

UM MAPEAMENTO NÃO-LINEAR EM DIVERSAS CAMADAS PARA A DETECÇÃO DE NOVOS CONTATOS EM SISTEMAS DE CLASSIFICAÇÃO DE SONAR PASSIVO

VINÍCIUS DOS SANTOS MELLO* NATANAEL NUNES DE MOURA JUNIOR* JOSÉ MANOEL DE SEIXAS*

**Laboratório de Processamento de Sinais
Universidade Federal do Rio de Janeiro
Av. Horácio Macedo 2030, 21941-914, Rio de Janeiro, Brasil*

Email: `viniciusdsmello@lps.ufrj.br` `natmourajr@lps.ufrj.br` `seixas@lps.ufrj.br`

Abstract— Advances in naval technology development have made ship noise less intense, and because of this, their detection by passive sonar systems have become a challenging task, therefore, automatic classification systems of contacts become more a must. These systems are subjected to operate on signals that were not available at the time of their development so that they must comprise some sort of novelty detectors. Deep Learning consists of a set of techniques that use several ways to access information contained in the input data, and one of these is the application of successive non-linear transformations that can produce different levels of abstraction. Stacked Autoencoders are an example of this approach and initialize the weights of a deep neural network in an unsupervised way. In this article, the impact of non-linear mapping based on Stacked Autoencoders (SAE) in a novelty detector developed for an automatic passive sonar signal classification system will be evaluated. For this, experimental data acquired from the Brazilian Navy will be used for the development of novelty detectors based on deep neural networks. Each of the deep models was initialized with weights extracted from Stacked Autoencoders trained on the same database. The obtained results will be compared to previous results from novelty detectors based on artificial neural networks.

Keywords— Passive Sonar Systems, Machine Learning, Novelty Detection, Deep Learning

Resumo— Avanços no desenvolvimento de tecnologia naval têm tornado o ruído irradiado por navios cada vez menos intenso e, devido a isso, a sua detecção por sistemas de sonar passivo se tornou uma tarefa desafiadora, por isso, sistemas de classificação automática de contatos se fazem necessários nesse ambiente. Estes sistemas estão sujeitos a operar em sinais que não estavam disponíveis no momento do seu desenvolvimento; deste modo, estes sistemas devem conter detectores de novidade. O aprendizado profundo consiste em um conjunto de técnicas que utilizam diversas maneiras para acessar informações contidas nos dados de entrada, e uma destas é a aplicação de sucessivas transformações não-lineares que possam produzir diferentes níveis de abstração. Os *Stacked Autoencoders* (SAE) são um exemplo desta aplicação e inicializam os pesos de uma rede profunda de maneira não-supervisionada. Neste artigo, o impacto do mapeamento não-linear baseado em SAEs em um detector de novidade desenvolvido para um sistema de classificação automática em sinais de sonar passivo será avaliado. Para isso, dados experimentais adquiridos junto a Marinha do Brasil serão utilizados para o desenvolvimento de detectores de novidade baseado em redes neurais profundas. Cada um dos modelos profundos foi inicializado com pesos extraídos de SAEs que são treinados sobre a mesma base de dados. Os resultados obtidos serão comparados com os resultados de detectores de novidade baseados em redes neurais artificiais rasas, previamente desenvolvidos.

Palavras-chave— Sistemas de Sonar Passivo, Aprendizado de Máquina, Detecção de Novidade, Aprendizado Profundo

1 Introdução

Aplicações no ambiente submarino, geralmente, utilizam ondas mecânicas, como o som, para acessar informações em sua operação (Urick, 1983). Em operações navais, o som pode ser utilizado em diferentes frentes, como o levantamento da distância ao fundo, a detecção e classificação de ameaças e a comunicação submarina (Hodges, 2011). No entanto, o oceano é um ambiente bastante ruidoso, e assim, torna-se necessária a utilização de técnicas de processamento de sinais a fim de extrair as informações úteis dos sinais sonoros.

O conjunto de técnicas que utiliza o som para a extração de informações no ambiente submarino é chamado de Sonar (**S**ound **N**avigation **A**nd **R**anging) e este pode operar de duas maneiras: ativa e passiva. Na primeira, um pulso sonoro contendo multifrequência é emitido, e seu eco é

utilizado para localizar e classificar possíveis alvos, enquanto na segunda, não há emissão de sinais (Ainslie, 2010). Submarinos militares, comumente, utilizam sistemas de sonar passivo, devido a questões estratégicas, pois estes não expõem sua posição ao realizar tarefas de monitoramento, detecção e classificação (Maranda, 2008).

