneiro na área de sonar foi realizado pelo físico brasileiro Marcelo Damy de Souza Santos, durante o esforço de guerra brasileiro na Segunda Guerra Mundial. Seu trabalho na USP (Universidade de São Paulo) durante a guerra foi desenvolver e equipar navios brasileiros com um sonar ativo¹, com intuito de proteger, no Atlântico Sul, a frota mercante aliada dos submarinos alemães [7].

Pesquisas nas áreas de interesse em sistemas de sonar, principalmente em propagação acústica no mar, instrumentação e processamento de sinais, têm sido realizadas entre a MB e a Universidade Federal do Rio de Janeiro (UFRJ) há décadas. Como exemplos de trabalhos conjuntos: desenvolvimento de projetos na área de instrumentação oceanográfica por UCHÔA [8], estudos em conformação de feixes para arranjos de sensores acústicos submarinos por NUNES DE MOURA [9] e FELZKY [10], propagação de sinais sonar por VIEIRA DE MATTOS [11], comunicações submarinas por sinais acústicos por VERAS CARDOSO [12], classificação de sinais em sonar por SOARES FILHO [13], DAMAS PAULA [14] e OLIVEIRA E SOUZA e SEIXAS [15], entre inúmeros outros trabalhos.

A tecnologia sonar tem emprego dual, ou seja, é utilizada no meio militar e civil, e neste último, também tem grande importância. Como exemplos temos os sona-

¹Tipo de sonar que emite um sinal acústico no meio e utiliza o eco deste sinal para localizar submarinos, no caso de emprego militar.

res de pesca, ecobatímetros (equipamentos utilizados para calcular a profundidade local), sonares de varredura (para exploração do leito de marinho e de rios para localização de naufrágios, exploração mineral, levantamento de perfis batimétricos, entre outras aplicações), sonares para monitoramento de atividade sísmica, equipamentos de ultrassom utilizados na medicina, perfiladores acústicos para levantamento de correntes marinhas ou de rios, sonares utilizados em comunicações submarinas, etc.

Também faz parte de uma das atribuições da Marinha do Brasil [4] o controle e segurança do tráfego marítimo nas águas jurisdicionais brasileiras. Para viabilizar esta tarefa, a MB buscou desenvolver o SisGAAz (Sistema de Gerenciamento da Amazônia Azul). Este sistema necessita de diversos sensores para detecção e acompanhamento das embarcações presentes na região monitorada. Este monitoramento não somente é realizado por sensores de superfície (radares e imagens de satélite, por exemplo) mas também pode ser realizado por sensores que operam abaixo d'água, no caso, com uso de sonares. A fim de atender esta necessidade, o IPqM desenvolveu o projeto VIPP (Vigilância e Informações Passivas em Portos), capaz de detectar e acompanhar navios através dos seus ruídos acústicos coletados por um sonar passivo.

Por ser uma tecnologia restrita ao público, para preservação da segurança nacional e propriedade industrial, trabalhos científicos aplicados a sistemas de sonar, voltados para emprego militar, são pouco divulgados e, em certas áreas, o conhecimento do estado da arte mundial torna-se difícil. Este fato tem motivado a MB a fomentar o desenvolvimento destas tecnologias. Uma delas é a classificação de navios, através do seu ruído sonoro propagado no mar, detectado pelo sonar de um submarino.

É natural do ser humano a busca pela automatização de suas tarefas. Desde os primeiros sistemas de sonar militares, a tarefa de classificação sempre foi essencial e, até hoje, quase que na totalidade das marinhas, esta tarefa é realizada pela análise humana associada a ferramentas de classificação automáticas.

Inicialmente, para classificação em um sonar passivo², apenas o áudio do sinal sonoro detectado pelo sonar era analisado pelo Operador de sonar (OS). Ao longo do tempo, foram exploradas características espectrais e ferramentas para visualização destas características (abordadas no Capítulo 2). A exploração do espectro do sinal fomentou diversas pesquisas na área de processamento de sinais para sonar e classificação em sonar.

Para a tarefa de classificação, de um modo geral, o emprego de Redes Neurais Artificiais (RNA) tem obtido grande êxito. Assim como o cérebro humano, as RNA trabalham de forma não linear, em aplicações de alta complexidade e de forma paralela [16]. Logo, são indicadas para o problema de classificação e reconhecimento de padrões em sonar. O desenvolvimento da computação nas últimas

²sonar que não emite sinal, apenas monitora os sinais presentes no meio aquoso.

décadas e maior disponibilidade de recursos computacionais viabilizaram seu emprego em vários problemas da sociedade, como o desenvolvimento de previsores, classificadores e sistemas de controle. A área de classificação em sonar não foi diferente, como apresentado no Capítulo 2. Hoje a classificação em sonar passivo encontrada na literatura está longe da realidade de um submarino, com trabalhos empregando poucas classes no desenvolvimento do problema e/ou com o uso de dados de origem sintética ou coletados em raia acústica, num ambiente controlado e de baixa profundidade.

A dificuldade em adquirir dados para o desenvolvimento de soluções mais próximas das necessidades de um submarino também é uma realidade. Uma das contribuições deste trabalho é a confecção de um banco de dados experimentais que represente a realidade operativa de um submarino, com muito mais classes disponíveis, quando se consideram os trabalhos encontrados na literatura, e que é composto por sinais de navios atualmente em operação. Além disso, este banco de dados é totalmente composto por gravações coletadas via sonar dos atuais submarinos da MB, navegando submersos em águas profundas, com os navios sendo gravados também em regime operativo. Além deste banco de dados, construiu-se um segundo, com sinais coletados pelo VIPP na baía da Guanabara, no Rio de Janeiro. Este segundo banco de dados possibilita o desenvolvimento de classificadores voltados para o monitoramento do tráfego marítimo em águas rasas, tanto de navios civis quanto militares. Outra contribuição é a aplicação do modelo de classes especialistas desenvolvido por OLIVEIRA E SOUZA e SEIXAS [15] com os novos dados coletados, bem como uma comparação deste com outros três classificadores, sendo um deles tratando-se de um novo modelo proposto, com uma organização hierárquica das classes. Este novo classificador associa conhecimento especialista a uma máquina comitê, como descrito no Capítulo 4. Além de ser empregado para classificação, o modelo proposto também pode ser utilizado como análise de resultados de classificação, como também descrito no Capítulo 4.

No Capítulo 4, foi empregado o conceito de Máquina de Comitê [17] em três modelos de classificadores, dois deles do tipo comitê de classes especialistas e outro utilizando conhecimento especialista para agrupar as classes em diversos classificadores integrados de forma hierárquica, conceito até então não empregado ao problema de classificação de navios em sonar passivo. Estes modelos buscaram atacar os problemas de alta dimensionalidade dos dados, grande presença de ruído, significativa quantidade de classes e desconhecimento da distribuição estatística dos dados, características presentes no problema abordado neste trabalho. Além três dos comitês, uma MLP também foi utilizada para os mesmos fins.

Os objetivos deste trabalho foram:

- Desenvolvimento de classificadores autóctones para: 1) os atuais e futuros sub-

marinos da Marinha do Brasil, em especial ao submarino de propulsão nuclear, o qual deverá possuir o maior grau possível de nacionalização, a fim de garantir seu pleno funcionamento e poder dissuasório, de forma mais independente possível de outras nações; e 2) o SisGAAz, ferramenta imprescindível para a classificação de navios, com uso de sinais acústicos submarinos, na tarefa de monitoramento do tráfego marítimo dos portos brasileiros.

- Criação de dois bancos de dados de gravações de ruído de navios, respectivamente para aplicação no desenvolvimento de classificadores para submarinos e sistemas de monitoramento de tráfego marítimo, focados nas necessidades operativas de ambas as tarefas.
- Proposta de um modelo para classificação e análise de resultados de classificação baseado na hierarquia de classes construída em função do conhecimento especialista em navios.
- Aplicação de quatro modelos de classificação nos conjuntos de dados gerados e análise de seus resultados.

A organização dos capítulos deste trabalho está da seguinte maneira: o Capítulo 2 aborda o funcionamento de um sistema de sonar de um submarino e a tarefa de classificação dos sinais detectados por ele, juntamente com uma revisão bibliográfica mais aprofundada sobre o assunto, mostrando que as atuais necessidades da MB não estão contempladas nestes trabalhos. No Capítulo 3, é realizada uma revisão bibliográfica das atuais ferramentas de classificação com potencial emprego ao problema de classificação em sonar passivo, na área de Máquinas de Comitê. No Capítulo 4, é apresentado o método utilizado para implementação dos quatro classificadores abordados neste trabalho. No Capítulo 5, são apresentados os dados utilizados e os resultados. Por fim, o Capítulo 6 inicia-se com uma discussão dos resultados, conclusões e também são elencados os trabalhos futuros.

Capítulo 2

Sistema de Sonar e Classificação de Navios

Um classificador de sinais de sonar é uma ferramenta integrante do sistema de sonar. Para a contextualização deste trabalho, faz-se necessária a apresentação do sonar, primeiramente num aspecto geral e depois com foco nos sonares presentes nos submarinos. Após esta apresentação, é abordada a forma como o operador sonar (OS) realiza a classificação de um navio com uso de ferramentas presentes no sistema de sonar passivo de submarinos. Por último, é realizada uma revisão bibliográfica sobre desenvolvimentos de classificadores de sinais de sonar, onde fica clara a falta de desenvolvimento de trabalhos publicados que atendam à demanda de um classificador a ser empregado no ambiente operativo de submarinos.

2.1 Sistemas de Sonar

Existem diversos tipos de sistemas de sonar, projetados para aplicações militares, civis ou duais (militares e civis). No campo civil, como exemplo, tem-se os sonares de varredura lateral (*side scan*), utilizados para mapeamento do fundo oceânico, sonares de pesca para localização de cardumes, sonares rebocados, que são aplicados em lavantamentos geológicos do fundo e subfundo de oceanos, entre outros [18].

Um sistema de sonar se diz “ativo” quando este emite um sinal acústico no meio aquoso e utiliza-se do eco deste sinal para realizar sua tarefa (localizar um submarino, um cardume de peixes, mapear o fundo oceânico, entre outras tarefas). Um sistema de sonar se diz “passivo” quando não emite sinal acústico, apenas utiliza o ruído do ambiente aquoso para realizar sua tarefa (exemplo: sonares de monitoramento de tráfego marítimo e sonares de submarinos). Este ruído é formado com a contribuição de várias fontes de sinal acústico, como navios, vida marinha, zonas de arrebentação de ondas, plataformas marítimas de petróleo, entre outras

fontes. A Figura 2.1 [19] ilustra as diferentes fontes de sinal acústico presentes nos oceanos, com suas respectivas faixas de frequência e níveis de ruído.

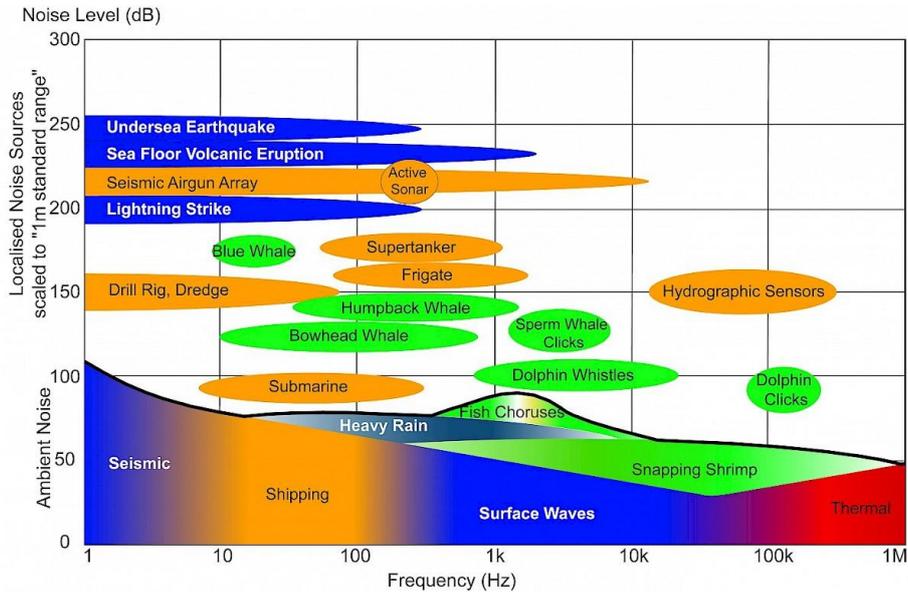


Figura 2.1: O ruído no mar. Ilustração com uso autorizado.

Um sistema de sonar comum em aplicações militares é o ativo, utilizado em navios que são empregados na caça de submarinos. Em geral, estes sonares são instalados em um bulbo abaixo do casco (Figura 2.2), composto internamente de um arranjo cilíndrico de transdutores [5].



Figura 2.2: Sonar ativo de casco usado em navios para caça de submarinos. Em detalhe, seu arranjo cilíndrico de transdutores.

Sonares ativos empregados em caça de submarinos também possuem versões rebocadas (Figura 2.3), que podem explorar diferentes profundidades com o intuito de buscar melhores canais de propagação do som na água [6], além da vantagem deste tipo de sonar receber menor influência do ruído acústico do seu próprio navio.

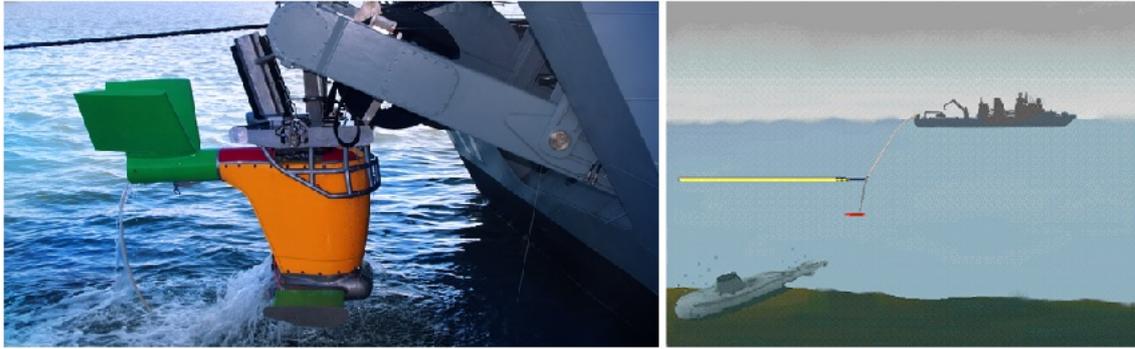


Figura 2.3: Sonar ativo rebocado usado em navios para caça de submarinos.

Outro sistema de sonar de uso militar é o utilizado em submarinos, o qual é de interesse deste trabalho. Uma vez submerso, este sistema é o principal sensor do submarino, pois os demais sensores (ópticos e eletromagnéticos) tornam-se ineficientes abaixo d'água [18]. O sistema de sonar de um submarino militar possui uma série de sonares (ou arranjos de sensores) empregados em diversas tarefas, sendo que quase todos eles operam no modo passivo, com o intuito de preservar a discrição do submarino na área de operação. Uma vez emitindo um sinal acústico, o submarino pode ser facilmente detectado por um sonar de um navio de superfície.

Na Figura 2.4, estão representados os principais sonares de um submarino, e cada um será abordado adiante. Um deles é o sonar cilíndrico, ou *cylindrical hull array* (CHA), localizado na proa do submarino. Este sonar possui seus hidrofones dispostos em um arranjo cilíndrico, trabalha no modo passivo e suas principais funções são: detecção de contatos (navios) e acompanhamento destes contatos (*tracking*). Alguns submarinos possuem um sonar esférico ao invés de um cilíndrico, com intuito de cobrir um maior espaço (ou volume) de monitoramento.

Nas duas laterais do submarino estão seus sonares de flanco, ou *flank array* (FA) [20]. São passivos e, devido ao seu comprimento, detectam contatos a distâncias maiores ¹ que o sonar cilíndrico, porém este possui maior ângulo de cobertura que o FA, que é plano.

Ainda nas duas laterais do submarino, encontram-se os sonares de medição passiva de distância de contatos, ou *passive ranging sonar* (PRS). Como seu nome diz, são passivos. Devido à grande distância entre seus sensores (em relação aos outros sonares do submarino), é possível estimar uma distância entre o contato e o submarino através de algoritmos baseados em triangulação.

Alguns submarinos utilizam um sonar passivo rebocado, ou *Towed Array* [20]. Este tipo de sonar tem duas grandes vantagens em relação aos demais sonares do

¹Quanto maior a dimensão de um arranjo de hidrofones, melhor será a relação sinal-ruído alcançada pelo formador de feixes, para frequências com maiores comprimentos de onda. Quanto maior o comprimento de onda de um sinal acústico, maior será sua distância de propagação. [6]

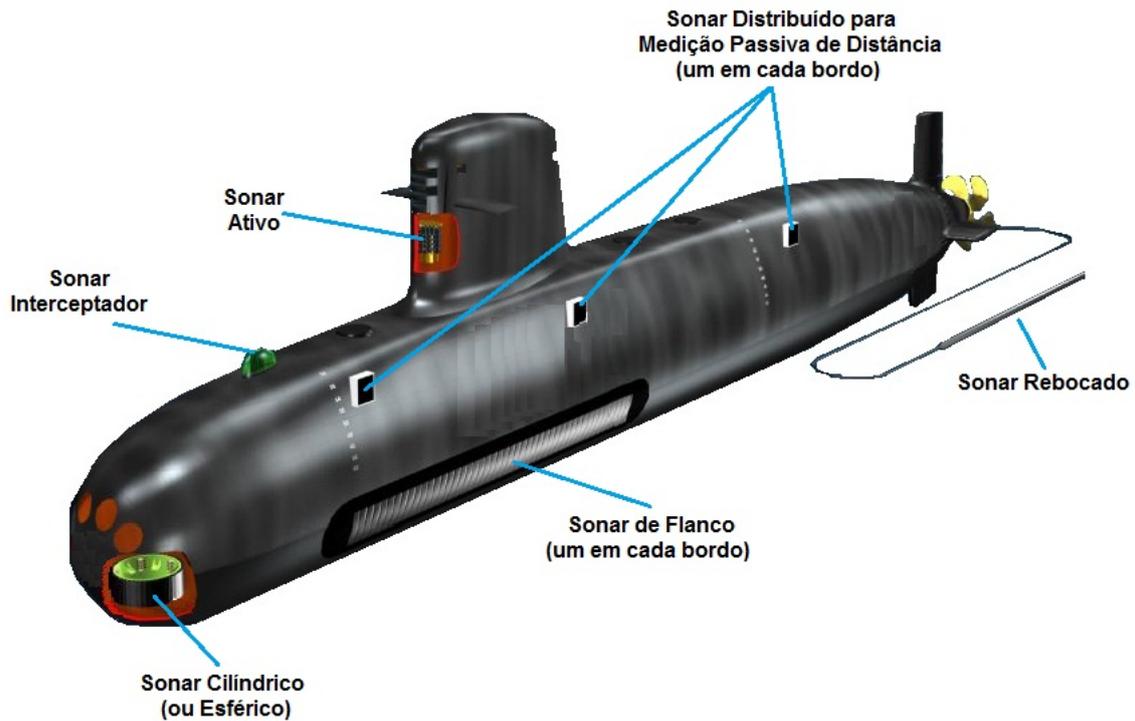


Figura 2.4: Os sonares presentes em um submarino militar.

submarino:

1. Por ser rebocado, possui seus hidrofones afastados do submarino, assim o ruído acústico proveniente do próprio submarino, chamado de ruído próprio, interfere menos no sinal recebido, se comparado aos outros sonares fixados diretamente no submarino. Estes sonares ficam mais próximos dos ruídos provenientes da propulsão e máquinas auxiliares, do arrasto hidrodinâmico do casco e ocasionais cavitações² de saliências do casco e/ou dos hélices;
2. Por possuir um comprimento maior (na ordem de centenas de metros), o sonar passivo rebocado possui maior diretividade [5] para frequências da ordem de dezenas de Hertz em comparação com os demais sonares do submarino, logo, detecta contatos a distâncias muito maiores que outros sonares.

Apesar destas vantagens, nem sempre os submarinos têm um sonar rebocado, pois seu uso restringe a manobrabilidade e operação do submarino (guinadas, velocidade, consumo, profundidade de operação, entre outros fatores).

Na parte superior da proa de um submarino, conforme Figura 2.4, encontra-se o sonar interceptador, ou *intercept sonar*. Este sonar detecta sinais acústicos emitidos por sonares ativos de navios, em busca de submarinos. O *intercept sonar* pode gerar

²Cavitação é a implosão de bolhas de vapor d'água formadas pela diferença de pressão num fluido em escoamento [21]

alertas para o submarino e também pode extrair características do sinal detectado, como faixa de frequência, intensidade do sinal, duração do pulso no tempo, entre outras características.

O submarino também possui um sonar ativo, ou *active sonar*, localizado geralmente no interior de sua vela, como pode ser visto na Figura 2.4. Este sonar somente é utilizado na fase de disparo de torpedo, quando o sistema de combate do submarino necessita de uma distância precisa entre ele e o alvo. É raramente utilizado, pois seu uso pode revelar a presença do submarino na área.

Alguns outros exemplos de sistemas de sonar de emprego militar ou dual são: sistemas de monitoramento (passivo e/ou ativo) de áreas portuárias, sistemas de sonar ativo de torpedos, sistemas sonar empregados na navegação de veículos subaquáticos, sistemas de comunicação submarina, sonares ativos arriados de helicópteros, sonobóias, entre outros.

O profissional que opera o sistema de sonar de um submarino é chamado de operador de sonar (OS). Este realiza diversas tarefas, dentre elas, a classificação dos contatos detectados pelo sonar. A seguir, é descrito como esta tarefa é realizada por este militar.

2.2 Classificação Realizada por um Operador de Sonar

Em sistemas de sonar de submarinos, em geral, o OS, após a detecção de um contato pelo sonar, faz o seu acompanhamento, analisa o sinal acústico oriundo deste contato, observa seu comportamento e, então, infere uma possível classificação, após um compilamento mental de uma série de informações estimadas deste contato, oriundas dos diversos sonares presentes no submarino e apresentadas de diversas formas ao OS.

Na fase de acompanhamento, o OS, num primeiro momento, faz a análise do áudio produzido pelo contato, o qual é detectado pelos sensores acústicos do sonar. Na análise de áudio, o OS pode estimar (ou não): a rotação por minuto (RPM) do hélice propulsor do contato, identificar a presença de turbina ou inferir um simples motor diesel, em relação à propulsão do contato, entre muitas outras características.

Num segundo momento, o OS faz as análises espectrais do sinal acústico oriundo do contato. As principais análises espectrais são as análises LOFAR (*LOw Frequency Analysis and Recording*) e DEMON (*DEModulation On Noise*).

A análise LOFAR trata da representação do sinal no domínio da frequência, num gráfico cartesiano onde as abcissas representam as frequências, em toda faixa de operação do sonar (banda larga), e as ordenadas representam as amplitudes dessas

frequências. O comportamento no tempo, das amplitudes das frequências analisadas, pode ser acompanhado no lofargrama, onde as abcissas são as frequências, as ordenadas são o tempo e as amplitudes são representadas numa escala de cor. Na Figura 2.5 há um exemplo de ambas as representações gráficas.

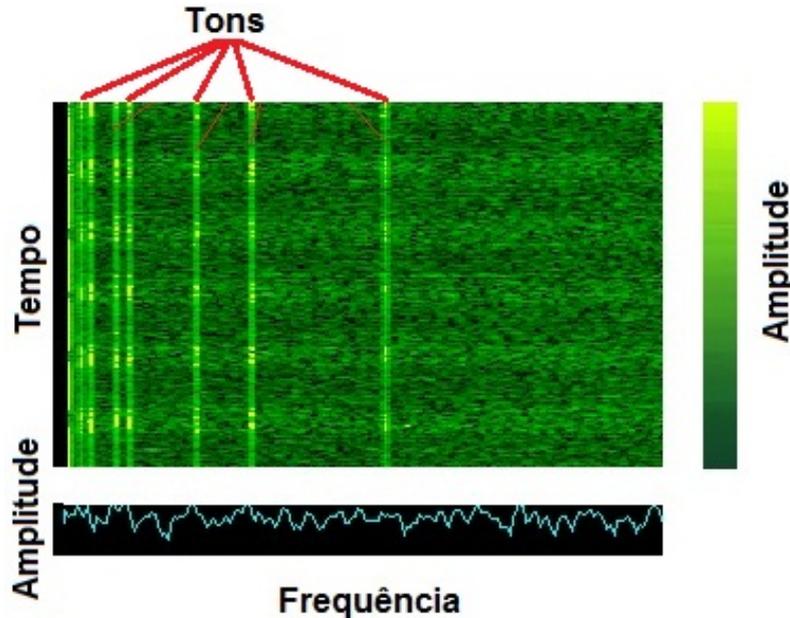


Figura 2.5: LOFAR (abaixo) e lofargrama (acima).