O Sistema de Sonar Passivo pode adquirir sinais provenientes de navios não disponíveis durante o período de desenvolvimento do sistema de classificação automática. Como estes navios possuem assinaturas sonoras que podem ser similares às dos exemplos pertencentes às classes conhecidas, a eficiência de classificação pode ser afetada. Assim sendo, torna-se necessário o emprego de detectores de novidades, que possam operar em conjunto com o sistema de classificação para aumentar a eficiência do mesmo (Knight et al., 1981). O objetivo principal dos detectores de novidade

é identificar padrões que não tenham participado do processo de desenvolvimento do modelo (Hodge and Austin, 2004).

A detecção de novidade tem recebido atenção crescente em aplicações envolvendo sistemas críticos que processam um grande conjunto de dados (Hodge and Austin, 2004). Isso inclui detecção de anomalias e falhas em sistemas industriais, detecção de fraudes em cartões de crédito, além de aplicações em outros domínios (Pimentel et al., 2014). Em sistemas críticos, em geral, a classe conhecida é majoritária em relação à classe desconhecida, devido à baixa frequência de ocorrência de eventos de classe novidade. Diversas são as técnicas encontradas no estado da arte para problemas de detecção de novidade (Pimentel et al., 2014), como o emprego de máquinas de vetor de suporte (SVM) (Ramyar et al., 2016), redes neurais artificiais (Soares-Filho et al., 2002), K-vizinhos mais próximos (kNN) (Hautamaki et al., 2004) e modelos escondidos de Markov (Zhang et al., 2003).

O aprendizado profundo é um conjunto de técnicas de aprendizado de máquina que possibilitam a tomada de decisões em níveis mais altos de abstração (Goodfellow et al., 2016). Esse conjunto de técnicas se baseia no treinamento de redes neurais profundas, que são modelos com mais camadas do que o habitual e que, por isso, possuem mais parâmetros a serem ajustados, sendo assim, mais complexos. Desse modo, devido ao aumento de complexidade dos modelos, é possível aumentar, a capacidade de discriminação, embora também aumente a probabilidade de perda de generalização (Schmidhuber, 2015).

Recentemente, algumas técnicas foram criadas para possibilitar o treinamento destes modelos sem a perda da generalização (Bengio et al., 2007; Srivastava et al., 2014). Devido a isso, o aprendizado profundo tem recebido crescente atenção em pesquisas de diferentes áreas, sendo encontrados trabalhos empregando suas técnicas na detecção de novidades. Em (Yan and Yu, 2015) é proposto a aplicação de um detector de anomalias, baseado em *Stacked Denoising Autoencoders*, para combustores de turbinas de gás, e em (Erfani et al., 2016) é encontrada uma aplicação de *Deep Belief Networks* para realizar a extração de características e, posteriormente, alimentar um modelo baseado em máquinas de vetor de suporte de uma classe para problemas de alta dimensionalidade.

Atualmente, sistemas de sonar passivo tem utilizado técnicas de aprendizado de máquina (Komari Alaie and Farsi, 2018). Em (Moura-Junior and Seixas, 2015), a Análise de componentes principais (PCA) foi utilizada para realizar uma compactação dos dados e, posteriormente, alimentar um modelo baseado em SVM de uma classe para encapsular os dados conhecidos, fazendo assim a detecção de novidade. Em (Soares-Filho et al., 2002), a técnica de compo-

nentes de discriminação (PCD) foi utilizada para pré-processar os dados de sonar antes de alimentar uma rede neural artificial do tipo *MLP* e uma rede Art. Além desses, em (Moura-Junior et al., 2017) SAE são utilizados para inicializar os pesos de um classificador em uma rede neural profunda.

O objetivo deste trabalho é avaliar os impactos provocados por mapeamentos não-lineares em diversas camadas, na detecção de novidades em sistemas de sonar passivo. Sendo assim, foram utilizados dados experimentais fornecidos pelo Instituto de Pesquisas da Marinha (IPqM), buscando, em primeiro lugar, encontrar o número ótimo de camadas capaz de detectar efetivamente eventos de classes desconhecidas. Para avaliação da técnica proposta, foram realizadas comparações com resultados obtidos em (Soares-Filho et al., 2002), obtidos a partir da utilização de redes neurais rasas.

O artigo é organizado da seguinte forma: primeiro, na Seção 2 será realizada uma descrição do Sistema de Sonar Passivo. Em sequência, na Seção 3, é feita uma descrição de Detecção de Novidades e as diferentes formas de abordagem. Na Seção 4 é explicada a metodologia utilizada. Finalmente, na Seção 5, os resultados experimentais obtidos são analisados e, por fim, serão apresentadas as conclusões na Seção 6.

2 Sistema de Sonar Passivo

Os dados de sonar passivo consistem de sinais adquiridos por transdutores chamados hidrofones. Cada hidrofone recebe sinais de maneira omnidirecional, fazendo-se assim, necessária a aplicação de métodos de conformação de feixes. Estes métodos são responsáveis pela organização dos sinais levando em consideração os atrasos provenientes da posição de cada um dos transdutores e, também, da direção de chegada dos sinais de interesse.

Uma vez que, em uma dada DOA, é detectado um sinal de interesse, o sinal conformado é utilizado para alimentar a chamada análise LO-FAR (Figura 1) (Li, 2012). Nesta análise, que é uma análise de banda larga, o sinal no domínio do tempo é, inicialmente, decimado de um fator Θ . Neste bloco de decimação, estão contemplados dois processos separados, o primeiro é um processo de filtragem, que foi realizado com um filtro de resposta ao impulso finita e o segundo é a retirada das amostras espaçadas de θ amostras. Com o sinal decimado, aplica-se então um processo de janelamento dos sinais, através da janela de Hanning e a transformação dos sinais para o domínio das frequências através da DFT. Os sinais foram janelados para o processamento devido a característica não estacionária do sinal proveniente dos navios de interesse.

Com o sinal no domínio da frequência, é aplicada a função módulo ao seu espectro e uma esti-




Figura 1: Diagrama de blocos para a análise LOFAR.

mativa do ruído de fundo do módulo do espectro é feita através do algoritmo TPSW (*two-pass split window*) com parâmetros estabelecidos em trabalhos anteriores (Soares-Filho et al., 2002). Este algoritmo foi utilizado pois os dados de sonar passivo apresentam informações concentradas em baixas frequências e, estas são acessadas de maneira mais eficiente por este método.

O resultado da aplicação desta análise aos dados é o chamado LOFARgrama, Figura 2. Este é um gráfico do tipo *waterfall* e pode ser visto integrado nos sistemas de sonar passivo utilizados nas operações da Marinha do Brasil. Neste gráfico, a medida que o tempo evolui, mais linhas compostas por informações frequenciais são adicionadas a parte superior, fazendo assim com que o gráfico também evolua, causando um efeito em cascata e gerando assim um gráfico tempo-frequência.




Figura 2: Resultado da análise LOFAR sob os dados no domínio do tempo.

3 Detecção de Novidade

Nesta aplicação, a detecção de novidades é a tarefa de identificação de dados que não estavam disponíveis durante o treinamento do modelo (Hodge and Austin, 2004; Pimentel et al., 2014). Ou seja, separar dados que apresentam uma alta medida de dissimilaridade em relação às classes utilizadas durante o processo de treinamento.

Diversas são as abordagens encontradas para problemas de detecção de novidade na literatura. Em (Hodge and Austin, 2004) são definidas as três abordagens fundamentais para o problema: (i)

detecção de novidades sem conhecimento prévio dos dados, tratando-se de uma abordagem não-supervisionada, (ii) modelagem de classes conhecidas e desconhecidas, configurando, assim uma abordagem supervisionada, (iii) modelagem apenas de dados previamente classificados como normais.

Outros autores, como em (Pimentel et al., 2014), classificam as técnicas de detecção de novidades em cinco categorias: (i) métodos probabilísticos, (ii) baseados em distância, (iii) baseados em reconstrução, (iv) baseados em domínio e (v) técnicas de teoria da informação. Dessa forma, para cada técnica o método utilizado para realizar a distinção entre classes normais e classes novidade varia.