No lofargrama, as frequências cujas amplitudes se mantêm com valores mais altos em relação às frequências vizinhas, ao longo do tempo, são chamadas frequências de tom (uma linha no lofargrama, como visto na Figura 2.5). O tom está associado a uma fonte de ruído do contato. Por exemplo, um gerador elétrico, dentro do navio, que rotaciona seu eixo a 60 Hz, produz como tom uma linha vertical em 60 Hz no lofargrama; ou um eixo de manivelas do motor a combustão de um navio, em processo de (des)aceleração de sua rotação, produz uma linha diagonal no lofargrama.

Observando os tons e conhecendo possíveis fontes de ruído de um navio, o OS pode inferir, no lofargrama, a presença de máquinas auxiliares do navio (bombas hidráulicas, motores elétricos, geradores elétricos, entre outros), identificar a faixa de frequência de emissões de sonares ativos, identificar a presença de motores diesel, turbinas, propulsão por motores elétricos, quantidade de cilindros de motores a combustão, identificar efeitos transientes (abertura de comportas, acionamento de bombas, içamento/recolhimento de periscópio e/ou esnorquel em submarinos, lançamento de torpedos, entre outros), identificar efeito Doppler devido à aproximação ou afastamento do contato em relação ao submarino, identificar engrenagens redutoras de motores de alta rotação para o eixo propulsor (baixa rotação), entre muitas outras características.

A análise DEMON também é uma representação do sinal acústico proveniente

do contato, no domínio da frequência, porém é realizada uma demodulação do sinal, na faixa de frequência que modula o ruído de cavitação das pás do(s) hélice(s) do navio, ou seja, é uma análise espectral em banda estreita.

Na análise DEMON, o OS pode estimar a quantidade de eixos propulsores do navio, a quantidade de pás e a RPM do(s) eixo(s) propulsor(es). Usualmente a escala das frequências utilizada é o RPM, a fim de facilitar a interpretação por parte do OS. A análise DEMON também possui seu demongrama, a fim de acompanhar o comportamento temporal do espectro. A Figura 2.6 possui um exemplo de DEMON e demongrama.

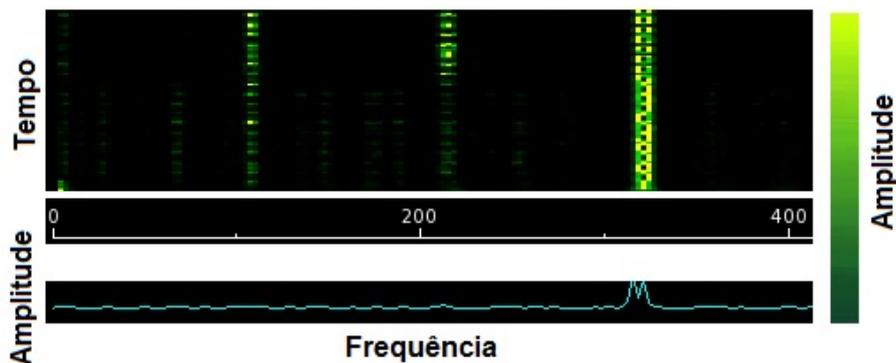


Figura 2.6: DEMON (abaixo) e demongrama (acima).

Estas análises espectrais, além das características extraídas das interpretações dos seus gráficos, também auxiliam o OS a confirmar características inferidas na análise de áudio. O OS faz uma espécie de “jogo” de confirmação de características inferidas em determinada análise em outra análise. As análises são feitas de forma cíclica e não sequencial, ou seja, o OS faz diversas vezes a interpretação do áudio e dos gráficos LOFAR e DEMON.

Para exemplificar este processo, seguem abaixo três situações que comumente ocorrem num processo de classificação de um OS:

- Extrai a RPM na análise de áudio e confirma esta informação na análise DEMON;
- Infere-se na análise DEMON a presença de dois eixos propulsores e confirma esta informação na análise LOFAR;
- Identifica a presença de turbina na análise de áudio (através de som característico) e confirma esta informação na análise LOFAR.

Após alguns minutos de acompanhamento, também é possível inferir algumas características cinemáticas do contato que está sendo acompanhado, como, por exemplo, sua velocidade ou sua taxa de guinada (graus/segundo). Apesar destas características serem estimadas pelo sistema de combate e não pelo sonar, elas também

auxiliam o OS na tarefa de classificação do contato. A Figura 2.7 retrata o processo de classificação feito por um OS.

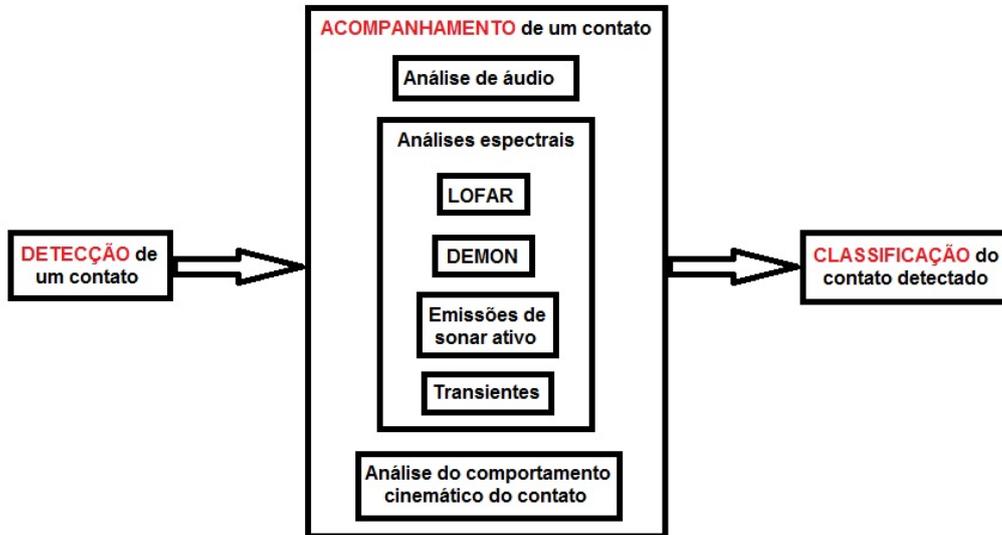


Figura 2.7: Processo de classificação de um contato por um operador de sonar.

Como visto, as principais características espectrais de um contato podem ser estimadas da análise LOFAR. Os tons do lofargrama do sinal acústico de um navio geralmente são associados a sua “assinatura acústica”, porém muitos tons mudam facilmente. Por exemplo, com a mudança da RPM do motor ou com o uso ou não de determinado equipamento a bordo (uma bomba hidráulica, por exemplo). Outros tons são observados em quase todos os navios, como exemplo, os tons de 60 Hz e 400 Hz ligados à geração de corrente elétrica alternada, das respectivas frequências de oscilação. Alguns navios de guerra são dotados de equipamentos para dificultar suas análises espectrais, como exemplo, navios que possuem geradores de cavitação que camuflam a cavitação do(s) hélice(s); navios que possuem hélices de passo controlável, ou seja, podem desenvolver diferentes velocidades para uma mesma rotação do(s) eixo(s) propulsor(es); e plantas propulsoras e máquinas auxiliares de baixíssima produção de ruído.

As diversas análises que o OS necessita realizar, dentro do mínimo intervalo de tempo, e que muitas vezes envolve mais de um contato a ser analisado, torna sua tarefa extenuante, o que pode levar ao cometimento de erros. O desenvolvimento de ferramentas que automatizam o processo de classificação torna-se necessário. A seguir, são apresentados diversos trabalhos da literatura desenvolvidos para classificação em sonar passivo.

2.3 Desenvolvimentos na Classificação Automática de Navios em Sonar Passivo

NEVES JÚNIOR [22] classificou quatro classes de navios, com dados gravados em raia acústica, utilizando uma rede neural MLP (MultiLayer Perceptron) treinada com algoritmo *backpropagation* [16]. Foi considerada uma classe de ruído, contendo sons provenientes do ambiente marinho. Foi feita uma compactação dos dados com uso de *Principal Component Analysis* (PCA) [23], extraída por uma rede neural treinada pelo algoritmo GHA (*Generalized Hebbian Algorithm*) [24]. Foram testadas diversas configurações da MLP e da quantidade de componentes principais utilizadas, sendo os melhores resultados alcançados com uma rede de duas camadas, uma com dez e outra com cinco neurônios e utilizando vinte e uma componentes principais, que atingiu, nos melhores casos, um índice de acerto médio de 92,41% de classificação.

Três classes de barcos de pesca foram classificados por CHIN-HSING *et al.* [25] através de características tonais, extraídas por *Discrete Wavelet Transform* (DWT), da densidade espectral de potência média. Os sinais das embarcações foram coletados em três velocidades diferentes. Após a extração dos atributos, dois tipos de redes neurais foram testadas para classificação: MLP e AKC (*Adaptive Kernel Classifier*). Ambas alcançaram um índice de acerto de 98%. A classificação com uso direto da densidade espectral atingiu 80% como maior índice de acerto.

SOARES FILHO [13] desenvolveu classificadores neurais para um conjunto de sinais de quatro classes de navios, coletados numa raia acústica. Numa fase de pré-processamento, com conhecimento especialista, foram avaliados alguns parâmetros como faixa de frequência a ser utilizada, contendo os tons mais significativos, número de bins do espectro e eliminação do ruído de fundo com o uso do *Two-Pass Split Window* (TPSW) [26]. Após o pré-processamento, foram testados três formas de compactação dos dados: PCA, *NonLinear Principal Component Analysis* (NLPCA) [27] e *Principal Component Discrimination* (PCD) [28]. Foram testadas uma rede neural do tipo MLP e uma rede neural do tipo ART (*Adaptive Resonance Theory*) [29] com o objetivo de avaliar a inclusão de uma nova classe a um sistema já treinado.

O uso de PCD superou os resultados dos demais compactadores. Para a MLP, a eficiência média alcançada foi de 94%, e a ART, com inclusão de uma nova classe (3 classes mais uma), atingiu 63%.

O problema de detecção de uma nova classe, para um classificador de sonar passivo foi abordado por DE MOURA JUNIOR e DE SEIXAS [30]. Foi proposta uma Máquina de Vetores de Suporte (SVM: *Support Vector Machine*) [16] como detector, treinada com classes conhecidas. Após o treinamento, foram apresentadas ao detector classes desconhecidas. Foi utilizado um conjunto de dados contendo

quatro classes e o pré-processamento dos sinais foi semelhante ao utilizado por SOARES FILHO [13] e para compactação dos dados, foi utilizado PCA (por volta de 270 componentes). Foram realizadas quatro situações onde uma das quatro classes correspondia à classe desconhecida. A eficiência de classificação para classes conhecidas variou entre 33,33% e 96,88%, e para eficiência de detecção da classe desconhecida, os resultados variaram entre 72,84% e 87,09%.

HOWELL e WOOD [31] implementaram uma rede neural híbrida para classificação de 12 classes de sinais acústicos submarinos reais, de diversas fontes sonoras (navio, submarino, vocalizações de baleia azul, de orcas, tremor sísmico, entre outros). A rede neural híbrida desenvolvida foi ativada com janelas de tempo do espectrograma, passando primeiro por uma rede SOM (*Self Organizing Map*)[16], cuja saída ativou uma MLP. Testaram-se variações nos parâmetros de intervalo de banda de frequência, número de pontos da FFT (*Fast Fourier Transform*) e tamanho da janela de tempo do espectro, bem como alguns parâmetros no treinamento das redes. Esta rede neural híbrida alcançou, no melhor caso, um índice de acerto médio de 60%, considerando todas as classes (variando entre 44% e 83%).

Uma ferramenta de auxílio ao OS na classificação foi desenvolvida por LOPES DOS SANTOS [32], onde um banco de dados foi populado com informações relacionadas aos tons de oito classes de navios, cujos sinais foram adquiridos em raia acústica e foram pré-processados de semelhante forma utilizada por SOARES FILHO [13]. Para cada classe de navio, foram associados tons extraídos do lofargrama por um especialista (OS). Após a extração, foram calculadas, para cada tom, sua variação em frequência e sua frequência central. Na fase de classificação, os mesmos passos foram feitos e uma consulta ao banco trazia uma ou mais possíveis classes as quais o navio poderia pertencer (visto que alguns tons podem se repetir em classes diferentes), assim como a possibilidade de não pertencer a classe alguma. Dos 28 sinais de teste (diferentes dos sinais usados para povoar o banco), um sinal não foi classificado, quatro foram associados corretamente a uma classe e os demais foram ligados à possibilidade de pertencer a mais de uma classe, sendo a classe correta pertencente às opções dadas pelo sistema.

A extração de características dos tons do lofargrama e a RPM medida na análise DEMON foram utilizadas para o treinamento de uma MLP por DAMAS PAULA [14], com o objetivo de classificar quatro classes de navios. Os dados foram gravados numa raia acústica. A rede neural foi implementada com uma camada oculta com cem neurônios e a saída da rede foi feita com quatro neurônios (maximamente esparsa) com função de ativação do tipo tangente hiperbólica. Para o conjunto de validação, a melhor combinação de características apresentou índices de acerto entre 71,4% e 91,7%.

OLIVEIRA E SOUZA e SEIXAS [15] abordaram o problema de classificação

de 8 classes de navios com sinais adquiridos numa raia acústica. Na fase de pré-processamento dos dados, foram utilizadas as mesmas técnicas que SOARES FILHO [13], seguida da compactação dos dados via PCD [28]. O classificador construído seguiu a arquitetura de Classes Especialistas (ou Sistemas Modulares [16]), onde cada especialista foi implementado por uma rede neural do tipo MLP. Foram testadas quatro formas de integração dos especialistas e abordados os problemas de detecção e inserção de uma nova classe, num sistema já treinado. Também buscou-se uma solução para o problema de desbalanceamento de classes. Os melhores resultados alcançaram uma eficiência SP (Soma-Produto) [33] média de 88,7%.

DAS *et al.* [34] avaliaram três formas de extração de características do sinal de 3 classes de navios para posterior classificação: extração de 9 características do espectro, 32 características do cepstro e 32 características do cepstro médio. Os dados utilizados foram sinais reais e sintéticos de 3 classes de navios, cada uma com uma forma de propulsão: diesel, turbina a gás e vapor. Os sinais reais foram adquiridos de 2 navios de cada classe. Um classificador bayesiano foi utilizado, empregando os sinais com e sem ruído inserido. O índices de acerto na classificação, com dados sem ruído foram: somente com espectro 85,90%, com cepstro 92,50% e cepstro médio 96,38%. Nos testes com ruído, o cepstro médio venceu em todos os casos, variando o índice de classificação entre 60,69% e 90,62%.

O espectro gerado da análise DEMON foi utilizado por JIANG *et al.* [35] para classificar duas classes de navios, com o objetivo de utilizar características associadas ao efeito de cavitação dos hélices. Foi investigada a variação da banda de frequência na classificação. Após a extração do DEMON, uma SVM foi utilizada para classificação, com e sem o uso de PCA (com 26 componentes) para redução de dimensionalidade. Os melhores índices de acerto obtidos foram de 88,57% com uso de PCA e 75% sem PCA.

Num cenário de guerra, o submarino pode ter de detectar contatos muito próximos ou sobrepostos em relação à visada do sensor. A fim de realizar a separação de dois ou mais sinais oriundos de dois ou mais contatos diferentes, NUNES DE MOURA [36] estudou a aplicação de técnicas de separação cega de fontes de sinal, baseadas em ICA (*Independent Component Analysis*) e fatoração de matrizes não negativas como pré-processamento, antes das análises espectrais LOFAR e DEMON. Técnicas estatísticas avaliaram a melhora da relação sinal-ruído (ou SNR: *Signal-to-Noise Ratio*) e relação sinal-interferência (ou SIR: *Signal-to-Interference Ratio*). O uso de ICA apresentou melhores resultados e foram utilizados dados reais adquiridos pelo submarino e dados simulados.

MEERPOHL *et al.* [37] patentearam um classificador que realiza uma comparação entre tons detectados no espectro (de forma automática ou manual) e tons presentes num banco de dados, com uso de correlação. Características eventualmente

inferidas pelo OS na análise Demon, como número de eixos e pás dos hélices, podem ser comparadas com as respectivas características presentes no banco de dados. A saída do sistema proposto é a indicação da provável classe do navio, acompanhada de um fator de coincidência. O banco de dados é realimentado com as novas classificações, tornando-o mais robusto ao longo do tempo de uso do sistema. A patente pertence a uma importante empresa alemã fabricante de sistemas de sonar para submarinos. Não há registros de resultados na patente.

ESCORCIA *et al.* [38] classificaram três classes de navios, aplicando ao sinal um pré-processamento (filtro de *Hamming* [39], seguido da Transformada Rápida de Fourier) e uma compactação utilizando PCA. Avaliou-se o uso entre 64 e 256 componentes. Com as componentes extraídas, foram testados quatro classificadores: KNN (*K-Nearest Neighbor*) [16], MLP, RBF (*Radial Basis Function*) [16] e PNN (*Probabilistic Neural Network*) [40]. Uma variação no número de pontos da FFT foi testada. Para cada classificador, os melhores índices de acerto foram 96,1% para RBF, 96,0% para MLP, 86,73% para KNN e 84,9% para PNN.

Aplicando a transformada de Bark-wavelet [41], WANG e ZENG [42] dividiram o sinal acústico em várias componentes, que foram re combinadas com o objetivo de eliminar o ruído. Então, aplicou-se a transformada de Hilbert-Huang para extração de características, utilizadas para ativação de uma SVM. Os sinais utilizados foram gravados por um hidrofone, oriundos de 4 classes de navios. Verificou-se também o desempenho da classificação com inserção de ruído. Os índices de acerto médio alcançados foram: 98,3% para sinais sem inserção de ruído, 93,3% com SNR a 25 dB, 95,0% para SNR a 20dB, 93,3% para SNR a 15 dB, 85,0% para SNR a 10 dB e 71,7% para SNR a 5 dB.

YANG e CHEN [43] representaram o córtex auditivo para classificar sinais comuns no ambiente marinho. Num primeiro estágio, o sinal acústico foi transformado numa representação neural interna (espectrograma auditivo), e depois estimou-se o conteúdo da modulação do sinal. O modelo proposto extraiu quatro características do sinal: frequência central, taxa de modulação temporal, escala de modulação espectral e tempo médio. O conjunto de dados foi formado por sinais oriundos de atividade humana (navios, submarinos e torpedos) e de atividade natural (vocalizações de animais, chuva, bolhas, etc), que foram separados nessas duas classes. O classificador utilizado foi máxima verossimilhança. Os índices de acerto ficaram na ordem de 80%.

O modelo paralelo para redução de dimensionalidade de dados PARAFAC (*PARAllel FACTor analysis*) [44] foi utilizado por OLIVEIRA *et al.* [45] para compactação do sinal de 4 navios, para posterior classificação. Os sinais foram adquiridos em raia acústica, para classificação foi implementada uma MLP. Cinco experimentos foram realizados:

1. Decomposição PARAFAC com grande número de fatores (1000) e sem remoção do ruído de fundo;
2. Somente a remoção do ruído de fundo do sinal (TPSW);
3. Decomposição PARAFAC com 115 fatores e sem remoção de ruído, mais um 116º atributo como sendo a RPM do navio;
4. Remoção do ruído de fundo do sinal (TPSW) e Decomposição PARAFAC com 115 fatores;
5. Remoção do ruído de fundo do sinal (TPSW) e Decomposição PARAFAC com 125 fatores, sendo o número de fatores estimado pelo método CORCONDIA [46];

Para os cinco experimentos, os índices de acerto alcançados foram de 70,75%, 85,38%, 96,05%, 89,33% e 93,10%, respectivamente.

VAHIDPOUR *et al.* [47] propuseram a extração das características tonais do LO-FAR através da segmentação da imagem do espectro, seguida de uma binarização. Os dados utilizados foram gravações reais de cinco classes de navios, coletadas por um hidrofone. Para a classificação, foi implementada uma MLP e um classificador baseado em fractal. Para avaliar os classificadores em relação ao ruído no sinal, os dados foram testados sem inserção de ruído, e com SNR de 5dB e 10dB. Para cada caso, a MLP atingiu índices de acerto médio de 100%, 94,07% e 95,13%, respectivamente, contra 93,33%, 46,93% e 51,23% do método baseado em fractal, respectivamente.

Um vetor de características extraídas do espectro foi implementado por LEAL *et al.* [48] para classificar sinais reais de dois navios mercantes, lancha e golfinho. No pré-processamento, foi aplicada Transformada Discreta de Fourier, seguida de um janelamento. Então formaram-se os vetores de características com dez informações: maior pico de energia do sinal, a energia total de oito intervalos de 500 Hz do sinal (0 a 4 KHz) e a décima característica foi a frequência central do sinal suavizado. Os classificadores testados foram: uma rede neural MLP com 2 camadas e uma SVM. Os índices de acurácia alcançados ficaram entre 71% e 92%, com a MLP obtendo leve vantagem, com respeito a algumas classes.

NOHA [49] propôs um método para extração de características do LOFAR empregando DWT antes da extração de MFFC: *Mel-Frequency Cepstral Coefficients* [50], para classificação de 6 classes de navios simulados em diferentes velocidades, distâncias, número de pás, hélices e ruído ambiente. Foi testado o MFFC com e sem DWT, antes de seu processamento. Com DWT, o melhor índice de identificação foi de 95,83% e sem DWT, 94,44%.

Como visto, nota-se a falta de trabalhos que abordaram o problema de classificação mais próximo da realidade de um submarino, ou seja, com uso de sinais

adquiridos pelo submarino e com número de classes mais significativo. Talvez esta falta esteja relacionada à dificuldade de acesso a esse tipo de dado, pela complexidade em abordar um problema com maior número de classes, ou simplesmente pelo motivo de sigilo, onde este tipo de trabalho não é publicado.

Para o trabalho aqui proposto, foi possível adquirir dados coletados diretamente do sistema de sonar de um submarino, ou seja, foi possível formar uma base de dados contendo exatamente o mesmo sinal que um classificador teria contato numa situação real. Esta base de dados possui 24 classes, número de classes maior que a quantidade de classes dos trabalhos encontrados na literatura, que na grande maioria das vezes variou entre 2 a 4 classes, sendo 8 classes o maior número explorado, observado em OLIVEIRA E SOUZA e SEIXAS [15]. Para ser possível verificar os classificadores abordados numa situação de monitoramento portuário através de sonar passivo, construiu-se uma segunda base de dados, contendo 31 classes, com sinais coletados por um sonar passivo instalado em uma região de porto.

SOARES FILHO [13] e OLIVEIRA E SOUZA e SEIXAS [15] utilizaram técnicas semelhantes no pré-processamento de sinais acústicos de navios, oriundos de gravações de raia acústica, para posterior classificação, sendo que o primeiro trabalho abordou o problema com quatro classes e o segundo, com oito classes. Uma arquitetura de máquina de comitê foi empregada por OLIVEIRA E SOUZA e SEIXAS [15] com sucesso. No trabalho aqui apresentado, aplicaram-se máquinas de comitê em três dos quatro classificadores abordados. No capítulo a seguir, o conceito de máquinas de comitê é explorado, seguido da apresentação de alguns trabalhos da literatura que aplicaram tais máquinas.

Capítulo 3

Máquinas de Comitê

Os sinais acústicos de navios detectados por um sistema de sonar passivo de um submarino possuem certas características que devem ser levadas em conta para o projeto de um classificador que os utilize, dentre elas: alta dimensionalidade dos dados, desbalanceamento entre o número de amostras coletadas das classes e a interferências do ruído ambiente, do ruído próprio (do submarino) e do sistema de sonar (ruído eletrônico) nos dados. Vale lembrar que estas fontes de ruído comportam-se diferentemente para cada aquisição de amostras realizada, e suas distribuições estatísticas são desconhecidas, assim como a distribuição estatística das classes, além da significativa quantidade de classes.

Ferramentas para compactação de dados de alta dimensionalidade, para classificação em sonar passivo, têm sido exploradas com sucesso, como visto no Capítulo 2, por NEVES JÚNIOR [22] e ESCORCIA *et al.* [38] com uso de PCA, SOARES FILHO [13], com uso de PCA, NPCA e PCD, OLIVEIRA E SOUZA e SEIXAS [15], com uso de PCD, NOHA [49], com uso de Wavelets, entre muitas outras abordagens. Outros trabalhos do Capítulo 2 também exploraram a extração de características, como DAMAS PAULA [14], DAS *et al.* [34], YANG e CHEN [43], entre outros. Neste trabalho, a técnica de extração de PCD foi utilizada, e é detalhada adiante.

O desbalanceamento de amostras entre as classes é um problema comum em classificação e neste trabalho será aplicada a técnica de ponderar o gradiente do algoritmo de treinamento de forma proporcional à quantidade de amostras da classe treinada, baseada na técnica CNC-N (Classe e Não Classe Normalizada) desenvolvida por OLIVEIRA E SOUZA e SEIXAS [15]. A remoção do ruído do sinal será realizada com a aplicação do filtro TPSW conforme utilizado por SOARES FILHO [13]. O problema de não se conhecer a distribuição estatística das classes é suprido com o uso de classificadores neurais, que não exigem tal conhecimento *a priori*, no processo de treinamento [16].