A abordagem probabilística baseia-se em estimar a densidade de probabilidade (PDF) dos dados. Dessa forma, a partir da utilização de um limiar, que limita a fronteira da região de conhecimento, é possível distinguir se um evento na entrada do modelo pertence a região dos dados conhecidos, descrita pela PDF, ou não. As técnicas baseadas em distância, por outro lado, são embasadas em calcular a medida de similaridade entre pontos. As abordagens baseadas em reconstrução, englobam as redes neurais, e são, comumente, utilizadas em aplicações críticas de regressão e classificação. Elas consistem em modelar os dados disponíveis para treinamento. Deste modo, quando um evento não pertencente às classes conhecidas for apresentado ao modelo, este produzirá um erro de reconstrução, geralmente, definido como a distância entre o valor verdadeiro e o valor predito. Em contrapartida, a abordagem baseada em domínio consiste em encapsular os dados conhecidos, ou seja, o conhecimento a respeito dos dados, configurando-se, assim, numa forma supervisionada de aprendizado. Diferentemente das demais abordagens, a abordagem baseada nos métodos de teoria da informação calcula a informação contida no conjunto de dados através de medidas como entropia, entropia relativa, dentre outras.

4 Método

Para realizar a detecção de novidades no sistema de sonar passivo, é proposto o método representado pelo diagrama de blocos da Figura 3. Uma vez que os dados são obtidos no domínio do tempo os mesmos passam pela análise LOFAR, que os transforma para o domínio da frequência. No domínio das frequências, os dados passam por uma etapa de pré-processamento onde é realizada a extração de parâmetros dos *Autoencoders*. Após essa etapa, é realizada a etapa de treinamento dos classificadores que servirão também como detetores de novidade.




Figura 3: Etapas treinamento de um modelo baseado em *Stacked Autoencoders*.

4.1 Flutuações Estatísticas Consideradas

Em aplicações de sonar passivo, o conjunto de dados disponível dispõe, comumente, de uma pequena parte das possíveis classes de navios, ou porque novos navios são desenvolvidos e construídos, ou devido a confidencialidade dos dados dos navios de diferentes armadas. Para emular a detecção de novidades e acessar as flutuações estatísticas da proposta apresentada, cada classe disponível no conjunto de treinamento é selecionada para ser tratada como novidade, passando a ser desconhecida para esta aplicação, enquanto as demais são tratadas como classes conhecidas. Assim, serão realizadas n rodadas, onde n é o número de classes disponíveis no conjunto de dados, como ilustrado na Figura 4.

Rodada 1	Rodada 2	Rodada 3	Rodada 4
Classe A	Classe A	Classe A	Classe A
Classe B	Classe B	Classe B	Classe B
Classe C	Classe C	Classe C	Classe C
Classe D	Classe D	Classe D	Classe D

Figura 4: Processo de emulação de novidades com as classes existentes.

Além das diferentes rodadas realizadas, outra técnica utilizada para realização dos treinamentos dos modelos propostos foi a validação cruzada *jack knife*. Neste caso, se k -folds forem selecionados, o conjunto de dados é dividido aleatoriamente em k sub-conjuntos. A cada rodada de treinamentos, $k - 1$ conjuntos são utilizados para a extração de características e 1 conjunto avalia a generalização do treinamento. Ao final, a estimativa da incerteza do processo pode ser feita utilizando a média e a variância dos resultados obtidos com os *folds*.

4.2 Stacked Autoencoders

Um *Stacked Autoencoder* é um modelo neural com o objetivo de aprender representações de

um conjunto de dados e, comumente, é utilizado para redução de dimensionalidade (Hinton and Salakhutdinov, 2006) e, mais recentemente, para aprender modelos geradores de dados.

Sua arquitetura (Figura 5) é baseada na conexão entre *autoencoders*, onde esses são formados por um *encoder* e por um *decoder*. Ao passar pelo *encoder*, a dimensão do dado de entrada é reduzida e, ao passar esse resultado pelo *decoder*, este retorna para sua dimensão original.