A existência de maior quantidade de classes a serem utilizadas neste trabalho, comparado aos trabalhos apresentados no Capítulo 2, motivou a busca por

estratégias neurais que aplicam o conceito de *dividir para conquistar* [16], que é o caso das Máquinas de Comitê [16] ou *Ensemble Methods* [17]. Máquinas de Comitê são um conjunto (Comitê ou *Ensemble*) de membros (classificadores ou regressores) que, em conjunto, solucionam um problema. A arquitetura de uma Máquina de Comitê resume-se em duas partes: o conjunto dos membros e um integrador de suas saídas [17], a fim de obter uma única saída do Comitê. Existem diversas estratégias de treinar os membros de um comitê e de integrá-los.

BARBOSA [51] ressalva que, na literatura em geral, as máquinas de comitê podem ser divididas em duas classes: *ensembles* e sistemas modulares. Neste caso, um *ensemble* é composto por membros que são treinados para executar a mesma tarefa, enquanto que sistemas modulares possuem membros treinados para executar tarefas diferentes (especialistas).

O uso de máquinas de comitê, ao invés de classificadores simples, traz vantagens em termos de generalização, segundo DIETTERICH [52], através de três enfoques: Estatístico, Computacional e Representativo. No enfoque estatístico, muitas vezes o espaço de hipóteses é muito grande para ser explorado por um conjunto de dados de treinamento limitado. Várias hipóteses podem levar a uma mesma acurácia. Apenas um classificador pode escolher uma dessas hipóteses que, em contato com novos dados, pode cometer erros na predição. O uso de mais hipóteses (aprendidas por mais especialistas ou membros de um *ensemble*) diminui o risco do cometimento desses erros. Computacionalmente, o fato de existirem mais membros sendo treinados a partir de diferentes pontos iniciais no espaço de hipóteses diminui a possibilidade destes atingirem um mínimo local errado. Por fim, em termos de representação, o uso de vários membros expande a região representada do espaço de hipóteses.

ZHOU [17] demonstrou que o erro cometido pelo *ensemble* é menor que o erro cometido com o uso de um único membro, na seguinte situação: supõe-se que um *ensemble* formado por T membros individuais h_1, h_2, \dots, h_T , e a saída do i -ésimo membro h_i , para instâncias de x , é $h_i(x) \in \mathbb{R}$. Neste caso, o *ensemble* é projetado para combinar as saídas h_i para predição de um número real. Supõe-se que a integração da saída dos T membros seja o valor médio entre eles, logo, a saída $H(x)$ do *ensemble* é dado por:

$$H(x) = \frac{1}{T} \sum_{i=1}^T h_i(x). \quad (3.1)$$

Sendo $f(x)$ o valor correto a ser esperado para a entrada x , com distribuição $p(x)$, a saída $h_i(x)$, dada pelo membro i , é $f(x)$ mais um erro, ou seja:

$$h_i(x) = f(x) + \epsilon_i(x), \quad i = 1, \dots, T \quad (3.2)$$

logo, o Erro Quadrático Médio (EQM) para h_i pode ser escrito como:

$$\int (h_i(x) - f(x))^2 p(x) dx = \int \epsilon_i(x)^2 p(x) dx, \quad (3.3)$$

e o erro médio \bar{e} dos membros:

$$\bar{e}(h) = \frac{1}{T} \sum_{i=1}^T \int \epsilon_i(x)^2 p(x) dx. \quad (3.4)$$

Logo, o erro $e(H)$ esperado para o *ensemble* é:

$$e(H) = \int \left(\frac{1}{T} \sum_{i=1}^T h_i(x) - f(x) \right)^2 p(x) dx = \int \left(\frac{1}{T} \sum_{i=1}^T \epsilon_i(x) \right)^2 p(x) dx. \quad (3.5)$$

Nota-se que $e(H) \leq \bar{e}(h)$, ou seja, o erro do *ensemble* é menor ou igual ao erro médio dos membros, individualmente. Caso os ϵ_i 's tenham média zero e sejam descorrelacionados:

$$\int \epsilon_i(x) p(x) dx = 0 \text{ e } \int \epsilon_i(x) \epsilon_j(x) p(x) dx = 0, \text{ para } i \neq j, \quad (3.6)$$

tem-se que:

$$e(H) = \frac{1}{T} \bar{e}(h), \quad (3.7)$$

ou seja, neste caso, o erro do *ensemble* é menor que o erro médio dos membros do *ensemble*, num fator de T , porém sabe-se que na prática, os membros estão correlacionados por serem treinados para o mesmo problema e, na maioria das vezes, treinados com o mesmo conjunto de dados.

Quando erros ocorrem no *ensemble*, a ocorrência de erros deve se restringir ao mínimo número de membros [53]. Este fato está ligado ao conceito de Diversidade do *ensemble*. O aumento da diversidade (ou independência estatística) entre os membros do *ensemble* diminui o erro médio do *ensemble*. Isto até um certo ponto, pois o aumento demasiado da diversidade faz com que os membros do *ensemble* percam em exatidão (ou polarização).

De um modo geral, há três formas de se buscar a diversidade entre os membros do *ensemble* [54], variando-se no treinamento: *i*) Ponto inicial no espaço de hipóteses; *ii*) Conjunto de hipóteses acessível; e/ou *iii*) Percurso no espaço de hipóteses.

A variação do *i*) Ponto inicial no espaço de hipóteses pode ser feita com a inicialização aleatória dos pesos dos membros, ou através da escolha de pesos iniciais distantes. A variação do *ii*) Conjunto de hipóteses acessível é possível de duas formas: *a*) manipulação dos dados de treinamento (por exemplo: inserção de ruído,

dados artificiais, uso de algoritmos de treinamento *bagging* [55], *boosting* [56] e *random forest* [57], entre outros). Ou *b*) através da variação da arquitetura dos membros do *ensemble* (algoritmos com poda ou construtivos, exemplo: PCD Construtiva [15], *ensembles* híbridos, entre outras técnicas).

Para a manipulação dos dados de treinamento, três algoritmos têm se destacado [58]: *Bagging*, *Boosting* e *Random Forest*. Os dois primeiros abordam a estratégia de reamostrar os dados de treinamento de diferentes formas para cada membro do *ensemble*, enquanto *random forest* segue a idéia de treinar seus componentes (árvores) com parte dos atributos dos dados, usando diferentes atributos para cada membro.

O algoritmo *Bagging* (*Bootstrap AGGREGatING*), foi proposto por BREIMAN [55] e realiza uma separação aleatória do conjunto de treinamento, gerando sub-conjuntos. Cada sub-conjunto é utilizado para o treinamento de cada membro do *ensemble*. Espera-se que estes sub-conjuntos gerem membros mais independentes estatisticamente. Pode ser feita ou não a superposição de amostras e os membros podem ou não serem do mesmo tipo (árvores de decisão, redes neurais, SVM, entre outros), ou seja, o *ensemble* pode ou não ser híbrido.

O Aprendizado por *Boosting* foi desenvolvido por SCHAPIRE [56]. Para compor o *ensemble*, faz-se uma construção sequencial dos membros, onde as amostras classificadas erradas no treinamento do primeiro membro recebem um peso maior na etapa de treinamento do próximo membro.

Random Forest trata-se de um *ensemble* de árvores de decisão, desenvolvido por BREIMAN [57]. No treinamento, a mesma idéia do *bagging* é utilizada para dividir o conjunto de treinamento aleatoriamente, porém cada árvore opera com parte dos atributos das amostras (de treinamento ou ativação). Estes atributos também são escolhidos aleatoriamente. A técnica de *Random Forest* é indicada para problemas de alta dimensionalidade e o algoritmo *C4.5*, desenvolvido por QUINLAN [59], é bastante utilizado na literatura, através de um pacote de desenvolvimento para linguagem Java, disponibilizada pelo *Weka* [60], chamada *J48*.

Na Equação (3.1), a integração dos membros do *ensemble* foi feita pela média simples. Existem diversas formas de integrar os membros de um comitê, a escolha depende da tarefa a ser realizada pelo comitê (regressão ou classificação) e da forma como os membros foram treinados. Entre essas formas de integração, tem-se a média ponderada, onde os pesos podem ser estimados pelo erro de treinamento de cada membro, integração por voto (classe mais votada é a saída do *ensemble*) simples ou ponderado, integração do tipo *o vencedor leva tudo* (*the winner takes all*), onde a saída do *ensemble* é a saída do membro com maior resposta, integradores neurais, entre muitos outros. A seguir, alguns trabalhos com aplicação de *ensembles* para classificação são apresentados, focando nas formas de treinamento, integração

e arquitetura individual dos membros.

Para a construção de *ensembles* de MLP, COELHO [61] desenvolveu um método que foi aplicado a 4 problemas de classificação, sendo três com dados reais, contidos no repositório criado por NEWMAN *et al.* [62]. Para o treinamento das redes neurais, foi utilizado o algoritmo *opt-aiNet* [63], uma meta-heurística baseada em sistema imunológico, a qual foi adaptada para buscar a diversidade do erro entre as redes MLP. Para a construção do *ensemble*, foram testadas: duas técnicas construtivas, ou seja, insere-se um membro no *ensemble* e avalia se houve ou não melhora; duas técnicas de poda, ou seja, o *ensemble* inicia com todos os membros e avalia-se a retirada de um membro; e uma técnica utilizando um algoritmo de agrupamento aplicado à saída das redes. Para cada agrupamento calculado, foi utilizada a melhor rede dentro de cada agrupamento; e por fim, também foi testado o *ensemble* utilizando todos os membros gerados. Para a integração dos membros, foram testados: média simples, média ponderada (com e sem viés), voto majoritário e *winner takes all*. Os resultados dos *ensembles* também foram comparados com emprego de uma rede MLP simples. Os resultados alcançados ficaram semelhantes aos melhores resultados encontrados na literatura, para os conjuntos de dados disponíveis em [62].

PATEL *et al.* [64] utilizou um método de criação de *ensembles* baseado no método DECORATE (*Diverse Ensemble Creation by Oppositional Relabeling of Artificial Training Examples*) [65], usando RNA como membros, e foi comparado com a aplicação do DECORATE formado por RBF, *Random Forest* e *Naive Bayes*. Os *ensembles* foram aplicados em quatro problemas de classificação utilizando dados reais do repositório [62]. No método proposto, primeiramente o conjunto de dados é particionado em vários outros conjuntos, com seus respectivos subconjuntos de teste, cada tupla desses conjuntos é usada em uma iteração de treinamento de um candidato a membro do *ensemble*. Em cada caso, o erro com o conjunto de teste é calculado e guardado. São gerados dados artificiais que são adicionados ao conjunto de dados original e o erro do candidato é novamente calculado. Caso ele seja menor que o erro anterior, o candidato torna-se membro do *ensemble*. O procedimento é repetido até o número de iterações desejado. Outra forma de controlar as iterações é avaliar, a cada inserção de um membro, o erro do *ensemble*, parando de inserir outros membros caso o erro aumente. Ao final, a saída do *ensemble* é calculada por média ou voto (dependendo da aplicação). O *ensemble* formado por RNA atingiu a melhor acurácia média de 95%, seguido do uso de RBF e *Naive Bayes*, com 94% e *Random Forest* com 93%.

Uma revisão dos *ensembles* comumente usados na literatura foi feita por RAHMAN e TASNIM [66], para a tarefa de classificação. Os classificadores individuais que compõem o *ensemble* mais usados são RNA, SVM, árvores de decisão e KNN. Ainda segundo os autores, os métodos utilizados para construção dos *ensembles*

geralmente baseiam-se em seis abordagens: *i*) manipulação dos parâmetros de treinamento; *ii*) manipulação da função de erro; *iii*) manipulação do espaço de atributos; *iv*) manipulação dos rótulos de saída; *v*) agrupamentos e *vi*) manipulação dos padrões de treinamento. RAHMAN e TASNIM [66] também abordam de forma superficial seis aplicações de *ensembles* classificadores desenvolvidos especificamente para suas respectivas aplicações: avaliação da qualidade de dados de sensor, previsão e causa do encerramento de fazenda de mariscos por contaminação, reconhecimento de caligrafia, mapeamento do *habitat* bentônico, tratamento de dados faltantes de sensor e previsão de crescimento de algas.

Um meta-classificador desenvolvido por KIM e CHO [67] foi aplicado à análise de expressão gênica para inferir a ocorrência ou não de tumor, utilizando quatro conjuntos de dados, oriundos do cólon, mama, próstata e linfoma. Os dados utilizados são de alta dimensionalidade (entre mil e quatro mil dimensões) e baixo número de amostras (entre 45 e 102). Os dados foram subdivididos em 2/3 para treinamento e 1/3 para teste. O método proposto possui duas fases: treino dos candidatos a membros do *ensemble* e construção do meta-classificador (*ensemble*). Um algoritmo genético é aplicado na otimização da escolha dos membros do *ensemble*, devido ao grande número de membros candidatos (54, no total). Nove métodos de seleção de genes foram utilizados para selecionar atributos para treinamento. Seis classificadores foram testados: MLP, SVM e três variantes de KNN. Foram testadas quatro diferentes integrações dos membros:

1. Resultado final é calculado pela votação majoritária (saída binária) dos membros;
2. Resultado final é baseado na soma das saídas (valor real) dos membros dividido pelo número de membros. Se o resultado for maior que 0,5, ele é classificado como *não-tumor*;
3. Cada saída (binária) dos membros é associada a um peso. Se a soma para *tumor* for maior que *não tumor*, a saída é *tumor*, caso contrário é *não tumor*;
4. A soma ponderada da saída (valor real) dos membros é dividida pela soma dos pesos. Se o resultado for menor que 0,5, a classificação é *não tumor*.

Para os dados do cólon, um *ensemble* com MLP obteve o melhor resultado, com 88,1% de acurácia. Para os dados de próstata, venceu um *ensemble* com SVM, com 93,4%. Para os dados de mama, venceu o *ensemble* DECORATE com 80,91%. Para o linfoma, venceu o método proposto, com 94%.

Uma abordagem empregando aprendizagem profunda (*Deep Learning*) [68] em um *ensemble* treinado de forma não supervisionada foi proposta por SHAHAM *et al.*

[69]. O *ensemble* seguiu a arquitetura *Deep Neural Network* (DNN) [70] baseada em RBM (*Restricted Boltzmann Machine*) [71]. O método proposto foi comparado com quatro outros métodos de *ensembles* não supervisionados:

1. um *ensemble* com membros de máxima verossimillhança integrados com voto majoritário;
2. um *ensemble* com membros de máxima verossimillhança sob o modelo Dawid e Skene [72];
3. um modelo probabilístico geracional bayesiano proposto por [73];
4. método L-SML(*Latent Spectral Meta Learner*) [74].

Os resultados também foram comparados com outros dois métodos de classificação supervisionados: MLP e otimizador bayesiano. Todos os classificadores foram utilizados em quatro conjunto de dados simulados e três conjunto de dados reais do repositório [75]. Nos quatro conjuntos de dados simulados, o método proposto venceu, em acurácia de classificação, em dois casos (86,8% e 88,1%), em um caso empatou em primeiro lugar com o *ensemble* com modelo Dawid e Skene (94,8%), e ficando em segundo lugar no quarto caso, perdendo para o método L-SML (95,8% contra 95,1%). Nos três conjuntos de dados reais, o método proposto empatou em primeiro lugar no primeiro caso, com o método L-SML (98,4%), perdeu para o L-SML no segundo caso (97,7% contra 97,6%) e venceu no terceiro caso (98,5%).

Nota-se na literatura que há uma grande variedade de formas de se implementar comitês para classificação. Como visto no Capítulo 2, OLIVEIRA E SOUZA e SEIXAS [15] obtiveram um índice SP de 88,7% com uso de comitê de classes especialistas aplicados na classificação de 8 classes de navios, sendo o trabalho encontrado na literatura mais próximo do contexto deste trabalho, logo, a solução adotada por OLIVEIRA E SOUZA e SEIXAS [15] foi escolhida para ser implementada neste trabalho.

No Capítulo 2, também foi visto no trabalho de SOARES FILHO [13] emprego do conhecimento especialista na determinação de parâmetros no pré-processamento dos sinais de Sonar. Neste trabalho, no Capítulo 4, propõe-se o uso de conhecimento especialista para balizar a integração de classificadores, membros de um comitê, de forma hierárquica, bem como a definição das classes que cada membro deste comitê ficará responsável por classificar. Além de apresentar este comitê hierárquico, o próximo Capítulo também aborda a forma como o comitê de classes especialistas de OLIVEIRA E SOUZA e SEIXAS [15] fo adequado ao contexto deste trabalho.

Capítulo 4

Método

SOARES FILHO [13] e OLIVEIRA E SOUZA e SEIXAS [15] exploraram uma eficiente forma de pré-processamento e compactação dos dados, as quais também foram utilizadas neste trabalho. O método proposto por OLIVEIRA E SOUZA e SEIXAS [15] foi implementado com novos conjuntos de dados, mais próximos da realidade de um submarino. Além disso, foi implementado um comitê cujos membros foram integrados de forma hierárquica, baseada em conhecimento especialista. Estratégias usando comitês de redes neurais, como visto anteriormente na literatura, têm sido empregadas com sucesso em aplicações com dados de alta dimensionalidade, grande presença de ruído, classes desbalanceadas e significativa quantidade de classes. Estas características também estão presentes no problema de classificação em Sonar. Quanto ao comitê hierárquico, trata-se de uma nova proposta para abordar o problema, associando características de um comitê de classificadores com o conhecimento especialista.

O método proposto neste trabalho consiste em classificar navios com base em seus sinais acústicos, primeiramente fazendo-se um pré processamento destes sinais, seguida da compactação dos sinais e então treinando os classificadores conforme as quatro abordagens apresentadas adiante. Por último é feita uma avaliação do desempenho de cada abordagem. Cada um desses passos é descrito a seguir.

4.1 Pré-Processamento dos Sinais

SOARES FILHO [13] desenvolveu uma sequência de passos para o pré-processamento de sinais de navios, os quais foram empregados neste trabalho. O primeiro passo foi a aplicação de uma decimação com fator 4 no espectro, seguida da aplicação de uma janela de Hamming [39] e cálculo da Transformada Discreta de Fourier. Após estas operações, foi calculado o módulo do espectro e então aplicado o filtro TPSW [26], para retirada do ruído de fundo. Foram utilizados os mesmos parâmetros de OLIVEIRA E SOUZA e SEIXAS [15] para o filtro TPSW, ou seja,

uma janela de convolução de tamanho 104 e limiar de 2 (se a convolução num determinado ponto do espectro for acima deste limiar, este ponto recebe o valor da média local). Após a aplicação do filtro TPSW, são utilizados, deste espectro final, os primeiros 400 pontos (ou bins), ou seja, uma amostra do conjunto de dados gerada é na forma de um vetor de 400 atributos, associado a um determinado navio. Devido ao desbalanceamento dos dados, alguns navios possuem mais vetores de atributos que outros. Uma descrição mais detalhada dos dados é feita na Sessão 5.1. O pré-processamento é esquematizado na Figura 4.1.

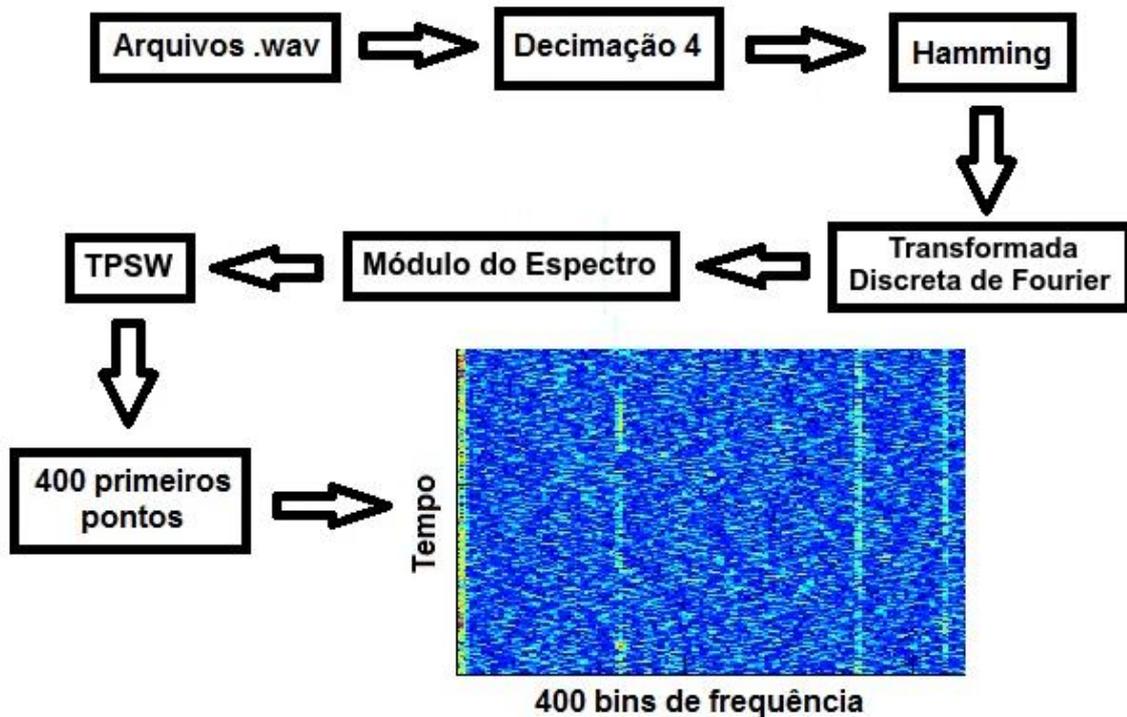


Figura 4.1: Pré-processamento dos sinais dos navios.

4.2 Compactação dos Sinais

Neste trabalho, a fase de compactação dos sinais pré-processados foi realizada com a aplicação da técnica da extração construtiva de PCD [28]. Esta técnica superou os resultados alcançados para PCA e NLPCA para classificação em Sonar, em SOARES FILHO [13], e foi utilizada com sucesso por OLIVEIRA E SOUZA e SEIXAS [15]. A extração das PCD é feita através do treinamento de uma MLP com uma camada de ativação de 400 entradas (correspondendo aos 400 bins extraídos do sinal, durante o pré-processamento) e uma segunda camada que inicializa com um neurônio e vai sendo incrementada de um em um neurônio ao longo do treinamento. Na primeira etapa do treinamento, a MLP treinada com um neurônio produz a primeira PCD. Esta componente é o vetor de pesos que conecta este neurônio à

camada de ativação. A seguir, é inserido mais um neurônio e a rede é novamente treinada, porém os pesos do neurônio treinado anteriormente não são modificados. Ao fim deste segundo treinamento, tem-se a segunda componente, que corresponde aos pesos do segundo neurônio. O incremento de neurônios segue até a quantidade de componentes desejada. A fim de evitar mínimos locais, o treinamento para cada neurônio é feito diversas vezes e escolhe-se a componente que possui maior índice SP, calculado com um conjunto de dados de teste.

A seguir, são apresentados os quatro classificadores abordados neste trabalho: uma rede neural do tipo MLP, um comitê de classes especialistas, cujos especialistas são redes neurais do tipo MLP, ou máquinas de vetor de suporte, e um comitê de redes neurais do tipo MLP dispostas em forma hierárquica.

4.3 Rede Neural do Tipo MultiLayer Perceptron

A MLP implementada tem como entrada o vetor de atributos dos navios (com quatrocentos atributos). No caso do número de neurônios da camada oculta, trata-se dos neurônios que correspondem às PCD, conforme técnica descrita na Seção anterior. A quantidade de PCD que apresentar maior índice SP no processo de treinamento (cálculo da SP com uso de conjunto de teste) será a quantidade definida dos neurônios da camada oculta. O índice SP está detalhado na Seção 5.2. A camada de saída da MLP é do tipo maximamente esparsa [16], ou seja, contém a quantidade de neurônios correspondente a quantidade de classes do problema. Todos os neurônios foram implementados com função de ativação do tipo tangente hiperbólica.

O processo de treinamento supervisionado de uma MLP é um problema de otimização onde se busca a minimização do erro de classificação da saída da MLP. Diversos algoritmos de treinamento têm sido desenvolvidos, baseados em otimização estocástica [76], com destaque ao algoritmo Adam [77], que é baseado em gradiente de primeira ordem de funções objetivas estocásticas. Suas características de bom desempenho em problemas não estacionários, com grande volume de dados e de parâmetros, características também presentes na classificação de sinais de Sonar, tornam o algoritmo Adam uma excelente escolha para o problema abordado neste trabalho.

4.4 Comitê de Classes Especialistas

Um comitê de classes especialistas combina diversos classificadores (ou regressores) especializados em sub-tarefas do domínio do problema [17]. Neste trabalho, o comitê possui especialistas para cada classe, ou seja, o especialista é capaz de inferir se a

classe apresentada a ele pertence ou não à classe de sua especialização. Dado um exemplo da classe A , espera-se que sobressaia a resposta do especialista da classe A , enquanto os demais a classifiquem como não sendo das classes para as quais são especialistas. Este modelo de classificador foi utilizado por OLIVEIRA E SOUZA e SEIXAS [15] para oito classes de navios e foi implementado neste trabalho.

Um comitê de classes especialistas divide a tarefa de classificar todas as classes usando um único classificador em várias sub-tarefas de classificação binária (classe ou não classe) atribuída a cada especialista. Esta classificação binária é realizada por uma rede neural do tipo MLP ativada com o vetor de atributos dos navios, ou seja, cada especialista é uma MLP. A saída destas MLP são integradas de forma que o comitê tenha uma única saída. A integração das MLP (especialistas) foi implementada com a regra “*the winner takes all*” [16], ou seja, o especialista que apresenta a maior saída vence, isto é, a classe que este representa é eleita a classe identificada pelo comitê.

O problema de desbalanceamento dos dados deste trabalho foi enfrentado empregando-se no treinamento das redes neurais um fator normalizado de ponderação no gradiente, solução desenvolvida para o mesmo propósito por OLIVEIRA E SOUZA e SEIXAS [15]. Num caso hipotético, onde um problema de classificação contendo dez classes com dez amostras cada, tem-se um conjunto de dados balanceado. Para treinar o i -ésimo especialista, com $1 \leq i \leq 10$, para cada exemplo da classe i do conjunto de dados, teríamos nove exemplos de não classe (demais classes). Nota-se que, mesmo para um conjunto de dados balanceado, o treinamento de diversos especialistas para problemas com mais de duas classes torna-se desbalanceado.

OLIVEIRA E SOUZA e SEIXAS [15] explorou três formas de compensar, na função objetivo do algoritmo de treinamento, o desbalanceamento das classes, sendo a técnica CNC-N a que obteve melhor resultado, utilizando como função objetivo a Equação (4.1), onde o erro de treinamento E de um especialista é composto pelo erro correspondente à classe, E_c , e à não classe, E_{nc} :

$$E = \frac{1}{2} \left(\frac{1}{\|\nabla E_c\|} \right) E_c + \frac{1}{2} \left(\frac{1}{\|\nabla E_{nc}\|} \right) E_{nc} \quad (4.1)$$

Neste trabalho, dois comitês de classes especialistas foram implementados. Um deles utilizou especialistas construídos com redes neurais do tipo MLP, e outro utilizou SVM para a construção de cada especialista. A escolha dos especialistas para compor os comitês se deu da seguinte maneira: para o comitê de MLP, variou-se a topologia da rede, neste caso a quantidade de neurônios da camada oculta, e escolheu-se a topologia que apresentou melhor SP médio dentre os *fold*s de treinamento. Já o comitê de SVM, variou-se o parâmetro C [16] no processo de treina-

mento de uma SVM, onde C é uma constante que penaliza o erro de treinamento do classificador em detrimento da quantidade de vetores de suporte deste classificador, ou seja, a minimização do erro de treinamento se dá com o aumento do número de vetores de suporte, porém este aumento demasiado de vetores de suporte pode levar ao treinamento de um classificador com baixo poder de generalização, daí a necessidade da parcimônia na escolha do número de vetores de suporte, sendo esta a função de C no processo de treinamento. Neste trabalho, variou-se o parâmetro C , sendo escolhido aquele onde o comitê apresentou melhor SP médio. Foi utilizado o *kernel* gaussiano.

4.5 Comitê Hierárquico

O comitê de classificadores dispostos de forma hierárquica foi desenvolvido da seguinte maneira: no primeiro nível, chamado “Super”, foi implementado um classificador capaz de distinguir todas as classes do problema porém reagrupadas em novas classes. Cada nova classe contém classes originais do problema que possuem navios com características operativas em comum. O segundo nível da hierarquia contém a quantidade de classificadores respectivos às novas classes criadas para a saída do classificador do nível hierárquico acima. Cada um deles foi treinado para distinguir as classes de navios que o compuseram. Neste segundo nível, caso haja características em comum relevantes entre as classes, estas formam novas classes, caso contrário o classificador do nível em questão é treinado para distinguir entre as classes originais do problema. Esta ideia se propaga a níveis hierárquicos inferiores até que não haja mais características em comum entre as classes originais.

A criação de cada nova classe bem como a disposição destas hierarquicamente foi realizada com base no conhecimento especialista em navios. Por exemplo, pode-se implementar um classificador especialista em submarinos, um classificador especialista em porta aviões e um classificador especialista em *destroyers* são implementados neste segundo nível. No terceiro nível, a especialização torna-se menos abrangente, por exemplo, abaixo de “porta aviões” criam-se dois outros classificadores: um especialista em porta aviões com propulsão nuclear e outro em porta aviões com propulsão não nuclear. As especializações terminam quando o nível hierárquico corresponde a uma determinada classe original de navio. Por questão de sigilo militar, não foi descrito aqui os reais subconjuntos que englobam cada nível hierárquico bem como quais navios compõem as classes do conjunto de dados. A Figura 4.2 apresenta a disposição dos níveis hierárquicos (Super, A, B, C, D, AA, AB, AC, DA e DB) até atingir cada uma das 24 classes do conjunto de dados provenientes de submarino (representadas pelos algarismos 1 a 24).

A Figura 4.3 representa a disposição dos diversos níveis hierárquicos (Super, A,

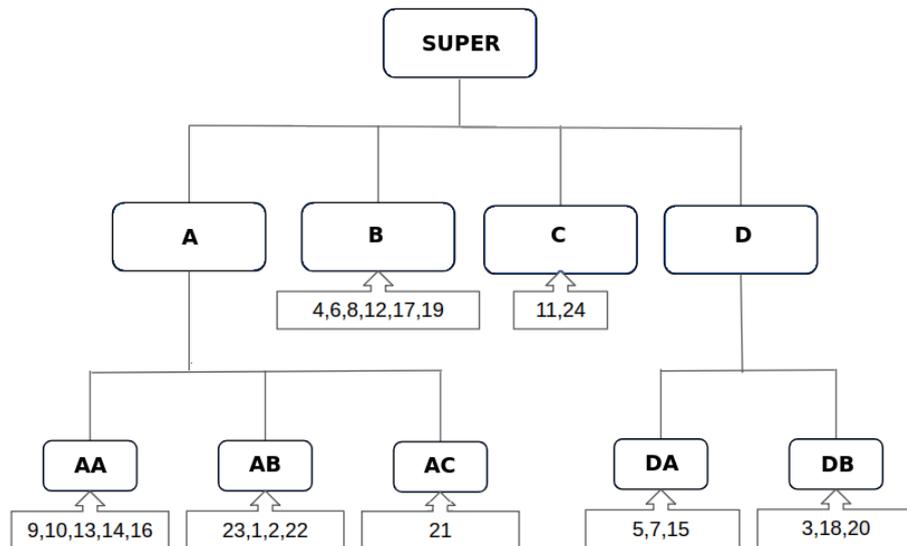


Figura 4.2: Comitê hierárquico para as 24 classes provenientes das gravações do Sonar de submarino.

B, B1 a B8) para o conjunto de dados provenientes do VIPP (31 classes), até atingir o nível hierárquico das classes propriamente ditas (representadas pelos algarismos 1 a 31).

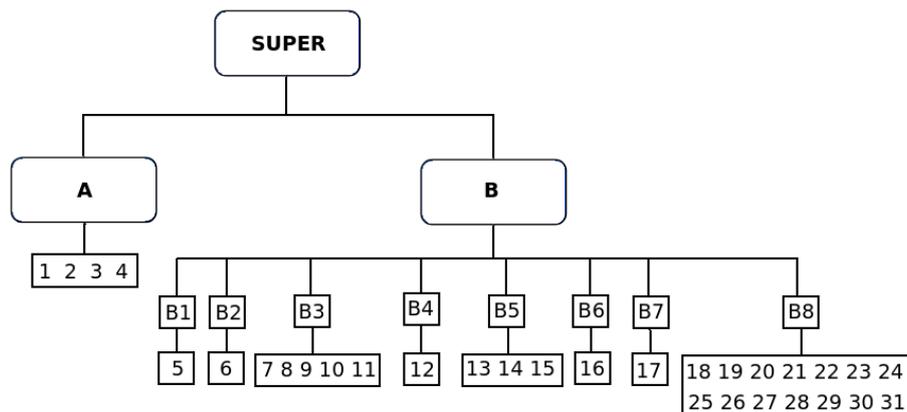


Figura 4.3: Comitê hierárquico para as 31 classes provenientes do VIPP.

O comitê hierárquico tem cada nível hierárquico treinado com as classes que o compõem. Cada nível é chamado de membro do comitê. Uma vez todos os membros treinados, a ativação se dá pelo membro Super. A saída deste membro identifica qual o próximo membro a ser ativado (com o mesmo *input* do nível acima). A ativação dos níveis hierárquicos mais inferiores continua até a a resposta da saída do membro atingir uma das classes originais do problema.

Cada membro do comitê hierárquico é uma rede do tipo MLP ativada com quatrocentas entradas que se correspondem ao vetor de características dos navios, contendo uma quantidade de neurônios na camada oculta (mesma regra de extração de PCD utilizada no comitê de classes especialistas com MLP) correspondente à

quantidade de neurônios que apresentou melhor SP médio, com saída maximamente esparsa, com todos os neurônios da rede com função de ativação do tipo tangente hiperbólica. Os membros deste comitê, redes do tipo MLP, também utilizaram o algoritmo Adam, validação cruzada e balanceamento dos dados via CNC-N no processo de treinamento.

4.5.1 A Hierarquia de Classes na Análise dos Resultados

Utilizando o contexto de hierarquia de classes do comitê hierárquico, agora não como um classificador, mas como uma forma de apresentar o comportamento dos falsos positivos resultantes da classificação errada de uma determinada classe realizada por um classificador. Pode-se buscar agrupar as confusões em classes “irmãs” à classe esperada ou em classes “primas” à classe esperada, sendo uma classe “irmã” aquela que se encontra no mesmo nível hierárquico da classe esperada e abaixo de uma mesma classe hierarquicamente acima da classe esperada. Como exemplo de classes irmãs, tem-se as classes 5, 7 e 15 da Figura 4.2.

Uma classe A se diz “prima” de uma classe B quando estas estão num mesmo nível hierárquico e as respectivas classes do nível hierárquico acima de A e B são irmãs. Como exemplo, tem-se as classes 3, 18 e 20, primas da classe 5, conforme hierarquia definida na Figura 4.2.

Foram definidas duas relações entre as classes (irmãs e primas), baseadas na hierarquia entre elas, utilizadas para analisar as confusões de um classificador. É possível criar outras relações, porém estas duas se mostram o suficiente para analisar um classificador do quão longe está um falso positivo da classe correta, na ocorrência de confusão. Num contexto operativo, lembrando da operação associada de classificadores automáticos e seres humanos (OS), uma confusão gerada por um classificador automático, onde o falso positivo trata-se de uma classe irmã (ou prima) da classe correta, ainda sim é um resultado útil numa situação de dúvida do OS, quando este consulta o classificador automático para norteá-lo na escolha entre duas classes não irmãs (ou não primas) e a classificação automática resulta numa classe irmã (ou prima) de umas das classes em que o OS está em dúvida.

Neste trabalho, a análise dos resultados baseada na hierarquia das classes foi chamada de análise hierárquica. Para quantificar esta análise, pode-se contar a quantidade de falsos positivos classificados como classes irmãs e primas e dividir este valor pela quantidade total de falsos positivos para a classe analisada. Vale lembrar que, num primeiro momento, espera-se que um classificador produza o mínimo possível de falsos positivos, porém dentro do contexto de aplicação deste trabalho, havendo ocorrência de falsos positivos, é interessante que o maior número possível de falsos positivos sejam estimações das classes irmãs e primas.

A seguir são apresentados os resultados dos quatro classificadores abordados neste trabalho, bem como maiores detalhes de seus parâmetros e dos conjuntos de dados utilizados. Ao fim, a análise hierárquica dos resultados também é gerada para as classes com maior confusão.

Capítulo 5

Resultados

Neste Capítulo são abordados detalhadamente os dois conjuntos de dados utilizados. Em seguida, são apresentadas as figuras de mérito utilizadas para avaliação dos classificadores, seus resultados e a análise hierárquica das maiores confusões realizadas pelos classificadores na geração de falsos positivos.

5.1 Conjuntos de Dados Utilizados

Foi utilizado neste trabalho dois conjunto de dados. O primeiro trata-se de dados reais gerados de gravações de sinais recebidos de um sistema de sonar de um submarino, através do canal de áudio do OS, toda vez que o OS classificou um contato. Estes áudios foram gravados em arquivos com extensão *.wav* com 16 bits de resolução de amplitude e adquiridos a uma frequência de amostragem de 31.250 Hz. Foram coletadas 24 classes de navios. Estes dados possuem a vantagem de serem produzidos no ambiente de um sistema de sonar de um submarino em operação, ou seja, possuem toda sorte de influências que um sinal acústico produzido por um navio pode sofrer, até chegar ao canal de áudio de um OS, como por exemplo: perdas na propagação do sinal no ambiente marinho, interferência de outras fontes sonoras (do ambiente marinho, de outros navios ou do ruído próprio do submarino), ruído eletrônico do próprio sistema de sonar, entre outros fatores.

Um segundo conjunto de dados construído neste trabalho é composto de gravações de ruído de navios detectados pelo sistema VIPP: Vigilância e Informações Passivas em Portos, desenvolvido pelo IPqM. Este sistema consiste num arranjo de hidrofones dispostos numa estrutura semi elíptica, opera no modo passivo (não emite sinais acústicos) e é integrado ao SDAC: Sistema de Detecção, Acompanhamento e Classificação de Contatos que, além das funcionalidades descritas em seu nome, o SDAC também grava os sinais detectados na área de vigilância do VIPP, o qual é instalado em regiões portuárias de intenso tráfego marítimo. O SDAC também foi desenvolvido pelo IPqM e também é empregado em outros sistemas de sonar,

inclusive em submarinos. Na Figura 5.1 encontra-se o arranjo de sensores acústicos do VIPP. Cada sensor acústico do VIPP é chamado de *stave*: um conjunto de hidrofones encapsulados, neste caso, três hidrofones. No caso do *stave* utilizado, a tensão do sinal de saída é a soma das tensões de cada hidrofone.

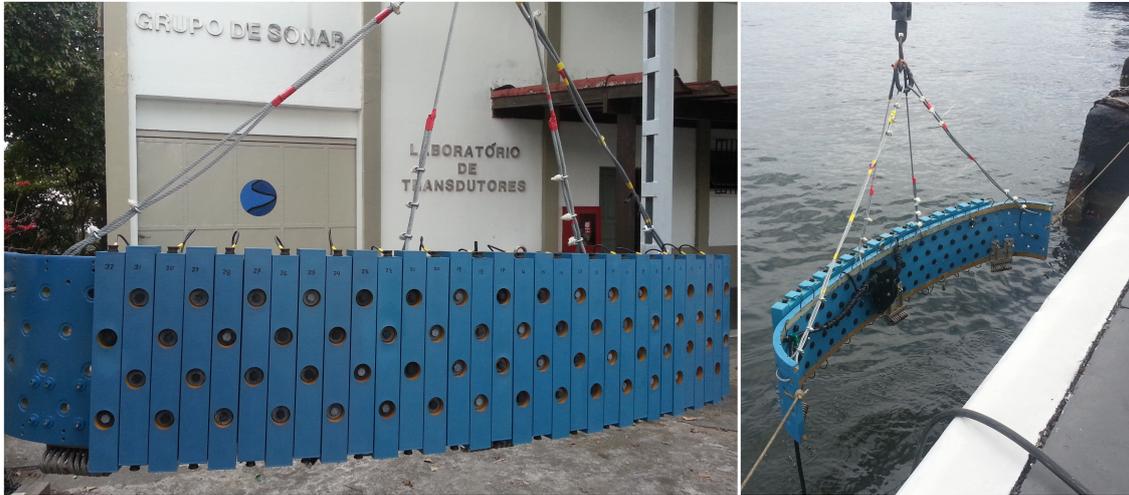


Figura 5.1: VIPP e seu arranjo semi elíptico de *staves*

O conjunto de dados adquiridos pelo VIPP possui 31 classes de navios, com sinais gravados em arquivos com extensão *.wav* com 16 bits de resolução de amplitude e adquiridos a uma frequência de amostragem de 31.250 Hz. As classes de navios pertencentes aos dados oriundos do monitoramento do tráfego marítimo são importantes de serem testados neste trabalho, pois há o interesse da MB em buscar uma ferramenta de classificação a ser empregada no VIPP, que opera em condições diferentes de um sistema de sonar de um submarino.

Uma vez aplicado o pré-processamento descrito na Sessão 4.1 nos arquivos de áudio dos navios, foram gerados para cada classe de navio, as quantidades de janelas (amostras do conjunto de dados) representadas nas Tabelas 5.1 e 5.2, respectivamente para os dados provenientes de gravações de submarinos e do VIPP. Em ambos os conjuntos de dados, nota-se um grande desbalanceamento entre as classes. Na Tabela 5.1 (submarino), estão em negrito: a classe 6, com menor número de janelas igual a 2.232, e a classe 23, com maior número de janelas igual a 45.589. Na Tabela 5.2 (VIPP), estão em negrito: a classe 17, com menor número de janelas igual a 328, e a classe 11, com maior número de janelas igual a 3753.

O conjunto de dados foi então separado em dez *fold*s a fim de treinar os classificadores aplicando a técnica de validação cruzada (ou *cross validation*) [16], sendo um *fold* para teste e os nove restantes para treinamento. A cada época de treinamento avaliou-se o classificador pelo seu índice Soma-Produto [33] explicado na Sessão 5.2.

Nas figuras 5.2 e 5.3, respectivamente para os conjuntos de dados com 24 e 31 classes, é possível visualizar da distribuição dos exemplos de cada classe entre os dez

Tabela 5.1: Quantidades de janelas para cada classe de navios do conjunto de dados proveniente de submarino.

Classe	Nº Janelas	Classe	Nº Janelas	Classe	Nº Janelas
1	3.209	9	14.562	17	5.428
2	3.037	10	23.224	18	3.614
3	3.212	11	5.633	19	5.493
4	3.203	12	3.192	20	3.031
5	4.781	13	11.314	21	5.292
6	2.232	14	5.542	22	16.225
7	10.821	15	2.532	23	45.589
8	5.898	16	19.233	24	13.816

Tabela 5.2: Quantidades de janelas para cada classe de navios do conjunto de dados proveniente do VIPP.

Classe	Nº Janelas	Classe	Nº Janelas	Classe	Nº Janelas
1	2059	12	1054	23	2228
2	607	13	1374	24	2952
3	466	14	718	25	1757
4	1324	15	1178	26	1303
5	828	16	410	27	1430
6	1766	17	328	28	2728
7	1020	18	1353	29	1924
8	632	19	2498	30	1589
9	1206	20	1417	31	1848
10	890	21	1576	—	—
11	3753	22	605	—	—

*fold*s criados. A cor preta representa os exemplos contidos no *fold* e a cor branca representa os exemplos não contidos no *fold*.

Neste trabalho, o conjunto de dados provenientes das gravações oriundas de submarinos também é referenciado como conjunto de dados de 24 classes, e o conjunto de dados provenientes das gravações do VIPP também é referenciado como conjunto de dados de 31 classes.

5.2 Figuras de Mérito

Os classificadores foram avaliados pelos seus valores médios das figuras de mérito (entre os *fold*s de treinamento), calculadas com o conjunto de teste. As três figuras de mérito utilizadas foram: Eficiência de Classificação, índice Soma-Produto (SP) [33] e razão entre o número de falsos positivos de classes irmãs e primas e o número total de falsos positivos para uma determinada classe analisada (vide Sessão 4.5.1).

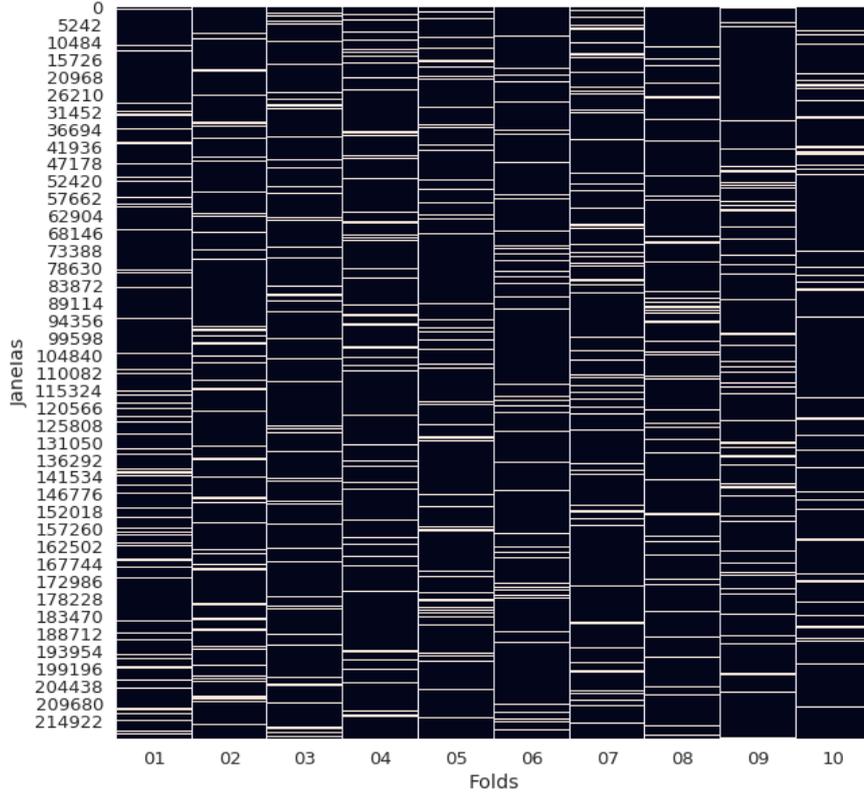


Figura 5.2: Distribuição dos exemplos do conjunto de dados de 24 classes entre os 10 *fold*s criados.

Cada *fold*, em cada topologia definida, foi inicializado 10 vezes, gerando assim um valor médio das figuras de mérito utilizadas para cada *fold*.

O índice SP é uma medida que visa encontrar o melhor equilíbrio entre a probabilidade de detecção e a probabilidade de um falso alarme. o índice SP é calculado em função da eficiência do classificador para cada classe do problema. Para um problema de N classes, a Eficiência de Classificação Eff_i para a i -ésima classe é calculada de acordo com a Equação (5.1):

$$Eff_i = \frac{\text{Número de verdadeiros positivos da classe}_i}{\text{Número de exemplos da classe}_i} \quad (5.1)$$

A eficiência de classificação para a i -ésima classe aproxima-se do valor igual a um à medida que o classificador acerta a classificação dos exemplos da i -ésima classe e se aproxima de zero quanto mais erra na classificação dos exemplos da i -ésima classe. Dada a eficiência de classificação Eff , o índice SP para um classificador especializado em classificar N classes é calculado de acordo com a Equação (5.2):

$$SP = \sqrt{\left(\frac{\sum_{i=1}^N Eff_i}{N}\right) \cdot \left(\sqrt[N]{\prod_{i=1}^N Eff_i}\right)} \quad (5.2)$$

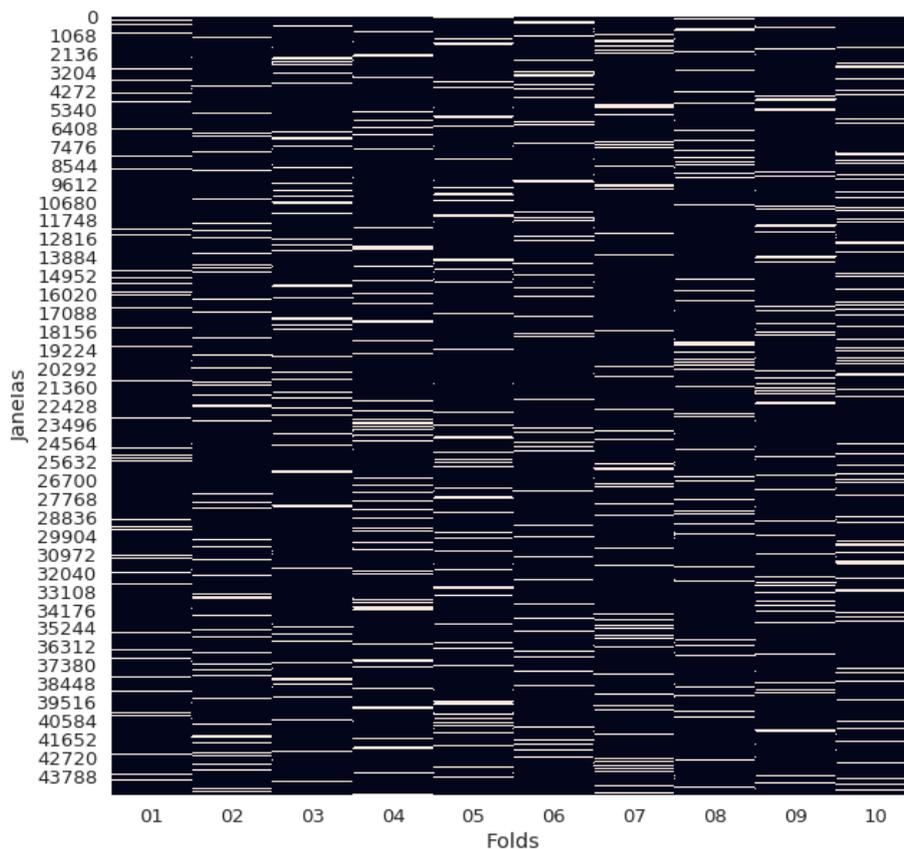


Figura 5.3: Distribuição dos exemplos do conjunto de dados de 31 classes entre os 10 *folds* criados.