O treinamento dessa arquitetura é realizado com um algoritmo conhecido como *layer-wise pre-training* (Bengio et al., 2007) e é classificado como não-supervisionado, correspondendo a um treinamento realizado em cada camada de *autoencoder*. Inicia-se treinando o primeiro *autoencoder* e, após treiná-lo, seus pesos são fixados e a saída de seu *encoder* será utilizada como entrada para o treinamento do próximo *autoencoder*. Após esse processo ser realizado até a última camada, pode ser feito um *fine-tuning* de pesos de uma rede neural MLP alimentada pelo SAE treinado utilizando alvos conhecidos e realizando uma retro propagação do erro alvo-saída, conhecido como *backpropagation* (LeCun et al., 2015).

Essa retropropagação do erro também é utilizada em redes neurais rasas. Porém, ao criar redes mais profundas, há uma tendência à convergência mais rápida dos pesos das camadas mais próximas à saída em relação aos pesos mais próximos à entrada. Com isso, redes mais profundas apresentam uma falha de generalização se treinadas somente com o *backpropagation*, tornando o treinamento ineficaz para classificação de novos dados. Dessa forma, o *layer-wise pretraining* tem o objetivo de iniciar os pesos da estrutura da rede neural a partir de valores que favoreçam a minimização do erro. Um outro ponto relevante desse pré-treinamento é uma possível extração de características do conjunto de dados.




Figura 5: Etapas treinamento de um modelo baseado em *Stacked Autoencoders*.

4.3 Figuras de Mérito

Com o objetivo de avaliar o erro de reconstrução de cada *autoencoder*, e, posteriormente, escolher a topologia do modelo, na etapa de *Pre-training*, duas Figuras de mérito são utilizadas:

a divergência de Kullback-Leibler (KLD), Equação 1, (Amari et al., 1996) a qual mede a quasil-distância entre duas densidade de probabilidade (P e Q) estimadas a partir do dado original (P) e sua reconstrução (Q), e Erro Médio Quadrático (MSE) entre a entrada i e sua reconstrução $\hat{i}$, Equação 2.

$$KL(P, Q) = \sum_i P_i \log_{10} \frac{P_i}{Q_i} \quad (1)$$

$$MSE = \frac{1}{N_{eventos}} \sum_{j=1}^{N_{eventos}} (i(j) - \hat{i}(j))^2 \quad (2)$$

Para a eficiência de classificação, na etapa de *fine-tuning*, eficiência de classificação de classes conhecidas (Equação 3) e acurácia de classificação de classes conhecidas (Equação 4) são utilizadas, além disso, em conjunto é utilizado o Índice SP - Soma-Produto - (Equação 5), o qual tem sido adotado em trabalhos anteriores, devido sua capacidade de mensurar a eficiência de classificação balanceada para um número grande de classes.

Em (Augusteijn and Folkert, 2002) foi utilizada uma detecção de novidade baseada em um limiar de excitação na camada de saída e, classifica um evento como novidade, se este não produzir excitações nos neurônios de saída superiores ao limiar escolhido. Esta mesma abordagem foi utilizada em (Soares-Filho et al., 2002), onde uma análise de limiares foi desenvolvida objetivando a detecção de novidade para um Sonar Passivo utilizando redes neurais. Assim, baseado na saída do modelo, a eficiência de classificação da classe k -th ($Eff_k(\theta)$) é obtida utilizando um limiar de classificação identificado por θ . Se algum dos neurônios de saída forem excitados acima do valor de θ é aplicada a regra de o vencedor leva tudo.

$$Eff_k(\theta) = \frac{eventos_k \text{ classificados corretamente}}{total \text{ de eventos}_k} \quad (3)$$

$$Acc(\theta) = \frac{\sum_{k=1}^{N_{classes}} Eff_k(\theta)}{N_{classes}} \quad (4)$$

$$SP(\theta) = \sqrt[2]{\left(\frac{\sum_{n=1}^N Eff_i(\theta)}{N} \cdot \sqrt[2]{\prod_{n=1}^N Eff_i(\theta)} \right)} \quad (5)$$

Foram apresentados eventos da classe novidade aos modelos treinados, e as saídas produzidas foram analisadas utilizando-se um limiar variável. Dessa forma, a eficiência de detecção de novidades foi estimada (Equação 6). Assim, $eventos_k \text{ novidade corretos}$ representa a quantidade de eventos da classe novidade corretamente identificados como novidade, enquanto

$total \text{ eventos novidade}_k$ representa o número total de eventos da classe novidade.

$$NoveltyDet.(\theta) = \frac{eventos_k \text{ novidade corretos}}{total \text{ eventos novidade}_k} \quad (6)$$

4.4 Escolha de topologia

Para escolha da melhor topologia, foi realizada variações de neurônios em cada *autoencoder* avaliando-se as figuras de mérito descritas na subseção 4.3. Além disso, ao encontrar um número ótimo de neurônios em cada *autoencoder* adicionava-se uma nova camada repetindo-se a variação de neurônios para analisar o impacto causado sob a eficiência do modelo ao elevar o nível de abstração.