O índice SP varia de zero a um, estando mais próximo de um quanto maior a eficiência de classificação de todas as classes. Uma classe com baixa eficiência de classificação força o índice SP a valores mais próximos de zero. No treinamento das MLP que formam três dos quatro classificadores analisados neste trabalho, o índice SP foi monitorado durante o processo de treinamento e foi escolhida a MLP com maior SP.

5.2.1 Resultados para a Rede Neural do tipo MultiLayer Perceptron

Para o conjunto de dados de 24 classes, a topologia de MLP escolhida conteve 150 neurônios na camada oculta, apresentando melhor índice SP médio com menor desvio-padrão ($0,80 \pm 0,00$). São apresentados, na Figura 5.4, os valores médios do índice SP e seus desvios-padrões, para diversas quantidades de neurônios na camada oculta da MLP.

Na Figura 5.5 estão representados os valores médios de Eficiência da MLP contendo 150 neurônios, para o conjunto de dados com 24 classes.

Para o conjunto de dados de 31 classes, a melhor topologia de MLP conteve 200

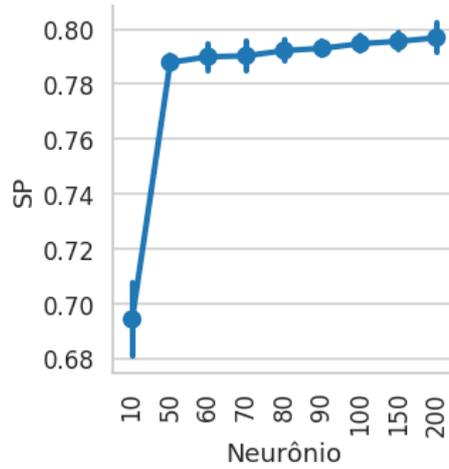


Figura 5.4: Índices SP médios para diversas quantidades de neurônios na camada oculta da MLP, para o conjunto de dados de 24 classes.

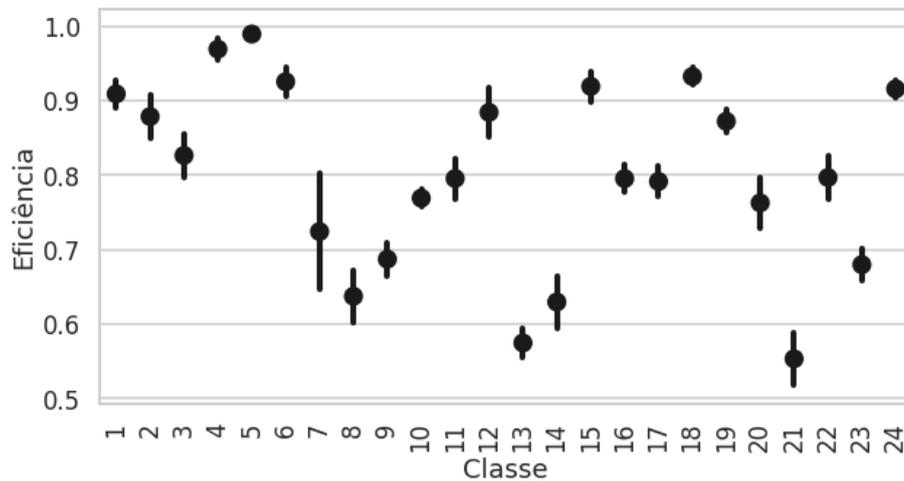


Figura 5.5: Eficiências médias da MLP com 150 neurônios na camada oculta para as 24 classes.

neurônios na camada oculta, apresentando um índice SP médio de $0,70 \pm 0,07$. São apresentados na Figura 5.6, os valores médios do índice SP e seus desvios-padrões, para diversas quantidades de neurônios na camada oculta da MLP, para 31 classes.

Na Figura 5.7 estão representados os valores médios de Eficiência da MLP contendo 200 neurônios, para conjunto de dados com 31 classes.

5.2.2 Resultados para o Comitê de Classes Especialistas com MLP

Inicialmente verificou-se, para o conjunto de dados dos submarinos com 24 classes, qual melhor topologia (quantidade de neurônios da camada oculta da MLP) para os especialistas, a qual variou entre 5, 10, 20, 50 e 100 neurônios. A Tabela 5.3 contém o número de neurônios dos especialistas que apresentaram melhor índice SP médio.

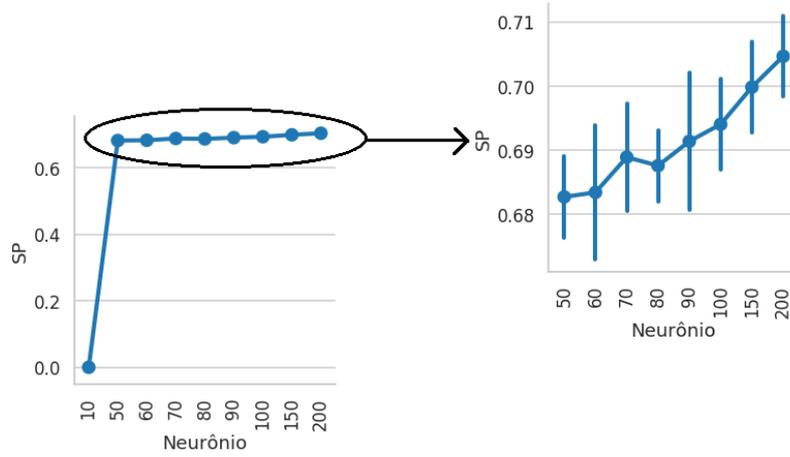


Figura 5.6: Índices SP médios para diversas quantidades de neurônios na camada oculta da MLP, para o conjunto de dados de 31 classes.

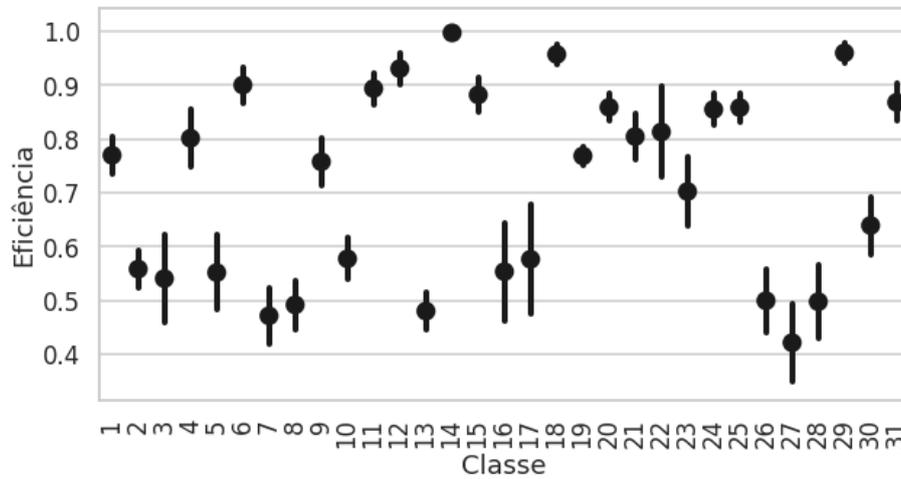


Figura 5.7: Eficiências médias da MLP com 200 neurônios na camada oculta para 31 classes.

Tabela 5.3: Topologias com melhores SP médios para cada especialista para o conjunto de dados com 24 classes.

Especialista	Nº de Neurônios	SP	Especialista	Nº de Neurônios	SP
1	100	$0,94 \pm 0,01$	13	100	$0,71 \pm 0,02$
2	100	$0,92 \pm 0,01$	14	50	$0,69 \pm 0,01$
3	100	$0,89 \pm 0,02$	15	50	$0,91 \pm 0,01$
4	20	$0,98 \pm 0,01$	16	50	$0,89 \pm 0,01$
5	50	$1,00 \pm 0,00$	17	50	$0,79 \pm 0,02$
6	100	$0,91 \pm 0,01$	18	100	$0,93 \pm 0,01$
7	100	$0,88 \pm 0,01$	19	50	$0,90 \pm 0,01$
8	5	$0,73 \pm 0,02$	20	50	$0,74 \pm 0,02$
9	10	$0,81 \pm 0,01$	21	50	$0,55 \pm 0,02$
10	50	$0,88 \pm 0,01$	22	100	$0,89 \pm 0,01$
11	5	$0,84 \pm 0,02$	23	10	$0,88 \pm 0,00$
12	100	$0,92 \pm 0,01$	24	100	$0,94 \pm 0,00$

Na Figura 5.8 estão os índices SP médios e seus desvios-padrões apresentados pelos especialistas para o conjunto de dados de 24 classes. Estes valores de SP foram calculados como a média apresentada em cada *fold* de treinamento.

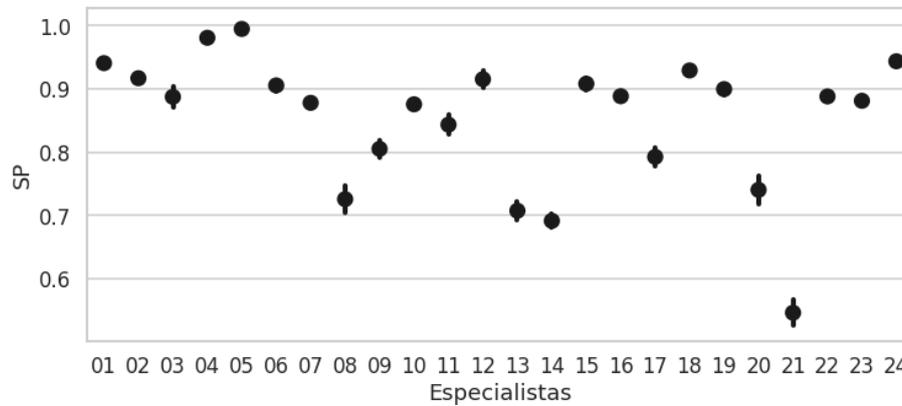


Figura 5.8: Índices SP médios e seus desvios-padrões para cada especialista do comitê de classes especialistas MLP, calculados como valor médio para cada *fold* de treinamento, para 24 classes.

Ao compor o comitê com os especialistas selecionados através das topologias que apresentaram melhores SP médios, calcularam-se as eficiências médias de classificação para o conjunto de dados com 24 classes, as quais se encontram na Figura 5.9, juntamente com seus desvios-padrões.

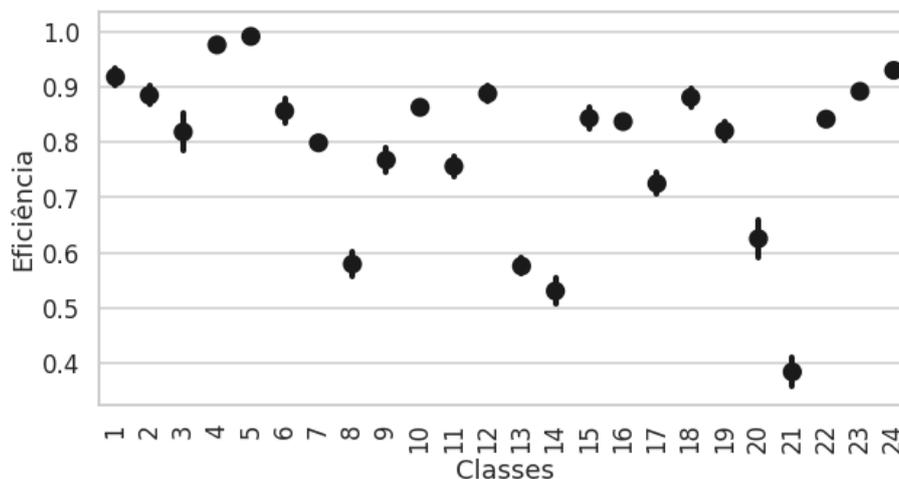


Figura 5.9: Eficiências médias e seus desvios-padrões do Comitê de Classes Especialistas MLP para o conjunto de dados de 24 classes.

De semelhante modo, foram calculados para o conjunto de dados do VIPP de 31 classes, as melhores topologias para cada especialista, em termos de valor médio de SP. A topologia verificada também variou entre 5, 10, 20, 50 e 100 neurônios. A Tabela 5.4 representa os melhores especialistas e suas respectivas topologias.

Na Figura 5.10 estão os índices SP médios e seus desvios-padrões apresentados

Tabela 5.4: Topologias com melhores SP médios para cada especialista para o conjunto de dados com 31 classes.

Especialista	Nº de Neurônios	SP	Especialista	Nº de Neurônios	SP
1	50	$0,87 \pm 0,02$	17	20	$0,64 \pm 0,06$
2	100	$0,65 \pm 0,05$	18	5	$0,97 \pm 0,01$
3	50	$0,74 \pm 0,04$	19	20	$0,85 \pm 0,02$
4	50	$0,78 \pm 0,02$	20	20	$0,89 \pm 0,02$
5	50	$0,70 \pm 0,03$	21	10	$0,84 \pm 0,03$
6	100	$0,95 \pm 0,01$	22	10	$0,85 \pm 0,04$
7	50	$0,57 \pm 0,02$	23	5	$0,80 \pm 0,04$
8	50	$0,70 \pm 0,04$	24	50	$0,93 \pm 0,02$
9	100	$0,85 \pm 0,04$	25	100	$0,92 \pm 0,02$
10	100	$0,65 \pm 0,05$	26	5	$0,65 \pm 0,04$
11	20	$0,96 \pm 0,01$	27	50	$0,56 \pm 0,05$
12	50	$0,96 \pm 0,01$	28	10	$0,72 \pm 0,03$
13	100	$0,65 \pm 0,07$	29	5	$0,98 \pm 0,01$
14	20	$1,00 \pm 0,00$	30	50	$0,70 \pm 0,03$
15	10	$0,91 \pm 0,02$	31	100	$0,92 \pm 0,02$
16	10	$0,63 \pm 0,04$	—	—	—

pelos especialistas para o conjunto de dados de 31 classes. Estes valores de SP foram calculados como a média apresentada em cada *fold* de treinamento.

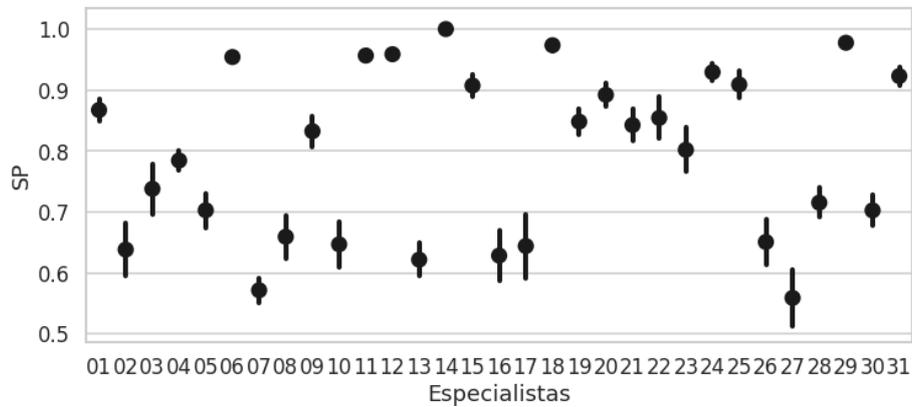


Figura 5.10: Índices SP médios e seus desvios-padrões para cada especialista do comitê de classes especialistas MLP, calculados como valor médio para cada *fold* de treinamento, para 31 classes.

Ao compor o comitê com os especialistas selecionados através das topologias que apresentaram melhores SP médios, calculou-se as eficiências médias de classificação para o conjunto de dados com 31 classes, as quais se encontram na Figura 5.11, juntamente com seus desvios-padrões.

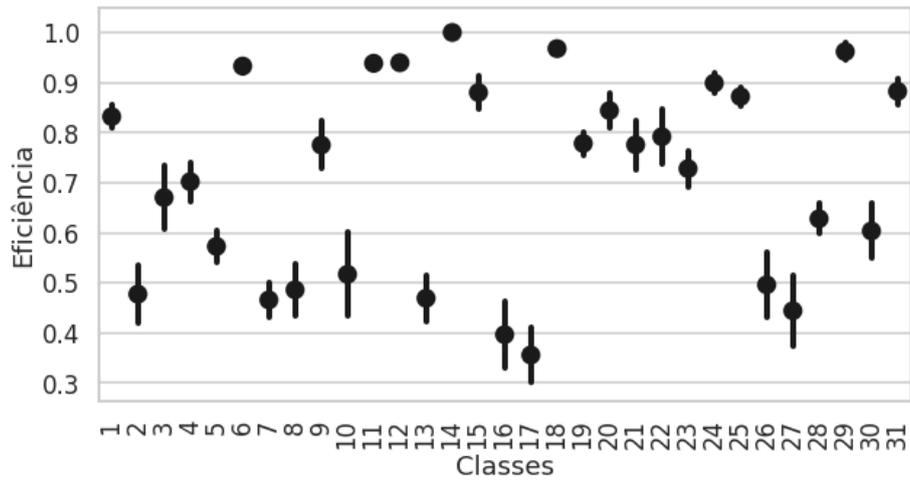


Figura 5.11: Eficiências médias e seus desvios-padrões do Comitê de Classes Especialistas MLP para o conjunto de dados de 31 classes.

5.2.3 Resultados para o Comitê de Classes Especialistas com Máquinas de Vetores de Suporte

Inicialmente foi verificado qual parâmetro C , do processo de treinamento do comitê de SVM, obteve melhor SP médio para o conjunto de validação, para os dados com 24 classes e depois para 31 classes. Variou-se C entre os valores presentes no eixo das abcissas dos gráficos da Figura 5.12. Nestes gráficos, o eixo das ordenadas representa os valores de SP médios para cada valor de C , para cada conjunto de dados.

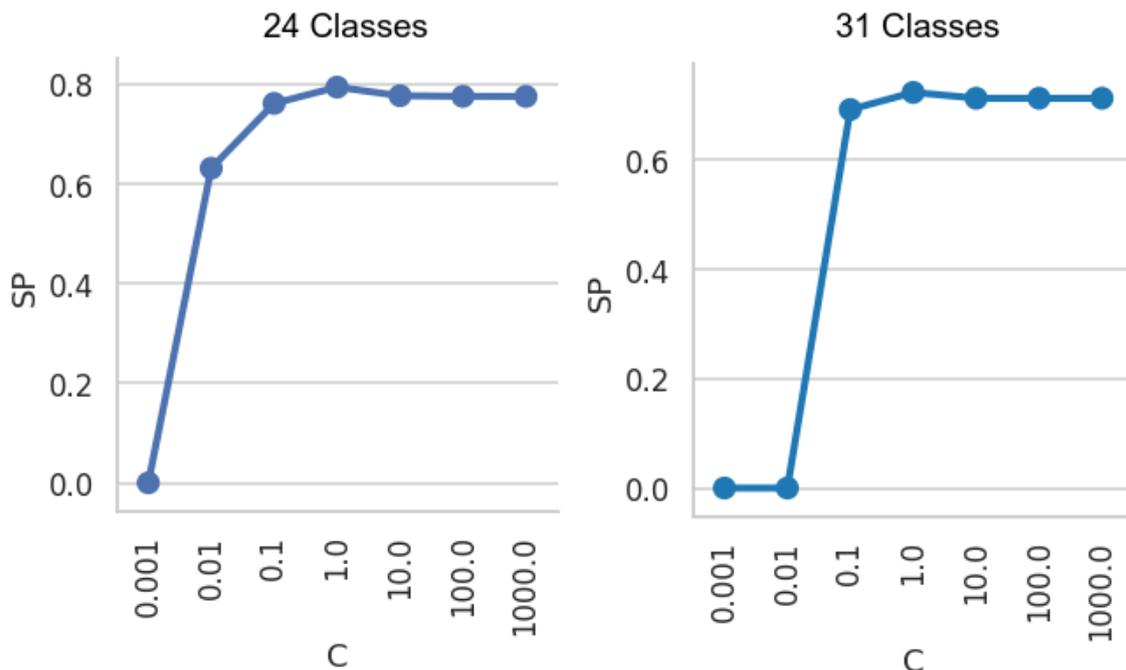


Figura 5.12: SP médios para os valores de C usados no processo de treinamento das SVM, para ambos os conjuntos de dados.

Escolheu-se com base na Figura 5.12, o valor de C igual a 1 para ambos os conjuntos de dados. Com isso, os comitês de SVM para 24 e 31 classes ficaram com as topologias representadas na Figura 5.13.

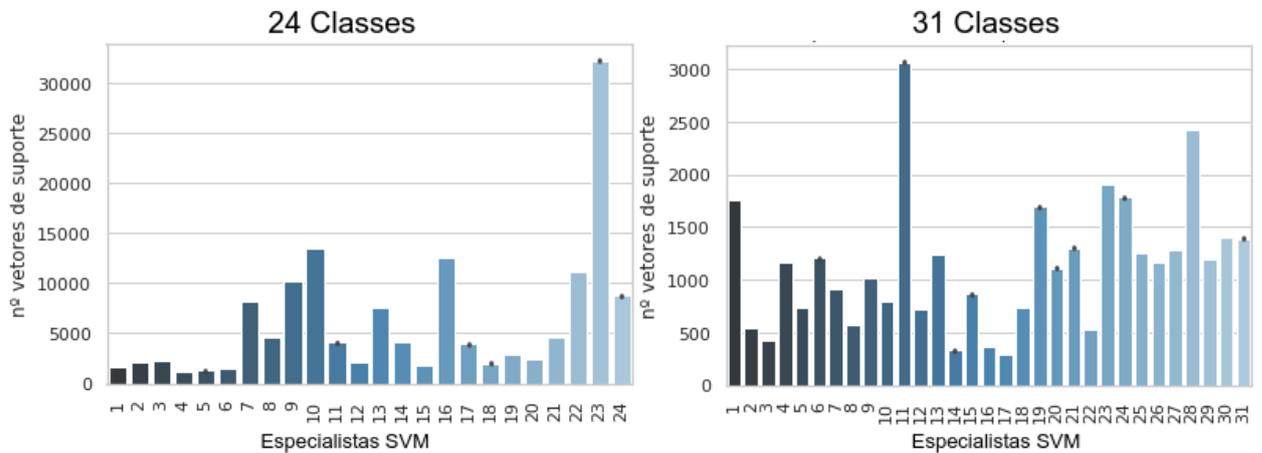


Figura 5.13: Quantidade de Vetores de Suporte para cada especialista do comitê de SVM, para o conjunto de dados de 24 e 31 classes.

Na Figura 5.14 estão representadas as eficiências de classificação do comitê de especialistas SVM para o conjunto de dados de 24 classes, e na Figura 5.15 para 31 classes.

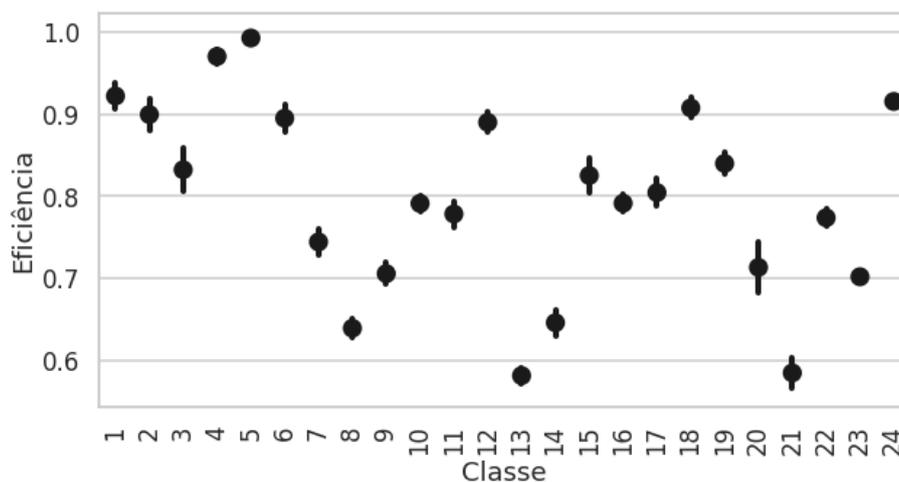


Figura 5.14: Eficiências médias e seus desvios-padrões do Comitê de Classes Especialistas SVM para o conjunto de dados de 24 classes.

5.2.4 Resultados para o Comitê Hierárquico

Utilizando o conjunto de dados dos submarinos com 24 classes, verificou-se inicialmente qual melhor topologia (quantidade de neurônios da camada oculta da MLP) para os membros do comitê hierárquico, a qual variou entre 5, 10, 20, 30, 50, 100 e

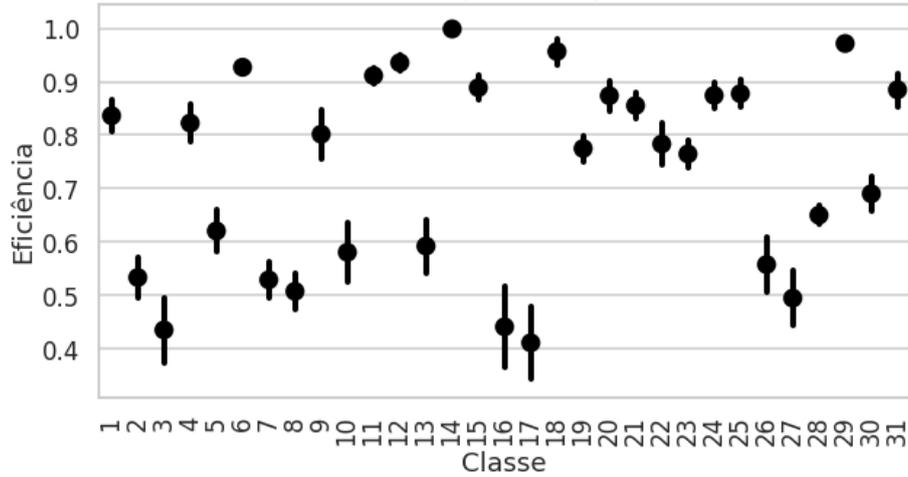


Figura 5.15: Eficiências médias e seus desvios-padrões do Comitê de Classes Especialitas SVM para o conjunto de dados de 31 classes.

200 neurônios. A Figura 5.16 representa a variação do SP para as topologias abordadas. Foi escolhida a topologia de 100 neurônios por apresentar melhor SP médio para o comitê, igual a $0,73 \pm 0,01$.

Na Figura 5.17 estão os índices SP médios e seus desvios-padrões apresentados pelos membros do comitê hierárquico para o conjunto de dados de 24 classes. Estes valores de SP foram calculados como a média apresentada em cada *fold* de treinamento.

Ao compor o comitê com os membros selecionados através das topologias que apresentaram melhores SP médios, calcularam-se as eficiências médias de classificação para o conjunto de dados com 24 classes, as quais se encontram na Figura 5.18, juntamente com seus desvios-padrões.

Aplicando o conjunto de dados de 31 classes ao comitê hierárquico, inicialmente verificou-se a melhor topologia para cada membro. Conforme visto na Sessão 4.5, vale lembrar que os membros deste comitê diferenciam-se de um conjunto de dados para outro. As topologias verificadas variaram entre 5, 10, 20, 30, 50, 100 e 200 neurônios. A Figura 5.19 representa a variação do SP para as topologias abordadas. Foi escolhida a topologia de 50 neurônios por apresentar melhor SP médio para o comitê, igual a $0,61 \pm 0,02$.

Na Figura 5.20 estão os índices SP médios e seus desvios-padrões apresentados pelos membros do comitê hierárquico para o conjunto de dados de 31 classes. Estes valores de SP foram calculados como a média apresentada em cada *fold* de treinamento.

Ao compor o comitê com os membros selecionados através das topologias que apresentaram melhores SP médios, calcularam-se as eficiências médias de classificação para o conjunto de dados com 31 classes, as quais se encontram na Figura

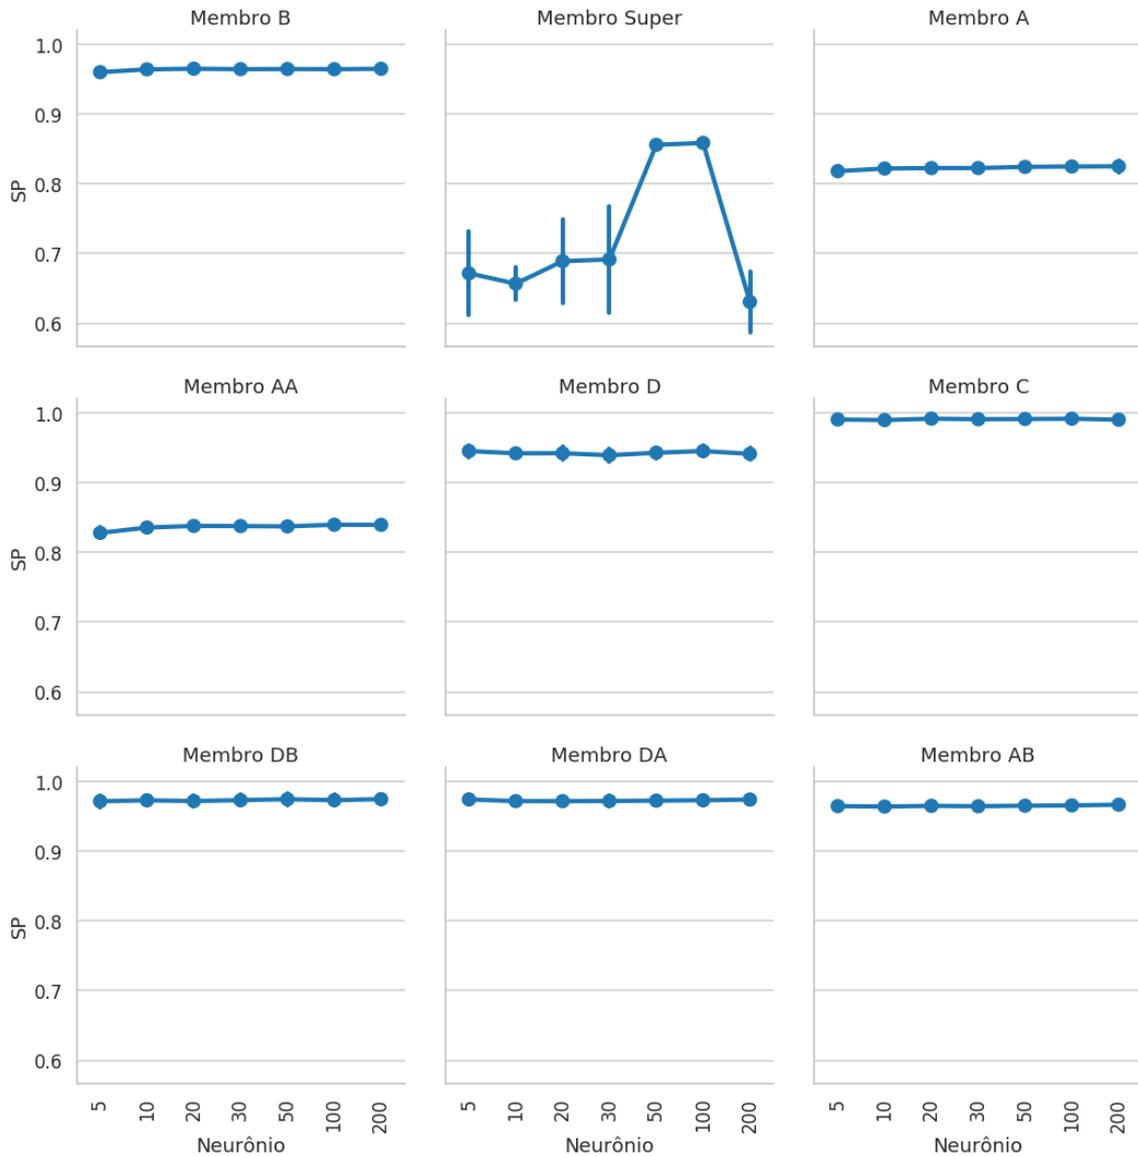


Figura 5.16: Variação do índice SP em função da quantidade de neurônios para cada membro do comitê hierárquico, calculados como valor médio para cada *fold* de treinamento para 24 classes.

5.21, juntamente com seus desvios-padrões.

5.2.5 Síntese dos Resultados e Análise Hierárquica

Na Tabela 5.5 estão compilados os valores de SP médios alcançados pelos quatro classificadores abordados. As matrizes de confusão não foram apresentadas devido ao grande tamanho (24x24 e 31x31), porém na Tabela 5.6 estão representadas as maiores confusões produzidas pelos classificadores, na forma da razão entre a quantidade de exemplos confundidos com determinada classe dividido pelo número de exemplos da classe correta. Vale ressaltar que as Figuras 5.5, 5.7, 5.9, 5.11, 5.14, 5.15, 5.18 e 5.21 representam a diagonal principal das matrizes de confusão dos

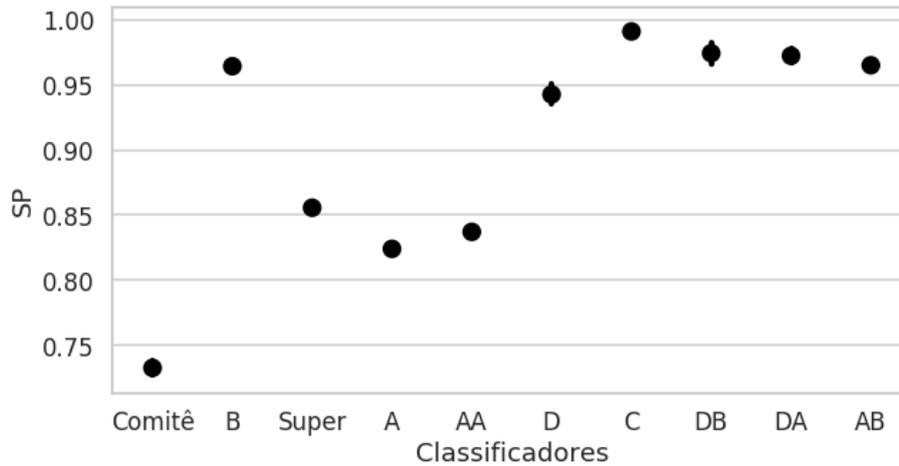


Figura 5.17: Índices SP médios e seus desvios-padrões para cada membro do comitê hierárquico, calculados como valor médio para cada *fold* de treinamento para 24 classes.

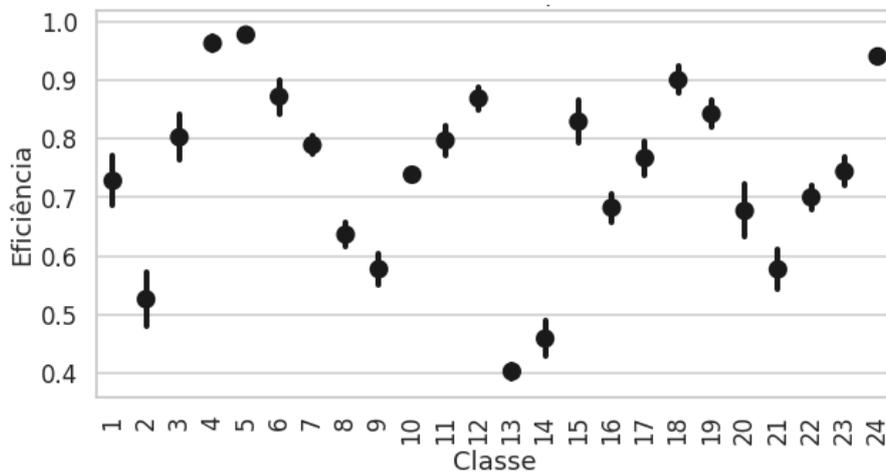


Figura 5.18: Eficiências médias e seus desvios-padrões do Comitê Hierárquico para o conjunto de dados de 24 classes.

classificadores para os dois conjuntos de dados abordados.

Tabela 5.5: Índices SP médios (e seus desvios padrões) para cada classificador abordado para cada conjunto de dados (24 e 31 classes).

Classificadores	24 Classes	31 Classes
MLP	0,80 ± 0,00	0,70 ± 0,07
Especialistas MLP	0,77 ± 0,01	0,70 ± 0,01
Especialistas SVM	0,79 ± 0,01	0,72 ± 0,01
Hierárquico	0,73 ± 0,01	0,61 ± 0,02

Com base na Tabela 5.6, elencaram-se a classe 13 (do conjunto de dados de 24 classes) e a classe 16 (do conjunto de dados de 31 classes) para a análise hierárquica (definida na Sessão 4.5.1). Para isso, fez-se a apresentação gráfica do quantitativo de confusões destas classes para os quatro classificadores abordados. Sendo as Figuras

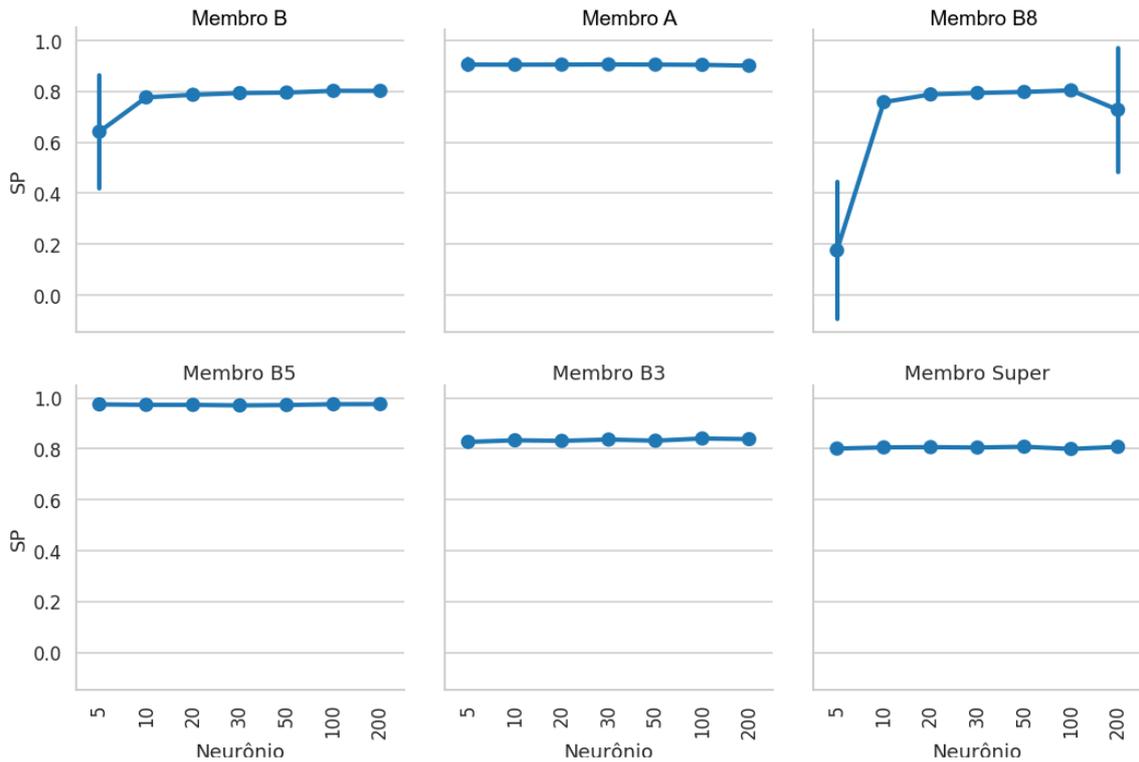


Figura 5.19: Variação do índice SP em função da quantidade de neurônios para cada membro do comitê hierárquico, calculados como valor médio para cada *fold* de treinamento para 31 classes.

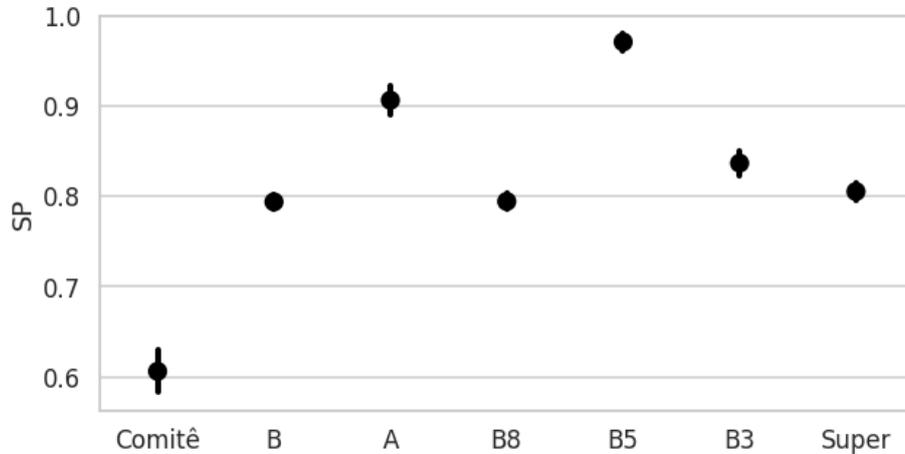


Figura 5.20: Índices SP médios e seus desvios-padrões para cada membro do comitê hierárquico, calculados como valor médio para cada *fold* de treinamento para 31 classes.

5.22 e 5.26 referentes a estas classes para a MLP, as Figuras 5.23 e 5.27 para o comitê de especialistas MLP, as Figuras 5.24 e 5.28 para o comitê de especialistas SVM e as Figuras 5.25 e 5.29 para o comitê Hierárquico.

Nas Figuras 5.22, 5.26, 5.23, 5.27, 5.24 e 5.28, a classe esperada (da qual utilizou-se de suas janelas para ativar um determinado classificador) está representada na cor vermelha. As demais classes contidas nos eixos das abcissas são aquelas onde

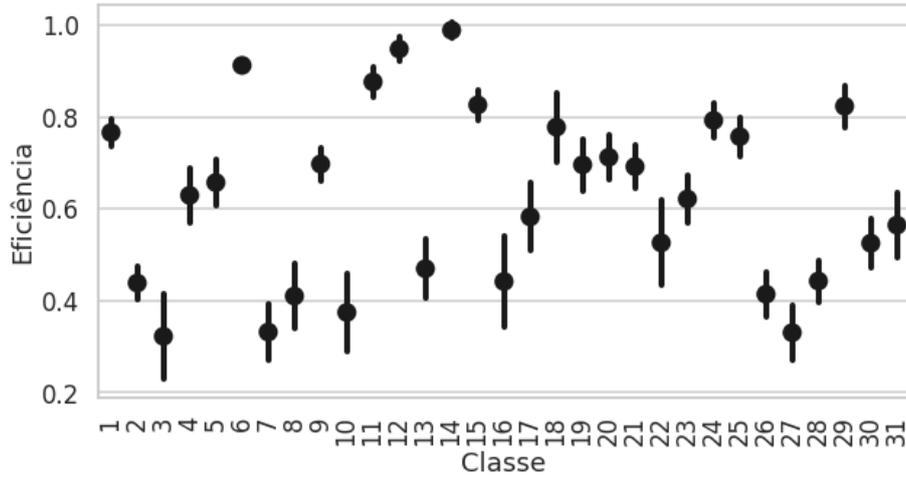


Figura 5.21: Eficiências médias e seus desvios-padrões do Comitê Hierárquico para o conjunto de dados de 31 classes.

Tabela 5.6: Maiores confusões produzidas pelos classificadores. O valor de confusão é a razão entre o número de exemplos confundidos com determinada classe e o número de exemplos da classe esperada.

24 Classes			
	Classe Esperada	Classe Confundida	Confusão
MLP	13	21	$0,14 \pm 0,02$
	21	13	$0,12 \pm 0,03$
Especialistas MLP	13	23	$0,19 \pm 0,01$
	21	23	$0,25 \pm 0,03$
Especialistas SVM	21	13	$0,13 \pm 0,01$
	13	21	$0,16 \pm 0,01$
Hierárquico	13	21	$0,24 \pm 0,03$
	14	08	$0,14 \pm 0,04$
31 Classes			
MLP	16	01	$0,18 \pm 0,07$
	26	27	$0,10 \pm 0,03$
Especialistas MLP	16	01	$0,24 \pm 0,07$
	04	11	$0,19 \pm 0,03$
Especialistas SVM	16	01	$0,28 \pm 0,10$
	03	28	$0,17 \pm 0,05$
Hierárquico	04	11	$0,21 \pm 0,05$
	16	01	$0,34 \pm 0,08$

houve confusão com a classe representada na cor vermelha, sendo as classes irmãs em laranja (quando houve ocorrência), as classes primas em amarelo (quando houve ocorrência) e representadas em azul as demais classes confundidas. O desvio-padrão é representado com uma barra preta acima das colunas que representam os contadores das classes.

Na Tabela 5.7 encontram-se os valores médios e seus desvios-padrões da razão entre o número de falsos positivos classificados como classes irmãs e primas e o número total de falsos positivos para a classe 13 do conjunto de dados de 24 classes

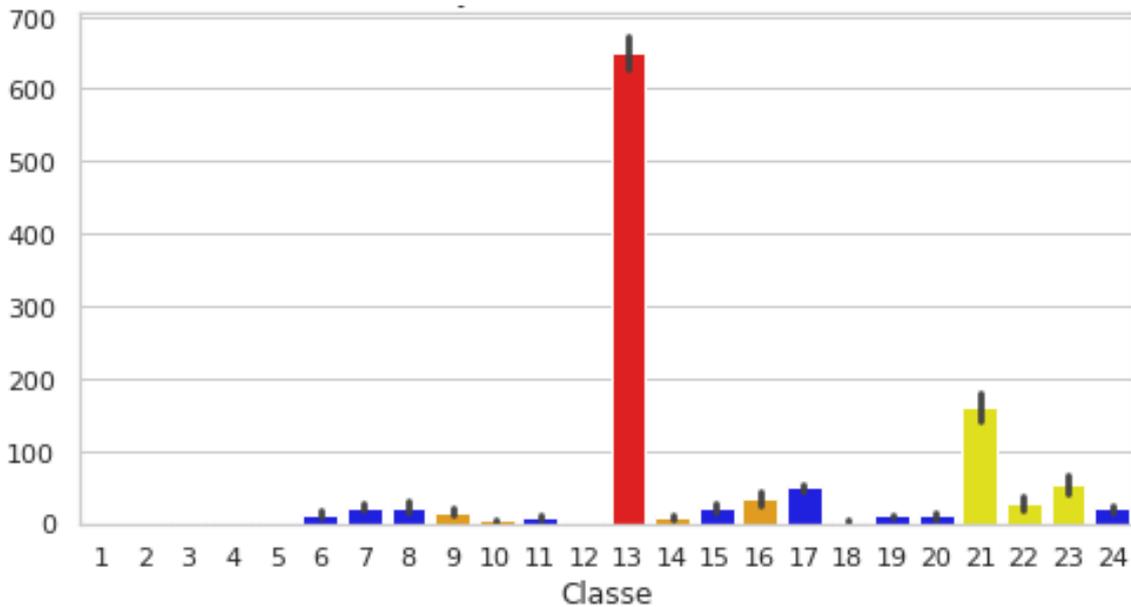


Figura 5.22: Classes estimadas pela MLP com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.

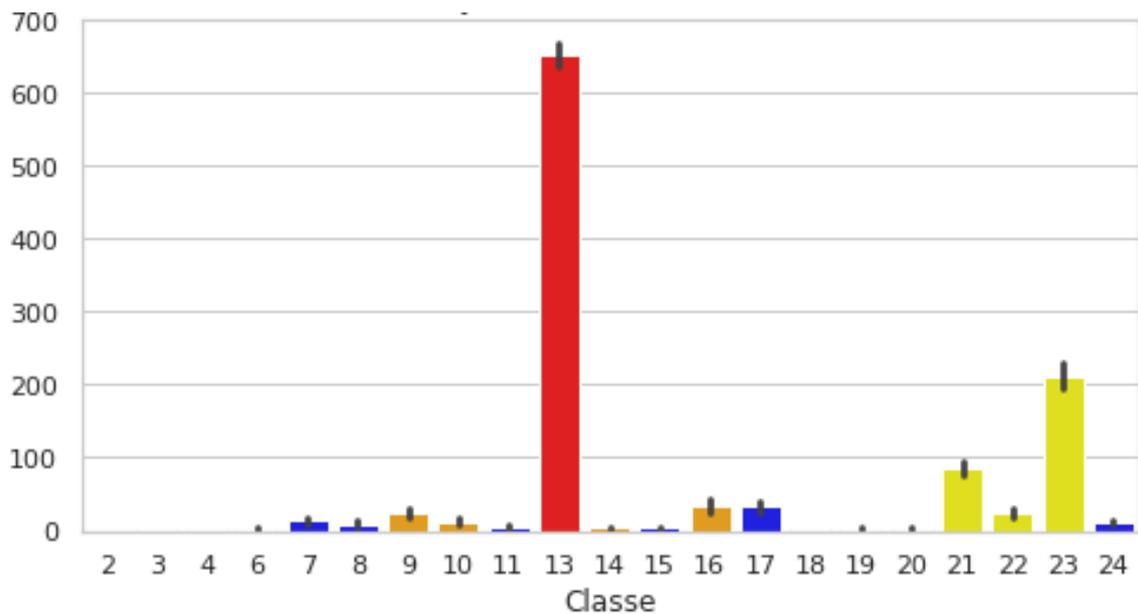


Figura 5.23: Classes estimadas pelo comitê de especialistas MLP com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.

e para classe 16 do conjunto de dados de 31 classes, para os quatro classificadores abordados neste trabalho. Também foram inseridos na Tabela 5.7 os valores de eficiência de classificação destas duas classes analisadas.