5 Resultados Experimentais

Utilizando o método disposto anterior, os resultados experimentais foram obtidos com base nos dados disponibilizados pela Marinha do Brasil.

5.1 Dados Experimentais

Os dados deste trabalho correspondem a ruídos irradiados por diferentes navios que foram adquiridos pela Marinha do Brasil em diferentes cenários. O conjunto de dados utilizado é composto por 4 classes de navios que foram adquiridas na raia acústica de Arraial do Cabo. Os experimentos na raia acústica consistem em navios se movendo em um ambiente controlado pela MB com 1.500 metros de comprimento.

Geralmente, as gravações foram feitas com um único hidrofone que é acoplado a um sistema de aquisição que possui frequência de amostragem de 22.050 Hz e 8 bits de resolução. A gravação do experimento é feita quando o navio se encontra a 1.000 metros antes da posição do hidrofone e termina quando o navio se encontra a 500 metros depois da posição do hidrofone. A profundidade do hidrofone é de 45 metros.

Para comparação dos resultados, redes neurais artificiais foram treinadas para detecção de novidade utilizando como referências os resultados obtidos em (Soares-Filho et al., 2002).

5.2 Topologia dos Modelos

Diversas topologias foram treinadas como forma de se encontrar o melhor modelo de detecção de novidade. Para cada topologia, em cada uma das camadas, foi realizada uma variação do número de neurônios da mesma, avaliando-se a divergência KL entre os dados de entrada e a sua reconstrução na etapa de *Pre-training*, bem como o índice SP na etapa de *Fine-tuning*. A Figura 6 ilustra as

duas análises feitas para a primeira camada de um *autoencoder* cujo a classe novidade é a classe B. Como pode ser observado, os valores do índice SP apresentam pouca variação a partir de 200 neurônios, o que pode ser explicado por uma saturação nas eficiências de classificação de cada uma das classes conhecidas, além disso, a medida que os modelos se tornam mais complexos, a reconstrução da classe novidade apresenta um menor valor de divergência KL, ou seja, o modelo consegue reconstruir padrões desconhecidos no momento do seu treinamento. Sendo assim, foi adotado um critério de escolha baseado nos valores do índice SP, portanto, na figura em questão o número de neurônios foi de 400 e para as outras camadas e outras classes como novidade o mesmo critério foi adotado.




Figura 6: Análise de índice SP e divergência KL para uma variação de neurônios no primeiro *autoencoder*.

Modelo	Topologia
SAE_1	400-400-3
SAE_4	400-400-350-300-250-3
SAE_8	400-400-350-300-250-200-150-100-50-3

Tabela 1: Topologias selecionadas para detecção de novidades em Sistemas de Sonar Passivo (Topologias selecionadas de acordo com o critério descrito na seção 4.4).

5.3 Impacto de multicamadas

Após o treinamento de todos os modelos, foram realizadas análises para cada camada considerando as figuras de mérito apresentadas anteriormente para uma variação de limiares na camada de saída. As Figuras 7a, 7b e 7c apresentam os resultados das curvas de eficiência de classificação por classe, índice SP e detecção de novidade para a classe D como novidade utilizando as topologias

do SAE_1 , SAE_4 e SAE_8 , respectivamente. Pode ser observado nesta análise que conforme o valor do limiar é aumentado os valores de eficiência de classificação diminuem, indicando que os eventos conhecidos precisam excitar cada vez mais os neurônios de saída para serem identificados corretamente. Além disso, observa-se que os valores de detecção de novidade aumentam. Esta análise foi realizada para todos os modelos inicializados com SAE e teve como objetivo estimar o impacto produzido devido aos sucessivos mapeamentos não-lineares sobre a performance do modelo.