No capítulo a seguir é realizada uma discussão dos resultados apresentados, seguido de algumas conclusões e trabalhos futuros propostos.

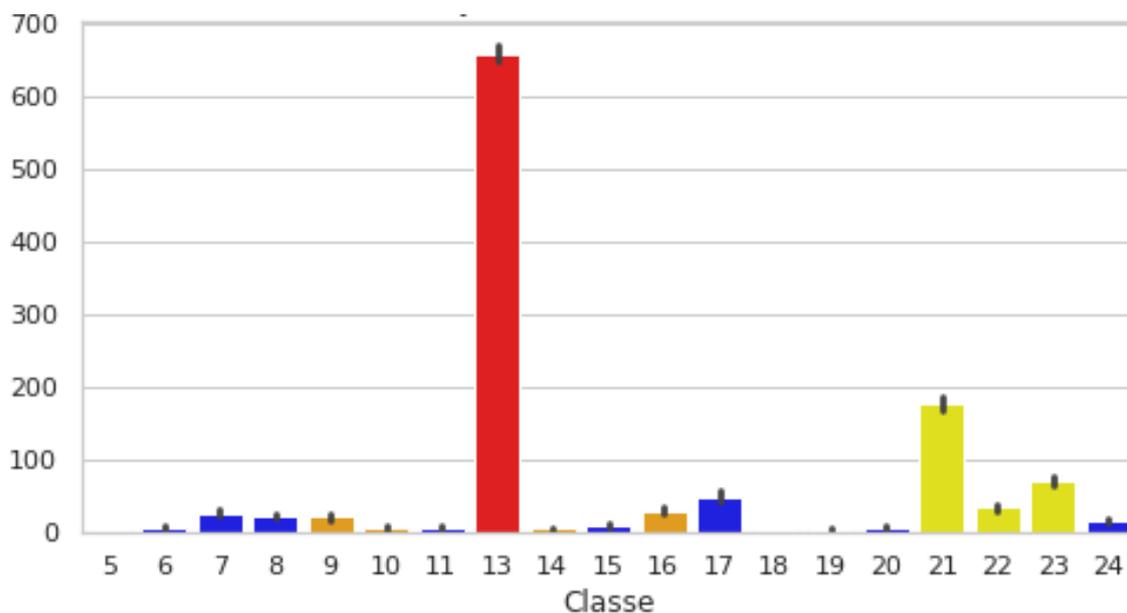


Figura 5.24: Classes estimadas pelo comitê de especialistas SVM com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.

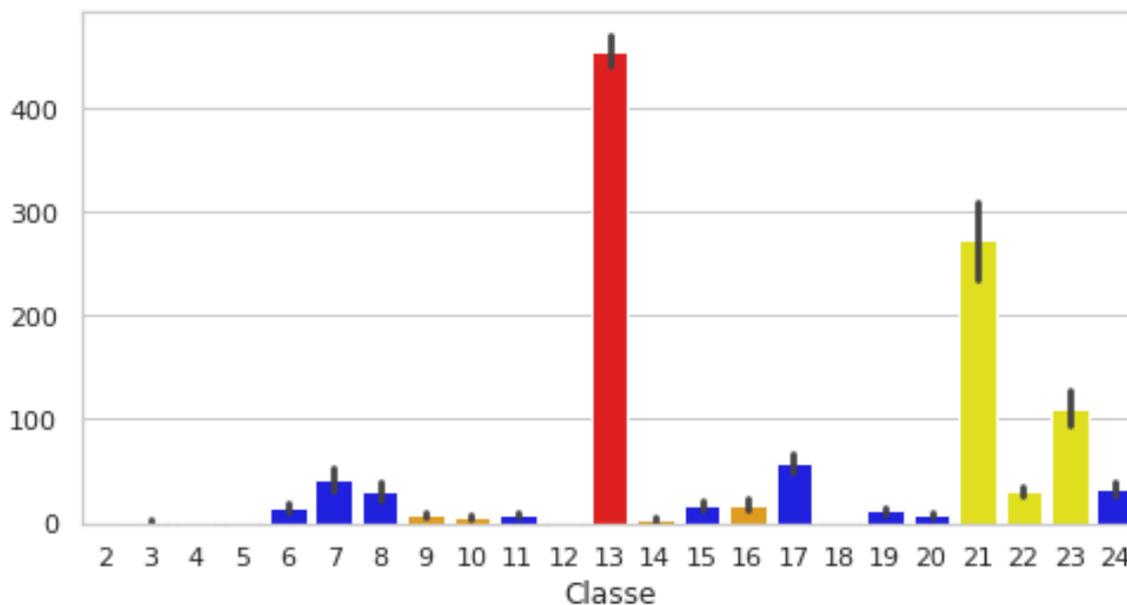


Figura 5.25: Classes estimadas pelo comitê Hierárquico com ativação dos exemplos da classe 13 do conjunto de dados de 24 classes. O eixo das ordenadas é o contador das classes estimadas.

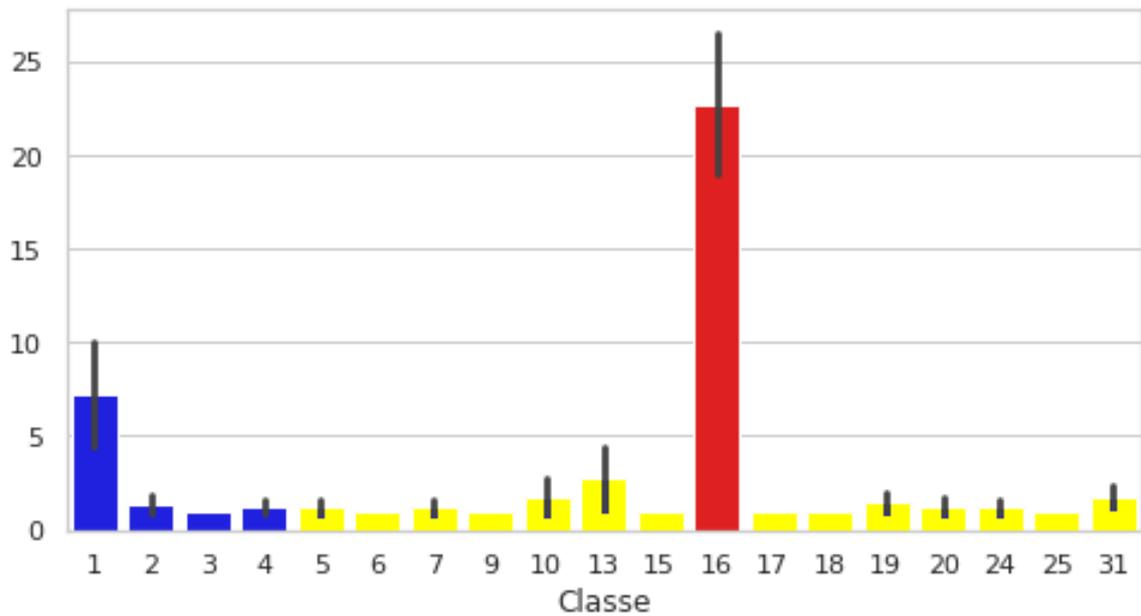


Figura 5.26: Classes estimadas pela MLP com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.

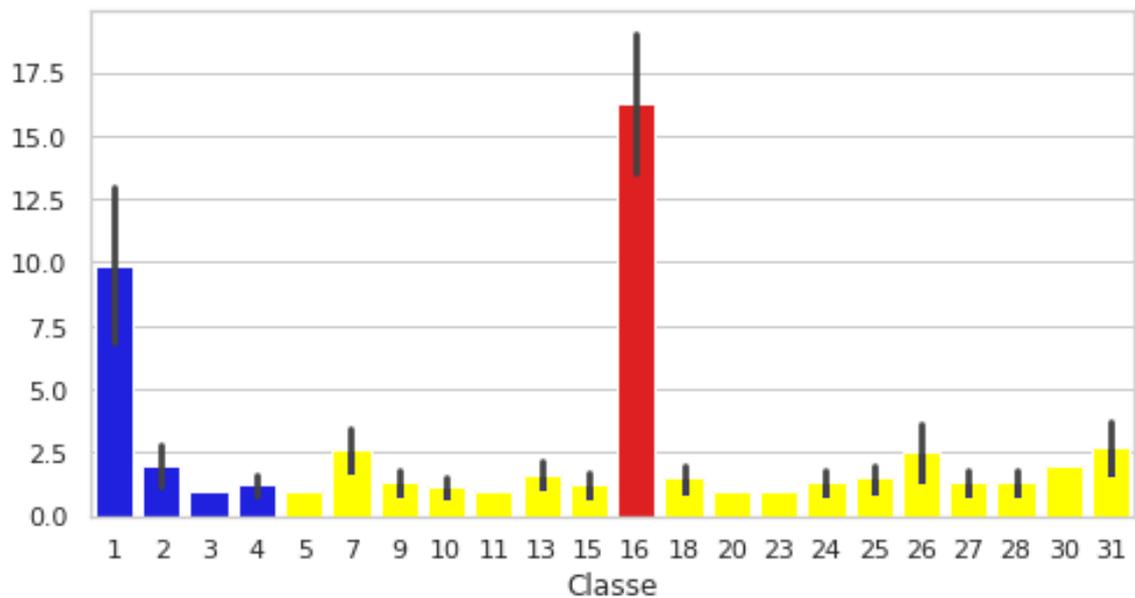


Figura 5.27: Classes estimadas pel comitê de especialistas MLP com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.

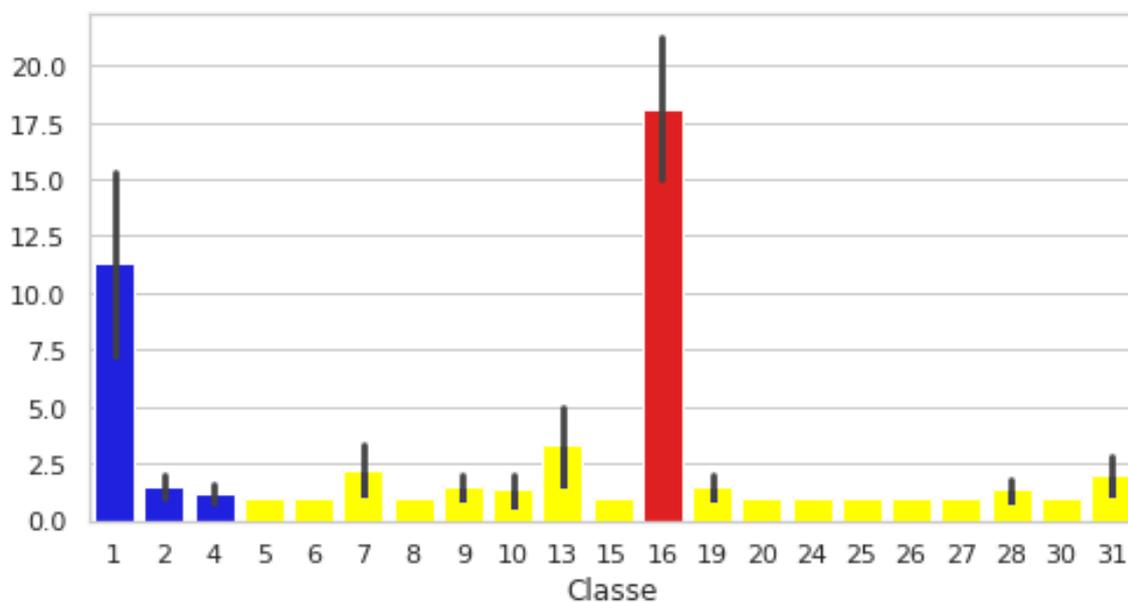


Figura 5.28: Classes estimadas pelo comitê de especialistas SVM com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.

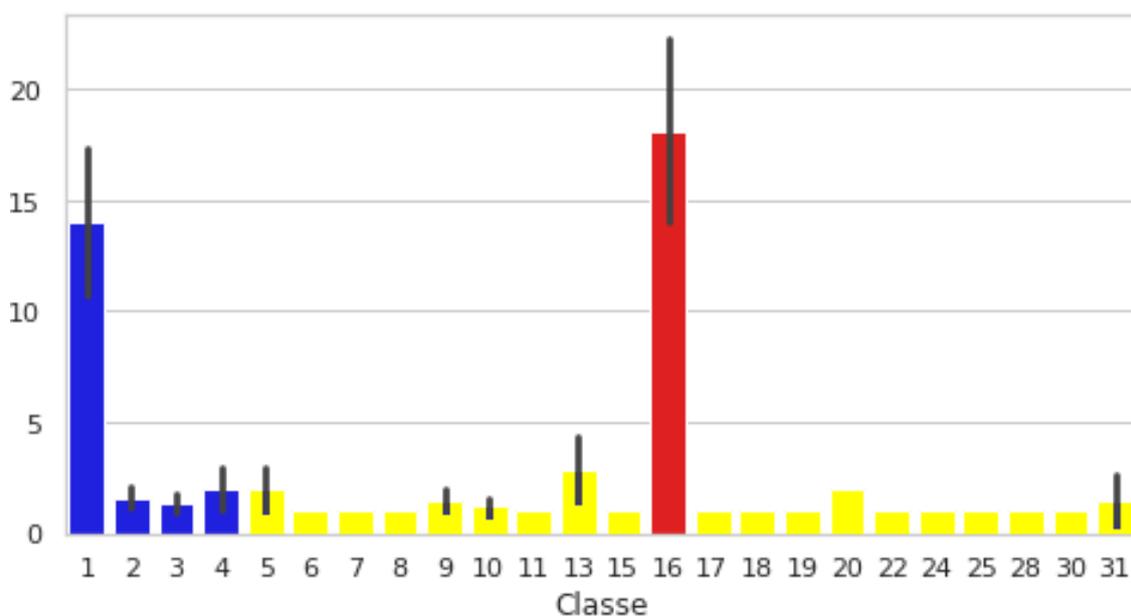


Figura 5.29: Classes estimadas pelo comitê Hierárquico com ativação dos exemplos da classe 16 do conjunto de dados de 31 classes. O eixo das ordenadas é o contador das classes estimadas.

Tabela 5.7: Análise hierárquica das classes 13 (do conjunto de 24 classes) e 16 (do conjunto de 31 classes) e suas respectivas eficiências de classificação para cada classificador. FPIP: razão entre o número de Falsos Positivos de Irmãs e Primas e o número de falsos positivos totais para a classe em análise.

Classificadores	Classe 13 (24 Classes)		Classe 16 (31 Classes)	
	Eficiência	FPIP	Eficiência	FPIP
MLP	$0,57 \pm 0,02$	$0,74 \pm 0,01$	$0,55 \pm 0,09$	$0,46 \pm 0,15$
Especialistas MLP	$0,58 \pm 0,01$	$0,87 \pm 0,02$	$0,40 \pm 0,07$	$0,48 \pm 0,13$
Especialistas SVM	$0,58 \pm 0,01$	$0,72 \pm 0,01$	$0,44 \pm 0,08$	$0,49 \pm 0,04$
Hierárquico	$0,40 \pm 0,01$	$0,67 \pm 0,02$	$0,44 \pm 0,10$	$0,33 \pm 0,16$

Capítulo 6

Discussão, Conclusões e Trabalhos Futuros

6.1 Discussão

A MLP, em ambos os conjuntos de dados, ao ser treinada com 50 neurônios na camada oculta, atingiu um valor de SP médio próximo do melhor resultado, como pode ser visto nas Figuras 5.4 e 5.6, ficando estável entre 50 e 200 neurônios. Para o conjunto de 24 classes, a MLP obteve melhor índice SP entre os classificadores analisados. As classes 13 e 21 foram as que a MLP apresentou maior dificuldade em classificar, conforme Figura 5.5, as quais também resultaram numa maior confusão, como pode ser visto na Tabela 5.6. Esta confusão foi recíproca entre as classes 13 e 21.

Para o conjunto de dados de 31 classes, a MLP apresentou menores valores de SP para as classes 7 e 27 (vide Figura 5.7), porém as maiores confusões foram obtidas com as classes 16 e 26 (vide Tabela 5.6).

Ao analisar as Figuras 5.8 e 5.9 referentes ao conjunto de dados de 24 classes, nota-se que se manteve uma correlação entre os valores de SP de cada membro do comitê com as eficiências de cada classe para o comitê integrado. O mesmo ocorreu entre as Figuras 5.10 e 5.11 referentes ao conjunto de dados de 31 classes.

Para ambos os conjuntos de dados, a quantidade de neurônios na camada oculta para cada especialista variou significativamente (5 a 100) ao buscar a melhor topologia em função do valor de SP (vide Tabelas 5.3 e 5.4). Esse fenômeno também ocorreu com os especialistas em [15].

O comitê de classes especialistas SVM obteve o melhor índice SP médio entre os classificadores abordados. Ao buscar o melhor SP em função de alguns valores de C , para ambos os conjuntos de dados, o valor de C igual a 1 obteve melhores resultados, como visto na Figura 5.12. Na Figura 5.13 pode-se visualizar que, para ambos os

conjuntos de dados, as quantidades de vetores de suporte para as diferentes classes variaram significativamente entre si, com valores da ordem de 1000 a 30000 vetores para o conjunto de dados de 24 classes e valores da ordem de 250 a 3000 vetores para o conjunto de dados de 31 classes.

O comitê hierárquico apresentou os menores índices SP médios dentre os classificadores abordados. Ao visualizar a variação do SP pela quantidade de neurônios na camada oculta da MLP que representa cada membro do comitê hierárquico (Figuras 5.16 e 5.19) nota-se que em geral os membros apresentaram baixa variação do SP ao variar a topologia, exceto nos casos do membro Super para 24 classes e para o membro B8 para 31 classes.

Para o conjunto de dados de 24 classes, as maiores confusões apresentadas pelos classificadores envolveram as classes 13, 21 e 23 (vide Tabela 5.6). Estas três classes pertencem à nova classe A do comitê hierárquico. Nota-se que o desbalanceamento da quantidade de janelas entre as classes não influenciou significativamente os classificadores implementados, mas a semelhança entre as classes (13, 21 e 23) provocou as maiores confusões registradas.

As classes 13, 21 e 23 do conjunto de dados com 24 classes representam navios com projeto de propulsão muito semelhantes, do tipo CODOG (*Combined Diesel or Gas*). As três classes são provenientes de projetos de países da Europa Ocidental, possuem dois motores a diesel, duas turbinas a gás, dois eixos propulsores, velocidades de operação durante o combate da ordem de 30 nós e foram projetados para o mesmo tipo de missão: Guerra A/S (Anti-Submarina). Essas características próximas podem ocasionar assinaturas acústicas semelhantes entre essas classes de navios, dificultando a tarefa de classificação e facilitando a confusão entre estas classes, ocorrida em todos os classificadores implementados.

As classes 3, 5, 7, 15, 18 e 20 do conjunto de dados de 24 classes são de navios cujos projetos otimizam a mínima produção de ruído acústico, logo são classes mais difíceis de serem detectadas pelos sonares em comparação com as demais classes do referido conjunto de dados. A minimização do ruído acústico acarreta na minimização de ocorrências de tons no espectro destes navios, logo a dificuldade de classificá-los também aumenta, visto que o aprendizado dos classificadores aqui implementados baseia-se na informação tonal. Analisando as eficiências dos classificadores para classes citadas (vide Figuras 5.5, 5.9, 5.14 e 5.18), nota-se que no geral todos os classificadores implementados não apresentaram dificuldade em classificar as referidas classes.

Na análise hierárquica, nota-se que em geral, os classificadores tiveram um comportamento semelhante na classificação das classes elencadas para a referida análise. Para a classe 13 do conjunto de dados de 24 classes, houve uma reciprocidade entre esta e a classe 21 no que diz respeito à confusão, porém isso não ocorreu entre as clas-

ses 16 e 1 do conjunto de dados de 31 classes. Como já descrito anteriormente, além da semelhança operativa entre a classe 13 e 21 (do conjunto de dados de 24 classes), também há uma semelhança em sua assinatura acústica, o mesmo não ocorre com as classes 16 e 1 (do conjunto de dados de 31 classes).

6.2 Conclusões

De um modo geral, os classificadores tiveram mais dificuldade em classificar o conjunto de dados de 31 classes (oriundas de gravações do VIPP) que o conjunto de 24 classes (oriundas de gravações de submarinos), como visto na Tabela 5.5. Isso ocorreu não somente pelo fato de um conjunto de dados possuir mais classes que o outro, mas também por conta de muitos outros fatores. Um deles é o fato de que as corridas gravadas pelos submarinos (24 classes) possuem muito mais amostras (ou exemplos) por classe que os dados do VIPP (31 classes), como pode ser visto ao comparar as Tabelas 5.1 e 5.2. Um submarino fica muitos minutos, às vezes horas, acompanhando pelo sonar determinado contato, isso possibilita uma coleta de muitas amostras do ruído deste contato. O inverso ocorre no VIPP, pois este se encontra instalado num canal de navegação muito estreito, entre uma ilha e o continente, isso fez com que seus contatos permanecessem no máximo um ou dois minutos ao alcance do sonar, isso acarretou em gravações com poucas amostras das classes. Outro fator relevante é a diferença de um sistema sonar para outro (VIPP e sonares de submarinos), principalmente no que diz respeito ao número de hidrofones e filtragem do sinal. Um submarino possui milhares de hidrofones (dispostos em diversos arranjos conforme descrito no Capítulo 2) enquanto o VIPP não chega a uma centena. O sinal gravado a partir do áudio disponibilizado ao OS, num submarino, passa por uma filtragem (esta desconhecida, apenas de conhecimento do fabricante). Os sinais do VIPP não foram filtrados. Estas duas diferenças influenciam na qualidade do sinal no que diz respeito à relação sinal-ruído.

Após a revisão bibliográfica, concluiu-se a falta de trabalhos, na literatura aberta ao público, aplicados na classificação de sinais oriundos de sensores de um submarino, bem como a preocupação em projetar classificadores aplicados à realidade operativa de um submarino para fins militares. O número de trabalhos que utilizam classes de navios militares é limitado. Não foram encontrados trabalhos com número de classes de navios superiores a 8. Os bancos de dados utilizados neste trabalho, superiores a 8 classes, possuem 24 classes para sinais adquiridos de submarinos operando em águas profundas e coletando sinais de navios também em regime operativo, e 31 classes para sinais adquiridos em um sistema de monitoração de tráfego marítimo de zona portuária.

Como visto no capítulo 2, navios militares operam com equipamentos e/ou

técnicas que visam confundir o sonar de um submarino. O banco de dados de 24 classes possui somente navios militares, os quais foram gravados em condições operativas, tanto na forma como foram adquiridos (do sensor de um submarino) quanto na forma como os navios gravados estavam operando no momento da gravação. Estes fatores são importantes quando se quer desenvolver uma ferramenta de classificação a ser empregada no mar para fins militares.

Uma vez operando juntamente com o OS num submarino, o comitê hierárquico pode retornar para o usuário não somente sua saída do último nível hierárquico, mas sim, apresentar ao OS a saída de todos os níveis hierárquicos. Por exemplo, com base na Figura 4.2, supõe-se que o OS está na dúvida entre o navio ser da classe 10 ou 12, porém tem certeza que o navio é uma dessas classes. Supõe-se que a saída do comitê hierárquico foi a classe 21, com uma “nota” (pode ser a saturação do neurônio de saída da classe) igual a 0,60, porém, para o comitê chegar à classe 21, a “nota” do membro Super para a nova classe A foi 0,90. Logo, a saída do membro Super pode subsidiar o OS a escolher como a verdadeira classe do navio a classe 10, pois esta classe está abaixo da nova classe A a qual o comitê apresentou uma nota “alta” (comparada à nota 0,60 de sua saída final) igual a 0,90.

O modelo hierárquico proposto neste trabalho pode ser utilizado como um classificador e como uma análise da ocorrência de falsos positivos classificados como classes irmãs e primas da classe esperada. Para esta análise foi criada uma figura de mérito. Em função da aplicação da tarefa de classificação, podem ser criadas outras relações entre as classes, além de irmãs e primas, bem como podem ser definidas outras figuras de mérito.