A partir da variação do limiar na saída do modelo é possível definir pontos de operação para o detector de novidade. Dessa forma, foi definido três pontos de operação: 25 %, 50 % e 75 % de detecção de novidade, a saber o primeiro ponto visa a classificação das classes conhecidas, o segundo ponto visa um meio termo entre classificação e detecção de novidade e o terceiro ponto tende a ser a operação em um ambiente onde a detecção de novidade é priorizada (os resultados apresentados nas Tabelas 2a, 2b e 2c, respectivamente). Sendo assim, é possível realizar uma comparação dos resultados obtidos para cada modelo treinado.

Tabela 2: Resultados experimentais para três pontos de operação distintos.

(a) Ponto de Operação para Classificação de Classes conhecidas (25% de Det. Novidade).


Classe Novidade	SAE_1	SAE_4	SAE_8
	SP	SP	SP
Classe A	78,75%	77,50%	73,25%
Classe B	80,00%	78,20%	70,00%
Classe C	81,25%	80,00%	68,75%
Classe D	81,25%	80,00%	70,00%

(b) Ponto de Operação intermediário (50% de Det. Novidade).


Classe Novidade	SAE_1	SAE_4	SAE_8
	SP	SP	SP
Classe A	55,75%	51,50%	40,00%
Classe B	57,50%	58,25%	48,75%
Classe C	55,00%	61,25%	50,00%
Classe D	61,25%	63,75%	50,00%

(c) Ponto de Operação para Detecção de Novidade (75% de Det. Novidade).


Classe Novidade	SAE_1	SAE_4	SAE_8
	SP	SP	SP
Classe A	30,00%	30,00%	23,75%
Classe B	43,50%	41,25%	28,75%
Classe C	48,75%	43,50%	37,50%
Classe D	47,50%	43,50%	43,50%



(a) Utilizando um modelo inicializado a partir dos pesos de uma camada de *autoencoder*.



(b) Utilizando um modelo inicializado a partir dos pesos de quatro camadas de *autoencoder*.



(c) Utilizando um modelo inicializado a partir dos pesos de oito camadas de *autoencoder*.

Figura 7: Resultados para detecção de novidade utilizando modelos inicializados a partir dos pesos de camadas de *autoencoders*.

É possível observar nestas tabelas que há uma sensibilidade do índice SP em relação a mudança de ponto de operação, isto é, em relação a eleva-

ção da detecção de novidade. Além disso, ocorre uma redução do índice SP ao aumentar o número de camadas escondidas, o que é causado devido ao aumento da exigência que os eventos precisam cumprir para representar bem a classe a qual estes pertencem.

Os resultados aqui obtidos podem ser comparados com os resultados obtidos em (Soares-Filho et al., 2002) com uma rede neural MLP, onde definindo-se também os mesmos três pontos de operação teríamos para o índice SP 95,3 % (25 % de detecção de novidade), 90,0 % (50 % de detecção de novidade) e 70,0 % (75 % de detecção de novidade). No entanto, em (Soares-Filho et al., 2002) é utilizado um pré-processamento nos dados voltado para elevar a eficiência de classificação, enquanto que neste trabalho é utilizado o dado bruto, sem pré-processamento, e uma técnica não-supervisionada.

6 Conclusões

Neste trabalho foi desenvolvido um detector de novidade para sistemas de sonar passivo de forma eficiente baseado em redes neurais profundas com inicialização dos pesos por *Stacked AutoEncoders*. Os dados experimentais foram processados pela análise LOFAR e os resultados foram obtidos com diferentes figuras de mérito.

Em comparação com trabalhos anteriores, a técnica do SAE demonstrou-se promissora, devido ao fato de que esta é vista como uma etapa de treinamento não-supervisionado. Além disso, foi observado que ao aumentar o número de camadas a detecção de novidade aumenta, no entanto, o modelo torna-se mais exigente dos eventos das classes conhecidas para que estes sejam classificados corretamente.

Como trabalhos futuros que podem ser citados a análise de diferentes formas de treinamento de *Stacked Autoencoders* e de outras estruturas de *Deep Learning* para a detecção de novidades em sistemas de sonar passivo. Por exemplo, as redes neurais recursivas (RNN), que são modelos que acessam a informação temporal diretamente durante o seu treinamento.

Agradecimentos

Os autores gostariam de agradecer à CAPES, CNPq e FAPERJ pelo suporte a este trabalho. E um agradecimento especial ao grupo de Sonar do Instituto de Pesquisas da Marinha (IPqM) por disponibilizar o conjunto de dados e por discussões frutíferas a respeito deste trabalho.

Referências

Ainslie, M. (2010). *Principles of Sonar Performance Modelling*, Springer-Verlag Berlin Hei-

- delberg.
- Amari, S.-i., Cichocki, A. and Yang, H. H. (1996). A new learning algorithm for blind signal separation, *Advances in neural information processing systems*, pp. 757–763.
- Augusteijn, M. and Folkert, B. (2002). Neural network classification and novelty detection, *International Journal of Remote Sensing* **23**(14): 2891–2902.
- Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H. (2007). Greedy layer-wise training of deep networks, *Advances in neural information processing systems*, pp. 153–160.
- Erfani, S. M., Rajasegarar, S., Karunasekera, S. and Leckie, C. (2016). High-dimensional and large-scale anomaly detection using a linear one-class svm with deep learning, *Pattern Recognition* **58**: 121–134.
- Goodfellow, I., Bengio, Y. and Courville, A. (2016). *Deep Learning*, MIT Press.
- Hautamaki, V., Karkkainen, I. and Franti, P. (2004). Outlier detection using k-nearest neighbour graph, *Proceedings of the Pattern Recognition, 17th International Conference on (ICPR'04) Volume 3 - Volume 03*, ICPR '04, IEEE Computer Society, Washington, DC, USA, pp. 430–433.
- Hinton, G. E. and Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks, *science* **313**(5786): 504–507.
- Hodge, V. and Austin, J. (2004). A survey of outlier detection methodologies, *Artif. Intell. Rev.* **22**(2): 85–126.
- Hodges, R. P. (2011). *Underwater acoustics: Analysis, design and performance of sonar*, John Wiley & Sons.
- Knight, W. C., Pridham, R. G. and Kay, S. M. (1981). Digital signal processing for sonar, *Proceedings of the IEEE* **69**(11): 1451–1506.
- Komari Alaie, H. and Farsi, H. (2018). Passive sonar target detection using statistical classifier and adaptive threshold, *Applied Sciences* **8**(1): 61.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning, *Nature* **521**(7553): 436–444.
- Li, Q. (2012). *Digital Sonar Design in Underwater Acoustics*, Springer-Verlag Berlin Heidelberg.
- Maranda, B. H. (2008). *Passive Sonar*, Springer New York, pp. 1757–1781.
- Moura-Junior, N. N., Mello, V. S., Cerqueira, L. A. and Seixas, J. M. (2017). Classificação de sinais de sonar passivo utilizado stacked autoencoders, *2017 XIII Brazilian Congress on Computational Intelligence (CBIC)*.
- Moura-Junior, N. N. and Seixas, J. M. (2015). Novelty detection in passive sonar systems using support vector machines, *2015 Latin America Congress on Computational Intelligence (LA-CCI)*.
- Pimentel, M. A., Clifton, D. A., Clifton, L. and Tarassenko, L. (2014). A review of novelty detection, *Signal Processing* **99**: 215 – 249.
- Ramyar, S., Homaifar, A., Karimoddini, A. and Tunstel, E. (2016). Identification of anomalies in lane change behavior using one-class svm, *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 004405–004410.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview, *Neural Networks* **61**(Supplement C): 85 – 117.
- Soares-Filho, W., Seixas, J. M. and Caloba, L. P. (2002). Enlarging neural class detection capacity in passive sonar systems, *2002 IEEE International Symposium on Circuits and Systems. Proceedings (Cat. No.02CH37353)*.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting., *Journal of machine learning research* **15**(1): 1929–1958.
- Urick, R. (1983). *Principles of Underwater Sound for Engineers*, McGraw-Hill.
- Yan, W. and Yu, L. (2015). On accurate and reliable anomaly detection for gas turbine combustors: A deep learning approach, *Proceedings of the annual conference of the prognostics and health management society*.
- Zhang, X., Fan, P. and Zhu, Z. (2003). A new anomaly detection method based on hierarchical hmm, *Parallel and Distributed Computing, Applications and Technologies, 2003. PDCAT'2003. Proceedings of the Fourth International Conference on*, IEEE, pp. 249–252.