Este trabalho abordou a demanda de desenvolvimento de um classificador nacional para os submarinos brasileiros, especialmente ao submarino nuclear. Tal ferramenta é dificilmente adquirida no mercado internacional, e quando estão disponíveis para aquisição, são ferramentas do tipo “caixa preta”, não havendo garantia de seu correto e pleno funcionamento. Outra demanda da MB abordada neste trabalho é a classificação de sinais acústicos de navios aplicada ao SisGAAz (Sistema Gerenciamento da Amazônia Azul) com o uso do conjunto de dados de 31 classes, o qual engloba navios civis e militares, navegando em águas rasas de regiões portuárias, coletados pelo VIPP (Vigilância Passiva em Portos), sistema de monitoramento desenvolvido pelo IPqM.

Os comitês classificadores abordados neste trabalho apostam na estratégia de “dividir para conquistar” [16]. Nos comitês de especialistas (MLP e SVM), o problema de classificação foi subdividido entre as unidades especialistas de forma que cada uma preocupou-se em discriminar uma classe específica das demais. No comitê hierárquico, o problema foi subdividido em níveis hierárquicos contendo subconjuntos das classes originais do problema, escolhidas com base no conhecimento

especialista.

Na revisão da literatura, o uso de máquinas de comitê para classificação em sonar foi observado apenas em OLIVEIRA E SOUZA e SEIXAS [15]. Aqui o trabalho referenciado foi testado para um número muito maior de classes, com acentuado desbalanceamento de classes e elevado número de janelas totais para aprendizado em comparação com o conjunto de dados de oito classes. Nos modelos de classes especialistas, devem ser treinados e ativados n especialistas, neste caso, n igual a 24 e 31. Já o comitê hierárquico, no caso das 24 classes, ativam-se três redes MLP no máximo, sendo alguns casos apenas duas. Ainda para o caso de 24 classes, o comitê hierárquico demandou o treinamento de apenas 9 redes neurais (Super, A, B, C, D, AA, AB, DA e DB). Para 31 classes, o modelo hierárquico também ativa de 2 a 3 redes neurais e foi feito o treinamento de 6 redes neurais (Super, A, B, B3, B5 e B8).

No caso na necessidade de inclusão de nova classe, os comitês de classes especialistas necessitam do treino de um novo especialista, no caso do modelo hierárquico, este deve ter o membro do nível hierárquico acima da nova classe retreinado.

6.3 Trabalhos Futuros

O pré-processamento de sinais utilizado neste trabalho foi desenvolvido por SOARES FILHO [13] com foco em sinais coletados em raia acústica, diferentemente dos dados deste trabalho. Futuros avanços no pré-processamento de sinais especialmente desenvolvido para os dados utilizados neste trabalho podem auxiliar no incremento dos índices SP alcançados.

O comitê hierárquico pode ser implementado substituindo suas redes MLP por *ensembles* ou comitês de classes especialistas, em qualquer nível hierárquico. Como trabalho futuro também se sugere o estudo da inclusão de novas classes nos modelos, conforme realizado em [15].

Ao visitar o *site* de informações gerais *Wikipedia* [78] observa-se numa rápida contagem que as duas maiores Marinhas do mundo, pertencentes aos Estados Unidos da América e à China, possuem cada uma da ordem de quinhentos navios de guerra, categorizados em aproximadamente cinquenta classes. Este fato mostra que o atual banco de dados utilizado neste trabalho ainda é pequeno em comparação com a quantidade e navios existentes numa escala mundial, logo o contínuo incremento deste banco de dados se faz necessário como trabalho futuro.

A saída do comitê de classes especialistas pode ser verificada com o uso dos membros do comitê hierárquico da forma como o exemplo a seguir, para o conjunto de 24 classes: supõe-se que o comitê de especialistas inferiu a classe 10 como resposta de determinada classificação, então ativa-se o membro AA do comitê hierárquico

e este pode confirmar a classe 10 como saída dos especialistas. Essa forma de integração se torna interessante quando o comitê de especialistas infere uma resposta a qual apresentou baixa saturação do neurônio de saída, por exemplo, valores abaixo de 0,5, ou quando o comitê de especialistas apresenta mais de uma resposta com alta saturação dos neurônios de saída, neste caso pode-se ativar mais de um membro do comitê caso as classes com alta saturação sejam de membros diferentes no comitê hierárquico.

Referências Bibliográficas

- [1] SHAFFER, A. “The Challenge of Technological Superiority.” *Defense AT&L*, v. 44, n. 4, pp. 8 – 10, 2015. ISSN: 15475476. Disponível em: <<http://search.ebscohost.com/login.aspx?direct=true&db=mth&AN=103367237&lang=pt-br&site=ehost-live>>. Acesso em 20 de dezembro de 2019.
- [2] KENDALL, F. “Manufacturing Innovation and Technological Superiority.” *Defense AT&L*, v. 45, n. 5, pp. 2 – 4, 2016. ISSN: 15475476. Disponível em: <<http://search.ebscohost.com/login.aspx?direct=true&db=mth&AN=117882744&lang=pt-br&site=ehost-live>>. Acesso em 25 de janeiro de 2019.
- [3] JONES, G. “How France helped us win Falklands war, by John Nott”, *The Telegraph*, Mar 2002. Disponível em: <<https://www.telegraph.co.uk/news/uknews/1387576/How-France-helped-us-win-Falklands-war-by-John-Nott.html>>. Acesso em 02 de fevereiro de 2019.
- [4] *Livro Branco de Defesa Nacional*. 1 ed. Brasil, Ministério da Defesa, 2012.
- [5] WAITE, A. D. *Sonar for Practising Engineers*. Wiley, 2002.
- [6] URICK, R. J. *Principles of Underwater Sound*. McGraw-Hill Book Company, 1983.
- [7] MAAS, A., HOOIJMAIJERS, H. *Scientific Research in World War II - What scientists did in the war*. Routledge Studies in Modern History, 2009.
- [8] UCHÔA, C. A. B. *Contribuições ao Desenvolvimento de um Perfilador Acústico de Correntes Oceânicas*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 1995.
- [9] NUNES DE MOURA, N. *Conformação Adaptativa de Feixes Aplicada a Sinais Sonar de Banda Larga*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 1997.

- [10] FELZKY, M. A. *Uma Contribuição às Técnicas de Localização de Fontes Sonoras Através de Sonar Passivo Utilizando Filtros Fracionários*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 2007.
- [11] VIEIRA DE MATTOS, E. *Limitação imposta pela Reverberação na Detecção Sonar Ativa em Águas Rasas*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 1981.
- [12] VERAS CARDOSO, S. *Sistema Digital de Telefonia Acústica Submarina*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 2014.
- [13] SOARES FILHO, W. *Classificação do Ruído Irrradiado por Navios Usando Redes Neurais*. Tese de doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil, 2001.
- [14] DAMAS PAULA, M. *Estudo de Tons e Suas Características para Utilização em um Classificador de Navios Baseado em Redes Neurais*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 2007.
- [15] OLIVEIRA E SOUZA, J. A. B. F., SEIXAS, J. M. “Class-modular multi-layer perceptron networks for supporting passive sonar signal classification.” *IET Radar Sonar Navigation*, v. 10, pp. 311 – 317, 2016. ISSN: 1751-8784. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=7397068>>. Acesso em 23 de fevereiro de 2019.
- [16] HAYKIN, S. *Neural Networks: A Comprehensive Foundation (3rd Edition)*. Upper Saddle River, NJ, USA, Prentice-Hall, Inc., 2007. ISBN: 0131471392.
- [17] ZHOU, Z.-H. *Ensemble Methods: Foundations and Algorithms*. Chapman & Hall/CRC, 2012. ISBN: 1439830037, 9781439830031.
- [18] AINSLIE, M. A. *Principles of Sonar Performance Modeling*. Springer, 2010. ISBN: 978-3-540-87661-8. doi: 10.1007/978-3-540-87662-5.
- [19] “Undewater Noise: Quality Status Report 2010, figura 9.13 (baseada na imagem original de Coates, 2002 ©Seiche Ltd. 2006)”. Disponível em: <<http://www.ospar.org/work-areas/eiha/noise>>. Acesso em 03 de fevereiro de 2019.
- [20] FERGUSON, B. G., CAREVIC, D. “Optimal spatial filtering of real data from submarine sonar arrays”. In: *in Proceedings of the OCEANS*, Sydney, Austrália, 2010. IEEE. doi: 10.1109/OCEANSSYD.2010.5603580.

- [21] KOIVULA, T., ELLMAN, A., VILENIUS, M. “Experiences on cavitation detection methods”. In: *in Proceedings of the XVI IMEKO World Congress, Vienna, Austria*, pp. 49–54, 2000. Acesso em 03 de junho de 2018.
- [22] NEVES JÚNIOR, I. P. *Classificação de Alvos de Sonar Passivo Utilizando Redes Neurais*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 1995.
- [23] PEARSON, K. “On Lines and Planes of Closest Fit to Systems of Points in Space”, *Philosophical Magazine*, v. 2, n. 6, pp. 559–572, 1901. Disponível em: <<http://stat.smmu.edu.cn/history/pearson1901.pdf>>. Acesso em 18 de janeiro de 2019.
- [24] SANGER, T. D. “Optimal Unsupervised Learning in a Single-Layered Linear Feedforward Neural Network.” *Neural Networks*, v. 2, pp. 459–473, 1989.
- [25] CHIN-HSING, C., JIANN-DER, L., MING-CHI, L. “Classification of underwater signals using wavelet transforms and neural networks”, *Mathematical and Computer Modelling*, v. 27, n. 2, pp. 47 – 60, 1998. ISSN: 0895-7177. doi: [http://dx.doi.org/10.1016/S0895-7177\(97\)00259-8](http://dx.doi.org/10.1016/S0895-7177(97)00259-8). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0895717797002598>>. Acesso em 08 de dezembro de 2018.
- [26] STRUZINSKI, W. A., LOWE, E. D. “A performance comparison of four noise background normalization schemes proposed for signal detection systems”, *Acoustical Society of America*, v. 76, n. 6, pp. 1738 – 1742, 1984.
- [27] KRAMER, M. “Nonlinear Principal Component Analysis using Autoassociative Neural Networks.” *AICHE*, v. 37, pp. 365 – 375, 1991.
- [28] CALÔBA, L., PEREIRA, F. S., SEIXAS, J. M. “Neural Discriminating Analysis for a Second-Level Trigger System”. In: *Proceedings of the International Conference on Computing in High Energy Physics*, Rio de Janeiro, RJ, Brasil, 1995.
- [29] DUDA, R. O., HART, P. E., STORK, D. G. *Pattern Classification*. Wiley, 2001.
- [30] DE MOURA JUNIOR, N. N., DE SEIXAS, J. M. “Novelty Detection in Passive SONAR Systems using Support Vector Machines”. In: *Computational Intelligence (LA-CCI), 2015 Latin America Congress on*. IEEE, 2015. doi: 10.1109/LA-CCI.2015.7435957.

- [31] HOWELL, B., WOOD, S. “Passive sonar recognition and analysis using hybrid neural networks”. In: *In Proceedings of the OCEANS*, v. 4, pp. 1917–1924. IEEE, 2003.
- [32] LOPES DOS SANTOS, F. *Auxílio à Classificação Sonar Passiva por Tons Característicos*. Dissertação de mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil, 2005.
- [33] DOS ANJOS, A., TORRES, R., SEIXAS, J., et al. “Neural triggering system operating on high resolution calorimetry information”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 559, n. 1, pp. 134–138, 2006. ISSN: 0168-9002. doi: <https://doi.org/10.1016/j.nima.2005.11.132>. Proceedings of the X International Workshop on Advanced Computing and Analysis Techniques in Physics Research.
- [34] DAS, A., KUMAR, A., BAHL, R. “Marine vessel classification based on passive sonar data: the cepstrum-based approach”, *IET Radar, Sonar and Navigation*, v. 7, pp. 438 – 441, 2013. ISSN: 1751-8784. doi: [10.1049/iet-rsn.2011.0142](https://doi.org/10.1049/iet-rsn.2011.0142).
- [35] JIANG, X., WANG, Q., ZENG, X. “Cavitation Noise Classification Based on Spectral Statistic Features and PCA Algorithm”, *3rd International Conference on Computer Science and Network Technology*, pp. 438 – 441, 2013.
- [36] NUNES DE MOURA, N. *Detecção e Classificação de Sinais de Sonar Passivo Usando Métodos de Separação Cega de Fontes*. Tese de doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil, 2013.
- [37] MEERPOHL, G., KRÜGER, T., TIESTE, R. “Verfahren und Vorrichtung zum Klassifizieren von Wasserfahrzeugen”. Fevereiro 2014. Disponível em: <http://www.google.st/patents/DE102012015638A1?cl=de&hl=pt-PT>. DE Patent App. DE201,210,015,638. Acesso em 02 de março de 2018.
- [38] ESCORCIA, J. R., PÉREZ, R. P., BAYONA, H., et al. “Acoustic Fingerprint Recognition Using Artificial Neural NetworksPolibits”, *Networks Polibits*, v. 50, pp. 69 – 73, 2014. ISSN: 1870-9044. Disponível em: <http://www.redalyc.org/articulo.oa?id=402640464011>. Acesso em 01 de fevereiro de 2019.

- [39] DINIZ, P. S. R., DA SILVA, E. A. B., LIMA NETO, S. *Digital Signal Processing: System Analysis and Design*. Cambridge University Press, 2002.
- [40] SPECHT, D. F. “Probabilistic Neural Networks”, *Neural Netw.*, v. 3, n. 1, pp. 109–118, Janeiro 1990. ISSN: 0893-6080. doi: 10.1016/0893-6080(90)90049-Q. Disponível em: <[http://dx.doi.org/10.1016/0893-6080\(90\)90049-Q](http://dx.doi.org/10.1016/0893-6080(90)90049-Q)>.
- [41] NORDEN. “The Hilbert-huang Transform And Its Applications”. cap. Introduction to the Hilbert-Huang Transform and Its Related Mathematical Problems, pp. 1–26, World Scientific, 2005.
- [42] WANG, S., ZENG, X. “Robust underwater noise targets classification using auditory inspired time–frequency analysis”, *Applied Acoustics*, v. 78, pp. 68 – 76, 2014. ISSN: 0003-682X. doi: <http://dx.doi.org/10.1016/j.apacoust.2013.11.003>. Disponível em: <[//www.sciencedirect.com/science/article/pii/S0003682X13002624](http://www.sciencedirect.com/science/article/pii/S0003682X13002624)>. Acesso em 16 de fevereiro de 2019.
- [43] YANG, L., CHEN, K. “AUDITORY CORTICAL REPRESENTATION AND ITS CLASSIFICATION FOR PASSIVE SONAR SIGNALS”, *21st International Congress on Sound and Vibration*, 2014.
- [44] PHAN, A.-H., CICHOCKI, A. “PARAFAC Algorithms for Large-scale Problems”, *Neurocomputing*, v. 74, pp. 1970–1984, 2011.
- [45] OLIVEIRA, R. L., DE LIMA, B. S., EBECKEN, N. F. “Multiway analysis in data SONAR classification”, *Mechanical Systems and Signal Processing*, v. 45, n. 2, pp. 531 – 541, 2014. ISSN: 0888-3270. doi: <http://dx.doi.org/10.1016/j.ymsp.2013.11.008>. Disponível em: <[//www.sciencedirect.com/science/article/pii/S0888327013006353](http://www.sciencedirect.com/science/article/pii/S0888327013006353)>. Acesso em 03 de janeiro de 2019.
- [46] BRO, R., KIERS, H. A. L. “A new efficient method for determining the number of components in PARAFAC model”, *J. Chemometrics*, , n. 17, pp. 274–286, 2003.
- [47] VAHIDPOUR, V., RASTEGARNIA, A., KHALILI, A. “An automated approach to passive sonar classification using binary image features”, *Journal of Marine Science and Application*, v. 14, n. 3, pp. 327–333, 2015. ISSN: 1993-5048. doi: 10.1007/s11804-015-1312-z. Disponível em: <<http://dx.doi.org/10.1007/s11804-015-1312-z>>. Acesso em 21 de fevereiro de 2019.

- [48] LEAL, N., LEAL, E., SANCHEZ, G. “Marine Vessel Recognition by Acoustic Signature”, *ARPJ Journal of Engineering and Applied Sciences*, v. 10, n. 20, pp. 9633–9639, Novembro 2015. ISSN: 1819-6608.
- [49] NOHA, K. “Application of wavelet transform for classification of underwater acoustic signals”. In: *in Proceedings of the 22nd International Congress on Acoustics*, Buenos Aires, Argentina, Setembro 2016. Disponível em: <<http://www.ica2016.org.ar/ica2016proceedings/ica2016/ICA2016-0262.pdf>>. Acesso em 10 de fevereiro de 2019.
- [50] DAVIS, S., MERMELSTEIN, P. “Comparison of Parametric Representations for Monosyllabic Word Recognition in Continuously Spoken Sentences”, *IEEE Transactions Acoust., Speech, Signal Processing*, v. 28, n. 4, pp. 357–366, 1980.
- [51] BARBOSA, B. H. G. *Computação Evolucionária e Máquinas de Comitê na Identificação de Sistemas Não-Lineares*. Tese de doutorado, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil, 2009.
- [52] DIETTERICH, T. G. “Ensemble methods in machine learning”. In: *In Proceedings of the 1st International Workshop on Multiple Classifier Systems*, pp. 1–15, Sardenha, Itália, 2000.
- [53] HANSEN, L. K., SALAMON, P. “Neural networks ensembles”, *IEEE Transactions Patterns Anal. Machine Intelligence*, v. 12, n. 10, pp. 993–1001, 1990.
- [54] BROWN, G. *Diversity in Neural Network Ensembles*. Tese de doutorado, Universidade de Birmingham, Birmingham, Reino Unido, 2004.
- [55] BREIMAN, L. “Bagging predictors”, *Machine Learning*, v. 24, n. 2, pp. 123–140, 1996.
- [56] SCHAPIRE, R. E. “The Strength of Weak Learnability”, *Machine Learning*, v. 5, n. 2, pp. 197–227, 1990. doi: 10.1007/bf00116037.
- [57] BREIMAN, L. “Random Forests”, *Machine Learning*, v. 45, n. 1, pp. 5–32, 2001.
- [58] YANG, P., YANG, Y. H., ZHOU, B. B., et al. “A review of ensemble methods in bioinformatics”, *Current Bioinformatics*, v. 5, n. 4, pp. 296–308, 2010.
- [59] QUINLAN, J. R. *C4.5: Programs for Machine Learning*. San Francisco, USA, Morgan Kaufmann Publishers Inc., 1993. ISBN: 1-55860-238-0.

- [60] HALL, M., FRANK, E., HOLMES, G., et al. “The WEKA Data Mining Software: An Update”, *SIGKDD Explor. Newsl.*, v. 11, n. 1, pp. 10–18, novembro 2009. ISSN: 1931-0145. doi: 10.1145/1656274.1656278. Disponível em: <<http://doi.acm.org/10.1145/1656274.1656278>>. Acesso em 18 de janeiro de 2019.
- [61] COELHO, G. P. *Geração, Seleção e Combinação de Componentes para Ensembles de Redes Neurais Aplicadas a Problemas de Classificação*. Dissertação de mestrado, UNICAMP, Campinas, Brasil, 2006.
- [62] NEWMAN, D., HETTICH, S., BLAKE, C., et al. “UCI repository of machine learning databases”, Disponível em: <<http://www.ics.uci.edu/~mllearn/MLRepository.html>>. Acesso em 28 de janeiro de 2017.
- [63] DE CASTRO, L. N., TIMMIS, J. “An artificial immune network for multimodal function optimization”. In: *in Proceedings of the IEEE Congress on Evolutionary Computation*, pp. 674–699, Havaí, EUA, 2002.
- [64] PATEL, M. C., PANCHAL, M., BHAVSAR, H. P. “Decorate Ensemble of Artificial Neural Networks with High Diversity for Classification”, *International Journal of Computer Science and Mobile Computing*, v. 2, pp. 134 – 138, 2013. ISSN: 2320–088X. Disponível em: <<http://www.ijcsmc.com/docs/papers/May2013/V2I5201345.pdf>>. Acesso em 04 de março de 2019.
- [65] MELVILLE, P., MOONEY, R. J. “Constructing Diverse Classifier Ensembles Using Artificial Training Examples”. In: *Proceedings of the 18th International Joint Conference on Artificial Intelligence, IJCAI’03*, pp. 505–510, San Francisco, CA, USA, 2003. Morgan Kaufmann Publishers Inc. Disponível em: <<http://dl.acm.org/citation.cfm?id=1630659.1630734>>. Acesso em 02 de março de 2019.
- [66] RAHMAN, A., TASNIM, S. “Ensemble Classifiers and Their Applications: A Review”, *CoRR*, v. abs/1404.4088, 2014. Disponível em: <<http://arxiv.org/abs/1404.4088>>. Acesso em 19 de fevereiro de 2019.
- [67] KIM, K.-J., CHO, S.-B. “Meta-classifiers for High-dimensional, Small Sample Classification for Gene Expression Analysis”, *Pattern Anal. Appl.*, v. 18, n. 3, pp. 553–569, agosto 2015. ISSN: 1433-7541. doi: 10.1007/s10044-014-0369-7. Disponível em: <<http://dx.doi.org/10.1007/s10044-014-0369-7>>. Acesso em 23 de fevereiro de 2019.

- [68] GOODFELLOW, I., BENGIO, Y., COURVILLE, A. *Deep Learning*. MIT Press, 2016.
- [69] SHAHAM, U., CHENG, X., DROR, O., et al. “A Deep Learning Approach to Unsupervised Ensemble Learning”, *ArXiv e-prints*, fevereiro 2016. Acesso em 03 de janeiro de 2019.
- [70] SCHMIDHUBER, J. “Deep learning in neural networks: An overview”, *Neural Networks*, v. 61, pp. 85 – 117, 2015. ISSN: 0893-6080. doi: <http://dx.doi.org/10.1016/j.neunet.2014.09.003>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0893608014002135>>. Acesso em 04 de março de 2019.
- [71] HINTON, G. E., SALAKHUTDINOV, R. R. “A Better Way to Pre-train Deep Boltzmann Machines”. In: Pereira, F., Burges, C. J. C., Bottou, L., et al. (Eds.), *Advances in Neural Information Processing Systems 25*, Curran Associates, Inc., pp. 2447–2455, 2012. Disponível em: <http://papers.nips.cc/paper/4610-a-better-way-to-pretrain-deep-boltzmann-machines.pdf>>. Acesso em 04 de dezembro de 2018.
- [72] PARISI, F., STRINO, F., NADLER, B., et al. “Ranking and combining multiple predictors without labeled data”, *Proceedings of the National Academy of Sciences*, v. 111, n. 4, pp. 1253–1258, janeiro 2014. ISSN: 1091-6490. doi: 10.1073/pnas.1219097111. Disponível em: <http://dx.doi.org/10.1073/pnas.1219097111>>. Acesso em 02 de março de 2019.
- [73] WELINDER, P., BRANSON, S., PERONA, P., et al. “The Multidimensional Wisdom of Crowds”. In: Lafferty, J. D., Williams, C. K. I., Shawe-Taylor, J., et al. (Eds.), *Advances in Neural Information Processing Systems 23*, Curran Associates, Inc., pp. 2424–2432, 2010. Disponível em: <http://papers.nips.cc/paper/4074-the-multidimensional-wisdom-of-crowds.pdf>>. Acesso em 15 de janeiro de 2019.
- [74] JAFFE, A., FETAYA, E., NADLER, B., et al. “Unsupervised Ensemble Learning with Dependent Classifiers”. In: *in Proceedings of the 19th International Conference on Artificial Intelligence and Statistics*, v. 31, Cadiz, Espanha, 2016. Disponível em: <http://www.jmlr.org/proceedings/papers/v51/jaffe16.pdf>>. Acesso em 03 de novembro de 2018.

- [75] EWING, ADAM D, H. K. E. H. Y. E. K. C. C. Y. T. N. B. J. C. P. C. W. D. S. V. Y. “Combining tumor genome simulation with crowdsourcing to benchmark somatic single-nucleotide-variant detection”, *Nature methods*, v. 12, n. 7, pp. 623–630, 2015. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4856034/>>. Acesso em 02 de março de 2019.
- [76] BAHAR, P., ALKHOULI, T., PETER, J.-T., et al. “Empirical Investigation of Optimization Algorithms in Neural Machine Translation”. In: *Conference of the European Association for Machine Translation*, pp. 13–26, Praga, República Tcheca, Junho 2017.
- [77] KINGMA, D. P., BA, J. “Adam: A Method for Stochastic Optimization”, *CoRR*, v. 1412.6980, 2014.
- [78] “Wikipedia: the free encyclopedia”. Disponível em: <https://en.wikipedia.org/wiki/Main_Page>. Acesso em 02 de março de 2019.